UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM CONTROLADORIA E CONTABILIDADE

Marcio Kawahara Iguma

Big Data Analytics e a evolução das práticas de Auditoria Interna: um estudo sobre os antecedentes da aceitação e adoção da tecnologia no setor privado brasileiro

São Paulo

2019

Prof. Dr. Vahan Agopyan
Reitor da Universidade de São Paulo

Prof. Dr. Fábio Frezatti
Diretor da Faculdade de Economia, Administração e Contabilidade

Prof. Dr. Valmor Slomski
Chefe do Departamento de Contabilidade e Atuária

Prof. Dr. Lucas Ayres Barreira de Campos Barros
Coordenador do Programa de Pós-Graduação em Controladoria e Contabilidade

MARCIO KAWAHARA IGUMA

Big Data Analytics e a evolução das práticas de Auditoria Interna: um estudo sobre os antecedentes da aceitação e adoção da tecnologia no setor privado brasileiro

Dissertação apresentada ao Programa de Pós-Graduação em Controladoria e Contabilidade do Departamento de Contabilidade da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, como requisito parcial para a obtenção do título de Mestre em Ciências.

Área de concentração: Contabilidade e Controladoria

Orientador: Prof. Dr. Edson Luiz Riccio

Versão Corrigida

(versão original disponível na Biblioteca da Faculdade de Economia, Administração e Contabilidade)

São Paulo

2019

Catálogo na Publicação (CIP)
Ficha Catalográfica com dados inseridos pelo autor

Iguma, Marcio Kawahara.

Big Data Analytics e a evolução das práticas de Auditoria Interna: um estudo sobre os antecedentes da aceitação e adoção da tecnologia no setor privado brasileiro / Marcio Kawahara Iguma. - São Paulo, 2019.

173 p.

Dissertação (Mestrado) - Universidade de São Paulo, 2020.

Orientador: Edson Luiz Riccio.

1. Auditoria Interna. 2. Big Data Analytics. 3. UTAUT. I. Universidade de São Paulo. Faculdade de Economia, Administração e Contabilidade. II. Título.

Nome: Iguma, Marcio Kawahara

Título: Big Data Analytics e a evolução das práticas de Auditoria Interna: um estudo sobre os antecedentes da aceitação e adoção da tecnologia no setor privado brasileiro

Dissertação apresentada ao Programa de Pós-Graduação em Controladoria e Contabilidade do Departamento de Contabilidade da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, como requisito parcial para a obtenção do título de Mestre em Ciências.

Aprovado em:

Banca Examinadora

Prof. Dr. _____

Instituição: _____

Julgamento: _____

Prof. Dr. _____

Instituição: _____

Julgamento: _____

Prof. Dr. _____

Instituição: _____

Julgamento: _____

AGRADECIMENTOS

Ao Deus Supremo e Fiel, porque d'Ele, por meio d'Ele, e para Ele são todas as coisas. A Ele toda honra, toda glória e todo o louvor.

À minha amada esposa Adriana pelo seu apoio incondicional, companheirismo e compreensão desde a decisão de encarar o desafio do mundo acadêmico. À nossa princesinha Anne Yuri, presente de Deus, que nos trouxe muitas alegrias. Aos meus pais Taeko e Takeo pelo suporte, cuidado e exemplo de caráter. Aos meus sogros Nair e Osvaldo, e à Michele pelo apoio e incentivo.

Ao Prof. Dr. Edson Luiz Riccio por ter aceitado o meu convite de orientação, pela sua atenção, direcionamento e apoio durante a minha trajetória no mestrado. Aos professores da banca do exame de qualificação, Prof. Dr. Napoleão Galegale, Prof. Dr. Washington Lopes e Prof. Dr. Adilson Yoshikumi pelas críticas, recomendações e contribuições para o enriquecimento do estudo. Aos membros da comissão julgadora de defesa da dissertação, Prof. Dr. Andson Braga de Aguiar (presidente), Prof. Dr. Jose Dutra de Oliveira Neto, Prof. Dr. Napoleão Galegale e Prof. Dr. Joshua Imoniana.

Aos meus amigos e colegas de mestrado e doutorado, em especial a Robson Pereira, Vitor Nasu, Cristiane de Almeida, Flavio Riberi, Laura Salvagnin, Tassiani Santos e Julio Cesar Rodrigues. Aos amigos Wesley Augusto Borges, Alexandre Moysés Nascimento, Rafael Vieira, Ricardo Tashiro, Claudia Maki Yanagihara e Prof. Dr. Jurandir Itzo Yanagihara que muito contribuíram para o estudo.

A todos os auditores internos que participaram da pesquisa respondendo ao questionário on-line. Aos profissionais das áreas de Auditoria Interna e TI que dispuseram do seu precioso tempo, agregaram conhecimento e compartilharam experiências valiosas para a pesquisa, Fabiano Castello (IIA Brasil), Antônio Edson dos Santos (IIA Brasil), Ricardo Santana (KPMG), Gustavo Galegale (ISACA), Rutemberg Araujo e Leandro Galindo; Paulo Castro, Alexandro Buck e Luiz Manoel (Magazine Luiza).

À FEA/USP pela estrutura, ambiente e recursos disponibilizados aos alunos. Ao Departamento de Contabilidade e Atuária pelo privilégio de cursar o mestrado em Contabilidade. Aos funcionários da secretaria do PPGCC pelo apoio administrativo. Aos funcionários da Biblioteca da FEA, em especial a Adriana Santos e Fernanda Lima.

Aos professores da FEA-USP por todos os ensinamentos, Prof. Dr. Eliseu Martins, Prof. Dr. Fábio Frezatti, Prof. Dr. Reinaldo Guerreiro, Prof. Dr. Nelson Carvalho, Profa. Dra. Silvia Casa Nova, Prof. Dr. Luís Eduardo Afonso, Profa. Dra. Mara Jane Malacrida, Prof. Dr. Eduardo Flores, Prof. Dr. Renê Pimentel, Prof. Dr. Ariovaldo dos Santos, Prof. Dr. Bruno Salotti, Prof. Dr. Henrique Castro e Prof. Dr. Lucas Barros.

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

“Mas a sabedoria que vem do alto é, primeiramente pura, depois pacífica, moderada, tratável,
cheia de misericórdia e de bons frutos, sem parcialidade, e sem hipocrisia.”

(Tiago 3:17)

RESUMO

Iguma, M. K. (2019). *Big Data Analytics e a evolução das práticas de Auditoria Interna: um estudo sobre os antecedentes da aceitação e adoção da tecnologia no setor privado brasileiro*. (Dissertação de Mestrado). Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.

Big Data Analytics (BDA) é um tema que vem recebendo destaque na mídia e na comunidade científica. Um número crescente de empresas está acelerando a implantação de iniciativas de BDA para desenvolver *insights* críticos que podem fornecer a eles uma vantagem competitiva. Diante desse cenário, em que as técnicas tradicionais de análise de dados tornam-se inadequadas, os auditores internos deverão adquirir habilidades para enfrentar o desafio complexo da coleta, análise e síntese de grandes quantidades de dados de várias fontes, demandando novos recursos, novas métricas e novas formas de pensar que causarão impactos nas práticas de Auditoria Interna (AI). Considerando que o conhecimento sobre o uso de técnicas de BDA na AI ainda é limitado, o presente estudo tem como objetivo investigar os fatores que influenciam a aceitação de soluções de BDA nas práticas de AI, segundo a percepção dos auditores internos que atuam em empresas do setor privado brasileiro. O modelo teórico, seus conceitos, construtos e hipóteses foram elaborados a partir da Teoria Unificada da Aceitação e do Uso da Tecnologia (UTAUT). Os dados da amostra de 305 respondentes foram coletados por meio do questionário on-line que foi enviado aos auditores internos da rede de relacionamentos do LinkedIn e posteriormente submetidos a técnicas de estatística descritiva e multivariada de equações estruturais (MEE-PLS). Os resultados apontaram que, dentre as ferramentas de TI atualmente utilizadas pelos respondentes, os sistemas ERP são os mais utilizados e revelaram que a Expectativa de Desempenho (ED) e a Influência Social (IS) são preditores significativos das intenções dos auditores internos de adotar o BDA, enquanto que os efeitos de Expectativa de Esforço (ES) e Condições Facilitadoras (CF), assim como os efeitos das variáveis moderadoras Gênero, Idade e Experiência, não foram significativos sobre a Intenção de Uso (IU). Desse modo, o estudo procurou trazer contribuições teóricas e práticas para a profissão de AI, para o Instituto dos Auditores Internos (IIA Brasil), para as organizações, para estudantes e instituições de curso superior.

Palavras-chave: Auditoria Interna. *Big Data Analytics*. UTAUT

ABSTRACT

Iguma, M. K. (2019). *Big Data Analytics and the evolution of Internal Audit practices: a study on the antecedents of technology acceptance and adoption in the Brazilian private sector*. (Dissertação de Mestrado). Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.

Big Data Analytics (BDA) is a topic that has been highlighted in the media and in the scientific community. An increasing number of companies are accelerating the implementation of BDA initiatives to develop critical insights that can provide them with a competitive advantage. Faced with this scenario, in which traditional data analysis techniques become inadequate, internal auditors must acquire skills to face the complex challenge of collecting, analyzing and synthesizing large amounts of data from various sources, demanding new resources, new metrics and new ways of thinking that will impact Internal Audit (IA) practices. Considering that knowledge about the use of BDA techniques in IA is still limited, the present study aims to investigate the factors that influence the acceptance of BDA solutions in IA practices, according to the perception of internal auditors who work in companies in the Brazilian private sector. The theoretical model, its concepts, constructs and hypotheses were elaborated from the Unified Theory of Acceptance and Use of Technology (UTAUT). The sample data of 305 respondents were collected through an online questionnaire that was sent to internal auditors in the LinkedIn network and subsequently subjected to techniques of descriptive and multivariate statistics of structural equations (MEE-PLS). The results showed that, among the IT tools currently used by respondents, ERP systems are the most used and revealed that Performance Expectations (PE) and Social Influence (SI) are significant predictors of the of internal auditors to adopt the BDA, while the effects of Expectation of Effort (EE) and Facilitating Conditions (FC), as well as the effects of the moderating variables Gender, Age and Experience, were not significant on Intention to Use (BI). In this way, the study sought to bring theoretical and practical contributions to the IA profession, to the Institute of Internal Auditors (IIA Brasil), to organizations, students and educational institutions.

Keywords: Internal Audit. Big Data Analytics. UTAUT

LISTA DE FIGURAS

Figura 1 – Big Data: Transações com Interações e Observações.....	22
Figura 2 – Análise Bibliométrica: palavras-chaves de TI mais citadas no contexto de auditoria	29
Figura 3 – Modelo de Governança Corporativa e seus elementos	38
Figura 4 – Análise bibliométrica: palavras-chave específicas da área de auditoria	42
Figura 5 – Controle e processo organizacional	47
Figura 6 – Ciclo de valor de uma empresa de comércio exterior que utiliza atividades eletrônicas.....	48
Figura 7 – Fluxograma de sistemas do processo de compra	49
Figura 8 – Passos do processo de Auditoria Interna.....	54
Figura 9 – Modelo conceitual de estágios de expansão de BDA nas práticas de AI.....	81
Figura 10 – Modelo UTAUT de Venkatesh et al. (2003)	90
Figura 11 – Modelo UTAUT adaptado para o estudo	96
Figura 12 – Distribuição dos respondentes da amostra no mapa do Brasil	111
Figura 13 – Representação dos procedimentos de ajuste do MEE.....	121
Figura 14 – Modelo ajustado após análise do Modelo de Mensuração	128

LISTA DE QUADROS

Quadro 1 – Unidades de Medidas Computacionais.....	21
Quadro 2 – Características de auditores internos e auditores externos.....	36
Quadro 3 – Profissões da Auditoria Interna, Auditoria Externa e Auditoria de TI.....	40
Quadro 4 – Definições de Auditoria Interna em ordem cronológica.....	43
Quadro 5 – Riscos, exposições e controles internos no processo de compras.....	50
Quadro 6 – Procedimentos de Auditoria Interna.....	53
Quadro 7 – A Evolução da TI e os Desafios de Auditoria.....	65
Quadro 8 – Eventos de desenvolvimento do Big Data	66
Quadro 9 – Modelo de 6Vs	68
Quadro 10 – Tipos de dados de Big Data	70
Quadro 11 – As cinco dimensões da criação de valor a partir do Big Data.....	72
Quadro 12 – Cadeia de valor de BDA	73
Quadro 13 – Seis tipos de aplicações de BDA.....	74
Quadro 14 – Definição de BDA elaborada para o estudo.....	75
Quadro 15 – Métodos analíticos de BDA	76
Quadro 16 – BDA: oportunidades, mudanças de paradigma e desafios para a Auditoria Interna	79
Quadro 17 – Principais pesquisas sobre a adoção de TI pela Auditoria Interna	85
Quadro 18 – Teorias base para o modelo UTAUT.....	88
Quadro 19 – Construtos e seus respectivos indicadores, construtos originais e hipóteses	100

LISTA DE TABELAS

Tabela 1 – Características individuais dos respondentes	107
Tabela 2 – Experiência profissional dos respondentes	108
Tabela 3 – Formação dos respondentes (graduação e pós-graduação)	109
Tabela 4 – Tipo de organização.....	110
Tabela 5 – Formas de aquisição de competências de TI pelos respondentes.....	112
Tabela 6 – Ferramentas de TI utilizadas pelos respondentes	113
Tabela 7 – Tipos de dados utilizados pelos respondentes.....	114
Tabela 8 – Atividades de Auditoria Interna	115
Tabela 9 – Análise Descritiva: Expectativa de Desempenho (ED)	116
Tabela 10 – Análise Descritiva: Expectativa de Esforço (EE).....	117
Tabela 11 – Análise Descritiva: Influência Social (IS)	118
Tabela 12 – Análise Descritiva: Condições Facilitadoras (CF)	119
Tabela 13 – Análise Descritiva: Intenção de Uso (IU)	120
Tabela 14 – AVE (antes do ajuste)	122
Tabela 15 – AVE (após o ajuste).....	122
Tabela 16 – Fator de Inflação da Variância (VIF) dos Indicadores	123
Tabela 17 – Fator de Inflação da Variância (VIF) dos Construtos.....	124
Tabela 18 – Consistência interna (Alfa de Cronbach) e Confiabilidade Composta (CC)	125
Tabela 19 – Validade Discriminante (VD)	125
Tabela 20 – Raiz quadrada da AVE.....	127
Tabela 21 – Correlação das Variáveis Latentes	127
Tabela 22 – Coeficientes de Determinação de Pearson (R^2).....	128
Tabela 23 – Relevância ou Validade Preditiva (Q^2)	129
Tabela 24 – Tamanho do Efeito (f^2)	130
Tabela 25 – Coeficientes estruturais (Path Coefficients).....	131
Tabela 26 – Valores de significância (Construtos).....	131
Tabela 27 – Valores de significância (Variáveis Moderadoras)	132

LISTA DE ABREVIATURAS E SIGLAS

AC: Auditoria Contínua

ACL: *Audit Command Language*

ACr: Alfa de Cronbach

AI: Auditoria Interna

AICPA: *American Institute of Certified Public Accountants*

API: *Application Programming Interface*

ARP: *Analytical Review Procedures*

AVE: *Average Variance Extracted*

BACEN: Banco Central do Brasil

BDA: *Big Data Analytics*

BI: *Business Intelligence*

CAATT: *Computer-Assisted Audit Tools and Techniques*

CC: Confiabilidade Composta

CFC: Conselho Federal de Contabilidade

CIA: *Certified Internal Auditor*

CISA: *Certified Information Systems Auditor*

COBIT: *Control Objectives for Information and Related Technology*

COSO: *Committee of Sponsoring Organizations of the Treadway Commission*

CPA: *Certified Public Accountant*

CPC: Comitê De Pronunciamentos Contábeis

CRC: Conselho Regional de Contabilidade

CVM: Comissão de Valores Mobiliários

EDP: *Electronic Data Processing*

ERP: *Enterprise Resource Planning*

ETL: *Extraction, Transformation, and Load*

GAS: *Generalized Audit Software*

HTML: *HyperText Markup Language*

IAF: *Internal Audit Function*

IBRACON: Instituto dos Auditores Independentes do Brasil

IDEA: *Interactive Data Extraction and Analysis*

IFAC: *International Federation of Accountants*

IFRS: *International Financial Reporting Standards*

IIA: *The Institute of Internal Auditors*

IoT: *Internet of Things* (Internet das Coisas)

IPPF: *International Professional Practices Framework*

ISA: *International Standards on Auditing*

ISACA: *Information Systems Audit and Control Association*

ITIL: *IT Infrastructure Library*

LPT: *Labor Process Theory*

MEE: Modelagem de Equações Estruturais

NBC: Normas Brasileiras de Contabilidade Técnicas de Auditoria

NFD: *Non-Financial Data*

NoSQL: *Not Only SQL*

PLS-PM: *Partial Least Squares - Path Modeling*

QA: *Question answering*

RFID: *Radio Frequency Identification*

SAS: *Statement on Auditing Standards*

SAS: *Statistical Analysis System*

SCI: Sistema de Controles Internos

SEC: *Security and Exchange Comission*

SIC: *Systems of Internal Control*

SUSEP: Superintendência de Seguros Privados

SOX: Lei Sarbanes-Oxley (2002)

UTAUT: *Unified Theory of Acceptance and Use of Technology*

TI: Tecnologia da Informação

VD: Validade Discriminante

VIF: *Variance Inflation Factor*

VL: Variável Latente

XBRL: *eXtensible Business Reporting Language*

XML: *eXtensible Markup Language*

SUMÁRIO

1 INTRODUÇÃO	21
1.1 Contextualização	21
1.2 Problema de Pesquisa	24
1.3 Objetivo Geral	28
1.4 Objetivos Específicos.....	28
1.5 Justificativas e Contribuições.....	29
1.6 Delimitações	32
1.7 Estrutura do Trabalho.....	32
2 REVISÃO DA LITERATURA	33
2.1 História da Auditoria.....	33
2.2 Tipos de Auditoria.....	35
2.3 A Evolução da Auditoria Interna	40
2.4 Auditoria Interna e Conceitos Relacionados	45
2.5 Procedimentos e Técnicas de Auditoria Interna	52
2.6 O Uso de Ferramentas de TI pela Auditoria Interna.....	58
2.7 <i>Big Data Analytics</i> (BDA).....	65
2.8 BDA e Auditoria Interna	78
3 MODELO TEÓRICO	85
3.1 Expectativa de Desempenho (ED).....	90
3.2 Expectativa de Esforço (EE).....	91
3.3 Influência Social (IS).....	92
3.4 Condições Facilitadoras (CF).....	93
3.5 Gênero, Idade, Experiência e Voluntariedade.....	94
4 METODOLOGIA DA PESQUISA.....	97
4.1 Tipologia da Pesquisa.....	97
4.2 Elaboração do Questionário	98
4.3 Implementação da Survey	102
4.4 População e Amostra da Pesquisa	103
4.5 Métodos de Análise de Dados.....	104
5 ANÁLISE DOS RESULTADOS.....	107
5.1 Análise Descritiva dos Dados	107
5.1.1 Caracterização do Respondente.....	107
5.1.2 Ferramentas de TI, Tipos de Dados e Atividades de Auditoria Interna	112

5.1.3 Itens dos Construtos do Modelo UTAUT	116
5.2 Análise do Modelo de Equações Estruturais	120
5.2.1 Análise do Modelo de Mensuração	121
5.2.2 Análise do Modelo Estrutural	128
5.3 Discussão das Análises	133
6 CONSIDERAÇÕES FINAIS	139
6.1 Contribuições Práticas	141
6.2 Contribuições Teóricas	143
6.3 Limitações	144
6.4 Pesquisas Futuras	144
REFERÊNCIAS	145
GLOSSÁRIO	159
APÊNDICES	163
APÊNDICE A – Questionário	163
APÊNDICE B – Feedback dos Respondentes	171

1 INTRODUÇÃO

1.1 Contextualização

As ideias da “era digital” são conhecidas desde os anos 1960 e até o ano 2000, um quarto da informação em escala mundial estava armazenada em formato digital. Digitalização é um conceito que alcançou enorme popularidade no início dos anos 1990 e diz respeito à conversão de sinais analógicos em sinais digitais por meio de ferramentas como o reconhecimento óptico de caracteres (OCR – *Optical Character Recognition*) (De Mauro, Greco, & Grimaldi, 2016). Com o crescimento surpreendente dos dados digitais, 7% dos dados eram analógicos em 2007 e, anos mais tarde, a quantidade foi estimada em menos de 2% em 2013 (Mayer-Schonberger & Cukier, 2013). De acordo com o relatório de 2011 da *International Data Corporation* (IDC), pioneira no estudo de Big Data, o volume total de dados criados e copiados foi de 1,8 *zettabyte* nos 20 anos anteriores (Gantz & Reinsel, 2011; Chen, Mao, & Liu, 2014). O desenvolvimento da Internet na década de 1970 e sua subsequente adoção em larga escala desde os anos 1990 aumentaram exponencialmente as velocidades de geração e coleta de dados comerciais (Chen, Chiang, & Storey, 2012).

De acordo com a Agência Nacional de Segurança dos EUA (NSA – *National Security Agency*), a Internet processa 1.826 *petabytes* de dados por dia e estima-se que a quantidade chegará a 35 trilhões de *gigabytes* até 2020 (Chen & Lin, 2014) de modo que a capacidade de geração de dados global nunca foi tão poderosa desde a invenção da Tecnologia da Informação (TI) no início do século XIX (Wu, Zhu, Wu, & Ding, 2014). As unidades de medidas computacionais estão representadas no Quadro 1 para melhor entendimento sobre o volume de dados digitais.

Quadro 1 – Unidades de Medidas Computacionais

Kilobyte (KB)		2^{10} bytes	1.024
Megabyte (MB)	1.024 KB	2^{20} bytes	1.048.576
Gigabyte (GB)	1.024 MB	2^{30} bytes	1.073.741.824
Terabyte (TB)	1.024 GB	2^{40} bytes	1.099.511.627.776
Petabyte (PB)	1.024 TB	2^{50} bytes	1.125.899.906.842.620
Exabyte (EB)	1.024 PB	2^{60} bytes	1.152.921.504.606.850.000
Zettabyte (ZB)	1.024 EB	2^{70} bytes	1.180.591.620.717.410.000.000
Yottabyte (YB)	1.024 ZB	2^{80} bytes	1.208.925.819.614.630.000.000.000

Fonte: Elaborado pelo autor

Os dados tornaram-se um importante fator de produção que pode ser comparável a ativos materiais e capital humano. O termo “Big Data” foi cunhado para representar o profundo significado dessa tendência de explosão de dados, que foram apontados como o “novo petróleo” que deve transformar a nossa sociedade (Hu, Wen, Chua, & Li, 2014) causando impactos nos negócios e em áreas como Ciência e Engenharia. O movimento de crescimento do Big Data é impulsionado por meio de grandes quantidades de dados não estruturados ou multidimensionais que são continuamente produzidos e armazenados com um custo muito mais barato do que costumava ser (Fan, Han, & Liu, 2014) e pela difusão e adoção generalizada de dispositivos móveis, plataformas de mídia social incluindo YouTube, Facebook e Twitter e tecnologias relacionadas à IoT como a Identificação por Rádio Frequência (RFID – *Radio Frequency Identification*) (Chen et al., 2014; Wamba, Akter, Edwards, Chopin, & Gnanzou, 2015). Dataficação (*datafication*), um conceito bastante associado à geração de Big Data, corresponde ao processo de transformar interações sociais e empresariais num formato quantificado de forma que possam ser tabulados e analisados, traduzindo em dados muitos aspectos do mundo que nunca foram quantificados antes (Mayer-Schonberger & Cukier, 2013).

Conforme ilustra a Figura 1, Big Data pode ser representado pela integração de transações com interações e observações, (Connolly, 2012; Moniruzzaman & Hossain, 2013; Alles & Gray, 2016).

Figura 1 – Big Data: Transações com Interações e Observações

Na literatura, diversas expressões foram utilizadas para se referir ao Big Data, tais como “a próxima grande inovação” (Gobble, 2013), “o quarto paradigma da ciência” (Strawn, 2012), “a próxima fronteira para inovação, competição e produtividade” (Manyika et al., 2011), a próxima “revolução da administração” (McAfee & Brynjolfsson) e “o filão principal da mudança disruptiva em um ambiente de negócios em rede” (Baesens, Bapna, Marsden, Vanthienen, & Zhao, 2014). Big Data é um conceito abstrato associado a “uma nova geração de tecnologias e arquiteturas, projetadas para extrair economicamente valor de volumes muito grandes de uma ampla variedade de dados, permitindo a captura, descoberta e análise em alta velocidade” (Gantz & Reinsel, 2011, p.6) segundo o relatório do IDC de 2011 (Chen et al., 2014).

Big Data Analytics (BDA) vem atraindo grande interesse de setores como indústria, governo e comunidades de pesquisa (Hu et al., 2014), recebendo destaque em artigos da mídia (*The Economist* e *The New York Times*), de revistas científicas como *Nature* e *Science*, nas publicações *Hype Cycles* de 2012 e 2013 da Gartner (Hu et al., 2014; Chen et al., 2014; Chen & Zhang, 2014) e do relatório “*Big Data for Development*” publicado em julho de 2012 pela Organização das Nações Unidas (ONU).

A pesquisa da McKinsey & Company sobre a adoção de soluções de Big Data nos serviços de saúde dos EUA, na administração do setor público da União Europeia, no varejo dos EUA e na produção global, constatou melhoras na eficiência, qualidade, produtividade de empresas privadas e maiores benefícios para os seus consumidores (Manyika et al., 2011). Murdoch e Detsky (2013) destacam aplicações bem-sucedidas de Big Data em diferentes setores: a) na astronomia: o SDSS (*Sloan Digital Sky Survey*) com informações telescópicas; b) em vendas no varejo: o grande número de transações do Walmart; c) em mecanismos de pesquisa: personalização do Google de pesquisas individuais com base em dados da *web*; e d) em campanhas de propaganda política com o foco em eleitores com maior probabilidade de apoiar seu candidato com base em pesquisas na *web*.

Um número crescente de empresas está acelerando a implantação de suas iniciativas de BDA, com o objetivo de desenvolver *insights* críticos (Mikalef, Krogstie, Pappas, & Pavlou, 2019), otimizar as operações de negócios, prever resultados, melhorar a eficiência, tomar melhores decisões, criar produtos e serviços inovadores e capturar novas oportunidades de mercado para obter vantagem competitiva contra seus rivais (Davenport, Barth, & Bean, 2012). Grandes empresas incluindo EMC, Oracle, IBM, Microsoft, Google, Amazon e Facebook

iniciaram seus projetos de Big Data. Desde 2005, a IBM vem investindo US \$ 16 bilhões em 30 aquisições relacionadas a Big Data (Chen et al., 2014).

No campo da Auditoria, há um reconhecimento entre profissionais, grandes empresas e pesquisadores acadêmicos de que o potencial do BDA pode levar os auditores a um melhor julgamento, tomada de decisão e coleta de evidências (Brown-Liburd, Issa & Lombardi, 2015) e também de que a complexidade do ambiente tecnológico, a geração de grandes volumes de dados em formatos heterogêneos e o crescente uso da análise desses dados nos processos de negócios trazem desafios para a comunidade de Auditoria (Vasarhelyi, Kogan, & Tuttle 2015; Appelbaum, Kogan & Vasarhelyi, 2017). BDA é um tema que vem sendo abordado por artigos publicados pelas companhias Big Four (EY, 2015; PwC, 2015; KPMG, 2018), pelo IIA (IIARF, 2016) e no período recente de três anos (2015, 2016 e 2017) foi identificado o interesse acadêmico internacional sobre os aspectos da incorporação de BDA nas práticas de Auditoria segundo o estudo bibliométrico de Iguma e Riccio (2018).

1.2 Problema de Pesquisa

A ascensão da economia digital alterou fundamentalmente a maneira de administrar negócios e realizar auditorias. Atualmente, grande parte das empresas de tamanho significativo utiliza sofisticados sistemas como *Enterprise Resource Planning* (ERP), *Customer Relationship Management* (CRM), *Supply Chain Management* (SCM) ou *Busines-to-Business* (B2B) (Jans, Alles, & Vasarhelyi, 2010) e sistemas integrados à nuvem (*cloud*), à Internet das Coisas (IoT) e a fontes de dados externas.

As organizações armazenam enormes quantidades e variedades de dados, desde dados tradicionais associados a vendas e despesas a dados não estruturados associados a vídeos, *weblogs*, email e *tweets*, empregando abordagens analíticas de negócios novas e complexas para gerar inteligência para a tomada de decisões com a utilização de BDA (Vasarhelyi, Kogan, & Tuttle 2015; Appelbaum, Kogan & Vasarhelyi, 2017). A revolução trazida pelo Big Data transformou as empresas em empresas orientadas a dados e provocou uma mudança total no uso das informações, tanto na maneira como os dados são gerenciados e armazenados quanto na maneira como eles são processados, analisados e interpretados (Agrawal et al., 2011).

O advento do BDA provocou também transformações nos processos de negócios e alterações nos ecossistemas corporativos, mudando o cenário de concorrência e introduzindo

as empresas em novos contextos do mercado (Wamba et al., 2015; Manyika et al., 2011). Entretanto, a extração de conhecimento valioso a partir de Big Data não é uma tarefa comum (Chen e Lin, 2014), pois requer mudança de paradigma nos métodos estatísticos e nas arquiteturas de computação (Fan et al., 2013), gerando novos desafios, como o de organizar e gerenciar efetivamente esses conjuntos de dados (Hu et al., 2014). Assim como novos processos de negócio estão sendo adicionados enquanto outros estão sendo eliminados em decorrência do advento do BDA, o mesmo deve ocorrer na Função de Auditoria Interna (IAF – *Internal Audit Function*) (Appelbaum, Kogan, & Vasarhelyi, 2017).

A Auditoria Interna (AI) cresceu significativamente ao longo dos anos, em importância e na abrangência do escopo de atuação, devido aos fatores significativos de mudança que as organizações estão enfrentando tais como o ambiente regulatório, as evoluções na Governança Corporativa (Ramamoorti, 2003) e as novas tecnologias (Hass, Abdolmohammadi, & Burnaby, 2006; Vasarhelyi & Halper, 1991). Como a AI tem acesso a processos e dados de toda a organização, o BDA pode permitir que os auditores internos forneçam *insights* sobre problemas de risco, controle e desempenho que nenhuma outra função da organização pode fornecer (Verver, 2015).

No ambiente emergente de BDA, as tecnologias tradicionais mostram-se inadequadas diante das modernas tecnologias de análise de dados, que são capazes não apenas de melhorar a precisão dos resultados das previsões, mas também de expandir o escopo da análise incluindo dados semiestruturados e dados não estruturados (Liu, 2014). Assim, as técnicas de BDA têm o potencial de substituir muitas das técnicas tradicionalmente executadas por auditores (Richins, G., Stapleton, A., Stratopoulos, T., & Wong, 2017) que são limitadas para o entendimento de riscos e coleta de evidências de auditoria no contexto do Big Data (Wang & Cuthbertson, 2015).

Os auditores internos deverão enfrentar o desafio complexo da coleta, análise e síntese de grandes quantidades de dados de várias fontes para formar julgamentos. Para alcançar a implementação extensiva de BDA na AI, serão necessários novos recursos, novas métricas e novas formas de pensar (Brown-Liburd et al., 2015) causando impactos em praticamente todas as fases do processo de AI (Vasarhelyi & Halper, 1991).

De acordo com Tang, Norman e Vandrzyk (2017), considerando que as mudanças disruptivas resultantes do BDA são inevitáveis, os auditores internos precisam aprender novas habilidades para lidar com os riscos que essas mudanças trarão para suas organizações nos

próximos anos. Hass, Abdolmohammadi e Burnaby (2006) apontam que novas competências são necessárias para que a AI se torne uma função ainda mais valiosa de administração geral como um agente principal de transformação. A função de AI deve evoluir, partindo de uma abordagem retroativa e corretiva, com o foco no passado, para uma abordagem preventiva, com o foco no presente e no futuro, por meio de avaliação de cenários, estratégias e voltado para os resultados dos negócios da organização (Silva, 2012; Kuenkaikaew, 2013).

Entretanto, a profissão de AI apresenta uma natureza conservadora na adoção de TI com base no seu histórico de experiências anteriores com a computação cliente-servidor e a Internet (Alles, 2015) em comparação a outras áreas corporativas, tais como marketing, recursos humanos e gerenciamento da cadeia de suprimentos (Chiu, Chan & Vasarhelyi, 2018). A auditoria, que fez grandes progressos na década passada, não acompanhou o ritmo da economia em tempo real (Alles, 2015).

Pesquisas sugerem que o processo de aceitação dos CAATTs pelos auditores foi mais lenta do que o esperado e que essas ferramentas não são utilizadas com frequência e de forma sistemática (Payne & Curtis, 2010; Bierstaker et al., 2014). A Auditoria Contínua (AC) apresentou um ritmo de expansão entre os auditores semelhante ao dos CAATTs, mesmo oferecendo benefícios para as empresas como a minimização de erros contábeis, análises e comunicação mais tempestiva dentro da organização (Gonzalez, Sharma, & Galletta, 2012). A baixa aceitação de *data mining* deve-se à complexidade das ferramentas e carência de competências técnicas necessárias (Kim et al., 2009).

Alles (2015) questiona se a profissão de AI verá o BDA como uma oportunidade a qual responderá positivamente por iniciativa própria em vez de adotá-lo como uma reação defensiva à pressão do mercado de seus clientes, se e quando o BDA tornar-se tão importante para a operação dos negócios quanto os sistemas ERP provaram ser na década anterior. Os auditores finalmente começaram a obter dados dos sistemas ERP e a desenvolver técnicas para auditar as configurações desses sistemas, enquanto que a adoção de outras tecnologias como a AC e mineração de texto (*Text Mining*) ainda está em andamento.

A literatura acadêmica internacional no campo da Contabilidade e da Auditoria apresenta estudos sobre os aspectos da incorporação de BDA nas práticas de Auditoria (Iguma & Riccio, 2018) sendo, porém, poucas as pesquisas sobre a intenção de adoção e uso de BDA por indivíduos ou por organizações relacionados à profissão de AI. Tang, Norman e Vendrzyk (2017), por exemplo, examinaram o impacto do BDA no comportamento dos profissionais de

AI por meio da abordagem de estudo de casos, entrevistando 12 Chefes Executivos de Auditoria (CAE – *Chief Audit Executive*), sendo 6 de empresas com fins lucrativos e 6 de organizações sem fins lucrativos. No entanto, não foram encontrados estudos com um número maior de amostra de respondentes, com a aplicação de modelos teóricos para a compreensão da aceitação do BDA por auditores internos no cenário brasileiro ou mesmo no cenário internacional.

Diante do exposto, identificou-se a necessidade de estudar o comportamento dos profissionais de AI na realidade prática do setor privado brasileiro, frente ao fenômeno do crescente volume de dados multidimensionais que são colhidos, armazenados e interpretados pelas organizações e dos impactos causados pela adoção de BDA nos processos de negócios, levando-se em consideração a natureza conservadora do auditor interno. Desse modo, esse trabalho visa investigar o contexto atual de utilização de ferramentas de TI, a perspectiva do profissional em relação ao BDA e os fatores que influenciam a sua intenção em adotar essa tecnologia, cuja análise e recomendações poderão contribuir para o avanço da AI rumo à plena utilização de BDA na evolução de suas práticas a fim de agregar valor às organizações. Assim, o presente estudo guia-se pela seguinte questão de pesquisa:

Quais são os fatores que influenciam a intenção do uso de soluções tecnológicas de *Big Data Analytics* nas práticas de Auditoria Interna em empresas do setor privado brasileiro, segundo a percepção dos auditores internos?

1.3 Objetivo Geral

O presente estudo tem como objetivo geral identificar e analisar os fatores Expectativa de Desempenho, Expectativa de Esforço, Influência Social e Condições Facilitadoras que influenciam a aceitação de soluções de BDA e sua adoção nas práticas de AI, em constante evolução, segundo a percepção dos auditores internos que atuam em empresas do setor privado brasileiro. É importante destacar que, mais do que uma pesquisa sobre a aceitação da tecnologia, este é um estudo sobre a origem, o desenvolvimento e a evolução da função de AI, sua relevância para as organizações e o importante papel que o BDA pode desempenhar no processo evolutivo da profissão.

1.4 Objetivos Específicos

Os seguintes objetivos específicos correspondem às etapas necessárias para o cumprimento do objetivo geral:

- a) Obter conhecimento preliminar sobre a área de AI por meio de entrevistas com profissionais e visitas a empresas.
- b) Pesquisar a literatura acadêmica sobre o desenvolvimento da profissão de AI, suas práticas e principais conceitos, e sobre o seu histórico de adoção de ferramentas de TI;
- c) Pesquisar a literatura acadêmica sobre BDA, seus conceitos, tecnologias e aplicações em diversos setores, e os aspectos de sua incorporação nas práticas de AI;
- d) Elaborar a definição de BDA própria para o estudo.
- e) Pesquisar os conceitos e construtos do modelo UTAUT e sua aplicação em estudos anteriores e elaborar o modelo adaptado ao contexto da pesquisa.
- f) Elaborar o diagrama de expansão da incorporação BDA na auditoria interna com base em elementos fornecidos pela literatura.
- g) Elaborar o questionário estruturado em blocos com base nos tipos de ferramentas de TI, tipos de dados, tipos de atividades de AI e indicadores do modelo UTAUT fornecidos pela literatura. Posteriormente, realizar o pré-teste do instrumento de coleta de dados e ajustes no questionário sugeridos por colaboradores da pesquisa.
- h) Criar uma rede de relacionamentos de usuários do LinkedIn (auditores internos) para divulgação da pesquisa e encaminhamento do link do questionário na plataforma Google Forms.

- i) Realizar a análise de poder estatístico para verificação do tamanho mínimo da amostra.
- j) Realizar a análise do modelo de equações estruturais (MEE) observando todos os critérios, validações e consistências, para os testes de hipóteses.
- k) Com base nos achados e análise dos resultados, apresentar recomendações que poderão trazer contribuições para a pesquisa acadêmica e para a profissão de AI.

1.5 Justificativas e Contribuições

Conforme mencionado anteriormente, BDA é um tema abordado por artigos publicados pelas companhias Big Four e pelo IIA no campo da Auditoria Interna. Com relação à produção científica internacional, o estudo bibliométrico de Iguma e Riccio (2018) sobre as soluções tecnológicas e ferramentas de *software* mais estudadas do campo da Auditoria demonstrou que Alles, M. e Vasarhelyi, M. foram os autores mais produtivos no período entre 1991 e 2017. “Big Data” foi a terceira palavra-chave mais citada por publicações nesse período em onze artigos nos três últimos anos (2015, 2016 e 2017), evidenciando o crescente interesse dos pesquisadores acadêmicos sobre o tema (Figura 2).

Figura 2 – Análise Bibliométrica: palavras-chaves de TI mais citadas no contexto de auditoria

Fonte: Iguma e Riccio (2018)

A literatura apresenta diversos estudos acadêmicos sobre o uso da TI por auditores governamentais, auditores externos e auditores internos (Li, Dai, Gershberg, & Vasarhelyi, 2018). Com relação às pesquisas sobre a aceitação de ferramentas de TI na Auditoria Interna, destacam-se: Ferramentas e Técnicas de Auditoria Assistida por Computador (CAATTs – *Computer-Assisted Audit Tools and Techniques*) (Kim, Mannino, & Nieschwietz, 2009; Mahzan & Lymer, 2008, 2014), de auditoria contínua (Gonzalez et al., 2012; Vasarhelyi, Alles, Kuenkaikaew, & Littley, 2012; Nascimento, 2019) e de *Audit Analytics* (Li et al. 2018). A importância do tema para a comunidade acadêmica pode ser explicada por Bierstaker, Janvrin e Lowe (2014): “embora o uso da TI no mundo dos negócios tenha crescido exponencialmente nas últimas duas décadas, o grau em que os auditores responderam a esse fenômeno permanece uma questão empírica”.

Segundo Gandomi e Haider (2015), o rápido crescimento do Big Data indica que as publicações acadêmicas foram superadas pelo discurso nos meios populares. O estudo de Gepp, Linnenluecke, O’Neill e Smith (2018) aponta que a Auditoria está atrasada em relação aos outros fluxos de pesquisa sobre o uso de técnicas valiosas de BDA, revelando uma lacuna entre a pesquisa acadêmica e a prática profissional de Auditoria na área de Big Data. No geral, a prevalência de técnicas de BDA na prática de Auditoria permanece amplamente desconhecida. Segundo Wang e Cuthbertson (2015), apesar da importância do uso de BDA para melhorar a qualidade da auditoria e das necessidades práticas de alavancar a enorme quantidade de dados disponíveis, o entendimento do uso da análise de dados nos trabalhos de auditoria ainda é limitado.

