

# FÓRUM

Submetido 26.09.2018. Aprovado 19.07.2019

Avaliado pelo sistema *double blind review*. Editores Científicos Convidados: Eduardo de Rezende Francisco, José Luiz Kugler, Soong Moon Kang, Ricardo Silva e Peter Alexander Whigham

Versão traduzida

DOI: <http://dx.doi.org/10.1590/S0034-759020190605>

## INTENÇÃO DE ADOÇÃO DE *BIG DATA* NA CADEIA DE SUPRIMENTOS: UMA PERSPECTIVA BRASILEIRA

*Intention to adopt big data in supply chain management: A Brazilian perspective*

*Intención de adopción de big data en la cadena de suministros: Una perspectiva brasileña*

### RESUMO

As aplicações de *big data* têm remodelado vários modelos de negócios e provocado grandes transformações na gestão da cadeia de suprimentos (GCS). Apoiado pela literatura emergente de *big data*, GCS e teoria unificada de aceitação e uso de tecnologia (UTAUT), este estudo tem como objetivo avaliar as variáveis que influenciam os profissionais brasileiros que atuam na GCS a adotar *big data*. Assim, nós adaptamos e validamos um modelo UTAUT previamente desenvolvido. Um total de 152 profissionais que atuam na gestão de cadeias de suprimentos revelou que condições facilitadoras (como a infraestrutura de TI) têm uma grande influência na adoção de *big data*. Por outro lado, a influência social e a expectativa de desempenho não apresentaram efeito significativo. Este estudo contribui para a prática, com conhecimentos valiosos para os tomadores de decisão que estão considerando projetos de *big data*. Além disso, ele ajuda a minimizar a lacuna em relação aos estudos de *big data* no contexto brasileiro.

**PALAVRAS-CHAVE** | *Big data*, gestão da cadeia de suprimentos, adoção, survey, partial least squares structural equation modeling, PLS-SEM.

### ABSTRACT

*Big data applications have been remodeling several business models and provoking strong radical transformations in supply chain management (SCM). Supported by the literature on big data, supply chain management, and the unified theory of acceptance and use of technology (UTAUT), this study aims to evaluate the variables that influence the intention of Brazilian SCM professionals to adopt big data. To this end, we adapted and validated a previously developed UTAUT model. A survey of 152 supply chain respondents revealed that facilitating conditions (e.g., IT infrastructure) have a high influence on their intention to adopt big data. However, social influence and performance expectancy showed no significant effect. This study contributes to the practical field, offering valuable insights for decision-makers considering big data projects. It also contributes to the literature by helping minimize the research gap in big data in the Brazilian context.*

**KEYWORDS** | *Big data*, supply chain management, adoption, survey, partial least squares structural equation modeling, PLS-SEM.

### RESUMEN

*Las aplicaciones de big data han estado remodelando varios modelos de negocios y han provocado fuertes transformaciones en la cadena de suministro (CS). Con el apoyo de la literatura de big data, CS y la teoría unificada de aceptación y uso de la tecnología (UTAUT), este estudio tiene objetivo evaluar las variables que afectan a los profesionales brasileños para adoptar big data. Por lo tanto, adaptamos y validamos un modelo UTAUT previamente desarrollado. Un total de 152 encuestados de CS revelaron que las condiciones de facilitación (por ejemplo, la infraestructura de TI) tienen una gran influencia en la adopción de big data. Por otro lado, la influencia social y la expectativa de desempeño no mostraron un efecto significativo. Este estudio contribuye a la práctica, con información valiosa para los responsables de la toma de decisiones que están considerando proyectos de big data. Además, ayudamos a minimizar la brecha con respecto a los estudios de big data en el contexto brasileño.*

**PALABRAS CLAVE** | *Big data*, gestión de la cadena de suministro, adopción, survey, partial least squares structural equation modeling, PLS-SEM.

**MACIEL M. QUEIROZ<sup>1</sup>**

maciel.queiroz@docente.unip.br

ORCID: 0000-0002-6025-9191

**SUSANA CARLA FARIAS PEREIRA<sup>2</sup>**

susana.pereira@fgv.br

ORCID: 0000-0002-3952-7489

<sup>1</sup> Universidade Paulista, Programa de Pós-graduação em Administração, São Paulo, SP, Brasil

<sup>2</sup> Fundação Getulio Vargas, Escola de Administração de Empresas de São Paulo, SP, Brasil

## INTRODUÇÃO

O rápido avanço de tecnologias da informação e comunicação (TICs) motivou profissionais e estudiosos de logística e cadeia de suprimentos (Zinn & Goldsby, 2017a, 2017b) a entender o que as organizações podem agregar com essas tecnologias. Uma tecnologia inovadora e impactante que surgiu recentemente é o *big data* (grande volume de dados) (Davenport, 2006; Manyika et al., 2011; Rotella, 2012). A quantidade de dados produzidos diariamente tem aumentado drasticamente nos últimos anos (Domo, 2017). Esse crescimento trouxe diversos desafios ao gerenciamento de dados. Nesse contexto, o *big data* é uma abordagem robusta para ajudar organizações a analisarem (Croll, 2015) grandes quantidades de dados e aprimorarem o processo de tomada de decisão (Abawajy, 2015).

A literatura considera o *big data* a “próxima grande inovação” (Gobble, 2013, p. 64) e “o quarto paradigma da ciência” (Strawn, 2012, p. 34), e que tem impacto em praticamente todos os modelos de negócios. Por exemplo, 35% da receita da Amazon.com é gerada utilizando *big data* (Wills, 2014), juntamente com a reformulação de atividades de *marketing* que coletam dados importantes sobre o comportamento dos consumidores em tempo real (Erevelles, Fukawa, & Swayne, 2016). Um campo que vem realizando esforços significativos para utilizar o *big data* é a gestão da cadeia de suprimentos (GCS) (Gunasekaran et al., 2017; Kache & Seuring, 2017; Richey, Morgan, Lindsey-Hall, & Adams, 2016; Wu et al., 2017; Zhao, Liu, Zhang, & Huang, 2017).

Apesar dos potenciais benefícios do emprego do *big data* no GCS (Hazen, Boone, Ezell, & Jones-Farmer, 2014; Kache & Seuring, 2017; Schoenherr & Speier-Pero, 2015), ainda há pouco conhecimento sobre *big data* e poucas iniciativas para adotá-lo no mercado brasileiro de GCS, e a literatura carece de fortes resultados empíricos (Queiroz & Telles, 2018). O estágio atual de utilização de *big data* constitui uma oportunidade para acadêmicos e profissionais preencherem essa lacuna. Por exemplo, até onde sabemos, nenhum estudo anterior analisou a intenção comportamental (IC) dos profissionais brasileiros de GCS de adotar *big data*, e o presente estudo visa preencher essa lacuna. Adaptamos um modelo previamente desenvolvido e validado de aceitação e uso de tecnologia (*Unified theory of acceptance and use of technology* - [UTAUT]) (Venkatesh, Morris, Davis & Davis, 2003; Queiroz & Wamba, 2019), incluindo um construto de confiança. Mais especificamente, este estudo responde à seguinte pergunta: Como as variáveis do modelo UTAUT explicam a IC dos profissionais brasileiros de GCS de adotar *big data*?

