

## **Big Data Analytics and the evolution of Internal Audit practices**

### **Big Data Analytics e a evolução das práticas de Auditoria Interna**

#### **ABSTRACT**

Big Data Analytics (BDA) has been the topic of extensive coverage in the public media and 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. As 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. The present study aims to investigate the factors that influence the acceptance of BDA solutions in Internal Audit Function (IAF), according to the perception of internal auditors in companies in the Brazilian private sector. The theoretical model, its concepts, constructs and hypotheses were adapted from the Unified Theory of Acceptance and Use of Technology (UTAUT). The findings revealed that Performance Expectancy and Social Influence are significant predictors of the of internal auditors to adopt BDA solutions, while the effects of Effort Expectancy and Facilitating Conditions, as well as the effects of the moderating variables Gender, Age and Experience, were not significant on Behavioral Intention. In this way, the study sought to bring theoretical and practical contributions to the IA profession, the Institute of Internal Auditors (The IIA), organizations and educational institutions.

Keywords: Internal Audit. Big Data Analytics. UTAUT

#### **RESUMO**

*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. À medida 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 função de Auditoria Interna. 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 resultados apontaram que a Expectativa de Desempenho e a Influência Social são preditores significativos das intenções dos auditores internos em adotar o BDA, enquanto que os efeitos de Expectativa de Esforço e Condições Facilitadoras, assim como os efeitos das variáveis moderadoras Gênero, Idade e Experiência, não foram significativos sobre a Intenção de Uso. Desse modo, o estudo procurou trazer contribuições teóricas e práticas para a profissão de AI, para o Instituto dos Auditores Internos (The IIA Brasil), para as organizações e instituições de curso superior.

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

## 1 INTRODUÇÃO

O conceito de “era digital” surgiu nos 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 no mundo 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). Segundo 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). O Quadro 1 apresenta as unidades de medidas computacionais para entendimento do crescimento do volume de dados digitais.

Quadro 1 – Unidades de Medidas Computacionais

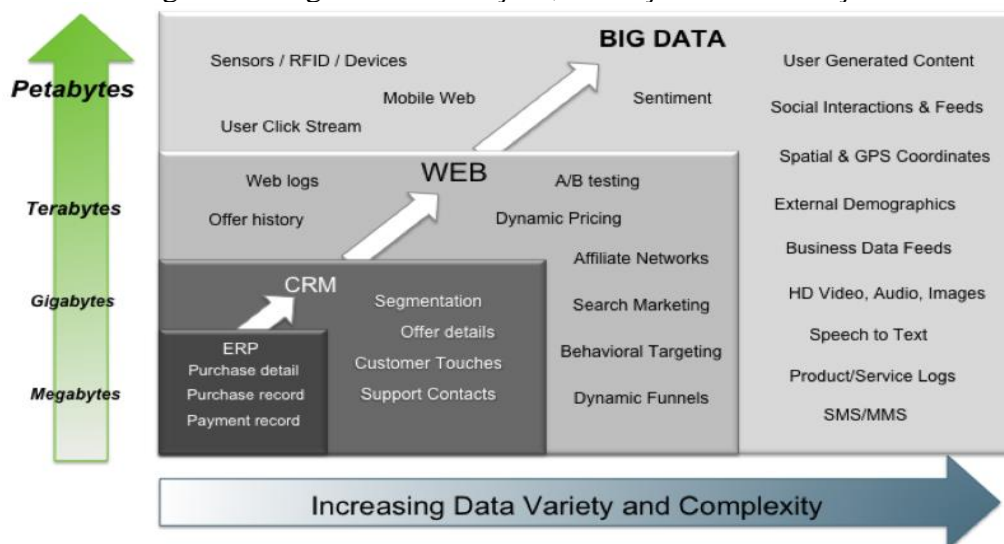
Kilobyte (KB)		$2^{10}$ bytes	1.024
Megabyte (MB)	1.024 KB	$2^{20}$ bytes	1.048.576
Gigabyte (GB)	1.024 MB	$2^{30}$ bytes	1.073.741.824
Terabyte (TB)	1.024 GB	$2^{40}$ bytes	1.099.511.627.776
Petabyte (PB)	1.024 TB	$2^{50}$ bytes	1.125.899.906.842.620
Exabyte (EB)	1.024 PB	$2^{60}$ bytes	1.152.921.504.606.850.000
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 aos ativos materiais e ao capital humano. O termo “Big Data” foi cunhado para representar o profundo significado dessa tendência de explosão de dados e que foi apontado 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 de Big Data é impulsionado por grandes quantidades de dados não estruturados e multidimensionais que são continuamente gerados e armazenados a um custo reduzido (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 Internet das Coisas (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). A Figura 1 traz a representação de Big Data como a integração de transações, interações e observações (Moniruzzaman & Hossain, 2013).

Figura 1 – Big Data: Transações, Interações e Observações



Fonte: Connolly (2012)

Definimos BDA para o presente estudo como o 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, permitindo a descoberta de insights para a tomada de decisão.

O advento do BDA provocou 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). Assim, diante da introdução de novos processos de negócio enquanto outros processos são eliminados, o mesmo deve ocorrer com a Função de Auditoria Interna (IAF – *Internal Audit Function*) (Appelbaum, Kogan, & Vasarhelyi, 2017).

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), assim como a complexidade do ambiente tecnológico, o crescente uso da análise de grandes volumes de dados em formatos heterogêneos 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 The IIA (IIARF, 2016). 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).

A Auditoria Interna (AI) cresceu significativamente ao longo dos anos, em relevância e abrangência de seu escopo de atuação, devido às mudanças que as

organizações estão enfrentando relacionadas ao ambiente regulatório, às evoluções na Governança Corporativa (Ramamoorti, 2003) e às novas tecnologias (Hass, Abdolmohammadi, & Burnaby, 2006; Vasarhelyi & Halper, 1991). Os auditores internos podem potencialmente acessar Big Data de sua organização mais facilmente, de forma completa e a qualquer momento, em comparação aos auditores externos. Além disso, o uso de BDA por auditores internos geralmente é mais abrangente, por exemplo, no uso de informações não financeiras como parte de uma auditoria operacional (Alles & Gray, 2016).

No ambiente emergente de BDA, as técnicas tradicionais de análise de dados mostram-se inadequadas diante das modernas tecnologias, 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, Stapleton, Stratopoulos, & Wong, 2017). 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 etapas do trabalho de AI (Vasarhelyi & Halper, 1991).

Tang, Norman e Vendrzyk (2017) consideram que as mudanças disruptivas resultantes do BDA são inevitáveis, levando os auditores internos a aprenderem novas habilidades para lidar com os riscos que essas mudanças trarão para as 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 e estratégias, voltada para os resultados dos negócios da organização (Silva, 2002; Kuenkaikaw, 2013).

No entanto, há evidências históricas fornecidas por pesquisas anteriores de que a profissão de AI possui uma natureza conservadora na adoção de ferramentas de TI, com base em suas experiências com computação cliente-servidor e 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).