Gepp, Linnenluecke, O’Neill e Smith (2018) também indicaram a necessidade de pesquisas para alinhar ainda mais a teoria e a prática nessa área, por exemplo, para entender melhor a aplicação das técnicas de BDA na auditoria e investigar o uso real das técnicas de BDA na profissão de auditoria como um todo, abrangendo o maior número possível de empresas.

Brown-Liburd e Vasarhelyi (2015) sugeriram futuras pesquisas para compreender os efeitos da eliminação dos processos de auditoria mais tradicionais para aproveitar totalmente os benefícios do Big Data e como o uso de análises de dados mais avançadas afetará o julgamento do auditor. Appelbaum, Kogan e Vasarhelyi (2017) sugeriram questões a serem abordadas por pesquisas sobre a adoção de BDA pela profissão de Auditoria.

Assim, o presente estudo pretende colaborar para o preenchimento da lacuna entre a pesquisa acadêmica e a prática profissional de auditoria na área de Big Data, podendo servir de referência para futuras pesquisas nacionais e internacionais, ajudando a impulsionar o crescimento da produção científica sobre as possibilidades de BDA e de outras inovações tecnológicas na AI.

Nesse sentido, as principais contribuições teóricas desse trabalho correspondem ao desenvolvimento e aplicação do modelo de aceitação individual de BDA a partir de adaptações do modelo UTAUT ao contexto da pesquisa; e os achados da pesquisa sobre como os auditores internos percebem a relevância do uso de BDA e os fatores que influenciam a intenção de adoção dessa tecnologia nas práticas de AI pelos profissionais no setor privado brasileiro.

A aplicação do modelo teórico desenvolvido para este estudo pode trazer contribuições especificamente para a área de pesquisa sobre a aceitação do usuário de novas tecnologias, que é descrita como uma das áreas mais maduras na literatura de SI contemporâneos e que resultou em vários modelos teóricos, incluindo o modelo UTAUT, com raízes em SI, Psicologia e Sociologia (Venkatesh, Morris, Davis & Davis, 2003).

Do ponto de vista prático, este trabalho fornece ao público organizacional o conhecimento sobre a importância e os principais aspectos do BDA, as transformações da profissão de AI e as habilidades necessárias dos auditores internos diante da evolução tecnológica.

Os resultados da pesquisa com relação aos dados demográficos dos respondentes da amostra, às tecnologias utilizadas e tipos de dados analisados atualmente pelos auditores internos e os fatores que influenciam a intenção de uso de BDA, bem como as recomendações sugeridas pelo estudo, podem fornecer subsídios aos profissionais, às organizações, às instituições de ensino e ao IIA Brasil para a discussão de ações que possam ajudar a AI na incorporação de BDA em suas práticas.

1.6 Delimitações

A primeira delimitação, ou fronteira de investigação, remete aos profissionais investigados, que atualmente atuam exclusivamente na função de AI no setor privado brasileiro. Deste modo, não fazem parte do universo desta pesquisa os auditores de sistemas e de TI, os profissionais de auditoria governamental e os auditores externos, mesmo que estes tenham conhecimento das práticas de AI. A delimitação geográfica abrange organizações instaladas no Brasil, independentemente da origem do capital. A delimitação temporal considera o ano de 2019, mesmo período da coleta de dados.

1.7 Estrutura do Trabalho

A presente pesquisa está organizada em cinco capítulos, que mantêm uma conexão lógica entre si. O Capítulo 1 (Introdução) apresenta a contextualização do problema da pesquisa, a questão de pesquisa a ser investigada, os objetivos da dissertação, as justificativas e contribuições, as delimitações e a própria estrutura do trabalho.

No Capítulo 2 (Revisão da Literatura), são analisadas as literaturas, fornecendo indícios e suporte à proposição da questão da pesquisa e sua investigação, abordando elementos de AI (origem da auditoria, tipos de auditorias, história e desenvolvimento da AI, principais práticas e conceitos, e histórico do uso de ferramentas de TI), de BDA (fenômeno da explosão dos dados digitais, digitalização e datificação, definições de Big Data, *Data Analytics* tradicional, conceitos e tecnologias de *Big Data Analytics*) e aspectos da incorporação de BDA na AI.

O modelo UTAUT, seus respectivos construtos e as hipóteses propostas são apresentadas no Capítulo 3 (Modelo Teórico). No Capítulo 4 (Metodologia da Pesquisa) são apresentados os aspectos metodológicos adotados para o alcance dos objetivos traçados, a tipologia, a forma de coleta, a população e a amostra da pesquisa. O Capítulo 5 (Análise dos Resultados) aborda a análise descritiva e a análise de Modelagem de Equações Estruturais (MEE).

Por fim, as Considerações Finais no Capítulo 6 oferecem reflexões sobre os resultados da análise, as contribuições práticas e teóricas, as limitações do trabalho, os possíveis desdobramentos da pesquisa e os indicativos de estudos futuros.

2 REVISÃO DA LITERATURA

2.1 História da Auditoria

Todos os tipos de auditoria praticados atualmente têm um ancestral em comum, com raízes profundas na Antiguidade. Porém, à medida que as empresas se tornaram maiores e mais complexas, surgiram novas formas de auditoria, tais como a auditoria financeira, auditoria de *compliance* e auditoria operacional (Boynton, Johnson, & Kell, 2002). Quanto ao aspecto de profissionalização, destacam-se a Auditoria Interna (AI), a auditoria externa (Sawyer, 1988) e a auditoria governamental (Miranda, 2018) ou auditoria fiscal (Junior, Fernandes, Ranha, & Carvalho, 2011) do setor público (Imoniana, 2019). De acordo com o historiador Richard Brown (1905, citado por Mautz & Sharaf, 1961), a origem da Auditoria remonta à época tão remota quanto a da Contabilidade. Watts e Zimmerman (1983) consideram que a Contabilidade e a Auditoria evoluíram de forma conjunta na história das corporações.

Em 1941, a AI emergiu como uma ramificação da auditoria, à parte e distinta da auditoria externa, e sua formalização concretizou-se por meio do estabelecimento do IIA nos Estados Unidos, fundado em Nova Iorque por 24 auditores (Mihret, 2014). A AI surgiu inicialmente como um controle administrativo, cuja função era a de medir e avaliar a eficácia dos outros controles, por meio de uma análise mais detalhada de políticas e procedimentos internos (Crepaldi, 2012; Cordeiro, 2013).

O AIA (*American Institute of Accountants*) surgiu como IPA (*Institute of Public Accountants*) em 1916 e foi renomeada como AICPA (*American Institute of Certified Public Accountants*), tornando-se um instituto com importância decisiva para os desenvolvimentos das práticas contábeis e de auditoria externa (Imoniana, 2019). Em 1991, foram emitidos os pronunciamentos *Statement on Auditing Standards* (SAS) para explicar a natureza e extensão da responsabilidade do auditor e oferecer orientações para esses profissionais. Em 1977 foi fundada a IFAC (*International Federation of Accountants*) em Munique como uma organização internacional, que publica as *International Standards on Auditing* (ISAs). A IFAC estimula a harmonização entre as normas internacionais e locais de modo que a adoção das normas internacionais é voluntária e não deve se sobrepor às normas locais, como as emitidas pelo IBRACON (Instituto dos Auditores Independentes do Brasil).

A Lei *Sarbanes-Oxley* de 2002, que ficou popularmente conhecida como SOX, foi elaborada pelos congressistas americanos Paul S. Sarbanes e Michael G. Oxley em resposta aos escândalos corporativos no mercado financeiro dos Estados Unidos, para restaurar a confiança do investidor no mercado de capitais e na auditoria profissional, aprimorando a precisão e a confiabilidade da transparência e da divulgação de informações financeiras corporativas.

A série de escândalos envolveu grandes empresas de capital aberto como a Enron e WorldCom, devido a ocorrência de fraudes na contabilidade, com a participação direta da Arthur Andersen, uma das empresas *Big Five*. A Enron usou muitas estruturas complexas de capital para esconder o fato de que seus fluxos de caixa eram muito pequenos e suas dívidas muitas vezes maiores do que o divulgado (Vaassen, Meuwissen, & Schelleman, 2013). Com a dissolução da Arthur Andersen, o grupo das grandes empresas de auditoria PriceWaterhouseCoopers, Ernest & Young (EY), Deloitte Touche Tohmatsu e KPMG, passou a ser conhecido como *Big Four*.

A SOX promoveu grandes alterações nos procedimentos e no controle de administração das empresas, órgãos reguladores responsáveis pelo estabelecimento de normas, comitês de auditoria e firmas de auditoria independente. De acordo com Seção 404 (Avaliação Gerencial dos Controles Internos), uma das disposições mais importantes da SOX, as companhias abertas deveriam garantir a estrutura de controles internos adequada para que as suas demonstrações contábeis espelhassem a sua situação econômico-financeira em todos os aspectos materiais e relevantes. Tais procedimentos da SOX vieram para fortalecer os princípios de Governança Corporativa, demandando a manutenção de departamentos de AI nas organizações para auxiliar o comitê de auditoria no gerenciamento de riscos e assegurar a solidez dos controles internos (Carcello, Hermanson, & Raghunandan, 2005; Gramling, Maletta, Schneider, & Church, 2004).

A função de AI passou a ser vista como parte da solução para os problemas do setor corporativo relacionados aos controles, à comunicação e à ética, contribuindo com o monitoramento e o aperfeiçoamento dos processos de gerenciamento de riscos e de controles internos (Sarens & De Beelde, 2006). Assim, a SOX confirmou a importância da AI na Governança Corporativa (Carey, Subramaniam, & Ching, 2006; Hass et al., 2006; Gramling et al., 2004; Silva, 2012).

No Brasil, o surgimento da auditoria está relacionado com a instalação de filiais e subsidiárias de empresas internacionais que precisavam avaliar seus investimentos no país. De acordo com Ricardino e Carvalho (2004), o primeiro parecer de auditoria independente que se

tem conhecimento foi o do balanço da São Paulo Tramway Light & Power Co, com data de 9 de abril de 1903, certificado pelos auditores canadenses Clarkson & Cross. Anos depois, a primeira empresa de auditoria independente a se instalar no país foi a Deloitte Touche Tohmatsu no Rio de Janeiro em 1911.

Em janeiro de 1972, as normas e procedimentos de auditoria independente foram elaboradas pelo IBRACON, então denominado Instituto dos Auditores Independentes do Brasil (IAIB), aprovadas pelo Conselho Federal de Contabilidade, por meio da resolução CFC nº 321/72 em que constam os requisitos básicos a serem observados no desempenho do trabalho de auditoria, definindo as normas relativas à pessoa do auditor, à execução do trabalho e ao parecer de auditoria. As Normas Brasileiras de Contabilidade Técnicas de Auditoria (NBC) apresentam a Estrutura Conceitual para trabalhos de asseguração e outros aspectos referentes à auditoria independente (Imoniana, 2019) e as NBC TI 01, especificamente, dizem respeito à AI (CFC, 2003).

Em novembro de 1960, foi fundado o Instituto dos Auditores Internos do Brasil (AUDIBRA), para representar a comunidade nacional de auditores internos e dos profissionais de controles interno e externo. Posteriormente, em 1998, a entidade afiliou-se oficialmente ao IIA, passando a difundir o reconhecimento e a importância da função do auditor interno no âmbito dos setores privado e público.

2.2 Tipos de Auditoria

As profissões de Contabilidade e a Auditoria Externa têm longa história em muitos países determinadas geralmente por governos e regulamentadas por conselhos profissionais ou entidades governamentais. De forma geral, o auditor externo (ou auditor independente) preocupa-se com transações e controles contábeis e financeiros e é responsável por “assegurar que as informações contábeis disponibilizadas ao público estejam corretas e limitar a possibilidade de o controlador manipular resultados e expropriar os pequenos acionistas, ajudando a alinhar os interesses dos envolvidos nas sociedades empresárias” (Hallak & Silva, 2012, p.224). Enquanto a auditoria externa se preocupa com o controle interno, quanto aos possíveis efeitos que este possa acarretar às demonstrações financeiras, servindo de base para emissão de seu parecer, o auditor interno tem sua ótica voltada para o que o controle interno representa para a organização (Attie, 2011).

Por outro lado, a profissão de AI é mais recente, a partir do estabelecimento do IIA em 1941, que atua como um regulamentador internacional por meio de capítulos e institutos (Sarens et al., 2011). O auditor interno tem interesse nas operações e controles que atravessam a organização, e está associado a diversos termos, tais como: auditoria operacional, auditoria de desempenho, auditoria de programa e auditoria orientada ao gerenciamento. Sawyer (1988) destacou a ampliação do campo da AI para além das transações contábeis, seguindo a filosofia de Alvarez (1970, citado por Sawyer, 1988), segundo o qual “a auditoria financeira por si só não oferece uma base favorável para ideias de ponta e inovadoras”.

O quadro 2 ilustra as principais características que diferenciam os auditores internos dos auditores externos (Cordeiro, 2013; Crepaldi, 2012; Sawyer, 1988; Migliavacca, 2002; Moscove, Simkin, & Bagranoff, 2002).

Quadro 2 – Características de auditores internos e auditores externos

AUDITORIA INTERNA	AUDITORIA EXTERNA / AUDITORIA INDEPENDENTE
Grau de independência menos amplo. Existe a relação direta de subordinação hierárquica, considerando que as atividades são executadas por colaboradores da própria empresa.	Grau de independência mais amplo. Não há relação de subordinação, pois as atividades são executadas por pessoas sem vínculo de emprego com a empresa.
Independência em relação às atividades auditadas, mas pode atender às necessidades da administração.	Independência em relação à administração e ao conselho de diretoria da organização.
Tem como principais objetivos avaliar os processos internos, adequação das práticas às expectativas da alta administração, melhoria contínua e avaliação da eficácia organizacional.	Tem como principais objetivos a revisão das práticas administrativas, com reflexos nas demonstrações financeiras, pois a adequação dessas práticas atende a terceiros interessados na empresa, especialmente os investidores.
Revisa todas as operações e controles da empresa para maior eficiência, eficácia e economia dos recursos.	Revisa as operações e os controles internos para determinar a abrangência de seus trabalhos e a contabilidade das informações financeiras.
O sistema de controle interno é permanentemente avaliado, possibilitando assim a revisão e aperfeiçoamento das rotinas da empresa.	O sistema de controle interno é base para a definição do escopo da auditoria, possibilitando a avaliação da necessidade de um maior ou menor aprofundamento.
As atividades de revisão são realizadas continuamente.	As atividades de revisão são realizadas periodicamente.

“continua”

“continuação”

AUDITORIA INTERNA	AUDITORIA EXTERNA / AUDITORIA INDEPENDENTE
Está diretamente envolvido com prevenção de fraude de qualquer forma e dimensão nas atividades auditadas.	Está envolvido com prevenção e detecção de fraude em geral, quando houver relacionamento direto com demonstrações financeiras e estas forem afetadas materialmente.
Possibilita maior acompanhamento posterior à auditoria, evidenciando se as áreas/processos corrigiram os rumos.	O acompanhamento posterior à auditoria somente é possível quando da realização de nova auditoria, revisando os pontos falhos que foram detectados anteriormente.
O produto final da auditoria interna é um relatório detalhado com as observações e sugestões de melhorias com maior grau de detalhamento.	O produto final da auditoria é a emissão de um parecer sobre as demonstrações financeiras, acompanhado de um relatório com as observações e sugestões de melhorias, todavia normalmente com menor grau de detalhamento.
Multidisciplinar: formação em Ciências Contábeis não é obrigatória. O auditor interno pode vir de outras áreas como TI, engenharia ou direito.	Graduação em Ciências Contábeis.

Fonte: Adaptado de Cordeiro (2013, p.26)

“conclusão”

A AI e a auditoria externa se complementam, necessitam uma da outra e devem estar sempre em harmonia, sendo significativas para o mundo dos negócios (Migliavacca, 2002). Ambas têm sua atenção voltada para o controle interno como ponto de partida de seu exame, e modificam a extensão do seu trabalho de acordo com as suas observações e a eficiência do sistema de controles internos existentes (Attie, 2011; Cruz, 2009).

A Figura 3 ilustra um modelo de Governança Corporativa desenvolvido a partir dos conceitos da Teoria da Agência, contemplando a AI, auditoria externa e a interação com outros elementos da Governança Corporativa (Pickett, 2011).

Figura 3 – Modelo de Governança Corporativa e seus elementos

As normas de auditoria externa como o SAS reconhecem a AI como um recurso valioso para o processo de relato financeiro (Lin, Pizzini, Vargus, & Bardhan, 2011), agregando valor e reduzindo erros que seriam detectados por auditores externos (Carey, Tanewski, & Simnett, 2000; Carcello et al., 2005). A auditoria externa considera a AI como parte do sistema de controle da empresa e por este motivo, se a atividade exercida pela AI funciona a contento, pode reduzir a extensão dos seus trabalhos (Attie, 2011). A decisão do auditor externo tem importantes consequências econômicas (Glover, Prawitt, & Wood, 2008) e por isso, este deve avaliar a objetividade, a competência e o trabalho desempenhado por auditores internos.

Geralmente o auditor interno é caracterizado pelo seu vínculo empregatício. Estudos identificaram práticas de terceirização das atividades de AI (Spira & Page, 2004) nos anos 1990, particularmente nos Estados Unidos, Canadá e Austrália, seguindo a tendência de terceirização de áreas *non-core*, tais como TI e recursos humanos, visando a economia de custos e a utilização da competência técnica do prestador externo (Carey et al., 2006). As grandes empresas de

contabilidade, como as *Big Four*, apontavam os benefícios da prestação de serviços terceirizados de AI (Glover et al., 2008). Entretanto, o IIA posicionou-se de forma contrária à terceirização da função de AI por auditores externos, principalmente porque o conhecimento profundo e familiar sobre as idiossincrasias da organização é essencial no papel central da AI no gerenciamento de riscos (Covaleski, Dirsmith, & Rittenberg, 2003; Rittenberg & Covaleski, 2001).

Para executar o trabalho de AI com eficiência, o profissional necessita de um certo nível de acesso a dados de sistemas de informação por meio de programas aplicativos ou por extrações solicitadas ao departamento de TI (Vasarhelyi et al., 2012). No entanto, é importante fazer a distinção entre AI e Auditoria de TI, Auditoria de Sistemas de Informação, ou Auditoria de Processamento Eletrônico de Dados (EDP), cujo foco é a avaliação do papel do computador na consecução dos objetivos da auditoria e do controle.

O COBIT (*Control Objectives for Information and Related Technology*), publicado pelo ITGI (*IT Governance Institute*), é um dos principais modelos de Governança de TI que orienta os auditores na tarefa de avaliar e controlar riscos de negócios associados com ambientes informatizados. O COBIT utiliza as bases conceituais do COSO e tem como foco a gestão dos processos de TI baseados em objetivos de negócios.

Outro modelo amplamente usado é o ITIL (*IT Infrastructure Library*), publicado pelo governo do Reino Unido para proporcionar melhores práticas para a gestão de serviços de TI (Moscove, Simkin, & Bagranoff, 2002). Singleton (2011) destaca a relevante contribuição de auditores de TI para os testes substantivos, especificamente na extração e análise de dados, que são procedimentos para coletar evidências de auditoria. Além disso, é comum o auditor de TI dar suporte à equipe de AI, no intuito de identificar oportunidades para inclusão de rotinas de TI nos procedimentos de auditoria.

Os auditores internos também podem se aprofundar no conhecimento sobre o ambiente de TI de sua própria organização, bem como adquirir conhecimentos especializados e desenvolver competências técnicas relacionadas à auditoria de sistemas de informação (Moscove et al., 2002).

O quadro 3 apresenta tipos de institutos, normas e certificações para exemplificação das diferenças entre as profissões de AI, auditoria externa e auditoria de TI.

Quadro 3 – Profissões da Auditoria Interna, Auditoria Externa e Auditoria de TI

Profissional	Instituto / órgãos	Normas, frameworks, melhores práticas	Certificações profissionais
Auditor Interno	IIA, IIA Brasil	IPPF, COSO	CIA (Certified Internal Auditor)
Auditor Externo / Independente	IFAC, AICPA, IBRACON, CRC	CPC, IFRS, SAS, ISA	CPA (Certified Public Accountant), CRC (Conselho Regional de Contabilidade)
Auditor de Sistemas / TI	ISACA	COBIT, ITIL	CISA (Certified Information systems Auditor)

Fonte: Elaborado pelo autor

2.3 A Evolução da Auditoria Interna

O papel da AI vem passando por transformações há décadas, sendo três os períodos de mudanças de paradigma reconhecidos por pesquisadores (McNamee & McNamee, 1995; Castanheira, 2007):

- O primeiro paradigma da AI teve como principais características a observação e a contabilização, e a utilização da técnica de reexecução dos passos, perdurando por muito tempo;
- O segundo paradigma foi marcado pela fundação do IIA em 1941 com os conceitos de “controle” e de “Sistema de Controles Internos (SCI)” que ainda encontram-se enraizados no processo de auditoria;
- Atualmente, o terceiro paradigma corresponde à visão dos processos com foco nos riscos do negócio e nas práticas de Governança Corporativa, com a utilização de sofisticados modelos de risco, amostragem estatística, CAATTs e gestão de qualidade total com foco no cliente, como parte do processo de auditoria.

Antes dos anos 1940, a função principal do auditor interno era a de conferir a propriedade das transações e dos registros (Mihret, 2014). No entanto, o desenvolvimento do pensamento sistêmico facilitou o foco em avaliação de SCI na AI após a Segunda Guerra Mundial, com o crescimento em tamanho e em complexidade dos sistemas e das organizações empresariais que provocaram grandes mudanças nas práticas de AI (McNamee & McNamee, 1995).

Historicamente, a AI era vista como uma função de “polícia” ou “cão-de-guarda” organizacional (Morgan, 1979), tolerada como um componente de controle organizacional, porém subserviente ao cumprimento dos objetivos corporativos (Spira & Page, 2004). Em 1979, Morgan identificou as primeiras iniciativas dos auditores internos para combinar as funções orientadas ao controle e as funções de consultoria, passando a orientar os níveis organizacionais, desde o nível mais baixo até o mais alto (Morgan, 1979). Vinte anos depois da definição de Morgan, o IIA apresentou a definição de AI com foco na independência e objetividade, identificando os papéis de asseguarção e consultoria, enfatizando a agregação de valor, e na melhoria da eficácia dos processos de gerenciamento de risco, controle e governança corporativa (Spira & Page, 2004).

A AI era um pouco mais do que um controle de qualidade do serviço de *controller*, isto é, uma atividade integrante do departamento de Controladoria cujo trabalho era o de verificar se as operações de contabilidade da organização foram executadas corretamente. Posteriormente, a AI, que oferecia serviços de auditoria financeira, de *compliance* e de fraude para o *controller*, passou a oferecer serviços de consultoria para a administração da organização (Courtemanche, 1991). Adams (1988) utilizou a Teoria da Agência para explicar a existência da AI, a natureza de sua função e a abordagem particular adotada no trabalho dos auditores internos, atuando na solução de potenciais conflitos de interesse entre principal e agente, alertando o principal sobre os problemas que merecem atenção e que podem trazer ameaças aos recursos colocados sob responsabilidade do agente (Sawyer, 1988).

O papel do auditor interno evoluiu de uma função de apreciação, monitoramento e avaliação para uma função de asseguarção, consultoria, assistência e recomendação (Davies, 2001), destacando o papel crucial da AI em aprimorar a qualidade da governança corporativa (Spira & Page, 2004).

A agregação de valor aos negócios da organização é considerada outro importante aspecto da AI (Mihret, 2014). A atuação da AI estaria dedicada não somente à asseguarção da conformidade com políticas e procedimentos, mas também em incorporar um escopo mais amplo de atividades, incluindo gerenciamento de riscos (McNamee & McNamee, 1995; Carrington & Catasu, 2007; Sarens et al., 2011).

De acordo com a perspectiva da AI baseada em riscos (RBA – *Risk-Based Auditing*), a AI atua como um instrumento alinhado à estratégia da organização, identificando, medindo e priorizando os riscos para possibilitar o foco nos controles internos mais importantes, testando-

os com maior profundidade ou mais minuciosamente, e cobrindo um alcance mais amplo dos problemas que confrontam a administração, além de olhar para frente para acrescentar mais valor à organização, ao invés de se apoiar na avaliação de registros históricos (McNamee & McNamee, 1995). O estudo bibliométrico de Iguma e Riccio (2018) demonstra que “*risk*” (risco) foi o termo mais citado nas publicações sobre auditoria no contexto do uso de ferramentas de TI (Figura 4).

Figura 4 – Análise bibliométrica: palavras-chave específicas da área de auditoria

Fonte: Iguma e Riccio (2018)

O quadro 4 apresenta definições que representam diferentes pontos de vista sobre a IAF que continua passando por transformações e sendo revisada década a década (Moorthy, Seetharaman, Mohamed, Gopalan, & San, 2011).

É importante destacar as mudanças observadas nas definições do IIA em três épocas distintas. A definição de 1978 dá ênfase ao controle na atividade da AI e, em relação à definição de 1958, a Contabilidade deixou de ser citada. Já a definição de 1999 apresenta um escopo mais amplo da AI abrangendo gerenciamento de riscos, controle e governança.

Quadro 4 – Definições de Auditoria Interna em ordem cronológica

AUTORES	DEFINIÇÃO DE AUDITORIA INTERNA
Donald J. Bevis (citado por Sá, 1958, p.40)	A auditoria interna corresponde ao fator do sistema de controle interno estabelecido como instrumento independente para medir a adequação e eficácia de todos os outros controles financeiros e contábeis.
IIA (1958, citado por Ramamoorti, 2003)	A auditoria interna emerge como um segmento especial do amplo campo da contabilidade , utilizando as técnicas e os métodos básicos de auditoria. O auditor interno tem como foco a investigação da validade de representações. Contudo, diferentemente do auditor externo, está interessado em cobrir uma extensão muito maior e está envolvido em muitos assuntos em que a relação com as contas é geralmente um tanto remota.
Gonçalves (1967, citado por Pereira & Nascimento, 2005)	A auditoria interna é a função superior do controle econômico-financeiro da empresa. Nela repousa a base do controle interno da empresa.
Sá (1968, p.20)	Auditoria interna é uma parte especializada da auditoria que se dedica a um exame de maior profundidade e constância, executado por um serviço ligado à estrutura administrativa interna da azienda, visando proteger e sugerir, acompanhando os fatos patrimoniais.
IIA (1978, citado por Ramamoorti, 2003)	A auditoria interna é uma atividade de avaliação independente estabelecida dentro de uma organização como um serviço para a organização. É um controle que funciona examinando e avaliando a adequação e eficácia de outros controles. O objetivo da auditoria interna é auxiliar os membros da organização no cumprimento efetivo de suas responsabilidades. Para esse fim, a auditoria interna fornece análises, avaliações, recomendações, conselhos e informações sobre as atividades revisadas. O objetivo da auditoria inclui promover um controle efetivo a um custo razoável.
IBRACON (Instituto dos Auditores Independentes do Brasil, 1998, citado por Pereira & Nascimento, 2005)	Auditoria interna é uma atividade de avaliação organizada dentro de uma entidade, como um serviço para a entidade. Suas funções incluem, entre outras atribuições, examinar, avaliar e monitorar a adequação e eficácia dos sistemas contábeis e de controle interno.
IIA (1999, citado por Ramamoorti, 2003)	A auditoria interna é uma atividade independente e objetiva de avaliação (<i>assurance</i>) e de consultoria, desenhada para adicionar valor e melhorar as operações de uma organização. Ela auxilia uma organização a realizar seus objetivos a partir da aplicação de uma abordagem sistemática e disciplinada para avaliar e melhorar a eficácia dos processos de gerenciamento de riscos, controle e governança .

“continua”

“continuação”

AUTORES	DEFINIÇÃO DE AUDITORIA INTERNA
CFC (2003). NBC TI 01 - Normas Brasileiras de Contabilidade	A auditoria interna compreende os exames, análises, avaliações, levantamentos e comprovações metodologicamente estruturados para a avaliação da integridade, adequação, eficácia, eficiência e economicidade dos processos, dos sistemas de informações e de controles internos integrados ao ambiente e de gerenciamento de riscos, com vistas a assistir à administração da entidade no cumprimento de seus objetivos.
Mihret (2014)	Sob a perspectiva da <i>Labor Process Theory</i> (LPT), auditoria interna pode ser compreendida como uma função que ajuda a maximização do valor excedente e redução do desperdício e de qualquer desvalorização do capital resultante de fraude, corrupção ou ineficiência.

Fonte: Elaborado pelo autor

“conclusão”

Em 2009, o IIA publicou a Estrutura Internacional de Práticas Profissionais (IPPF – *International Professional Practices Framework*) fornecendo métodos organizados e orientações aos profissionais de AI do mundo. Posteriormente foi publicado o modelo de “Três Linhas de Defesa no Gerenciamento de Riscos e Controle” no intuito de esclarecer os papéis e as responsabilidades dos auditores internos e facilitar a coordenação de sua atuação com a de outras funções, a fim de evitar lacunas ou duplicidade de trabalho na cobertura dos controles. Além dos auditores internos, diferentes tipos de profissionais estão envolvidos em atividades de gerenciamento de riscos e controle dentro das organizações, tais como, especialistas em controles internos, inspetores de qualidade, investigadores de fraude, entre outros.

O modelo das três linhas de defesa é representado pelos seguintes grupos na estrutura de uma organização (IIA, 2013): (a) Primeira linha de defesa: Gestão Operacional; (b) Segunda linha de defesa: Gerenciamento de Riscos e Conformidade (*Compliance*); e (c) Terceira linha de defesa: Auditoria Interna.

O posicionamento do IIA quanto ao escopo de avaliação da AI, como terceira linha de defesa, tem como abrangência:

a) Uma grande variedade de objetivos, incluindo a eficiência e a eficácia das operações; a salvaguarda de ativos; a confiabilidade e a integridade dos processos de reporte; e a conformidade com leis, regulamentos, políticas, procedimentos e contratos; b) todos os elementos da estrutura de gerenciamento de riscos e controle interno, que inclui: o ambiente de controle interno; todos os elementos da estrutura de gerenciamento de riscos da organização (identificação, avaliação de riscos e resposta); informação e comunicação; e monitoramento; c) A empresa como um todo, divisões, subsidiárias, unidades de operação e funções - incluindo os processos do negócio, como vendas, produção, marketing, segurança, funções voltadas para o cliente e operações – assim como funções de suporte (ex., contabilidade de receita e despesas, recursos humanos, compras, folha de pagamento, orçamentos, gestão de infraestrutura e ativos, inventário e tecnologia da informação). (IIA, 2013, p.5)

2.4 Auditoria Interna e Conceitos Relacionados

O IBGC, Instituto Brasileiro de Governança Corporativa, fundado em 1995, foi a primeira organização dedicada à promoção da Governança Corporativa no Brasil. O relatório de 2018 elaborado pela parceria entre o IBGC e IIA Brasil destaca a relevância da AI como atividade para o fortalecimento da governança das organizações, e define Governança Corporativa como “o sistema pelo qual as organizações são dirigidas, monitoradas e incentivadas” (IBGC & IIA, 2018, p.19).

A Governança Corporativa “lida com as maneiras pelas quais os fornecedores de recursos financeiros das empresas asseguram-se de que irão obter retorno sobre o investimento” (Shleifer & Vishny, 1997). De acordo com a Organisation for Economic Co-Operation and Development (OECD), a Governança Corporativa envolve:

um conjunto de relacionamentos entre a administração de uma empresa, seu conselho, seus acionistas e outros stakeholders. A governança corporativa também fornece a estrutura através da qual os objetivos da empresa são definidos e os meios para atingir esses objetivos e monitorar o desempenho são determinados (OECD, 2004, p.11).

Desde o surgimento das organizações nasceu a necessidade de controlá-las (Vaassen et al., 2013). Segundo Martins (2009, p.305), controle significa “conhecer a realidade, compará-la com o que deveria ser, tomar conhecimento rápido das divergências e suas origens e tomar

atitudes para sua correção”. O controle interno, de forma mais específica, compreende o planejamento organizacional e todos os métodos e procedimentos adotados dentro de uma empresa, a fim de salvaguardar seus ativos, verificar a adequação e o suporte dos dados contábeis, promover a eficiência operacional e encorajar a aderência às políticas definidas pela direção (Migliavacca, 2002; Almeida, 2011).

Os aspectos de controle interno e sua aplicação no contexto da Governança Corporativa têm recebido atenção internacional, sendo estudados por comitês de pesquisa, principalmente com a promulgação da SOX nos Estados Unidos.

Vaassen, Meuwissen e Schelleman (2013) especificaram os tipos de medidas de controle interno: verificações detalhadas (checagem total e observação parcial); verificações formais e materiais; verificações negativas e positivas; controles de políticas; controle de padrões; controle de expectativas; controle de autoridade; controle de progresso; controle de eficiência; controle da execução; e controle de custódia. Moscovice, Simkin e Bagranoff (2002) identificaram três tipos principais de procedimentos de controle de uma empresa: controles preventivos, controles de detecção e controles corretivos.

O *framework* do *Committee of Sponsoring Organizations of the Treadway Commission* (COSO), metodologia de controle interno recomendada fortemente pela SOX como *benchmark* para as companhias de capital aberto, influenciou significativamente a consciência de risco e controle das companhias (Sarens & De Beelde, 2006). Essa estrutura foi concebida pelo esforço conjunto de cinco institutos regulatórios norte-americanos (AICPA – *American Institute of Certified Public Accountants*, FEI – *Financial Executives International*, IIA – *The Institute of Internal Auditors*, AAA – *American Accounting Association* e IMA – *Institute of Management Accountants*).

A definição de Controle Interno segundo o COSO é um “processo conduzido pela estrutura de governança, administração e outros profissionais da entidade, e desenvolvido para proporcionar segurança razoável com respeito à realização dos objetivos relacionados a operações, divulgação e conformidade” (COSO, 2013, p. 6).

Os dois principais modelos do COSO, ICIF (*Internal Control – Integrated Framework*) e o ERM (*Enterprise Risk Management*), têm focos diferentes e são complementares (COSO, 2017). Em 1992, o COSO publicou o modelo ICIF que descreve os componentes do controle interno e apresenta os critérios para avaliação dos SCI da organização (COSO, 2013): (a)

Ambiente de controle; (b) Avaliação de riscos; (c) Atividades de controle; (d) Informação e comunicação; e (e) Atividades de monitoramento.

Em 2004 o COSO emitiu novo relatório denominado Gerenciamento de Riscos Corporativos - Estrutura Integrada (*Enterprise Risk Management - Integrated Framework*), ou COSO II, abordando a evolução do gerenciamento de riscos corporativos em um ambiente de negócios em contínuo desenvolvimento.

Posteriormente, foi lançada uma versão atualizada intitulada Gerenciamento dos Riscos Corporativos – Integrado com Estratégia e Performance (*Enterprise Risk Management - Integrating with Strategy and Performance*), abordando o risco tanto no processo de definição de estratégias como na melhoria de performance. Em 2013, o modelo COSO original de 1992 foi revisado, ao qual foram incluídos 17 princípios associados aos componentes do controle interno (COSO, 2013).

Para melhor entendimento do conceito de “controle” e sua relação com o processo organizacional, a Figura 5 demonstra o exemplo de um controle e seus elementos em um sistema de produção: a) a entrada (*input*) inclui pessoas, máquinas e matéria-prima; b) o processamento converte a matéria-prima e mão-de-obra em um produto; c) a saída (*output*) inclui o produto acabado; d) o SCI inclui o controle de produção, que regula o fluxo de entrada de materiais e serviços e inspeciona a saída; e) o controle compara a saída com os padrões por meio de inspeções; f) o *feedback* informa as divergências com o elemento de entrada; e g) a ação corretiva aperfeiçoa o processo para melhor atender aos padrões aceitáveis.

Figura 5 – Controle e processo organizacional

Fonte: Sawyer (1988, p.95)

Os processos organizacionais podem ser classificados como primários e secundários (Vaassen et al., 2013). Os processos primários são essenciais para a sobrevivência da organização (compras, estoque, produção, vendas), enquanto que os secundários (gestão de recursos humanos, investimento em ativos fixos, gestão de caixa, contabilidade e livro-razão) servem de apoio para os processos primários.

Para demonstrar as inter-relações entre os processos, os autores apresentaram o exemplo da Figura 6.

Figura 6 – Ciclo de valor de uma empresa de comércio exterior que utiliza atividades eletrônicas

Fonte: Adaptado de Vaassen et al. (2013, p. 118)

A Figura 7 demonstra o fluxograma de sistemas de um exemplo de processo de compra, descrevendo o fluxo de documentos (como a comunicação flui pela organização), assim como a série de medidas de controle interno (comparação das faturas com as ordens de compras e os relatórios de recebimento).

Figura 7 – Fluxograma de sistemas do processo de compra

Fonte: Adaptado de Vaassen et al. (2013, p. 135)

Conforme o exemplo da Figura 7, o processo de compras tem início na área de estoques que envia a requisição de compras para o departamento de compras. Após realizar a cotação com três fornecedores, com base nas informações dos arquivos de fornecedores e de estoques, o departamento de compras envia a solicitação ao fornecedor que apresentou a melhor cotação.

Em seguida, a confirmação do recebimento da requisição é enviada ao departamento de compras que, por sua vez, envia a notificação ao departamento de contas a pagar. Quando os bens são recebidos pela área de estoque, um relatório é enviado ao departamento de contas a pagar, que compara a fatura com a notificação de requisição de compra e com o relatório de recebimento.

Por fim, caso os três documentos estejam de acordo, o departamento de contas a pagar atualiza o livro-razão auxiliar do contas a pagar, estabelece o pagamento (aprova o pagamento da fatura) e autoriza o caixa a realizar o pagamento ao fornecedor (Vaassen et al., 2013). O quadro 5 traz uma visão geral dos riscos, exposições e controles aplicáveis referente ao exemplo do processo de Compras.

Quadro 5 – Riscos, exposições e controles internos no processo de compras

RISCO	EXPOSIÇÃO	CONTROLES INTERNOS
Influência dos fornecedores em relação aos agentes de compras por meio de propinas, comissões secretas ou outras formas de indução.	Custo mais alto de bens a serem comprados em relação à qualidade dos bens ou serviços.	Seleção adequada e recompensa aos agentes de compras.
		Verificações amostrais detalhadas de preços de compras pelo controller ou chefe do departamento contábil.
		Exame analítico dos preços de compras.
Comprar quantidade excessiva	Custos de estoque muito altos	Não autorizar as compras pelo departamento de compras, mas pelo solicitante
		Registros de inventário permanentes e adequados.
Comprar bens a preços inflacionados	Custos de compra muito altos	Comparação de preço de compra com lista de preços antes de fazer a compra.
Comprar bens de qualidade inferior	Clientes insatisfeitos ou atrasos na produção	Comprar de fornecedores previamente selecionados
		Avaliação periódica de preços e qualidade dos fornecedores
Comprar quantidade insuficiente	Clientes insatisfeitos ou atrasos na produção	Registros de inventário permanentes e adequados
Pagar por bens que não foram recebidos	Perda de dinheiro	Conciliação das faturas com os bens recebidos pelo controller ou chefe do departamento contábil

Fonte: Vaassen et al., 2013, p. 158

Existem duas abordagens básicas para a criação de um SCI: a primeira, baseada na tipologia de organizações a partir da perspectiva do controle interno (comércio, produção e serviços) enquanto que a segunda abordagem baseia-se em processos de transações que ocorrem dentro das organizações (processos de compra, de venda, de produção, de contabilidade e de recursos humanos) (Vaassen et al., 2013). Os controles internos precisam ser documentados e disponibilizados aos usuários, geralmente por meio de um manual de controles internos contendo os seguintes componentes: (a) descrição da organização, incluindo sua estrutura, estratégia, cultura (inclusive o ambiente de controle); (b) uma avaliação da probabilidade e do impacto de determinados riscos; (c) descrição dos controles internos por processo, incluindo informações dos procedimentos administrativos, controles a serem usados, fluxo de dados, coleções de dados e departamentos ou escritórios envolvidos no processo.

Segundo Moscove, Simkin e Bagranoff (2002), certos elementos essenciais devem ser incluídos no SCI de toda companhia: (1) trilha de auditoria, (2) boas práticas e políticas de pessoal, (3) separação (ou segregação) de funções, (4) proteção física dos ativos, (5) revisão interna dos controles pelo subsistema de auditoria e (6) relatório de desempenho dos controles internos.

A segregação (ou separação) de funções é uma medida de controle preventivo que focaliza a estruturação das atribuições de tarefas, de tal modo que, as atividades de uns funcionários sirvam para conferir as de outros funcionários, com a previsão de três funções: autorizar transações, registrar transações e manter custódia de ativos. Ela reduz tanto o risco de erros humanos quanto o risco de fraude, assegurando que os funcionários não tenham sob sua responsabilidade um ciclo completo de operações. Um caso que ilustra a importância da segregação de funções é o da instituição financeira inglesa Baring Bank, que encerrou suas atividades em 1995. A causa de sua falência foi atribuída a Nick Leeson, que ocupou as posições de gerente de operações de derivativos, gerente geral e *trader* chefe em Singapura, atuando tanto no *front* como no *back office*. Leeson praticou diversas atividades fraudulentas envolvendo negociações especulativas no mercado de derivativos financeiros, que foi facilitada pela ausência de controles internos e externos (Kornert, 2003; Pickett, 2011; Imoniana, 2019).