Para responder a essa pergunta, este trabalho baseia-se na literatura relacionada ao *big data* (Davenport, 2006; Manyika et al., 2011; Queiroz & Telles, 2018), GCS (Carter, Rogers, & Choi, 2015; Mentzer et al., 2001) e UTAUT (Queiroz & Wamba, 2019; Venkatesh et al., 2003; Venkatesh, Thong, & Xu, 2012) para desenvolver as hipóteses e o modelo. O modelo conceitual foi adaptado e validado utilizando modelos de equações estruturais de mínimos quadrados parciais (*partial least squares structural equation modeling* – PLS-SEM). As principais conclusões têm fortes implicações teóricas e gerenciais. Da perspectiva gerencial, verificamos que condições facilitadoras (exemplo: infraestrutura) exercem grande influência sobre a IC de adotar *big data*. Sob a ótica teórica, nossos resultados revelaram que a influência social e expectativa de desempenho não são bons preditores da IC de profissionais brasileiros de GCS em adotar *big data*.

Este artigo está organizado da seguinte forma. Inicialmente, apresentamos os principais fundamentos teóricos para estudos de *big data*, GCS e UTAUT. Em seguida, descrevemos as hipóteses, o modelo de pesquisa e metodologia, bem como a análise baseada em PLS-SEM. Discutimos as implicações gerenciais e teóricas, assim como as limitações do presente estudo e orientações para pesquisas futuras. Finalmente, as principais conclusões são destacadas.

## BASES TEÓRICAS

### *Big data*: Fundamentos, conceitos e desafios

O *big data* surgiu como uma TIC altamente inovadora. Uma definição abrangente e adequada de *big data* é “[...] conjuntos de dados cujo tamanho está além da capacidade das ferramentas de software de banco de dados de coletar, armazenar, gerenciar, e analisar” (Manyika et al., 2011, p. 1). Assim, o *big data* pode ser considerado uma abordagem robusta para analisar dados no contexto de decisões descritivas, prescritivas e preditivas (Phillips-Wren & Hoskisson, 2015). Essa abordagem é comumente chamada de *big data analytics* (BDA) e envolve uma abordagem de cinco Vs (volume, velocidade, variedade, veracidade e valor) (Queiroz & Telles, 2018; Wamba et al., 2017). Em outras palavras, o BDA usa estatísticas sofisticadas e modelos matemáticos e computacionais para analisar grandes volumes de dados e fornecer informações aos tomadores de decisão. Neste estudo, usamos a definição de *big data* proposta por Phillips-Wren e Hoskisson (2015) como a quantidade de dados que supera a capacidade das organizações de armazená-los e analisá-los para apoiar e melhorar o processo de tomada de decisão.

O volume de dados aumentou drasticamente nos últimos anos devido à variedade de dados produzidos (Bibri & Krogstie, 2017) (por exemplo, ERP, Twitter, Facebook, Google, LinkedIn, GPS, entre outros) e à velocidade da transmissão de dados (Munshi & Mohamed, 2017; Srinivasan & Swink, 2018). Esse cenário complexo impulsiona organizações a desenvolverem recursos específicos para armazenar, processar e analisar dados para auxiliar o processo de tomada de decisão. No entanto, criar valor não é uma tarefa fácil, principalmente porque a capacidade das organizações de processar e analisar dados é limitada. Além disso, confirmar a veracidade dos dados, que indica a sua qualidade e confiabilidade (Munshi & Mohamed, 2017; Nobre & Tavares, 2017), é um grande desafio para as empresas.

*Big data* está sendo utilizado no aprimoramento do GCS utilizando sistemas baseados em múltiplos agentes (Giannakis & Louis, 2016), otimização do GCS verde considerando materiais perigosos e emissão de carbono (Zhao et al., 2017), setor manufatureiro (Zhong, Newman, Huang, & Lan, 2016) e exploração de informações de GCS (Kache & Seuring, 2017). Foi demonstrado que o *big data* pode melhorar significativamente o desempenho das empresas (Akter, Wamba, Gunasekaran, Dubey, & Childe, 2016; Gunasekaran et al., 2017; Wamba, Akter, Edwards, Chopin, & Gnanzou, 2015; Wang, Gunasekaran, Ngai, & Papadopoulos, 2016).

## Gestão da cadeia de suprimentos e os impactos de tecnologias de ponta

Recentemente, os campos de logística e GCS foram impactados significativamente pelo crescimento exponencial do uso de TICs. Dessa forma, acadêmicos e empresários procuraram entender os possíveis efeitos e oportunidades de aplicar o GCS em seus modelos de negócios (Zinn & Goldsby, 2017a, 2017b). Nesse contexto, o GCS é definido como:

O gerenciamento de uma rede de relacionamentos dentro de uma empresa e entre organizações e unidades de negócios interdependentes, incluindo fornecimento de materiais, compras, produção, logística, marketing, e sistemas relacionados que facilitam o fluxo de materiais, serviços, finanças, e informações do produtor original ao cliente final com o objetivo de agregar valor, maximizar a lucratividade por meio de eficiências, e satisfazer o cliente. (Stock & Boyer, 2009, p. 706)

Além disso, o GCS pode ser considerado uma rede (Carter et al., 2015) e um sistema adaptativo complexo (Choi, Dooley e Rungtusanatham, 2001), e a crescente quantidade de dados tem aumentado essa complexidade. O uso de *big data* no GCS auxilia o processo de tomada de decisão, fornecendo informações relevantes sobre a dinâmica do sistema (por exemplo, padrões de compra de clientes, análise de custos e tendências de mercado). Análises descritivas e prescritivas robustas (Wang et al., 2016) têm melhorado significativamente o desempenho de empresas (Akter et al., 2016; Gunasekaran et al., 2017).

## Modelos de aceitação de tecnologia (MATs) e Teoria unificada de aceitação e uso de tecnologia (UTAUT)

Vários estudos avaliaram o desenvolvimento e disseminação da tecnologia da informação (TI) (Davis, 1989; Morris & Venkatesh, 2000; Venkatesh & Brown, 2001; Wamba, 2018) e valores e comportamentos individuais em relação à adoção e uso de TI (Mamonov & Benbunan-Fich, 2017; Youngberg, Olsen, & Hauser, 2009). O MAT é uma contribuição importante na adoção da tecnologia (Davis, 1989) e tem suas raízes na teoria da ação racional (Ajzen & Fishbein, 1980). Os fundamentos do MAT baseiam-se em duas variáveis: utilidade percebida e facilidade de uso percebida. Mais recentemente, Venkatesh et al. (2003) propuseram a consolidação das teorias do MAT que antecederam a UTAUT.

### UTAUT

O modelo UTAUT (Venkatesh et al., 2003) é uma abordagem robusta e relevante para entender comportamentos individuais de adoção e uso da tecnologia. O modelo possui quatro constructos voltados a intenção de uso da tecnologia: expectativa de desempenho (ED), expectativa de esforço (EE), influência social (IS) e condições facilitadoras (CFs).

A ED refere-se ao “grau em que um indivíduo acredita que o uso do sistema o ajudará a melhorar seu desempenho profissional” (Venkatesh et al., 2003, p. 447). A EE é “o grau de facilidade associado ao uso do sistema” (Venkatesh et al., 2003, p. 450). A IS denota “o grau em que um indivíduo percebe que outras pessoas importantes acreditam que ele ou ela deve usar o novo sistema” (Venkatesh et al., 2003, p. 451). As CFs indicam “o grau em que um indivíduo acredita que existe uma infraestrutura organizacional e técnica de suporte ao uso do sistema” (Venkatesh et al., 2003, p. 453). O modelo UTAUT possui quatro moderadores: gênero, idade, experiência e voluntariedade de uso. No entanto, seguindo as

premissas de um estudo anterior (Weerakkody, El-Haddadeh, Al-Sobhi, Shareef, & Dwivedi, 2013), esses moderadores não foram empregados no presente modelo adaptado (explicado na próxima seção) porque se trata de um estudo preliminar de adoção de BDA no contexto brasileiro de GCS.

