

FÓRUM

Enviado 24.07.2018. Aprobado 19.07.2019

Avaliado através de um processo de revisão duplo-cego. Editores Científicos: Eduardo de Rezende Francisco, José Luiz Kugler, Soong Moon Kang, Ricardo Silva e Peter Alexander Whigham

Versão original

DOI: <http://dx.doi.org/10.1590/S0034-759020190607>

FATORES QUE AFETAM A ADOÇÃO DE ANÁLISES DE BIG DATA EM EMPRESAS

Factors affecting the adoption of big data analytics in companies

Factores que afectan a la adopción del análisis Big Data en empresas

RESUMO

Com a quantidade total de dados duplicando a cada dois anos, o baixo preço da computação e do armazenamento de dados torna a adoção de análises de Big Data (Big Data analytics - BDA) desejável para as empresas como uma ferramenta de obtenção de vantagem competitiva. Dada a disponibilidade de software livre, por que algumas empresas não adotaram essas técnicas? Para responder a essa pergunta, estendemos a teoria unificada de adoção e uso de tecnologia (UTAUT) adaptada para o contexto do BDA, adicionando duas variáveis: resistência ao uso e risco percebido. Usamos o grau de implementação dessas técnicas para dividir as empresas em usuárias e não usuárias de técnicas de BDA. Os modelos estruturais foram avaliados por partial least squares (PLS). Os resultados mostram que a importância de uma boa infraestrutura excede as dificuldades que as empresas enfrentam para implementar BDA. Enquanto as empresas que planejam usar Big Data esperam resultados significativos, os usuários atuais são mais céticos em relação ao seu desempenho.

PALAVRAS-CHAVE | Big Data, intenção de usar, teoria unificada de adoção e uso de tecnologia, resistência ao uso, risco percebido.

ABSTRACT

With the total quantity of data doubling every two years, the low price of computing and data storage makes the adoption of Big Data analytics (BDA) desirable for companies, as a tool to get competitive advantage. Given the availability of free software, why haven't some companies adopted these techniques? To answer this question, we extended the unified theory of technology adoption and use of technology model (UTAUT) to adapt it for the BDA context by adding two variables: resistance to use and perceived risk. We used the level of implementation of these techniques to divide companies into users and non-users of BDA. The structural models were evaluated by partial least squares (PLS). The results show the importance of good infrastructure exceeds the difficulties companies face in implementing it. While companies planning to use Big Data expect strong results, current users are more skeptical about its performance.

KEYWORDS | Big Data, intention behavior, unified theory of acceptance and use of technology, resistance to use, perceived risk.

RESUMEN

Con la cantidad total de datos duplicándose cada dos años, el bajo precio de la informática y del almacenamiento de datos hace que la adopción del análisis Big Data (BDA) sea altamente deseable para las empresas, como una herramienta para obtener una ventaja competitiva. Dada la disponibilidad de software libre, ¿por qué algunas empresas no han adoptado estas técnicas? Para responder a esta pregunta, ampliamos la teoría unificada de la adopción y uso de tecnología (UTAUT) para adaptarlo al contexto BDA agregando dos variables: resistencia al uso y riesgo percibido. Utilizamos el grado de implantación de estas técnicas para dividir las empresas entre: usuarias y no usuarias de BDA. Los modelos estructurales fueron evaluados con partial least squares (PLS). Los resultados muestran que la importancia de una buena infraestructura excede las dificultades que enfrentan las empresas para implementarla. Mientras que las compañías que planean usar BDA esperan muy buenos resultados, las usuarias actuales son más escépticos sobre su rendimiento.

PALABRAS CLAVE | Big Data, intención de uso, teoría unificada de la adopción y uso de tecnología, resistencia al uso, riesgo percibido.

JUANO-PEDRO CABRERA-SANCHEZ¹

jcabrera10@us.es

ORCID: 0000-0001-5723-3153

ÁNGEL F. VILLAREJO-RAMOS¹

curro@us.es

ORCID: 0000-0002-6916-2839

¹ Universidad de Sevilla, Facultad de Ciencias Económicas y Empresariales, Sevilla, Espanha

INTRODUÇÃO

Atualmente, a sociedade gera dados sobre nossas atividades a uma taxa exponencial de crescimento. Esses dados abrangem, por exemplo, os nossos celulares e a sua localização, quaisquer transações *on-line*, a internet das coisas, redes sociais, *wearables* etc. As empresas que podem transformar esses dados sobre seus clientes em informações em tempo real ganham uma vantagem competitiva substancial (Sivarajah, Kamal, Irani, & Weerakkody, 2017). Os dados do usuário permitem que as empresas saibam quando seus clientes consomem seus produtos, os melhores momentos para promoções e como melhorar os sentimentos em relação à marca. As empresas que usam análises de *Big Data* (*Big Data Analytics* - BDA) (McAfee & Brynjolfsson, 2012) podem processar grandes quantidades de dados, quase em tempo real, e se tornar líderes de mercado.


A adoção, implementação e gestão de BDA exige que as empresas adquiram novas habilidades. Novos perfis de carreira, como cientista de dados, que combina engenharia, estatística e um profundo conhecimento de negócios, estão entre os empregos mais procurados hoje em dia. Os funcionários com essas habilidades ajudam as empresas a extrair dados gerados

pelas próprias empresas e seus clientes. Isso muda a forma como as decisões são tomadas, favorecendo uma abordagem orientada a dados em oposição a uma abordagem baseada na experiência pessoal dos CEOs (McAfee & Brynjolfsson, 2012).

As empresas que utilizam BDA devem enfrentar os desafios que surgem no chamado ciclo de vida dos dados: dúvidas sobre os próprios dados, dificuldades no processamento dos dados e preocupações sobre a sua gestão (Akerkar, 2014; Zicari, 2014). As dúvidas sobre dados giram em torno de seu volume, variedade, velocidade, veracidade, volatilidade, valor e visualização. As tarefas de processamento de dados incluem técnicas relacionadas a aquisição de dados, armazenamento em bases de dados, limpeza e transformação de dados existentes, seleção correta do modelo e apresentação de resultados. Finalmente, o gerenciamento adequado de dados envolve considerações éticas, incluindo o respeito pela privacidade e segurança do usuário.

Como a tomada de decisão é cada vez mais orientada por dados, as empresas devem obter informações valiosas de modo eficiente a partir de um ambiente de dados em rápida mudança. Esse processo é detalhado por Agrawal, Bernstein e Bertino (2011), como mostra a Figura 1.

Figura 1. Processos de *Big Data*



Como vemos, o uso de BDA pelas empresas envolve dois processos principais: gerenciamento de dados e análise de dados. Enquanto o gerenciamento de dados levanta questões de engenharia, a análise de dados está mais relacionada aos interesses dos profissionais de *marketing* e *analytics*. O BDA é o processo de obtenção de valor a partir de dados, encontrando padrões ocultos que apoiam a tomada de decisão orientada por dados.

As empresas que consideram a adoção de BDA enfrentam diversas barreiras, como falta de conhecimento, medo, resistência à mudança e limitações próprias da tecnologia (Yaqoob et al., 2016). No entanto, o BDA melhora a tomada de decisão delas, utilizando técnicas e *softwares* livres e de código aberto. Isso nos

leva a dois questionamentos. Primeiro, o que afeta sua adoção? Segundo, por que muitas empresas ainda não usam o BDA? A maior parte da literatura sobre BDA concentra-se em aspectos técnicos relacionados ao seu ecossistema: desenvolvimento de aplicações, mineração de dados, análise, previsão, prescrição ou modelagem estatística (Sivarajah et al., 2017). Há pouca pesquisa sobre a adoção de BDA dentro de empresas (Brünink, 2016; Demoulin & Coussement, 2018; Huang, Liu, & Chang, 2012; Kwon, Lee, & Shin, 2014; Rahman, 2016; Verma, Bhattacharyya, & Kumar, 2018).

Este estudo, baseado no modelo de teoria unificada de aceitação e uso de tecnologia (UTAUT) (Venkatesh, Morris, Davis, & Davis, 2003), considera o impacto de duas novas variáveis,

resistência ao uso e percepção de risco, na adoção de BDA. O objetivo deste estudo é explicar a adoção e uso dessa nova tecnologia por empresas e compreender os problemas de implementação, a fim de propor recomendações aos profissionais. É por isso que fizemos uma diferenciação entre empresas usuárias e não usuárias dessa tecnologia e procuramos diferentes fatores que afetam sua aceitação e uso.