A ameaça de fraude é um dos desafios de governança mais comuns que as organizações enfrentam, independentemente de seu tamanho, indústria ou localização, e que geralmente está associada à ocorrência de falhas nos controles internos da companhia (Imoniana, 2019; Silva; 2012). Ao longo dos anos, pesquisas têm abordado a inclusão da atividade de detecção de fraude no trabalho do auditor interno e demonstrado também que a função de AI tem um importante papel na qualidade das demonstrações financeiras, especialmente nas áreas de prevenção e

detecção de fraudes (Church, McMillan, & Schneider, 2001; Coram, Ferguson, & Moroney, 2008). Contudo, segundo o posicionamento do IIA, o papel da AI é o de avaliar os controles de prevenção ou detecção de fraudes. A investigação de fraudes somente deve ser executada pelo auditor interno com experiência específica e conhecimento necessário para fazê-lo.

2.5 Procedimentos e Técnicas de Auditoria Interna

A atividade da AI está estruturada em procedimentos com enfoque técnico, objetivo, sistemático e disciplinado (CFC, 2003). Crepaldi (2012) aponta a importância dos procedimentos de auditoria, que são investigações técnicas que, tomadas em conjunto, permitem a formação fundamentada de opinião. A opinião formada pelo auditor precisa estar, inquestionavelmente, apoiada em fatos comprovados, evidências factuais e informações irrefutáveis (Attie, 2011). Deste modo, a evidência de auditoria consiste na informação obtida pelo auditor interno que fundamenta os resultados da AI, servindo de base factual para opiniões, conclusões e recomendações à administração da entidade. As evidências de auditoria podem ser classificadas como física, testemunhal, documental e analítica, e devem passar por testes de suficiência, competência e relevância (Sawyer, 1988).

O trabalho de campo (*field work*) é o processo sistemático de coletar evidências objetivamente sobre as operações de uma entidade, cujo propósito é executar os procedimentos de auditoria que estão especificados no programa de auditoria, em resposta aos objetivos de auditoria. As informações e apontamentos obtidos pelo auditor durante seu exame, bem como as provas e descrições dessas realizações que constituem a evidência do trabalho executado e o fundamento da sua opinião, são documentadas em um conjunto de formulários conhecidos como papéis de trabalho (*working papers*) (Coderre, 2005; Ratliff, Wallace, Loebbecke, & McFarland, 1988).

Os testes de observância visam à obtenção de razoável segurança de que os controles internos estabelecidos pela administração estão em efetivo funcionamento, e são aplicados por meio de inspeção, observação, investigação e confirmação. Os testes substantivos são utilizados para obtenção de evidência quanto à suficiência, exatidão e validade dos dados produzidos pelos sistemas de informação da entidade, sendo direcionados para todas áreas fracas conhecidas, incluindo aquelas áreas cujos controles não foram cobertos durante os testes de observância (Pickett, 2011). O quadro 6 apresenta o resumo dos principais procedimentos de AI mencionados na literatura (Gil, 2000; CFC, 2003; Pickett, 2011; Crepaldi, 2012; Imoniana, 2019).

Quadro 6 – Procedimentos de Auditoria Interna

Procedimentos	Descrição
Exame físico e contagem	É a verificação <i>in loco</i> das características do item examinado: quantidade, identificação, autenticidade, qualidade. Exemplo: inventário, contagem de estoques.
Observação de procedimentos	Observar as atividades e os procedimentos do auditado em operação é um método útil para a coleta de informações visto que é obtida em primeira-mão pelo auditor interno.
Confirmação e circularização	A confirmação dos fatos de uma área tendo terceiros como referência é um meio de verificar a precisão desses fatos. Quanto mais independentes forem os terceiros, mais confiáveis serão os resultados.
Inquérito e investigação minuciosa	Formulação de perguntas e obtenção de respostas satisfatórias, por meio de entrevistas, aplicação de questionários, declarações formais e conversações informais.
Exame de registros auxiliares	Com o objetivo de comprovar o registro principal.
Reconciliação	O processo de comparar um conjunto de figuras com outro conjunto tem base no princípio de partidas dobradas que garante o equilíbrio entre as contas contábeis. Pode ser executado para fornecer evidências sobre a adequação dos controles.
Conferência de cálculos	O recálculo envolve o exame de elementos derivados de outros elementos para verificar a sua precisão. Exemplo: listagem de estoque.
Canais de denúncias	Canal utilizado para a comunicação de irregularidades ou agressões aos diversos sistemas do negócio.
<i>Walk-through</i>	O procedimento leva os auditores passo a passo através de processos específicos.

Fonte: Elaborado pelo autor

Ratliff, Wallace, Loebbecke e McFarland (1988) descrevem a AI como um processo de pensamento crítico, de análise e avaliação cuidadosa, diferentemente de um processo conduzido de forma mecânica. Na figura 8, o fluxograma apresenta os nove passos do processo de AI propostos pelos autores, que será detalhado na sequência.

Figura 8 – Passos do processo de Auditoria Interna

Fonte: Adaptado de Ratliff et al. (1988, p.174)

Por “auditado” entende-se a entidade, subsidiária, operação, programa organizacional, ou mesmo um processo isolado, atividade ou condição da organização. O **primeiro passo**, que corresponde ao processo de seleção de um auditado, é determinado pelo conceito de risco que corresponde à probabilidade de perda ou incerteza associada ao cumprimento de um objetivo. Existem três métodos pelos quais o auditado pode ser selecionado: seleção sistemática pelo estabelecimento de um plano de auditoria baseado na avaliação de riscos; *ad hoc* por solicitação

da administração ou do conselho, às vezes em caráter de emergência; e por solicitação do auditado (Ratliff et al., 1988).

Após determinar o que será auditado, os auditores começam a preparação da auditoria num conjunto de sete fases no **segundo passo**: (1) uma definição preliminar dos objetivos e do escopo de auditoria; (2) revisão dos arquivos e outros materiais de auditorias anteriores; (3) seleção da equipe de auditoria e de outros recursos; (4) comunicação preliminar com o auditado sobre a auditoria que será realizada; (5) preparação do programa de auditoria preliminar; (6) determinar como, quando e para quem os resultados serão comunicados; e (7) obter aprovação da abordagem de auditoria (Ratliff et al., 1988).

No **terceiro passo**, o levantamento preliminar é realizado no local do auditado (*on site*), abrangendo um conjunto de procedimentos para fornecer aos auditores e aos auditados o conhecimento sobre o ponto de partida do trabalho de auditoria que será realizado na revisão de controles internos: (1) a conferência de abertura; (2) visita ao local do auditado (*on-site tour*); (3) estudo dos documentos; (4) descrição por escrito do auditado por meio de explicações narrativas, fluxogramas, diagramas organizacionais, assim como informações sobre o desempenho financeiro e operacional; e (5) revisões analíticas (*Analytical Review*) para fornecer melhor entendimento sobre as operações do auditado que são representadas por termos quantitativos que revelam variações e tendências, chamando a atenção dos auditores para as áreas com potenciais problemas específicos e sujeitas a riscos (Ratliff et al., 1988).

O procedimento de revisão analítica (ARP – *Analytical Review Procedures*) abrange o estudo dos relacionamentos entre dados selecionados ou dados agregados e pode ser usado para determinar a razoabilidade dos registros da informação financeira e avaliar resultados operacionais. O uso principal do ARP e de outras técnicas quantitativas é o de fornecer a evidência de auditoria. Outros benefícios da ARP incluem: fornecer subsídios na definição do escopo de auditoria; seleção de entidades para auditar; foco da atenção em áreas com problemas potenciais; relativa facilidade para executar; e um meio para melhorar a análise de riscos. Geralmente, essas técnicas têm menor custo e consomem menor tempo do que outros testes substantivos. As técnicas de ARP podem ser classificadas em três categorias: não quantitativas ou de julgamento, tal como escaneamento (*scanning*); quantitativas simples, tais como testes de tendência, de *ratio* e de razoabilidade; e quantitativas avançadas, tais como análise de regressão e redes neurais. Além das técnicas citadas, outras técnicas quantitativas podem ser aplicadas na análise do auditor interno tais como programação linear, teoria da probabilidade, modelos de inventário, análise sensível, teoria dos jogos (*game theory*), simulações e árvores de decisão (Sawyer, 1988).

A revisão dos controles internos, que abrange a descrição, análise, avaliação dos controles internos e avaliação de riscos estão contemplados no **quarto passo**. Este passo compreende a conclusão do questionário, fluxogramas, descrições narrativas, *walk-throughs*, teste limitado do sistema de controles internos e matrizes de controles internos. Os resultados da avaliação de riscos determinam se os auditores irão ampliar os testes (**quinto passo**) ou se passarão diretamente para **sexto passo**, para desenvolver descobertas, conclusões e recomendações para os auditados (Ratliff et al., 1988).

O **quinto passo**, também denominado trabalho de campo por alguns auditores, representa o coração da maioria das auditorias. Os auditores geralmente decidem realizar um exame mais profundo do auditado, principalmente por conta das incertezas remanescentes dos passos de auditoria anteriores. Enquanto a análise dos controles internos e o levantamento preliminares são projetados para descobrir possíveis pontos fracos e pontos fortes dos controles, o teste expandido serve para confirmar essas informações e quantificar a exposição dos riscos relacionados, fornecendo também um estudo sobre como o auditado interage com outras partes da organização e com os elementos do ambiente organizacional. Essencialmente, três objetivos do teste expandido devem ser considerados: (1) revisão das operações e dos controles projetados para tornar as operações eficazes e eficientes; (2) teste para determinar se as operações estão em conformidade (*compliance*) com o sistema de controle projetado; e (3) avaliação do projeto do sistema de controle e do efeito da conformidade ou não conformidade com os controles. Para executar o teste expandido, o auditor tem a oportunidade de utilizar o seu completo conjunto de ferramentas, incluindo habilidades para entrevistas e outros relacionamentos humanos, organização de papéis de trabalho (*working papers*), senso aguçado de lógica, conhecimento de técnicas de amostragem estatística e outros métodos quantitativos, e de ferramentas de *software* para avaliar o ambiente tecnológico. Por fim, os auditores estarão preparados para realizar uma avaliação final do sistema de controle e assim formular recomendações (Ratliff et al., 1988).

No início, o trabalho do auditor consistia principalmente na reexecução de todos os procedimentos de escrituração de livros contábeis e fiscais. Entretanto, essa técnica tornou-se obsoleta e com o aperfeiçoamento do processo de auditoria, foram adotadas diversas ferramentas no dia a dia do auditor, tais como modelagem sofisticada de risco, amostragem estatística, técnicas de auditoria assistidas por computador e gestão de qualidade total orientada ao cliente (Mihret, 2014; Silva, 2012).

A utilização de modelos estatísticos auxilia os auditores internos na geração de hipóteses corretas, eliminando os falsos positivos de uma abordagem conduzida através de procedimentos analíticos; assim como o uso de indicadores e critérios estatísticos ajudam a coletar evidências adicionais que podem melhorar o entendimento e o julgamento por parte do auditor (Leitch & Chen, 2003; Green & Trotman, 2003).

Amostragem estatística corresponde ao processo de aplicar processos de auditoria em menos que 100% da população para se chegar a conclusões sobre a população. A determinação da amostra permite ao auditor interno emitir uma opinião sobre o universo a partir da análise de um subconjunto representativo como, por exemplo, selecionar uma amostra do universo cliente de uma agência bancária valendo-se dos seguintes critérios: contas não movimentadas; contas com maior saldo; e contas com maior frequência ou períodos negativos (Gil, 2000). O auditor deve decidir sobre (1) qual abordagem de amostragem utilizar, (2) quantas unidades selecionar, (3) como selecionar as unidades, (4) como avaliar e documentar os resultados em termos dos objetivos da auditoria. Os princípios em que o processo de amostragem científica está baseado operam somente se a amostra for selecionada aleatoriamente. Existem diferentes tipos de seleção randômica: (1) amostragem numérica randômica; (2) amostragem de intervalo (sistemática); (3) estratificada, (4) *cluster* (Sawyer, 1998).

Com a conclusão do estudo e da avaliação do auditado, os auditores estão preparados para desenvolver os seus achados e determinar quais mudanças são necessárias para melhorar os controles internos no **sexto passo**. Os achados compreendem as condições observadas, o critério adotado para avaliar a condição, o efeito (ou risco) associado a quaisquer problemas observados, e as causas dos problemas. As recomendações podem ser realizadas de quatro formas: (1) nenhuma mudança no sistema de controle; (2) aumentar o controle; (3) proteção para cobrir certos riscos; e (4) mudanças em taxas de retorno dos riscos em investimentos. Em seguida, o **sétimo passo** inclui a documentação e a comunicação dos resultados da auditoria. O relatório contém uma explicação dos objetivos, escopo, questões, procedimentos gerais, achados e recomendações da auditoria. Após a entrega do relatório de auditoria e sua apresentação, o auditado tem a oportunidade de responder ao relatório, no **oitavo passo**, correspondente ao acompanhamento da auditoria (*follow-up*) e que pode ser conduzido de três formas: (1) a alta gerência pode consultar o auditado para decidir se, quando e como as recomendações do auditor serão atendidas; (2) o auditado deve agir sobre tais decisões; e (3) os auditores aguardam um período de tempo após a conclusão da auditoria, e verificam se as ações corretivas foram atendidas e os resultados desejados foram alcançados, ou se a administração e

o conselho assumiram a responsabilidade em não atender as ações corretivas (Ratliff et al., 1988).

O **nono e último passo** corresponde à avaliação dos auditores sobre o trabalho de auditoria realizado, com relação à sua eficácia, para determinar o que poderia ser feito para melhorar o seu desempenho e como as futuras auditorias poderão se beneficiar a partir de um trabalho concluído (Ratliff et al., 1988).

2.6 O Uso de Ferramentas de TI pela Auditoria Interna

A teoria prevê três tipos de abordagens sobre a forma como os auditores utilizam recursos e soluções de TI (Bierstaker, Burnaby, & Thibodeau, 2001; Moscovice, Simkin, & Bagranoff, 2002; Braun & Davies, 2003; Silva, 2012; Pedrosa, 2015; Imoniana, 2016):

- a) Auditoria em torno do computador (*around the computer*): pressupõe que a presença de relatórios corretos indica operações de processamento corretas, testando transações normais, mas ignora as exceções. Esta abordagem requer do auditor interno pouco treinamento em TI, não sendo uma prática eficaz de auditoria em ambientes computadorizados complexos e de alta tecnologia. O auditor, por exemplo, realiza manualmente os mesmos cálculos e compara os seus resultados com os dos relatórios, tratando o processo da aplicação de computador como uma caixa-preta;
- b) Auditoria por meio do computador (*through the computer*): o auditor segue a trilha de auditoria mediante as fases de operações internas do computador no processamento automático de dados, envolvendo teste e validação dos programas de computador e uma avaliação dos aplicativos de sistema. Deste modo, a principal tarefa do auditor interno é verificar a lógica do processamento e controle e não a correção dos cálculos. Existem quatro formas relacionadas a essa abordagem: (1) uso de dados de teste, teste integrado e simulação paralela para testar programas; (2) uso de técnicas de auditoria para validar os programas de computador; (3) uso de listagens e aplicativos especializados de controle para avaliar aplicativos de sistemas; e (4) uso de módulos de auditoria para realizar auditoria contínua.
- c) Auditoria com computador (*with the computer*): nessa abordagem, o computador torna-se uma ferramenta que auxilia em vários processos de auditoria. Os auditores internos podem usar CAATs para ajudá-los em várias tarefas num ambiente informatizado em que os dados devem ser obtidos dos ambientes computacionais em que estão armazenados.

Pesquisadores concordam que a abordagem de auditoria em torno do computador é a menos viável diante do atual contexto das organizações, em constante evolução dos modelos de negócios e da complexidade dos ambientes tecnológicos (Silva, 2012; Moscovice, Simkin, & Bagranoff, 2002; Bierstaker, Burnaby, & Thibodeau, 2001).

O termo *Computer-Assisted Audit Tools* (CAATs) ou *Computer-Assisted Audit Tools and Techniques* (CAATTs), que pode ser definido como qualquer uso da tecnologia para auxiliar na realização de um trabalho de auditoria, tanto a AI como a auditoria externa (Braun & Davis, 2003; Mahzan & Lymer, 2008), inclui programas de processamento de texto, ferramentas para a produção de papéis de trabalho (*working papers*), planilhas eletrônicas, sistemas de bancos de dados, ferramentas para análise e extração de dados, linguagem de consulta estruturada (SQL – *Structured Query Language*), bem como ferramentas para suporte a testes substantivos, *softwares* para predição do comportamento de dados (*data mining*) e para análises estatísticas tais como amostragem e regressão.

O termo CAATTs, que é empregado pelo AICPA desde 1979 para representar as técnicas que permitem a realização de testes de forma diferente daqueles executados manualmente (AICPA, 1979), foi precedido por outras designações tais como “*Computer Audit Software*”, “*Computer Audit Packages*” e “*EDP – Electronic Data Processing*”.

Bierstaker, Janvrin e Lowe (2014) relacionaram tarefas de auditoria com a utilização de ferramentas de CAATTs: 1. avaliar riscos de fraude; 2. identificar lançamentos contábeis manuais e outros ajustes a serem testados; 3. verificar a precisão dos arquivos eletrônicos; 4. reexecutar procedimentos; 5. selecionar amostras de transações nos principais arquivos eletrônicos; 6. classificar transações com características específicas; 7. testar uma população inteira em vez de uma amostra; 8. obter evidência sobre a eficácia do controle; 9. avaliar a existência e integridade do inventário. CAATTs podem ser classificados em dois grupos de técnicas e ferramentas de auditoria (Braun & Davis, 2003) de acordo com o tipo de exame da lógica da aplicação:

- a) Exame direto da lógica interna da aplicação: teste de dados, Facilidade de Teste Integrado (ITF – *Integrated Test Facility*) e simulação paralela;
- b) Exame indireto, por meio de realização de inferências sobre a lógica da aplicação a partir dos dados processados por ela: Módulo Integrado de Auditoria (EAM – *Embedded Audit Module*) e GAS (*Generalized Audit Software*).

As ferramentas conhecidas como GAS são consideradas as CAATTs mais comumente utilizadas (Ahmi, 2012) que podem assumir a forma de pacotes de *software* comerciais ou desenvolvidos internamente por especialistas da companhia (Sawyer, 1988). Alguns autores classificam como GAS as ferramentas IDEA (*Interactive Data Extraction and Analysis*) e ACL (*Audit Command Language*), utilizados para extração, manipulação e sumarização de dados, execução de *queries* em bancos de dados, e tarefas analíticas para posterior condução de análises e rotinas de auditoria (Debreceny, Lee, Neo, & Shuling, 2005).

Fay e Negangard (2017) relacionam os principais benefícios das ferramentas GAS: (a) testar populações inteiras de dados em vez de apenas uma amostra; (b) analisar dados de uma variedade de fontes; (c) auxiliar na avaliação de riscos, identificando tendências e anomalias nos dados; (d) facilitar a análise abrangente das transações; (e) processar grandes volumes de dados quase instantaneamente; (f) manter a integridade dos dados de origem, armazenando e apresentando dados importados em um formato somente leitura; (g) executar procedimentos comuns de auditoria com o clique de um botão; (h) funcionar com qualquer tamanho de arquivo e um número ilimitado de registros; e (i) criar *log* de todas as ações executadas pelo usuário.

Diversos pesquisadores têm investigado o impacto do ERP sobre as atividades de AI, os mecanismos de controle interno e a qualidade da informação gerada por essa tecnologia (Madani, 2009). Devido à integração de programas e arquivos de dados em um único sistema ERP, não há subsistemas, partições ou sistemas legados isolados que necessitam de ações de reconciliação. Riccio (2001) define ERP como:

“um sistema de informação que sincroniza, integra e controla em tempo real os processos de uma empresa pelo emprego de tecnologia de informação avançada. Foi concebido dentro do conceito de Sistema de Informação Único para toda a empresa. É composto por módulos integrados por um único banco de dados e configurados para atender às necessidades específicas de cada organização. O ERP induz a alterações nos processos, pois traz embutido no software as melhores práticas para operação de uma empresa. O ERP requer que os diversos setores operem de maneira integrada, sincronizada e colaborativa na operação e na solução de problemas. Cada usuário depende dos demais para o bom funcionamento do sistema como um todo. Consequentemente, o relacionamento entre os departamentos, incluindo a Contabilidade, obrigatoriamente passa a ser mais constante e intenso.” (p. 11)

O ERP também inclui recursos de controle e de auditoria, tais como ferramentas de administração de perfis, *workflow* de negócios, funcionalidades de *log* e recursos de rastreamento completo de transação, favoráveis ao trabalho dos auditores internos. Por outro lado, embora ofereça vantagens, a utilização de ERP pode tornar a organização mais vulnerável a potenciais ameaças provenientes de intrusos internos e externos tentando acessar informação sensível, modificar dados e cometer outros atos indesejáveis no sistema. Para solucionar potenciais problemas, segundo a literatura, a AI deverá assumir um papel no processo de monitoria contínua (Madani, 2009; Silva, 2012).

Apontada por pesquisadores como o futuro da auditoria empresarial, substituindo a auditoria tradicional (Vasarhelyi, Tostes, Alles, & Riccio, 2006; Chan & Vasarhelyi, 2011), a Auditoria Contínua (AC), que também é conhecida por “asseguração contínua”, “auditoria em tempo real”, “auditoria remota”, “auditoria à distância” e “monitoramento contínuo” é uma metodologia usada para monitorar analiticamente processos corporativos de negócios, aproveitando a automação e integração dos processos de negócio e da TI (Vasarhelyi & Halper, 1991). De acordo com essa visão, a auditoria deixa de ser executada periodicamente, de forma estática, para operar o monitoramento de forma contínua, abrangendo todo o processo de negócios e riscos associados, cobrindo uma porcentagem muito maior de dados da empresa, gerando alarmes e relatórios de exceções levantadas durante o teste contínuo para que os auditores as tratem oportunamente (Lombardi, Bloch & Vasarhelyi, 2014; Nascimento, 2019). O conceito atual de Auditoria Contínua, de acordo com Silva (2012),

“está relacionado com a disponibilidade de dados mais próximos de um evento, se possível em tempo real, com capacidade de ser processado e correlacionado em um ambiente computadorizado e seguro, que traga informações eletrônicas fidedignas, que serão tratadas pelos auditores e pelos gestores da organização.” (p. 10)

O objetivo da AC em reduzir a latência entre a ocorrência da transação de negócio e a avaliação sobre aquela transação é atingido por meio de uma forte dependência em TI, como sistemas ERP, *softwares* de *Business Intelligence* (BI), soluções de aplicação *web* (Vasarhelyi et al., 2012). Os dados capturados pela AC podem ser mantidos em um *data mart* específico destinados para esse fim, com as evidências coletadas em tempo real em relação ao processamento do sistema de aplicação, sendo os dados disponibilizados para posteriores análises por meio de ferramentas analíticas de *software* (Rezaee, Sharbatoghlie, Elam, & McMickle, 2002).

Data warehouse pode ser definido como um único grande repositório que integra dados obtidos de todos os sistemas de aplicação através da organização, acompanhado por ferramentas de extração e análise de dados, enquanto que os *data marts* são repositórios menores no nível de uma área funcional específica, cuja criação passa pelas três fases do ETL: extração, transformação e carga. Um *data mart* integrado apresenta as seguintes funcionalidades: (a) *query*, análise e relatórios integrados através de uma interface unificada de usuário; (b) capacidade para exportar os resultados das *queries* para planilhas eletrônicas e sistemas de banco de dados comuns; (c) um mecanismo de busca capaz de acessar e processar grandes volumes de dados; (d) funcionalidade para agregação de dados e banco de dados multidimensional; (e) funcionalidades de exploração e avançada modelagem estatística de dados; e (f) funcionalidade de visualização de dados para exploração de *data mining* e identificação de padrões e tendências nos dados.

Data mining é uma área ampla que integra técnicas provenientes de campos como o aprendizado de máquina (*machine learning*), a estatística, o reconhecimento de padrões, a inteligência artificial e sistemas de banco de dados, para possibilitar a análise de grandes volumes de dados com o foco em modelagem e na descoberta de conhecimento para uma abordagem preditiva e não descritiva. As técnicas de *data mining* são aplicadas em métodos de solução de problemas e em *data analytics* de uso geral (Marjani et al, 2017; Bihani & Patil, 2014). Os algoritmos de *data mining* foram desenvolvidos por pesquisadores integrantes de comunidades de inteligência artificial tais como k-means, SVM (*Support Vector Machine*) e *Naive Bayes*. Tais algoritmos, que abarcam os tipos de análise como classificação, *clustering*, regressão e análise de associação, foram incorporados em sistemas de *data mining* comerciais (Chen, Chiang, & Storey, 2012).

Por exemplo, o e-mail corporativo é uma importante forma de evidência de auditoria que inclui o contexto, a intenção e os resultados de ações gerenciais. Debreceeny e Gray (2011) aplicaram técnicas de *data mining* sobre mensagens de e-mails da Enron nas fases do trabalho de auditoria, combinando o entendimento das redes sociais, o processamento de análise textual (*textual analysis*) com o uso de processamento de linguagem natural.

Data mining também pode ser adotada para orientar o julgamento do auditor na formulação de opinião sobre a continuidade da entidade (*going concern*), como uma solução alternativa às técnicas de estatística de regressão logística (Martens, Bruynseels, Baesens, Willekens, & Vanthienen, 2008).

Text mining (mineração de texto) pode ser vista como uma técnica de EDA de exploração de informações contidas em documentos textuais de várias maneiras, incluindo a

descoberta de padrões e tendências nos dados e a identificação de associação entre entidades descritas nos dados de texto (Liu, 2014). Holton (2009) aplicou técnicas de *text mining* combinadas com o modelo *Naive Bayesian* para analisar mensagens de e-mails de empregados de uma companhia no intuito de detectar fatores motivacionais de atividades fraudulentas. Segundo a pesquisadora, empregados insatisfeitos constituem o principal fator associado à ocorrência de fraudes ocupacionais, causando prejuízos de \$652 bilhões nas organizações dos Estados Unidos.

A técnica de *process mining* (mineração de processos) é uma variação do *data mining* que se concentra nos processos e não nos dados, permitindo aos usuários descobrir, extrair conhecimento, controlar e aprimorar processos analisando *logs* de eventos. Um “*log* de eventos”, também chamado de “trilha de auditoria”, corresponde ao registro cronológico das atividades do sistema de computador que é armazenado em um arquivo no sistema e geralmente inclui quatro componentes: (1) a atividade que está ocorrendo durante o evento, (2) a instância do processo do evento, (3) o criador ou a parte responsável pelo evento e (4) o registro de data e hora do evento (Liu, 2014; Jans et al., 2010).

O termo *data analytics* refere-se ao uso extensivo e sistemático de dados, análise estatística e quantitativa, análise exploratória e preditiva e gerenciamento baseado em fatos para conduzir decisões e ações de negócios (Davenport & Kim, 2013), por meio de tecnologias de *Business Intelligence and Analytics* (BI&A) que incluem *data mining*, *Relational Database Management Systems* (RDBMS), *data warehousing*, ferramentas de ETL (*Extraction, Transformation and Load*), *Online Analytical Processing* (OLAP) e *Business Performance Management* (BPM) (Chen et al., 2012).

O termo *audit analytics* é empregado por alguns autores para se referir ao uso de *data analytics* no domínio da auditoria (Li, Dai, Gershberg, & Vasarhelyi, 2018; Kuenkaikaew, 2013) e é definido como uma ciência de “descoberta e análise de padrões, identificação de anomalias e extração de outras informações úteis nos dados subjacentes ou relacionados ao objeto de uma auditoria por meio de análise, modelagem e visualização com o objetivo de planejar ou executar a auditoria” (AICPA, 2015).

Em comparação aos CAATTs tradicionais, *audit analytics* requer conhecimentos e habilidades especiais do auditor, pois a falha no entendimento completo da análise de auditoria pode resultar no uso incorreto da metodologia, bem como na interpretação incorreta de seus resultados (Li, Dai, Gershberg, & Vasarhelyi, 2018; Kuenkaikaew, 2013).

Expert systems (sistemas especialistas) são programas de *software* que armazenam conhecimento extraído de especialistas humanos e foram aplicados a uma variedade de tarefas de auditoria com um crescimento significativo nessa área a partir da década de 1980 (Brown et al., 2007). Os sistemas de inteligência artificial, diferentemente dos sistemas especialistas, tentam desenvolver postulados básicos transformando-os em comportamento inteligente.

Os primeiros sistemas especialistas se concentraram na emulação de profissionais, tentando replicar o comportamento e as decisões dos especialistas humanos. No campo da AI, o uso dos sistemas especialistas está associado ao rastreamento e à verificação de transações suscetíveis à fraude, à revisão analítica e identificação de riscos de auditoria, ao julgamento e controle de continuidade (*going concern*) em ambientes avançados de EDP (Yang & Vasarhelyi, 1998).

Koskivaara (2004) realizou a revisão de estudos no campo da auditoria (interna e externa), todos relacionados ao potencial das redes neurais para aprimorar os ARP. Rede neural é um tipo de sistema de inteligência artificial que conecta elementos de processamento relativamente simples para formar uma rede. Um sistema de redes neurais pode fornecer informações objetivas sobre uma companhia e permitir aos auditores internos direcionarem o foco dos testes substantivos nos lugares certos (Brown et al., 2007).

A auditoria tradicional mudou consideravelmente como resultado de mudanças na TI, incluindo sistemas ERP mais avançados, o uso da nuvem e a rápida expansão de dados disponíveis para gerentes e auditores.

Conforme demonstra o Quadro 7, o cenário de TI em constante evolução leva a uma variedade de desafios de auditoria que se agravam ao longo do tempo (Chan et al., 2018). A convergência dos armazéns de sistemas ERP e de outros avanços tecnológicos, que incluem novos tipos de dados e os algoritmos de mineração de dados, evoluiu naturalmente para o que chamamos de Big Data (Alles & Gray, 2016).

Quadro 7 – A Evolução da TI e os Desafios de Auditoria

Fase	Período	Exemplos de Aplicações	Desafios de Auditoria
1	1945-1955	Aplicações científicas e militares	Transcrição de dados. Processo repetitivo.
2	1955-1965	Fitas magnéticas. Aplicações naturais.	Dados visualmente não legíveis. Dados que podem ser alterados sem deixar vestígios.
3	1965-1975	Sistemas de compartilhamento de tempo. Armazenamento em disco expandido. Operações de apoio.	O acesso aos dados sem acesso físico.
4	1975-1985	Bases de dados integradas. Sistemas de apoio à decisão (decisão auxiliar). Aplicações em todas as áreas.	Leiautes de dados físicos e lógicos diferentes. Nova camada de complexidade. Decisões inseridas em <i>software</i> .
5	1986-1991	<i>Networks</i> . Sistemas de apoio à decisão (não especialista). Armazenamento óptico em massa.	Dados distribuídos entre sites. Grandes quantidades de dados. Processamento distribuído por entidade. Fonte de dados sem papel. Sistemas interconectados.
6	1991-2000	Sistemas de apoio à decisão (especialista).	Decisões estocásticas inseridas em sistemas de TI.
7	2000-2010	Sistemas distribuídos. Internet baseada em nuvem (<i>cloud</i>).	Dados armazenados em nuvem. <i>Softwares</i> de TI replicados virtualmente.
8	2010-2020	[Big Data] Preponderância de dados aplicáveis em uma grande variedade de negócio, Contabilidade e áreas de Auditoria.	Múltiplas fontes de dados de captura automática.
9	2020+	[Inteligência Artificial] Sistemas que incorporam módulos capazes de autoaperfeiçoamento.	Atividades de auditoria e divulgação são lentas e ocorrem demasiadamente atrasadas.

Fonte: adaptado de Chan et al. (2018)

2.7 Big Data Analytics (BDA)

Hu, Wen, Chua e Li (2014) descrevem a história do desenvolvimento de Big Data, separando-a cronologicamente em estágios de evolução das capacidades de armazenamento e de gerenciamento de conjuntos de dados proporcionada pelo desenvolvimento de novas tecnologias de bancos de dados (Quadro 8).

Quadro 8 – Eventos de desenvolvimento do Big Data

Capacidade	Período	Descrição do Período
Megabyte para Gigabyte	de 1970 e 1980	Foco em atender a necessidade de hospedar dados históricos de negócios e executar consultas relacionais para análises e relatórios de negócios. O conceito de “ <i>database machine</i> ”, que consistia na integração de <i>hardware</i> e <i>software</i> para a solução de problemas, foi desenvolvido com a expectativa de obter melhor desempenho e menor custo mas não conseguiu acompanhar o progresso dos computadores de uso geral.
Gigabyte para Terabyte	Final dos anos 1980	As capacidades de armazenamento e de processamento de um único grande sistema de computador deixaram de acompanhar a expansão do volume de dados facilitada pela popularização da tecnologia digital. O surgimento do conceito de paralelização de dados (<i>data parallelization</i>) consistiu na utilização de vários tipos de bancos de dados paralelos com compartilhamento de disco (<i>shared-disk databases</i>) e de memória (<i>shared-memory databases</i>), com destaque para a arquitetura “ <i>shared-nothing</i> ” que obteve sucesso. Os sistemas comerciais como o <i>Teradata</i> , que trabalhavam com modelo de dados relacional, foram pioneiros no paralelismo para o particionamento de dados no armazenamento.
Terabyte para Petabyte	Final dos anos 1990	Período marcado pelo rápido desenvolvimento da Web 1.0, que levou o mundo inteiro à era da Internet, juntamente com páginas <i>web</i> semiestruturadas ou não estruturadas contendo terabytes ou petabytes de dados. Os bancos de dados paralelos forneciam pouco suporte para dados não estruturados e sua capacidade estava limitada a terabytes. O Google desenvolveu soluções para o gerenciamento e a análise de dados em escala <i>web</i> , como o modelo de programação <i>Google File System</i> (GFS) e <i>MapReduce</i> .
	Em meados dos anos 2000	O conteúdo gerado pelo usuário, vários sensores e outras fontes de dados onipresentes produziram um fluxo avassalador de dados de estrutura mista, o que exigia uma mudança de paradigma na arquitetura de computação e mecanismos de processamento de dados em larga escala. Os bancos de dados NoSQL, que são livres de esquemas, rápidos, altamente escalonáveis e confiáveis, começaram a surgir para lidar com esses dados.
Petabyte para Exabyte	Corresponde à atual tendência de expansão	O relatório “Extraindo valor do caos” (Gantz, & Reinsel, 2011), sobre o conceito e o potencial do Big Data, publicado pela EMC em 2011, despertou o interesse na academia e na indústria, impulsionando o desenvolvimento de projetos de Big Data por empresas dominantes do mercado incluindo Oracle, Microsoft, Google, Amazon e Facebook.

Fonte: adaptado de Hu et al. (2014)

Embora o significado do termo “Big Data” esteja literalmente associado a “grande volume de dados”, Big Data representa um conceito abstrato e amplo, não havendo um consenso sobre a sua definição, pois assim como outras disciplinas emergentes, sofreu uma evolução rápida e caótica na literatura, o que dificultou o desenvolvimento de uma definição universal e formalmente aceita (De Mauro, Greco, & Grimaldi, 2016).

Devido a diferentes pontos de vistas e interesses de empresas científicas e tecnológicas, pesquisadores, analistas de dados e profissionais técnicos, diferentes definições de Big Data foram propostas. Diversos autores usam a noção de “V” para definir Big Data (Wamba et al., 2015). Contudo, o modelo de 3Vs, composto por Volume, Velocidade e Variedade, não foi criado originalmente para descrever o Big Data. Esse modelo foi associado ao Big Data em 2001 pela META (atualmente Gartner) e por outras empresas, incluindo a IBM e a Microsoft (Chen et al., 2014).

Posteriormente, o modelo passou a contar com 4Vs, com a inclusão do Valor, a fim de enfatizar a importância de extrair benefícios econômicos dos big data disponíveis (Gantz, & Reinsel, 2011). A Veracidade foi adicionada tempos depois, formando o modelo de 5Vs, para destacar a importância de dados de qualidade e o nível de confiança em várias fontes de dados (White, 2012; Wamba et al., 2015), lidando com anonimato, imprecisão ou inconsistência, vieses, dúvidas, confusões e evidências equivocadas com dados (Sivarajah, Kamal, Irani, & Weerakkody, 2016).

Por fim, a Variabilidade foi incluída no modelo considerando que, frequentemente, a velocidade do Big Data não é consistente e tem altos e baixos periódicos (Gandomi & Haider, 2015).

Quadro 9 – Modelo de 6Vs

Vs	Descrição
Volume	Volume refere-se à magnitude dos dados que consomem grande armazenamento ou implicam em grande número de dados de registros (Russom, 2011), que são gerados a partir de diferentes fontes e continua a se expandir.
Velocidade	Velocidade refere-se à alta taxa de entrada de dados não homogêneos, o que resulta na criação de novos dados ou na atualização dos dados existentes (Chen et al., 2014).
Variedade	Os dados são gerados a partir de uma grande variedade de fontes e formatos e contêm campos de dados multidimensionais (Russom, 2011), caracterizando-se pela heterogeneidade de dados estruturados, semiestruturados e não estruturados.
Valor	É o aspecto mais importante do Big Data que se refere ao processo de descobrir grandes valores ocultos em grandes conjuntos de dados de vários tipos e geração rápida (Hashem et al., 2014)
Veracidade	A IBM cunhou a Veracidade que representa a confiabilidade inerente a algumas fontes de dados. Assim, a necessidade de lidar com dados imprecisos e incertos é outra faceta do Big Data (Gandomi & Haider, 2015).
Variabilidade	O SAS introduziu a Variabilidade como dimensão adicional do Big Data. Variabilidade refere-se à variação nas taxas de fluxo de dados (Gandomi & Haider, 2015).

Fonte: Elaborado pelo autor

Big Data é uma combinação de diversas características, tais como: “1) grande volume com fontes de dados heterogêneas e diversas; 2) autônomo com controle distribuído e descentralizado; e 3) complexo e com associações de dados e conhecimento em evolução” (Wu et al., 2014). De Mauro, Greco e Grimaldi (2016) apresentaram a classificação de definições de Big Data em quatro grupos, cada grupo conforme o seu foco específico na descrição do fenômeno: Grupo I: os atributos de dados que correspondem às características de Big Data como, por exemplo, o modelo dos “Vs”; Grupo II: as necessidades tecnológicas que dão suporte ao processamento de grandes quantidades de dados; Grupo III: característica de Big Data que superam os limites de capacidade dos sistemas convencionais exigindo abordagens alternativas para processamento dos dados; e Grupo IV: Impacto Social, ou seja, os efeitos do avanço do Big Data na sociedade.

Big Data é alimentado a partir de muitas fontes diferentes, incluindo fontes de dentro da organização, como dados de sistemas ERP e dados transacionais, e dados de fontes do ambiente externo, como dados oferecidos por terceiros, dados gerados por usuários, dados abertos e dados de sensores (Wamba et al., 2015). Desse modo, os dados geralmente não foram produzidos e coletados para os mesmos fins para os quais são utilizados em Big Data (Günther, Rezazade,

Huysman, & Feldberg, 2017). A análise de Big Data pode ser categorizada em dois paradigmas alternativos, sob o aspecto de tempo de processamento (Hu et al., 2014):

- a) Processamento de *streaming*: paradigma em que os dados chegam em um fluxo para aplicativos on-line, geralmente em segundos ou mesmo em milissegundos. O fluxo de dados é contínuo e rápido, transportando um volume enorme. Por este motivo, apenas uma parte do fluxo é armazenada em memória de tamanho limitado.
- b) Processamento em lote (*batch*): paradigma em que os dados são primeiro armazenados e depois analisados. No *MapReduce*, que se tornou o *framework* dominante de processamento em lote, os dados são divididos em pequenos fragmentos e depois processados em paralelo e de maneira distribuída para gerar resultados intermediários, que são agregados para se obter o resultado final.

O *Apache Hadoop* é a implementação mais utilizada e conhecida do *framework* de computação *MapReduce* (White, 2015), constituindo uma estrutura de *software* de código aberto que integra armazenamento de dados, processamento de dados, gerenciamento de sistemas e outros módulos e que está se tornando a principal solução para lidar com os desafios relacionados a gerenciamento e análise de Big Data. Em vez de contar com um *hardware* proprietário centralizado, o *Hadoop* permite o processamento distribuído de grandes volumes de dados em grandes grupos de servidores comuns, apresentando muitas vantagens, incluindo escalabilidade, custo-benefício, flexibilidade e tolerância a falhas (Hu et al., 2014).

