

FÓRUM

Submetido 01.10.2018. 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/S0034-759020190604>

CAPACIDADE DE GESTÃO DA INFORMAÇÃO E IMPLEMENTAÇÃO DE ESTRATÉGIA DE *BIG DATA*

Information management capability and Big Data strategy implementation

Capacidad de gestión de la información e implementación de estrategia de Big Data

RESUMO

O interesse das organizações em desenvolver estratégias de *Big Data* está aumentando significativamente. No entanto, a expectativa do valor desses benefícios e dos custos envolvidos na aquisição ou desenvolvimento dessas soluções não é homogênea para todas as empresas, gerando imperfeições competitivas no mercado de recursos estratégicos. A capacidade de gestão da informação (CGI) tem como premissa fornecer as informações necessárias para que as estratégias de *Big Data* sejam bem-sucedidas. Este artigo se propõe a analisar a CGI como um agente de imperfeição no mercado de fatores estratégicos de *Big Data*. As hipóteses foram testadas a partir de uma Survey com 101 respondentes e analisadas com a utilização de SEM-PLS. Os resultados indicam uma influência CGI positiva na expectativa de valor e uma negativa na expectativa de custo. A expectativa de custo afeta inversamente a intenção de comprar ou desenvolver os recursos para implantar estratégias de *Big Data*. A expectativa de valor tem um efeito positivo em ambas as intenções.

PALAVRAS-CHAVE | *Big Data*, gestão da informação, strategic factor market, expectativa de valor, expectativa de custo.

ABSTRACT

Firms are increasingly interested in developing Big Data strategies. However, the expectation of the value of these benefits and of the costs involved in acquiring or developing these solutions are not homogeneous for all firms, which generates competitive imperfections in the market for strategic resources. Information Management Capability (IMC) aims to provide the required unique insights for successful Big Data strategies. This study analyzes IMC as an imperfection agent in the market for strategic Big Data resources. The hypotheses were tested using a survey of 101 respondents and analyzed with SEM-PLS. The results indicate the positive influence of IMC on value expectation and a negative effect on cost expectation. Cost expectation inversely affects the intent to purchase or develop the resources to implement Big Data strategies. Value expectation has a positive effect on both intents.

KEYWORDS | *Big Data*, information management, strategic factor market, value expectation, cost expectation.

RESUMEN

El interés de las organizaciones en el desarrollo de estrategias de Big Data está aumentando significativamente. Sin embargo, la expectativa del valor de los beneficios y de los costos implicados en el acreedor o el desarrollo de estas soluciones no es homogénea para todas las empresas, impugnando las imperfecciones en el mercado de los recursos estratégicos. Capacidad de Gestión de la Información (CGI) utiliza las premisas proporcionar las pruebas requeridas para el éxito de Big Data, este artículo tiene como objetivo analizar el CGI como un agente de imperfección en el Strategic Factor Market de Big Data. Las hipótesis se probaron de una encuesta de 101 respondedores y se analizaron con SEM-PLS. Los resultados indican la positiva influencia de CGI sobre la expectativa y una negativa en una expectativa de los costos. La expectativa de los costos inversamente afecta al intento de comprar o de desarrollar los recursos para implementar estrategias Big Data. La expectativa de valor tiene un efecto positivo en ambos intents.

PALABRAS-CLAVES | *Big Data*, information management, strategic factor market, expectativa de valor, expectativa de los costos.

ANTONIO CARLOS GASTAUD

MAÇADA¹

acgmacada@ea.ufrgs.br

ORCID: 0000-0002-8849-0117

RAFAEL ALFONSO BRINKHUES²

rafael.brinkhues@viamao.ifrs.edu.br

ORCID: 0000-0002-9367-5829

JOSÉ CARLOS DA SILVA FREITAS JUNIOR³

freitas1995@gmail.com

ORCID: 0000-0002-9050-1460

¹ Universidade Federal do Rio Grande do Sul, Escola de Administração, Porto Alegre, RS, Brasil

² Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Sul, Viamão, RS, Brasil

³ Universidade do Vale do Rio dos Sinos, Escola de Gestão e Negócios, São Leopoldo, RS, Brasil

INTRODUÇÃO

“*Big Data* é possivelmente a mais significativa ruptura de ‘tecnologia’ nos ecossistemas empresariais e acadêmicos desde a ascensão meteórica da Internet e da economia digital” (Agarwal & Dhar, 2014, p. 443). Diversas formas de dados que não geram valor não contribuem para as organizações. O valor dos dados está, portanto, impulsionando o crescente interesse em *Big Data* (Chiang, Grover, Liang, & Zhang, 2018). Pesquisadores e fornecedores de tecnologia reconhecem os benefícios da adoção da análise de *Big Data* em práticas de negócios (Wang, Kung, Wang, & Cegielski, 2018). As empresas estão cada vez mais interessadas em desenvolver estratégias de *Big Data* (Tabesh, Mousavindin, & Hasani, 2019). O percentual de empresas que já investem ou planejam investir em *Big Data* cresceu de 64% em 2013 (Gartner, 2014) para 73% em 2018 (Davenport & Bean, 2018). “As organizações estão atualmente buscando adotar a tecnologia de *Big Data*, mas estão incertas dos benefícios que ela pode trazer para a organização, além de se preocuparem com os custos de implementação” (Lakoju & Serrano, 2017, p. 1). O volume de investimentos está crescendo a um ritmo ainda maior. O mercado de tecnologia e serviços de *Big Data* crescerá a uma taxa de crescimento anual composta (TCAC) de 11,9%, atingindo 260 bilhões de dólares até 2022 (International Data Corporation [IDC], 2018). Os impactos organizacionais esperados são muitos, e incluem redução de custos, aumento nos *insights* de negócios, revelações de informações estratégicas e melhor tomada de decisão (Kwon, Lee, & Shin, 2014). No entanto, o valor esperado desses benefícios e os custos envolvidos na aquisição e desenvolvimento dessas soluções não são os mesmos para cada empresa, o que gera imperfeições competitivas no mercado de recursos estratégicos.