Segundo Gandomi e Haider (2015), a mídia pública cobriu o rápido crescimento da evolução e adoção do Big Data, impulsionando a pesquisa da comunidade acadêmica nessa área. O estudo de Gepp, Linnenluecke, O'Neill e Smith (2018) aponta que a Auditoria está um passo atrás em relação às demais correntes de pesquisa sobre o uso de técnicas 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 do reconhecimento sobre a 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.

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 ainda poucos os estudos sobre o comportamento da adoção dessa solução tecnológica. Tang, Norman e Vendrzyk (2017), por exemplo, examinaram a adoção de BDA por profissionais de AI utilizando a abordagem de estudo de casos, entrevistando 12 Chefes Executivos de Auditoria (CAE – *Chief Audit Executive*), sendo 6 CAEs de empresas com fins lucrativos e 6 CAEs de organizações sem fins lucrativos dos EUA. No entanto, não foram encontrados estudos com abordagem quantitativa e a aplicação de modelos teóricos para a compreensão da aceitação de BDA por auditores internos no cenário brasileiro ou mesmo no cenário internacional.

Diante do exposto, levantou-se a necessidade de identificar o cenário das tecnologias atualmente utilizadas por auditores internos, bem como, estudar o comportamento desses profissionais frente ao fenômeno do crescente volume de dados multidimensionais que são coletados, 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, o presente estudo tem como objetivo investigar e analisar os fatores contextuais de Expectativa de Desempenho, Expectativa de Esforço, Influência Social e Condições Facilitadoras que influenciam a intenção de adotar soluções de BDA nas práticas de AI, segundo a percepção dos auditores internos que atuam em empresas do setor privado brasileiro.

Este artigo está organizado em cinco seções, incluindo esta introdução. Na Seção 2 é apresentado o embasamento teórico deste trabalho, enquanto que a Seção 3 inclui os aspectos metodológicos; os resultados são apresentados e discutidos na Seção 4. As contribuições práticas e teóricas, limitações e pesquisas futuras são fornecidas nos comentários finais da Seção 5.

## **2 REFERENCIAL TEÓRICO**

### **2.1 A Evolução da Auditoria Interna**

As profissões de Contabilidade e a Auditoria Externa têm longa história em muitos países, enquanto que a profissão de AI é mais recente, organizada a partir do estabelecimento do The IIA em 1941 (Sarens et al., 2011). De forma geral, o auditor externo preocupa-se com transações e controles contábeis e financeiros, sendo 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).

Enquanto a auditoria externa tem o seu foco voltado para o controle interno, quanto aos possíveis efeitos deste sobre as demonstrações financeiras, servindo de base para emissão de seu parecer, o auditor interno tem sua ótica voltada para o quê o controle interno representa para a organização (Attie, 2011). 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 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):

- a) O primeiro paradigma da AI teve como principais características a observação, a contabilização, e a utilização da técnica de reexecução de processos, perdurando por muito tempo;

- b) O segundo paradigma foi marcado pela fundação do The IIA em 1941 com os conceitos de “controle” e de “Sistema de Controles Internos (SCI)” que ainda encontram enraizados no processo de auditoria;
- c) 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.

É importante destacar as mudanças observadas nas definições de AI em épocas distintas (Quadro 2). A definição de 1978 dá ênfase ao controle na atividade da AI e, em relação à definição de 1958, a AI deixou de ser citada como um segmento do campo da Contabilidade. Já a definição de 1999 apresenta um escopo mais amplo da AI abrangendo a avaliação de processos de gerenciamento de riscos, controle e governança.

Quadro 2 – Definições de Auditoria Interna em ordem cronológica

Autores	Definição de Auditoria Interna
The IIA (1958, citado por Ramamoorti, 2003)	A auditoria interna emerge como um segmento especial do amplo campo da <b>contabilidade</b> , 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.
The 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 <b>controle</b> 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.
The 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 <b>gerenciamento de riscos, controle e governança</b> .

Fonte: Elaborado pelo autor

## 2.2 O Uso de Ferramentas de TI pela Auditoria Interna

A literatura apresenta três tipos de abordagens sobre a forma como os auditores utilizam recursos e soluções de TI (Moscove, Simkin, & Bagranoff, 2002; Imoniana, 2016): (a) Auditoria em torno do computador (*around the computer*): requer do auditor interno pouco treinamento em TI, que 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. Pesquisadores concordam que esta abordagem é a menos viável diante do contexto das organizações de evolução dos modelos de negócios e da complexidade dos ambientes tecnológicos; (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 o teste e a 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; e (c) Auditoria com computador (*with the computer*): o computador torna-se uma ferramenta que auxilia os 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.

O termo *Computer-Assisted Audit Tools and Techniques* (CAATs), que pode ser definido como qualquer uso da tecnologia para auxiliar o trabalho de auditoria, tanto a AI como a auditoria externa (Braun & Davis, 2003; Mahzan & Lymer, 2010), 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 o suporte a testes substantivos, *softwares* para predição do comportamento de dados (*data mining*) e para análises de amostragem e regressão estatística. Conforme demonstra o Quadro 3, a constante evolução do cenário de TI oferece uma variedade de desafios para a auditoria cada vez mais complexos ao longo do tempo (Chan et al., 2018). A convergência dos repositórios de sistemas ERP e de outros avanços tecnológicos, que incluem novos tipos de dados e algoritmos de mineração de dados, evoluiu naturalmente para o que chamamos de Big Data (Alles & Gray, 2016).

Quadro 3 – A Evolução da TI e os Desafios de Auditoria

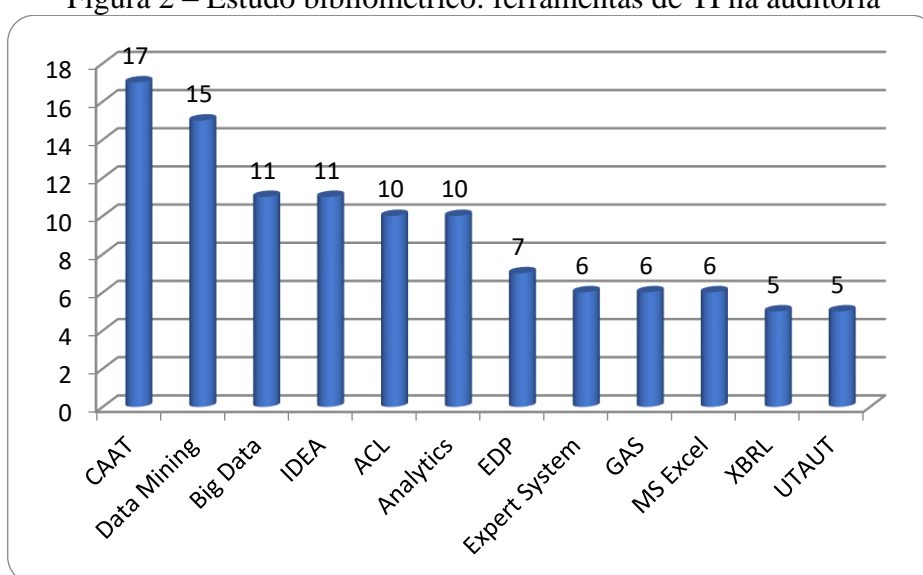
Fase	Período	Exemplos de Aplicações	Desafios de Auditoria
1	1945-1955	Aplicações científicas e militares	Transcrição de dados. Processo repetitivo.
2	1955-1965	Fitas magnéticas. Aplicações naturais.	Dados visualmente não legíveis. Dados que podem ser alterados sem deixar vestígios.
3	1965-1975	Sistemas 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	Networks. 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)