NoSQL (*Not Only SQL*) refere-se a um grupo eclético e cada vez mais familiar de sistemas de gerenciamento de dados não relacionais onde bancos de dados não são primordialmente construídos em tabelas e geralmente não usam SQL para manipulação de dados (Moniruzzaman & Hossain, 2013). Os bancos de dados NoSQL estão se tornando mais populares para o armazenamento permanente e gerenciamento de conjuntos de dados desordenados em larga escala de Big Data devido a certas características essenciais, incluindo a ausência de esquema, suporte à replicação fácil e suporte a uma enorme quantidade de dados (Hu et al., 2014; Chen et al., 2014). O quadro 10 apresenta os diferentes tipos de dados de Big Data.

Quadro 10 – Tipos de dados de Big Data

Tipos de Dados	Descrição
Estruturados	Constituem 5% de todos os dados existentes (Mayer-Schonberger & Cukier, 2013), referem-se aos dados tabulares, em formato predefinido de linhas e colunas, encontrados em planilhas ou bancos de dados relacionais (Gandomi & Haider, 2015), que são fáceis de inserir, consultar, armazenar e analisar. Exemplos de dados estruturados incluem números, palavras e datas.
Semiestruturados	São dados que não seguem o formato de arquivo fixo de um sistema de banco de dados convencional, constituindo um <i>continuum</i> entre dados totalmente estruturados e não estruturados. O <i>eXtensible Markup Language</i> (XML), uma linguagem de texto para troca de dados na <i>web</i> , é um exemplo típico de dados semiestruturados (Gandomi & Haider, 2015), assim como arquivos HTML (<i>HyperText Markup Language</i>) (Marjani, et al., 2017).
Não estruturados	São dados que não seguem um modelo ou formato específico e às vezes carecem da organização estrutural exigida pelas máquinas para análise, como mensagens de texto, informações de localização, vídeos e dados de mídia social, imagens e áudio. Considerando que o tamanho desse tipo de dados continua aumentando com o uso de dispositivos móveis, a necessidade de analisar e entender esses dados se tornou um desafio (Gandomi & Haider, 2015; Marjani et al., 2017). Exemplos: mensagens (texto, email, <i>tweets</i> , <i>blogs</i>) - conteúdo gerado pelo usuário, dados transacionais (registros da <i>web</i> , transações comerciais), dados científicos (dados provenientes de experimentos intensivos em dados - dados de genoma e assistência médica), dados da <i>web</i> (imagens postadas nas mídias sociais; leituras de dados de sensores) (Chen, Chiang, & Storey, 2012; Chen et al., 2013).

Fonte: Elaborado pelo autor

De acordo com Chen, Mao e Liu (2014), alguns dos métodos tradicionais de *data analytics* podem ser utilizados para análise de Big Data: a) análise de *cluster* (*cluster analysis*); b) análise fatorial (*factor analysis*); c) análise de correlação (*correlation analysis*); d) análise de regressão (*regression analysis*); e) teste A/B; f) análise estatística; e g) algoritmos de mineração de dados (*data mining*).

Embora a maioria dos métodos tradicionais de *data analytics* apresente bom desempenho para análises de amostra de dados com tamanho moderado, tais métodos não estão preparados para processar os dados massivos multidimensionais de Big Data. Por este motivo, é necessário desenvolver métodos estatísticos e computacionais capazes de abordar problemas como heterogeneidade, acúmulo de ruído, correlações espúrias e endogeneidade incidental (Fan

et al., 2014), exigindo uma “grande mente” para lidar com essa combinação de características do Big Data (Wu et al., 2014).

O *data analytics* tradicional é comumente aplicado na detecção e prevenção de fraudes nos setores governamental, bancário e de seguros. Entretanto, as organizações estão procurando aproveitar o potencial do BDA para melhorar seus sistemas e executar análises mais rápidas (Elgendy & Elragal, 2014). *Big Data Analytics* (BDA), ou análise de dados de Big Data, permite a mineração efetiva de uma quantidade massiva de dados em diferentes níveis, podendo ser em tempo real ou quase em tempo real, incluindo modelagem, visualização, predição e otimização.

O Big Data em seu estado bruto não tem valor para nenhuma organização até que esses dados sejam analisados e convertidos em informações úteis (Tang et al., 2017). Markus e Topi (2015) afirmam especificamente que “Big Data não é apenas sobre dados, mas também o que é ou poderia ser feito com dados e as metas e valores que motivam esse uso”.

Günther, Rezazade, Huysman e Feldberg (2017) apontaram para a necessidade de analisar o ganho real obtido pelas organizações a partir do Big Data, identificando como os potenciais podem ser traduzidos em valor social e valor econômico. Enquanto o valor social corresponde à melhoria do bem-estar social e a geração de benefícios sociais, o valor econômico pode ser medido pelo aumento de lucro, crescimento dos negócios e a vantagem competitiva de uma organização.

Wamba, Akter, Edwards, Chopin e Gnanzou (2015) destacaram cinco dimensões relacionadas à criação de valor a partir do Big Data, com base nos elementos do artigo da McKinsey Global Institute (Manyika et al., 2011), conforme apresentado no quadro 11.

Quadro 11 – As cinco dimensões da criação de valor a partir do Big Data

DIMENSÃO	PROPÓSITO DA DIMENSÃO
Criação de transparência	Reduzir o tempo de pesquisa e processamento; reduzir o <i>time to market</i> e melhorar a qualidade.
Experimentação para descobrir necessidades	Instrumentalizar processos e realizar experimentos controlados, coletando dados mais precisos e usando-os para analisar a variabilidade no desempenho (em tempo real ou quase real) para entender suas causas principais e, assim, permitir que os líderes gerenciem o desempenho em níveis mais altos.
Segmentação de populações para personalizar ações	Permitir que as organizações criem segmentações altamente específicas e adaptem produtos e serviços precisamente para atender a essas necessidades.
Substituição ou suporte à tomada de decisão humana por algoritmos automatizados	Facilitar a tomada de decisão aprimorada, minimização de riscos e descoberta de informações valiosas que, de outra forma, permaneceriam ocultas.
Inovação de modelos, produtos e serviços de negócios	Permitir que as empresas criem novos produtos e serviços, aprimorem os existentes e inventem modelos de negócios inteiramente novos.

Fonte: Adaptado de Wamba et al. (2015)

O potencial de criação de valor do Big Data é alavancado por outras tecnologias de forma a aperfeiçoar a tomada de decisão baseada em evidências, por meio de processos capazes de analisar e adquirir inteligência a fim de transformar dados em conhecimento significativo e relevante (*insights*) (Gandomi & Haider, 2015). Mikalef, Krogstie, Pappas e Pavlou (2019) argumentam que as empresas precisam adquirir e desenvolver uma combinação única de recursos tecnológicos, humanos, financeiros e intangíveis, que seria difícil de ser imitada por seus concorrentes. Desse modo, ao mesmo tempo em que é alavancado por outras tecnologias, o Big Data também contribuiu para impulsionar a disseminação dessas avançadas ferramentas e técnicas de análise de dados no mundo real, como a análise de sentimentos (*sentiment analysis*), que anteriormente não eram economicamente viáveis para aplicações em larga escala.

A cadeia de valor do BDA, que utiliza os dados como matéria-prima, é constituída por uma estrutura sistemática composta por quatro fases sequenciais: a geração e a aquisição de dados, que são processos de exploração, o armazenamento de dados e a análise de dados (Hu et al., 2014; Chen et al., 2014) resumidas no Quadro 12.

Quadro 12 – Cadeia de valor de BDA

Fase da Cadeia de Valor	Descrição
Fase 1 – Geração de Dados	A geração de dados diz respeito à forma como conjuntos de dados grandes, diversos e complexos são gerados a partir de várias fontes de dados longitudinais e/ou distribuídas.
Fase 2 – Aquisição de Dados	<p>É o processo de obtenção de informações dividido em três subprocessos: coleta de dados, transmissão de dados e pré-processamento de dados.</p> <ol style="list-style-type: none"> 1. A coleta de dados é utilizar técnicas especiais para adquirir dados brutos de um ambiente específico de geração de dados, utilizando métodos que incluem arquivos de <i>log</i>, que geralmente são usados em quase todos os dispositivos digitais contendo, por exemplo, o número de cliques, taxas de cliques, visitas e outros registros de propriedades dos usuários da <i>web</i>; e detecção de dados sensoriais de diferentes tipos como onda sonora, voz, vibração, automóvel, produto químico, corrente, clima, pressão, temperatura, que são transferidas para um ponto de coleta de dados por meio de redes com ou sem fio. 2. Transmissão de dados: após a conclusão da coleta de dados brutos, os dados serão transferidos para uma infraestrutura de armazenamento de dados para processamento e análise. 3. Pré-processamento de dados: compreende técnicas de integração, limpeza e eliminação de redundância de dados provenientes de uma grande variedade de fontes, de forma a evitar desperdícios com o armazenamento de dados sem significado e, deste modo, não apenas reduzindo despesas de armazenamento, mas também melhorando a qualidade dos dados para facilitar uma análise de dados eficaz.
Fase 3 – Armazenamento de Dados (<i>Data Storage</i>)	Diz respeito ao armazenamento e gerenciamento persistentes de conjuntos de dados em larga escala. Um sistema de armazenamento de dados pode ser dividido em duas partes: infraestrutura de <i>hardware</i> e gerenciamento de dados.
Fase 4 – Análise de Dados	A análise de dados utiliza métodos ou ferramentas analíticas para inspecionar, transformar e modelar dados para extrair valor. A pesquisa analítica emergente pode ser classificada em seis áreas técnicas críticas: análise estruturada de dados, análise de texto, análise multimídia, análise da <i>web</i> , análise de rede e análise móvel.

Fonte: Elaborado pelo autor

Visualização de dados (*data visualization*), cujo principal objetivo é representar o conhecimento de maneira mais intuitiva e eficaz (Chen & Zhang, 2014) é considerado um método de assistência para a análise de dados (Hu et al., 2014) estando inserido na Fase 4.

A empresa de comércio eletrônico eBay, com centenas de milhões de usuários ativos e bilhões de mercadorias vendidas a cada mês, recorreu à ferramenta de visualização de Big Data denominada Tableau para tornar esses dados compreensíveis por meio de imagens intuitivas.

Hu, Wen, Chua e Li, (2014) descrevem seis tipos de aplicações de BDA que podem ser utilizados: análise de dados estruturados, *text analytics*, *web analytics*, *multimedia analytics*, *network analytics* e *mobile analytics* (Quadro 13).

Quadro 13 – Seis tipos de aplicações de BDA

Aplicações de BDA	Descrição
1. Análise de Dados Estruturados	Análise de dados estruturados em grande volume, gerados por aplicativos de negócios e pesquisas científicas, realizada por meio de técnicas de <i>data mining</i> e análise estatística, incluindo <i>deep learning</i> , que consiste em um conjunto de métodos de <i>machine learning</i> (aprendizado de máquina) e <i>process mining</i> .
2. <i>Text Analytics</i> / <i>Text Mining</i>	É o processo de extrair informação útil e conhecimento de textos não estruturados, combinando diferentes disciplinas como <i>machine learning</i> , estatística, linguística computacional, e <i>data mining</i> , com base principalmente no processamento de linguagem natural (NLP – <i>Natural Language Processing</i>). Os tipos de textos mais comuns incluem mensagens de e-mail, documentos corporativos, páginas on-line e conteúdo de mídias sociais. Exemplos: <i>question answering systems</i> (sistemas de resposta a perguntas) aplicados em muitas áreas como educação, sites, saúde e defesa; <i>opinion mining</i> (mineração de opinião), oferecendo oportunidades para a compreensão das opiniões do público em geral e de consumidores em relação a eventos sociais, movimentos políticos, estratégias da empresa, campanhas de marketing e preferências de produtos.
3. <i>Web Analytics</i>	A análise <i>web</i> busca recuperar, extrair e avaliar informação para a geração de conhecimento a partir de documentos e serviços da <i>web</i> automaticamente, com base em diversas áreas de pesquisa como NLP e <i>text mining</i> , abrangendo três áreas de interesse: a) <i>Web content mining</i> , envolvendo tipos de dados como texto, imagem, áudio, vídeo, metadados e hiperlinks; b) <i>Web structure mining</i> é a descoberta do modelo subjacente às estruturas de links em um site ou entre sites da <i>web</i> ; e c) <i>Web usage mining</i> , refere-se à mineração de dados secundários gerados por sessões ou comportamentos da <i>web</i> , incluindo dados de <i>logs</i> de acesso ao servidor da <i>web</i> , <i>logs</i> de servidor proxy, logs de navegador, perfis de usuários, dados de registro, sessões ou transações de usuários, <i>cookies</i> , consultas de usuários, dados de favoritos, entre outros.
4. <i>Mutimedia Analytics</i> (Análise Multimídia)	É a extração de conhecimento de interesse e compreensão de semântica capturados através de dados multimídia, contidos em imagem, áudio e vídeo, que cresceram a um ritmo fenomenal e são quase onipresentes.

“continua”

“continuação”

5. <i>Network Analytics</i> (Análise de Redes)	Envolve a análise de dados de redes sociais on-line, que evoluiu de análises bibliométricas e de análises de redes de sociologia, e que podem ser obtidos com base em links ou no conteúdo produzido. As estruturas de links das redes de informação multimídia são divididas em quatro categorias: ontologias semânticas, mídia comunitária, álbuns de fotografias pessoais e localizações geográficas; e permitem melhorar resultados do sistema de recuperação (<i>retrieval system</i>), do sistema de recomendação (<i>recommendation system</i>), da marcação colaborativa (<i>collaborative tagging</i>), entre outros.
6. <i>Mobile Analytics</i>	É a análise de dados gerados por dispositivos móveis como telefones celulares, sensores e RFID. Atualmente, a análise móvel está longe de ser madura, sendo a análise descritiva e a análise preditiva as mais utilizadas.

Fonte: Adaptado de Hu et al. (2014)

“conclusão”

A partir dos conceitos fornecidos pela revisão da literatura, a seguinte definição de BDA foi elaborada para o presente estudo:

Quadro 14 – Definição de BDA elaborada para o estudo

“Big Data Analytics corresponde ao processo de aplicação sistemática de técnicas e ferramentas avançadas de análise de dados para explorar o potencial de Big Data, cuja capacidade de integração de dados heterogêneos, que crescem em volume de forma exponencial e em alta velocidade, permite a extração de insights para a tomada de decisão”.

Fonte: Elaborado pelo autor

Günther, Rezazade, Huysman e Feldberg (2017) afirmam os *insights* de BDA podem ser gerados por dois tipos de abordagens que se complementam e devem ser equilibrados.

Na abordagem indutiva, primeiramente, os dados são coletados sem um objetivo predefinido e, em seguida, procura-se gerar uma explicação teórica. A abordagem dedutiva é orientada a hipóteses, partindo de uma teoria geral que depois é testada quando os dados específicos são coletados. Essa abordagem é comum em ambientes de assistência médica e apresentam riscos de viés de confirmação.

Sivarajah, Kamal, Irani e Weerakkody (2016) descrevem os métodos analíticos de BDA segundo uma perspectiva holística que são usados para extrair *insights* a partir dos dados (Quadro 15).

Quadro 15 – Métodos analíticos de BDA

Métodos analíticos de BDA	Descrição
Análise Descritiva	Examina os dados e as informações para definir o estado atual de uma situação de negócios em que os desenvolvimentos, padrões e exceções se tornam evidentes, na forma de produção de relatórios padrão, relatórios <i>ad hoc</i> e alertas.
Análise Investigativa	Trata de investigar dados para certificar/rejeitar proposições de negócios, por exemplo, detalhamento analítico em dados, análise estatística, análise fatorial.
Análise Preditiva	Está relacionada à previsão e modelagem estatística para determinar as possibilidades futuras.
Análise Prescritiva	Concentra-se em prever probabilidades e tendências futuras. Otimização e testes randomizados para avaliar como as empresas aprimoram seus níveis de serviço enquanto diminuem as despesas.
Análise Preventiva	Capacidade de tomar ações preventivas em eventos que podem influenciar negativamente o desempenho organizacional, por exemplo, identificar os possíveis perigos e recomendar estratégias de mitigação com antecedência.

Fonte: adaptado de Sivarajah et al. (2016)

A pesquisa existente na academia e na indústria mostra que os varejistas podem alcançar um aumento de até 15 a 20% no ROI por meio da utilização de análises de Big Data (Wamba et al., 2015).

O Walmart, tradicional gigante do varejo, processa 267 milhões de transações por dia em suas 6.000 lojas no mundo todo, e lida com mais de 1 milhão de transações de clientes a cada hora, que são importadas para bancos de dados com mais de 2,5 *petabytes* de dados. Com a colaboração da Hewlett Packard, o Walmart estabeleceu um *data warehouse* com capacidade para armazenar 4 *petabytes*, aplicando sofisticadas técnicas de aprendizado de máquina para explorar o conhecimento oculto nesse enorme volume de dados, melhorando a eficiência de suas estratégias de preços e campanhas publicitárias, bem como o gerenciamento de seus estoques e sua cadeia de suprimentos (Manyika et al., 2011; Chen & Zhang, 2014).

Dentre as opções de ferramentas de BDA disponíveis no mercado, como *softwares* comerciais e *softwares* de código aberto (*open source*), destacam-se o [R], Microsoft Excel e Weka/Pentaho entre os mais utilizados para mineração e análise de dados (Chen et al., 2014):

1. [R], uma linguagem de programação de código aberto e ambiente de *software*, foi projetado para mineração/análise e visualização de dados.
2. Excel: O Excel, um componente essencial do pacote de *software* comercial Microsoft Office, fornece poderosos recursos de processamento de dados e análise estatística, como os *plug-ins* avançados Analysis ToolPak e o Solver Add-in.
3. Weka/Pentaho: Weka, abreviado de *Waikato Environment for Knowledge Analysis*, é um *software* de aprendizado de máquina e *data mining* gratuito e de código aberto, escrito em Java, capaz de realizar processamento de dados, seleção de recursos, classificação, regressão, *clustering*, regra de associação e visualização. Já o *Pentaho*, um *software* de *Business Intelligence* (BI), fornece ferramentas para suporte a relatórios, análises, gráficos, integração de dados e mineração de dados.

O supercomputador Watson da IBM, segundo a literatura, é citado como um exemplo de solução de inteligência algorítmica para análise de Big Data, que utiliza técnicas de QA (*Question Answering*) para perguntas feitas em linguagem natural, sendo implementada em áreas como saúde, finanças, marketing e educação (Günther et al., 2017). Os algoritmos são desenvolvidos com cada vez mais capacidade de visualizar o comportamento humano em tempo real, não mais usando dados apenas para fins descritivos, mas também para fins preditivos e prescritivos (Gandomi e Haider, 2015).

Segundo Murdoch e Detsky (2013), o Memorial Sloan-Kettering Cancer Center adotou o IBM Watson como solução tecnológica para diagnosticar e propor opções de tratamento para pacientes com câncer, oferecendo sugestões extraídas da análise de dados do paciente em tempo real, em vez de usar apenas árvores de decisão baseadas em regras pré-definidas.

BDA é percebida como uma fonte de produtos, serviços e oportunidades de negócios inovadores. Porém, se por um lado o BDA oferece potencial para a descoberta de padrões sutis e heterogeneidades de uma população, cuja realização não é possível com dados em pequena escala, por outro lado, o tamanho massivo, a complexidade e a alta dimensionalidade do Big Data introduzem desafios computacionais e estatísticos exclusivos na maneira de analisar informações, tais como:

- a) Mais dados (todos os dados disponíveis são usados em vez de uma amostra);
- b) Dados mais confusos (dados incompletos ou imprecisos podem ser usados em vez de limitar os completos); e
- c) Correlação (a correlação se torna mais importante, superando a causalidade como meio para tomar decisões) (De Mauro, Greco, & Grimaldi, 2016).

Os desafios em utilizar BDA incluem preocupações com o gargalo de escalabilidade, com privacidade, endogeneidade incidental, erros de medição e com a qualidade dos dados no momento da integração com outros dados e informações. Caso a qualidade dos dados não seja adequada, uma correlação falsa poderá resultar na análise incorreta de uma oportunidade de negócios (White, 2012).

2.8 BDA e Auditoria Interna

O BDA tem potencial para melhor projetar estimativas, continuidade (*going concern*), fraude, entre outras variáveis de interesse para auditores internos e externos, enquanto que o uso de ferramentas e técnicas pode ajudar a transformar e aperfeiçoar as técnicas de auditoria (Alles, 2015).

Com relação às atividades relacionadas ao uso de BDA, existem duas características distintas entre auditores internos e auditores externos:

- a) Em primeiro lugar, auditores internos podem potencialmente acessar Big Data de sua organização mais facilmente, de forma completa e a qualquer momento, em relação aos auditores externos.
- b) Em segundo lugar, o uso de BDA por auditores internos geralmente é mais abrangente, como por exemplo na seleção mais ampla de informações não financeiras como parte de uma auditoria operacional (Alles & Gray, 2016).

O estudo “2015 Data Analytics and Leadership Survey” realizado pelo IIA (IIARF, 2016) demonstrou que as funções de AI que integraram BDA em suas operações apontaram um número de benefícios em quatro amplas categorias: a) maior eficiência; b) decisões melhor informadas; c) monitoramento e mitigação de riscos; d) redução mensurável de custos. De acordo com o mesmo estudo, profissionais de AI reconheceram como benefícios de BDA:

- a) Simplificação do processo de auditoria;
- b) Redução no tempo de trabalho de campo;
- c) Identificação de transações fraudulentas;
- d) Maior consistência do escopo de auditoria; e
- e) Capacidade de executar uma quantidade maior de projetos de auditoria.

Estudos acadêmicos no campo da auditoria relacionam diversos aspectos da incorporação de soluções de BDA na AI como oportunidades, desafios, mudanças de paradigma e implantação (Quadro 16).

Quadro 16 – BDA: oportunidades, mudanças de paradigma e desafios para a Auditoria Interna

BDA – Oportunidades para a Auditoria Interna	
Earley (2015); Moffitt e Vasarhelyi (2013)	Audidores podem testar um número maior de transações do que é possível atualmente, aumentando a suficiência da evidência de auditoria. O foco em procurar erros em amostra seria substituído pela procura de anomalias em padrões de dados sobre a população completa (100% da amostra).
Earley (2015); Moffitt e Vasarhelyi (2013)	A qualidade da auditoria pode ser melhorada através do fornecimento de valiosos <i>insights</i> nos processos dos clientes, mantendo uma base de conhecimento sobre soluções de anomalias em transações que poderão ser transferidas de ano em ano, para uso dos auditores internos. Os dados obtidos em cada trabalho de auditoria, de campanhas de vendas a <i>working papers</i> , tudo poderia ser armazenado para posterior análise.
Earley (2015)	Facilitar a detecção de fraudes com a utilização de ferramentas que permitem aos auditores analisarem grande conjuntos de dados de forma eficiente.
Earley (2015)	Audidores podem fornecer serviços e solucionar os problemas de seus clientes que estão além das capacidades atuais, utilizando dados não financeiros (NFD – <i>Non-Financial Data</i>), dados externos e dados não estruturados para melhor informar o planejamento da auditoria (particularmente, na avaliação de riscos), e auditar de forma mais eficiente áreas que demandam julgamento, tais como avaliação (<i>valuation</i>) e continuidade (<i>going concern</i>).

“continua”

BDA – Mudanças de Paradigma na Auditoria Interna	
Alles e Gray (2016)	Necessidade de mudanças significativas nos padrões atuais de auditoria.
Alles e Gray (2016)	Maior confiança em NFD que são tipos de dados que auditores normalmente não têm clareza sobre como realizar a sua validação.
Alles e Gray (2016)	Desenvolvimento de habilidades técnicas e mudança do perfil da equipe de auditoria.
Alles e Gray (2016)	Perspicácia de negócios para selecionar os elementos de Big Data a serem analisados e como interpretar os resultados.
Alles e Gray (2016)	Acesso sem precedentes aos dados sensíveis e proprietários do cliente que não fazem parte dos dados tradicionais solicitados durante uma auditoria.
Moffitt e Vasarhelyi (2013)	Metodologias para a execução de medidas de avaliação com maior frequência e, eventualmente, em tempo real ou <i>real-time</i> .
Moffitt e Vasarhelyi (2013); Kuenkaikaw (2013)	Abordagens de auditoria preventiva e preditiva devem ser formuladas considerando questões como materialidade das estimativas.
BDA – Mudanças de Paradigma na Auditoria Interna	
Moffitt e Vasarhelyi (2013)	Auditores devem passar a confiar em modelos analíticos para validar elementos, relacionando mercados, dados operacionais, vendas, esforços de pós-vendas.
Moffitt e Vasarhelyi (2013)	Novas formas de evidência de auditoria, tais como alarmes e alertas, <i>text mining</i> , e a busca de exceções excepcionais podem ser utilizadas para complementar ou substituir certas formas de evidência de auditoria.
BDA – Desafios para a Auditoria Interna	
Earley (2015); Brown-Liburd et al. (2015)	Treinamento e especialização de auditores: a proliferação de grandes quantidades de dados, principalmente dados não financeiros, demandaria a especialização dos auditores em habilidades de reconhecimento de padrões e avaliação de anomalias.
Earley (2015)	Disponibilidade, relevância e integridade dos dados dos clientes de auditoria.
Brown-Liburd et al. (2015)	A dificuldade em diferenciar dados relevantes e não relevantes do Big Data, sendo que a característica ambígua dos dados não estruturados pode resultar em julgamentos de auditoria incorretos.
Brown-Liburd et al. (2015); Alles e Gray (2016)	Ao contrário de explicar causalidade, a análise de Big Data tem o foco em correlações por meio da busca de padrões que podem ajudar a prever futuras ocorrências (Mayer-Schonberger & Cukier, 2013).
Brown-Liburd et al. (2015)	Sobrecarga de informação: informação excessiva pode tornar o processo de tomada de decisão menos eficiente e eficaz, levando a decisões incorretas, e dificuldades em reconhecer a correlação entre os detalhes e a perspectiva global.

Fonte: Elaborado pelo autor

“conclusão”

De acordo com Alles e Gray (2016), o processo de adoção de BDA não é uma escolha de tudo ou nada. A AI pode iniciar o processo de adoção de BDA utilizando os dados que estão disponíveis em seus sistemas transacionais e desenvolvendo suas competências analíticas com dados similares às variáveis que lhes são familiares – tais como aplicações de pedidos de compras – avançando gradativamente para a análise de dados não estruturados e externos à organização com a utilização de técnicas cada vez mais avançadas de BDA (Alles & Gray, 2016; Schmarzo, 2013).

Moffitt e Vasarhelyi (2013) citam o exemplo do AQM (*Accounting Quality Model*), conhecido como “RoboCop”, uma ferramenta analítica lançada pela SEC para a detecção e prevenção de fraudes que identifica desvios dos padrões de relatórios relacionados, especialmente a maneira como *accruals* discricionários são gerenciados. Os pesquisadores sugerem que, à medida que a diversidade e a quantidade de dados aumentam, a SEC precisará implementar e manter plataformas de Big Data. Os bancos de dados utilizados pelo AQM que originalmente tem como fonte primária de dados o XBRL, podem tornar-se um repositório local de Big Data, passando a coletar dados de empresas e de indivíduos como funcionários e clientes, incluindo registros telefônicos, atividades na Internet, comportamentos de compra e atividades de mídia social.

O seguinte modelo conceitual foi elaborado para demonstrar os estágios de expansão da incorporação de soluções de BDA nas práticas de AI (Figura 9), com base nos modelos propostos por Alles e Gray (2016) e Richins, Stapleton, Stratopoulos e Wong (2017).

Figura 9 – Modelo conceitual de estágios de expansão de BDA nas práticas de AI

		Tipos de Ferramentas de TI	
		Tradicional	Estendida
Tipos de Dados	Tradicional	[Célula A] Análise CDA com Dados Estruturados	[Célula C] Análise EDA com Dados Estruturados
	Estendida	[Célula B] Análise CDA com Dados Semiestruturados e Dados Não Estruturados	[Célula D] Análise EDA com Dados Semiestruturados e Dados Não Estruturados

Fonte: Adaptado de Alles e Gray (2016) e Richins et al. (2017)

A partir das combinações entre as ferramentas de TI e os tipos de dados utilizados pelos auditores internos são constituídas as quatro células que representam os estágios de expansão da adoção de BDA conforme o tipo de análise de dados:

- a) [Célula A] Análise CDA com dados estruturados. Exemplo: os auditores internos estão utilizando ferramentas tradicionais de auditoria para análise de amostra de dados;
- b) [Célula B] Análise CDA com dados semiestruturados e dados não estruturados. Exemplo: indica sinais de análise dados semiestruturados, como os XML e XBRL, como parte das práticas de AI;
- c) [Célula C] Análise EDA com dados estruturados. Exemplo: os auditores internos estão analisando a população completa por meio de ferramentas de visualização de dados (Tableau), porém com o foco ainda em dados e procedimentos tradicionais de auditoria;
- d) [Célula D] Análise EDA com dados semiestruturados e dados não estruturados. Exemplo: incorporação plena de BDA e ferramentas avançadas de *analytics* nas práticas de AI.

Segundo Bihani e Patil (2014), análise de dados é “um processo de inspeção, limpeza, transformação e modelagem de dados com o objetivo de destacar informações úteis, sugerir conclusões e apoiar a tomada de decisão”. A maioria das técnicas de análise de dados atualmente utilizadas na AI concentra-se na abordagem conhecida como Análise de Dados Confirmatória (CDA – *Confirmatory Data Analysis*) que, embora possa avaliar de forma precisa se um objetivo predefinido de auditoria foi alcançado, não pode descobrir riscos que não estavam previstos nos objetivos de auditoria. Por outro lado, a Análise de Dados Exploratória (EDA – *Exploratory Data Analysis*), é uma abordagem de análise de dados com ênfase no reconhecimento de padrões e geração de hipóteses a partir de um conjunto de dados brutos. Ao invés de utilizar estatística básica e gráficos simples, as técnicas avançadas de EDA abrangem as técnicas de visualização de dados (*data visualization*) e de mineração de dados (*data mining*), tais como: análise de agregação (*clustering*) e de associação; técnicas de mineração de texto (*text mining*); análise de redes sociais (*social network*) e *process mining* (Liu, 2014).

Os tipos de ferramentas de TI são classificados em dois grupos (Figura 9): (a) Tradicional: CAATs, ACL, IDEA, ferramentas de sistemas ERP, ETL (*Extract, Transform and Load*), linguagens SQL, execução de *queries* e Auditoria Contínua; e (b) Estendida:

visualização de dados (Qlikview e Tableau), linguagens de programação e modelagem estatística (SAS, [R], Python, SPSS) e plataformas de inteligência artificial e aprendizado de máquina (IBM Watson, Microsoft Azure).

Os tipos de dados, de forma semelhante aos tipos de ferramentas de TI, podem ser classificados em dois grupos: (a) Tradicional: dados financeiros e dados não financeiros obtidos de bancos de dados da empresa; e (b) Estendida: dados de arquivos em formato XML e XBRL, dados em linguagem natural, dados estruturados externos à empresa (Exemplo: SERASA), dados não estruturados externos à empresa (páginas de *websites*, mensagens em redes sociais), dados em formato de imagem ou vídeo (reconhecimento facial, identificação de documentos), dados em formato de áudio para análise de sentimento (canal de denúncias).

3 MODELO TEÓRICO

A literatura apresenta estudos para compreender como e por que os indivíduos adotam novas tecnologias da informação. Dentro dessa ampla área de investigação, podem ser encontradas correntes de pesquisa com o foco na aceitação individual da tecnologia, utilizando como variável dependente a intenção ou o uso, enquanto outras correntes se concentraram no sucesso da implementação no nível organizacional (Venkatesh et al., 2003).

Foram realizadas pesquisas sobre a adoção da TI por auditores governamentais, auditores externos e auditores internos (Li, Dai, Gershberg, & Vasarhelyi, 2018), propondo modelos de aceitação individual e referenciais teóricos (*frameworks*), a fim de compreender os fatores que influenciam essa aceitação, bem como os aspectos da resistência aos sistemas de informação por parte dos usuários. O Quadro 17 relaciona as principais pesquisas realizadas sobre o tema.

Quadro 17 – Principais pesquisas sobre a adoção de TI pela Auditoria Interna

ANO	PAÍS	TÓPICO	PALAVRAS	POPULAÇÃO
2003	Finlândia	Artificial Neural Networks in auditing: state of the art. (Koskivaara, 2004)	Computer-Assisted Audit Tools	Não se aplica (revisão da literatura)
2003	EUA	Computer-Assisted Audit Tools and Techniques: Analysis and perspectives. (Braun & Davis, 2003)	Computer-Assisted Audit Tools and Techniques; Generalized Audit Software	Auditores estaduais nos EUA. Uma amostra de 350 auditores e 90 respostas completas.
2008	EUA	An examination of contextual factors and individual characteristics affecting technology implementation decisions in auditing (Curtis & Payne, 2008)	Computer-Assisted Audit Techniques (CAATs)	139 auditores-gerentes de uma grande empresa de contabilidade.

“continua”

“continuação”

2009	EUA	Information technology acceptance in the internal audit profession: Impact of technology features and complexity (Kim, Mannino, & Nieschwietz, 2009)	Generalized Audit Software (GAS)	185 auditores internos do IIA (população de 1600)
2012	Reino Unido	Adoption of Generalised Audit Software (GAS) by external auditors in the UK (Ahmi, 2012)	Computerised Assisted Audit Tools and Techniques; Generalised Audit Software (GAS)	Empresas de auditoria. 3.587 participantes da amostra. 404 respostas completas
2012	Canadá e EUA	The antecedents of the use of continuous auditing in the internal auditing context (Gonzalez, Sharma & Galletta, 2012)	Continuous auditing; Continuous assurance; Internal auditing; UTAUT; Technology use	124 auditores internos da América do Norte, 60 do Oriente Médio e 26 de outras regiões (Europa, Ásia, Australásia e América do Sul).
2014	EUA	Factors influencing auditors' use of Computer-Assisted Audit Techniques (Bierstaker, Janvrin & Lowe, 2014)	Computer-Assisted Audit Tools and Techniques (CAATTs)	181 auditores (externos). Big 4, empresas nacionais, regionais e locais.
2014	EUA	Modeling voluntary CAAT utilization decisions in auditing (Curtis & Payne, 2014)	Computer-Assisted Audit Techniques (CAATs)	75 auditores administrativos de uma das 4 maiores empresas de contabilidade
2014	Reino Unido e Malásia	Examining the adoption of Computer-Assisted Audit Tools and Techniques: Cases of generalized audit software use by internal auditors (Mahzan & Lymer, 2014)	Computer-Assisted Audit Tools and Techniques; Generalized Audit Software	8 auditores internos do Reino Unido e 2 da Malásia
2015	Portugal	Computer-Assisted Audit Tools and Techniques use: Determinants for individual acceptance (Pedrosa, 2015)	CAATTs; UTAUT; TAM	110 Revisores Oficiais de Contas

“continua”

“continuação”

2018	Brasil (FEAUSP)	Antecedentes da aceitação e adoção da Auditoria Contínua no setor público brasileiro: O caso do Tribunal de Contas do Estado de São Paulo (Miranda, 2018)	Auditoria Governamental	362 agentes de fiscalização (servidores do TCESP), 84 respostas completas
2019	Brasil (PUC-SP)	Antecedentes da aceitação e adoção da Auditoria Contínua pelos Auditores Internos (Nascimento, 2019)	Auditoria Contínua; Auditoria Interna; UTAUT	103 auditores internos do The IIA Brasil

Fonte: Adaptado de Pedrosa (2015, p.34)

“conclusão”

O TAM (*Technology Acceptance Model*), proposto por Davis et al. (1989), foi o modelo sobre a aceitação de TI mais utilizado por quase duas décadas, superando outros modelos como a Teoria da Ação Racional (TRA) e a Teoria do Comportamento Planejado (TPB), resistindo ao teste do tempo e chegando ao status de um tipo de paradigma (Bagozzi, 2007). Outro modelo bem conhecido é o Modelo de Sucesso dos Sistemas de Informação (DeLone & McLean, 2003), no qual a Intenção de Uso é precedida por três variáveis de aspecto técnico: qualidade da informação, qualidade do sistema e qualidade do serviço. Entretanto, Mardiana, Tjakraatmadja e Aprianingsih (2015) indicaram que a Intenção de Uso não foi explicada completamente por esses três fatores e que este modelo carece de fundamento teórico para prever a Intenção de Uso.

Em 2003, um novo modelo foi proposto por Viswanath Venkatesh, Michael G. Morris, Gordon B. Davis e Fred D. Davis denominado Teoria Unificada da Aceitação e do Uso de Tecnologias (UTAUT), por meio de um estudo de revisão, comparação e síntese de oito modelos teóricos previamente aceitos (Quadro 18). O objetivo do novo modelo é avaliar a probabilidade de sucesso de introduções de novas tecnologias, compreender os fatores que motivam a aceitação/rejeição da TI e projetar intervenções proativamente (Venkatesh et al., 2003).

Quadro 18 – Teorias base para o modelo UTAUT

	TEORIA		AUTORES	ANO
1	Theory of Reasoned Action (TRA)	Teoria da Ação Racional	M. Fishbein e I. Ajzen	1975
2	Technology Acceptance Model (TAM)	Modelo de Aceitação da Tecnologia	F. D. Davis	1989
3	Motivational Model (MM) and IT use	Modelo Motivacional	F. D. Davis, R. P. Bagozzi e P. R. Warshaw	1992
4	Theory of Planned Behaviour (TPB)	Teoria do Comportamento Planejado	I. Ajzen	1991
5	Model Combining TAM and TPB	Modelo de combinação de TAM e TPB	S. Taylor e P. A. Todd	1995
6	Model of PC Utilization (MPCU)	Modelo de Utilização do PC	R. L. Thompson, C. A. Higgins e J. M. and Howell	1991
7	Innovation Diffusion Theory (IDT)	Teoria da Difusão da Inovação	E. Rogers	1995
8	Social Cognitive Theory (SCT)	Teoria Social Cognitiva	A. Bandura	1986

Fonte: Elaborado pelo autor

Venkatesh et al. (2003) conduziram a comparação empírica dos oito modelos por meio de uma pesquisa com funcionários de quatro organizações de setores diferentes (entretenimento, telecomunicações, bancário e público) e os resultados demonstraram que a taxa de explicação dos modelos variou de 17% a 53%.

Dos sete construtos que pareciam ser determinantes diretos da intenção ou uso em um ou mais dos modelos individuais, os autores identificaram que quatro construtos exerciam papel significativo: Expectativa de Desempenho, Expectativa de Esforço, Influência Social e Condições Facilitadoras.

A UTAUT foi elaborada com base nesses construtos incluindo outros quatro construtos de controle: experiência, gênero, idade e voluntariedade de uso. Por fim, os autores aplicaram o modelo UTAUT nas mesmas quatro empresas em que foram aplicados os oito modelos na etapa inicial, além de mais duas organizações do setor financeiro e do varejo.

Os resultados demonstraram que a UTAUT foi capaz de explicar 69% da variação da Intenção de Uso, superando todos os demais modelos revisados. Os autores apontaram as limitações desses modelos e as soluções correspondentes propostas pela UTAUT.

O trabalho de revisão e comparação realizado por Venkatesh et al (2003) identificou cinco limitações dos oito modelos revisados:

1. Tecnologia em estudo: o tipo de tecnologias estudadas nos modelos era relativamente simples. A UTAUT foi desenvolvida com o foco em tecnologias organizacionais complexas e sofisticadas;
2. Participantes: em muitos contextos dos modelos anteriores, os participantes são estudantes. Venkatesh et al (2003) tentaram superar essas limitações concentrando-se nos participantes em ambientes não acadêmicos;
3. Momento: a maioria dos testes dos oito modelos foi realizada após a decisão de aceitação ou rejeição dos participantes, e não durante o processo de tomada de decisão de adoção ativa. A UTAUT adotou uma abordagem diferente estudando o processo de adoção através de várias etapas da experiência com uma nova tecnologia, desde o momento da introdução inicial até as etapas de maior experiência;
4. Natureza da medição: os estudos anteriores empregavam comparações limitadas, transversais ou comparações entre indivíduos. O estudo de Venkatesh et al. (2003) acompanhou os participantes através de vários estágios da experiência com novas tecnologias e comparou os modelos usando os mesmos participantes; e
5. Contextos voluntários vs. contextos obrigatórios: alguns dos estudos anteriores foram conduzidos no contexto de uso voluntário. A pesquisa de Venkatesh et al. (2003) examina configurações voluntárias e obrigatórias.

A UTAUT é considerada uma teoria bem estabelecida e amplamente utilizada em pesquisas sobre adoção individual de tecnologias. O estudo de Venkatesh et al. (2003) conta com mais de 8.000 citações, incluindo pesquisas em que o modelo foi adaptado ao contexto da auditoria (Mahzan & Lymer, 2008 ; Ahmi, 2012; Gonzalez et al., 2012; Bierstaker et al., 2014; Curtis & Payne, 2014; Mahzan & Lymer, 2014; Pedrosa, 2015; Nascimento, 2019).