De acordo com a teoria do mercado de fatores estratégicos (MFE), as empresas precisam estar consistentemente mais informadas do que outras empresas que visam implementar a mesma estratégia para obter desempenho superior (Barney, 1986), este autor afirma que a análise das capacidades da empresa pode ajudar mais na criação dessas circunstâncias que o ambiente competitivo. Argumentamos que a capacidade de gestão da informação (CGI) pode trazer o único *insight* necessário para a implementação de estratégias bem-sucedidas de *Big Data*. Definimos CGI como a capacidade da empresa de acessar dados e informações de ambientes internos e externos, mapear e distribuir dados para processamento, e permitir que se ajuste para atender as necessidades e direções do mercado. A literatura indica que a CGI influencia positivamente e diretamente o desempenho de uma empresa (Carmichael, Palacios-Marques, & Gil-Pichuan, 2011) ou é mediada por outras capacidades organizacionais (Mithas,

Ramasubbu, & Sambamurthy, 2011). Não há evidências de que a CGI atual de uma empresa possa acomodar o crescimento acentuado do fluxo de dados não estruturados (White, 2012).

No entanto, a CGI pode ter um papel relevante nas expectativas e intenção de implementar uma estratégia para lidar com *Big Data*. Muitos adeptos de *Big Data* estão buscando tais oportunidades devido ao fácil acesso a capacidades computacionais e *software* analíticos (Agarwal & Dhar, 2014). Por outro lado, 43% dos diretores referem-se aos défices orçamentários como a principal barreira atrapalhando ações que tirem proveito desse contexto (McKendrick, 2013). Isso indica simetria na expectativa de custo dos recursos para a implementação de uma estratégia de *Big Data*. Do ponto de vista acadêmico, muitos estudos investigam esse fenômeno, especialmente da área de Sistemas da Informação (SI), os quais analisam a criação de valor a partir desses dados (por exemplo, Brown, Chui, & Manyika, 2011; Davenport, Barth, & Bean, 2012; Johnson, 2012; Lakoju & Serrano, 2017; McAfee & Brynjolfsson, 2012).

No entanto, poucos trabalhos focam a relação entre CGI e *Big Data* para a obtenção desse valor (Brinkhues, Maçada, & Casalinho, 2014; Mohanty, Jagadeesh, & Srivatsa, 2013). “A literatura atual sobre a realização do valor de *Big Data* é caracterizada por um número limitado de estudos empíricos e alguns que trazem ideias antigas sob novos formatos” (Günther, Rezazade Mehrizi, Huysman, & Feldberg, 2017). Este estudo tem como objetivo determinar como a variação no nível de CGI entre as empresas cria imperfeições competitivas no mercado de recursos para a implementação de estratégias de *Big Data*. Para cobrir essa lacuna de pesquisa, propomos uma escala para medir a CGI e desenvolver conceitualmente um modelo de pesquisa para avaliar empiricamente a relação entre a CGI e a implementação da estratégia de *Big Data*. Esse modelo, baseado na teoria do MFE, investiga especificamente a influência da CGI sobre o valor e as expectativas de custo dos recursos necessários para essa implementação, e, com base na teoria do custo de transação, o efeito dessas expectativas sobre a intenção de adquirir ou desenvolver esses recursos. Construímos a escala seguindo a literatura e coletamos dados de executivos via classificação de cartões. O modelo de pesquisa foi testado por meio de uma *Survey* com 101 diretores, e os dados foram analisados utilizando o SEM-PLS.

O artigo prossegue como detalhado a seguir. A próxima seção desenvolve as hipóteses e apresenta o modelo de pesquisa. A seção seguinte detalha os procedimentos para construir a escala de CGI e para a coleta de dados. Posteriormente, apresentamos e discutimos os resultados e, finalmente, apresentamos nossas conclusões e implicações para a pesquisa e prática gerencial.

O CGI E O MFE

“Mercados de Fatores Estratégicos (MFE) são mercados onde os recursos necessários para a implementação de uma estratégia são adquiridos” (Barney, 1986, p. 1231); assim, as empresas só podem extrair desempenho superior quando o MFE for imperfeito devido às diferenças na expectativa do valor futuro desses recursos estratégicos. Em outras palavras, as empresas devem poder extrair um maior valor dos recursos necessários para a sua implementação estratégica em vez de arcar com custos de aquisição significativamente inferiores ao seu valor econômico. “O objetivo dos programas de *Big Data* deve ser fornecer valor suficiente para justificar que continuem sendo utilizados na exploração de novas capacidades e *insights*” (Mithas, Lee, Earley, Murugesan, & Djavanshir, 2013, p. 18). Para obter essa vantagem, as empresas têm de estar mais bem-informadas do que as outras empresas que atuam no mesmo MFE (Barney, 1986). A CGI pode servir como um propulsor dessa vantagem.

Mithas et al. (2011) propõem o construto CGI para desenvolver um modelo conceitual vinculando-o a três outras capacidades organizacionais (gestão de clientes, gestão de processos e gestão de desempenho). Seus resultados mostram que essas capacidades de gestão mediam a influência positiva da CGI no desempenho da empresa. O conceito de CGI de Mithas et al. (2011) consiste em três habilidades: fornecer dados e informações aos usuários a partir de níveis adequados de precisão, pontualidade, confiabilidade, segurança e confidencialidade; fornecer conectividade e acesso universal com escopo e escala adequados; e adaptar a infraestrutura às necessidades emergentes e direções do mercado. Carmichael et al. (2011) definem a CGI como um construto de segunda ordem composto pela compilação e produção de informações; acesso à informação; e identificação de requisitos de distribuição de informações. Outro autor, Phadtare (2011), propõe que a CGI está ligada a cinco fatores: aquisição e retenção, processamento e síntese, recuperação e uso, transmissão e divulgação, e sistema de apoio e integração.