A segunda seção do artigo descreve os fundamentos teóricos do modelo proposto. A terceira seção descreve a metodologia que usamos. A quarta seção analisa os resultados obtidos a partir da aplicação do modelo em uma amostra de empresas. Por fim, apresentamos as principais conclusões teóricas e práticas, bem como as limitações da nossa pesquisa.

ANTECEDENTES TEÓRICOS E HIPÓTESES DO MODELO PROPOSTO

Análise e marketing usando *Big Data*

O *Big Data* revolucionou o *marketing analytics* e o *marketing* em geral. Forneceu novos conceitos e novas formas de fazer as coisas (Watson, 2019; Wedel & Kannan, 2016) para gerar uma vantagem competitiva. O BDA permite a inovação de serviços, o que cria valor estratégico para as empresas (Chiang, Grover, Liang, & Zhang, 2018).

Atualmente, o BDA está sendo usado em campanhas de *marketing* com o foco em aumentar o envolvimento do cliente (Liu, Shin, & Burns, 2019). A revisão da literatura mostra um número crescente de publicações sobre o uso de técnicas de *Big Data* para criar benefícios de *marketing* relacional. (Amado, Cortez, Rita, & Moro, 2018).

A gestão de *marketing* pode usar a enorme quantidade de dados disponíveis (por exemplo, nas mídias sociais) para obter *insights* valiosos de seus clientes. As empresas que exploram o *Big Data* a partir das mídias sociais ganham vantagens competitivas porque conhecem melhor os clientes (Ducange, Pecori, & Mezzina, 2018). Estudos mostram que o uso do BDA na inteligência de negócios (Sun, Sun, & Strang, 2018) e para manter a privacidade do cliente (Palmatier & Martin, 2019) cria ativos importantes no *marketing* de relacionamento.

No entanto, a literatura de adoção do BDA é relativamente escassa, e está focada no nível da indústria (Lai, Sun, & Ren, 2017; Rehman, Chang, Batoool, & Wah, 2016; Wright, Robin, Stone, & Aravopoulou, 2019; Yadegaridehkordi et al., 2018). Poucos autores têm pesquisado quais fatores afetam a adoção do BDA por empresas.

Modelos de aceitação da análise de *Big Data*

A adoção de tecnologia por empresas e consumidores é fundamental para o seu sucesso. Vários modelos de adoção de tecnologia foram desenvolvidos e testados, incluindo a teoria do comportamento planejado (TPB) (Ajzen, 1991) e o modelo de adoção de tecnologia (TAM) (Davis, 1985). Mas, sem dúvida, o modelo UTAUT (Venkatesh et al., 2003) é o mais abrangente. Esse modelo integra modelos e teorias anteriores para analisar a adoção e aceitação de tecnologias.

Estudos anteriores investigando a adoção de BDA por empresas (Brünink, 2016; Demoulin & Coussement, 2018; Huang et al., 2012; Kwon et al., 2014; Rahman, 2016; Verma et al., 2018) usaram o TAM original (Davis, 1985), TAM₂ (Venkatesh & Davis, 2000), TAM₃ (Venkatesh & Bala, 2008) ou o modelo UTAUT sem quaisquer variáveis extras. Os modelos de aceitação foram atualizados desde a sua introdução até mesmo evoluindo para novos modelos. Como o modelo UTAUT já é um modelo maduro, nós o aprimoramos com duas novas variáveis (descobertas significativas desta pesquisa), que ajudam a explicar quando as empresas optam por adotar o BDA.

A teoria do raciocínio comportamental (Claudy, Garcia, & O'Driscoll, 2015) fornece um quadro geral em que o envolvimento do usuário é muito importante para a adoção bem-sucedida de tecnologia (Ives & Olson, 2008). Os usuários que estão predispostos a mudar têm menos resistência à adoção de uma nova tecnologia (Laumer, Maier, Eckhardt, & Weitzel, 2016). Diferentes atitudes moldam o processo de adoção de uma nova tecnologia (López, Rodríguez, & Cerveró, 2006). Esta pesquisa nos levou a buscar padrões diferentes entre empresas usuárias e não usuárias em nossa amostra.

O modelo que propomos inclui quatro variáveis independentes extraídas do modelo UTAUT. A primeira, expectativa de desempenho, é definida como o grau em que se espera que o uso da tecnologia ofereça benefícios para a empresa. A segunda, expectativa de esforço, mede a facilidade de uso esperada de uma tecnologia. A terceira, influência social, mede como os indivíduos acreditam que amigos e familiares gostariam que eles usassem uma determinada tecnologia. A quarta, condições facilitadoras, é definida como o quanto os consumidores acreditam que recursos e apoio estarão disponíveis para desenvolver um determinado comportamento. O modelo propõe uma influência direta das três primeiras variáveis sobre a intenção comportamental, enquanto as condições facilitadoras afetam a intenção comportamental e o comportamento de uso. Arenas-Gaitán, Peral-Peral e Villarejo-Ramos (2016) apontam que o diferencial desse modelo é sua capacidade de identificar quais

fatores são os principais determinantes da adoção. O modelo permite a inclusão de diferentes variáveis moderadoras que interferem na influência dos construtos-chave do modelo.

Adicionamos resistência ao uso e risco percebido aos construtos do UTAUT. Resistência ao uso consiste em reações negativas à mudança ou implementação de um novo sistema (Kim & Kankanhalli, 2009). O risco percebido é o potencial de perdas resultante da implementação de uma nova tecnologia ou sistema de informação (Featherman & Pavlou, 2003).

Hipóteses do modelo proposto

Propomos diversas hipóteses baseadas no modelo estendido da UTAUT para a aceitação e uso do BDA por empresas.

Expectativa de desempenho refere-se à percepção do desempenho que a tecnologia terá e é um dos construtos mais influentes em relação à intenção comportamental. Vários estudos (Brünink, 2016; Chauhan & Jaiswal, 2016; Yu, 2012) além do trabalho original (Venkatesh et al., 2003) confirmam essa relação positiva. Portanto, propomos como hipótese:

H1: Expectativa de desempenho influencia positivamente a intenção comportamental de usar BDA.

Expectativa de esforço refere-se à expectativa de facilidade de aprendizagem e uso dessa nova tecnologia. De acordo com o modelo UTAUT, o grau de adoção do BDA depende da expectativa da facilidade ou dificuldade de usá-la. Diversos estudos confirmam essa relação (Al-Gahtani, Hubona, & Wang, 2007; Chauhan & Jaiswal, 2016; Kim, Chan, & Gupta, 2007; Lee & Song, 2013; Yu, 2012) e o efeito da expectativa de esforço na intenção comportamental. Assim, propomos como segunda hipótese do modelo:

H2: Expectativa de esforço, ou facilidade de uso, afeta positivamente a intenção comportamental de usar BDA.

Influência social, conceito originalmente desenvolvido por Venkatesh et al. (2003) e ampliado no UTAUT2 (Venkatesh, Thong, & Xu, 2012), mede o efeito gerado pelo que os outros (amigos e familiares) pensam sobre essa tecnologia. Em um ambiente profissional, o que os gestores e colegas pensam também é muito importante (Al-Gahtani et al., 2007; Brünink, 2016; Chauhan & Jaiswal, 2016; Gupta, Huang, & Niranjana, 2010; Kim et al., 2007; Lee & Song, 2013). Portanto, propomos como hipótese:

H3: Influência social afeta positivamente a intenção comportamental de usar BDA.

Resistência ao uso consiste na oposição ou reações negativas à implementação de uma nova tecnologia. Como Gibson (2004) conclui, a introdução de muitas tecnologias novas falhou devido à oposição dos usuários à sua implementação. Embora a literatura atual reconheça a resistência ao uso (Kim & Kankanhalli, 2009; Lapointe & Rivard, 2007), poucos estudos a integram no modelo UTAUT. No entanto, existem precedentes para usá-la para explicar a intenção comportamental (Hsieh, 2015). Norzaidi, Salwani, Chong e Rafidah (2008) encontraram relação entre a resistência ao uso e o uso do usuário, o que foi confirmado por outros estudos que não utilizaram o modelo UTAUT (Bhattacharjee & Hikmet, 2007; Poon et al., 2004). Portanto, propomos como hipótese:

H4: Resistência ao uso afeta negativamente a intenção comportamental de usar BDA.