No que diz respeito à produção científica internacional sobre as soluções tecnológicas mais estudadas no campo da auditoria, o estudo bibliométrico de Iguma e Riccio (2018) demonstrou que “Big Data” foi a terceira palavra-chave mais citada pelas publicações acadêmicas no período de três anos (2015, 2016 e 2017), revelando o crescente interesse dos pesquisadores acadêmicos sobre o assunto (Figura 2).

Figura 2 – Estudo bibliométrico: ferramentas de TI na auditoria



Fonte: Iguma and Riccio (2018)

### 2.3 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 4).

Quadro 4 – 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.



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> ).
Terabyte para Petabyte	Final dos anos 1990	Período marcado pelo rápido desenvolvimento da Web 1.0, que levou o mundo à era da Internet, juntamente com páginas <i>web</i> semiestruturadas ou não estruturadas contendo terabytes ou petabytes de dados. 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	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 um grande volume de dados, Big Data representa um conceito abstrato e amplo. A falta de consenso sobre a sua definição pode estar relacionada à evolução rápida e caótica na literatura, o que dificultou o desenvolvimento de uma definição universal e formalmente aceita (De Mauro, Greco, & Grimaldi, 2016). 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 diz respeito apenas sobre dados, mas considera também o que pode ser feito com dados, metas e valores que motivam esse uso.

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 de dados, 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 explorar o potencial do BDA para melhorar seus sistemas e executar análises mais rápidas (Elgendy & Elragal, 2014). 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 funções de modelagem, visualização, predição e otimização. Hu, Wen, Chua e Li, (2014) descrevem seis tipos de

aplicações de BDA: análise de dados estruturados, *text analytics*, *web analytics*, *multimedia analytics*, *network analytics* e *mobile analytics* (Quadro 5).

Quadro 5 – 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>Multimedia 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.
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)

## 2.4 BDA e Auditoria Interna

Estudos acadêmicos no campo da auditoria apontam diversos aspectos da incorporação de soluções de BDA na AI como oportunidades, desafios, mudanças de paradigma e implantação (Quadro 6).

Quadro 6 – BDA: oportunidades, mudanças de paradigma e desafios para a Auditoria Interna

<b>BDA – Oportunidades para a Auditoria Interna</b>	
Moffitt & Vasarhelyi (2013); Yoon et al. (2015); Earley (2015)	Os auditores podem testar mais transações do que é atualmente possível, aumentando a suficiência das evidências de auditoria. Big Data pode oferecer suporte quando a evidência de auditoria tradicional é deficiente, complementando-a com informações suficientes, confiáveis e relevantes. Os dados externos incluem dados sobre amplos fatores e tendências macroeconômicos, dados do setor, dados sobre concorrentes específicos e dados capturados por meio de plataformas de mídia e mídia social.
Earley (2015); Moffitt & Vasarhelyi (2013)	O foco na procura de erros de amostra seria substituído pela busca de anomalias nos padrões de dados de toda a população. A amostragem estatística faz pouco sentido no momento em que muitas asserções podem ser facilmente verificadas no nível da população.
Earley (2015); Moffitt & Vasarhelyi (2013)	A qualidade da auditoria pode ser aprimorada fornecendo informações valiosas sobre os processos do cliente, mantendo uma base de conhecimento sobre soluções para anomalias nas transações que podem ser transferidas de ano para ano, para uso dos auditores internos. Os dados obtidos em cada trabalho de auditoria, desde campanhas de vendas a documentos de trabalho, tudo poderia ser armazenado para análise posterior.
Earley (2015)	Facilite a detecção de fraudes com o uso de ferramentas que permitem aos auditores analisar grandes conjuntos de dados com eficiência.
Earley (2015)	Os auditores podem fornecer serviços e resolver os problemas de seus clientes que estão usando, além dos recursos atuais, dados não financeiros (NFD), dados externos e dados não estruturados para melhor informar o planejamento de auditoria (particularmente na avaliação de riscos) e áreas de auditoria com mais eficiência que exigem julgamento, como avaliação (avaliação) e continuidade (continuidade).
<b>BDA – Mudanças de Paradigma na Auditoria Interna</b>	
Alles & Gray (2016)	Maior confiança em NFD, que são os tipos de dados que os auditores geralmente não têm clareza sobre como executar sua validação.
Alles & Gray (2016)	Desenvolvimento de habilidades técnicas e alteração do perfil da equipe de auditoria.
Alles & Gray (2016)	Visão de negócios para selecionar os elementos do Big Data a serem analisados e como interpretar os resultados.
Alles & Gray (2016)	Acesso sem precedentes a dados confidenciais e proprietários do cliente que não fazem parte dos dados convencionais solicitados durante uma auditoria.
Moffitt & Vasarhelyi (2013)	Metodologias para a execução de medidas de avaliação com mais frequência e, eventualmente, em tempo real ou em tempo real.
Moffitt & Vasarhelyi (2013); Kuenkaikaew (2013)	As abordagens de auditoria preventiva e preditiva devem ser formuladas considerando questões como materialidade das estimativas.
Moffitt & Vasarhelyi (2013)	Os auditores devem começar a confiar em modelos analíticos para validar elementos, relacionando mercados, dados operacionais,

vendas e esforços pós-venda.

Moffitt & Vasarhelyi (2013)	Novas formas de evidência de auditoria, como alarmes e alertas, mineração de texto e a busca por exceções excepcionais podem ser usadas para complementar ou substituir certas formas de evidência de auditoria.
<b>BDA – Desafios para a Auditoria Interna</b>	
Earley (2015); Brown-Liburd et al. (2015)	Treinamento e conhecimento do auditor: a proliferação de grandes quantidades de dados, especialmente dados não financeiros, exigiria que os auditores se especializassem em habilidades de reconhecimento de padrões e avaliação de anomalias.
Earley (2015)	Disponibilidade, relevância e integridade dos dados.
Brown-Liburd et al. (2015)	A dificuldade em diferenciar dados relevantes e não relevantes do Big Data e a característica ambígua de dados não estruturados podem resultar em julgamentos de auditoria incorretos. Os auditores não estão acostumados a coletar e incorporar dados não financeiros de fontes não tradicionais, como e-mails e redes sociais.
Brown-Liburd et al. (2015); Alles & Gray (2016)	A dificuldade de reconhecer padrões de evidência. Em vez de explicar a causalidade, a análise do Big Data concentra-se nas correlações por meio da pesquisa de padrões que podem ajudar a prever ocorrências futuras.
Brown-Liburd et al. (2015)	Sobrecarga de informações: informações excessivas podem tornar o processo de tomada de decisão menos eficiente e eficaz, levando a decisões incorretas e dificuldades em reconhecer a correlação entre detalhes e a perspectiva global.
Moffitt & Vasarhelyi (2013)	Os auditores podem ter que sugerir novos processos de verificação devido à impossibilidade de auditar grandes sistemas de dados em sua forma atual.