Com base nos três trabalhos mencionados acima (Carmichael et al., 2011; Mithas et al., 2011; Phadtare, 2011), identificamos cinco dimensões da CGI (acesso, distribuição, pessoas, arquitetura e infraestrutura). Em seguida, como explicaremos detalhadamente nas próximas seções, realizamos uma análise de classificação de cartões com executivos, que apontou para uma escala composta por 10 itens dessas dimensões. A partir dessa análise, formulamos uma definição de CGI que, aplicada neste estudo, corresponde ao conjunto de habilidades da empresa que articulam a infraestrutura da informação, a arquitetura da informação e o acesso à informação, possibilitando o ajuste organizacional em

resposta às mudanças impostas por ambientes externos. Assim, esperamos que as organizações com CGI mais desenvolvida sejam mais precisas em suas expectativas de valor e possam tirar proveito da assimetria da informação no MFE, de onde derivam imperfeições competitivas no MFE.

Além disso, esperamos que as empresas que desenvolveram CGI com uma qualidade superior durante uma das eras anteriores de GI — Suporte a Decisão, Suporte Executivo, Processamento Analítico *On-line* e Inteligência e Análise de Negócios (Davenport, 2014) — tenham uma maior expectativa de valor da próxima fronteira do *Big Data*. Prevemos esse resultado porque o desenvolvimento da CGI em nível elevado impacta positivamente o desempenho organizacional (Carmichael et al., 2011; Mithas et al., 2011), o que favorece um efeito polarizador das percepções entre o passado e o presente (Vasconcelos, Mascarenhas, & Vasconcelos, 2006). A estratégia de *Big Data* é um conjunto de soluções baseadas em avanços recentes na análise de *Big Data*. As organizações buscam incorporar essas soluções em seus próprios processos de tomada de decisão com sucesso (Tabesh et al., 2019). Assim, essas empresas têm uma maior expectativa de valor das estratégias de *Big Data* com base em suas experiências anteriores positivas com investimentos de GI. Por outro lado, as empresas que não atingiram o mesmo nível de CGI podem não ter tido o mesmo sucesso nos seus empreendimentos em GI, e essa experiência negativa pode resultar numa maior expectativa de custo para adotar esse tipo de estratégia.

H1: As empresas com CGI mais elevada têm uma expectativa de custo menor para implementar uma estratégia de *Big Data*.

H2: As empresas com CGI mais elevada têm maiores expectativas de extração de valor da implementação de uma estratégia de *Big Data*.

Expectativa de valor assimétrico e intenção de adquirir/desenvolver capacidades de estratégia de *Big Data*

Estudos anteriores também demonstram o efeito positivo da utilização de dados para a aquisição de soluções de *Big Data* (Kwon et al., 2014). No entanto, as empresas também podem desenvolver os recursos e capacidades para implementar uma estratégia de *Big Data* internamente.

As organizações existem para realizar transações internas de modo mais eficiente do que seria realizá-las no mercado (Coase, 1937). Por conseguinte, as empresas que não organizam os seus recursos para atingir os seus objetivos de maneira mais eficiente do que o mercado perdem a sua razão de existir. Assim, a busca dos recursos necessários para implementar uma

estratégia de *Big Data* pode tomar dois caminhos: desenvolvê-los internamente ou adquiri-los no mercado. As organizações podem desenvolver internamente as capacidades necessárias para essa implementação se forem eficientes na reorganização dos recursos envolvidos. No entanto, se o custo para adquirir esses fundos no mercado for menor do que o valor para produzi-los internamente, as empresas tendem a adquiri-los.

Os custos das transações são consequência da distribuição assimétrica e incompleta da informação entre as organizações envolvidas na troca (Cordella, 2006). O surgimento de vários fornecedores com soluções para gerenciar *Big Data* provoca incerteza sobre o valor que as empresas podem extrair desses recursos. Assim, a decisão de adquirir ou desenvolver os fatores necessários para implementar uma estratégia de *Big Data* também é afetada pelas diferenças nas expectativas assimétricas de valor que a empresa pode extrair desse investimento. Acreditamos que diferentes níveis de expectativas influenciam positivamente ambas as decisões, seja a de adquirir ou a de desenvolver internamente os recursos para extrair valor de *Big Data*.

H3a: Empresas com maiores expectativas de extração de valor das estratégias de *Big Data* têm maior intenção de adquirir essas soluções.

H3b: Empresas com maiores expectativas de extração de valor de *Big Data* têm maior intenção de desenvolver essas soluções internamente.

Expectativa de custos assimétricos e intenção de adquirir/developolver capacidades de estratégia de *Big Data*

Recursos como milhões de instruções por segundo (MIPS) e *terabytes* de armazenamento para dados estruturados são menos

dispendiosos quando operados por meio de tecnologias de *Big Data* do que por meio de tecnologias tradicionais (Davenport, 2014). No entanto, os custos de outros recursos menos tangíveis podem ser mais difíceis de prever.

Por exemplo, os custos de transação frequentemente aumentam ao adotar uma solução de SI. No entanto, quando os custos associados à adoção não excedem os custos externos que afetam a adoção, as empresas podem reduzi-los (Cordella, 2006).

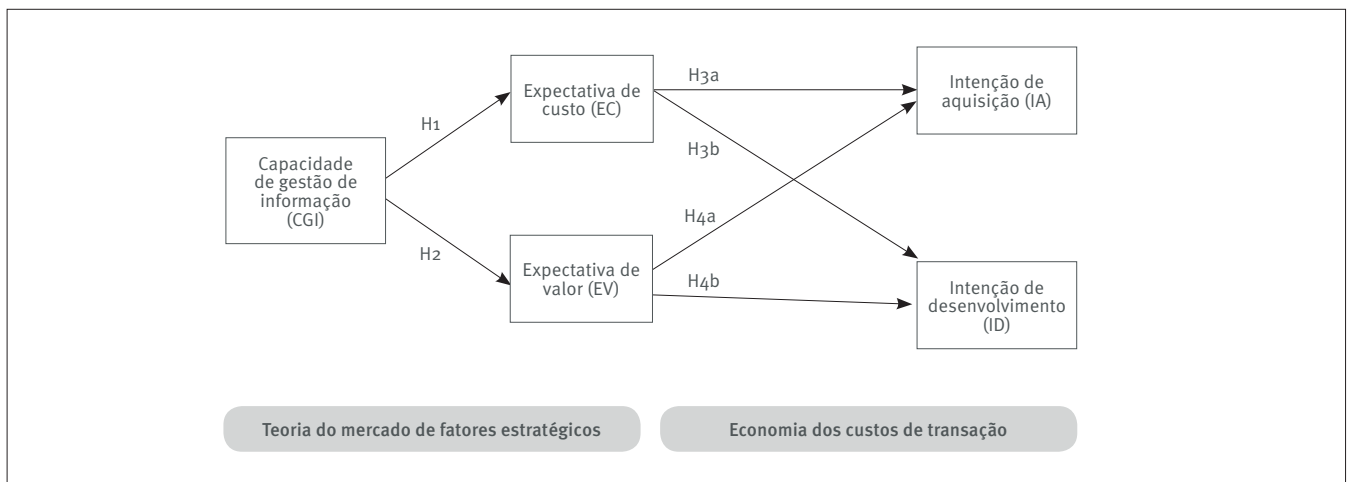
Assim como acreditamos que empresas com CGI mais bem desenvolvida tenham uma menor expectativa dos custos necessários para adotar uma estratégia de *Big Data*, também é provável que essa previsão de custos reduzidos aumente a predisposição para a implementação. Além disso, com uma expectativa de custo mais precisa, as empresas com um nível elevado de CGI podem criar uma estratégia adequada a seus orçamentos. Acreditamos que o efeito oposto também é válido: as empresas com CGI menos desenvolvidas tendem a ter previsões de custos menos exatas e, portanto, maior incerteza ao decidir se compram ou desenvolvem recursos para implementar uma estratégia de *Big Data*.