Sampieri, Collado e Lucio (2013) definem construto como uma “variável mensurada que acontece dentro de uma hipótese, teoria ou esquema teórico”. Venkatesh et. al. (2003) teorizaram que quatro construtos desempenham um papel significativo como determinantes diretos do Comportamento de Uso (CO) e Intenção de Uso (IU) do usuário (variáveis dependentes): Expectativa de Desempenho (ED), Expectativa de Esforço (EE), Influência Social (IS) e Condições Facilitadoras (CF), enquanto os construtos de controle Experiência,

Gênero, Idade e Voluntariedade de Uso não são determinantes diretos e atuam como variáveis moderadoras da relação entre os construtos (ED, EE, IF, CF) e a Intenção de Uso (IU) (Figura 10).

A Intenção de Uso de uma nova tecnologia está relacionada à perspectiva do indivíduo em relação aos eventos futuros (ED, EE, IF, CF), considerando que a sua motivação é influenciada conforme a sua expectativa dos resultados desses eventos. O Comportamento de Uso (CO) do usuário é impulsionado pela Intenção de Uso (IU) e impactado somente pelo fator das Condições Facilitadoras (CF) no modelo UTAUT (Figura 10).

Figura 10 – Modelo UTAUT de Venkatesh et al. (2003)

Fonte: Adaptado de Venkatesh et al. (2003, p.23)

3.1 Expectativa de Desempenho (ED)

A Expectativa de Desempenho (ED) é o mais forte preditor de intenção de uso de novas tecnologias e corresponde ao “grau em que um indivíduo acredita que o uso da ferramenta o ajudará a alcançar melhor os resultados desejados” (Venkatesh et al., 2003, p. 23). Os padrões e diretrizes de auditoria, como os emitidos pelo IIA, sugerem claramente que o uso de TI pode ajudar a aumentar a eficiência e a eficácia do trabalho do auditor interno, enquanto que estudos apontam que auditores internos realizam o seu trabalho com o uso de ferramentas tecnológicas,

executando atividades como testes de controles, compreensão dos controles de TI de seus clientes e avaliação de riscos durante o planejamento de auditoria (Mahzan & Lymer, 2008).

Estudos acadêmicos no campo da auditoria apresentam as oportunidades de BDA que podem melhorar o desempenho do trabalho do auditor interno (Quadro 16). Pesquisadores defendem que o BDA tem o potencial de levar a melhores previsões de estimativas, continuidade operacional e fraude no trabalho de auditoria e que os auditores internos irão adotar o BDA como uma maneira de melhorar a relação custo-benefício e aumentar a eficácia do seu trabalho (Alles, 2015; Brown-Liburd et al., 2015). Assim, conforme o pressuposto de que o uso de BDA será facilitado pela percepção de utilidade do sistema e pelos ganhos de produtividade no trabalho dos auditores internos, a seguinte hipótese é proposta:

H₁: A Expectativa de Desempenho afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

3.2 Expectativa de Esforço (EE)

A Expectativa de Esforço (EE) refere-se ao “grau de facilidade associado ao uso da ferramenta” (Venkatesh et al., 2003, p.26), ou seja, os auditores internos não precisam apenas superar a curva de aprendizado para se tornar hábeis no uso da tecnologia, mas também para considerá-los fáceis e eficientes de usar. (Gonzalez et al., 2012).

Banker, Chang e Kao (2002) realizaram uma pesquisa com gerentes de auditoria e funcionários de diferentes categorias em cinco escritórios de uma empresa contábil internacional de consultoria e auditoria, que fez grandes investimentos em TI, principalmente em *software* de auditoria e aplicativos de *groupware* para compartilhamento de conhecimento. As entrevistas de campo indicaram benefícios tanto para um auditor júnior, que obteve economia de esforço e redução de erros com o uso de documentos de trabalho eletrônico, como também para a redução do esforço da coordenação, com a utilização de compartilhamento de arquivos por auditores seniores. Um dos entrevistados, por exemplo, observou que o armazenamento do banco de dados permitiu rápida evidenciação para o cliente e modificação de planos e relatórios anteriores de auditoria e, conseqüentemente, as horas de trabalho foram reduzidas significativamente.

De acordo com o conceito da Facilidade de Uso Percebida, o sistema que for mais fácil de usar, dentre várias opções, terá mais chance de ser aceito pelos usuários. Assim, a segunda hipótese proposta neste estudo é:

H₂: A Expectativa de Esforço afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

3.3 Influência Social (IS)

A Influência Social (IS) pode ser definida como “o grau em que um indivíduo percebe que outros indivíduos importantes acreditam que ele ou ela deve usar a nova ferramenta” (Venkatesh et al., 2003, p. 27), existindo uma influência da imagem e da crença normativa em relação à intenção de adotar o BDA como, por exemplo, pela influência do Chefe de Auditoria Interna da organização, de outros auditores da empresa ou de outros contatos profissionais (Mahzan & Lymer, 2008). A noção de influência social é bem fundamentada na literatura da Psicologia, onde resultados de estudos de prestação de contas mostraram que as decisões individuais são frequentemente influenciadas pelas visões conhecidas dos superiores (Curtis & Payne, 2008).

Loraas e Wolfe (2006) descobriram que os auditores da equipe tinham maior probabilidade de usar voluntariamente o *software* geralmente disponível (como o Excel), em vez de abordagens manuais para uma tarefa de auditoria, quando seu supervisor de auditoria apoiava a decisão. Alguns pesquisadores argumentam que os auditores internos irão adotar BDA de forma tão plena quanto seus clientes, para manter-se atualizados tecnologicamente, como também para aumentar a credibilidade dos produtos de seu trabalho (Alles, 2015). Espera-se que quanto maior o grau em que os auditores internos percebem que pessoas de influência apoiam o uso de BDA, maior é a probabilidade de que eles adotem esta tecnologia, expressa na terceira hipótese:

H₃: A Influência Social afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

3.4 Condições Facilitadoras (CF)

As Condições Facilitadoras (CF) são definidas como “o grau em que um indivíduo acredita que existe uma infraestrutura organizacional e técnica para apoiar o uso do sistema” (Venkatesh et al., 2003, p. 29), referindo-se às percepções individuais sobre a disponibilidade de recursos tecnológicos e/ou organizacionais (conhecimento, recursos e oportunidades) que podem remover barreiras ao uso de um sistema, incorporando conceitos de três construtos: controle comportamental percebido, condições facilitadoras e compatibilidade. Isso se refere ao suporte técnico, monetário e de treinamento e aos recursos disponíveis para os auditores internos para facilitar o uso do sistema de auditoria contínua.

Segundo Mahzan e Lymer (2008), as CF que podem impactar nas motivações dos auditores internos em relação às CAATTs são a adequação das informações sobre o que os CAATTs podem fazer, suporte de vendedores ou fornecedores de *software* e suporte da alta gerência em suas organizações. Os resultados do estudo de Janvrin, Bierstaker e Lowe (2009) sugerem que em ambientes complexos de TI, quando os auditores confiam nos controles, eles têm maior probabilidade de usar CAATs para várias tarefas, demonstrando que a disponibilidade de uma infraestrutura organizacional e de suporte de TI que apoiem o uso de ferramentas tecnológicas pelo auditor interno exercem influência sobre a decisão do mesmo em adotá-las.

Em um contexto de auditoria, essa infraestrutura pode envolver empresas que fornecem recursos de tecnologia apropriados e suporte de computador a seus funcionários, como instruções especializadas, central de suporte, linha direta e/ou diretrizes de uso (Bierstaker et al. 2014). Desse modo, prevendo que as CF influenciarão positivamente a intenção do uso de BDA, formula-se a quarta hipótese:

H4: As Condições Facilitadoras positivas aumentam a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

Venkatesh, Brown, Maruping e Bala (2006) discutiram as limitações do construto Condições Facilitadoras (CF) na UTAUT, que se restringem à captura do efeito de fatores externos (recursos) e, deste modo, a presença favorável ou mesmo a ausência das CF não influenciam por si só a Intenção de Uso (IU) do sistema. Por outro lado, pesquisas em SI e Psicologia Social conceitualizaram e operacionalizaram, além das facetas externas, as facetas

internas de condições facilitadoras (CF), que operam através do construto Expectativa de Esforço (EE) e este, por sua vez, influencia diretamente a Intenção de Uso (IU).

Venkatesh e Bala (2008) propõem uma configuração alternativa para CF em seu modelo TAM3, sugerindo que o CF está indiretamente associado à intenção pelo caminho da facilidade de uso percebida (EE) até a utilidade percebida (PE). Nos testes anteriores do UTAUT, o EE influencia diretamente a intenção de usar a tecnologia e o CF influencia o uso real da tecnologia. Curtis e Payne (2014) entendem que esses relacionamentos são mais complexos em um contexto de auditoria e que suportam o relacionamento de EE entre CF e outros fatores em um modelo UTAUT adaptado à adoção voluntária de CAATTs.

Alles (2015) fez uma analogia entre os sistemas de ERP e BDA com relação aos seus impactos nas práticas de auditoria, utilizando como referência a bem-sucedida adoção de sistemas ERP na AI. De acordo com o pesquisador, o ERP tornou-se onipresente em todos os aspectos da empresa e passou a determinar como os negócios eram executados e os registros mantidos e, assim, os auditores começaram a realizar o seu trabalho por meio desses sistemas (Alles, 2015). Assim, as CF podem proporcionar maior agilidade na capacitação do auditor interno, reduzindo o tempo de sua curva de aprendizado e influenciando o grau de facilidade (EE) com que o profissional irá adotar ferramentas de BDA. Nesse sentido, a seguinte hipótese foi adicionada para este estudo:

H5: As Condições Facilitadoras afetam positivamente a Expectativa de Esforço dos auditores internos para a adoção de soluções tecnológicas de BDA.

3.5 Gênero, Idade, Experiência e Voluntariedade

Conforme ilustra a Figura 10, o modelo original da UTAUT não prevê que Gênero, Idade, Experiência e Voluntariedade exercem efeito moderador em todas as relações entre os quatro construtos (ED, EE, IS, CF) e a variável dependente Intenção de Uso (IU). Venkatesh, Morris, Davis e Davis (2003) reconhecem que a relação com a Expectativa de Desempenho é moderada por Gênero e Idade, sendo o efeito mais significativo para homens mais jovens, enquanto que a relação com a Expectativa de Esforço é moderada por Gênero, Idade e Experiência e o efeito é mais forte para mulheres, principalmente as mais jovens, nos estágios iniciais da experiência. A moderação da relação com a Influência Social ocorre por Gênero, Idade, Experiência e Voluntariedade considerando que o efeito seja mais forte para as mulheres,

principalmente as mais velhas e em contextos obrigatórios nos estágios iniciais da experiência. No caso de Condições Facilitadoras, que se relaciona com a variável dependente Comportamento de Uso, a moderação ocorre por Idade e Experiência, sendo o efeito mais forte para os trabalhadores mais velhos, principalmente com o aumento da experiência.

Entretanto, Dwivedi, Rana, Chen e Williams (2011) identificaram estudos que utilizaram o modelo UTAUT ignorando o efeito de variáveis moderadoras que poderiam estar distorcendo o desempenho real da teoria, considerando que o moderador (uma variável ou construto independente) altera a força ou até a direção de um relacionamento entre dois construtos no modelo, afetando diretamente a relação entre eles (Hair, Ringle & Sarstedt, 2014). Diante do exposto, as seguintes hipóteses são propostas:

H₆: O Gênero impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

H₇: A Idade impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

H₈: A Experiência impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

O construto de controle “Voluntariedade de uso” do modelo original não foi considerado como um construto relevante para o modelo do presente estudo, assumindo-se que o comportamento dos auditores internos é voluntário (Curtis & Payne, 2014; Bierstaker et al., 2014; Nascimento, 2019).

A Figura 11 ilustra o modelo teórico desta pesquisa, adaptado do modelo original da UTAUT (Venkatesh et al., 2003), demonstrando também os construtos originais dos modelos anteriores e as hipóteses H₁, H₂, H₃, H₄ e H₅ a serem testadas.

Estudos exploratórios que não têm como objetivo o exame do comportamento real de uso (CO) assumem que as CF influenciam diretamente a IU dos usuários (Gonzalez et al., 2012; Nascimento, 2019), como é o caso da presente pesquisa.

Figura 11 – Modelo UTAUT adaptado para o estudo

Fonte: Adaptado de Venkatesh et al. (2003)

4 METODOLOGIA DA PESQUISA

Neste capítulo são descritos os procedimentos metodológicos seguidos na condução da pesquisa, incluindo informações sobre a tipologia da pesquisa, a caracterização da população e da amostra do estudo, bem como a forma de coleta e análise de dados (Gil, 2000).

4.1 Tipologia da Pesquisa

O presente estudo é classificado como quantitativo quanto ao enfoque, utilizando coleta de dados para testar hipóteses, baseando-se na medição numérica e na análise estatística para estabelecer padrões e comprovar teorias.

Quanto ao alcance, o estudo é exploratório, cujo objetivo é examinar um tema ou um problema pouco estudado, sobre o qual existem muitas dúvidas ou que não foi abordado antes, antecedendo as pesquisas com alcances descritivos, correlacionais ou explicativos.

Quanto ao desenho, a pesquisa é classificada como não experimental, em que não há manipulação deliberada de variáveis e nos quais somente são observados os fenômenos em seu ambiente natural para depois analisá-lo; e transversal, em que os dados são coletados em um único momento, ao contrário da pesquisa longitudinal, que coleta dados ao longo do tempo, para realizar inferências a respeito da evolução, causas e efeitos (Sampieri et al., 2013).

No que diz respeito às estratégias de pesquisa, que correspondem às formas de coletar e analisar dados empíricos (Martins & Theóphilo, 2009), foram utilizadas na pesquisa o levantamento (*survey*) e a pesquisa bibliográfica.

O levantamento (*survey*) é utilizado, de uma forma geral, quando os dados podem ser coletados em amostra de uma população que se deseja conhecer, com possibilidade de variação do grau de erro, e visa responder questões acerca da distribuição de variáveis e relações entre as suas características, em situações naturais no ambiente onde ocorrem os fenômenos (Martins & Theóphilo, 2009).

Os fundamentos teóricos do estudo foram obtidos por meio da pesquisa bibliográfica, a partir de livros, artigos de periódicos nacionais e internacionais, teses e dissertações, relatórios de pesquisas de instituições acadêmicas e de empresas do mercado.

4.2 Elaboração do Questionário

O questionário é um importante e popular instrumento de coleta de dados que corresponde a um conjunto ordenado e consistente de perguntas a respeito de variáveis e situações que se deseja medir ou descrever (Martins & Theóphilo, 2009) e foi adotado como ferramenta da estratégia de levantamento da pesquisa.

A versão final do questionário pode ser consultada no Apêndice A. O instrumento foi elaborado com base na teoria e nos construtos e indicadores da UTAUT que foram adotados e testados por estudos anteriores (Miranda, 2018; Nascimento, 2019), contendo perguntas objetivas fechadas, tanto em escala Likert como em escala desenvolvida especificamente para o estudo.

As questões foram formuladas para serem compreensíveis, com claro entendimento, para não induzirem as respostas (Martins & Theóphilo, 2009), observando as recomendações de Sampieri et al. (2013) quanto aos problemas que surgem ao elaborar perguntas, no intuito de aumentar a taxa de respostas.

A aplicação do questionário buscou mapear o perfil dos profissionais, as ferramentas e tipos dados tradicionais utilizados nas práticas de AI, além das ferramentas e tipos de dados de BDA, bem como investigar os fatores que influenciam a intenção dos auditores internos em adotar soluções de BDA, por meio de questões agrupadas em três blocos.

O primeiro bloco apresentou o termo de consentimento livre e esclarecido, indicando o objetivo da pesquisa, a garantia de confidencialidade dos dados, o tempo estimado previsto para resposta do questionário, oferecendo ao respondente a opção de desistir ou prosseguir com a pesquisa.

Em seguida, constam as perguntas para se obter informações relacionadas à caracterização do respondente: gênero; idade; área de formação (graduação e pós-graduação); tempo de experiência como profissional de AI; certificações profissionais; tipo, localização geográfica, quantidade de funcionários e faturamento da empresa em que o auditor interno atua; como adquiriu competências em TI; e interesse em eventos sobre inovações tecnológicas.

O segundo bloco tem início com uma breve apresentação sobre o conceito de BDA, elaborada pelo pesquisador, no intuito de alinhar o entendimento que os respondentes têm sobre o tema com o conceito acadêmico e, em seguida, são apresentadas três subseções de perguntas relacionadas aos tipos de ferramentas tecnológicas, aos tipos de dados analisados, tradicionais

ou não tradicionais, e em quais atividades de AI esses tipos estão sendo atualmente utilizados pelos respondentes:

- a) Ferramentas de TI: análise de dados aplicadas à auditoria (ACL e IDEA); sistemas ERP; ETL; linguagens SQL; auditoria contínua; visualização de dados; linguagens de programação e modelagem estatística (SAS, [R], Python, SPSS); plataformas de inteligência artificial e aprendizado de máquina (IBM Watson).
- b) Tipos de dados: dados financeiros; dados não financeiros obtidos de bancos de dados da empresa (cadastro de clientes), dados de arquivos em formato XML, XBRL (*eXtensible Business Reporting Language*), dados em linguagem natural para *text mining* (mensagens de e-mail); dados estruturados externos à empresa (exemplo: SERASA); dados não estruturados externos à empresa (páginas de *websites*, mensagens em redes sociais); dados em formato de imagem ou vídeo (reconhecimento facial); dados em formato de áudio (canal de denúncias).
- c) Atividades de AI: planejamento de auditoria; avaliação do controle interno; avaliação de riscos de auditoria; testes de auditoria; circularização; evidências de auditoria; amostragem estatística; análise de segregação de funções; análise e recuperação de pagamentos duplicados.

As questões do terceiro bloco foram elaboradas com base nos itens de questionário do estudo de Venkatesh et al. (2003) para estimar os modelos estruturais e realizar testes preliminares e validações.

Hair, Ringle e Sarstedt (2014) destacam a importância da codificação na aplicação da análise multivariada, sendo que escalas ordinais como as Likert são as mais comuns em um contexto de MEE.

A escala Likert de 5 pontos foi adotada neste estudo, atentando para os requisitos de equidistância, com as categorias (1) discordo totalmente, (2) discordo, (3) não concordo nem discordo, (4) concordo e (5) concordo totalmente, que é percebida como simétrica e equidistante de forma que, por exemplo, a distância entre as categorias 1 e 2 é a mesma entre as categorias 3 e 4.

O quadro 19 apresenta cada um dos quatro construtos do modelo teórico com seus respectivos indicadores (itens do terceiro bloco do questionário), construtos originais e hipótese a ser testada.

Quadro 19 – Construtos e seus respectivos indicadores, construtos originais e hipóteses

EXPECTATIVA DE DESEMPENHO (ED)			
HIPÓTESE	CONSTRUTO ORIGINAL	DESCRIÇÃO DO CONSTRUTO	INDICADORES (Itens do Questionário)
H1: A Expectativa de Desempenho afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.	Utilidade Percebida / Perceived usefulness (PU)	O grau em que um indivíduo acredita que utilizar um determinado sistema pode aumentar o seu desempenho no desenvolvimento de sua atividade (Davis, 1989).	[1] O uso de ferramentas de BDA é útil para o meu trabalho.
			[6] O uso de ferramentas de BDA permite que eu conclua as tarefas mais rapidamente.
			[19] O uso de ferramentas de BDA aumenta a minha produtividade.
	Job-Fit	A medida que uma pessoa acredita que o uso de tecnologias pode melhorar o desempenho de seu trabalho (Thompson, Higgins & Howell; 1991).	[15] O uso de ferramentas de BDA melhora a qualidade do meu trabalho.
	Expectativa de Resultado / Outcome Expectations (OE)	Dois tipos de consequências do comportamento: (a) Expectativas pessoais relacionadas com auto-estima e senso de realização; (b) Expectativas de Desempenho relacionados aos resultados do trabalho. (Compeau & Higgins 1995).	[12] Tenho mais chance de obter reconhecimento profissional com o uso de ferramentas de BDA.
EXPECTATIVA DE ESFORÇO (EE)			
HIPÓTESE	CONSTRUTO ORIGINAL	DESCRIÇÃO DO CONSTRUTO	INDICADORES (Itens do Questionário)
H2: A Expectativa de Esforço afeta positivamente a intenção dos auditores internos para a adoção da tecnologia de soluções tecnológicas de BDA.	Facilidade de uso percebida / Perceived ease of use (EOU)	O grau em que uma pessoa entende que o uso de um determinado sistema estaria livre de esforço (Davis, 1989)	[5] A minha interação com ferramentas de BDA ocorre de forma clara e compreensível.
			[16] Seria fácil tornar-me habilidoso no uso de ferramentas de BDA.
			[8] Eu considero as ferramentas de BDA fáceis de usar.
	Facilidade de uso / Ease of use (EU)	O nível em que uma inovação é percebida como sendo fácil de usar (Moore, Benbasat 1991)	[11] Aprender a utilizar ferramentas de BDA é fácil para mim.

“continua”

“continuação”

INFLUÊNCIA SOCIAL (IS)			
HIPÓTESE	CONSTRUTO ORIGINAL	DESCRIÇÃO DO CONSTRUTO	INDICADORES (Itens do Questionário)
H3: A Influência Social afeta positivamente a intenção dos auditores internos para a adoção da tecnologia de soluções tecnológicas de BDA.	Norma Subjetiva / Subjective norm (SN)	A percepção do indivíduo que a maioria das pessoas que são importantes para ela acredita que ela deve ou não executar o comportamento em questão (Fishbein & Ajzen 1975)	[13] Pessoas que exercem influência sobre o meu comportamento acham que eu devo utilizar as ferramentas de BDA no meu trabalho.
			[3] Pessoas importantes para mim acham que eu devo utilizar as ferramentas de BDA no meu trabalho.
	Fatores Sociais / Social factors (SF)	Correspondem à internalização da cultura subjetiva do grupo de referência, e acordos interpessoais específicos que um indivíduo faz com outros indivíduos, em situações sociais específicas (Thompson et al. 1991, p. 126).	[7] A gerência da área de auditoria interna incentiva o uso de ferramentas de BDA.
			[17] Em geral, a empresa tem dado suporte para o uso de ferramentas de BDA.
CONDIÇÕES FACILITADORAS (CF)			
HIPÓTESE	CONSTRUTO ORIGINAL	DESCRIÇÃO DO CONSTRUTO	INDICADORES (Itens do Questionário)
H4: As Condições Facilitadoras positivas aumentam a intenção dos auditores internos para a adoção da tecnologia de soluções tecnológicas de BDA.	Controle Comportamentamental Percebido / Perceived behavioral control (PBC)	Reflete as percepções de restrições internas e externas sobre o comportamento, abrangendo auto-eficácia, condições facilitadoras de recursos e condições facilitadoras de tecnologia.	[4] Os recursos necessários para usar ferramentas de BDA no trabalho estão disponíveis para mim.
			[14] Eu tenho conhecimento adequado para usar ferramentas de BDA.
			[18] As ferramentas de BDA não são compatíveis com outras ferramentas que eu uso.
	Condições Facilitadoras	Fatores objetivos no ambiente em que observadores concordam que uma atividade é fácil de realizar, incluindo a disponibilização de suporte de computador.	[9] Um profissional ou equipe de suporte está disponível para me auxiliar quando tenho dificuldades em utilizar ferramentas de BDA.

Fonte: Elaborado pelo autor

“conclusão”

4.3 Implementação da Survey

O questionário foi desenvolvido na plataforma *web* do Google Forms, que oferece recursos para a criação e manutenção de formulários on-line, acompanhamento das respostas preenchidas e a extração dos dados em diferentes formatos de arquivo, que podem ser utilizados em ferramentas como MS Excel e SPSS. O *survey* on-line simplifica consideravelmente o processo de pesquisa, oferecendo uma opção fácil e econômica de usar (Smith, 2017).

No que diz respeito à preocupação com as taxas de respostas, o encaminhamento do link gerado pela plataforma Google Forms permite o acesso ao questionário por meio de outros canais além do e-mail, incluindo mensagens de WhatsApp e de redes sociais como Facebook e LinkedIn, por meio de computadores e dispositivos móveis, ampliando as oportunidades de participação da pesquisa. Entretanto, pode existir a limitação em acessar o link em ambientes organizacionais, considerando que algumas instituições podem restringir o acesso a determinadas fontes de e-mails e plataformas *web*.

A realização do pré-teste (ou teste piloto) do instrumento de pesquisa é essencial para verificar a sua capacidade de gerar as respostas necessárias do público-alvo e melhorar a confiabilidade e a validade de perguntas individuais, fazendo mais do que validar a redação das perguntas ao fornecer uma indicação firme da validade do escopo da pesquisa e das prioridades e preferências dos entrevistados (Smith, 2017; Van der Stede, Young, & Chen, 2005).

O pré-teste torna-se importante principalmente para o *survey* on-line, pois neste caso não há entrevistadores para relatar problemas nas perguntas e no instrumento de pesquisa para o pesquisador. Van der Stede et al. (2005) recomendam a submissão do questionário para a avaliação de três grupos de pessoas:

- a) Colegas com entendimento do design e do tópico do estudo para avaliar a validade do construto das perguntas e como elas falharão em alcançar os objetivos do estudo;
- b) Possíveis entrevistados para identificar e corrigir problemas com as perguntas e o questionário;
- c) Usuários dos dados para obter *feedback* de pessoas com conhecimento substantivo do tópico da pesquisa.

Diante do exposto, o pré-teste foi conduzido em duas etapas, no período de 3 a 17 de julho de 2019. A primeira etapa, com dois doutorandos e um mestrando do curso de pós-graduação em Contabilidade da FEA/USP e um doutorando do curso de pós-graduação em

Economia da FEA-RP/USP, e a segunda etapa com três profissionais do mercado, sendo dois auditores internos e um auditor externo com conhecimentos sobre a função de AI.

A partir das recomendações dos colaboradores do pré-teste foram realizados ajustes no texto do termo de consentimento de participação, na linguagem e nas escalas das questões, no detalhamento de enunciados e termos específicos de AI, e nos aspectos visuais e de navegação do questionário em dispositivos móveis e computadores.

Após a realização de todos os ajustes sugeridos e da revisão do questionário pelos colaboradores, iniciou-se o processo de coleta de dados com o encaminhamento do link da versão definitiva do questionário para a população-alvo da pesquisa, ou seja, os auditores internos.

4.4 População e Amostra da Pesquisa

A população, que corresponde a um conjunto de indivíduos que apresentam determinadas características em comum (Martins & Theóphilo, 2009), é constituída pelos auditores internos que atuam em empresas do setor privado brasileiro. A unidade de análise, a fim de delimitar a população, é composta predominantemente pelos auditores internos cadastrados com perfil no LinkedIn, uma rede social para utilização estritamente profissional.

O período de coleta de dados foi de 25 de julho a 19 de setembro de 2019, em que foi realizado um trabalho de construção de uma rede de relacionamentos de auditores internos, totalizando 1500 conexões, tendo como contato inicial os membros da comunidade “RAC² - Riscos, Auditoria, *Compliance* e Controles Internos”, para os quais foram enviadas mensagens individuais com o link do questionário utilizando o próprio sistema de mensagens do LinkedIn.

Após a conclusão do envio das mensagens individuais, foi publicada uma mensagem de *follow up* para toda a rede de conexões do pesquisador. A quantidade final de 321 questionários coletados incluiu 50 questionários de auditores internos associados do IIA Brasil, que acessaram o questionário pelo link divulgado no “121º Boletim do IIA Brasil”, enviado por e-mail aos associados em 23 de agosto de 2019.

A amostra pode ser definida como “um subgrupo da população de interesse sobre o qual os dados serão coletados, e que deve ser definido ou delimitado anteriormente com precisão” (Sampieri et al., 2013). No presente estudo, os auditores internos participaram da pesquisa de forma voluntária sendo a amostra considerada não probabilística, na qual “a escolha dos

elementos não depende da probabilidade, mas de causas relacionadas com as características da pesquisa ou de quem faz a amostra” (Sampieri et al., 2013).

Para determinar o tamanho mínimo da amostra em uma análise PLS-PM, Hair, Ringle e Sarstedt (2014) sugerem aos pesquisadores a consideração do poder estatístico com o auxílio de programas de *software* como o G*Power ao invés de seguir orientações gerais como a regra das 10 vezes. Segundo Hair et al. (2014), o “maior poder estatístico significa que o PLS-PM tem maior probabilidade de apresentar um relacionamento específico significativo quando é de fato significativo na população”.

Primeiro, foi avaliado o construto ou variável que recebe o maior número de setas ou tem o maior número de preditores, ou seja, a variável dependente Intenção de Uso (IU) com 4 preditores na parte mais complexa do modelo (Figura 15). A amostra mínima calculada pelo *software* G*Power para o estudo foi de 89 casos, considerando um nível de significância de 5%, o tamanho do efeito (f^2) de 15%, o poder estatístico de 95%, o que é superior ao valor mínimo de 80% recomendado por Hair et al. (2014). Alguns autores sugerem calcular o dobro ou o triplo da quantidade mínima obtida para que o modelo seja mais consistente (Ringle, Silva, & Bido, 2014), resultando em 267 casos.

A amostra final, com 305 respostas, considerada para a análise estatística do presente estudo, é superior à quantidade mínima calculada de 267 casos. Dos 321 questionários respondidos da amostra coletada no levantamento, foram excluídos 16 casos, correspondendo a 3 respondentes que não concordaram com o termo de aceite, 12 respondentes do setor público e 1 resposta considerada inconsistente devido à falta de variabilidade após verificação do desvio padrão.

4.5 Métodos de Análise de Dados

Os métodos de análise de dados adotados no presente estudo incluem as técnicas de estatística descritiva de análise e a técnica multivariada de modelagem de equações estruturais (MEE) com a utilização dos *softwares* Microsoft Excel, SPSS (Pacote Estatístico para Ciências Sociais) e SmartPLS.

A estatística descritiva diz respeito à organização, sumarização e descrição de um conjunto de dados através de gráficos, tabelas, e do cálculo de medidas a partir de uma coleção de dados numéricos (Martins & Theóphilo, 2009).

A análise multivariada envolve a aplicação de métodos estatísticos que analisam simultaneamente múltiplas variáveis, que representam medidas associadas a indivíduos, empresas, eventos, atividades, entre outros (Hair et al., 2014).

A modelagem de equações estruturais (MEE) ou *Structural Equation Modeling* (SEM), que surgiu nas ciências sociais nas últimas décadas, é “uma classe de técnicas multivariadas que combinam aspectos de análise fatorial e regressão, permitindo ao pesquisador examinar simultaneamente as relações entre variáveis medidas e variáveis latentes (VLs), ou relações entre variáveis latentes” (Hair et al., 2014).

A abordagem de MEE selecionada para este trabalho é a dos Mínimos Quadrados Parciais (*Partial Least Squares Path Modeling* – PLS-PM), conforme a Figura 12. PLS-PM é adequado para pesquisas exploratórias, quando o objetivo da pesquisa é o desenvolvimento da teoria e a explicação da variância (previsão dos construtos) e quando for difícil ou impossível atender aos requisitos mais rigorosos das técnicas multivariadas mais tradicionais, sendo assim descrita como “modelagem suave” (*soft modeling*).

O método de PLS-PM trabalha eficientemente com amostras pequenas e modelos complexos, com modelos de medição reflexivos e formativos, fornecendo estimativas muito robustas de modelo com dados que têm propriedades distributivas normais ou extremamente não normais e, deste modo, pode ser aplicado em uma ampla variedade de situações de pesquisa (Hair et al., 2014).

5 ANÁLISE DOS RESULTADOS

Com a conclusão da coleta de dados, inicia-se o processo de análise de dados, segundo o enfoque quantitativo, com o uso de estatísticas descritiva e inferencial, de forma impessoal e atendendo aos critérios objetividade, rigor, confiabilidade e validade. As análises quantitativas, que são interpretadas de acordo com as previsões iniciais (hipóteses) e os estudos anteriores (teoria), buscam explicar como os resultados se encaixam no conhecimento existente (Sampieri et al., 2013). Sampieri et al. (2013) descreveram as fases do processo de análise de dados quantitativos: (1) selecionar o programa estatístico no computador para a análise de dados; (2) executar o programa; (3) explorar os dados, analisá-los e visualizá-los por variáveis do estudo; (4) avaliar a confiabilidade e validade dos instrumentos escolhidos; (5) realizar análises estatísticas descritivas de cada variável do estudo; (6) realizar análises estatísticas inferenciais sobre as hipóteses formuladas; (7) efetuar análises adicionais; e (8) preparar os resultados para apresentá-los.

5.1 Análise Descritiva dos Dados

5.1.1 Caracterização do Respondente

Conforme demonstrado na Tabela 1, é possível identificar que os homens representam 70,8% dos respondentes, mais do que o dobro da quantidade de mulheres. A maior concentração encontra na faixa etária entre 29 e 39 anos, sendo que a média de idade é de 36,5 anos, a idade mínima de 24 e a idade máxima de 63 anos.

Tabela 1 – Características individuais dos respondentes

	Características Individuais	%	Quantidade
Gênero	FEMININO	29,2	89
	MASCULINO	70,8	216
Idade (em anos)	Abaixo de 22	0,00%	0
	Entre 23 e 28	16,72%	51
	Entre 29 e 39	53,77%	164
	Entre 40 e 45	14,10%	43
	Entre 46 e 55	10,82%	33
	Acima de 55	4,59%	14
	Total	100,00%	305

Fonte: Elaborado pelo autor

Com relação ao tempo de experiência profissional na área de AI, 33,12% dos respondentes encontram-se na faixa de 5 a 9 anos, seguidos por respondentes com experiência entre 10 e 19 anos (29,51%) e com menos de 5 anos (26,23%), sendo que 11,14% dos respondentes possuem mais de 19 anos de experiência. A certificação profissional com o maior número de ocorrências é a CIA (4,59%) e 78,36% dos respondentes não possuem certificação.

Tabela 2 – Experiência profissional dos respondentes

Experiência (em anos)	menos de 5	26,23%	80
	entre 5 e 9	33,12%	101
	entre 10 e 19	29,51%	90
	entre 20 e 29	8,52%	26
	entre 30 e 39	2,62%	8
Certificações	Certified Internal Auditor (CIA)	4,59%	14
	Risk Management Assurance™ (CRMA™)	1,97%	6
	Outros	15,08%	46
	Não possui	78,36%	239

Fonte: Elaborado pelo autor

Todos os respondentes possuem formação superior, com destaque para as áreas de Ciências Contábeis (40,66%) e Administração (37,05%). A maior parte dos respondentes possui pós-graduação em Ciências Contábeis (20,98%) e em Administração (20,98%), de forma semelhante à graduação, considerando também que 88 respondentes (28,85%) não possuem pós-graduação e 7 respondentes possuem pós-graduação *stricto sensu* (acadêmica).

É importante destacar que a revisão da literatura apontou que a AI, diferentemente da auditoria externa, tem característica multidisciplinar. A análise descritiva do presente estudo apontou maior concentração nos cursos de Ciências Contábeis e Administração em relação a outras áreas de formação como Sistemas de Informação e Engenharia.

Tabela 3 – Formação dos respondentes (graduação e pós-graduação)

Área de Formação (Graduação)	Ciências Contábeis	40,66%	124
	Administração	37,05%	113
	Sistemas de Informação	8,52%	26
	Engenharia	4,92%	15
	Economia	1,97%	6
	Ciências Atuariais	0,98%	3
	Comunicação Social	0,98%	3
	Direito	0,66%	2
	Matemática	0,66%	2
	Relações Internacionais	0,66%	2
	Outros	2,95%	9
Formação de Pós- graduação	Lato Sensu (Especialização)	36,72%	112
	Master Business Administration (MBA)	31,15%	95
	Stricto Sensu (Mestrado Profissional)	1,31%	4
	Stricto Sensu (Mestrado Acadêmico)	0,66%	2
	Stricto Sensu (Doutorado)	0,33%	1
	Outros	0,98%	3
	Não possui	28,85%	88
Área de Formação (Pós- graduação)	Administração	20,98%	64
	Ciências Contábeis	20,98%	64
	Sistemas De Informação/Tecnologia Da Informação	6,56%	20
	Controladoria	3,93%	12
	Finanças	2,30%	7
	Engenharia	1,64%	5
	Outros	14,75%	45
	Não possui	28,85%	88

Fonte: Elaborado pelo autor

As empresas em que os respondentes atuam são, na maior parte, organizações de grande porte, sendo 48,5% com mais de 5.000 funcionários e 55,1% com faturamento anual superior a R\$ 1 bilhão. As organizações do setor privado contaram com o maior número de casos (53,8%) seguidas por empresas de capital aberto (42,6%) de acordo com a Tabela 4.

Tabela 4 – Tipo de organização

		Frequência	%
Tipo de Organização	Capital aberto (listada)	130	42,6
	Organização privada (não listada)	164	53,8
	Organização sem fins lucrativos (não relacionada ao governo)	11	3,6
Localização			
Geográfica	BA	1	0,3
	CE	10	3,3
	DF	3	1,0
	GO	2	0,7
	MA	1	0,3
	MG	11	3,6
	MS	1	0,3
	PB	1	0,3
	PE	1	0,3
	PR	15	4,9
	RJ	25	8,2
	RN	1	0,3
	RS	17	5,6
	SC	2	0,7
	SP	214	70,2
Quantidade de			
Funcionários	Mais de 5.000	148	48,5
	Entre 1.000 e 5.000	84	27,5
	Entre 500 e 999	29	9,5
	Entre 100 e 499	29	9,5
	Menos de 100	15	4,9
Faturamento			
anual	Mais de R\$ 1 bilhão	168	55,1
	Entre R\$ 500 e R\$ 1 bilhão	68	22,3
	Entre R\$ 250 e R\$ 499 milhões	34	11,1
	Menos de R\$ 250 milhões	35	11,5

Fonte: Elaborado pelo autor

A Tabela 4 e a Figura 12 apresentam a distribuição geográfica dos respondentes concentrados de forma predominante na região Sudeste, especialmente no estado de São Paulo (70,2%). Não foram encontrados registros nos seguintes estados: Acre, Alagoas, Amapá, Amazonas, Espírito Santo, Mato Grosso, Pará, Piauí, Rondônia, Roraima, Sergipe e Tocantins.

Figura 12 – Distribuição dos respondentes da amostra no mapa do Brasil

Fonte: Elaborado pelo autor

Dentre as formas pelas quais os auditores internos adquirem conhecimentos e habilidades em Tecnologia da Informação (TI), a que mais se destacou foi a formação fornecida pelas suas empresas (47,87%) na Tabela 5.

A maioria dos respondentes (87,2%) informou participar ou ter interesse em participar de eventos relacionados a inovações tecnológicas em AI, como os seminários e congressos organizados pelo IIA Brasil.

Tabela 5 – Formas de aquisição de competências de TI pelos respondentes

	%	Quantidade
Autodidata	12,46%	38
Cursos de formação externos	16,72%	51
Formação pela Empresa	47,87%	146
Formação pela Instituição de Ensino Superior	7,87%	24
Não se aplica	15,08%	46

Fonte: Elaborado pelo autor

5.1.2 Ferramentas de TI, Tipos de Dados e Atividades de Auditoria Interna

No segundo bloco de questões, foi utilizada uma escala de pontos, em ordem crescente de intensidade, com variação de 1 (baixa frequência) a 5 (alta frequência), para medir a frequência de utilização de tipos de ferramentas de TI, tipos de dados e tipos de atividades de AI. Além disso, foi disponibilizada também uma opção para captar a não utilização dos tipos mencionados (0 – não utiliza).

Em relação às ferramentas tecnológicas avançadas não utilizadas pelos respondentes da amostra, é possível observar as ferramentas de inteligência artificial e aprendizado de máquina (231 respondentes), linguagens de programação e modelagem estatística (198 respondentes), ETL (165 respondentes) e visualização de dados (138 respondentes) sendo que, esses tipos de ferramentas apresentam também baixa frequência de utilização (Tabela 6).

Os tipos de ferramentas que apresentam as maiores frequências de utilização, somando-se os níveis 3 a 5 (de média para alta), são: ERP (250 respondentes), ferramentas de CAATTs como ACL e IDEA (168 respondentes) e auditoria contínua (165 respondentes).