Fonte: Elaborado pelo autor

## 2.5 Caminhos de expansão de BDA

Este estudo propõe uma conceituação dos caminhos de expansão da adoção de BDA nas práticas de AI em duas dimensões (tipo de dados e tipos de ferramentas de TI), com base nos modelos propostos por Alles e Gray (2016) e Richins et al. (2017), fornecendo um modelo composto por quatro células (Figura 3):

Figura 3 – Caminhos de expansão do BDA na AI

		Ferramentas de TI	
		Tradicional	Expandida
Tipos de Dados	Tradicional	[Célula A] CDA com dados estruturados	[Célula C] EDA com dados estruturados
	Expandida	[Célula B] CDA com dados semi-estruturados e não estruturados	[Célula D] EDA com dados semi-estruturados e não estruturados

Fontes: adaptado de Alles e Gray (2016) e Richins et al. (2017)

A maioria das técnicas de análise de dados na AI concentra-se na Análise Confirmatória de Dados (CDA), que pode avaliar com precisão se um objetivo de auditoria predefinido foi alcançado, mas é incapaz de descobrir riscos não previstos nos objetivos de auditoria. Por outro lado, a Análise Exploratória de Dados (EDA) concentra-se no reconhecimento de padrões e geração de hipóteses a partir de um conjunto de dados brutos, incluindo visualização de dados e técnicas de mineração de dados, como análise de agrupamento e associação, técnicas de mineração de texto, análise de redes sociais e mineração de processos (Liu, 2014).

As ferramentas de TI são classificadas em dois grupos: (a) Tradicional: ferramentas de sistemas CAATs, ACL, IDEA, ERP, ETL (Extrair, Transformar e Carregar), linguagens SQL, execução de consultas e auditoria contínua; e (b) Expandida: visualização de dados (Qlikview, Tableau), linguagens de programação e modelagem estatística (SAS, R, Python, SPSS) e plataformas de inteligência artificial e aprendizado de máquina (IBM Watson, Microsoft Azure). Da mesma forma, os tipos de dados podem ser classificados em dois grupos: (a) Tradicional: dados financeiros e não financeiros obtidos dos bancos de dados estruturados da empresa; e (b) Expandida: dados de arquivos no formato XML e XBRL, dados em linguagem natural, dados estruturados externos à empresa (Exemplo: SERASA), dados não estruturados externos à empresa (páginas do site, mensagens nas redes sociais), imagem ou dados de vídeo (reconhecimento facial e identificação de documento), dados de áudio para análise de sentimentos (canal de comunicação).

## 2.6 UTAUT

A literatura apresenta estudos para compreender como e por que os indivíduos adotam novas tecnologias de 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 de uso ou comportamento de uso, enquanto outras correntes concentram-se no sucesso da implementação no nível organizacional (Venkatesh et al., 2003). 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, 2010; Ahmi, 2012; Gonzalez et al., 2012; Bierstaker et al., 2014; Curtis & Payne, 2014; Mahzan, 2014; Pedrosa, 2015; Nascimento, 2019).

Venkatesh et. al. (2003) teorizaram que os graus de Expectativa de Desempenho (ED), Expectativa de Esforço (EE), Influência Social (IS) influenciam diretamente a extensão da Intenção de Uso (IU), enquanto que presume-se que o grau de Intenção de Uso (IU) e Condições Facilitadoras (CF) determine diretamente o uso inicial de uma tecnologia, portanto, o Comportamento de Uso (CO). Assim, a intenção de uso de uma nova tecnologia está relacionada à perspectiva do indivíduo em relação a eventos futuros (ED, EE, IS, CF), considerando que a motivação deles é influenciada de acordo com as expectativas dos resultados desses eventos. Os quatro moderadores Gênero, Idade, Experiência e Voluntariedade de uso são propostos para influenciar a relação entre as variáveis independentes e dependentes.

### 2.6.1 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 The 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, 2010). 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: **H<sub>1</sub>**: A Expectativa de Desempenho afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

### 2.6.2 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. Assim, a segunda hipótese proposta neste estudo é: **H<sub>2</sub>**: A Expectativa de Esforço afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

### 2.6.3 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, 2010). A noção de influência social é bem fundamentada na literatura da Psicologia, onde os resultados de estudos de prestação de contas mostraram que as decisões individuais são frequentemente influenciadas pelas visões conhecidas dos superiores (Curtis & Payne, 2008). 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: **H<sub>3</sub>**: A Influência Social afeta positivamente a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

#### 2.6.4 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 organizacionais (conhecimento, recursos e oportunidades) que podem remover barreiras ao uso de um sistema. 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. 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 e Bala (2008) sugeriram que CF está indiretamente associado à intenção de uso pelo caminho da facilidade de uso percebida (EE) até a utilidade percebida. 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.

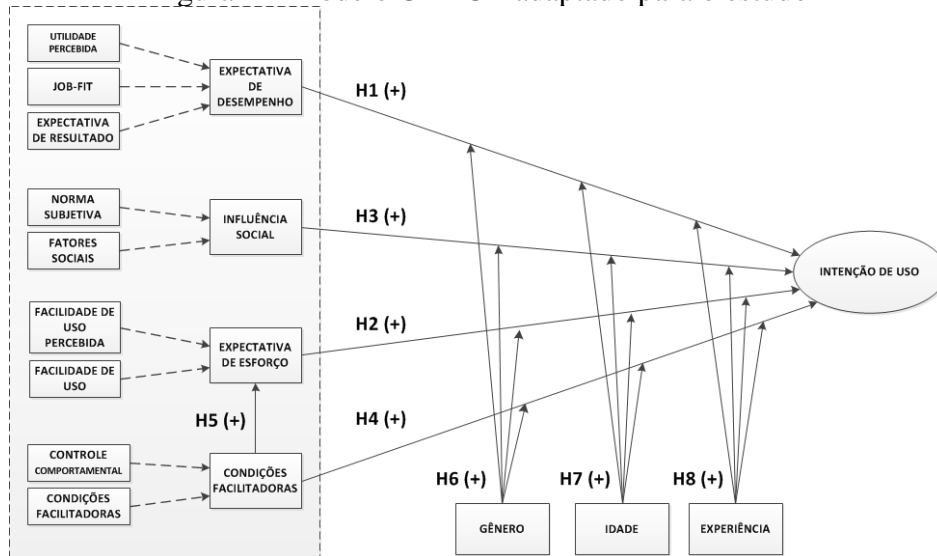
#### 2.6.5 Gênero, Idade, Experiência e Voluntariedade

Este estudo investiga se Gênero, Idade e Experiência têm efeito moderador em todas as relações entre os quatro construtos (ED, EE, IS, CF) e a variável dependente Intenção de Uso (IU). 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; e **H8**: A Experiência impacta a intenção dos auditores internos para a adoção de soluções tecnológicas de BDA.