H4a: Empresas com maiores expectativas dos custos para implementar estratégias de *Big Data* têm menor intenção de adquirir essas soluções.

H4b: Empresas com maiores expectativas do custo para implementar estratégias de *Big Data* têm menor intenção de desenvolver essas soluções internamente.

Considerando as quatro hipóteses desenvolvidas acima, construímos o modelo de pesquisa. Uma ilustração disso pode ser vista na Figura 1.

Figura 1. Modelo de pesquisa



METODOLOGIA DE PESQUISA

As hipóteses foram testadas utilizando uma modelagem de equações estruturais de mínimos quadrados parciais (PLS-SEM) com base nos dados da *Survey*. PLS-SEM é frequentemente recomendado para pesquisa em gestão, porque os dados nesse campo muitas vezes não aderem a uma distribuição normal multivariada, ao mesmo tempo que os modelos são complexos e podem ser informativos. Também é recomendado para amostras menores e modelos com menos suporte prévio na literatura (Hair, Hult, Ringle, & Sarstedt, 2016; Ringle, Silva, & Bido, 2014). Diante das variáveis envolvidas e da natureza desta pesquisa, consideramos o uso dessa técnica estatística apropriada para testar empiricamente as hipóteses do modelo conceitual.

No entanto, realizamos uma etapa preliminar que consistiu na aplicação de um questionário e análise de *Card Sorting* para propor uma escala para mensurar CGI. Descrevemos essa etapa na próxima seção, e em seguida descrevemos os passos e detalhes sobre a amostra, coleta de dados e validação.

Classificação de cartões para criar uma escala de CGI

Adaptamos uma escala para medir a CGI na fase quantitativa usando uma *Survey*. Essa escala foi baseada em instrumentos de pesquisa existentes (Carmichael et al., 2011; Mithas et al., 2011). A necessidade de construir uma escala de CGI que pudesse lidar com esse novo ambiente de dados não influenciou as demais variáveis, que já tinham escalas testadas.

Para a escala, aplicamos a ferramenta Optimal Workshop para realizar uma classificação de cartões com 10 executivos de TI. Cada participante *on-line* levou uma média de sete minutos para concluir. Com base nos resultados da classificação de cartões, reduzimos a escala de 20 itens em cinco dimensões (pessoas, distribuição, acesso, infraestrutura e arquitetura de informação) para 10 itens, analisando uma matriz na qual usamos o corte acima de 60% de similaridade. Para avaliar as dimensões, utilizou-se uma análise de dendrograma para o melhor método de mesclagem, que frequentemente supera o método de concordância real quando uma pesquisa tem menos participantes. Ele faz suposições sobre *clusters* mais maciços com base em relacionamentos de pares individuais (Optimal Workshop, 2017). As pontuações do corte representam 40% dos participantes que concordam com partes desse agrupamento. Cinco dimensões emergiram do grupo de escalas-itens avaliados pelos executivos, que, por sua vez, foram selecionados a partir

da literatura existente. Esse grupo foi coletado por meio da análise de classificação de cartões e nomeado com base nos itens coletados (pessoas, distribuição, acesso, infraestrutura e arquitetura da informação), de acordo com a análise dos autores dos resultados da etapa preliminar do estudo.

Assim, desenvolvemos a escala de CGI para este estudo. Desenvolvemos essa escala porque uma pesquisa aprofundada sobre esse construto (Mithas et al., 2011) foi validada a partir de uma adaptação utilizando dados secundários preexistentes e também para incorporar elementos abordados em outros trabalhos (Carmichael et al., 2011). As escalas para as demais variáveis do instrumento de pesquisa foram adaptadas da literatura e modificadas conforme necessário para este estudo. Todos os itens usaram uma escala Likert de sete pontos (1-Discordo fortemente; 7-Concordo fortemente). A análise estatística foi realizada utilizando o pacote de *software* SmartPLS versão 3.2.0.

Exemplo de quadro e coleta de dados

Coletamos dados por meio de uma pesquisa *on-line* criada usando a plataforma Google Forms. Os dados foram coletados em redes sociais, principalmente de grupos específicos de discussão sobre os temas abordados. Cerca de 29.282 pessoas viram os avisos, 208 pessoas clicaram neles, e recebemos 114 formulários preenchidos. A taxa de resposta foi de 59%. Entre estas, 13 foram eliminadas por meio de três questões de validação inseridas no questionário para auxiliar o controle da qualidade dos dados, o que nos deixou com uma amostra final de 101 formulários. Assim, a amostra excede o mínimo de 68 casos considerando um poder de 0,8 e um tamanho de efeito médio f^2 de 0,15 (Hair et al., 2016) com as variáveis tendo um número máximo de dois preditores. A amostra mínima foi calculada usando a ferramenta G*Power 3.1 (Faul, Erdfelder, Buchner, & Lang, 2009).