## Hipóteses e modelo de pesquisa

Com o apoio da literatura relevante sobre *big data*, GCS e UTAUT, adaptamos um modelo descrito por Queiroz e Wamba (2019) para compreender o comportamento de adoção de *big data* por profissionais brasileiros de GCS. Adotamos alguns conceitos e hipóteses propostos no modelo de Queiroz e Wamba (2019) (Figura 1), pois estes foram previamente validados (Quadro 1), e um constructo de confiança previamente validado que foi adicionado a esses conceitos (Alalwan, Dwivedi, & Rana, 2017; Gefen, Karahanna, & Straub, 2003). Além disso, os constructos utilizados em nosso modelo têm relacionamentos diferentes daqueles descritos na literatura (Queiroz & Wamba, 2019).

### Condições facilitadoras

As CFs desempenham um papel fundamental na previsão da aceitação e intenção de uso de tecnologia (Venkatesh et al., 2003, 2012). Neste estudo, as CFs denotam o conhecimento dos profissionais de GCS sobre os recursos e infraestrutura organizacional disponíveis para dar suporte ao uso de *big data*. Estudos anteriores relataram que CFs são um bom preditor da IC de adotar *big data* (Huang, Liu, & Chang, 2012; Sabi, Uzoka, Langmia, & Njeh, 2016). O presente estudo postula que CFs influenciam diretamente a IC e são fundamentais na EE (Dwivedi et al., 2017) e também influenciam a ED (Wang, Jeng & Huang, 2017). Portanto, propomos as seguintes hipóteses:

H1a: CFs afetam positivamente a EE.

H1b: CFs afetam positivamente a ED.

H1c: CFs afetam positivamente a IC de adotar *big data*.

### Confiança

O conceito de confiança foi estudado exaustivamente nos campos de administração e sistemas de informação (Colquitt & Rodell, 2011; Wu, Zhao, Zhu, Tan, & Zheng, 2011). Confiança é definida como “a predisposição de uma pessoa de se tornar vulnerável às ações de outra pessoa (contraparte) com base na expectativa de que a contraparte realize uma ação específica importante para o credor, independentemente da capacidade de monitorar ou

controlar a contraparte” (Mayer, Davis, & Schoorman, 1995, p. 712). Essa definição indica que confiança é a disposição de depender de uma contraparte com base na integridade, benevolência e credibilidade. Nesse contexto, o *big data* é confiável para os usuários. Em consonância com trabalhos anteriores (Wu et al., 2011), propomos as seguintes hipóteses:

H2a: Confiança afeta positivamente a ED.

H2b: Confiança afeta positivamente a IC de adotar *big data*.

### Influência social

A IS é um bom preditor da IC de usar a tecnologia (Venkatesh et al., 2003). Neste trabalho, a IS denota até que ponto os profissionais de GCS acreditam que seus colegas devem usar *big data*. Estudos anteriores destacam que a IS afeta a IC (Batara, Nurmandi, Warsito, & Pribadi, 2017; Oliveira, Faria, Thomas, & Popovič, 2014; Venkatesh et al., 2012). A nossa hipótese é que, no contexto do GCS, a IS afeta significativamente a confiança (Chin, Wafa, & Ooi, 2009) e, por sua vez, a IC (Alalwan et al., 2017). Portanto, propomos as seguintes hipóteses:

H3a: IS afeta positivamente a confiança.

H3b: IS afeta positivamente a IC de adotar *big data*.

### Expectativa de esforço

A EE está relacionada à complexidade de operação do sistema (Venkatesh et al., 2003). Neste estudo, a EE refere-se à facilidade de uso de sistemas de *big data* por profissionais de GCS. Estudos anteriores discutiram o efeito da EE na IC e uso de uma nova tecnologia (Batara et al., 2017; Venkatesh et al., 2012; Zhao, Ni, & Zhou, 2018) e na adoção de *blockchain* em GCS (Francisco & Swanson, 2018). Nesse sentido, a seguinte hipótese foi postulada:

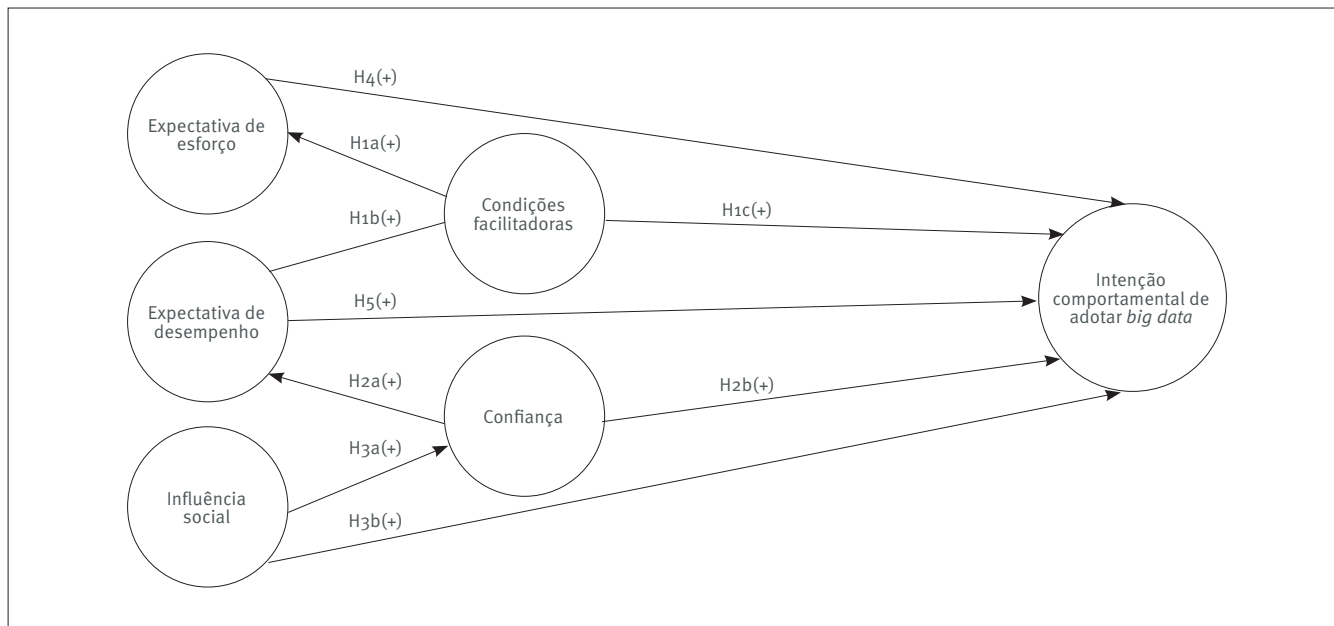
H4: A EE afeta positivamente a IC de adotar *big data*.

### Expectativa de desempenho

Neste trabalho, a ED denota o nível em que um profissional de GCS percebe que o *big data* melhorará sua produtividade e desempenho. As empresas podem analisar diferentes tipos de dados utilizando estatísticas robustas e técnicas de aprendizado de máquina (Kune, Konugurthi, Agarwal, Chillarige, & Buyya, 2016), resultando em considerável economia de tempo e melhora da produtividade nas organizações, aumentando seu desempenho (Gunasekaran et al., 2017; Wamba et al., 2017). Portanto, apresentamos a seguinte hipótese:

H5: ED afeta positivamente a IC de adotar *big data*.