Risco percebido consiste no potencial de perdas na implementação de uma nova tecnologia. Além do trabalho de Featherman e Pavlou (2003), que inclui a escala de medição que utilizamos, muitos estudos consideraram risco percebido como um antecedente com impacto negativo na intenção comportamental (Kim, Ferrin, & Rao, 2008; Lee & Song, 2013; Martins, Oliveira, & Popovič, 2014). Portanto, propomos como hipótese:

H5: Risco percebido afeta negativamente a intenção comportamental de usar BDA.

Condições facilitadoras são favoráveis quando há fácil acesso aos recursos necessários para a utilização de uma nova tecnologia e o suporte subsequente (Venkatesh et al., 2003). Em estudos posteriores utilizando UTAUT2, Venkatesh et al. (2012) descobriram que esse construto tem um efeito significativo sobre a intenção comportamental de usar uma nova tecnologia. Além disso, estudos mais recentes têm verificado efeito positivo dessa variável sobre a intenção comportamental (Duyck et al., 2010; Hung, Wang, & Chou, 2007; Wu, Tao, & Yang, 2007). Assim, propomos como hipótese:

H6: Condições facilitadoras influenciam positivamente a intenção comportamental de usar BDA.

Tanto a TPB (Ajzen, 1991) como o UTAUT (Venkatesh et al., 2003) têm sido usados para demonstrar como as condições facilitadoras favoráveis afetam positivamente o uso de uma nova tecnologia. Vários trabalhos subsequentes (Al-Gahtani et al., 2007; Brünink, 2016; Chauhan & Jaiswal, 2016; Duyck et al., 2010; Kim et al., 2007) confirmam essa relação. Portanto, propomos como hipótese:

H7: Condições facilitadoras afetam positivamente o uso de BDA.

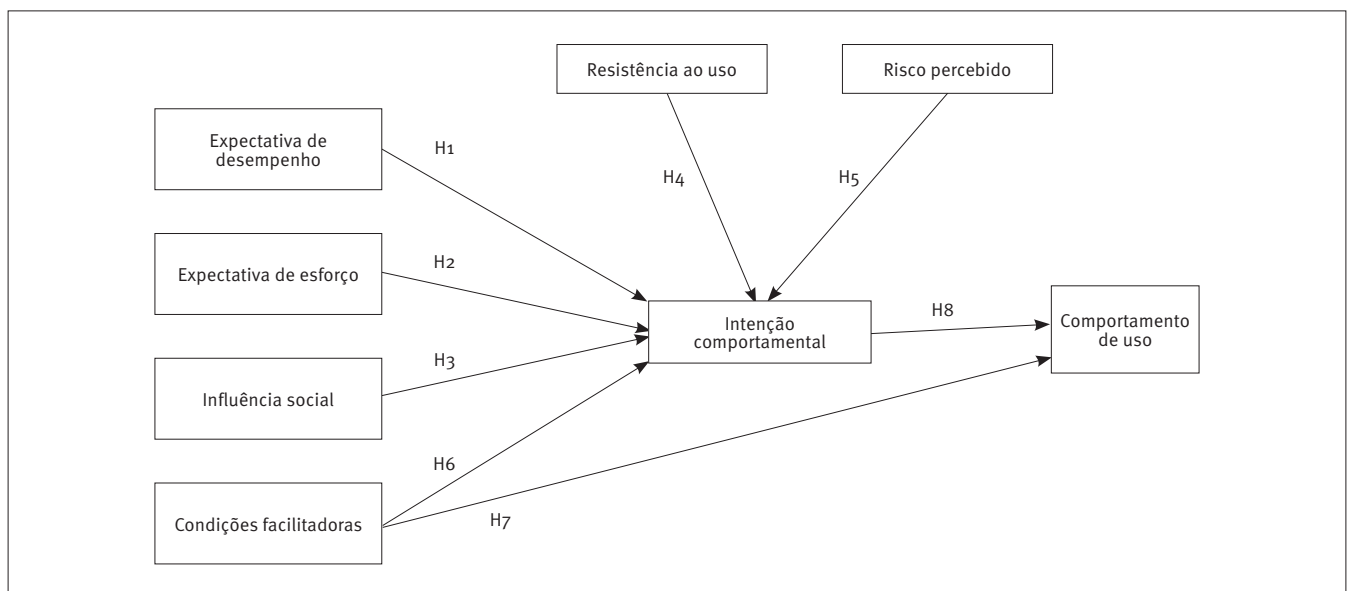
Os principais modelos de aceitação tecnológica (TRA, TAM, UTAUT e UTAUT2) apontam para uma relação direta entre intenção comportamental e uso de tecnologias (Davis, 1985; Fishbein & Ajzen, 1975; Venkatesh et al., 2003, 2012). Essa influência tem sido demonstrada em contextos semelhantes à adoção de BDA, como *internet banking* (Martins et al., 2014), compras de voos *on-line* (Escobar-Rodríguez & Carvajal-Trujillo, 2014), sistemas eletrônicos de gerenciamento de documentos (Afonso,

Gonzalez, Roldán, & Sánchez-Franco, 2012) e *Enterprise Resource Planning* (ERP) (Chauhan & Jaiswal, 2016). Portanto, propomos como hipótese:

H8: A intenção comportamental de usar BDA afeta positivamente seu uso.

Na Figura 2, mostramos o modelo proposto de aceitação e uso de BDA com caminhos identificados em nossas hipóteses.

Figura 2. Modelo de aceitação de Big Data em empresas



METODOLOGIA DE PESQUISA

Descrição da amostra

Nossa pesquisa, cujos dados foram coletados entre setembro e outubro de 2017 via *e-mail* pessoal e telefone, contou com 199 respostas de CEOs e gerentes de empresas atuando em diferentes áreas, como Recursos Humanos, Finanças, *Marketing* e Vendas. Um pré-teste da pesquisa foi realizado com cinco gestores voluntários e vários pesquisadores especialistas, que preencheram o questionário e forneceram *feedback* sobre as questões. Na Tabela 1, classificamos as empresas dos entrevistados de acordo com suas receitas e setores.

Escalas de medição

Para os construtos UTAUT, adaptamos as escalas de Venkatesh et al. (2003) para o contexto do BDA. A resistência ao uso foi medida com a escala proposta por Bhattacherjee e Hikmet (2007), enquanto o risco percebido foi medido com a escala de

Featherman e Pavlou (2003). Escalas Likert de sete pontos foram utilizadas em todos os casos.

Ferramentas estatísticas

Para estimar o modelo estrutural, utilizamos o método de mínimos quadrados parciais (PLS), (Chin & Dibbern, 2010; Hair, Sarstedt, Ringle, & Mena, 2012) com o *software* estatístico Smart PLS 3.2.3 (Ringle, Wende, & Becker, 2015). Para evitar viés de medida, ou *common method bias* (CMB), na amostra observada, seguimos as recomendações de Burton-Jones (2009). Também seguimos as recomendações de Podsakoff, MacKenzie, Lee e Podsakoff (2003), MacKenzie, Podsakoff e Podsakoff (2011); Podsakoff, MacKenzie e Podsakoff (2012), e Kock e Lynn (2012). Porque o estudo se concentra em CMB e PLS para modelos de equações estruturais. Seguindo Kock (2015), adicionamos questões não relacionadas para criar uma variável latente e consideramos esses indicadores e as demais variáveis como antecedentes. A variável CMB atua como a variável dependente de todas as outras variáveis do

modelo. Os fatores de inflação de variância estimados por esse método devem ser inferiores a 3,3 para confirmar que a amostra não tem CMB. Na Tabela 2, demonstramos que nossa amostra está em conformidade com esse requisito.