Os entrevistados eram gerentes e executivos de TI ou de outras áreas relacionadas à implementação de estratégias de GI. A Tabela 1 resume os perfis das empresas respondentes, a partir do qual podemos concluir que a amostra é diversificada e levemente focada na indústria e tamanho, seja por meio do número de funcionários ou faturamento. As duas diferenças mais aparentes na variável de tamanho aparecem nas duas primeiras linhas. Na primeira linha, há uma porcentagem menor de empresas faturando até um milhão de dólares (16%), enquanto a porcentagem de empresas com até 50 funcionários é de 27%. Em contrapartida, a segunda linha apresenta um percentual maior de faturamento (23% de 1 a 6,7 milhões de dólares) e um número menor de empregados. Uma possível explicação

para essas diferenças podem estar no elevado número de postos de trabalho tecnológicos, os quais têm um alto potencial de rentabilidade, mesmo tendo menos trabalhadores. Houve diferenças significativas nos resultados relativos ao tamanho da indústria ou da empresa. Ao utilizar técnicas de mistura finita em PLS, não foram identificadas classes latentes que evidenciem a presença de grupos dentro de uma amostra.

Tabela 1. Perfil das empresas respondentes

Indústria	%	Número de Funcionários	%	Receita Anual	%
Tecnologia	24%	Até 50	27%	Até 1 milhão de dólares	16%
Manufatura	18%	51-100	13%	de 1 a 6,7 milhões de dólares	23%
Serviços financeiros	12%	101-500	11%	de 6,7 a 37,5 milhões de dólares	14%
Serviços profissionais	11%	501-1.000	16%	de 37,5 a 125 milhões de dólares	12%
Outros	35%	Mais de 1.000	33%	Mais de 125 milhões de dólares	36%

Nota: n=101

RESULTADOS

Primeiramente, apresentamos uma análise dos resultados em termos do modelo de medição, seguida de uma avaliação do modelo estrutural.

Avaliação do modelo de medição

O modelo de medição foi avaliado por meio de uma série de testes de confiabilidade, incluindo confiabilidade composta (CC), alfa de Cronbach, variância média extraída (VME) e validade discriminante (Hair et al., 2016; Ringle et al., 2014). Como mostra a Tabela 2, seguindo os critérios de Fornell e Larcker (Henseler, Ringle, & Sinkovics, 2009), o modelo converge, e o resultado é satisfatório, porque a VME de todas as variáveis está acima de 0,50.

Embora o indicador tradicional para avaliar a consistência interna seja o alfa de Cronbach, CC é o melhor indicador para

PLS-PM, pois é o menos sensível ao número de itens em cada construto (Ringle et al., 2014). Na Tabela 2, também vemos que todas as variáveis apresentam ambos os indicadores (alfa de Cronbach e CC) acima de 0,7. Portanto, todas as variáveis são consideradas adequadas e satisfatórias (Hair et al., 2016). Ainda na Tabela 2, relatamos os critérios de Fornell e Larcker (1981) para verificar a qualidade discriminante com base nos valores de correlação entre as variáveis. Os resultados indicam que não há correlação entre variáveis distintas maiores que a raiz quadrada da VME de cada variável (destacadas em cinza na diagonal principal).

Como último critério para avaliar a qualidade do modelo de medida, a validade discriminante foi calculada utilizando uma análise de cargas cruzadas (Chin, 1998). Na Tabela 3, não encontramos indicadores com cargas fatoriais abaixo de sua variável em relação aos demais. Tendo atendido os critérios de qualidade e a validade discriminante do modelo, avaliaremos, na próxima subseção, o modelo estrutural.

Tabela 2. Critérios de qualidade

Variáveis	VME	Confiabilidade composta	Alfa de Cronbach	EC	ID	CGI	IA	EV
Expectativa de custo	0,778	0,875	0,715	0,882				
Intenção de desenvolvimento	0,698	0,874	0,784	-0,304	0,836			
CGI	0,548	0,923	0,907	-0,407	0,258	0,740		
Intenção de aquisição	0,657	0,851	0,747	-0,405	0,735	0,300	0,811	
Expectativa de valor	0,819	0,901	0,780	-0,392	0,318	0,647	0,360	0,905
Média				4,75	3,26	4,18	3,40	5,16
DP				1,64	1,87	1,64	1,92	1,67

Nota: VME = Variância Média Extraída; EC = Expectativa de Custo; ID = Intenção de Desenvolvimento; CGI = Capacidade de Gestão da Informação; IA = Intenção de Aquisição; EV = Expectativa de Valor.

Tabela 3. Cargas cruzadas

Itens x Variáveis	CGI	EC	ID	IA	EV
CGI1	0,585	-0,178	0,022	0,004	0,363
CGI2	0,757	-0,255	0,236	0,263	0,459
CGI3	0,784	-0,273	0,177	0,165	0,543
CGI4	0,823	-0,347	0,319	0,351	0,656
CGI5	0,817	-0,289	0,190	0,203	0,600
CGI6	0,697	-0,182	0,033	-0,048	0,349
CGI7	0,735	-0,265	0,308	0,480	0,486
CGI8	0,686	-0,293	0,107	0,286	0,425
CGI9	0,711	-0,417	0,125	0,191	0,337
CGI10	0,773	-0,455	0,259	0,186	0,452
EC1	-0,387	0,885	-0,299	-0,316	-0,390
EC2	-0,331	0,879	-0,237	-0,399	-0,301
ID1	0,253	-0,285	0,826	0,819	0,305
ID2	0,239	-0,204	0,892	0,588	0,253
ID3	0,145	-0,261	0,786	0,385	0,226
IA1	0,253	-0,285	0,826	0,819	0,305
IA2	0,249	-0,404	0,481	0,858	0,362
IA3	0,229	-0,269	0,517	0,751	0,166
EV1	0,557	-0,361	0,325	0,362	0,907
EV2	0,615	-0,349	0,250	0,289	0,903

Avaliação do modelo estrutural

Para testar as hipóteses e o poder preditivo do modelo, foram calculados os coeficientes de determinação de Pearson (R^2), o tamanho do efeito (f^2), a validade preditiva (Q^2) e o coeficiente de caminho (r). De acordo com os critérios de Cohen (1988), pode-se verificar um efeito médio do modelo sobre as variáveis expectativa de custo (EC) (0,166) e intenção de desenvolvimento (ID) (0,139), um grande efeito sobre a variável expectativa de valor (EV) (0,419) e um efeito relativamente grande sobre a variável intenção de aquisição (0,212).