#### 2.6.6 O modelo UTAUT adaptado

A Figura 4 apresenta o modelo teórico deste estudo, com seus conceitos, construtos e hipóteses, elaborado com base no modelo UTAUT. Estudos exploratórios que não visam examinar o comportamento de uso (CO) pressupõem que CF influencia diretamente a Intenção de Uso (IU) dos usuários (Gonzalez et al., 2012; Nascimento, 2019). Além disso, a variável de controle Voluntariedade de Uso não foi considerada relevante para o contexto deste estudo, assumindo que o comportamento dos auditores internos seja voluntário (Curtis & Payne, 2014; Bierstaker et al., 2014; Nascimento, 2019).

Figura 4 – Modelo UTAUT adaptado para o estudo



Fonte: Elaborado pelo autor

### 3 MÉTODO DE PESQUISA

A abordagem quantitativa do presente estudo é quantitativa, utilizando a coleta de dados para testar hipóteses com base na análise estatística para estabelecer padrões e provar teorias. Adotou-se uma pesquisa online para coletar os dados e testar o modelo de pesquisa, composto por três grupos de perguntas. O primeiro grupo foi desenvolvido para capturar o perfil demográfico dos entrevistados: idade, gênero e formação acadêmica; anos de experiência profissional em AI; certificações profissionais; tipo, localização geográfica, número de funcionários e receita anual da empresa; habilidades de TI adquiridas; e interesse em eventos sobre inovações tecnológicas. O segundo grupo contém itens sobre os tipos de dados e ferramentas de TI usados nas práticas atuais de AI, medidos por uma escala de intensidade de uso, com base nos elementos do modelo de caminhos de expansão do BDA (Figura 3). Finalmente, o terceiro grupo refere-se aos fatores que influenciam a intenção dos auditores internos em adotar soluções de BDA, com base na teoria, constructos e indicadores da UTAUT, aplicando a escala Likert de cinco pontos entre 1 (discordo totalmente) e 5 (concordo totalmente).

A população deste estudo é composta por 1.500 auditores internos que atuam em empresas do setor privado brasileiro cadastradas com um perfil do LinkedIn, uma rede social para uso estritamente profissional. As respostas foram coletadas por meio do questionário on-line desenvolvido na plataforma Google Forms. Antes da pesquisa principal, um estudo piloto foi realizado com a distribuição de questionários a profissionais de AI e estudantes de pós-graduação para garantir a confiabilidade e a validade das medidas. A amostra final de 305 respondentes atendeu aos critérios da análise de poder estatístico, que calculou um tamanho amostral de 267 respondentes com poder estatístico de 0,95, superior ao mínimo de 0,80 recomendado por Hair et al. (2014), indicando maior consistência do modelo.

#### 3.1 DESCRIÇÃO DA AMOSTRA

Os dados demográficos revelam que a maior parte dos entrevistados são do sexo masculino (70,8%), com idades entre 29 e 39 anos (53,77%), sendo a idade média de 36,5



anos, a idade mínima de 24 anos e a idade máxima de 63 anos. Em relação aos anos de experiência profissional como auditor interno, 33,12% estão na faixa de 5 a 9 anos, seguidos por respondentes com experiência entre 10 e 19 anos (29,51%) e menos de 5 anos (26,23%), enquanto 11,14% possuem mais de 19 anos de experiência. A certificação profissional com o maior número de ocorrências é a CIA (*Certified Internal Auditor*) (4,59%) enquanto que 78,36% não possuem certificação.

Todos os respondentes possuem diploma de curso superior, especialmente nas áreas de Contabilidade (40,66%) e Administração (37,05%). A maioria dos respondentes possui pós-graduação nas áreas de Contabilidade (20,98%) e Administração (20,98%), considerando também que 28,85% não possuem pós-graduação. Desse modo, o caráter multidisciplinar da AI é observado na alta concentração dos cursos de Contabilidade e Administração em relação a outras áreas como Sistemas de Informação e Engenharia.

Com relação às empresas nas quais os entrevistados operam, 48,5% são organizações de grande porte, com mais de 5.000 funcionários e 55,1% apresentam receitas anuais superiores a R\$ 1 bilhão. As organizações do setor privado representam 53,8% dos casos, seguidas pelas empresas de capital aberto (42,6%). As empresas estão concentradas predominantemente na região Sudeste do Brasil, principalmente no estado de São Paulo (70,2%). Por outro lado, não foram encontrados registros nos seguintes estados: Acre, Alagoas, Amapá, Amazonas, Espírito Santo, Mato Grosso, Pará, Piauí, Rondônia, Roraima, Sergipe e Tocantins.

Dentre as formas pelas quais os auditores internos adquirem conhecimentos e habilidades em TI, a que mais se destacou foi o treinamento fornecido por suas empresas (47,87%). A maioria dos entrevistados (87,2%) relatou ter participado ou ter interesse em participar de eventos relacionados a inovações tecnológicas em AI, como seminários e congressos organizados pelo The IIA Brasil.

O segundo grupo de respostas mostra que o ERP (81,90%) é a ferramenta de TI com maior frequência de uso pelos respondentes da amostra, seguido por CAATs como ACL e IDEA (55,10%) e auditoria contínua (54,20%). As ferramentas avançadas de TI não utilizadas, como inteligência artificial e aprendizado de máquina (75,70%), modelagem estatística e linguagens de programação (64,90%), ETL (54,10%) e visualização de dados (45,20%), apresentaram também baixa frequência de uso entre os demais respondentes. Os tipos de dados com maior frequência de utilização são dados não financeiros (89,90%), dados financeiros (88,20%) e arquivos XML ou XBRL (66,30%), dados em linguagem natural (60,40%), dados estruturados externos à empresa (49,80%), dados não estruturados externos à empresa (40,60%). Os demais tipos de dados, como os dados de imagem ou vídeo (56,40%) e de áudio para análise de sentimentos (44,30%) não são utilizados por parte dos respondentes. As atividades de AI executadas com o uso de ferramentas e tipos de dados de TI com maiores frequências incluem testes de auditoria (92,80%), obtenção de evidência de auditoria (89,40%), avaliação de controle interno (88,20%), amostragem estatística (83,30%), avaliação de risco de auditoria (81,00%), análise e recuperação de pagamentos duplicados (75,80%), análise de segregação de funções (75,00%) e, menos utilizada, tarefa de circularização (51,50%).