Tabela 1. Empresas da amostra de acordo com a receita e setor de atividade

	< 2 M€	2M€<X<10M€	10M€<X<43M€	> 43 M€	(não respondido)	- Total
Agricultura	1	3	2	1		7
Comércio e distribuição	5	4	1	10		20
Telecomunicações	6	2	4	14	1	27
Construção	2		1	4		7
Educação	2	1		2		5
Energia	1			3		4
Financeiro	1		2	8		11
Industrial	5	3	2	6		16
Outros	10	10	6	13	2	41
Saúde	3			2		5
Serviços	24	12	9	10		55
(não respondido)					1	1
Total geral	60	35	27	73	4	199

Tabela 2. Variance inflation factor (VIF) de todas as variáveis para verificar CMB

	Variável_CMB
Intenção comportamental	2,423
Expectativa de Esforço	1,631
Condições facilitadoras	2,472
Risco percebido	1,288
Expectativa de desempenho	1,994
Resistência ao uso	1,852
Influência social	1,675
Comportamento de uso	1,996

RESULTADOS

Verificamos a confiabilidade de todos os construtos. A literatura atual sugere que, para que os modelos de medição sejam considerados confiáveis e válidos, as cargas fatoriais devem exceder 0,7 (Henseler, Ringle, & Sarstedt, 2014; Roldán & Sánchez-Franco, 2012). Na Tabela 3, mostramos que cada carga foi superior a 0,7, exceto no caso do terceiro indicador de condições facilitadoras (CF3), o qual foi descartado.

Tabela 3. Confiabilidade das escalas de medição (cargas)

	Intenção comportamental	Expectativa de esforço	Condições facilitadoras	Risco percebido	Expectativa de desempenho	Resistência ao uso	Influência social	Comportamento de uso
IC1	0,970							
IC2	0,986							
IC3	0,984							
IC4	0,974							
EE1		0,777						
EE2		0,887						
EE3		0,898						
EE4		0,874						
EE5		0,806						
CF1			0,874					
CF2			0,892					
CF4			0,847					
RP1				0,927				
RP2				0,924				
RP3				0,877				
ED1					0,899			
ED2					0,868			
ED3					0,909			
ED4					0,918			
ED5					0,785			
ED6					0,829			
ED7					0,784			
RU1						0,931		
RU2						0,964		
RU3						0,938		
RU4						0,902		
IS1							0,741	
IS2							0,877	
IS3							0,817	
IS4							0,792	
IS5							0,724	
CU								1,000

Em seguida, analisou-se a confiabilidade do construto utilizando indicadores de confiabilidade compostos e Alpha de Cronbach. Em todos os casos, os valores dos nossos indicadores foram acima de 0,7, conforme sugerido por Nunnally (1978). A validade convergente foi confirmada pela análise da variância média extraída. Todos os valores estavam acima do limite de 0,5 proposto por Straub, Boudreau e Gefen (2004). Esses indicadores, apresentados na Tabela 4, cumprem os requisitos.

Tabela 4. Confiabilidade composta e validade convergente

	Alfa de Cronbach	rho_A	Confiabilidade composta	Varição Média Extraída (AVE)
Intenção comportamental	0,985	0,986	0,989	0,958
Expectativa de esforço	0,906	0,934	0,928	0,722
Condições facilitadoras	0,841	0,843	0,904	0,759
Risco percebido	0,896	0,909	0,935	0,828
Expectativa de desempenho	0,940	0,947	0,951	0,736
Resistência ao uso	0,951	0,954	0,965	0,872
Influência social	0,851	0,874	0,893	0,627
Comportamento de uso	1,000	1,000	1,000	1,000

Em seguida, avaliamos a validade discriminante do modelo de medição de duas maneiras. Primeiro, realizamos o teste de Fornell e Larcker (Barclay, Higgins, & Thompson, 1995). Em seguida, usando a razão Heterotrait-Monotrait (HTMT) (Henseler et al., 2014), asseguramos que os valores estavam abaixo de 0,9 em todos os casos. Os resultados de ambos os testes são apresentados nas Tabelas 5 e 6.

Tabela 5. Validade discriminante (teste de Fornell-Larcker)

	Intenção comportamental	Expectativa de esforço	Condições facilitadoras	Risco percebido	Expectativa de desempenho	Resistência ao uso	Influência social	Comportamento de uso
Intenção comportamental	0,979							
Expectativa de esforço	0,384	0,850						
Condições facilitadoras	0,628	0,587	0,871					
Risco percebido	-0,331	-0,185	-0,283	0,910				
Expectativa de desempenho	0,544	0,434	0,373	-0,195	0,858			
Resistência ao uso	-0,506	-0,258	-0,343	0,408	-0,566	0,934		
Influência social	0,497	0,459	0,483	-0,246	0,479	-0,234	0,792	
Comportamento de uso	0,630	0,361	0,624	-0,276	0,402	-0,400	0,449	1,000

Tabela 6. Validade discriminante (Relação Heterotrait-Monotrait -HTMT)

	Intenção comportamental	Expectativa de esforço	Condições facilitadoras	Risco percebido	Expectativa de desempenho	Resistência ao uso	Influência social	Comportamento de uso
Intenção comportamental								
Expectativa de esforço	0,380							
Condições facilitadoras	0,690	0,649						
Risco percebido	0,349	0,202	0,324					
Expectativa de desempenho	0,559	0,449	0,411	0,206				
Resistência ao uso	0,521	0,269	0,383	0,443	0,597			
Influência social	0,532	0,507	0,567	0,297	0,524	0,254		
Comportamento de uso	0,635	0,355	0,679	0,287	0,405	0,408	0,476	

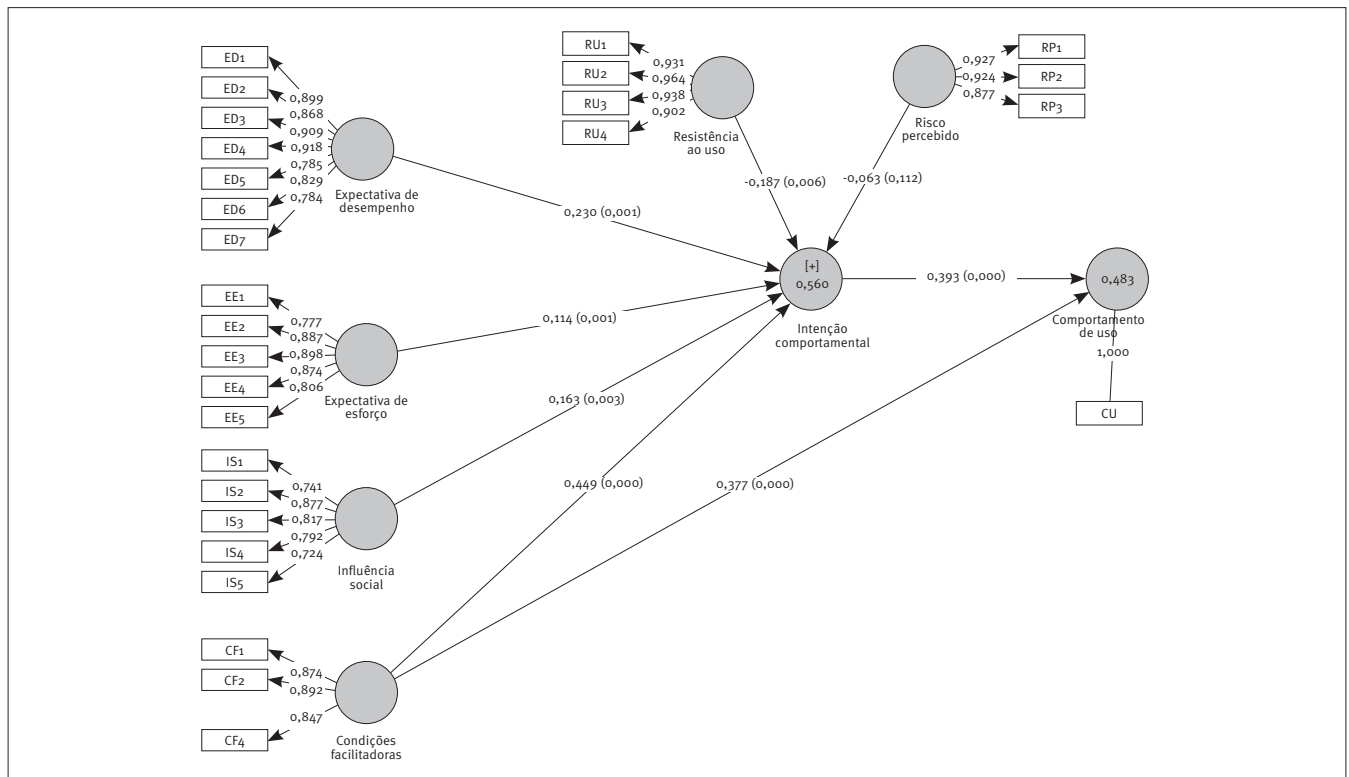
Os valores de R² para os construtos de segunda ordem (intenção comportamental e comportamento de uso) são mostrados na Tabela 7.