A análise de *bootstrapping* com mil amostras demonstra que todas as relações das variáveis observáveis com as variáveis latentes, e aquelas entre as variáveis latentes, apresentam correlações significativas e coeficientes de regressão considerando $p < 0,001$, o que faz com que H_0 seja rejeitada. Em seguida, foram realizadas duas outras avaliações de qualidade do ajuste do modelo, a validade preditiva (Q^2) e o tamanho do efeito (f^2), por meio do procedimento de olhos vendados. A Tabela 4 mostra que todos os Q^2 s estão acima de zero, demonstrando a precisão do modelo. A análise do tamanho do efeito considera uma utilidade média de EC, ID e intenção de aquisição (IA) para ajustar o modelo. Os resultados aproximam-se de uma utilidade relativamente grande do EV de acordo com os critérios de Hair et al. (2016). Finalmente, os

coeficientes de caminho, ilustrados na Figura 2, mostram que os resultados confirmam todas as hipóteses.

Tabela 4. Resultados de R^2 , Q^2 e f^2

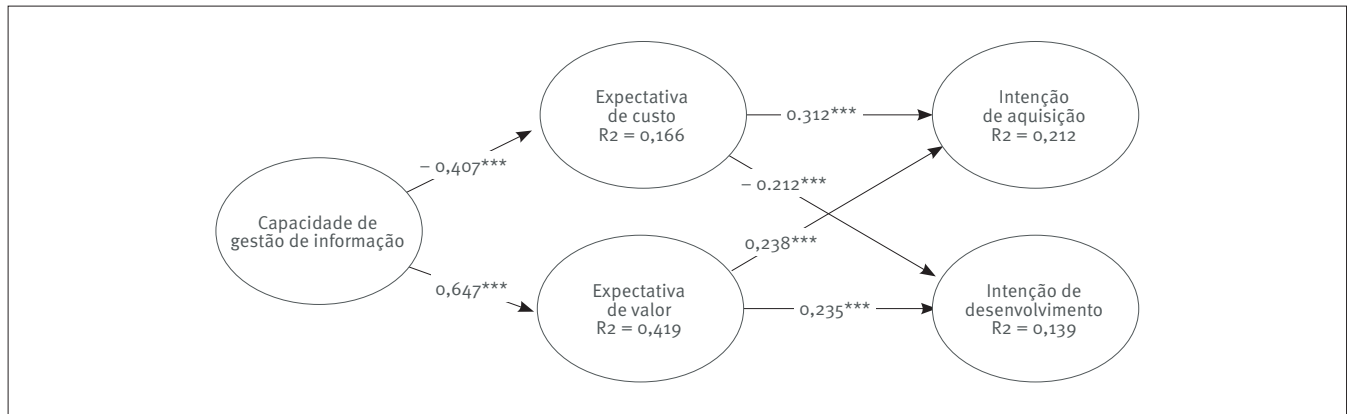
Relações	R^2	Q^2	f^2
EC	0,166	0,112	0,189
ID	0,139	0,085	0,143
IA	0,212	0,111	0,119
EV	0,419	0,333	0,339

Considerando os pressupostos teóricos do MFE, H_1 foi confirmado, uma vez que a CGI teve um impacto negativo sobre o CE de estratégias de *Big Data*; ou seja, quanto mais desenvolvido for a CGI da empresa, menor será a expectativa da despesa para implementar uma estratégia de *Big Data*. A análise do coeficiente de caminho destaca que o efeito da CGI é ainda mais evidente na expectativa do valor (EV) dessas estratégias. A Hipótese 2 foi confirmada, indicando que essa habilidade pode ser uma fonte potencial de imperfeições no MFE para *Big Data* em ambos os casos.

A outra metade do modelo (H_3 e H_4) descreve o impacto da expectativa de implementar estratégias de *Big Data* em termos de custo e valor na intenção de adquirir (H_3 e H_4) e desenvolver (H_3b e H_4b) essas capacidades. Ambas as hipóteses foram confirmadas. Esse impacto foi negativo para as Hipóteses 3a (compra) e 3b (desenvolvimento), demonstrando que uma alta expectativa de custo tem um impacto negativo na intenção de adquirir ou

desenvolver estratégias de *Big Data*. Os resultados também confirmaram as Hipóteses 4a e 4b. Em outras palavras, a intenção de adquirir ou desenvolver estratégias de *Big Data* foi positiva quando a expectativa de valor (EV) de uma estratégia de *Big Data* era maior.

Figura 2. Resultados do modelo empírico: coeficientes de caminho e R²



CONSIDERAÇÕES FINAIS

Finalizamos esta seção com uma discussão sobre o assunto e um esboço de futuras direções de pesquisa.

Contribuições para a literatura

Este artigo contribui para a literatura de sistemas de informação de gestão explorando um tema relativamente recente (*Big Data*) e sua relação com uma capacidade existente de uma empresa (CGI). Especificamente, analisamos esse fenômeno focando o seu impacto nas organizações. “Esse foco cria uma ligação mais estreita entre dados e modelos de negócios: nos preocupamos profundamente com a transformação de negócios e a criação de valor através de dados, e menos com algoritmos ou estruturas sem uma ligação com o valor empresarial” (Agarwal & Dhar, 2014, p. 445).