Tabela 6 – Ferramentas de TI utilizadas pelos respondentes

	0-NÃO											
	UTILIZA		1 - BAIXA		2		3 - MÉDIA		4		5 - ALTA	
	Fr	%	Fr	%	Fr	%	Fr	%	Fr	%	Fr	%
1. Análise de dados aplicada à auditoria. Exemplos: ACL (Audit Command Language), IDEA (Interactive Data Extraction and Analysis).	80	26,2%	27	8,9%	30	9,8%	56	18,4%	48	15,7%	64	21,0%
2. Ferramentas de sistemas ERP (Enterprise Resource Planning). Exemplos: SAP, Totvs.	28	9,2%	12	3,9%	15	4,9%	44	14,4%	69	22,6%	137	44,9%
3. Extração de dados (ETL – Extract, Transform, Load). Exemplo: Power Center.	165	54,1%	36	11,8%	28	9,2%	27	8,9%	23	7,5%	26	8,5%
4. Linguagens SQL e execução de Queries.	99	32,5%	40	13,1%	37	12,1%	55	18,0%	38	12,5%	36	11,8%
5. Rotinas de Auditoria Contínua (processos automatizados de monitoramento contínuo de dados).	60	19,7%	35	11,5%	45	14,8%	56	18,4%	42	13,8%	67	22,0%
6. Visualização de dados. Exemplos: Qlikview, Tableau.	138	45,2%	29	9,5%	30	9,8%	37	12,1%	35	11,5%	36	11,8%
7. Linguagens de programação e modelagem estatística. Exemplos: SAS, [R], Python, SPSS.	198	64,9%	36	11,8%	21	6,9%	20	6,6%	23	7,5%	7	2,3%
8. Plataformas de inteligência artificial e aprendizado de máquina. Exemplos: IBM Watson, Microsoft Azure.	231	75,7%	29	9,5%	14	4,6%	22	7,2%	5	1,6%	4	1,3%

Fonte: Elaborado pelo autor

Os tipos de dados identificados como não utilizados pelos respondentes (Tabela 7) são os dados em formato de imagem ou vídeo (172 respondentes), dados em formato de áudio para análise de sentimento (135 respondentes), dados não estruturados externos à empresa (86 respondentes) e dados estruturados externos à empresa (78 respondentes) sendo que esses tipos de dados apresentam também baixa frequência de utilização. As maiores frequências de

utilização encontram-se em dados não financeiros (274 respondentes), dados financeiros (269 respondentes) e dados de arquivos em formato XML e XBRL (202 respondentes).

Tabela 7 – Tipos de dados utilizados pelos respondentes

	0-NÃO UTILIZA		1 - BAIXA		2		3 - MÉDIA		4		5 - ALTA	
	Fr	%	Fr	%	Fr	%	Fr	%	Fr	%	Fr	%
1. Dados financeiros	10	3,3%	12	3,9%	14	4,6%	48	15,7%	70	23,0%	151	49,5%
2. Dados não financeiros obtidos de bancos de dados da empresa (Exemplos: cadastros de clientes, fornecedores, estoques, recursos humanos).	9	3,0%	10	3,3%	12	3,9%	42	13,8%	88	28,9%	144	47,2%
3. Dados de arquivos em formato XML, XBRL.	54	17,7%	26	8,5%	23	7,5%	57	18,7%	57	18,7%	88	28,9%
4. Dados em linguagem natural (Exemplos: mensagens de e-mail, atas de reunião) para text mining (mineração de texto).	65	21,3%	25	8,2%	31	10,2%	46	15,1%	46	15,1%	92	30,2%
5. Dados estruturados externos à empresa (Exemplo: SERASA).	78	25,6%	41	13,4%	34	11,1%	60	19,7%	37	12,1%	55	18,0%
6. Dados não estruturados externos à empresa (Exemplos: páginas de websites, mensagens em redes sociais).	86	28,2%	40	13,1%	55	18,0%	46	15,1%	37	12,1%	41	13,4%
7. Dados em formato de imagem ou vídeo (Exemplo: reconhecimento facial, identificação de documentos).	172	56,4%	39	12,8%	28	9,2%	31	10,2%	17	5,6%	18	5,9%
8. Dados em formato de áudio para análise de sentimento (Exemplo: canal de denúncias).	135	44,3%	41	13,4%	31	10,2%	31	10,2%	26	8,5%	41	13,4%

Fonte: Elaborado pelo autor

Todas as atividades de AI, nas quais os respondentes utilizam os tipos de ferramentas de TI e tipos de dados, apresentaram frequências altas com destaque para os testes de auditoria (197 respondentes), a obtenção de evidências de auditoria (170 respondentes), a avaliação do controle interno (149 respondentes), e a avaliação de riscos de auditoria (139 respondentes), apresentando também níveis 4 (intermediário-alto) e 3 (médio) relevantes. A atividade de Circularização foi apontada como não utilizada por 27,2 % dos respondentes da amostra.

Tabela 8 – Atividades de Auditoria Interna

	0-NÃO		1 - BAIXA		2		3 - MÉDIA		4		5 - ALTA	
	Fr	%	Fr	%	Fr	%	Fr	%	Fr	%	Fr	%
1. Planejamento da auditoria	24	7,9%	20	6,6%	28	9,2%	50	16,4%	52	17,0%	131	43,0%
2. Avaliação do controle interno, identificando potenciais outliers que possam indicar falhas ou fraquezas dos controles.	10	3,3%	12	3,9%	14	4,6%	52	17,0%	68	22,3%	149	48,9%
3. Avaliação de riscos de auditoria	12	3,9%	19	6,2%	27	8,9%	48	15,7%	60	19,7%	139	45,6%
4. Testes de auditoria	5	1,6%	6	2,0%	11	3,6%	30	9,8%	56	18,4%	197	64,6%
5. Circularização (confirmação de fatos alegados pelo auditado a partir de fontes de dados externas à empresa)	83	27,2%	35	11,5%	30	9,8%	47	15,4%	39	12,8%	71	23,3%
6. Obtenção de evidências de auditoria	14	4,6%	10	3,3%	8	2,6%	41	13,4%	62	20,3%	170	55,7%
7. Amostragem estatística	15	4,9%	17	5,6%	19	6,2%	57	18,7%	66	21,6%	131	43,0%
8. Análise de Segregação de funções	30	9,8%	30	9,8%	16	5,2%	59	19,3%	43	14,1%	127	41,6%
9. Análise e Recuperação de Pagamentos Duplicados	34	11,1%	19	6,2%	21	6,9%	53	17,4%	53	17,4%	125	41,0%

Fonte: Elaborado pelo autor

5.1.3 Itens dos Construtos do Modelo UTAUT

As questões do terceiro bloco referem-se aos itens do questionário elaborado por Venkatesh et al. (2003) para estimar os modelos estruturais, realizar testes preliminares e validações do modelo UTAUT. A tabela 9 demonstra os resultados da análise descritiva referente ao construto Expectativa de Desempenho e seus respectivos construtos originais. Em Utilidade Percebida, 83% concordam que o uso de ferramentas de BDA é útil para o desempenho do seu trabalho, 75% concordam que permitem a conclusão das tarefas com mais rapidez e 75% concordam que aumentam a produtividade. No construto *Job-Fit*, observa-se que 78% concordam que as ferramentas de BDA podem aumentar o seu desempenho no desenvolvimento de sua atividade e, com relação ao construto Expectativa de Resultado, 75% concordam que têm mais chances de obter reconhecimento profissional com o uso de ferramentas de BDA.

Tabela 9 – Análise Descritiva: Expectativa de Desempenho (ED)

Indicador	Não				
	Discordo	Discordo	concordo,	Concordo	Concordo
	Totalmente	Parcialmente	nem discordo	Parcialmente	Totalmente
	%	%	%	%	%
1. O uso de ferramentas de BDA é útil para o meu trabalho.	1%	3%	13%	23%	60%
6. O uso de ferramentas de BDA permite que eu conclua as tarefas mais rapidamente.	5%	3%	17%	26%	49%
12. Tenho mais chance de obter reconhecimento profissional com o uso de ferramentas de BDA.	4%	6%	16%	27%	48%
15. O uso de ferramentas de BDA melhora a qualidade do meu trabalho.	3%	4%	14%	28%	50%
19. O uso de ferramentas de BDA aumenta a minha produtividade.	4%	3%	17%	27%	48%

Fonte: Elaborado pelo autor

O construto Expectativa de Esforço (EE), que inclui os construtos originais Facilidade de Uso Percebida e Facilidade de Uso, é representado na tabela 10. Com relação à Facilidade de Uso Percebida, destacam-se 36% dos respondentes que discordam total ou parcialmente que a interação com ferramentas de BDA ocorre de forma clara e compreensível, enquanto 35% concordam total ou parcialmente. De forma semelhante, há um equilíbrio entre aqueles que discordam (32%) ou concordam (30%) total ou parcialmente que as ferramentas de BDA são fáceis de usar enquanto 38% posicionam-se na categoria neutra (não concordam e nem discordam). A facilidade em adquirir habilidade no uso de ferramentas de BDA é apontada, em primeiro lugar, por 46% que concordam de forma total ou parcial seguida por 37% que não concordam e nem discordam dessa assertiva.

Quanto ao construto Facilidade de Uso, 47% consideram fácil o aprendizado do uso de ferramentas de BDA, enquanto que 31% não concordam e nem discordam dessa assertiva. De uma forma geral, o construto Expectativa de Esforço apresentou certo equilíbrio entre aqueles que concordam ou discordam de forma parcial ou total. Além disso, foram observados níveis relevantes de respostas na categoria neutra (não concordo, nem discordo).

Tabela 10 – Análise Descritiva: Expectativa de Esforço (EE)

Indicador	Não				
	Discordo	Discordo	concordo,	Concordo	Concordo
	Totalmente	Parcialmente	nem discordo	Parcialmente	Totalmente
	%	%	%	%	%
5. A minha interação com ferramentas de BDA ocorre de forma clara e compreensível.	17%	19%	29%	19%	16%
8. Eu considero as ferramentas de BDA fáceis de usar.	11%	22%	38%	17%	12%
11. Aprender a utilizar ferramentas de BDA é fácil para mim.	9%	13%	31%	28%	19%
16. Seria fácil tornar-me habilidoso no uso de ferramentas de BDA.	6%	11%	37%	24%	22%

Fonte: Elaborado pelo autor

O construto Influência Social (IS), que contempla os construtos originais Norma Subjetiva e Fatores Sociais, é representado na tabela 11. Conforme a Norma Subjetiva, verificou-se que a maioria dos respondentes concordam total ou parcialmente que as pessoas importantes acham que elas devam utilizar as ferramentas de BDA no trabalho (63%) e que pessoas que exercem influência sobre o comportamento deles acham que estes devem utilizar as ferramentas de BDA no trabalho (52%).

Quanto ao construto Fatores Sociais, 52% dos respondentes concordam total ou parcialmente que a gerência da área de AI incentiva o uso de ferramentas de BDA e 31% entendem que a empresa tem incentivado o uso de ferramentas de BDA. De uma forma geral, pode-se afirmar que a maioria dos respondentes concorda com a existência da influência de pessoas para que os auditores internos adotem as ferramentas de BDA no seu trabalho.

Tabela 11 – Análise Descritiva: Influência Social (IS)

Indicador	Não				
	Discordo	Discordo	concordo,	Concordo	Concordo
	Totalmente	Parcialmente	nem discordo	Parcialmente	Totalmente
	%	%	%	%	%
3. Pessoas importantes para mim acham que eu devo utilizar as ferramentas de BDA no meu trabalho.	8%	13%	16%	22%	41%
7. A gerência da área de auditoria interna incentiva o uso de ferramentas de BDA.	18%	11%	18%	16%	36%
13. Pessoas que exercem influência sobre o meu comportamento acham que eu devo utilizar as ferramentas de BDA no meu trabalho.	10%	13%	24%	22%	30%
17. Em geral, a empresa tem dado suporte para o uso de ferramentas de BDA.	24%	18%	27%	15%	16%

Fonte: Elaborado pelo autor

O construto Condições Facilitadoras (CF), formado pelos construtos originais Controle Comportamental Percebido e Condições Facilitadoras, é apresentado na tabela 12. Conforme o construto Controle Comportamental Percebido, a maioria dos respondentes discorda total ou parcialmente que os recursos necessários para usar ferramentas de BDA no trabalho estão disponíveis para eles (43%), que possuem conhecimento adequado para usar ferramentas de BDA (37%) e que as ferramentas de BDA não são compatíveis com outras ferramentas já utilizadas (44%).

Quanto ao construto original de Condições Facilitadoras, 48% dos respondentes discordam total ou parcialmente, enquanto que 28% dos respondentes concordam total ou parcialmente, que um profissional ou equipe de suporte está disponível para auxiliá-los quando surgem dificuldades em utilizar ferramentas de BDA. De uma forma geral, pode-se afirmar que a maioria dos respondentes discorda que há uma infraestrutura organizacional e técnica que apoie o uso do ferramentas de BDA. Além disso, também foram observados níveis relevantes de respostas na categoria neutra (não concordo, nem discordo).

Tabela 12 – Análise Descritiva: Condições Facilitadoras (CF)

Indicador	Não				
	Discordo	Discordo	concordo,	Concordo	Concordo
	Totalmente	Parcialmente	nem discordo	Parcialmente	Totalmente
	%	%	%	%	%
4. Os recursos necessários para usar ferramentas de BDA no trabalho estão disponíveis para mim.	23%	20%	27%	12%	19%
9. Um profissional ou equipe de suporte está disponível para me auxiliar quando tenho dificuldades em utilizar ferramentas de BDA.	28%	20%	24%	13%	15%
14. Eu tenho conhecimento adequado para usar ferramentas de BDA.	14%	23%	35%	16%	11%
18. As ferramentas de BDA não são compatíveis com outras ferramentas que eu uso.	23%	21%	33%	10%	12%

Fonte: Elaborado pelo autor

Conforme demonstrado na Tabela 13, verificou-se que os respondentes concordam de forma total ou parcial que planejam (62%), intencionam (65%), ou que irão (55%) utilizar ferramentas de BDA no trabalho nos próximos meses.

Tabela 13 – Análise Descritiva: Intenção de Uso (IU)

Indicador	Discordo	Discordo	Não	Concordo	Concordo
	Totalmente	Parcialmente	concordo, nem discordo	Parcialmente	Totalmente
	%	%	%	%	%
2. Eu planejo utilizar ferramentas de BDA no trabalho nos próximos meses.	7%	10%	21%	20%	42%
10. Eu tenho intenção em utilizar ferramentas de BDA em meu trabalho nos próximos meses.	9%	10%	17%	23%	42%
20. Eu irei utilizar ferramentas de BDA no trabalho nos próximos meses.	16%	11%	18%	22%	33%

Fonte: Elaborado pelo autor

5.2 Análise do Modelo de Equações Estruturais

A presente seção procura apresentar os resultados obtidos na análise do modelo de equações estruturais (MEE) segundo o método PLS-PM (*Partial Least Squares - Path Modeling*) para discutir o modelo teórico e realizar testes das hipóteses elaboradas para a pesquisa (Hair et al., 2014).

Conforme apresentado na seção 4.4 (Métodos de Análise de Dados), a análise deve ser conduzida em basicamente dois momentos: a análise do modelo de mensuração e a análise do modelo estrutural.

Figura 13 – Representação dos procedimentos de ajuste do MEE

Fonte: Adaptado de Ringle et al. (2014)

5.2.1 Análise do Modelo de Mensuração

A primeira etapa de análise do modelo de mensuração, que no presente estudo trata-se de um modelo de mensuração reflexivo, corresponde ao estudo das cargas fatoriais dos indicadores, assim como suas variâncias médias extraídas (AVE – *Average Variance Extracted*).

A AVE é uma medida comum para estabelecimento da Validade Convergente e corresponde ao grau no qual um construto latente explica a variância de seus indicadores (Hair et al., 2014) ou quanto, em média, as variáveis se correlacionam positivamente com os seus respectivos construtos. O aumento do valor da AVE, que corresponde à média das cargas fatoriais elevada ao quadrado, pode ser obtido pela eliminação das variáveis com cargas fatoriais de menor valor (Ringle et al., 2014).

Tabela 14 – AVE (antes do ajuste)

Construtos	Variância média extraída (AVE)
Condições Facilitadoras	0,492
Expectativa de Desempenho	0,658
Expectativa de Esforço	0,640
Influência Social	0,683
Intenção de Uso	0,842

Fonte: Elaborado pelo autor

Como podemos observar na tabela 14, o construto Condições Facilitadoras (CF) obteve uma variância média extraída (AVE) abaixo de 0,5. Por este motivo, foi realizado o ajuste do modelo retirando o indicador [18] “As ferramentas de BDA não são compatíveis com outras ferramentas que eu uso”, que apresentou carga fatorial menor que 0,70. Assim, após o ajuste do modelo, a Tabela 15 apresenta a condição ideal onde todas as AVE estão acima de 0,50 (Hair et al., 2014), indicando que o modelo converge para um resultado satisfatório (Fornell & Larcker, 1981).

Tabela 15 – AVE (após o ajuste)

Construtos	Variância Média Extraída (AVE)
Condições Facilitadoras	0,615
Expectativa de Desempenho	0,658
Expectativa de Esforço	0,642
Influência Social	0,683
Intenção de Uso	0,842

Fonte: Elaborado pelo autor

O Fator de Inflação da Variância (VIF – *Variance Inflation Factor*) quantifica a gravidade da colinearidade entre os indicadores em um modelo de medição formativo. Embora a sua aplicação não seja obrigatória para modelos reflexivos, a análise de multicolinearidade foi realizada no presente estudo. O modelo pode apresentar problemas de colinearidade quando os indicadores redundantes forem usados como itens únicos para medir dois ou mais construtos (Hair et al., 2014).

Conforme mostra a tabela 16, os valores dos indicadores não apresentaram Fatores de Inflação de Variância Externos (*outer VIF values*) acima de 5,0 indicando que o modelo não apresenta problemas de multicolinearidade.

Tabela 16 – Fator de Inflação da Variância (VIF) dos Indicadores

Indicadores	VIF
1. O uso de ferramentas de BDA é útil para o meu trabalho.	1,738
10. Eu tenho intenção em utilizar ferramentas de BDA em meu trabalho...	2,731
11. Aprender a utilizar ferramentas de BDA é fácil para mim.	2,258
12. Tenho mais chance de obter reconhecimento profissional com o uso...	1,617
13. Pessoas que exercem influência sobre o meu comportamento acham...	2,193
14. Eu tenho conhecimento adequado para usar ferramentas de BDA.	1,275
15. O uso de ferramentas de BDA melhora a qualidade do meu trabalho.	2,648
16. Seria fácil tornar-me habilitado no uso de ferramentas de BDA.	1,868
17. Em geral, a empresa tem dado suporte para o uso de ferramentas de BDA.	1,805
19. O uso de ferramentas de BDA aumenta a minha produtividade...	2,780
2. Eu planejo utilizar ferramentas de BDA no trabalho nos próximos meses.	2,936
20. Eu irei utilizar ferramentas de BDA no trabalho nos próximos meses.	3,352
3. Pessoas importantes para mim acham que eu devo utilizar as ferramentas...	2,065
4. Os recursos necessários para usar ferramentas de BDA no trabalho...	1,546
5. A minha interação com ferramentas de BDA ocorre de forma clara...	1,428
6. O uso de ferramentas de BDA permite que eu conclua as tarefas mais...	1,923
7. A gerência da área de auditoria interna incentiva o uso de ferramentas...	2,117
8. Eu considero as ferramentas de BDA fáceis de usar...	1,987
9. Um profissional ou equipe de suporte está disponível para me auxiliar.	1,356

Fonte: Elaborado pelo autor

Da mesma forma que os indicadores da Tabela 16, todos os construtos apresentaram VIF menores que 5,0 na Tabela 17 indicando que não há problemas de multicolinearidade.

Tabela 17 – Fator de Inflação da Variância (VIF) dos Construtos

	Condições Facilitadoras	Expectativa de Desempenho	Expectativa de Esforço	Influência Social	Intenção de Uso
Condições Facilitadoras			1,000		3,099
Expectativa de Desempenho					1,868
Expectativa de Esforço					2,489
Influência Social					2,520
Intenção de Uso					

Fonte: Elaborado pelo autor

Na segunda etapa, são observados os critérios de Consistência Interna (Alfa de Cronbach) e Confiabilidade Composta (CC). O Alfa de Cronbach (ACr) é uma medida da confiabilidade da consistência interna que assume cargas iguais de indicadores e que são priorizados de acordo com sua confiabilidade individual.

O ACr é considerado um indicador conservador por ser sensível ao número de itens na escala e, geralmente, por subestimar a confiabilidade da consistência interna (Hair et al., 2014).

Devido às limitações do ACr, a Confiabilidade Composta (CC) é considerada mais adequada ao PLS-PM pois não assume cargas iguais de indicador e prioriza as variáveis de acordo com as suas confiabilidades, variando entre 0 e 1, com valores mais altos indicando níveis mais altos de confiabilidade.

Conforme pode ser observado na Tabela 18, tanto a consistência interna quanto a confiabilidade estão adequados, com valores de ACr e Rho de Dillon-Goldstein acima de 0,70 e valores de CC acima de 0,70 (Hair et al., 2014), sendo considerados satisfatórios.

Desse modo, tanto a consistência interna quanto a confiabilidade estão adequados a esta pesquisa exploratória, indicando que as respostas são confiáveis.

Tabela 18 – Consistência interna (Alfa de Cronbach) e Confiabilidade Composta (CC)

Construtos	Alfa de Cronbach	rho_A	Confiabilidade Composta
Condições Facilitadoras	0,687	0,700	0,827
Expectativa de Desempenho	0,869	0,873	0,906
Expectativa de Esforço	0,818	0,836	0,877
Influência Social	0,845	0,848	0,896
Intenção de Uso	0,906	0,906	0,941

Fonte: Elaborado pelo autor

Na terceira etapa é avaliada a validade discriminante (VD) do MEE para indicar que os construtos ou VLs são independentes uns dos outros, ou seja, que um construto é único e captura fenômenos não representados por outros construtos no modelo (Hair et al., 2014).

O primeiro critério para avaliar a VD consiste no exame das cargas cruzadas (*cross loadings*) dos indicadores. Especificamente, a carga externa de um indicador no seu construto associado deve ser maior do que todas as suas cargas em outros construtos (as cargas cruzadas).

Na Tabela 19, é possível constatar que o modelo atende ao critério de VD, pois a carga fatorial de um indicador no seu respectivo construto é sempre maior do que as cargas fatoriais deste indicador com outros construtos.

Tabela 19 – Validade Discriminante (VD)

Indicadores	CF	ED	EE	IS	IU
CF 14. Eu tenho conhecimento adequado...	0,773	0,432	0,740	0,400	0,379
CF 4. Os recursos necessários para usar ferramentas de BDA no trabalho...	0,848	0,421	0,543	0,714	0,637
CF 9. Um profissional ou equipe de suporte está disponível para me auxiliar...	0,726	0,303	0,413	0,572	0,481
ED 1. O uso de ferramentas de BDA é útil para o meu trabalho...	0,397	0,788	0,442	0,519	0,555
ED 12. Tenho mais chance de obter reconhecimento profissional como uso...	0,343	0,731	0,389	0,481	0,467

“continua”

“continuação”

Indicadores	CF	ED	EE	IS	IU
ED 15. O uso de ferramentas de BDA melhora a qualidade do meu trabalho...	0,413	0,865	0,482	0,473	0,531
ED 19. O uso de ferramentas de BDA aumenta a minha produtividade...	0,444	0,874	0,517	0,535	0,552
ED 6. O uso de ferramentas de BDA permite que eu conclua...	0,419	0,790	0,495	0,486	0,480
EE 11. Aprender a utilizar ferramentas de BDA é fácil...	0,502	0,427	0,825	0,323	0,398
EE 16. Seria fácil tornar-me habilidoso no uso...	0,474	0,513	0,758	0,331	0,395
EE 5. A minha interação com ferramentas de BDA...	0,727	0,476	0,785	0,629	0,606
EE 8. Eu considero as ferramentas de BDA fáceis de usar	0,570	0,417	0,833	0,413	0,377
IS 3. Pessoas importantes para mim acham que eu devo utilizar as ferramentas...	0,483	0,507	0,400	0,823	0,632
IS 7. A gerência da área de auditoria interna incentiva o uso de ferramentas...	0,655	0,523	0,476	0,855	0,671
IS 13. Pessoas que exercem influência sobre o meu comportamento acham que eu...	0,511	0,572	0,477	0,835	0,569
IS 17. Em geral a empresa tem dado suporte para o uso...	0,708	0,435	0,495	0,791	0,597
IU 10. Eu tenho intenção em utilizar ferramentas de BDA...	0,553	0,606	0,537	0,666	0,907
IU 2. Eu planejo utilizar ferramentas de BDA no trabalho nos próximos meses.	0,590	0,579	0,510	0,684	0,915
IU 20. Eu irei utilizar ferramentas de BDA no trabalho nos próximos meses...	0,609	0,577	0,538	0,712	0,931

Fonte: Elaborado pelo autor

“conclusão”

O segundo critério, o de Fornell e Larcker (1981), é o mais conservador para a VD e compara as raízes quadradas dos valores das AVE de cada construto com as correlações entre os construtos (VLs).

O coeficiente de correlação de Pearson permite prever as pontuações de uma variável com base nas pontuações de outra variável de modo que, quanto maior for a correlação entre as variáveis (covariação) maior será a capacidade de precisão (Sampieri et al., 2013).

Tabela 20 – Raiz quadrada da AVE

	Condições Facilitadoras	Expectativa de Desempenho	Expectativa de Esforço	Influência Social	Intenção de Uso
Condições Facilitadoras	0,784				
Expectativa de Desempenho	0,498	0,811			
Expectativa de Esforço	0,733	0,574	0,801		
Influência Social	0,714	0,615	0,558	0,826	
Intenção de Uso	0,637	0,640	0,576	0,749	0,918

Fonte: Elaborado pelo autor

As tabelas 20 e 21 demonstram que os construtos são independentes uns dos outros, segundo o critério de Fornell e Larcker (1981). Observa-se que a raiz quadrada do AVE de cada construto (Tabela 20) é maior do que sua correlação mais alta com qualquer outro construto (Tabela 21).

Tabela 21 – Correlação das Variáveis Latentes

Construtos	Condições Facilitadoras	Expectativa de Desempenho	Expectativa de Esforço	Influência Social	Intenção de Uso
Condições Facilitadoras	1,000				
Expectativa de Desempenho	0,498	1,000			
Expectativa de Esforço	0,733	0,574	1,000		
Influência Social	0,714	0,615	0,558	1,000	
Intenção de Uso	0,637	0,640	0,576	0,749	1,000

Fonte: Elaborado pelo autor

Com a constatação da garantia da VD, concluem-se as validações do modelo de mensuração e, na sequência, parte-se para a análise do modelo estrutural voltada para a relação entre os construtos e as hipóteses da pesquisa. A Figura 14 apresenta o modelo ajustado após a análise do modelo de mensuração.

Figura 14 – Modelo ajustado após análise do Modelo de Mensuração

Fonte: Elaborado pelo autor

5.2.2 Análise do Modelo Estrutural

Na primeira etapa da análise do modelo estrutural, são avaliados os coeficientes de determinação de Pearson (R^2), a medida mais comumente utilizada, que avalia a porção da variância das variáveis endógenas explicada pelo modelo estrutural, indicando a qualidade do modelo ajustado (Ringle et al., 2014). O valor R^2 varia de 0 a 1, com níveis mais altos indicando maior precisão preditiva. Para a área de ciências sociais e comportamentais, Cohen (1988) sugere que $R^2=2\%$ seja classificado como efeito pequeno, $R^2=13\%$ como efeito médio e $R^2=26\%$ como efeito grande.

Tabela 22 – Coeficientes de Determinação de Pearson (R^2)

	R^2	R^2 ajustado
Expectativa de Esforço	0,537	0,535
Intenção de Uso	0,631	0,626

Fonte: Elaborado pelo autor

De acordo com a tabela 22, tanto o R^2 do construto Expectativa de Esforço (0,537), quanto o R^2 do construto Intenção de Uso (0,631), são classificados como um grande efeito indicando uma alta precisão preditiva do modelo.

Além de avaliar a magnitude dos valores de R^2 como um critério de precisão preditiva, são avaliados também outros dois indicadores de qualidade de ajuste do modelo: Validade Preditiva (Q^2) ou indicador de Stone-Geisser, e Tamanho do Efeito (f^2) ou Indicador de Cohen.

O Q^2 de Stone-Geisser avalia a qualidade da predição do modelo, sendo que os valores $Q^2 > 0$ indicam que o modelo se aproxima do que se esperava dele (Hair et al., 2014) e um modelo perfeito teria $Q^2 = 1$ (mostra que o modelo reflete a realidade, sem erros).

Quando o PLS-PM exhibe relevância preditiva, está demonstrando a precisão da previsão dos pontos de dados dos indicadores em modelos de medição reflexivos. A validade preditiva Q^2 foi calculada por meio da técnica *blindfolding* de reutilização de amostra e obteve valor maior do que 0 no construto Intenção de Uso (IU), indicando a relevância preditiva do modelo (Tabela 23).

Tabela 23 – Relevância ou Validade Preditiva (Q^2)

	SSO	SSE	$Q^2 (=1-SSE/SSO)$
Condições Facilitadoras	912,000	912,000	
Expectativa de Desempenho	1.520,000	1.520,000	
Expectativa de Esforço	1.216,000	1.216,000	
Influência Social	1.216,000	1.216,000	
Intenção de Uso	912,000	455,937	0,500

Fonte: Elaborado pelo autor

O Tamanho do Efeito (f^2) é obtido pela inclusão e pela retirada de construtos do modelo, um a um, verificando se o construto exógeno omitido tem um impacto substantivo nos construtos endógenos, para avaliar quanto cada construto é “útil” para o ajuste do modelo (Ringle et al., 2014; Hair et al., 2014).

O Tamanho do Efeito permite avaliar a contribuição de um construto exógeno para o valor R^2 de uma VL endógena (Tabela 22), de modo que os valores de f^2 de 2%, 15% e 35% indicam o efeito pequeno, médio ou grande, respectivamente, de um construto exógeno em um construto endógeno (Hair et al., 2014).

Tabela 24 – Tamanho do Efeito (f^2)

	Condições Facilitadoras	Expectativa de Desempenho	Expectativa de Esforço	Influência Social	Intenção de Uso
Condições Facilitadoras			1,158		0,012
Expectativa de Desempenho					0,085
Expectativa de Esforço					0,009
Influência Social					0,234

Fonte: Elaborado pelo autor

Na tabela 24, o construto Influência Social (IS) apresentou um efeito médio para o construto (0,234) pois o valor correspondente ao efeito de sua retirada não supera o valor de 0,35, enquanto os demais construtos apresentaram efeitos pequenos inferiores a 0,15.

Em seguida, após concluída a avaliação da qualidade de ajuste do modelo, realiza-se a interpretação dos coeficientes de caminho ou coeficientes estruturais (*path coefficients*), que correspondem às relações entre as VLs no modelo estrutural (Hair et al., 2014).

O PLS-PM não assume que os dados sejam normalmente distribuídos, baseando-se em um procedimento não paramétrico de inicialização para testar os coeficientes quanto à sua significância. O teste de significância é realizado para verificar se um determinado resultado ocorreu por ser verdadeiro ou decorrente de um evento aleatório ou erro.

Para tanto, foi utilizada a técnica de reamostragem *bootstrapping*, calculado com 1000 subamostras, para avaliar a significância dos coeficientes estruturais, que consiste em retirar da amostra original um grande número de subamostras que são sorteadas aleatoriamente (com substituição). Com essas informações, os valores *t* são calculados para avaliar a significância de cada coeficiente.

Tabela 25 – Coeficientes estruturais (*Path Coefficients*)

	Condições Facilitadoras	Expectativa de Desempenho	Expectativa de Esforço	Influência Social	Intenção de Uso
Condições Facilitadoras			0,733		0,115
Expectativa de Desempenho					0,242
Expectativa de Esforço					0,092
Influência Social					0,466

Fonte: Elaborado pelo autor

Os coeficientes estruturais próximos a + 1 indicam uma forte relação positiva enquanto que aqueles que se aproximam de – 1 indicam uma forte relação negativa de modo que, quanto mais próximos de 0 os coeficientes estimados estiverem, mais fracos serão os relacionamentos.

Os coeficientes estruturais apresentados na Tabela 25 indicam, por exemplo, que aumentando a VL Influência Social de 1, a VL endógena Intenção de Uso aumenta de 0,466.

Com relação à avaliação da significância dos coeficientes, são recomendados valores do teste *t* de Student $\geq 1,96$, que correspondem ao *p-value* $\leq 0,05$ a um nível de confiança de 95% (Ringle et al., 2014).

Tabela 26 – Valores de significância (Construtos)

	Amostra Original	Média	Desvio Padrão	T Statistics	P Values
Condições Facilitadoras → Expectativa de Esforço	0,733	0,734	0,026	28,499	0,000
Condições Facilitadoras → Intenção de Uso	0,115	0,113	0,072	1,593	0,111
Expectativa de Desempenho → Intenção de Uso	0,242	0,245	0,056	4,348	0,000
Expectativa de Esforço → Intenção de Uso	0,092	0,088	0,061	1,504	0,133
Influência Social → Intenção de Uso	0,466	0,471	0,069	6,770	0,000

Fonte: Elaborado pelo autor

Conforme ilustra a Tabela 26, a variável dependente Intenção de Uso (IU) recebe *inputs* de Expectativa de Desempenho (ED), Expectativa de Esforço (EE), Influência Social (IS) e Condições Facilitadoras (CF). ED e IS apresentam coeficientes estruturais com 0,242 e 0,466 respectivamente, indicando influência considerável sobre a IU.

Os construtos CF e EE apresentam coeficientes estruturais de 0,115 e 0,092 apresentando baixa influência sobre a IU. As relações de ED e IS com IU mostraram-se significantes estatisticamente ($t \geq 1,96$ e $p\text{-value} \leq 0,05$), com os respectivos valores do teste T de 4,388 e 6,770 enquanto que EE e CF não apresentaram significância estatística com relação à IU. O coeficiente estrutural da relação entre CF e EE foi 0,733 e o valor do teste t de 28,499, com alto nível de significância.

No intuito de compreender o papel exercido pelas variáveis moderadoras, foi utilizada a técnica de *bootstrapping* para analisar a diferença de Gênero, Idade e Experiência na relação entre ED, EE, IS e CF e a IU para verificar se essa diferença é determinante na aceitação de uma nova tecnologia. Conforme resultados apresentados na Tabela 27, nenhuma das relações das variáveis moderadoras apresenta efeitos significativos.

Tabela 27 – Valores de significância (Variáveis Moderadoras)

Path Coefficients					
	Amostra Original	Média	Desvio Padrão	T Statistics	P Values
Efeito moderador → Intenção de Uso	-0,040	-0,016	0,052	0,770	0,441
Efeito moderador - Condições facilitadoras → Intenção de Uso	-0,033	-0,047	0,082	0,405	0,686
Efeito moderador - Expectativa de desempenho → Intenção de Uso	-0,052	-0,018	0,073	0,722	0,470
Efeito moderador - Expectativa de esforço → Intenção de Uso	0,030	0,069	0,076	0,395	0,693
Efeito moderador - Influência social → Intenção de Uso	0,058	0,012	0,095	0,605	0,546
Outer Loadings					
	Amostra Original	Média	Desvio Padrão	T Statistics	P Values
Gênero <- Efeito moderador	-0,372	0,193	0,530	0,701	0,483
Idade <- Efeito moderador	0,865	0,551	0,529	1,636	0,102
Tempo de Atuação em Auditoria Interna <- Efeito moderador	0,694	0,534	0,405	1,713	0,087

Fonte: Elaborado pelo autor

5.3 Discussão das Análises

Com base nos resultados apresentados anteriormente, foi realizada a análise das hipóteses da pesquisa proporcionando as seguintes discussões:

H₁: A Expectativa de Desempenho afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

A hipótese foi suportada ($p\text{-value} < 5\%$). As análises estatísticas indicam que há uma relação positiva e significativa entre a expectativa de desempenho (ED) e a Intenção de Uso (IU) de modo que, quanto maior a Expectativa de Desempenho, maiores são as intenções em adotar o BDA nas práticas de AI. A ED é um fator determinante altamente significativo da aceitação de *software*, sendo considerado o mais forte preditor do modelo (Venkatesh et al., 2003) indicando que os auditores internos da amostra da pesquisa acreditam que uma nova tecnologia melhorará seu desempenho no trabalho e apresentam ter intenções positivas de utilizá-la, de forma semelhante aos estudos anteriores sobre a aceitação de AC por auditores internos (Nascimento, 2019), CAATTs por auditores internos (Mahzan & Lymer, 2014), CAATTs por auditores externos (Bierstaker et al., 2014; Curtis & Payne, 2014), AC por auditores do setor público (Miranda, 2018), e técnicas de Big Data por gerentes de empresas espanholas de prestação de serviços (Cabrera-Sánchez & Villarejo-Ramos, 2020).

H₂: A Expectativa de Esforço afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

A hipótese não foi suportada ($p\text{-value} > 5\%$). Os testes estatísticos não confirmaram a relação entre a Expectativa de Esforço (EE) e a Intenção de Uso (IU); sendo assim, a Expectativa de Esforço não foi uma variável que influenciou os auditores internos a adotarem BDA. Resultados semelhantes foram obtidos por estudos sobre aceitação de CAATTs por auditores externos (Bierstaker et al., 2014), CAATTs por auditores internos (Mahzan & Lymer, 2014; Al-Hiyari, Said & Hattab, 2019), CAATTs por auditores externos (Pedrosa, 2015) e com interpretações distintas.

Bierstaker, Janvrin e Lowe (2014) sugerem que os auditores priorizam a eficácia da auditoria ao adotar a tecnologia, em relação às preferências pessoais relacionadas às variáveis

de esforço, que têm menor peso na decisão. No estudo de Mahzan e Lymer (2014), nenhum dos entrevistados relatou a facilidade de uso do *software* como sendo crítica para suas decisões de usar o GAS.

Os resultados do estudo indicaram que a não consideração da EE como fator-chave de influência pode ser explicada pelo fato de que os auditores internos são profissionais que trabalham em um domínio de conhecimento especializado e possuem altos níveis de qualificação profissional, ou de que essas ferramentas GAS são bem suportadas pela disponibilidade de treinamento. Como tal, o esforço necessário para aprender esses sistemas não é, por si só, pelo menos, uma restrição significativa ao seu uso. Al-Hiyari, Said e Hattab (2019) explicaram que os entrevistados no estudo eram usuários especialistas do CAATTs e, portanto, a decisão de adotar CAATTs não foi influenciada pela EE. Por outro lado, o estudo de Pedrosa (2015) apontou que a hipótese não foi suportada devido às limitações de CAATTs apontadas pelos participantes da pesquisa, que refletiam a necessidade de esforços adicionais para ser proficiente nos CAATTs.

Os resultados do estudo de Gonzalez, Sharma e Galletta (2012) demonstraram que as percepções dos auditores internos sobre EE é um dos preditores significativos de suas intenções em adotar a AC. Segundo os autores, os auditores internos precisam superar a curva de aprendizado para se tornarem hábeis no uso de tecnologias e também devem considerá-las fáceis e eficientes de usar. O conceito de AC, que foi introduzido pela primeira vez por Groomer e Murthy (1989) e Vasarhelyi e Halper (1991), foi disseminado desde então entre acadêmicos e profissionais de AI e inúmeras pesquisas foram publicadas, incluindo trabalhos de teses e dissertações.

No entanto, diferentemente de AC, CAATTs e GAS, BDA ainda é um tema emergente em pesquisas no campo da AI no cenário internacional e, principalmente, no cenário brasileiro. Desse modo, o baixo grau de facilidade e clareza associado ao uso de BDA, segundo a percepção dos auditores internos, pode ser explicado pelo fato de que BDA é um tema que ainda está no processo inicial de disseminação e prática entre pesquisadores e profissionais de AI (Gepp et al., 2018). Além disso, de acordo com a literatura, um dos principais obstáculos para a adoção de BDA nas práticas de AI é a falta de pessoal capacitado (Alles, 2015; Earley, 2015; Brown-Liburd et al., 2015).

H3: A Influência Social afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

A hipótese foi suportada ($p\text{-value} < 5\%$). A Influência Social tem relação positiva e significativa com a Intenção de Uso no contexto de adoção voluntária deste estudo. Os resultados apoiam estudos anteriores (Curtis & Payne, 2008; Gonzalez et al, 2012; Curtis & Payne, 2014; Nascimento, 2019), mostrando que a tomada de decisão dos auditores é influenciada pelas visões conhecidas de seus superiores, sugerindo também que os parceiros exercem uma influência extraordinária, talvez inesperada, sobre indivíduos de todos os níveis de suas empresas (Curtis & Payne, 2008). Gonzalez, Sharma e Galletta (2012) descobriram que, devido a diferenças culturais, os auditores internos da América do Norte têm maior probabilidade de usar AC devido a pressões suaves criadas pela influência social positiva por meio de colegas e autoridades superiores, enquanto que os auditores do Oriente Médio usam a tecnologia se ela for determinada pelas autoridades superiores. Desse modo, o uso obrigatório de AC possivelmente por uma autoridade governamental ou talvez até pelo conselho de administração da empresa, carregaria logicamente uma pressão mais pesada do que em um ambiente voluntário. Tang, Norman e Vendirzyk (2017) realizaram entrevistas com CAEs em organizações com e sem fins lucrativos de vários setores, incluindo manufatura, serviços governamentais, energia, bancos e ensino superior. As descobertas do estudo indicaram que os entrevistados valorizam certificações profissionais e o uso de BDA no IAF como importante ou muito importante.