Figura 1. Modelo conceitual



## METODOLOGIA

### Amostra e coleta de dados

Um questionário baseado em Queiroz e Wamba (2019) foi utilizado para testar as hipóteses propostas. O questionário *on-line* foi baseado em conceitos e escalas validados anteriormente (Venkatesh et al., 2003, 2012; Gefen et al., 2003). O modelo de Queiroz e Wamba (2019) foi desenvolvido com base em estudos anteriores, e seus constructos foram adaptados de estudos recentes envolvendo MATs (Alalwan et al., 2017; Venkatesh et al., 2003, 2012). Utilizamos o questionário desenvolvido por Queiroz e Wamba (2019) porque nosso principal objetivo era identificar a intenção de adotar *big data*. Todos os constructos foram mensurados usando uma escala *Likert* de sete pontos, variando de 1 [discordo totalmente] a 7 [concordo totalmente] (Wamba et al., 2017). Antes da coleta de dados, foi realizado um teste-piloto com cinco acadêmicos seniores e cinco profissionais seniores de GCS. Os dados foram obtidos da rede social *LinkedIn* (Gupta & George, 2016; Queiroz & Telles, 2018). Após o teste-piloto, enviamos um questionário a 600 profissionais brasileiros de GCS com experiência em *big data*. A pesquisa foi realizada em agosto de 2018, em que recebemos 152 questionários válidos, representando uma taxa de resposta de 25,33%. Os constructos e seus respectivos itens estão mostrados no Quadro 1. O questionário foi validado empregando cargas fatoriais (Hair, Hult, Ringle, & Sarstedt, 2017), alfa de Cronbach, confiabilidade

composta, variância média extraída (Hair et al., 2017; Nunnally, 1978; Riffai, Grant, & Edgar, 2012) e validade discriminante.

## RESULTADOS E ANÁLISES

O PLS-SEM (Ringle, Wende, & Becker, 2015; Shim, Lee, & Kim, 2018; Sun & Teng, 2017) foi utilizado para analisar o modelo de estudo. O PLS-SEM é uma abordagem eficaz para analisar modelos simples e robustos da área de gestão e negócios (Hair, Sarstedt, Hopkins, & Kuppelwieser, 2014; Hair et al., 2017) e ganhou a atenção de estudiosos de GCS (Autry, Williams, & Golicic, 2014; Grawe, Daugherty, & Ralston, 2015; Han, Wang, & Naim, 2017; Yadlapalli, Rahman, & Gunasekaran, 2018). Suas principais vantagens são a flexibilidade no trabalho com amostras pequenas (por exemplo, 100 respondentes) e a presença de constructos formativos e reflexivos (Hair et al., 2017).

As características dos entrevistados estão apresentadas na Tabela 1. Os entrevistados do sexo masculino representaram cerca de 90% da amostra. A maioria (52,63%) dos entrevistados tinha entre 34 e 41 anos. Os entrevistados possuíam pós-graduação/MBA (nível acadêmico mais alto da amostra, 55,26%), diploma de bacharel (39,47%), ou mestrado acadêmico (5,26%). O tempo de experiência profissional dos entrevistados em suas respectivas organizações foi de 2 a 5 anos (50%), de 6 a 10 anos (21,05%), ou menos de 1 ano (18,42%). A amostra foi composta por analistas de logística (46,05%), gerentes de transporte (26,32%), gerentes de operações (18,42%) e gerentes de GCS (9,21%).

Quadro 1. Itens de mensuração

Constructo	Descrição	Itens	Fontes
Expectativa de desempenho (ED)	ED1	<i>Big data</i> é útil na minha vida diária.	(Alalwan et al., 2017; Venkatesh et al., 2003, 2012; Queiroz & Wamba, 2019)
	ED2	O uso de <i>big data</i> aumenta minhas chances de concluir tarefas importantes para mim.	
	ED3	O emprego de <i>big data</i> me ajuda a realizar tarefas mais rapidamente.	
	ED4	A aplicação de <i>big data</i> aumenta minha produtividade.	
Expectativa de esforço (EE)	EE1	Aprender a utilizar <i>big data</i> é fácil para mim.	(Alalwan et al., 2017; Venkatesh et al., 2003, 2012; Queiroz & Wamba, 2019)
	EE2	Minha interação com o <i>big data</i> é clara e adequada.	
	EE3	<i>Big data</i> é fácil de usar.	
	EE4	Consigo me tornar proficiente no uso de <i>big data</i> rapidamente.	
Influência social (IS)	IS1	As pessoas que são importantes para mim pensam que eu deveria empregar <i>big data</i> .	(Alalwan et al., 2017; Venkatesh et al., 2003, 2012; Queiroz & Wamba, 2019)
	IS2	As pessoas que são importantes para mim acham que eu deveria utilizar <i>big data</i> .	
	IS3	Pessoas cujas opiniões eu valorizo preferem que eu use <i>big data</i> .	
Condições facilitadoras (CFs)	CF1	Eu tenho os recursos necessários para adotar o <i>big data</i> .	(Alalwan et al., 2017; Venkatesh et al., 2003, 2012; Queiroz & Wamba, 2019)
	CF2	Eu tenho o conhecimento necessário para adotar <i>big data</i> .	
	CF3	<i>Big data</i> é compatível com outras tecnologias que eu utilizo.	
	CF4	Posso obter ajuda de outras pessoas quando tenho dificuldades em usar <i>big data</i> .	
Intenção comportamental (IC) de utilizar <i>big data</i>	IC1	Pretendo usar <i>big data</i> no futuro.	(Alalwan et al., 2017; Venkatesh et al., 2003, 2012; Queiroz & Wamba, 2019)
	IC2	Espero utilizar <i>big data</i> no futuro.	
	IC3	Tenho planos para adotar <i>big data</i> no futuro.	
Confiança (CO)	CO1	Acredito que <i>big data</i> é confiável.	(Alalwan et al., 2017; Gefen et al., 2003)
	CO2	Confio em <i>big data</i> .	
	CO3	Não duvido da credibilidade do <i>big data</i> .	
	CO4	Tenho certeza de que estruturas legais e tecnológicas me protegem adequadamente de problemas em <i>big data</i> .	
	CO5	<i>Big data</i> cumpre as funções pretendidas.	

Tabela 1. Perfil demográfico da amostra (n=152)

Gênero	n	%
Masculino	136	89,5
Feminino	16	10,5
Idade (anos)		
26-33	40	26,32
34-41	80	52,63
42-49	12	7,89
≥50	20	13,16
Nível educacional		
Bacharelado	60	39,47
Pós-graduação/MBA	84	55,26
Mestrado acadêmico	8	5,26
Tempo de experiência profissional (anos)		
<1	28	18,42
2-5	76	50,00
6-10	32	21,05
11-15	16	10,53
Profissão		
Analista de logística	70	46,05
Gerente de operações	28	18,42
Gerente de transporte	40	26,32
Gerente de cadeia de suprimentos	14	9,21

O modelo de estudo foi analisado utilizando o *software* SmartPLS versão 3.0 (Hair et al., 2017; Ringle et al., 2015). Primeiro, o modelo foi avaliado por suas cargas fatoriais, alfa de Cronbach, confiabilidade composta, variância média extraída e validade discriminante.