Em primeiro lugar, a pesquisa empregou uma teoria raramente utilizada em SI – MFE. Essa teoria, juntamente com a teoria do custo de transação (amplamente utilizada em SI), serviu como base para o desenvolvimento das hipóteses e confirmou a análise estatística. Considerando esse fundamento teórico e indicações encontradas na literatura, foi possível estabelecer a Hipótese 1. Nossos resultados atestam que a CGI pode ter um impacto negativo no custo esperado dos recursos necessários para implementar uma estratégia de *Big Data*. Esses resultados confirmam que as organizações têm expectativas de custo diferentes na busca de recursos estratégicos (Barney, 1986). A CGI desempenha um papel relevante nessa variedade de percepções, seja por meio de maior acurácia (Mithas et al., 2011) no acesso e distribuição da informação, seja pelo efeito

perceptivo de polarização (Vasconcelos et al., 2006). As empresas que não conseguiram desenvolver com êxito a CGI podem ter uma expectativa mais elevada do custo para implementar uma nova estratégia relacionada com GI. Entretanto, esse efeito parece ser mais evidente nas relações da Hipótese 2. Demonstramos que a CGI impacta positivamente a extração de valor esperada de uma estratégia de *Big Data*. Esse foi o efeito mais significativo que encontramos, podendo indicar um produto das habilidades desenvolvidas ou um reflexo de experiências bem-sucedidas em GI.

Por outro lado, nas Hipóteses 3a (compra) e 3b (desenvolver), explicamos o impacto do custo esperado na intenção de aquisição ou desenvolvimento dos recursos e capacidades para implementar uma estratégia para lidar com dados volumosos e heterogêneos. O impacto negativo foi confirmado por dados empíricos, demonstrando que uma expectativa de custo elevada tem um impacto ainda mais negativo na intenção de aquisição do que na intenção de desenvolver os recursos e capacidades necessários para estabelecer a estratégia internamente. Por outro lado, os resultados confirmaram a Hipótese 4 (H4a e H4b), mostrando que uma maior expectativa de extração futura de valor impacta positivamente a intenção de adquirir ou desenvolver estratégias de *Big Data*. Nesse caso, os efeitos de tamanho encontrados para a intenção de adquirir ou desenvolver os recursos necessários para essas estratégias foram muito semelhantes. No entanto, este estudo não teve como objetivo avaliar se essas expectativas correspondem ou não à realidade do mercado. É importante notar que, no geral, investimentos em estratégias de SI só reduzem os custos de transação se a empresa consome menos recursos do que a quantidade gerada pela economia (Ciborra, 1996).

Através de duas perspectivas teóricas, nossa pesquisa contribui para a compreensão do impacto que a CGI existente pode ter na adoção ou não de novas estratégias em resposta a mudanças na gestão da informação. Ainda mais importante, este estudo revelou o papel dessa capacidade como fonte potencial de imperfeições no MFE, podendo, assim, ser um primeiro passo para investigar o papel da CGI no desempenho competitivo das empresas.

Além disso, juntamente com a adoção da perspectiva da literatura sobre CGI, propomos uma nova definição mais alinhada com o contexto atual e as necessidades de GI das organizações. Também propusemos e validamos uma nova escala para medir esse construto.

Implicações práticas

Podemos categorizar as implicações práticas deste estudo para dois tipos de organizações: aquelas que buscam soluções para responder às mudanças ambientais causadas pelo *Big Data* e aquelas que oferecem essas soluções. Para as empresas que planejam implementar estratégias de *Big Data*, os resultados revelam uma grande variação nas expectativas tanto do valor quanto do custo dos recursos necessários. Essa variação pode traduzir-se em oportunidades de buscar no mercado por recursos subestimados ou de incorrer no risco de adquirir recursos sobrevalorizados. Para reduzir esses riscos e melhorar o desempenho na exploração dessas oportunidades, nossos resultados mostram que investir em GI não só melhora o desempenho organizacional (Carmichael et al., 2011; Mithas et al., 2011), como também pode ajudar as empresas a avaliar estratégias futuras.

Já para o outro lado do mercado, este estudo pode prover, para empresas que oferecem os recursos e capacidades para implementar estratégias de *Big Data*, algum *insight* sobre as expectativas de seus consumidores atuais ou potenciais. Compreender as diferenças nas percepções de organizações com níveis diversos de CGI pode ajudar as empresas a criar uma solução adequada e contribuir para o sucesso dessa solução no desenvolvimento da CGI em níveis mais elevados para seus clientes.

Limitações e estudos futuros

Nossa amostra de estudo foi muito heterogênea, como mostra a Tabela 1, pois coletamos dados de maneira não sistemática, o que pode, portanto, não refletir inteiramente a população de empresas. Também não é possível identificar se os resultados se aplicam a um grupo específico de organizações. Mensuramos

os construtos de intenção de aquisição e expectativa de custo utilizando apenas dois indicadores, e, apesar de ambos apresentarem bom desempenho em termos de validade e confiabilidade, ainda assim, utilizamos um indicador a menos do que o recomendado.

Esta pesquisa abre caminho para novas investigações em SI, em especial as relacionadas à CGI, o contexto do *Big Data*, e até mesmo novos estudos utilizando a teoria do MFE. Em relação à CGI, acreditamos que pesquisas futuras podem confirmar o papel estratégico dessas capacidades, especialmente nesse contexto de *Big Data*. Os pesquisadores podem usar o MFE para analisar outros fenômenos na área e conectá-lo a outras teorias na literatura de SI. O modelo pode mostrar-se válido para as estratégias de SI em geral e pode ser investigado no contexto de outras tecnologias (como análise de negócios ou inteligência de negócios).

CONCLUSÃO

Este estudo, apesar de trazer resultados quantitativos, é exploratório, dada a natureza do conteúdo analisado. Buscamos investigar como a CGI preexistente dentro das organizações afeta as expectativas e intenções dessas empresas de adotar uma nova estratégia de GI.

Nossos resultados oferecem *insights* sobre o efeito exercido nas relações entre CGI e custo e expectativa de valor futuro, além do impacto dessas expectativas na intenção de adquirir ou desenvolver os recursos necessários para implementar uma estratégia de *Big Data*. De modo geral, os resultados revelaram que a CGI influencia positivamente a expectativa de valor e influencia negativamente a expectativa de custo. A expectativa de valor impacta de maneira homogênea e positiva a intenção de adquirir ou desenvolver esses recursos. Finalmente, a expectativa de custo influencia negativamente a intenção de desenvolvimento e, de modo ainda mais contundente, a intenção de aquisição dos recursos e capacidades de *Big Data*.