### **3.2 ANÁLISE DE DADOS**

As hipóteses estabelecidas nesta pesquisa foram testadas por modelagem de equações estruturais (MEE), uma técnica de análise multivariada usada para explicar relações de dependência múltipla e inter-relacionada, combinando aspectos da análise fatorial e análise de regressão múltipla com a utilização do *software* SmartPLS. A

abordagem de MEE selecionada para este trabalho é a dos Mínimos Quadrados Parciais (*Partial Least Squares Path Modeling* – PLS-PM). 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 tradicionais, sendo assim descrita como “modelagem suave” (*soft modeling*) (Hair et al., 2014). A análise de dados deve ser conduzida em basicamente dois momentos: a análise do modelo de mensuração e a análise do modelo estrutural.

## 4 RESULTADOS

### 4.1 MODELO DE MENSURAÇÃO

Inicialmente, a Validade Convergente é obtida pela observação da Variância Média Extraída (AVE). A análise da Tabela 1 mostra que todos os constructos apresentaram valores de AVEs maiores que 0,50, indicando que o modelo converge para um resultado satisfatório (Fornell & Larcker, 1981). O próximo passo consiste em observar a confiabilidade composta (CC), o rho de Dillon-Goldstein e os valores de consistência interna indicados pelo alfa de Cronbach (AC). Tanto o AC quanto a CC são usados para avaliar se a amostra está livre de vieses ou mesmo se as respostas são confiáveis. Os valores de CC e AC são superiores a 0,70, sendo assim, considerados satisfatórios (Hair et al., 2014).

Tabela 1 – Validade Convergente, Consistência Interna e Confiabilidade Composta

Construtos	Alfa de Cronbach	rho_A	Confiabilidade Composta	Variância Média Extraída (AVE)
<b>Condições Facilitadoras</b>	0,687	0,701	0,827	0,615
<b>Expectativa de Desempenho</b>	0,869	0,874	0,906	0,658
<b>Expectativa de Esforço</b>	0,818	0,837	0,877	0,642
<b>Influência Social</b>	0,845	0,848	0,896	0,683
<b>Intenções comportamentais</b>	0,906	0,907	0,941	0,842

Fonte: Elaborado pelo autor

O Fator de Inflação de Variância (VIF) quantifica a gravidade da colinearidade entre os indicadores, que deve ser menor que 5 (e os valores de tolerância abaixo de 0,20) (Hair et al., 2014). Conforme mostrado na Tabela 2, os indicadores VIF determinam que a multicolinearidade não é uma preocupação pois todos os valores estão abaixo de 5,0.

Tabela 2 – Fator de Inflação da Variância (VIF) dos Construtos

Construtos	Condições Facilitadoras	Expectativa de Desempenho	Expectativa de Esforço	Influência Social	Intenção de Uso
<b>Condições Facilitadoras</b>			1		3,099
<b>Expectativa de Desempenho</b>					1,868
<b>Expectativa de Esforço</b>					2,489
<b>Influência Social</b>					2,520

Fonte: Elaborado pelo autor

A Validade Discriminante (DV) é entendida como um indicador de que os constructos ou variáveis latentes são independentes entre si (Hair et al., 2014). O critério Fornell e Larcker (1981) é considerado o mais conservador para DV e compara as raízes quadradas dos valores de AVE de cada construto com as correlações entre as variáveis latentes (VLs).

Tabela 3 – Raiz quadrada da AVE

Construtos	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 raízes quadradas dos AVEs são maiores que as correlações mais altas entre os constructos, conforme apresentamos nas tabelas 3 e 4, sugerindo que os constructos são independentes um do outro.

Tabela 4 – Correlação das Variáveis Latentes (VLs)

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

Os Indicadores não apresentaram Fatores de Inflação de Variância (*outer VIF values*) acima de 5,0, indicando que o modelo não apresenta problemas de multicolinearidade. O modelo atende também ao critério de Validade Discriminante (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 5).

Tabela 5 – VIF e VD dos Indicadores

Indicadores	VIF	CF	ED	EE	IS	IU
CF 4. Os recursos necessários para usar ferramentas de BDA no trabalho estão disponíveis para mim.	1,546	0,848	0,421	0,543	0,714	0,637
CF14. Eu tenho conhecimento adequado para usar ferramentas de BDA.	1,275	0,773	0,432	0,740	0,400	0,379
CF 9. Um profissional ou equipe de suporte está disponível	1,356	0,726	0,303	0,413	0,572	0,481

para me auxiliar.

ED 1. O uso de ferramentas de BDA é útil para o meu trabalho.	1,738	0,397	0,788	0,442	0,519	0,555
ED 6. O uso de ferramentas de BDA permite que eu conclua as tarefas mais rapidamente.	1,923	0,419	0,790	0,495	0,486	0,480
ED19. O uso de ferramentas de BDA aumenta a minha produtividade.	2,780	0,444	0,874	0,517	0,535	0,552
ED15. O uso de ferramentas de BDA melhora a qualidade do meu trabalho.	2,648	0,413	0,865	0,482	0,473	0,531
ED12. Tenho mais chance de obter reconhecimento profissional com o uso de ferramentas de BDA.	1,617	0,343	0,731	0,389	0,481	0,467
EE 5. A minha interação com ferramentas de BDA ocorre de forma clara e compreensível.	1,428	0,727	0,476	0,785	0,629	0,606
EE16. Seria fácil tornar-me habilidoso no uso de ferramentas de BDA.	1,868	0,474	0,513	0,758	0,331	0,395
EE 8. Eu considero as ferramentas de BDA fáceis de usar.	1,987	0,570	0,417	0,833	0,413	0,377
EE11. Aprender a utilizar ferramentas de BDA é fácil para mim.	2,258	0,502	0,427	0,825	0,323	0,398
IS13. Pessoas que exercem influência sobre o meu comportamento acham que eu devo utilizar as ferramentas de BDA no meu trabalho.	2,193	0,511	0,572	0,477	0,835	0,569
IS 3. Pessoas importantes para mim acham que eu devo utilizar as ferramentas de BDA no meu trabalho.	2,065	0,483	0,507	0,400	0,823	0,632
IS 7. A gerência da área de auditoria interna incentiva o uso de ferramentas de BDA.	2,117	0,655	0,523	0,476	0,855	0,671
IS17. Em geral, a empresa tem dado suporte para o uso de ferramentas de BDA.	1,805	0,708	0,435	0,495	0,791	0,597
IU 2. Eu planejo utilizar ferramentas de BDA no trabalho nos próximos meses.	2,936	0,590	0,579	0,510	0,684	0,915
IU10. Eu tenho intenção em utilizar ferramentas de BDA em meu trabalho nos próximos meses.	2,731	0,553	0,606	0,537	0,666	0,907
IU20. Eu irei utilizar ferramentas de BDA no trabalho nos próximos meses.	3,352	0,609	0,577	0,538	0,712	0,931