## Modelo de mensuração

Todas as cargas fatoriais excederam o limiar de 0,70 recomendado na literatura (Hair et al., 2017) (Tabela 2). As principais medidas de confiabilidade do constructo e consistência interna dos itens são mostradas na Tabela 3. O valor alfa de Cronbach e a confiabilidade composta ficaram acima do limite de 0,70, e todos os valores médios de variância extraídos ficaram acima do limiar de 0,50

(Hair et al., 2017; Nunnally, 1978; Riffai et al., 2012). Portanto, todos os constructos adotados no modelo foram validados. Os resultados de validade discriminante estão descritos na Tabela 4. Nesse caso, a raiz quadrada da variância média extraída de cada constructo deve ser maior que as correlações entre os constructos (Fornell & Larcker, 1981; Henseler, Ringle, & Sinkovics, 2009). Os valores obtidos foram superiores ao limiar de 0,70 (Fornell & Larcker, 1981), demonstrando que todos os constructos apresentaram validade discriminante (Ahmad & Khalid, 2017; Martins, Oliveira, & Popovič, 2014).

Tabela 2. Cargas fatoriais

	IC	EE	CF	ED	IS	CO
IC1	0,887					
IC2	0,916					
IC3	0,900					
EE1		0,945				
EE2		0,906				
EE3		0,947				
EE4		0,900				
CF1			0,789			
CF2			0,884			
CF3			0,719			
CF4			0,800			
ED1				0,764		
ED2				0,803		
ED3				0,914		
ED4				0,899		
IS1					0,953	
IS2					0,983	
IS3					0,967	
CO1						0,964
CO2						0,944
CO3						0,918
CO4						0,937
CO5						0,913

IC, intenção comportamental;  
 EE, expectativa de esforço;  
 CF, condições facilitadoras;  
 ED, expectativa de desempenho;  
 IS, influência social; CO, confiança.

Tabela 3. Medidas de confiabilidade

Constructo	Alfa de Cronbach	Confiabilidade composta	Variância média extraída
IC	0,881	0,926	0,808
EE	0,942	0,959	0,853
CF	0,806	0,873	0,637
ED	0,864	0,908	0,715
IS	0,965	0,977	0,934
CO	0,963	0,971	0,871

Tabela 4. Validade discriminante

Constructo	IC	EE	CF	ED	IS	CO
<b>IC</b>	<b>0,901</b>					
EE	0,527	<b>0,925</b>				
<b>CF</b>	0,614	0,577	<b>0,800</b>			
<b>ED</b>	0,314	0,238	0,620	<b>0,847</b>		
<b>IS</b>	0,399	0,390	0,508	0,421	<b>0,968</b>	
<b>CO</b>	0,511	0,456	0,580	0,640	0,715	<b>0,935</b>

IC, intenção comportamental; EE, expectativa de esforço; CF, condições facilitadoras; ED, expectativa de desempenho; IS, influência social; CO, confiança.

## Modelo estrutural

Os resultados do modelo estrutural estão nas Tabelas 5 e 6. A Tabela 5 destaca as estatísticas dos coeficientes de correlação. Os resultados corroboraram as seguintes hipóteses: H1a (CFs têm um efeito positivo significativo na EE) ( $\beta = 0,578$ ;  $p < 0,001$ ), H1b (CFs têm um efeito positivo significativo na ED) ( $\beta = 0,380$ ;  $p < 0,001$ ), H1c (CFs têm um efeito positivo significativo na IC) ( $\beta = 0,490$ ;  $p < 0,001$ ), H2a (a confiança tem um efeito positivo significativo na ED) ( $\beta = 0,413$ ;  $p < 0,001$ ), H2b (a confiança tem um efeito positivo significativo na IC) ( $\beta = 0,327$ ;  $p < 0,05$ ), e H3a (a IS tem um efeito positivo significativo na confiança) ( $\beta = 0,710$ ;  $p < 0,001$ ). Os resultados considerando as outras hipóteses foram inesperados: H3b (a IS tem um efeito positivo significativo na IC). O relacionamento foi negativo e não-significante ( $\beta = -0,073$ ;  $p = 0,519$ ). Assim, H3b não foi suportada. H4 (o EE tem um efeito positivo significativo na IC) não foi suportada também ( $\beta = 0,166$ ;  $p < 0,1$ ), assim como H5 (a ED tem um efeito positivo significativo na IC) ( $\beta = -0,214$ ;  $p < 0,05$ ). A Tabela 6 destaca as seguintes variâncias que foram obtidas: IC (46,0%), EE (33,3%), ED (49,8%) e confiança (50,3%) (Tabela 6). Todos os valores de R<sup>2</sup> do modelo excederam o limiar de 0,20, o que corrobora estudos anteriores (Chin, 1998; Martins et al., 2014).

Tabela 5. Coeficientes de caminhos

Valor	Beta	Desvio-padrão	Estatísticas t	Valor de p	Resultados
CF → EE	0,578	0,053	10,921*	0,000	Aceito
CF → ED	0,380	0,064	5,875*	0,000	Aceito
CF → IC	0,490	0,097	5,016*	0,000	Aceito
CO → ED	0,413	0,080	5,301*	0,000	Aceito
CO → IC	0,327	0,112	2,987**	0,003	Aceito
IS → CO	0,710	0,047	15,17*	0,000	Aceito
IS → IC	-0,073	0,097	0,646	0,519	Rejeitado
EE → IC	0,166	0,090	1,86	0,063	Rejeitado
ED → IC	-0,214	0,099	2,184**	0,029	Rejeitado

IC, intenção comportamental; EE, expectativa de esforço; CF, condições facilitadoras; ED, expectativa de desempenho; IS, influência social; CO, confiança.

\* $p < 0,001$ ; \*\* $p < 0,05$ .



Tabela 6. Resultados de R<sup>2</sup> (variáveis dependentes)

Constructo	R <sup>2</sup>	R <sup>2</sup> ajustado
IC	0,477	0,460
EE	0,337	0,333
ED	0,504	0,498
CO	0,506	0,503

IC, intenção comportamental; EE, expectativa de esforço; ED, expectativa de desempenho; CO, confiança

## DISCUSSÃO E IMPLICAÇÕES

O objetivo deste estudo foi compreender a intenção de adotar *big data* no contexto do GCS no Brasil. Em vista da falta de estudos sobre tecnologias de ponta no Brasil (Queiroz e Telles, 2018), este trabalho contribui para o conhecimento sobre BDA, GCS e MATs. Os resultados têm implicações gerenciais e teóricas significativas e oferecem orientações valiosas para adaptar e melhorar o modelo adotado.

### Implicações gerenciais

As principais conclusões deste estudo têm implicações importantes para gerentes e profissionais de GCS envolvidos com BDA e seus facilitadores de adoção. De acordo com a literatura que considera o *big data* uma ferramenta essencial para melhorar o GCS (Gunasekaran et al., 2017; Hazen, Skipper, Ezell, & Boone, 2016; Wang et al., 2016), o presente estudo demonstrou que o *big data* pode ser uma ferramenta adequada para ajudar os profissionais que trabalham no GCS a obterem conhecimento e tomarem decisões. Segundo, as CFs exercem uma grande influência na adoção de *big data*. Isso significa que os gerentes devem considerar a infraestrutura de TI, velocidade da internet e integração com outros sistemas, além de outros fatores (Sabi et al., 2016; Venkatesh et al., 2003).