No entanto, em outros estudos (Kim et al., 2009; Mahzan & Lymer, 2014; Al-Hiyari, Said & Hattab, 2019) os construtos relacionados à Influência Social nem sempre foram considerados significativos em contextos voluntários, mas em contextos obrigatórios (Venkatesh et al., 2003).

H4: As Condições Facilitadoras positivas aumentam a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

A hipótese não foi suportada ($p\text{-value} > 5\%$). Os testes estatísticos não confirmaram a relação entre as Condições Facilitadoras (CF) e Intenção de Uso (IU). De forma semelhante, outros estudos não encontraram efeito significativo da CF na intenção de usar tecnologia em um ambiente de auditoria (Curtis & Payne, 2014; Gonzalez et al., 2012; Nascimento, 2019).

Por outro lado, outros estudos identificaram as CF como um preditor significativo da aceitação da tecnologia por auditores. A evidência do estudo de Mahzan e Lymer (2014) sugere que é importante que os auditores saibam, antes de as organizações adotarem o GAS, que alguém na organização seria capaz de implementar e usar as ferramentas. Em sete dos dez casos, os auditores entrevistados tinham experiência anterior ou pelo menos um conhecimento prévio básico do uso do GAS. Outro fator de influência apontado pelos entrevistados é o treinamento direcionado, caso contrário eles não teriam adotado o GAS.

De acordo com Kim, Mannino e Nieschwietz (2009), o treinamento é mais influente na aceitação da tecnologia na AI porque os auditores consideram que o treinamento adicional seria benéfico para o seu trabalho e eles não usam tecnologias se a empresa não possuir uma equipe qualificada e familiarizada com o *software* ou uma equipe de TI. Os pesquisadores consideram como CF os fatores intraorganizacionais: suporte interno, treinamento interno e suporte gerencial; e os fatores extraorganizacionais incluem suporte externo e treinamento externo. As descobertas de Bierstaker, Janvrin e Lowe (2014) indicam que os auditores empregados pelas empresas Big 4 têm uma probabilidade significativamente maior do que os empregados por empresas menores de fornecer classificações mais altas para as CF, que por sua vez influenciam o uso de CAATs, considerando que as grandes empresas de auditoria têm mais recursos disponíveis para responder aos desenvolvimentos atuais e às necessidades dos clientes.

Segundo Alles (2015), as práticas de trabalho dos auditores internos são determinadas em um ambiente mais restrito quanto à disponibilidade de recursos, em comparação aos seus clientes de auditoria, que podem experimentar livremente o BDA para o propósito de obter lucros. BDA não deve ser percebido como uma mera tecnologia tradicional, considerando que outros métodos menos complexos foram adotados com hesitação ou mesmo ignorados pelos auditores. O autor também destaca que, para que tenha êxito na auditoria, o BDA deve seguir o exemplo da bem-sucedida aceitação do ERP, cujos sistemas foram implementados inicialmente para atender aos propósitos dos gerentes da organização, permitindo em seguida que os auditores aproveitassem o investimento já realizado.

Deste modo, a H₄ não foi suportada no presente estudo, que pode estar relacionado à não percepção das CF nas empresas em que esses profissionais atuam, que abrangem infraestrutura, suporte e treinamento internos e externos à organização.

H5: As Condições Facilitadoras afetam positivamente a Expectativa de Esforço dos auditores internos para a adoção da tecnologia de soluções tecnológicas de BDA.

A hipótese foi suportada ($p\text{-value} < 5\%$). As análises estatísticas indicam que há uma relação positiva e significativa entre as Condições Facilitadoras (CF) e a Expectativa de Esforço (EE). De forma semelhante, os resultados de Curtis e Payne (2014) e Nascimento (2019) indicaram que as CF estão positivamente associadas à EE. De acordo com pesquisas anteriores, treinamento adequado garante ao auditor uma maior probabilidade de usar a tecnologia corretamente, com menos esforço. Assim, à medida que o treinamento e a assistência técnica aumentam, as percepções de facilidade de uso também devem aumentar. É importante destacar que os resultados da análise das hipóteses não indicaram uma relação positiva e significativa entre os relacionamentos de EE e CF com IU, respectivamente, as hipóteses H₂ e H₄. Desse modo, considerando a hipótese H₅ em conjunto com as hipóteses H₂ e H₄, pode-se inferir que os auditores internos da amostra da pesquisa reconhecem que a disponibilidade de recursos (infraestrutura, suporte e treinamento) torna o uso de BDA mais fácil e claro; no entanto, eles não reconhecem que os recursos para auxiliá-los no aprendizado e uso de BDA estão disponíveis de forma relevante ao ponto de influenciá-los a adotarem essa tecnologia.

H6: O Gênero impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

H7: A Idade impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

H8: A Experiência impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

As hipóteses H₆, H₇ e H₈ não foram suportadas ($p\text{-value} > 5\%$). As variáveis moderadoras Gênero, Idade e Experiência não exerceram efeito significativo sobre a Intenção de Uso (IU) de acordo com os resultados da análise, que estão condizentes com pesquisas anteriores sobre a aceitação de AC por auditores internos (Nascimento, 2019), CAATTs por auditores internos (Al-Hiyari, Said, & Hattab, 2019), CAATs por auditores externos (Bierstaker et al., 2014) e GAS por auditores externos (Curtis & Payne, 2008).

6 CONSIDERAÇÕES FINAIS

A presente dissertação buscou investigar os efeitos dos quatro antecedentes que irão prever as intenções de adoção de soluções tecnológicas de BDA nas práticas de Auditoria Interna, captando a percepção de auditores internos que atuam em diversas empresas do setor privado brasileiro. É importante destacar que, mais do que uma pesquisa sobre a aceitação da tecnologia, este é um estudo sobre a origem, o desenvolvimento e a evolução da profissão de AI, sua relevância para as organizações e o importante papel que o BDA pode desempenhar no processo evolutivo de suas práticas.

O modelo teórico proposto pela pesquisa, seus conceitos, construtos e hipóteses foram elaborados a partir do modelo da Teoria Unificada da Aceitação e do Uso da Tecnologia (UTAUT) de Venkatesh, Morris, Davis e Davis (2003), de estudos posteriores que aplicaram a UTAUT e de outras pesquisas sobre a aceitação da tecnologia pelo usuário final, dentro e fora do campo da Auditoria.

A amostra de 305 respondentes atendeu aos critérios da análise de poder estatístico que calculou uma quantidade mínima de amostra de 267 casos considerando o poder estatístico de 95%, obtendo maior consistência do modelo. As respostas foram coletadas por meio do questionário on-line desenvolvido na plataforma Google Forms, que foi aplicado aos auditores internos cadastrados na rede social LinkedIn e aos profissionais associados do IIA Brasil, após a execução de pré-teste do instrumento de coleta de dados com profissionais do mercado e pós-graduandos de Mestrado e Doutorado. Na fase preparatória da pesquisa foram realizadas entrevistas com profissionais de AI e visitas às empresas que permitiram a criação de uma rede de relacionamentos, possibilitando maior interação com auditores internos e o alcance da quantidade de 305 respondentes da amostra, um número superior às amostras de diversos estudos anteriores sobre aceitação da tecnologia.

A análise descritiva revelou as características dos profissionais de AI da amostra da pesquisa. Os respondentes em sua maioria são homens (70,8%), na faixa etária entre 29 e 39 anos (53,77%) e média de idade de 36,5 anos, com experiência profissional na faixa de 5 a 9 anos (33,12%) e 78,36% não possuem certificação profissional. A maior parte dos auditores internos atua em organizações privadas de grande porte localizadas no estado de São Paulo (70,2%). Todos os respondentes possuem formação superior enquanto 28,85% não possuem pós-graduação. A maioria dos respondentes têm formação em Ciências Contábeis (graduação

40,66% e pós-graduação 36,72%) e Administração (graduação 37,05% e pós-graduação 31,15%) e 7 respondentes (2,30%) têm pós-graduação *stricto sensu*.

O sistema ERP foi apontado como a ferramenta de TI mais utilizada pelos auditores internos da amostra com frequência de utilização de 81,90%, seguido por ferramentas específicas de auditoria como CAATs (55,10%) e AC (54,20%). Com relação às tecnologias mais avançadas, geralmente associadas ao BDA, estas apresentaram frequências menores de utilização. Os resultados corroboram com Alles (2005), segundo o qual as forças competitivas tornaram os ERPs uma necessidade estratégica para os negócios, onipresente em todos os aspectos da organização, criando a necessidade de realizar auditorias em um ambiente computadorizado. Enquanto os auditores finalmente começaram a obter dados dos sistemas ERP e utilizá-los como ferramentas, a adoção de outras inovações como AC e mineração de texto ainda estão em andamento, considerando a natureza conservadora da profissão de AI indicada pela literatura acadêmica. O autor fez ainda uma analogia entre BDA e ERP, utilizando o ERP como referência para explicar a ampla adoção da tecnologia pela AI.

A análise descritiva também revelou que os dados não financeiros e dados financeiros tradicionais, em formato estruturado, são os principais tipos de dados analisados nas práticas de AI pelos respondentes da amostra, seguidos por tipos dados semi-estruturados de XML e por tipos de dados estruturados, com menor frequência. Com relação às práticas tradicionais de AI executadas com o auxílio da tecnologia, os testes de auditoria apresentaram a maior frequência (98,80%) enquanto que a circularização a menor frequência (51,50%).

Assim, o propósito desse segundo bloco do questionário foi o de revelar o quanto o cenário das práticas atuais de AI está próximo das práticas de BDA. Os resultados indicam a predominância da aplicação de tipos tradicionais de ferramentas tecnológicas e de análise de dados nas práticas de AI pelos auditores internos respondentes da pesquisa, enquanto que os tipos mais avançados apresentam menores frequências de utilização. Entretanto, é importante destacar que, conforme exposto na revisão da literatura, os aspectos de BDA envolvem a abordagem integrada de diferentes tipos de tecnologias, tipos de dados e técnicas de análise de dados de forma não tradicional. Sendo assim, o simples uso isolado de ferramentas de TI avançadas ou de dados não estruturados não pode ser considerado como uso de BDA.

Os resultados da análise do modelo de equações estruturais por meio do método de mínimos quadrados parciais (PLS) indicaram que a Expectativa de Desempenho (ED) e a Influência Social (IS) são preditores significativos das intenções dos auditores internos de

adotar soluções de BDA (IU) o que significa que os auditores internos estão mais dispostos a utilizar BDA quando percebem que os benefícios obtidos com o uso dessa ferramenta melhorariam sua eficiência no trabalho (ED) e que a intenção de usar BDA é afetada pela pressão social decorrente do chefe do departamento de AI ou de seus pares dentro das empresas (IS).

Por outro lado, os efeitos de Expectativa de Esforço (EE) e de Condições Facilitadoras (CF) individualmente não foram estatisticamente significativos para explicar a IU. Esses resultados podem ser explicados pelo fato de que BDA é um tema que ainda está no processo inicial de disseminação e prática entre pesquisadores e profissionais de AI (Gepp et al., 2018) e pela não percepção das CF (infraestrutura, suporte e treinamento internos e externos à organização) nas empresas em que os auditores internos atuam. No entanto, análises estatísticas também revelaram uma relação positiva e significativa entre os construtos CF e EE indicando que os auditores internos da amostra da pesquisa reconhecem que a disponibilidade de recursos (infraestrutura, suporte e treinamento) torna o uso de BDA mais fácil e claro; no entanto, eles não reconhecem que os recursos para auxiliá-los no aprendizado e uso de BDA estão disponíveis de forma relevante ao ponto de influenciá-los a adotarem essa tecnologia.

Por fim, as características individuais Gênero, Idade e Experiência, como variáveis moderadoras, não foram significativas quando inseridas no modelo e assim, as respectivas hipóteses não foram suportadas.

6.1 Contribuições Práticas

Dada a natureza conservadora da profissão de AI, identificar os fatores que influenciam a adoção de novas tecnologias por auditores internos ajuda pesquisadores e profissionais a projetarem treinamento, marketing e suporte de infraestrutura para incentivar a aceitação dessas ferramentas de TI (Bierstaker et al., 2014). As contribuições do presente estudo incluem recomendações de ordem prática para os seguintes públicos: a) profissionais do mercado, b) o IIA Brasil, c) organizações; e (d) cursos superiores de Contabilidade e Administração.

O conhecimento produzido pela literatura acadêmica sobre AI e BDA foi disseminado entre os respondentes da amostra, por meio do LinkedIn, e entre os profissionais entrevistados na fase de preparação da pesquisa. O Apêndice 3 (Feedback) apresenta os relatos de 40 dos 321 respondentes da amostra indicando o impacto positivo da pesquisa, considerando também que

196 respondentes informaram os seus endereços de e-mail demonstrando o interesse em receber os resultados da presente pesquisa.

A principal recomendação consiste no incentivo aos auditores internos a lerem os artigos de tecnologia mais recentes, obterem certificações profissionais e participarem de conferências e seminários, para que possam ter uma visão independente e objetiva da implantação de novas tecnologias em suas organizações (Wright, 2016). A análise descritiva apontou que a maioria dos respondentes (87,2%) participam ou tem interesse em participar de eventos relacionados a inovações tecnológicas em AI, como os seminários e congressos organizados pelo IIA Brasil. No entanto, considerando que 78,36% dos respondentes não possui certificações, o investimento em certificações pode ser um ponto importante a ser considerado pelos auditores internos para a sua capacitação em tecnologias de BDA.

Dentre as formas pelas quais os auditores internos adquirem conhecimentos e habilidades em TI, a que mais se destacou foi a formação fornecida pelas empresas em que estes profissionais atuam (47,87%) seguida por cursos de formação externos (16,72%). De acordo com Kim, Mannino e Nieschwietz (2009) o treinamento é mais influente na aceitação da tecnologia na AI, porque os auditores consideram que o treinamento adicional é benéfico para o seu trabalho e eles não usam tecnologias se a empresa não possuir uma equipe qualificada e familiarizada com o *software* ou uma equipe de TI. O desenvolvimento de programas de treinamento é importante para aumentar as expectativas dos auditores em relação a quão bem as tecnologias podem melhorar seu desempenho (ED) (Bierstaker et al., 2014) assim como a sua percepção de facilidade de uso (EE) (Bedard et al., 2003). O grau em que os auditores temem possíveis problemas de implementação depende da qualidade do treinamento recebido pelos auditores e da assistência esperada de TI (Curtis & Payne, 2014).

A constatação de que 4,59% dos respondentes possuem a Certified Internal Auditor (CIA), a principal certificação dos auditores internos, assim como a distribuição geográfica e as ferramentas de TI mais utilizadas pelos respondentes, podem auxiliar o IIA Brasil no planejamento de eventos, congressos e treinamentos sobre BDA para alcance de um maior número de profissionais.

A contribuição prática para as organizações consiste no incentivo para investimentos em infra-estrutura, suporte técnico e programas de treinamento de BDA (CF) e na proposta do modelo conceitual de estágios de expansão de BDA (Figura 9) que pode auxiliar a empresa no planejamento de projetos para implantar BDA de forma gradual e contínua tanto nas operações

de negócio como também nas práticas de AI. Uma medida sugerida para as organizações é a manutenção de uma equipe de suporte técnico para apoiar a IAF, composta por indivíduos altamente proficientes em tecnologias segundo o estudo de Tang, Norman e Vendrzyk (2017).

No que diz respeito às contribuições para a área de ensino, o estudo pode fornecer aos estudantes de graduação o conhecimento sobre os principais aspectos da profissão de AI e das tecnologias de BDA, bem como sugerir aos programas de curso de nível superior, principalmente Ciências Contábeis e Administração, a abordagem de disciplinas relacionadas às práticas de AI, de ciência de dados e de BDA.

6.2 Contribuições Teóricas

A principal contribuição teórica desta pesquisa está relacionada à aplicação de um modelo teórico para estudar a intenção de uso de BDA, elaborado com base no modelo original da UTAUT (Venkatesh et al., 2003), cooperando com pesquisas sobre a aceitação de tecnologias no campo da Auditoria, em específico a Auditoria Interna.

A principal modificação em relação ao modelo original UTAUT corresponde à ausência do construto de Comportamento de Uso (CO). Desse modo, o construto Condições Facilitadoras (CF) passou a ser um preditor da Intenção de Uso (IU), juntamente com a Expectativa de Desempenho (ED), a Expectativa de Esforço (EE) e a Influência Social (IS). Os resultados dos testes estatísticos não confirmaram a relação entre a Condições Facilitadoras (CF) e Intenção de Uso (IU), assim como em estudos anteriores com o foco em IU (Gonzalez et al., 2012; Curtis & Payne, 2014; Nganga, 2015; Nascimento, 2019). Tais resultados parecem confirmar o pressuposto do modelo original UTAUT de que as CF tornam-se não-significativas na previsão da IU quando ambos os construtos de ED e de EE estão presentes (Venkatesh et al., 2003).

Outra modificação apresentada pelo modelo foi a inclusão do relacionamento entre CF e EE conforme exposto na seção 3.4 (Condições Facilitadoras). Embora esse relacionamento não exista no modelo original da UTAUT (Venkatesh et al., 2003), Venkatesh (2000) encontrou suporte para a mediação completa do efeito de CF sobre a IU pela EE. Os resultados indicaram que a relação é positiva e significativa, de forma semelhante aos estudos de Curtis e Payne (2014) e Nascimento (2019). Entretanto, a relação CF e EE ainda é pouco explorada por estudos que aplicaram versões adaptadas do modelo original da UTAUT.

O modelo do presente estudo buscou verificar se as variáveis Gênero, Idade, Experiência e Voluntariedade exercem efeito moderador em todas as relações entre os quatro construtos (ED, EE, IS, CF) e a variável dependente Intenção de Uso (IU), enquanto que o modelo original da UTAUT prevê que as variáveis moderadoras são significantes em relacionamentos específicos. Contudo, assim como em outros estudos (Curtis & Payne, 2008; Bierstaker et al., 2014; Al-Hiyari, Said & Hattab, 2019; Nascimento, 2019), nenhuma das variáveis moderadoras exerceu efeito significativo sobre a Intenção de Uso (IU) de acordo com os resultados da análise.

6.3 Limitações

Entre as limitações do presente estudo, pode ser considerado um possível viés da percepção dos auditores internos, com relação à subjetividade e às características pessoais de cada respondente. Devido à natureza não probabilística da amostra, composta por respostas coletadas de forma espontânea e por conveniência, e o *survey* ser um tipo de estudo transversal, os resultados não podem ser generalizados a todos os profissionais de AI no setor privado brasileiro, mas somente para os respondentes da pesquisa. Assim como as pesquisas anteriores sobre aceitação de uso de tecnologias pela AI, o presente estudo examinou o contexto voluntário de adoção de TI e, por este motivo, os respectivos resultados não podem ser generalizados para configurações de uso mandatório (Venkatesh et al., 2003). Além disso, o foco do estudo é examinar a intenção de uso de BDA e, por este motivo, os resultados não podem ser generalizados para o comportamento de uso real de BDA.

6.4 Pesquisas Futuras

Pesquisas futuras podem ser direcionadas para examinar o uso real e a pós-adoção de soluções de BDA pela AI, com a possibilidade de avaliar os aspectos de utilização da tecnologia em diferentes setores do mercado por meio de estudos de casos múltiplos. A Internet das Coisas (IoT), a estratégia digital e as mudanças disruptivas resultantes de BDA são inevitáveis e os auditores internos precisam aprender novas habilidades para lidar com os riscos que essas mudanças trarão para suas organizações nos próximos anos (Tang et al., 2017). Desse modo, é importante produzir e avançar com o conhecimento sobre o tema da evolução de TI e seus impactos nas práticas de AI.

REFERÊNCIAS

- Adams, M. (1994). Agency Theory and the Internal Audit. *Managerial Auditing Journal*, 8-12. DOI: 10.1108/02686909410071133.
- Agrawal, D., Bernstein, P., & Bertino, E. (2011). Challenges and opportunities with big data 2011-1. In: Proceedings of the VLDB Endowment. 1–16. <http://dl.acm.org/citation.cfm?id=2367572%5Cnhttp://docs.lib.purdue.edu/cctech/1/>.
- Ahmi, A. (2012). *Adoption of generalised audit software (GAS) by external auditors in the UK* (Doctoral dissertation, Brunel University, School of Information Systems, Computing and Mathematics). Association, 1458-1460.
- Al-Hiyari, A., Said, N.A., & Hattab, E. (2019). Factors That Influence the Use of Computer Assisted Audit Techniques (CAATs) By Internal Auditors in Jordan.
- Almeida, M. C. (2012). Auditoria: um curso moderno e completo (8a ed). São Paulo, SP: Atlas.
- American Institute of Certified Public Accountants. (AICPA). (1979). Computer-Assisted Audit Techniques: Prepared by the computer services executive committee. American Institute of Certified Public Accountants, Inc.
- American Institute of Certified Public Accountants. (AICPA). (2015). Audit Analytics And Continuous Audit: Looking Toward the Future. American Institute of Certified Public Accountants, Inc.
- Alles, M. (2015). Drivers of the Use and Facilitators and Obstacles of the Evolution of Big Data by the Audit Profession. *Accounting Horizons*, 439-449. DOI: 10.2308/acch-51067
- Alles, M., Gray G. L. (2016). Incorporating big data in audits: Identifying inhibitors and a research agenda to address those inhibitors. *International Journal of Accounting Information Systems*. DOI: 10.1016/j.accinf.2016.07.004
- Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big data and analytics in the modern audit engagement: Research needs. *Auditing: A Journal of Practice & Theory*, 1–27. DOI: 10.2308/ajpt-51684.
- Attie, W. (2011). Auditoria: conceitos e aplicações (6a ed.). São Paulo, SP: Atlas.
- Aydiner, A. S., Tatoglu, E., Bayraktar, E., Zaim, S., & Delen, D. (2019). Business analytics and firm performance: The mediating role of business process performance. *Journal of Business Research*, 96 (October 2018), 228–237. <https://doi.org/10.1016/j.jbusres.2018.11.028>
- Banker, P. H., Chang, R. D. H., & Kao, Y. (2002). Impact of information technology on public accounting firm productivity, *Journal of Information Systems*, 16(2), 209-222. DOI: 10.2308/jis.2002.16.2.209

- Baesens, B., Bapna, R., Marsden, J.R., Vanthienen, J., & Zhao, J.L. (2014). Transformational issues of big data and analytics in networked business. *MIS Quart.* 38 (2), 629–632. DOI: 10.25300/MISQ/2016/40:4.03.
- Bagozzi, Richard. (2007). The Legacy of the Technology Acceptance Model and a Proposal for a Paradigm Shift. *Journal of the Association for Information Systems*. DOI: 10.17705/1jais.00122.
- Bedard, J., Jackson, C., Ettredge, M. L., & Johnstone, K. M. (2003). The effect of training on auditors' acceptance of an electronic work system. *International Journal of Accounting Information Systems*, 4, 227–250. DOI: 10.1016/j.accinf.2003.05.001
- Bierstaker, J., Burnaby, P., & Thibodeau, J. (2001). The impact of information technology on the audit process: An assessment of the state of the art and implications for the future. *Managerial Auditing Journal*, 159-164. DOI: 10.1108/02686900110385489.
- Bierstaker, J., Janvrin, D., & Lowe, D.J. (2014). What factors influence auditors' use of computer-assisted audit techniques? *Advances in Accounting* 30: 67–74. DOI: 10.1016/j.adia.2013.12.005
- Bihani, P., & Patil, S.T. (2014). A Comparative Study of Data Analysis Techniques. *International Journal of Emerging Trends & Technology in Computer Science*. Recuperado de <https://ijettcs.org/Volume3Issue2/IJETTCS-2014-04-09-077.pdf>.
- Boynton, W. C., Johnson, R. N., & Kell, W. G. (2002). Auditoria (J. E. dos Santos, Trad.). São Paulo, SP: Editora Atlas.
- Braun, R., & Davis, H. (2003). Computer-assisted audit tools and techniques: Analysis and perspectives. *Managerial Auditing Journal*, 725-731. DOI: 10.1108/02686900310500488.
- Brown, C. E., Wong, H. J., & Baldwin, A. A. (2007). A review and analysis of the existing research streams in continuous auditing. *Journal of Emerging Technologies in Accounting*. DOI: 10.2308/jeta.2007.4.1.1
- Brown-Liburd, H., Issa, H., & Lombardi, D. R. (2015). Behavioral implications of big data's impact on audit judgment and decision making and future research directions. *Accounting Horizons*, 451-468.
- Brown-Liburd, H., & Vasarhelyi, M. (2015). Big Data and Audit Evidence. *Journal of Emerging Technologies in Accounting*. 12. 1-16. 10.2308/jeta-10468.
- Carcello J. V., Hermanson D. R., & Raghunandan K. (2005). Factors associated with U.S. public companies' investment in internal audit. *Accounting Horizons*, 69-84. DOI: 10.2308/acch.2005.19.2.69.
- Carey, P., Tanewski G., & Simnett R. (2000). Voluntary demand for internal and external auditing by family businesses. *Auditing: A Journal of Practice and Theory* 19, 37–51. DOI: 10.2308/aud.2000.19.supplement.37
- Carey, P., Subramaniam, N., & Ching, K. (2006). Outsourcing Internal Audit in Australia. *Accounting and Finance*, 11-30. DOI: 10.1111/j.1467-629X.2006.00159.

- Carrington T., & Catasu B. (2007). Auditing stories about discomfort: becoming comfortable with comfort theory. *European Accounting Review*. DOI: 10.1080/09638180701265846.
- Castanheira, N. (2007). *Auditoria interna baseada no risco*. (Dissertação de Mestrado em Contabilidade e Auditoria). Escola de Economia e Gestão, Universidade do Minho, Portugal.
- Chan, D.Y., Chiu, V., Vasarhelyi, M.A., Byrnes, P.E., Al-Awadhi, A.M., Gullvist, B., Brown-Liburd, H.L., & Teeter, R.A. (2018). Continuous Auditing: Theory And Application.
- Chan, D. Y., & Vasarhelyi, M. A. (2011). Innovation and practice of continuous auditing. *International Journal of Accounting Information Systems*, 12(2), 152-160. DOI: 10.1016/j.accinf.2011.01.001
- Chen, C. & Zhang, C. (2014). Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*, 314-347. DOI: 10.1016/j.ins.2014.01.015.
- Chen, H., Chiang, R. H. L., & Storey, V. C. (2012). Business intelligence and analytics: From big data to big impact. *Management Information Systems Quarterly*, 36(4), 1165-1188.
- Chen, M., Mao, S., & Liu, Y. (2014). Big data: A survey. *Mobile Networks and Applications*. DOI: 19. 10.1007/s11036-013-0489-0.
- Chen, X., & Lin, X. (2014). Big Data Deep Learning: Challenges and Perspectives. *IEEE*. 2. 514-525. DOI: 10.1109/ACCESS.2014.2325029.
- Chiu, V., Chan, D., & Vasarhelyi, M. (2018). Continuous Auditing (Rutgers Studies in Accounting Analytics). *Emerald Publishing Limited*, 1-6. DOI: 10.1108/978-1-78743-413-420181001
- Church, B., Mcmillan, J., & Schneider, A. (2001). Factors Affecting Internal Auditors' Consideration of Fraudulent Financial Reporting during Analytical Procedures. *Auditing-a Journal of Practice & Theory*, 65-80. DOI: 10.2308/aud.2001.20.1.65.
- Cintra, Y. C. (2011). *A integração da sustentabilidade às práticas de controle gerencial das empresas no Brasil*. (Tese de Doutorado). Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.
- Coderre, D. (2005). Continuous Auditing: Implications for Assurance, Monitoring, and Risk Assessment. *The Institute of Internal Auditors Research Foundation*, Altamonte Springs, FL.
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2nd ed.). New York: Psychology Press.
- Committee of Sponsoring Organizations of the Treadway Commission. (COSO). (2013). *Controle Interno - Estrutura Integrada: Sumário Executivo*. Recuperado de <http://iibrasil.org.br/korbilload/upl/editorHTML/uploadDireto/cosoicif2013sum-editorHTML-00000001-05022018093939.pdf>.

- Committee of Sponsoring Organizations of the Treadway Commission. (COSO). (2017). Gerenciamento de Riscos Corporativos Integrado com Estratégia e Performance: Sumário Executivo. Recuperado de <http://iiabrazil.org.br/korbillload/upl/editorHTML/uploadDireto/sumariocosoerm-editorHTML-00000001-19022018164126.pdf>.
- Connolly, S. (2012). 7 key drivers for the Big Data market. Blog Posting May 15th. <http://connollyshaun.blogspot.com/>.
- Conselho Federal de Contabilidade. (CFC). (2003). Resolução nº 986/2003. Aprova a NBC TI 01 (NBC T 12) - Da Auditoria Interna. Disponível em: http://portalcfc.org.br/wordpress/wp-content/uploads/2013/01/Auditoria_Interna.pdf
- Coram, P., Ferguson, C., & Moroney, R. (2008). Internal Audit, Alternative Audit Structure and the Level of Misappropriation of Asset Fraud. *Accounting and Finance*, 543-559. DOI: 10.1111/j.1467-629X.2007.00247.x
- Cordeiro, C. M. R. (2013). Auditoria interna e operacional: Fundamentos, Conceitos e Aplicações práticas. São Paulo, SP: Atlas.
- Courtemanche, G. (1991). How has internal auditing evolved since 1941?, *Internal Auditor*, retrieved online at http://findarticles.com/p/articles/mi_m4153/is_n3_v48/ai_10819160.
- Covaleski M. A., Dirsmith M. W., & Rittenberg L. (2003). Jurisdictional disputes over professional work: the institutionalization of the global knowledge expert. *Accounting Organizations and Society*. DOI: 10.1016/S0361-3682(02)00029-6
- Crepaldi, S. A. (2012). Auditoria Contábil: Teoria E Prática (8a ed.). São Paulo, SP: Atlas.
- Cruz, B. R. (2009). *A prática da Controladoria nos maiores bancos que operam no Brasil à luz de uma estrutura conceitual básica de Controladoria*. (Dissertação de Mestrado). Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.
- Curtis, M., & Payne, E. (2008). An Examination of Contextual Factors and Individual Characteristics Affecting Technology Implementation Decisions in Auditing. *International Journal of Accounting Information Systems*, 104–121. DOI: 10.1016/j.accinf.2007.10.002.
- Curtis, M., & Payne, E. (2014). Modeling voluntary CAAT utilization decisions in auditing. *Managerial Auditing Journal*. 29. DOI: 10.1108/MAJ-07-2013-0903.
- Davenport, T.H., Barth, P., & Bean, R. (2012). How "big data" is different. MIT Sloan Management Review, Fall edition.
- Davenport, T. H., & Kim, J. (2013). Keeping up with the quants: Your guide to understanding and using analytics. Boston, MA: Harvard Business School Publishing Corporation.
- Davies M. (2001). The Changing Face of Internal Audit in Local Government. *Journal of Finance and Management in Public Service*.

- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science*. DOI: 10.1287/mnsc.35.8.982.
- De Mauro, A., Greco, M., & Grimaldi, M. (2016). A formal definition of Big Data based on its essential features. *Library Review*, 122-135. DOI: 10.1108/LR-06-2015-0061.
- Debreceeny, R., & Gray, G. (2011). Data Mining of Electronic Mail and Auditing: A Research Agenda. *Journal of Information Systems*, 195-226. DOI: 10.2308/isys-10167.
- Debreceeny, R., Lee, S., Neo, W., & Toh, J. (2005). Employing generalized audit software in the financial services sector: Challenges and opportunities. *Managerial Auditing Journal*, 605-618. DOI: 10.1108/02686900510606092.
- DeLone, W.H., & McLean, E.R. (2003), The DeLone and McLean model of information systems success: A ten-year update. *Journal of Management Information Systems*, 19(4), 9-30.
- Dwivedi, Y.K., Rana, N.P., Chen, H., & Williams, M.D. (2011), A metaanalysis of the unified theory of acceptance and use of technology (UTAUT). In: Nüttgens, M., Gadatsch, A., Kautz, K., Schirmer, I., Blinn, N., editors. *Governance and Sustainability in Information Systems. Managing the Transfer and Diffusion of IT*. Berlin, Heidelberg: Springer; p155-170.
- Earley, C. E. (2015). Data analytics in auditing: Opportunities and challenges. *Business Horizons*. DOI: 10.1016/j.bushor.2015.05.002
- Elgendy, N., & Elragal, A. (2014). Big Data Analytics: A Literature Review Paper. *Lecture Notes in Computer Science*, 214-227. DOI: 10.1007/978-3-319-08976-8_16.
- Ernst & Young. (EY). (2015). How big data and analytics can transform the audit. *Ernst & Young Global Limited*.
- Fan, J., Han, F., & Liu, H. (2014). Challenges of big data analysis. *Nat. Sci. Rev.* 1 (2), 293–314. DOI: 10.1093/nsr/nwt032.
- Fay, R., & Negangard, E. (2017). Manual journal entry testing: Data analytics and the risk of fraud. *Journal of Accounting Education*. DOI: 10.1016/j.jaccedu.2016.12.004.
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 39-50. DOI: 10.2307/3151312
- Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137–14. DOI: 10.1016/j.ijinfomgt.2014.10.007
- Gantz J., & Reinsel D. (2011). Extracting value from chaos. IDC iView, pp 1–12.
- Gepp A., Linnenluecke M.K., O'Neill T.J., & Smith T. (2018) Big data techniques in auditing research and practice: current trends and future opportunities. *J Account Lit* 40:102–115

- Gil, A. L. (2000). Auditoria operacional e de gestão: qualidade da auditoria (5a ed.). São Paulo, SP: Atlas.
- Glover, S., Prawitt, D., & Wood, D. (2007). Internal Audit Sourcing Arrangement and the External Auditor's Reliance Decision. *Contemporary Accounting Research*. DOI: 10.2139/ssrn.898800.
- Gonzalez, G., Sharma, P., & Galletta, D. (2012). The antecedents of the use of continuous auditing in the internal auditing context. *International Journal of Accounting Information Systems*, 248–262. DOI: 10.1016/j.accinf.2012.06.009
- Gobble, M.M. (2013). Big data: the next big thing in innovation. *Research Technology Management*. DOI: 10.5437/08956308X5601005.
- Gramling A. A., Maletta M., Schneider A., & Church B. (2004). The role of the internal audit function in corporate governance: a synthesis of the extant internal auditing literature and directions for future research. *Journal of Accounting Literature*.
- Green, W. & Trotman, K. (2003). An Examination of Different Performance Outcomes in an Analytical Procedures Task. Auditing-a *Journal of Practice & Theory*, 219-235. DOI: 10.2308/aud.2003.22.2.219.
- Groomer, S. & Murthy, Uday. (2018). Continuous Auditing of Database Applications: An Embedded Audit Module Approach: Theory and Application. DOI: 10.1108/978-1-78743-413-420181005.
- Günther, W. A., Rezazade Mehrizi, M. H., Huysman, M., & Feldberg, F. (2017). Debating big data: A literature review on realizing value from big data. *Journal of Strategic Information Systems*, 26(3), 191-209. DOI: 10.1016/j.jsis.2017.07.003
- Hallak, R., & Silva, A. (2012). Determinantes das despesas com serviços de auditoria e consultoria prestados pelo auditor independente no Brasil. *Revista Contabilidade & Finanças*, 223-231. DOI: 10.1590/S1519-70772012000300007.
- Hair, J. F., J., Ringle, C. M., & Sarstedt, M. (2014). Partial least squares structural equation modeling: Rigorous applications, better results and higher acceptance. Long Range Planning - Prentice-Hall.
- Hashem, I., Yaqoob, I., Anuar, N., Mokhtar, S., Gani, A., & Khan, S. (2014). The rise of “Big Data” on cloud computing: Review and open research issues. *Information Systems*, 98-115. DOI: 10.1016/j.is.2014.07.006.
- Hass, S., Abdolmohammadi, M. J. & Burnaby, P. (2006). The Americas literature review on internal auditing. *Managerial Auditing Journal*, 835–44. DOI: 10.1108/02686900610703778.
- Hendriksen, E. S., & Van Breda, M. F. (2009). Teoria da Contabilidade (5a ed.). São Paulo, SP: Atlas.
- Holton, C. (2009). Identifying disgruntled employee systems fraud risk through text mining: A simple solution for a multi-billion dollar problem. *Decision Support Systems*, 853-864. DOI: 10.1016/j.dss.2008.11.013.

- Hu, H., Wen, Y., Chua, T., & Li, X. (2014). Toward Scalable Systems for Big Data Analytics: A Technology Tutorial. *Access, IEEE*, 652-687. DOI: 10.1109/ACCESS.2014.2332453.
- Iguma, M.K., Riccio, E.L. (2018). The use of Information Technology tools in auditing: a Bibliometric Analysis – São Paulo: 15CONTECSI. DOI: 10.5748/9788599693148-15CONTECSI/PS-5734
- Imoniana, J. O. (2016). Auditoria de Sistemas de Informação (3a ed.). São Paulo, SP: Atlas.
- Imoniana, J. O. (2019). Auditoria: Planejamento, Execução e Reporte. São Paulo, SP: Atlas.
- Institute of Internal Auditors. IIA. (2003). Declaração de Posicionamento do IIA: As Três Linhas de Defesa no Gerenciamento Eficaz de Riscos e Controles.
- Institute of Internal Auditors Research Foundation. (IIARF). (2016). Data Analytics: Elevating Internal Audit's Value. The Institute of Internal Auditors Research Foundation.
- Instituto Brasileiro de Governança Corporativa (IBGC), & Instituto dos Auditores Internos do Brasil (IIA Brasil) (2018). Auditoria Interna: Aspectos essenciais para o Conselho de Administração. IBGC Orienta. Recuperado de <https://conhecimento.ibgc.org.br/Paginas/Publicacao.aspx?PubId=23980>.
- Instrução n. 586 da Comissão de Valores Mobiliários (CVM) de 8 de junho de 2017. (2017). Altera e acrescenta dispositivos à Instrução CVM nº 480, de 7 de dezembro de 2009. Recuperado de <http://www.cvm.gov.br/legislacao/instrucoes/inst586.html>.
- Jans, M., Alles, M., & Vasarhelyi, M.A. (2010). Process mining of event logs in auditing: opportunities and challenges. Working paper. Hasselt University. Belgium. DOI: 10.2139/ssrn.1578912.
- Janvrin, Diane & Bierstaker, James & Lowe, D. (2009). An Investigation of Factors Influencing the Use of Computer-Related Audit Procedures. *Journal of Information Systems*. DOI: 10.2308/jis.2009.23.1.97.
- Junior, J. H. P., Fernandes, A. M., Ranha, A., & Carvalho, J. C. O. (2011). Auditoria das demonstrações contábeis (2a ed.). Rio de Janeiro, RJ: FGV.
- Kim, H., Mannino, M., & Nieschwietz, R. (2009). Information technology acceptance in the internal audit profession: Impact of technology features and complexity. *International Journal of Accounting Information Systems*, 214-228. DOI: 10.1016/j.accinf.2009.09.001.
- Körnert, Jan. (2003). The Barings crises of 1890 and 1995: Causes, courses, consequences and the danger of domino effects. *Journal of International Financial Markets, Institutions and Money*, 187-209. DOI: 10.1016/S1042-4431(02)00044-6.
- Koskivaara, E. (2004). Artificial Neural Networks in Analytical Review Procedures. *Managerial Auditing Journal*. DOI: 10.1108/02686900410517821.
- KPMG. (2018). Automação inteligente e Auditoria Interna: Considerações para a avaliação e a implementação da automação inteligente. KPMG Assessores Ltda.

- Krahel, J. P., & Titera, W. (2015). Consequences of Big Data and Formalization on Accounting and Auditing Standards. *Accounting Horizons*. DOI: 10.2308/acch-51065.
- Kuenkaikaew, S. (2013). Predictive Audit Analytics: Evolving to a New Era. PhD Dissertation, Rutgers Business School.
- Leitch, R., & Chen, Y. (2003). The Effectiveness of Expectation Models in Recognizing Error Patterns and Generating and Eliminating Hypotheses While Conducting Analytical Procedures. *Auditing-a Journal of Practice & Theory*, 147-170. DOI: 10.2308/aud.2003.22.2.147.
- Li, H., Dai, J., Gershberg, T., & Vasarhelyi, M. (2018). Understanding usage and value of audit analytics for internal auditors: An organizational approach. *International Journal of Accounting Information Systems*, 59-76. DOI: 10.1016/j.accinf.2017.12.005.
- Lin, S., Pizzini, M., Vargus, M., & Bardhan, I.R. (2011). The role of the internal audit function in the disclosure of material weaknesses. *The Accounting Review*, 287-323. DOI: 10.2139/ssrn.1592593
- Liu, Q. (2014). *The application of exploratory data analysis in auditing*. Doctoral dissertation, Rutgers University Graduate School, Newark, NJ.
- Lombardi, D., Bloch, R., & Vasarhelyi, M. (2014). The Future of Audit. *Journal of Information Systems and Technology Management*. DOI: 10.1590/S1807-17752014000100002.
- Loraas, T., & Wolfe, C. J. (2006). Why wait? Modeling factors that influence that decision of when to learn a new use of technology. *Journal of Information Systems*, 20, Fall: 1–23.
- Madani, H. (2009). The role of internal auditors in ERP-based organizations. *Journal of Accounting & Organizational Change*, 514-526. DOI: 10.1108/18325910910994702.
- Mahzan, N., & Lymer, A. (2008). Adoption of computer assisted audit tools and techniques (CAATs) by internal auditors: current issues in the UK. In paper presented at BAA Annual Conference 2008 in Blackpool, UK, British Accounting Association, April.
- Mahzan, N., & Lymer, A. (2014). Examining the adoption of computer assisted audit tools and techniques: Cases of generalized audit software use by internal auditors. *Managerial Auditing Journal*. DOI: 10.1108/MAJ-05-2013-0877.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A.H. (2011). Big Data: the Next Frontier for Innovation, Competition and Productivity. McKinsey Global Institute.
- Mardiana, S., Tjakraatmadja, J. H., & Aprianingsih, A. (2015). DeLone–McLean Information System Success Model Revisited: The Separation of Intention to Use - Use and the Integration of Technology Acceptance Models. *International Journal of Economics and Financial Issues*, 5, 172-182.
- Markus, M., & H., Topi. (2015). Big Data, Big Decisions for Science, Society, and Business. Presented at Workshop on the Social, Economic and Workforce Implications of Big Data Analytics and Decision Making, Bentley University, Boston, MA.