Tabela 7. R² do modelo

	R ²	R ² ajustado
Intenção comportamental	0,560	0,546
Comportamento de uso	0,483	0,478

A Figura 3 mostra os valores para cada carga e caminho do modelo.

Figura 3. Resultados do modelo



Os valores dos coeficientes de caminho e a variância explicada das variáveis endógenas (R^2) foram analisados para avaliar o modelo estrutural. Os coeficientes de caminho indicam a intensidade da relação entre as variáveis independentes e dependentes. Utilizamos uma técnica de *bootstrapping* com 5 mil amostras para encontrar a confiabilidade dos coeficientes de caminho estimados, conforme é mostrado na Tabela 8.

Tabela 8. Estimativas do modelo estrutural (coeficientes de caminho)

Amostra inteira	Amostra original (O)	Valores-P
Intenção comportamental -> Comportamento de uso	0,393 ***	0,000
Expectativa de esforço -> Intenção comportamental	-0,114 *	0,032
Condições facilitadoras -> Intenção comportamental	0,449 ***	0,000
Condições facilitadoras -> Comportamento de uso	0,377 ***	0,000
Risco percebido -> Intenção comportamental	-0,063 (n. s.)	0,112
Expectativa de desempenho -> Intenção comportamental	0,230 ***	0,001
Resistência ao Uso -> Intenção comportamental	-0,187 **	0,006
Influência Social -> Intenção comportamental	0,163 **	0,003

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$. (bootstrapping com 5.000 sub-amostras e teste unicaudal).

Relações significativas com coeficientes de caminho e valor-p em negrito.

Calculou-se o indicador *Standardized Root Mean-square Residual* (SRMR) para avaliar o ajuste do modelo. O valor obtido, 0,065, foi menor que o limiar de 0,08 proposto por Henseler et al. (2014), o que sugere um bom ajuste do modelo. O modelo explica 47,85% da variação no uso e 54,6% da variação na intenção comportamental (ver Tabela 7), ambos excedendo o nível mínimo de 10% recomendado por Falk e Miller (1992).

Os resultados confirmam a maioria das hipóteses, exceto H5 (risco percebido) e H2 (expectativa de esforço). Os coeficientes das hipóteses confirmadas são significativos no nível de confiança de 1%. Embora a expectativa de esforço seja

significativa no nível de confiança de 5%, encontramos uma relação negativa devido a um efeito supressor (Falk & Miller, 1992) produzido pela nova relação de condições facilitadoras na intenção comportamental, então podemos rejeitar H2. Em ordem de influência, podemos ver que o fator condições facilitadoras é o que mais contribui para a intenção comportamental e o segundo que mais contribui para o uso. O segundo fator que mais contribui para a intenção comportamental é a expectativa de desempenho, enquanto o fator que mais contribui para o uso é a intenção comportamental. Observamos também que o coeficiente de intenção comportamental de uso é significativo no nível de confiança de 0,1%. O coeficiente do efeito da resistência ao uso na intenção comportamental é significativo e negativo.

Também calculamos o Stone-Geisser Q^2 para avaliar a capacidade preditiva do modelo (Gefen, Rigdon, & Straub, 2011). Os resultados são apresentados na Tabela 9. Conclui-se que o modelo tem relevância preditiva, pois os valores de Q^2 na Tabela 9 são maiores que zero (Roldán & Sánchez-Franco, 2012).

Tabela 9. Previsão de variáveis latentes

	REQM	Q^2
Intenção comportamental	0,558	0,502
Comportamento de uso	0,522	0,397

Considerou-se a possibilidade de heterogeneidade na amostra. Seguindo Becker, Rai, Ringle e Völckner (2013), executamos uma segmentação de classe latente PLS-POS e também uma segmentação de classe latente FIMIX. Não encontramos diferenças em grupos com segmentação *a posteriori*.

Em seguida, tentamos várias segmentações *a priori* com critérios diferentes (por exemplo, tamanho da empresa, uso de *Big Data*, setor de atividade), não encontrando diferenças entre essas subamostras. No entanto, encontramos diferentes comportamentos nas empresas quando estas eram perguntadas sobre o nível de maturidade da implementação do BDA. Utilizamos a escala proposta por Paulk, Curtis, Chrissis e Weber (1993), que tem sido amplamente utilizada (Berg, Leinonen, Leivo, & Pihlajamaa, 2002; Khatibian, Hasan, & Jafari, 2010; Urwiler & Frolick, 2008) e tem cinco níveis: inicial, replicável, definido, gerenciado e otimizado. Foram escolhidas empresas que não tinham implementado BDA ou que estavam nos dois primeiros níveis do Segmento 1 e aquelas nos últimos três níveis do Segmento 2. Tal como indicado na Tabela 10 para o Segmento 1 e na Tabela 11 para o Segmento 2, existem diferenças significativas entre esses dois segmentos e a amostra inteira (ver Tabela 8).

Tabela 10. Segmento 1. Estimativas do modelo estrutural (coeficientes de caminho)

NÃO USUÁRIOS E INICIANTES Segmento 1. Tamanho: 152 empresas	Amostra original (O)	Valores-P
Intenção comportamental -> Comportamento de uso	0,387 ***	0,000
Expectativa de esforço -> Intenção comportamental	-0,092 (n. s.)	0,094
Condições facilitadoras -> Intenção comportamental	0,344 ***	0,000
Condições facilitadoras -> Comportamento de uso	0,237 **	0,002
Risco percebido -> Intenção comportamental	-0,073 (n. s.)	0,106
Expectativa de desempenho -> Intenção comportamental	0,330 ***	0,000
Resistência ao uso -> Intenção comportamental	-0,227 **	0,002
Influência social -> Intenção comportamental	0,189 **	0,002

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$. (bootstrapping com 5.000 sub-amostras e teste unicaudal).

Relações significativas com coeficientes de caminho e valor-p em negrito.

Tabela 11. Segmento 2. Estimativas do modelo estrutural (coeficientes de caminho)

USUÁRIOS NORMAIS E HEAVY USERS Segmento 2. Tamanho: 47 empresas	Amostra original (O)	Valores-P
Intenção comportamental -> Comportamento de uso	0,561 ***	0,001
Expectativa de esforço -> Intenção comportamental	-0,186 (n. s.)	0,084
Condições facilitadoras -> Intenção comportamental	0,648 ***	0,001
Condições facilitadoras -> Comportamento de uso	0,128 (n. s.)	0,188
Risco percebido -> Intenção comportamental	-0,188 (n. s.)	0,106
Expectativa de desempenho -> Intenção comportamental	-0,214 (n. s.)	0,174
Resistência ao uso -> Intenção comportamental	-0,207 (n. s.)	0,172
Influência social -> Intenção comportamental	0,056 (n. s.)	0,354

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$. (bootstrapping com 5.000 sub-amostras e teste unicaudal).

Relações significativas com coeficientes de caminho e valor-p em negrito.

Realizamos um teste Anova e confirmamos as diferenças significativas entre as subamostras. Para as empresas não usuárias ou iniciantes (Segmento 1), todas as relações foram significativas, exceto os efeitos do risco percebido e da expectativa de esforço sobre a intenção comportamental. As condições facilitadoras e a expectativa de desempenho foram os fatores que mais contribuíram para a intenção comportamental, com altos níveis de significância. Os coeficientes de resistência ao uso e influência social também foram grandes e significativos. Para usuários normais e usuários pesados (Segmento 2), nenhuma das relações foi significativa, exceto o efeito das condições facilitadoras na intenção comportamental, que teve o efeito mais significativo entre todas as relações deste estudo. Curiosamente, a expectativa de desempenho não foi significativa.