Surpreendentemente, apesar de a literatura indicar que a ED é um bom preditor da IC de adotar tecnologia (Dwivedi et al., 2017; Farooq et al., 2017; Venkatesh et al., 2003; Weerakkody et al., 2013), o presente estudo demonstrou que a ED não foi um bom preditor da IC de usar *big data* entre profissionais brasileiros de GCS. Esse resultado pode representar uma barreira à adoção desse tipo de tecnologia e abre novas oportunidades de pesquisa. Por outro lado, a IS é forte preditora de confiança (Chin et al., 2009). Entretanto, a IS não afetou a IC de adotar *big data*. Portanto, mais pesquisas que auxiliem tomadores de decisão são necessárias.

### Implicações teóricas, limitações e perspectivas futuras

Do ponto de vista teórico, este estudo traz contribuições significativas para o campo da logística e da GCS. Primeiro, ao analisar a literatura sobre BDA, GCS e UTAUT, validamos um modelo teórico robusto. Adaptamos e aplicamos um modelo previamente desenvolvido, para utilização junto aos profissionais brasileiros de GCS, e nossos resultados validaram o modelo. O modelo teórico explicou 46% da IC, excedendo o limiar de 20% reportado na literatura (Chin, 1998; Martins et al., 2014). Além disso, os resultados de validade discriminante foram consistentes com a literatura e, portanto, apoiaram as hipóteses estruturais, e demonstraram que o modelo efetivamente mensura a IC de profissionais de GCS de adotar *big data*.

Nossos achados destacam que CFs são um bom preditor da IC de usar *big data*, e pesquisas futuras podem se concentrar em avaliar CFs e suas limitações. No modelo proposto, em consonância com um estudo anterior (Alalwan et al., 2017), a confiança foi um bom preditor de ED e IC. Por outro lado, a IS não foi uma boa preditora de IC, o que corrobora o resultado de um estudo anterior (Alalwan et al., 2017). Esse resultado sugere a necessidade de uma investigação mais aprofundada do papel da IS na implementação de *big data* e outras tecnologias emergentes na área de GCS.

Este estudo tem algumas limitações. Primeiro, uma variável moderadora poderia ser incorporada ao modelo (Venkatesh et al., 2003, 2012) para identificar nuances e diferenças na amostra, como tipo de indústria, gênero e experiência profissional. Segundo, devido a escassez de estudos sobre a adoção de *big data* no Brasil, nossos resultados possuem limitação relativo a comparação com outros estudos. No entanto, este estudo abre oportunidades para estudiosos e profissionais aplicarem o modelo validado e adaptarem-no a outros contextos. Terceiro, o modelo adotado foi testado em uma economia emergente; por esse motivo, os resultados não podem ser generalizados. Portanto, estudos adicionais são necessários para obter evidências empíricas em outros países utilizando esse modelo.

Este estudo é um dos primeiros a avaliar a IC de profissionais brasileiros de GCS de adotar *big data*. Há uma necessidade urgente e oportunidades de realizar investigações adicionais sobre essa e outras tecnologias de ponta (e.g., *blockchain*, internet das coisas e impressão 3D) e comparar as hipóteses desse modelo em outros contextos.

## CONCLUSÃO

Os objetivos deste estudo foram: 1. elucidar a IC de profissionais brasileiros de GCS de empregar *big data*; e 2. aplicar um modelo contendo constructos relacionados à IC. Este estudo forneceu uma compreensão mais aprofundada da intenção de adotar o BDA no GCS no Brasil.

As três contribuições deste estudo foram: 1. com base em literatura teórica robusta (Akter et al., 2016; Alalwan et al., 2017; Davis, 1989; Venkatesh et al., 2003, 2012; Queiroz & Wamba, 2019), adaptamos e aplicamos um modelo para entender a IC de profissionais brasileiros de GCS; 2. os resultados têm fortes implicações teóricas e práticas; uma implicação teórica é que CFs e confiança são bons preditores de IC; em contrapartida, a IS não foi um preditor de IC, o que contraria os resultados de dois estudos (Venkatesh et al., 2003, 2012), mas corrobora um estudo (Alalwan et al., 2017); e 3. a ED e EE não são bons preditores de IC. Portanto, esses resultados abrem oportunidades para melhor entender esses dois constructos, ajuda a preencher uma lacuna na literatura empírica brasileira sobre o uso de *big data* no GCS e estimula profissionais de logística e GCS a melhor compreender essa tecnologia.

## REFERÊNCIAS

- Abawajy, J. (2015). Comprehensive analysis of big data variety landscape. *International Journal of Parallel, Emergent and Distributed Systems*, 30(1), 5-14. doi:10.1080/17445760.2014.925548
- Ahmad, S. Z., & Khalid, K. (2017). The adoption of M-government services from the user's perspectives: Empirical evidence from the United Arab Emirates. *International Journal of Information Management*, 37(5), 367-379. doi:10.1016/j.ijinfomgt.2017.03.008
- Akter, S., Wamba, S. F., Gunasekaran, A., Dubey, R., & Childe, S. J. (2016). How to improve firm performance using big data analytics capability and business strategy alignment? *International Journal of Production Economics*, 182, 113-131. doi:10.1016/j.ijpe.2016.08.018
- Alalwan, A. A., Dwivedi, Y. K., & Rana, N. P. (2017). Factors influencing adoption of mobile banking by Jordanian bank customers: Extending UTAUT2 with trust. *International Journal of Information Management*, 37(3), 99-110. doi:10.1016/j.ijinfomgt.2017.01.002
- Autry, C. W., Williams, B. D., & Golicic, S. (2014). Relational and process multiplexity in vertical supply chain triads: An exploration in the U.S. restaurant industry. *Journal of Business Logistics*, 35(1), 52-70. doi:10.1111/jbl.12034
- Azjen, I., & Fishbein, M. (1980). *Understanding attitudes and predicting social behavior*. Englewood Cliffs, NJ: Prentice-Hall.
- Batara, E., Nurmandi, A., Warsito, T., & Pribadi, U. (2017). Are government employees adopting local e-government transformation? *Transforming Government: People, Process and Policy*, 11(4), 612-638. doi:10.1108/TG-09-2017-0056
- Bibri, S. E., & Krogstie, J. (2017). ICT of the new wave of computing for sustainable urban forms: Their big data and context-aware augmented typologies and design concepts. *Sustainable Cities and Society*, 32, 449-474. doi:10.1016/j.scs.2017.04.012
- Carter, C. R., Rogers, D. S., & Choi, T. Y. (2015). Toward the theory of the supply chain. *Journal of Supply Chain Management*, 51(2), 89-97. doi:10.1111/jscm.12073
- Chin, A., Wafa, S., & Ooi, A.-Y. (2009). The effect of internet trust and social influence towards willingness to purchase online in Labuan, Malaysia. *International Business Research*, 2(2), 72-81.
- Chin, W. W. (1998). Issues and opinion on structural equation modeling. *MIS Quarterly*, 22(1), 7-16.
- Choi, T. Y., Dooley, K. J., & Rungtusanatham, M. (2001). Supply networks and complex adaptive systems: Control versus emergence. *Journal of Operations Management*, 19(3), 351-366. doi:10.1016/S0272-6963(00)00068-1
- Colquitt, J. A., & Rodell, J. B. (2011). Justice, trust, and trustworthiness: A longitudinal analysis integrating three theoretical perspectives. *Academy of Management Journal*, 54(6), 1183-1206. doi:10.5465/amj.2007.0572
- Croll, A. (2015). *Data: Emerging trends and technologies*. Retrieved from <http://www.oreilly.com/data/free/data-emerging-trends-and-technologies.csp>
- Davenport, T. H. (2006). Competing on analytics. *Harvard Business Review*. Retrieved from <https://hbr.org/>
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340. doi:10.2307/249008
- Domo. (2017). Data never sleeps 4.0. Retrieved from <https://www.domo.com/blog/data-never-sleeps-4-0/>
- Dwivedi, Y. K., Rana, N. P., Janssen, M., Lal, B., Williams, M. D., & Clement, M. (2017). An empirical validation of a unified model of electronic government adoption (UMEGA). *Government Information Quarterly*, 34(2), 211-230. doi:10.1016/j.giq.2017.03.001
- Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897-904. doi:10.1016/j.jbusres.2015.07.001
- Farooq, M. S., Salam, M., Jaafar, N., Fayolle, A., Ayupp, K., Radovic-Markovic, M., & Sajid, A. (2017). Acceptance and use of lecture capture system (LCS) in executive business studies: Extending UTAUT2. *Interactive Technology and Smart Education*, 14(4), 329-348. doi:10.1108/ITSE-06-2016-0015

- Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), 39-50. doi:10.2307/3151312
- Francisco, K., & Swanson, D. (2018). The supply chain has no clothes: Technology adoption of blockchain for supply chain transparency. *Logistics*, 2(1), 2. doi:10.3390/logistics2010002
- Gefen, Karahanna, & Straub. (2003). Trust and TAM in online shopping: An integrated model. *MIS Quarterly*, 27(1), 51-90. doi:10.2307/30036519
- Giannakis, M., & Louis, M. (2016). A multi-agent based system with big data processing for enhanced supply chain agility. *Journal of Enterprise Information Management*, 29(5), 706-727. doi:10.1108/JEIM-06-2015-0050
- Gobble, M. M. (2013). Big data: The next big thing in innovation. *Research-Technology Management*, 56(1), 64-67. doi:10.5437/08956308X5601005
- Grawe, S. J., Daugherty, p. J., & Ralston, p. M. (2015). Enhancing dyadic performance through boundary spanners and innovation: An assessment of service provider-customer relationships. *Journal of Business Logistics*, 36(1), 88-101. doi:10.1111/jbl.12077
- Gunasekaran, A., Papadopoulos, T., Dubey, R., Wamba, S. F., Childe, S. J., Hazen, B., & Akter, S. (2017). Big data and predictive analytics for supply chain and organizational performance. *Journal of Business Research*, 70, 308-317. doi:10.1016/j.jbusres.2016.08.004
- Gupta, M., & George, J. F. (2016). Toward the development of a big data analytics capability. *Information & Management*, 53(8), 1049-1064. doi:10.1016/j.im.2016.07.004
- Hair, J. F., Sarstedt, M., Hopkins, L., & Kuppelwieser, V. G. (2014). Partial least squares structural equation modeling (PLS-SEM) An emerging tool in business research. *European Business Review*, 26(2), 106-121. doi:10.1108/EBR-10-2013-0128
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2017). *A primer on Partial Least Squares Structural Equation Modeling*. 2nd ed.. Thousand Oaks, CA: Sage Publications.
- Han, J. H., Wang, Y., & Naim, M. (2017). Reconceptualization of information technology flexibility for supply chain management: An empirical study. *International Journal of Production Economics*, 187, 196-215. doi:10.1016/j.ijpe.2017.02.018
- Hazen, B. T., Boone, C. A., Ezell, J. D., & Jones-Farmer, L. A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. *International Journal of Production Economics*, 154, 72-80. doi:10.1016/j.ijpe.2014.04.018
- Hazen, B. T., Skipper, J. B., Ezell, J. D., & Boone, C. A. (2016). Big data and predictive analytics for supply chain sustainability: A theory-driven research agenda. *Computers & Industrial Engineering*, 101, 592-598. doi:10.1016/j.cie.2016.06.030
- Henseler, J., Ringle, C. M., & Sinkovics, R. R. (2009). The use of partial least squares path modeling in international marketing. In R. Sinkovics & P. Ghauri (Eds.), *New challenges to international marketing* (Vol 20, pp. 277-319). Emerald Group Publishing Limited.
- Huang, T. C. K., Liu, C. C., & Chang, D. C. (2012). An empirical investigation of factors influencing the adoption of data mining tools. *International Journal of Information Management*, 32(3), 257-270. doi:10.1016/j.ijinfomgt.2011.11.006
- Kache, F., & Seuring, S. (2017). Challenges and opportunities of digital information at the intersection of big data analytics and supply chain management. *International Journal of Operations & Production Management*, 37(1), 10-36. doi:10.1108/IJOPM-02-2015-0078
- Kune, R., Konugurthi, p. K., Agarwal, A., Chillarige, R. R., & Buyya, R. (2016). The anatomy of big data computing. *Software: Practice and Experience*, 46(1), 79-105. doi:10.1002/spe.2374
- Mamonov, S., & Benbunan-Fich, R. (2017). Exploring factors affecting social e-commerce service adoption: The case of Facebook gifts. *International Journal of Information Management*, 37(6), 590-600. doi:10.1016/j.ijinfomgt.2017.05.005
- 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*. Retrieved from <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/big-data-the-next-frontier-for-innovation>
- Martins, C., Oliveira, T., & Popovič, A. (2014). Understanding the internet banking adoption: A unified theory of acceptance and use of technology and perceived risk application. *International Journal of Information Management*, 34(1), 1-13. doi:10.1016/j.ijinfomgt.2013.06.002
- Mayer, R. C., Davis, J. H., & Schoorman, F. D. (1995). An integrative model of organizational trust. *Academy of Management Review*, 20(3), 709-734. doi:10.2307/258792
- Mentzer, J. T., DeWitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C. D., & Zacharia, Z. G. (2001). Defining supply chain management. *Journal of Business Logistics*, 22(2), 1-25. doi:10.1002/j.2158-1592.2001.tb0001.x
- Morris, M. G., & Venkatesh, V. (2000). Age differences in technology adoption decisions: Implications for a changing work force. *Personnel Psychology*, 53(2), 375-403. doi:10.1111/j.1744-6570.2000.tb00206.x
- Munshi, A. A., & Mohamed, Y. A. R. I. (2017). Big data framework for analytics in smart grids. *Electric Power Systems Research*, 151, 369-380. doi:10.1016/j.epsr.2017.06.006
- Nobre, G. C., & Tavares, E. (2017). Scientific literature analysis on big data and internet of things applications on circular economy: A bibliometric study. *Scientometrics*, 111(1), 463-492. doi:10.1007/s11192-017-2281-6
- Nunnally, J. C. (1978). *Psychometric Theory: 2d Ed*. New York, NY: McGraw-Hill.