Fonte: Elaborado pelo autor

## 4.2 MODELO ESTRUTURAL

Na primeira etapa da análise do modelo estrutural, a medida mais utilizada é o coeficiente de determinação de Pearson ( $R^2$ ), que avalia a porção de variância das variáveis endógenas explicadas pelo modelo estrutural, indicando a qualidade do modelo ajustado (Ringle et al., 2014). Cohen (1988) sugere  $R^2 = 0,02$  como efeito pequeno,  $R^2 = 0,13$  como efeito médio e  $R^2 = 0,26$  como efeito grande. Assim, as variáveis dependentes da Expectativa de Esforço ( $R^2 = 0,537$ ) e da Intenção de Uso ( $R^2 = 0,631$ ) indicam grande efeito do modelo ajustado. Em seguida, são avaliados os valores de dois outros indicadores da qualidade do ajuste do modelo. O indicador Stone-Geisser avalia a qualidade da previsão do modelo, com valores  $Q^2 > 0$  indicando que o modelo está próximo do esperado (Hair et al., 2014), considerando que um modelo perfeito ( $Q^2 = 1$ ) teria que refletir a realidade sem erros. Assim, a validade preditiva ( $Q^2 = 0,50$ ) foi obtida usando a técnica de *blindfolding*. O Indicador de Cohen é obtido adicionando e removendo construções do modelo, uma por uma, verificando se o construto exógeno omitido tem um impacto substantivo em construtos endógenos, para avaliar o quanto cada construto é relevante para ajustar o modelo (Ringle et al., 2014; Hair et al., 2014). Os valores do tamanho do efeito ( $f^2$ ) de 0,02, 0,15 e 0,35 são considerados pequenos, médios e grandes, respectivamente

(Hair et al., 2014). A Tabela 6 mostra que a Influência Social (IS) tem efeito médio (0,234), enquanto os demais construtos apresentam efeitos pequenos (abaixo de 0,02).

Tabela 6 – Tamanho do Efeito ( $f^2$ )

Construtos	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

Em seguida, uma vez concluída a avaliação da qualidade do ajuste, os coeficientes do caminho são interpretados com o uso da técnica de reamostragem de *bootstrapping*, calculada com 1000 subamostras, a fim de avaliar a significância dos coeficientes estruturais. Coeficientes estruturais próximos a +1 indicam uma forte relação positiva, enquanto aqueles próximos a -1 indicam uma forte relação negativa, de modo que, quanto mais próximos de 0 dos coeficientes estimados, mais fracos serão os relacionamentos. Conforme mostrado na Tabela 7, a variável dependente Intenção de Uso (IU) recebe contribuições 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 uma influência considerável no IU. Os construtos CF e EE apresentam coeficientes estruturais de 0,115 e 0,092, com baixa influência no IU. As relações entre ED e IS com IU foram estatisticamente significantes ( $p < 0,05$ ), enquanto EE e CF não apresentaram significância estatística em relação a IU, respectivamente. O coeficiente estrutural da relação entre CF e EE foi de 0,733 com alto nível de significância.

Tabela 7 – Valores de significância (Construtos)

Caminho Estrutural	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	6,77	0,000

Fonte: Elaborado pelo autor

Em uma análise adicional, a técnica de *bootstrapping* foi usada para observar os efeitos moderadores de Gênero, Idade e Experiência em todas as relações entre ED, EE, IS, CF e IU para verificar se essa diferença é determinante na aceitação de novas tecnologias. De acordo com os resultados apresentados na Tabela 8, nenhum dos relacionamentos moderadores tem efeitos significativos.

Tabela 8 – Valores de significância (Variáveis Moderadoras)

Coeficientes de Caminho	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
Cargas Externas	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

### 4.3 DISCUSSÃO DOS RESULTADOS

Os resultados da análise do modelo de equações estruturais por meio do método de mínimos quadrados parciais (PLS) demonstraram 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) (**H<sub>1</sub>** e **H<sub>3</sub>**), indicando que os auditores internos estão mais dispostos a utilizar BDA quando percebem que os benefícios obtidos com o uso dessa ferramenta aumentam 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 (**H<sub>2</sub>** e **H<sub>4</sub>**). Esses resultados podem indicar que BDA ainda está no processo inicial de disseminação e prática entre pesquisadores e profissionais de AI (Gepp et al., 2018) e pela não observação das CF (infraestrutura, suporte e treinamento internos e externos à organização) nas empresas em que os auditores internos atuam. Desse modo, considerando que as análises estatísticas também revelaram uma relação positiva e significativa entre CF e EE (**H<sub>5</sub>**), os resultados sugerem que os respondentes reconhecem que a disponibilidade de recursos (infraestrutura, suporte e treinamento) torna o uso de BDA mais fácil e claro; no entanto, eles não confirmam 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 (**H<sub>6</sub>**, **H<sub>7</sub>** e **H<sub>8</sub>**) não foram suportadas.

## 5 COMENTÁRIOS FINAIS

Este estudo procurou investigar o desenvolvimento da profissão de AI, sua relevância para as organizações e o importante papel que a BDA pode desempenhar no processo de evolução de suas práticas. No geral, este estudo constatou que os construtos do modelo UTAUT foram um ponto de partida útil na identificação das principais dimensões que contribuem para a intenção de adoção de BDA, de acordo com a percepção dos auditores internos em empresas do setor privado brasileiro.

A análise descritiva revelou o uso predominante de análise de dados e ferramentas tecnológicas tradicionais na AI pelos respondentes da pesquisa, sendo os sistemas ERP apontados com a maior frequência de uso (81,90%) no contexto atual. Por outro lado, os tipos mais avançados de tecnologias associados a BDA, apresentaram baixas frequências de uso.

De acordo com Alles (2015), o ERP tornou-se presente em todos os aspectos da empresa e passou a determinar como os negócios eram executados e seus registros mantidos e, assim, os auditores começaram a realizar o seu trabalho por meio desses sistemas. O autor considera que a profissão de AI poderá responder positivamente à oportunidade de adotar BDA, por iniciativa própria, ou adotá-lo como a uma reação defensiva diante da pressão de seus clientes, à medida que BDA torna-se tão importante para a operação dos negócios quanto os sistemas ERP na década anterior.

A contribuição teórica deste estudo refere-se à aplicabilidade do modelo UTAUT adaptado ao contexto da auditoria, possibilitando abordagens específicas em pesquisas futuras. O construto Comportamento de Uso (CO) não foi considerado neste estudo devido à sua natureza exploratória e ao foco na intenção do usuário. Assim, Condições Facilitadoras (CF) tornou-se um dos preditores de Intenção de Uso (IU), juntamente com Expectativa de Desempenho (ED), Expectativa de Esforço (EE) e Influência Social (IS). No entanto, os resultados dos testes estatísticos não apoiaram a relação entre Condições Facilitadoras (CF) e Intenção de Uso (IU). Tais resultados estão alinhados com estudos anteriores (Gonzalez et al., 2012; Curtis & Payne, 2014; Nascimento, 2019), bem como com a premissa de UTAUT de que CF torna-se insignificante na previsão de IU quando os construtos de ED e EE estão presentes no modelo (Venkatesh et al., 2003).