DISCUSSÃO, CONCLUSÕES E LIMITAÇÕES

Nossa pesquisa amplia o modelo UTAUT para *Big Data* com uma nova variável, resistência ao uso. Com essa extensão, contribuimos para a generalização do modelo e para uma melhor compreensão da aceitação tecnológica. Nosso modelo inova, em relação à pesquisa anterior sobre BDA, ao incluir uma nova variável independente, resistência ao uso, ao modelo UTAUT e incluir o comportamento de uso de BDA como variável de desfecho. Brünink (2016) usa o modelo UTAUT sem adicionar resistência ao uso ou explicar o comportamento real de uso. Outros estudos (Demoulin & Cousssement, 2018) concentram-se no apoio do uso de aplicações de *Big Data* pela gestão, utilizando modelos como TAM, TAM2 ou TAM3 (Brown & Venkatesh, 2005; Huang et al., 2012; Verma et al., 2018). Esses modelos explicam a adoção e o uso real de BDA nas empresas, mas são mais limitados do que o modelo UTAUT.

Nossos resultados mostram que a intenção comportamental de usar BDA nas empresas é determinada por quatro fatores. Primeiro, a expectativa de desempenho, a percepção de que a implementação dessa tecnologia alcançará bons resultados, aumenta a adoção, como mostrado em estudos anteriores (Lee & Song, 2013; Yu, 2012). Segundo, a influência social tem um efeito positivo sobre a intenção de usar BDA, como demonstrado em artigos anteriores (Bozan, Parker, & Davey, 2016). Terceiro, condições facilitadoras, o apoio e o fornecimento de recursos necessários para o uso por parte da empresa aumenta tanto a intenção comportamental quanto o uso (Alharbi, 2014). Finalmente, a resistência ao uso diminui as intenções comportamentais de uso de BDA nas empresas, com um efeito mais significativo do que a influência social.

Também constatamos que, embora o BDA seja percebido como sendo de difícil uso (expectativa de esforço), a influência dessa percepção sobre a intenção comportamental é pequena e contida em outras relações: condições facilitadoras na intenção comportamental (efeito supressor acima mencionado).

Também encontramos um efeito positivo das condições facilitadoras sobre o comportamento de uso da nova tecnologia com um fator semelhante para intenção comportamental. Assim, pode-se dizer que os achados são consistentes com todas as hipóteses do modelo UTAUT, exceto H5 (risco percebido). Por acharmos que resistência ao uso tem um efeito significativo, propomos acrescentá-la ao modelo original, a fim de obter melhores explicações sobre a aceitação e uso de BDA nas empresas.

Finalmente, destacamos as diferenças de comportamento entre as empresas que não utilizam essas técnicas ou estão começando a utilizá-las (Segmento 1) e as empresas que já as utilizam há muito tempo (Segmento 2). Para as empresas iniciantes ou não usuárias, a expectativa de desempenho, a influência social e as condições facilitadoras têm efeito significativo e positivo na intenção comportamental e comportamento de uso, enquanto a resistência ao uso têm efeito significativo e negativo em ambas variáveis. Entre as empresas usuárias normais e usuárias pesadas, apenas condições facilitadoras têm efeito sobre a intenção comportamental, enquanto o resto das relações não é significativo. Isso pode sugerir que os usuários estabelecidos sabem o que podem alcançar com essas técnicas, então a única coisa com que eles se importam é ter boas condições facilitadoras, enquanto os iniciantes ainda não conhecem todas as capacidades dessa tecnologia, então eles consideram mais questões.

Quanto às implicações profissionais, os resultados sugerem que os executivos inferem que cada tecnologia tem sua própria curva de aprendizagem, e essa questão não afeta sua adoção sempre que grandes resultados são esperados, como no caso do *Big Data* (Cabrera-Sánchez & Villarejo-Ramos, 2018). Da mesma forma, se a empresa tem uma infraestrutura adequada, não tem nada a perder testando a tecnologia. De qualquer forma, para superar a resistência ao uso de BDA, ainda são necessárias informações claras sobre seus benefícios. Portanto, recomendamos duas etapas para gerentes. Na primeira etapa, eles devem ser informados de que a maioria dos *softwares* associados a essas técnicas é gratuito e que, se eles já têm recursos de *hardware*, devem testá-los. Na segunda etapa, deve haver comunicação com os gestores sobre os benefícios do uso de *Big Data*, inclusive com exemplos de empresas das mesmas áreas que o utilizam. Essa segunda ação é muito importante para as empresas que estão atualmente usando *Big Data*,

porque podemos inferir que elas não estão aproveitando todo o potencial da tecnologia. Elas possuem uma certa insatisfação com a tecnologia, e têm uma expectativa de desempenho muito baixa, quando o que deveria acontecer seria o oposto. Portanto, devemos informá-las sobre a tecnologia e como ela pode ser usada para gerar lucros em cada setor.

O uso de BDA nas empresas pode representar um avanço muito importante na gestão da informação, melhorando as relações com os clientes. Como é mais do que uma ferramenta de gerenciamento de relacionamento com o cliente, o BDA fornece informações relevantes às empresas e aumenta o conhecimento sobre os clientes, melhorando seu engajamento.

Embora o modelo UTAUT já tenha sido bastante testado e seja maduro, incluímos duas variáveis para estendê-lo. No entanto, muitas outras variáveis podem ser relevantes. Para essa tecnologia, construtos do modelo original, como a expectativa de desempenho, têm menor influência sobre a intenção comportamental do que um dos construtos que adicionamos, resistência ao uso. Como podem existir outras variáveis com efeitos significativos, o modelo UTAUT deve continuar evoluindo para fornecer melhores explicações para a aceitação de novas tecnologias. Pesquisas futuras sobre *Big Data* devem procurar identificar essas variáveis. Além disso, parece necessário explorar novas variáveis moderadoras com o objetivo de analisar possíveis efeitos não considerados anteriormente.

Finalmente, tamanhos amostrais maiores nos permitirão estabelecer diferenças de comportamento entre grupos de empresas, o que podemos analisar por meio de uma técnica de segmentação *a posteriori*, como segmentação orientada *a posteriori* – Mínimos Quadrados Parciais (POS-PLS). Então, se obtivermos uma amostra maior de empresas que estão usando (ou pretendem usar) *Big Data*, teremos um modelo com melhor desempenho e resultados mais informativos.

REFERÊNCIAS

- Afonso, C., Gonzalez, M., Roldán, J., & Sánchez-Franco, M. (2012). Determinants of user acceptance of a local eGovernment Electronic Document Management System (EDMS). In *Proceedings of the 12th European Conference on e-Government, ECEG* (pp. 19-28), Barcelona: Academic Publishing International Limited.
- Agrawal, D., Bernstein, P., & Bertino, E. (2011). Challenges and opportunities with Big Data 2011-1. *Proceedings of the VLDB Endowment* (pp. 1-16). Retrieved from <http://dl.acm.org/citation.cfm?id=2367572%5Cnhttp://docs.lib.purdue.edu/cctech/1/>
- Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179-211. doi:10.1016/0749-5978(91)90020-T