- Oliveira, T., Faria, M., Thomas, M. A., & Popovič, A. (2014). Extending the understanding of mobile banking adoption: When UTAUT meets TTF and ITM. *International Journal of Information Management*, 34(5), 689-703. doi:10.1016/j.ijinfomgt.2014.06.004
- Oliveira, T., Faria, M., Thomas, M. A. & Popovič, A. (2014). Extending the understanding of mobile banking adoption: When UTAUT meets TTF and ITM. *International Journal of Information Management*, 34(5), 689-703. doi:10.1016/j.ijinfomgt.2014.06.004
- Phillips-Wren, G., & Hoskisson, A. (2015). An analytical journey towards big data. *Journal of Decision Systems*, 24(1), 87-102. doi:10.1080/12460125.2015.994333
- Queiroz, M. M., & Telles, R. (2018). Big data analytics in supply chain and logistics: An empirical approach. *International Journal of Logistics Management*, 29(2), 767-783. doi:10.1108/IJLM-05-2017-0116
- Queiroz, M. M., & Wamba, S. F. (2019). Blockchain adoption challenges in supply chain: An empirical investigation of the main drivers in India and the USA. *International Journal of Information Management*, 46, 70-82. doi:10.1016/j.ijinfomgt.2018.11.021
- Richey, R. G., Morgan, T. R., Lindsey-Hall, K., & Adams, F. G. (2016). A global exploration of big data in the supply chain. *International Journal of Physical Distribution & Logistics Management*, 46(8), 710-739. doi:10.1108/IJPDLM-05-2016-0134
- Riffai, M. M. M. A., Grant, K., & Edgar, D. (2012). Big TAM in Oman: Exploring the promise of on-line banking, its adoption by customers and the challenges of banking in Oman. *International Journal of Information Management*, 32(3), 239-250. doi:10.1016/j.ijinfomgt.2011.11.007
- Ringle, C. M., Wende, S., & Becker, J. M. (2015). SmartPLS 3. Boenningstedt, Germany: SmartPLS GmbH.
- Rotella, p. (2012). Is data the new oil? *Forbes*. Retrieved from <http://www.forbes.com/sites/perryrotella/2012/04/02/is-data-the-new-oil/#44ed5b8e77a9>
- Sabi, H. M., Uzoka, F. E., Langmia, K., & Njeh, F. N. (2016). Conceptualizing a model for adoption of cloud computing in education. *International Journal of Information Management*, 36(2), 183-191. doi:10.1016/j.ijinfomgt.2015.11.010
- Schoenherr, T., & Speier-Pero, C. (2015). Data science, predictive analytics, and big data in supply chain management: Current state and future potential. *Journal of Business Logistics*, 36(1), 120-132. doi:10.1111/jbl.12082
- Shim, S., Lee, B., & Kim, S. L. (2018). Rival precedence and open platform adoption: An empirical analysis. *International Journal of Information Management*, 38(1), 217-231. doi:10.1016/j.ijinfomgt.2017.10.001
- Srinivasan, R., & Swink, M. (2018). An investigation of visibility and flexibility as complements to supply chain analytics: An organizational information processing theory perspective. *Production and Operations Management*, 27(10), 1849-1867. doi:10.1111/poms.12746
- Stock, J. R., & Boyer, S. L. (2009). Developing a consensus definition of supply chain management: A qualitative study. *International Journal of Physical Distribution & Logistics Management*, 39(8), 690-711. doi:10.1108/09600030910996323
- Strawn, G. (2012). Scientific research: How many paradigms? *EDUCAUSE Review*. Retrieved from <http://www.eric.ed.gov/ERICWebPortal/recordDetail?accno=EJ970900>
- Sun, J., & Teng, J. T. C. (2017). The construct of information systems use benefits: Theoretical explication of its underlying dimensions and the development of a measurement scale. *International Journal of Information Management*, 37(5), 400-416. doi:10.1016/j.ijinfomgt.2017.04.010
- Venkatesh, V., & Brown, S. A. (2001). A longitudinal investigation of personal computers in homes: Adoption determinants and emerging challenges. *MIS Quarterly*, 25(1), 71-102. doi:10.2307/3250959
- 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., & 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. doi:10.2307/41410412
- 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. *International Journal of Production Economics*, 165, 234-246. doi:10.1016/j.ijpe.2014.12.031
- Wamba, S. F., Gunasekaran, A., Akter, S., Ren, S. J. fan, Dubey, R., & Childe, S. J. (2017). Big data analytics and firm performance: Effects of dynamic capabilities. *Journal of Business Research*, 70, 356-365. doi:10.1016/j.jbusres.2016.08.009
- Wamba, S. F. (2018, March). Social media use in the workspace: applying an extension of the technology acceptance model across multiple countries. In *World Conference on Information Systems and Technologies* (pp. 385-392). Springer, Cham.
- Wang, C. S., Jeng, Y. L., & Huang, Y. M. (2017). What influences teachers to continue using cloud services? The role of facilitating conditions and social influence. *The Electronic Library*, 35(3), 520-533. doi:10.1108/EL-02-2016-0046
- Wang, G., Gunasekaran, A., Ngai, E. W. T., & Papadopoulos, T. (2016). Big data analytics in logistics and supply chain management: Certain investigations for research and applications. *International Journal of Production Economics*, 176, 98-110. doi:10.1016/j.ijpe.2016.03.014
- Weerakkody, V., El-Haddadeh, R., Al-Sobhi, F., Shareef, M. A., & Dwivedi, Y. K. (2013). Examining the influence of intermediaries in facilitating e-government adoption: An empirical investigation. *International Journal of Information Management*, 33(5), 716-725. doi:10.1016/j.ijinfomgt.2013.05.001
- Wills, M. J. (2014). Decisions through data: Analytics in healthcare. *Journal of Healthcare Management*, 59(4), 254-262.

- Wu, K. J., Liao, C. J., Tseng, M. L., Lim, M. K., Hu, J., & Tan, K. (2017). Toward sustainability: Using big data to explore the decisive attributes of supply chain risks and uncertainties. *Journal of Cleaner Production*, 142(Part 2), 663-676. doi:10.1016/j.jclepro.2016.04.040
- Wu, K., Zhao, Y., Zhu, Q., Tan, X., & Zheng, H. (2011). A meta-analysis of the impact of trust on technology acceptance model: Investigation of moderating influence of subject and context type. *International Journal of Information Management*, 31(6), 572-581. doi:10.1016/j.ijinfomgt.2011.03.004
- Yadlapalli, A., Rahman, S., & Gunasekaran, A. (2018). Socially responsible governance mechanisms for manufacturing firms in apparel supply chains. *International Journal of Production Economics*, 196, 135-149. doi:10.1016/j.ijpe.2017.11.016
- Youngberg, E., Olsen, D., & Hauser, K. (2009). Determinants of professionally autonomous end user acceptance in an enterprise resource planning system environment. *International Journal of Information Management*, 29(2), 138-144. doi:10.1016/j.ijinfomgt.2008.06.001
- Zhao, R., Liu, Y., Zhang, N., & Huang, T. (2017). An optimization model for green supply chain management by using a big data analytic approach. *Journal of Cleaner Production*, 142, 1085-1097.
- Zhao, Y., Ni, Q., & Zhou, R. (2018). What factors influence the mobile health service adoption? A meta-analysis and the moderating role of age. *International Journal of Information Management*, 43, 342-350. doi:10.1016/j.ijinfomgt.2017.08.006
- Zhong, R. Y., Newman, S. T., Huang, G. Q., & Lan, S. (2016). Big data for supply chain management in the service and manufacturing sectors: Challenges, opportunities, and future perspectives. *Computers & Industrial Engineering*, 101, 572-591. doi:10.1016/j.cie.2016.07.013
- Zinn, W., & Goldsby, T. J. (2017a). In search of research ideas? Call a professional. *Journal of Business Logistics*, 38(1), 4-5. doi:10.1111/jbl.12160
- Zinn, W., & Goldsby, T. J. (2017b). The role of academic research in supply chain practice: How much are we contributing? *Journal of Business Logistics*, 38(4), 236-237. doi:10.1111/jbl.12175