Os resultados também indicaram que a relação entre CF e EE é positiva e significativa, assim como os estudos de Curtis e Payne (2014) e Nascimento (2019). No entanto, essa relação CF e EE é pouco explorada por estudos que aplicaram versões adaptadas do modelo UTAUT original. Além disso, supunha-se que Gênero, Idade, Experiência teriam efeito moderador em todas as relações entre as variáveis dependentes e independentes. Ao contrário, nenhuma das variáveis moderadoras apresentou efeito significativo, sendo consistente com estudos anteriores (Curtis & Payne, 2008; Bierstaker et al., 2014; Al-Hiyari, Said & Hattab, 2019; Nascimento, 2019).

No que diz respeito às contribuições práticas, são fornecidas as principais dimensões que contribuem para a aceitação do BDA pelos auditores internos. Espera-se que o modelo possa ter impacto no papel das empresas em planejar os esforços para incentivar a adoção plena de BDA, incluindo treinamento, marketing e infraestrutura e suporte técnico (Bierstaker et al., 2014). A maioria dos entrevistados informou adquirir conhecimentos e habilidades de TI a partir de programas de treinamento oferecidos pelas empresas em que trabalha (47,87%), seguidos por cursos externos (16,72%). De acordo com Kim, Mannino e Nieschwietz (2009), o treinamento é o fator mais influente na aceitação da tecnologia na AI. O desenvolvimento de programas de treinamento é importante para aumentar as expectativas dos auditores sobre o quão bem as tecnologias

podem melhorar seu desempenho (ED) e sua percepção da facilidade de uso (EE) (Bierstaker et al., 2014; 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). Além disso, os auditores não usam tecnologia se a empresa não possui uma equipe de TI qualificada (Kim, Mannino e Nieschwietz, 2009). Assim, recomenda-se às organizações a manutenção de uma equipe de suporte técnico para a AI, composta por indivíduos altamente proficientes em tecnologias de BDA (Tang, Norman & Vandrzyk, 2017).

Os achados também podem trazer contribuições para o The IIA Brasil no que diz respeito à elaboração de estratégias de educação profissional contínua e de certificações profissionais. Embora a maioria dos entrevistados (87,2%) participe ou esteja interessada em participar de eventos relacionados a inovações tecnológicas como o BDA, 4,59% dos entrevistados possuem o CIA (*Certified Internal Auditor*), enquanto 78,36% não possuem certificações profissionais. Além disso, verificou-se também que os respondentes da pesquisa estão concentrados de forma predominante no estado de São Paulo.

Com relação às instituições de ensino superior, este estudo pode fornecer aos alunos de graduação conhecimento sobre os aspectos introdutórios de AI e tecnologias de BDA, além de contribuir para o planejamento de programas de disciplinas, principalmente em cursos de Contabilidade e Administração.

Dentre as limitações do presente estudo, pode-se considerar a natureza não probabilística da amostra, composta por respostas coletadas espontaneamente e por conveniência e, sendo a pesquisa um tipo de estudo transversal, os resultados não podem ser generalizados para todos os profissionais de AI do setor privado brasileiro. Quanto ao contexto voluntário da adoção de TI, os respectivos resultados não podem ser generalizados para configurações de adoção obrigatória (Venkatesh et al., 2003).

As pesquisas futuras podem ser direcionadas para examinar o comportamento de uso real e a pós-adoção de soluções de BDA pela AI, com a possibilidade de avaliar aspectos do uso da tecnologia em diferentes setores do mercado. A Internet das Coisas (IoT), estratégia digital e 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). Portanto, é importante produzir e avançar o conhecimento sobre a integração de BDA com outras tecnologias e seus impactos na profissão de AI.

## REFERÊNCIAS

- 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., & Hattab E. (2019). Factors that influence the use of computer assisted audit techniques (CAATs) by Internal Auditors in Jordan. ISSN: 1096-3685.
- 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.
- 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
- 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., 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.adiac.2013.12.005.
- Braun, R., & Davis, H. (2003). Computer-assisted audit tools and techniques: Analysis and perspectives. *Managerial Auditing Journal*, 725-731. DOI: 10.1108/02686900310500488.
- Brown-Liburud, 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.
- 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-Liburud, H.L., & Teeter, R.A. (2018). CONTINUOUS AUDITING: THEORY AND APPLICATION.
- 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
- Connolly, S. (2012). 7 key drivers for the Big Data market. Blog Posting May 15th. <http://connollyshaun.blogspot.com/>.
- 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.
- 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.
- 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.

- Ernest & 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.
- 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.
- 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
- 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*.
- 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.
- Hass, S., Abdolmohammadi, M. J. & Burnaby, P. (2006). The Americas literature review on internal auditing. *Managerial Auditing Journal*, 835–44. DOI: 10.1108/02686900610703778.
- 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.
- Institute of Internal Auditors. The 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.
- Janvrin, D., Bierstaker, J., & 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.
- 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.

- KPMG. (2018). Automação inteligente e Auditoria Interna: Considerações para a avaliação e a implementação da automação inteligente. KPMG Assessores Ltda.
- Kuenkaikaew, S. (2013). Predictive Audit Analytics: Evolving to a New Era. PhD Dissertation, Rutgers Business School.
- 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.
- Liu, Q. (2014). *The application of exploratory data analysis in auditing*. Doctoral dissertation, Rutgers University Graduate School, Newark, NJ.
- 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. (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.
- Mahzan, N., & Lymer, A. (2010). Adoption of Computer Assisted Audit Tools and Techniques (CAATs) by Internal Auditors: Current issues in the UK.
- 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.
- Markus, M. L., & Topi, H. (2015). Big data, big decisions for science, society, and business: report on a research agenda setting workshop. ACM Technical Report. <<http://dl.acm.org/citation.cfm?id=2849516>> (accessed 09.05.2017).
- 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.
- McNamee, D., & McNamee, T. (1995). The transformation of internal auditing. *Managerial Auditing Journal*. DOI: 10.1108/02686909510079639
- 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.
- Moscove, S. A., Simkim, M. G., & Baganoff, N. A. (2002). *Sistemas de informações contábeis*. São Paulo: Atlas, 2002.
- 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.
- 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.
- 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.
- 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.

- 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/isys-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.
- 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.
- Sawyer, L. B. (1988). *Sawyers' Internal Auditing*, Institute of Internal Auditors, Altamonte Springs, FL.
- 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.
- Tang, F., Norman, C.S., & Vandrzyk, V. P. (2017). Exploring perceptions of data analytics in the internal audit function. *Behaviour & Information Technology*, 36(11), 1125-1136.
- 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
- 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., 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.
- 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.
- Wang, T., & Cuthbertson, R. (2015). Eight issues on audit data analytics we would like researched. *Journal of Information Systems*. 29 (1), 155-162. DOI: 10.2308/isys-50955.
- 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.
- Yoon, K., Hoogduin, L., & Zhang, L. (2015). Big data as complementary audit evidence. *Accounting Horizons*, 431-438. DOI: 10.2308/acch-51076.