- Akerkar, R. (2014). Analytics on big aviation data: Turning data into insights. *International Journal of Computer Science and Applications*, 11(3), 116-127.
- Al-Gahtani, S. S., Hubona, G. S., & Wang, J. (2007). Information technology (IT) in Saudi Arabia: Culture and the acceptance and use of IT. *Information & Management*, 44(8), 681-691. doi:10.1016/j.im.2007.09.002
- Alharbi, S. T. (2014). Trust and acceptance of cloud computing: A revised UTAUT model. *Proceedings - 2014 International Conference on Computational Science and Computational Intelligence, CSCI 2014*, 2(Mm) (pp. 131-134). doi:10.1109/CSCI.2014.107
- Amado, A., Cortez, P., Rita, P., & Moro, S. (2018). Research trends on Big Data in marketing: A text mining and topic modeling based literature analysis. *European Research on Management and Business Economics*, 24(1), 1-7. doi:10.1016/j.iedeen.2017.06.002
- Arenas-Gaitán, J., Peral-Peral, B., & Villarejo-Ramos, A.-F. (2016). Grupos de mayores en la banca electrónica. Segmentación de clases latentes con PLS-POS. In *Congreso Marketing AEMARK*. Madrid, Spain.
- Barclay, D., Higgins, C., & Thompson, R. (1995). The Partial Least Squares (PLS) approach to causal modelling: Personal computer adoption and use as an illustration. *Technology Studies*, 2(2), 285-309.
- Becker, J.-M., Rai, A., Ringle, C. M., & Völckner, F. (2013). Discovering unobserved heterogeneity in structural equation models to avert Validity threats. *MIS Quarterly*, 37(3), 665-694. doi:10.25300/MISQ/2013/37.3.01
- Berg, P., Leinonen, M., Leivo, V., & Pihlajamaa, J. (2002). Assessment of quality and maturity level of R&D. *International Journal of Production Economics*, 78(1), 29-35. doi:10.1016/S0925-5273(00)00166-3
- Bhattacharjee, A., & Hikmet, N. (2007). Physicians' resistance toward healthcare information technology: A theoretical model and empirical test. *European Journal of Information Systems*, 16(6), 725-737. doi:10.1057/palgrave.ejis.3000717
- Bozan, K., Parker, K., & Davey, B. (2016). A closer look at the social influence construct in the UTAUT Model: An institutional theory based approach to investigate health IT adoption patterns of the elderly. *Proceedings of the Annual Hawaii International Conference on System Sciences, 2016-March* (pp. 3105-3114). doi:10.1109/HICSS.2016.391
- Brown, S. A., & Venkatesh, V. (2005). Model of adoption of technology in households: A baseline model test and extension incorporating household life cycle. *MIS Quarterly*, 29(3), 399-426. doi:10.2307/25148690
- Brünink, L. (2016). *Cross-functional Big Data integration: Applying the UTAUT model*. University of Twente (The Netherlands).
- Burton-Jones. (2009). Minimizing method bias through programmatic research. *MIS Quarterly*, 33(3), 445-471. doi:10.2307/20650304
- Cabrera-Sánchez, J.-P., & Villarejo-Ramos, Á.-F. (2018). Factores que afectan a la adopción del Big Data como instrumento de marketing en las empresas españolas. In *XXVIII Jornadas Luso-Espanholas de Gestão Científica*, At Guarda (Portugal).
- Chauhan, S., & Jaiswal, M. (2016). Determinants of acceptance of ERP software training in business schools: Empirical investigation using UTAUT model. *International Journal of Management Education*, 14(3), 248-262. doi:10.1016/j.ijme.2016.05.005
- Chiang, R. H. L., Grover, V., Liang, T.-P., & Zhang, D. (2018). Special issue: strategic value of Big Data and business analytics. *Journal of Management Information Systems*, 35(2), 383-387. doi:10.1080/07421222.2018.1451950
- Chin, W. W., & Dibbern, J. (2010). An introduction to a permutation based procedure for multi-group PLS analysis: Results of differences on simulated data and a cross-cultural analysis of the sourcing of information system services between Germany and the USA. In V. E. Vinzi, W. W. Chin, J. Henseler, & H. Wang (Eds.), *Handbook of partial least squares* (pp. 171-193). doi:10.1007/978-3-540-32827-8
- Claudy, M. C., Garcia, R., & O'Driscoll, A. (2015). Consumer resistance to innovation: A behavioral reasoning perspective. *Journal of the Academy of Marketing Science*, 43(4), 528-544. doi:10.1007/s11747-014-0399-0
- Davis, F. (1985). *A technology acceptance model for empirically testing new end-user information systems*. Massachusetts Institute of Technology, Sloan School of Management (December).
- Demoulin, N. T. M., & Coussement, K. (2018). Acceptance of text-mining systems: The signaling role of information quality. *Information & Management*. Advanced online publication. doi:10.1016/j.im.2018.10.006
- Ducange, P., Pecori, R., & Mezzina, P. (2018). A glimpse on big data analytics in the framework of marketing strategies. *Soft Computing*, 22(1), 325-342. doi:10.1007/s00500-017-2536-4
- Duyck, P., Pynoo, B., Devolder, P., Voet, T., Adang, L., Ovaere, D., & Vercruysse, J. (2010). Monitoring the PACS implementation process in a large university hospital-discrepancies between radiologists and physicians. *Journal of Digital Imaging*, 23(1), 73-80. doi:10.1007/s10278-008-9163-7
- Escobar-Rodríguez, T., & Carvajal-Trujillo, E. (2014). Online purchasing tickets for low cost carriers: An application of the unified theory of acceptance and use of technology (UTAUT) model. *Tourism Management*, 43, 70-88. doi:10.1016/j.tourman.2014.01.017
- Falk, R. F., & Miller, N. B. (1992). *A primer for soft modeling*. Akron, OH: University of Akron Press.
- Featherman, M. S., & Pavlou, P. A. (2003). Predicting e-services adoption: A perceived risk facets perspective. *International Journal of Human Computer Studies*, 59(4), 451-474. doi:10.1016/S1071-5819(03)00111-3
- Fishbein, M., & Ajzen, I. (1975). *Belief attitude, intention and behavior. An introduction to theory and research*. Reading, MA: Addison-Wesley.
- Gargallo López, B., Suárez Rodríguez, J., & Almerich Cerveró, G. (2006). La influencia de las actitudes de los profesores en el uso de las nuevas tecnologías. *Revista Espanola de Pedagogía*, 64(233), 45-66.
- Gefen, D., Rigdon, E. E., & Straub, D. (2011). An update and extension to SEM guidelines for administrative and social science research. *MIS Quarterly*, 35(2), 3-14. doi:10.1016/j.lrp.2013.01.001
- Gibson, C.F. (2004). IT-enabled business change: An approach to understanding and managing risk. *MIT Sloan Working Paper No. 4520-04*; *CISR Working Paper No. 346*. doi:10.2139/ssrn.644922
- Gupta, V. K., Huang, R., & Niranjana, S. (2010). A longitudinal examination of the relationship between team leadership and performance. *Journal of Leadership & Organizational Studies*, 17(4), 335-350. doi:10.1177/1548051809359184