- Marjani, M., Nasaruddin, F., Gani, A., Karim, A., Abaker T. H., I., Siddiqa, A., & Yaqoob, I. (2017). Big IoT Data Analytics: Architecture, Opportunities, and Open Research Challenges. *IEEE Access*. DOI: 10.1109/access.2017.2689040.
- Martens, D., Bruynseels, L., Baesens, B., Willekens, Ma., & Vanthienen, J. (2008). Predicting going concern opinion with data mining. *Decision Support Systems*, 765-777. DOI: 10.1016/j.dss.2008.01.003.
- Martins, E. (2009). *Contabilidade de custos* (9a ed.). São Paulo, SP: Atlas.
- Martins, G. de A., & Theóphilo, C. R. (2009). *Metodologia da investigação científica para ciências sociais aplicadas*. São Paulo: Atlas.
- Mautz, R.K., & Sharaf, H.A. (1964). *The Philosophy of Auditing*, American Accounting Association, Sarasota, FL.
- Mayer-Schonberger, V. & Cukier, K. (2013). *Big Data: Como Extrair Volume, Variedade, Velocidade e Valor da Avalanche de Informação Cotidiana* (P. P. Junior, Trad.). Rio de Janeiro, RJ: Elsevier.
- McAfee, A., & Brynjolfsson, E. (2012). Big data: The management revolution. *Harvard Business Review*, 60–68.
- McNamee D., & McNamee T. (1995). The transformation of internal auditing. *Managerial Auditing Journal*. DOI: 10.1108/02686909510079639
- Migliavacca, P. N. (2002). *Controles Internos nas Organizações*. São Paulo, SP: Edicta.
- Mihret, D. (2014). How can we explain internal auditing? The inadequacy of agency theory and a labor process alternative. *Critical Perspectives on Accounting*, 771–782. DOI: 10.1016/j.cpa.2014.01.003.
- Mikalef, P., Krogstie, J., Pappas, I. O., & Pavlou, P. (2019). Exploring the relationship between big data analytics capability and competitive performance: The mediating roles of dynamic and operational capabilities. *Information and Management*, (February 2018), 103169. <https://doi.org/10.1016/j.im.2019.05.004>
- Miranda, W. F. (2018). *Antecedentes da aceitação e adoção da Auditoria Contínua no setor público brasileiro: O caso do Tribunal de Contas do Estado de São Paulo*. (Tese de Doutorado). Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.
- Moffitt, K., & Vasarhelyi, M. (2013). AIS in an age of Big Data. *J. Inf. Syst.*, 1–19. DOI: 10.2308/isys-10372
- Moniruzzaman, A. B. M. & Hossain, S. (2013). NoSQL Database: New Era of Databases for Big data Analytics - Classification, Characteristics and Comparison. *Int J Database Theor Appl.* 6.
- Moorthy, M., Seetharaman, A., Mohamed, Z., Gopalan, M., & San, L. (2011). The Impact of Information Technology on Internal Auditing. *South African Journal of Business Management*, 3523-3539. DOI: 10.5897/AJBM10.1047.

- Morgan, G. (1979). Internal Audit Role Conflict: A Pluralist View. *Managerial Finance*, 160-170. DOI: 10.1108/eb013444
- Moscove, S. A., Simkim, M. G., & Bagranoff, N. A. (2002). *Sistemas de informações contábeis*. São Paulo: Atlas, 2002.
- Murdoch, T., & Detsky, A. (2013). The Inevitable Application of Big Data to Health Care. *JAMA: the journal of the American Medical Association*, 1351-2. DOI: 10.1001/jama.2013.393.
- Nascimento, A. M. V. (2019). *Antecedentes de aceitação e adoção da auditoria contínua pelos auditores internos*. (Dissertação de Mestrado). Programa de Mestrado em Ciências Contábeis e Atuariais, Pontifícia Universidade Católica de São Paulo, São Paulo.
- Nganga, C. S. N. (2015). *Aceitação do Uso de Recursos Tecnológicos pelos Docentes de Pós-Graduação em Contabilidade*. (Dissertação de Mestrado). Faculdade de Ciências Contábeis da Universidade de Uberlândia, Minas Gerais.
- Organisation for Economic Co-Operation and Development (OECD). (2004). Principles of corporate governance. Recuperado de <https://www.oecd.org/corporate/ca/corporategovernanceprinciples/31557724.pdf>.
- Payne, E. A., & Curtis, M.B. (2010). Can the unified theory of acceptance and use of technology help us understand the adoption of computer-aided audit techniques by auditors? Working paper: University of Louisville and University of North Texas.
- Pedrosa, I. M. M. (2015). *Computer-assisted audit tools and techniques use: determinants for individual acceptance*. Lisboa: ISCTE-IUL, 2015. Tese de doutoramento.
- Pereira, A. C., & Nascimento, W. S. (2005). Um estudo sobre a atuação da Auditoria Interna na detecção de fraudes nas empresas do setor privado no Estado de São Paulo. *Revista Brasileira de Gestão de Negócios*, 7(19), 46-56.
- Pickett, K. H. S. (2011). *The Essential Guide to Internal Auditing* (2nd ed.), John Wiley & Sons Ltd, Chichester.
- PriceWaterhouseCoopers. PwC. (2015). *Estudo sobre a Prática Profissional de Auditoria Interna: como encontrar o Norte Verdadeiro em um período de rápidas transformações* – São Paulo: PricewaterhouseCoopers LLC.
- Ratliff, R. L., Wallace, W. A., Loebbecke, J. K., & McFarland, W. G. (1988). *Internal auditing: principles and techniques*. USA: The Institute of Internal Auditors, Inc.
- Ramamoorti, S. (2003). Internal auditing: history, evolution, and prospects. In Bailey, A. D., Gramling, A. A., & Ramamoorti, S. *Research opportunities in internal auditing*. (pp. 1-23). Altamonte Springs: The Institute of Internal Auditors Research Foundation.
- Rezaee, Z., Sharbatoghlie, A., Elam, R., & McMickle, P. (2002). Continuous Auditing: Building Automated Auditing Capability. *Auditing-a Journal of Practice & Theory*, 147-163. DOI: 10.2308/aud.2002.21.1.147.

- Ricardino, A., & Carvalho, L.N.G. (2004). Breve retrospectiva do desenvolvimento das atividades de auditoria no Brasil. *Revista de Contabilidade & Finanças*.
- Riccio, E. L. (2001). *Efeitos da tecnologia de informação na Contabilidade. Estudos de Casos de Implementação de Sistemas Empresariais Integrados - ERP*. Tese de Livre Docência. FEA, USP.
- Richins, G., Stapleton, A., Stratopoulos, T., & Wong, C. (2017). Big Data Analytics: Opportunity or Threat for the Accounting Profession?. *Journal of Information Systems*. DOI: 10.2308/isisys-51805.
- Ringle, C., Silva, D., & Bido, D. (2014). Modelagem de Equações Estruturais com Utilização do Smartpls. *REMark: Revista Brasileira de Marketing*. DOI: 10.5585/bjm.v13i2.2717.
- Rittenberg L., & Covalski M. A. (2001). Internalization versus externalization of internal audit function: an examination of professional and organizational imperatives. *Accounting Organizations and Society*.
- Russom, P. (2011). Big Data Analytics. *TDWI*, 4th Quarter, 1-38.
- Sá, A. L. (1958). *Curso de Auditoria* (Vol. 1). São Paulo, SP: Atlas.
- Sá, A. L. (1968). *Auditoria Interna*. São Paulo, SP: Atlas.
- Sampieri, R. H.; Collado, C. F.; Lucio, M. D. P. B. (2013). *Metodologia de pesquisa – 5. ed. – São Paulo: Mc-Graw-Hill*.
- Sarens, G. (2009). Internal auditing research: Where are we going?. *International Journal of Auditing*. DOI: 10.1111/j.1099-1123.2008.00387.x.
- Sarens, G., Allegrini, M., D'Onza, G., & Melville, R. (2011). Are internal auditing practices related to the age of the internal audit function?: Exploratory evidence and directions for future research. *Managerial Auditing Journal*, 51-64. DOI: 10.1108/02686901111090835.
- Sarens, G., & De Beelde, I. (2006). The relationship between internal audit and senior management: an analysis of expectations and perceptions. *International Journal of Auditing, Chichester*, 219-41. DOI: 10.1111/j.1099-1123.2006.00351.x
- Sawyer, L. B. (1988). *Sawyers' Internal Auditing*, Institute of Internal Auditors, Altamonte Springs, FL.
- Schmarzo, B. (2013). *Big Data: Understanding how Data Powers Big Business*. John Wiley & Sons, Inc., Hoboken, NJ, USA.
- Shleifer, A., & Vishny, R. (1997). A Survey of Corporate Governance. *Journal of Finance*. DOI: 10.1111/j.1540-6261.1997.tb04820.x
- Silva, W. L. (2002). *Auditoria Continua de Dados como Instrumento de Automação do Controle Empresarial*. (Tese de Doutorado). Escola Politécnica, Universidade de São Paulo, SP.
- Singleton, T. W. (2011). How the IT auditor can make substantive contributions to a financial audit. *ISACA Journal*, 1, 1–3.

- Sivarajah, U., Kamal, M., Irani, Z., & Weerakkody, V. (2016). Critical analysis of Big Data challenges and analytical methods. *Journal of Business Research*. DOI: 10.1016/j.jbusres.2016.08.001.
- Smith, Malcolm (2017). *Research Methods in Accounting* (4th Edition). SAGE
- Spira, L., & Page, M. (2004). Risk Management: The Reinvention of Internal Control and the Changing Role of Internal Audit. *Accounting, Auditing & Accountability Journal*. DOI: 10.1108/09513570310492335.
- Strawn, G. O. (2012). Scientific research: how many paradigms? *Educ. Rev.* 47(3),26.
- Tang, F., Norman, C. S., & Vondrzyk, V. P. (2017). Exploring perceptions of data analytics in the internal audit function. *Behaviour & Information Technology*, 36(11), 1125-1136. Retrieved from https://www.researchgate.net/publication/318741113_Exploring_perceptions_of_data_analytics_in_the_internal_audit_function
- Vaassen, E., Meuwissen, R., & Schelleman, C. (2013). *Controle interno e sistemas de informação contábil: sob a ótica de empresas privadas e públicas*. São Paulo, SP: Saraiva.
- Van der Stede, W., Young, S., & Chen, C. (2005). Assessing the quality of evidence in empirical management accounting research: The case of survey studies. *Accounting, Organizations and Society*, 655-684. DOI: 10.1016/j.aos.2005.01.003
- Vasarhelyi, M., Alles, M., Kuenkaikaew, S., & Little, J. (2012). The acceptance and adoption of continuous auditing by internal auditors: A micro analysis. *International Journal of Accounting Information Systems*, 267-281. DOI: 10.1016/j.accinf.2012.06.011.
- Vasarhelyi, M., & Halper, F. (1991). The Continuous Audit of Online Systems. *Auditing: A Journal of Practice & Theory*.
- Vasarhelyi, M., Kogan, A., & Tuttle, B. M. (2015). Big data in accounting: An overview. *Accounting Horizons*, 381-396. DOI: 10.2308/acch-51071
- Vasarhelyi, M., Tostes, F., Alles, M., & Riccio, E. (2006). Continuous Auditing: The Usa Experience And Considerations For Its Implementation In Brazil. *Journal of Information Systems and Technology Management*. DOI: 10.4301/S1807-17752006000200007
- Venkatesh, V., & Bala, H. (2008), "Technology acceptance model 3 and a research agenda on interventions", *Decision Sciences*, Vol. 39 No. 2, pp. 273-315.
- Venkatesh, V., Brown, S., Maruping, L., & Bala, H. (2006). Predicting Different Conceptualizations of System Use: The Competing Roles of Behavioral Intention, Facilitating Conditions, and Behavioral Expectation. *MIS Quarterly*, 483-502. DOI: 10.2307/25148853.
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425-478. DOI: 10.2307/30036540.

- Venkatesh, V., Thong, J.Y.L., & Xu, X. (2012). Consumer acceptance and use of information technology: extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 36 (1), 157–178. <https://doi.org/10.1017/CBO9781107415324.004>.
- Verver, J. (2015). Six audit Analytics Success Factors. *Internal Auditor* 72 (3): 20–21.
- Wang, T., & Cuthbertson, R. (2015). Eight Issues on Audit Data Analytics We Would Like Researched. *Journal of Information Systems*: Spring 2015, Vol. 29, No. 1, pp. 155-162.
- Watts, R., & Zimmerman, J. (1983). Agency Problems, Auditing, and the Theory of the Firm: Some Evidence. *The Journal of Law & Economics*, 613-633. DOI: 10.1086/467051.
- Wamba, S.F., Akter, S., Edwards, A., Chopin, G., & Gnanzou, D. (2015). How ‘big data’ can make big impact: Findings from a systematic review and a longitudinal case study. *Int. J. Prod. Econ.*, 234–246. DOI: 10.1016/j.ijpe.2014.12.031.
- Warren, J., Moffitt, K. & Byrnes, P. (2015). How Big Data will change accounting. *Accounting Horizons*, 397-407. DOI: 10.2308/acch-51069
- White, M. (2012). Digital work places: vision and reality. *Bus. Inf. Rev.*
- White, T. (2012). Hadoop: The Definitive Guide. O'Reilly Media Inc.
- Wright, C. (2016). Technology Risk Gets More Complicated. *Internal Auditor* 73 (1): 67–68.
- Wu, X., Zhu, X., Wu, G., & Ding, W. (2014). Data Mining with Big Data. *Knowledge and Data Engineering, IEEE Transactions on*. 26. 97-107. DOI: 10.1109/TKDE.2013.109.
- Yang, D. C. & Vasarhelyi, M. A. (1998). The Application of Expert systems in Accounting. *Artificial Intelligence in Accounting and auditing – Towards New Paradigms*, 4, 29–43.
- Yoon, K., Hoogduin, L., & Zhang, L. (2015). Big data as complementary audit evidence. *Accounting Horizons*, 431-438. DOI: 10.2308/acch-51076

GLOSSÁRIO

Audit Command Language (ACL): ferramenta de análise de dados utilizada para extrair informações de arquivos para geração de relatórios de exceções, identificar tendências, localizar erros e fraudes, recalcular e verificar saldos, entre outras funcionalidades.

Assurance: um exame objetivo das evidências com a finalidade de fornecer uma avaliação independente sobre processos de governança, gerenciamento de riscos e controle para a organização. Os exemplos podem incluir compromissos financeiros, de desempenho, conformidade, segurança do sistema e *due diligence*.

Business Intelligence (BI): é o termo usado por fornecedores de *hardware* e *software* e consultores de TI para descrever a infraestrutura para armazenamento, integração, elaboração de relatórios e análise de dados que vêm do ambiente empresarial.

Condições Facilitadoras (CF): um dos quatro construtos do modelo UTAUT que desempenham um papel como determinantes diretos do comportamento de aceitação da tecnologia pelo usuário, corresponde ao grau em que um indivíduo acredita que existe uma infraestrutura organizacional e técnica para apoiar o uso do sistema.

Compliance: adesão a políticas, planos, procedimentos, leis, regulamentos, contratos ou outros requisitos.

Expectativa de Desempenho (ED): um dos quatro construtos do modelo UTAUT que desempenham um papel como determinantes diretos da intenção de uso (IU) da tecnologia pelo usuário, corresponde ao grau em que um indivíduo acredita que o uso da ferramenta o ajudará a melhor alcançar os resultados desejados.

Expectativa de Esforço (EE): um dos quatro construtos do modelo UTAUT que desempenham um papel como determinantes diretos da intenção de uso (IU) da tecnologia pelo usuário, corresponde ao grau de facilidade associado ao uso da ferramenta.

ETL (*Extraction, Transformation and Load*): é um tipo de *data integration* em três etapas (extração, transformação, carregamento) usado para combinar dados de diversas fontes comumente utilizado para construir um *data warehouse*. Nesse processo, os dados são retirados (extraídos) de um sistema-fonte, convertidos (transformados) em um formato que possa ser analisado, e armazenados (carregados) em um armazém ou outro sistema.

International Professional Practices Framework (IPPF): A estrutura conceitual que organiza a orientação oficial promulgada pelo IIA. A orientação oficial é composta por duas categorias: (1) obrigatória e (2) recomendada.

Going-concern assumption: pressuposto de que a entidade está em atividade e irá manter-se em operação por um futuro previsível não havendo a intenção, nem tampouco a necessidade, de entrar em processo de liquidação ou de reduzir materialmente a escala de suas operações (premissa da continuidade).

IDEA (Interactive Data Extraction and Analysis): é uma ferramenta de *software* que permite ao usuário, especialmente contador, auditor, analista financeiro, realizar análises de dados, aprimorar a auditoria e identificar falhas de controle.

Inteligência Artificial: consiste em sistemas baseados em computador que tentam simular o comportamento e os padrões de pensamento humano. Técnicas inteligentes ajudam os profissionais que tomam decisões capturando conhecimento individual e coletivo, descobrindo padrões e comportamentos em grandes quantidades de dados e gerando soluções para os problemas que são muito grandes e complexos para os seres humanos resolverem por conta própria.

Internet of Things (IoT): Internet das Coisas é definida como uma infraestrutura de rede global, que interconecta fisicamente e virtualmente objetos, com o objetivo de explorar dados capturados e suas capacidades de comunicação, caracterizada pelo alto grau de captura autônoma de dados, transferência de eventos de rede, conectividade e interoperabilidade.

Influência Social (IS): um dos quatro construtos do modelo UTAUT que desempenham um papel como determinantes diretos da intenção de uso (IU) da tecnologia pelo usuário, corresponde ao grau em que um indivíduo percebe que outras pessoas importantes acreditam que ele ou ela deve usar a nova ferramenta.

Intenção de Uso (IU) da tecnologia: variável dependente do modelo UTAUT.

Machine Learning: o aprendizado de máquina é uma disciplina científica que trata do projeto e desenvolvimento de algoritmos que melhoram automaticamente com a experiência, imitando o comportamento de aprendizado de humanos.

Python: uma linguagem de programação de alto nível que suporta tanto a programação orientada a objetos quanto a programação estruturada, com bibliotecas nativas que oferecem funcionalidades para desenvolvimento de projetos e implementação de aplicações complexas.

Query: é uma linguagem de computador de alto-nível utilizada para recuperar informações específicas de bancos de dados ou arquivos.

Radio Frequency Identification (RFID): termo genérico para tecnologias que usam ondas de rádio para identificar automaticamente pessoas ou objetos, normalmente possuindo três componentes: um dispositivo RFID (*tag* ou etiqueta); um leitor de etiquetas com uma antena e um microchip; e um sistema *host* ou conexão com um sistema corporativo.

Risco: é a probabilidade de perda ou incerteza associada ao cumprimento de um objetivo.

Sentiment Analysis: A análise de sentimento lida com a detecção do sentimento emocional preservado no texto por meio de análise semântica que se baseia principalmente na identificação de palavras positivas e negativas e no processamento de texto com o objetivo de classificar sua posição emocional como positiva ou negativa. O conceito de análise de sentimento, também conhecido pelo conceito de *opinion mining* (mineração de opinião) especializa-se para fins como avaliar a qualidade da recepção do mercado para um novo produto e o feedback geral do cliente ou estimar a popularidade de um produto ou marca.

Statistical Analysis System (SAS): é um sistema integrado de produtos de *software* fornecido pelo SAS Institute Inc. que permite aos programadores recuperar informações e gerenciar dados, gerar relatórios e gráficos, análise estatística, econometria e mineração de dados (*data mining*), planejamento de negócios, previsão e suporte a decisões, entre outras funcionalidades.

Statistical Package for Social Science (SPSS): a plataforma de *software* IBM SPSS oferece análise estatística avançada, uma biblioteca de algoritmos de *machine learning*, análise de texto, extensibilidade de *software* livre, integração com Big Data.

SQL (*Structured Query Language*): uma linguagem padrão de manipulação de dados para sistemas de gerenciamento de bancos de dados baseados no modelo relacional.

Trilha de auditoria: permite que os dados originários de transações possam ser acompanhados desde sua localização nos relatórios até os documentos fontes.

Variável Latente (VL): (também chamados de Construto) mede conceitos abstratos, complexos e que não podem ser observados diretamente por meio de (múltiplos) itens.

eXtensible Markup Language (XML): é uma metalinguagem, isto é, uma linguagem usada para descrever outras linguagens, baseada em de demarcadores (separadores de conteúdo) que é utilizada para a representação de dados, documentos e demais entidades (relatório, protocolo,

script) e, por ser um padrão aberto, independe da plataforma e do sistema utilizado para troca de informações via Internet ou em sistemas distribuídos.

APÊNDICES

APÊNDICE A – Questionário

Prezado(a),

O crescente interesse sobre o tema Big Data Analytics (BDA) em Auditoria Interna tem sido evidenciado tanto por publicações de empresas contábeis especializadas no mercado de consultoria e auditoria (Big 4) e The IIA (Institute of Internal Auditors), bem como por pesquisas científicas e trabalhos acadêmicos internacionais.

Este questionário foi elaborado para coletar informações sobre a percepção dos auditores internos quanto ao uso ou à intenção do uso de ferramentas tecnológicas de BDA nas práticas de auditoria interna, no cenário brasileiro, e no que diz respeito à avaliação da eficácia da governança, do gerenciamento de riscos e dos controles internos.

Respondendo o questionário, você estará contribuindo com a pesquisa de dissertação de Marcio Kawahara Iguma, estudante do curso de Mestrado em Ciências Contábeis na Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo (FEAUSP), sob orientação do Prof. Dr. Edson Luiz Riccio.

1. A participação no estudo é voluntária e isenta de despesas. Entretanto, o(a) participante deve ter ciência de que não será remunerado(a) pela participação na pesquisa.
2. O(A) participante tem a liberdade de desistir ou de interromper a colaboração nesta pesquisa no momento em que desejar, sem necessidade de qualquer explicação, apenas enviando uma mensagem à equipe de pesquisa, comunicando essa decisão.
3. Os dados pessoais de participantes serão mantidos em sigilo. Há concordância de que os resultados da pesquisa sejam divulgados em publicações científicas, com os dados no agregado, sem possibilidade de identificação.
4. O(A)s participantes poderão consultar o(a)s pesquisadores responsáveis, abaixo identificado(a)s, sempre que entenderem necessário obter informações ou esclarecimentos sobre o projeto de pesquisa e sobre a sua participação na pesquisa.
5. O(A)s participantes autorizam a gravação de suas respostas no banco de dados criado especificamente para esta pesquisa.
6. Para responder o questionário, não é necessário se identificar. Informamos que o tempo médio para respostas será de 10 minutos.

Desde já agradecemos a sua participação!

Equipe de pesquisa:

Marcio Kawahara Iguma, FEAUSP, mkiguma@usp.br

Prof. Dr. Edson Luiz Riccio, FEAUSP, elriccio@usp.br

Programa de Pós-Graduação em Controladoria e Contabilidade da Universidade de São Paulo (USP)

Concordo em participar desta pesquisa

- SIM (Ir para a seção 2 “1ª PARTE - CARACTERIZAÇÃO DO RESPONDENTE”)
- NÃO (Enviar formulário)

1ª PARTE – CARACTERIZAÇÃO DO RESPONDENTE

1. GÊNERO

☐ Masculino ☐ Feminino

2. IDADE (Ex: 35): _____ anos

3.1. FORMAÇÃO NA GRADUAÇÃO

- ☐ Administração
- ☐ Ciências Contábeis
- ☐ Sistemas de Informação/Tecnologia da Informação
- ☐ Engenharia
- ☐ Outra formação: _____
- ☐ Não se aplica

3.2. FORMAÇÃO PÓS-GRADUAÇÃO

- ☐ Lato Sensu (Especialização)
- ☐ Master Business Administration (MBA)
- ☐ Stricto Sensu (Mestrado Acadêmico)
- ☐ Stricto Sensu (Mestrado Profissional)
- ☐ Stricto Sensu (Doutorado)

3.3. ÁREA DE FORMAÇÃO (PÓS-GRADUAÇÃO)

- ☐ Administração
- ☐ Ciências Contábeis

- ☐ () Sistemas de Informação/Tecnologia da Informação
- ☐ () Engenharia
- ☐ () Outra formação: _____
- ☐ () Não se aplica

4. TEMPO DE ATUAÇÃO EM AUDITORIA INTERNA

_____ anos

5. CERTIFICAÇÕES

- ☐ () Certified Internal Auditor (CIA)
- ☐ () Risk Management Assurance™ (CRMA™)
- ☐ () Qualification in Internal Audit Leadership® (QIAL®)
- ☐ () Outras certificações: _____
- ☐ () Não se aplica

6. TIPO DE ORGANIZAÇÃO

6.1. Indique as características da empresa (cliente de auditoria interna) em que você trabalha atualmente (ou da última que você atuou):

- ☐ () Capital aberto (listada)
- ☐ () Organização privada (não listada)
- ☐ () Setor público (incluindo agências e organizações mantidas pelo governo)
- ☐ () Organização sem fins lucrativos não relacionada ao governo)

6.2. Localização geográfica da empresa (Estado/UF): _____

6.3. Aproximadamente, quantos empregados trabalham na empresa?

- ☐ () Menos de 100
- ☐ () Entre 100 e 499
- ☐ () Entre 500 e 999
- ☐ () Entre 1.000 e 4.999
- ☐ () Mais de 5.000

6.4. Indique a faixa que mais se aproxima do faturamento anual da empresa:

- ☐ () Menos de R\$ 250 milhões
- ☐ () Entre R\$ 250 e R\$ 499 milhões

() Entre R\$ 500 e R\$ 999 milhões

() Mais de R\$ 1 bilhão

7. COMPETÊNCIAS TECNOLÓGICAS INDIVIDUAIS

7.1. Adquiri competências em Tecnologia da Informação por meio de... (assinale as respostas que se apliquem à sua situação)

() Formação pela Empresa

() Formação pela Instituição de Ensino Superior

() Cursos de formação externos

() Autodidata

() Não se aplica

7.2. Participei ou tenho interesse em participar de eventos relacionados a inovações tecnológicas em auditoria interna? Exemplos:

- Seminário 2019 (São Paulo): “O mundo da Inteligência Artificial na Auditoria Interna” realizado em 06/06/2019.
- 39º CONBRAI (Florianópolis 2019): “Tecnologia e inovação para Auditoria Interna” (15 a 17/09/2019).

1- SIM

2- NÃO

2ª PARTE – BIG DATA ANALYTICS & AUDITORIA INTERNA

Big Data é o termo genérico para o conjunto de dados que cresce de forma exponencial e em alta velocidade, capturados ou gerados por diversas fontes geograficamente distribuídas, cuja integração de diferentes tipos de formatos e seu armazenamento são suportados por uma combinação de soluções tecnológicas inovadoras (definição do autor). Deste modo, o *Big Data* permite a potencialização da análise de informação relevante para tomada de decisão por meio de técnicas e ferramentas de *Data Analytics* cada vez mais avançadas, com a utilização de recursos de algoritmos matemáticos e estatísticos.

Instruções para preenchimento dos itens I, II e III

Favor indicar, nas perguntas abaixo, o grau de frequência de uso por meio de uma nota de um a cinco (1 a 5) e zero (0 - Não Utilizo) conforme o seguinte direcionamento:

0- NÃO SE APLICA

I. Ferramentas de Tecnologia da Informação

Nas atividades de auditoria interna eu utilizo as seguintes ferramentas de Tecnologia da Informação, com frequência...

Tipos de ferramentas tecnológicas	Frequência de Uso
1. Análise de dados aplicada à auditoria. Exemplos: ACL (Audit Command Language), IDEA (Interactive Data Extraction and Analysis).	
2. Ferramentas de sistemas ERP (Enterprise Resource Planning). Exemplos: SAP, Totvs.	
3. Extração de dados (ETL – Extract, Transform, Load). Exemplo: Power Center.	
4. Linguagens SQL e execução de Queries.	
5. Rotinas de Auditoria Contínua (processos automatizados de monitoramento contínuo de dados).	
6. Visualização de dados. Exemplos: Qlikview, Tableau.	
7. Linguagens de programação e modelagem estatística. Exemplos: SAS, [R], Python, SPSS.	
8. Plataformas de Inteligência Artificial e Aprendizado de Máquina. Exemplos: IBM Watson, Microsoft Azure.	

II. Tipos de Dados

Nas atividades de auditoria interna, eu executo tarefas de extração e análise dos seguintes Tipos de Dados, com a utilização das ferramentas de Tecnologia de Informação informadas no item anterior, com frequência...

Tipos de dados	Frequência de Uso
1. Dados financeiros	
2. Dados não financeiros obtidos de bancos de dados da empresa (Exemplos: cadastros de clientes, fornecedores, estoques, recursos humanos).	
3. Dados de arquivos em formato XML, XBRL.	
4. Dados em linguagem natural (Exemplos: mensagens de e-mail, atas de reunião).	
5. Dados estruturados externos à empresa (Exemplo: SERASA).	
6. Dados não estruturados externos à empresa (Exemplos: páginas de <i>websites</i> , mensagens em redes sociais).	
7. Dados em formato de imagem ou vídeo (Exemplo: reconhecimento facial, identificação de documentos).	
8. Dados em formato de áudio para análise de sentimento (Exemplo: canal de denúncias).	

III. Atividades de Auditoria Interna

Os tipos de ferramentas e de dados informados nos itens anteriores (I e II) são utilizados nas seguintes atividades de Auditoria Interna, com frequência...

Atividades de auditoria interna	Frequência de Uso
1. Planejamento da auditoria	
2. Avaliação do controle interno, identificando potenciais <i>outliers</i> que possam indicar falhas ou fraquezas dos controles.	
3. Avaliação de riscos de auditoria	
4. Testes de auditoria	
5. Circularização de informações	
6. Obtenção de evidências de auditoria	
7. Amostragem estatística	
8. Análise de Segregação de funções	
9. Análise e Recuperação de Pagamentos Duplicados	

3ª PARTE

A seguir, apresentamos as assertivas relacionadas à sua percepção quanto ao uso de ferramentas tecnológicas de **BDA** nas práticas de auditoria interna relacionadas à avaliação da eficácia da governança, do gerenciamento de riscos e dos controles internos.

Favor apontar o grau de concordância em cada uma das afirmações. Na escala, os números variam entre 1-Discordo totalmente (DT) e 5-Concordo totalmente (CT)

1-Discordo totalmente (DT)

2-Discordo parcialmente

3-Não concordo, nem discordo

4-Concordo parcialmente

5-Concordo Totalmente (CT)

		1(DT)	2	3	4	5(CT)
1	O uso de ferramentas de BDA é útil para o meu trabalho.					
2	Eu planejo utilizar ferramentas de BDA no trabalho nos próximos meses.					
3	Pessoas importantes para mim acham que eu devo utilizar as ferramentas de BDA no meu trabalho.					
4	Os recursos necessários para usar ferramentas de BDA no trabalho estão disponíveis para mim.					
5	A minha interação com ferramentas de BDA ocorre de forma clara e compreensível.					
6	O uso de ferramentas de BDA permite que eu conclua as tarefas mais rapidamente.					
7	A gerência da área de auditoria interna incentiva o uso de ferramentas de BDA.					
8	Eu considero as ferramentas de BDA fáceis de usar.					
9	Um profissional ou equipe de suporte está disponível para me auxiliar quando tenho dificuldades em utilizar ferramentas de BDA.					
10	Eu tenho intenção em utilizar ferramentas de BDA em meu trabalho nos próximos meses.					
11	Aprender a utilizar ferramentas de BDA é fácil para mim.					

12	Tenho mais chance de obter reconhecimento profissional com o uso de ferramentas de BDA.					
13	Pessoas que exercem influência sobre o meu comportamento acham que eu devo utilizar as ferramentas de BDA no meu trabalho.					
14	Eu tenho conhecimento adequado para usar ferramentas de BDA.					
15	O uso de ferramentas de BDA melhora a qualidade do meu trabalho.					
16	É fácil adquirir habilidade ao utilizar ferramentas de BDA.					
17	Em geral, a empresa tem dado suporte para o uso de ferramentas de BDA.					
18	As ferramentas de BDA não são compatíveis com outras ferramentas que eu uso.					
19	O uso de ferramentas de BDA aumenta a minha produtividade.					
20	Eu irei utilizar ferramentas de BDA no trabalho nos próximos meses.					

Caso você tenha interesse em receber os resultados da pesquisa, informe o seu e-mail na caixa de texto a seguir _____.

Caso deseje acrescentar algum comentário, sugestão ou dúvida, utilizar esse espaço _____.

APÊNDICE B – Feedback dos Respondentes

Respondente	Feedback
1	“Gostei muito desta pesquisa e ela fez-me refletir como preciso evoluir meu aprendizado quanto a BDA. Sou um usuário inicial, então se puder indicar-me cursos em que eu possa me especializar, ficarei muito grato.”
2	“Acabei de responder agora a sua pesquisa e parabéns pela iniciativa. somente pelo questionário eu consegui aprender bastante. A gente ver que muitas empresas não usam metade das Ferramentas que você sugere e de fato elas elevam em muito o nível de produtividade do auditor interno. Boa sorte!”
3	“Disseminar o uso dessa ferramenta junto aos Institutos dos Auditores como forma de ampliar as análises dos trabalhos verificados...”
4	“Gostaria de acrescentar que na equipe de auditoria da empresa que trabalho possui uma equipe de aud continua especializada em BDA.”
5	“Será imprescindível para o auditor aprender utilizar as ferramentas de análise de dados para a realização dos testes, visto que o volume de dados nas organizações é crescente, sendo assim, uma opinião baseada apenas numa amostragem não transmite a mesma segurança quando analisado um grande volume de transações.”
6	“Parabéns aos pesquisadores pela iniciativa. Somente pelas perguntas, vejo que o mundo corporativo ainda está muito distante do meio acadêmico. Se as grandes empresas aplicassem em Auditoria metade das ferramentas sugeridas nesse estudo, a Auditoria Interna seria muito mais desenvolvida no Brasil.”
7	“Muito interessante esse assunto, todos deveriam ter acesso e conhecimento sobre o mesmo.”
8	“A utilização de ferramentas de BigData e IA são fundamentais para o Auditor Interno garantir que possui abrangência o suficiente de forma eficaz com relação à avaliação dos Objetivos da Companhia. Uma vez que o BDA está cada vez mais presente nos objetivos e procedimentos de cada empresa, é fundamental que o auditor interno esteja bem preparado e capacitado para avaliar e utilizar essas ferramentas em seu dia-a-dia.”
9	“Gostei muito da pesquisa, este é o futuro da auditoria, que já chegou em algumas empresas, parabéns pela escolha do tema.”
10	“Todo auditor interno deveria ter conhecimento de bda ou pelo menos de bando de dados e como extrair informações.”
11	“Muito oportuno o tema. Não há como ignorar as mudanças que as auditorias internas terão que passar (na verdade já estão passando). Quanto mais cedo for iniciado o processo de inovação e adaptação, melhores serão os resultados. A tecnologia e os dados estão aí, disponíveis, então vamos utilizá-los. Parabéns e sucesso no trabalho.”
12	“Sugiro avaliar as áreas que mais utilizam o BDA em Auditoria. Ex. Inst. Financeiras, Indústria.”

13	“Parabéns pela iniciativa! Atuo com o uso de tecnologia na Auditoria por mais de 30 anos e por incrível que pareça tem auditores que ainda resistem!”
14	“Data Analytics é essencial, porém poucas pessoas sabem usar e precisamos direcionar essas análises para área específica de Data Analytics.”
15	“Minha empresa está trabalhando com uma consultoria para começar a utilizar o BDA na auditoria interna, porém ainda não foi apresentado o resultado do trabalho para o time e por isso ainda não estamos utilizando a ferramenta nos nossos trabalhos.”
16	“Excelente pesquisa abordando um assunto em foco a muito tempo na Auditoria Interna. Parabéns!”
17	“Embora no meu atual trabalho não utilize, acredito que a adoção de soluções BDA seja primordial para o bom planejamento e execução dos trabalhos de auditoria interna, garantindo maior assertividade e confiabilidade das análises.”
18	“Pesquisa atual e relevante! Parabéns!”
19	“Preciso de mais conhecimento, mas apoio de TI e budget para novos investimentos.”
20	“Parabéns pela pesquisa. Estou ansioso pelo resultado e para saber como os demais profissionais de auditoria estão alinhados com a prática de utilização de BDA.”
21	“Ferramentas de Big Data Analytics ainda são muito caras.”
22	“O questionário foi muito bem formulado com perguntas bastante pertinentes, parabéns.”
23	“Por gentileza, se possível gostaria de receber sua dissertação para ler quando estiver finalizada. Obrigado!”
24	“Não utilizo BDA no trabalho e não tenho nenhuma formação quanto a isso, mas é uma área de grande interesse meu.”
25	“Infelizmente na atual corporação que atuo, não temos previsão de obter recursos para investir em análise de dados (estamos em RJ). Tive oportunidade de trabalhar com o ACL na empresa anterior, mas admito que não evoluiu nada bem no setor de auditoria. Abraco”
26	“Que legal seu trabalho. Muito importante se falar em auditoria de dados. Uma pena que a empresa que trabalho ainda não se preocupar com BDA. Mas tenho lido bastante sobre o assunto.”
27	“Sucesso com seu trabalho de mestrado, realmente BDA já modificou a forma como a Auditoria trabalha.”
28	“... muito bom esse tema, sou especialista nesta área, estou atuando há 8 anos dentro da auditoria com a utilização de Analytics.”
29	“...respondi o questionário, muito interessante o tema, acredito muito em BDA na auditoria, caso tenha material sobre o tema, peço por favor me encaminhar.”
30	“Muito atual essa sua linha de pesquisa, parabéns!”
31	“Estou cursando Sistemas de Informação e em paralelo um curso de Python para Data Science, onde pretendo aplicar no escopo de auditoria interna, de forma preditiva. Ainda é um projeto, pois estou no 6º semestre fazendo o curso básico de Python para análise de dados. Se precisar de algo, estou a disposição.”

32	“Tenho tentado implementar análises utilizando SQL com PowerBI na minha área e a liderança tem gostado do resultado. Conseguimos de certa forma tirar insights que talvez não veríamos em amostras aleatórias. Sucesso na sua pesquisa. Abraço.”
33	“Me interesse pelo assunto e também estou fazendo uma pós...”
34	“Pertinente o tema da sua pesquisa quanto à área de Auditoria Interna. Caso precise de alguma ajuda, estou à disposição.”
35	“Adicionalmente, nós estamos fazendo um Benchmarking pra saber quais são as ferramentas mais utilizadas e as que trazem um melhor resultado para big data, data analytics, automatização de processos e etc. Neste "mundo" qual a ferramenta que desponta? Em minha percepção é o aql... Está correta ou existem melhores?”
36	“Muito bem estruturada sua pesquisa, com orientações claras e perguntas objetivas. Espero que tenha êxito no seu projeto.”
37	“...respondi a pesquisa. Muito interessante. Se precisar de mais alguma ajuda, estou a disposição. Bom trabalho! O tema que você escolheu é da mais alta importância para a Auditoria Interna.”
38	“...acabo de responder sua pesquisa e este é um tema que muito que interessa. Atualmente estou cursando um MBA sobre o assunto (sem qualquer incentivo ou auxílio da empresa) e busco justamente alguma forma de aplicar Analytics nos trabalhos, de forma gerar valor e ganhar tempo e produtividade.”
39	“Estou a disposição se puder ajudar em algo. Este assunto está realmente revolucionando a área de auditoria no mercado!”
40	“muito interessante seu tema de estudo, bem como a apresentação da pesquisa.”
41	“Respondido! O tema é super atual para nós de AI! Boa sorte na pesquisa.”