- Hair, J. F., Sarstedt, M., Ringle, C. M., & Mena, J. A. (2012). An assessment of the use of partial least squares structural equation modeling in marketing research. *Journal of the Academy of Marketing Science*, 40(3), 414-433. doi:10.1007/s11747-011-0261-6
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2014). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115-135. doi:10.1007/s11747-014-0403-8
- Hsieh, P. J. (2015). Healthcare professionals' use of health clouds: Integrating technology acceptance and status quo bias perspectives. *International Journal of Medical Informatics*, 84(7), 512-523. doi:10.1016/j.ijmedinf.2015.03.004
- 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
- Hung, Y. H., Wang, Y. S., & Chou, S. C. T. (2007). User acceptance of e-government services. *PACIS 2007 Proceedings*, 97. Retrieved from <http://aisel.aisnet.org/pacis2007>
- Ives, B., & Olson, M. H. (2008). User involvement and MIS success: A review of research. *Management Science*, 30(5), 586-603. doi:10.1287/mnsc.30.5.586
- Khatibian, N., Hasan gholi pour, T., & Abedi Jafari, H. (2010). Measurement of knowledge management maturity level within organizations. *Business Strategy Series*, 11(1), 54-70. doi:10.1108/17515631011013113
- Kim, D. J., Ferrin, D. L., & Rao, H. R. (2008). A trust-based consumer decision-making model in electronic commerce: The role of trust, perceived risk, and their antecedents. *Decision Support Systems*, 44(2), 544-564. doi:10.1016/j.dss.2007.07.001
- Kim, H.-W., & Kankanhalli, A. (2009). Investigating user resistance to information systems implementation: A status quo bias perspective. *MIS Quarterly*, 33(3), 567-582. doi:10.2307/20650309
- Kim, H. W., Chan, H. C., & Gupta, S. (2007). Value-based adoption of mobile internet: An empirical investigation. *Decision Support Systems*, 43(1), 111-126. doi:10.1016/j.dss.2005.05.009
- Kock, N. (2015). Common method bias in PLS-SEM: A full collinearity assessment approach. *International Journal of E-Collaboration*, 11(4), 1-10. doi:10.4018/ijec.2015100101
- Kock, N., & Lynn, G. S. (2012). Lateral collinearity and misleading results in variance-based SEM: An illustration and recommendations. *Journal of the Association for Information Systems*, 13(7), 546-580.
- Kwon, O., Lee, N., & Shin, B. (2014). Data quality management, data usage experience and acquisition intention of big data analytics. *International Journal of Information Management*, 34(3), 387-394. / doi:10.1016/j.ijinfomgt.2014.02.002
- Lai, Y., Sun, H., & Ren, J. (2017). Understanding the determinants of big data analytics (BDA) adoption in logistics and supply chain management: An empirical investigation. *International Journal of Logistics Management*, 29(2), 676-703. doi. 10.1108/IJLM-06-2017-0153
- Lapointe, L., & Rivard, S. (2007). A triple take on information system implementation. *Organization Science*, 18(1), 89-107. doi:10.1287/orsc.1060.0225
- Laumer, S., Maier, C., Eckhardt, A., & Weitzel, T. (2016). User personality and resistance to mandatory information systems in organizations: A theoretical model and empirical test of dispositional resistance to change. *Journal of Information Technology*, 31(1), 67-82. doi:10.1057/jit.2015.17
- Lee, J. H., & Song, C. H. (2013). Effects of trust and perceived risk on user acceptance of a new technology service. *Social Behavior and Personality: An International Journal*, 41(4), 587-597. doi:10.2224/sbp.2013.41.4.587
- Liu, X., Shin, H., & Burns, A. C. (2019). Examining the impact of luxury brand's social media marketing on customer engagement: Using big data analytics and natural language processing. *Journal of Business Research*. Advanced online publication. doi: 10.1016/j.jbusres.2019.04.042
- 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
- McAfee, A., & Brynjolfsson, E. (2012). Big Data: The management revolution. *Harvard Business Review*, 90(10), 61-68. <https://doi.org/10.1007/s12599-013-0249-5>
- MacKenzie, S. B., Podsakoff, P. M., & Podsakoff, N. P. (2011). Construct measurement and validation procedures in MIS and behavioral research: Integrating new and existing techniques. *MIS Quarterly*, 35(2), 293-334. doi:10.2307/23044045
- Norzaidi, M. D., Salwani, M. I., Chong, S. C., & Rafidah, K. (2008). A study of intranet usage and resistance in Malaysia's port industry. *Journal of Computer Information Systems*, 49(1), 37-47. doi:10.1080/08874417.2008.11645304
- Nunnally, J. C. (1978). *Psychometric theory* (2nd edit.) Hillsdale, NJ: McGraw-hill.
- Palmatier, R. W., & Martin, K. D. (2019). Understanding and valuing customer data. In R. W. Palmatier & K. D. Martin, *The Intelligent Marketer's Guide to Data Privacy* (pp. 73-92). Palgrave Macmillan, Cham. doi:10.1007/978-3-030-03724-6
- Paulk, M. C., Curtis, B., Chrissis, M. B., & Weber, C. V. (1993). Capability maturity model, version 1.1. *IEEE Software*, 10(4), 18-27. doi:10.1109/52.219617
- Podsakoff, P. M., MacKenzie, S. B., Lee, J.-Y., & Podsakoff, N. P. (2003). Common method biases in behavioral research: A critical review of the literature and recommended remedies. *Journal of Applied Psychology*, 88(5), 879-903. doi:10.1037/0021-9010.88.5.879
- Podsakoff, P. M., MacKenzie, S. B., & Podsakoff, N. P. (2012). Sources of method bias in social science research and recommendations on how to control it. *Annual Review of Psychology*, 63, 539-569. doi:10.1146/annurev-psych-120710-100452
- Poon, E. G., Blumenthal, D., Jaggi, T., Honour, M. M., Bates, D. W., & Kaushal, R. (2004). Overcoming barriers to adopting and implementing computerized physician order entry systems in U.S. hospitals. *Health Affairs*, 23(4), 184-190. doi:10.1377/hlthaff.23.4.184
- Rahman, N. (2016). Factors affecting Big Data technology adoption, 0-29. *Student Research Symposium*. Retrieved from <http://pdxscholar.library.pdx.edu/studentsymposium%5Cnhttp://pdxscholar.library.pdx.edu/studentsymposium/2016/Presentations/10>

- Rehman, M. H. U., Chang, V., Batool, A., & Wah, T. Y. (2016). Big data reduction framework for value creation in sustainable enterprises. *International Journal of Information Management*, 36(6), 917-928. doi:10.1016/j.ijinfomgt.2016.05.013
- Ringle, C. M., Wende, S., & Becker, J. M. (2015). SmartPLS. "SmartPLS 3." Boenningstedt: SmartPLS GmbH. Retrieved from <http://www.smartpls.com>
- Roldán, J. L., & Sánchez-Franco, M. J. (2012). Variance-based structural equation modeling: Guidelines for using partial least squares in information systems research. In M. Mora, O. Gelman, A.L. Steenkamp & M. Raisinghani, *Research methodologies, innovations and philosophies in software systems engineering and information systems*. IGI-Global. doi:10.4018/978-1-4666-0179-6.ch010
- Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of Big Data challenges and analytical methods. *Journal of Business Research*, 70, 263-286. <https://doi.org/10.1016/j.jbusres.2016.08.001>
- Straub, D., Boudreau, M., & Gefen, D. (2004). Validation guidelines for IS positivist research. *Communications of the Association for Information Systems*, 13(24), 380-427. doi:10.17705/1CAIS.01324
- Sun, Z., Sun, L., & Strang, K. (2018). Big Data analytics services for enhancing business intelligence. *Journal of Computer Information Systems*, 58(2), 162-169. doi:10.1080/08874417.2016.1220239
- Urwiler, R., & Frolick, M. N. (2008). The IT value hierarchy: Using Maslow's hierarchy of needs as a metaphor for gauging the maturity level of information technology use within competitive organizations. *Information Systems Management*, 25(1), 83-88. doi:10.1080/10580530701777206
- Venkatesh, V., & Bala, H. (2008). Technology acceptance model 3 and a research agenda on interventions. *Decision Sciences*, 39 (2), 273-315. doi:10.1111/j.1540-5915.2008.00192.x
- Venkatesh, V., & Davis, F. D. (2000). A theoretical extension of the technology acceptance model: Four longitudinal field studies. *Management Science*, 46(2), 186-204. doi:10.1287/mnsc.46.2.186.11926
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425-478. doi:10.2307/30036540
- Venkatesh, V., Thong, J. Y. L., & Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 36(1), 157-178. doi:10.1017/CBO9781107415324.004
- Verma, S., Bhattacharyya, S. S., & Kumar, S. (2018). An extension of the technology acceptance model in the big data analytics system implementation environment. *Information Processing and Management*, 54(5), 791-806. doi:10.1016/j.ipm.2018.01.004
- Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(November), 97-121. doi:10.1509/jm.15.0413
- Watson, H. J. (2019). Update tutorial: Big Data analytics: Concepts, technology, and applications. *Communications of the Association for Information Systems*, 44(1), 364-379. doi:10.17705/1CAIS.04421
- Wright, L. T., Robin, R., Stone, M., & Aravopoulou, D. E. (2019). Adoption of Big Data technology for innovation in B2B marketing. *Journal of Business-to-Business Marketing*. Advanced online publication. doi:10.1080/1051712X.2019.1611082
- Wu, Y. L., Tao, Y. H., & Yang, P. C. (2007). Using UTAUT to explore the behavior of 3G mobile communication users. *IEEM 2007: 2007 IEEE International Conference on Industrial Engineering and Engineering Management* (pp. 199-203). doi:10.1109/IEEM.2007.4419179
- Yadegaridehkordi, E., Hourmand, M., Nilashi, M., Shuib, L., Ahani, A., & Ibrahim, O. (2018). Influence of big data adoption on manufacturing companies' performance: An integrated DEMATEL-ANFIS approach. *Technological Forecasting and Social Change*, 137(March), 199-210. doi:10.1016/j.techfore.2018.07.043
- Yaqoob, I., Hashem, I. A. T., Gani, A., Mokhtar, S., Ahmed, E., Anuar, N. B., & Vasilakos, A. V. (2016). Big data: From beginning to future. *International Journal of Information Management*, 36(6), 1231-1247. doi:10.1016/j.ijinfomgt.2016.07.009
- Yu, C.-S. (2012). Factors affecting individuals to adopt mobile banking: Empirical evidence from the UTAUT model. *Journal of Electronic Commerce Research*, 13(2), 104-121.
- Zicari, R. (2014). Big data: Challenges and opportunities. In R. Akerkar (Ed.), *Big Data Computing* (pp. 103-128). Boca Raton, FL: CRC Press. doi:10.1201/b16014-5