Se um recurso fundamental para a sobrevivência nesse novo ambiente é a capacidade de obter acesso a mais informações sendo capaz de gerenciar esse fluxo de informação (Cordella, 2006), esta pesquisa contribui para a literatura de SI explorando o potencial da CGI nesse contexto de *Big Data*. Do ponto de vista acadêmico, este estudo testou uma teoria pouco utilizada na literatura, que os pesquisadores podem explorar ainda mais para analisar temas de SI. Por fim, esta pesquisa pode ajudar empresas que fornecem soluções de *Big Data*, bem como empresas que pretendem investir em estratégias para lidar com essa mudança no ambiente da gestão da informação.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

REFERÊNCIAS

- Agarwal, R., & Dhar, V. (2014). Editorial-*Big Data*, data science, and analytics: The opportunity and challenge for IS research. *Information Systems Research*, 25(3), 443-448. doi:10.1287/isre.2014.0546
- Barney, J. (1986). Strategic factor markets: Expectations, luck, and business strategy. *Management Science*, 32(10), 1231-1241.
- Brinkhues, R., Maçada, A., & Casalinho, G. (2014). Information management capabilities: Antecedents and consequences. In *Twentieth Americas Conference on Information Systems*. Savannah, 1-11. Retrieved from <https://pdfs.semanticscholar.org/1503/001cb9628f35acd727c4b31b02f613f6523c.pdf>
- Brown, B., Chui, M., & Manyika, J. (2011). Are you ready for the era of “*Big Data*”? Retrieved from http://www.t-systems.com/solutions/download-mckinsey-quarterly-/1148544_1/blobBinary/Study-McKinsey-Big-data.pdf [Accessed November 23, 2014].
- Carmichael, F., Palacios-Marques, D., & Gil-Pechuan, I. (2011). How to create information management capabilities through web 2.0. *The Service Industries*, 31(10), 1613-1625. doi:10.1080/02642069.2010.485635
- 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. (1998). The partial least squares approach for structural equation modeling. In G. A. Marcoulides (Ed.), *Modern methods for business research* (pp. 295-236). London, UK: Laurence Erlbaum Associates.
- Ciborra, C. U. (1996). *Teams, markets, and systems: Business innovation and information technology*. New York, NY: Cambridge University Press.
- Coase, R. H. (1937). The nature of the firm. *Economica*, 4(16), 386-405. doi:10.1111/j.1468-0335.1937.tb00002.x
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* 2nd ed. New Jersey, NJ: Lawrence Erlbaum Associates.
- Cordella, A. (2006). Transaction costs and information systems: Does IT add up? *Journal of Information Technology*, 21(3), 195-202. doi:10.1057/palgrave.jit.2000066
- Davenport, T. H. (2014). *Big Data at work: Dispelling the myths, uncovering the opportunities*. Boston, MA: Harvard Business School Publishing.
- Davenport, T. H., Barth, P., & Bean, R. (2012). How “*Big Data*” is different. *Sloan Management Review*, 54(1), 21-24.
- Davenport, T. H., & Bean, R. (2018). Data and innovation: How *Big Data* and AI are driving business innovation. New Vantage Partners LLC. Retrieved from <https://newvantage.com/wp-content/uploads/2018/01/Big-Data-Executive-Survey-2018-Findings.pdf>
- Faul, F., Erdfelder, E., Buchner, A., & Lang, A. G. (2009). Statistical power analyses using G* Power 3.1: Tests for correlation and regression analyses. *Behavior Research Methods*, 41(4), 1149-1160. doi:10.3758/BRM.41.4.1149
- 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
- Gartner. (2014). Newsroom Gartner survey reveals that 73 percent of organizations have invested or plan to invest in *Big Data* in the next two years. Retrieved from <http://www.gartner.com/newsroom/id/2848718>
- Günther, W. A., Rezazade Mehrizi, M. H., Huysman, M., & Feldberg, F. (2017). Debating *Big Data*: A literature review on realizing value from *Big Data*. *Journal of Strategic Information Systems*, 26(3), 191-209. doi:10.1016/j.jsis.2017.07.003
- Hair Jr, J. F., Hult, G. T. M., Ringle, C., & Sarstedt, M. (2016). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Thousand Oaks, CA: Sage Publications.
- Henseler, J., Ringle, C., & Sinkovics, R. (2009). The use of partial least squares path modeling in international marketing. Retrieved from <https://opus.lib.uts.edu.au/research/handle/10453/10057>
- International Data Corporation. (2018). Revenues for *Big Data* and business analytics solutions forecast to reach \$260 billion in 2022, Led by the banking and manufacturing industries, according to IDC. Retrieved from <https://www.idc.com/getdoc.jsp?containerId=prUS44215218>
- Johnson, J. (2012). *Big Data* + Big Analytics = Big Opportunity. *Financial Executive*, 28(6), 50-53.
- 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
- Lakoju, M., & Serrano, A. (2017). Framework for aligning Big-Data strategy with organizational goals. Proceedings of Twenty-third Americas Conference on Information Systems, Boston.
- McAfee, A., & Brynjolfsson, E. (2012). *Big Data: The management revolution*. *MIT Sloan Management Review*, 90(10), 61-68.
- Mckendrick, J. (2013). 2013 *Big Data* opportunities survey. *Unisphere Research*. New Providence. <http://www.unisphereresearch.com/Issues/5375-Big-Data-Big-Challenges-Big-Opportunities-2012-IOUG-Big-Data-Strategies-Survey.htm>
- Mithas, S., Lee, M., Earley, S., Murugesan, S., & Djavanshir, R. (2013). Leveraging *Big Data* and business analytics. *IT Professional*, 15(6), 18-20. doi:10.1109/MITP.2013.95
- Mithas, S., Ramasubbu, N., & Sambamurthy, V. (2011). How information management capability influences firm performance. *MIS Quarterly*, 35(1), 237-256.
- Mohanty, S., Jagadeesh, M., & Srivatsa, H. (2013). The new information management paradigm. In S. Mohanty, M. Jagadeesh, & H. Srivatsa, *Big Data Imperatives* (pp. 25-44). Berkeley, CA: Apress.
- Optimal WorkShop (2017). Card sorting 101. Your guide to creating and running an effective card sort. Retrieved from <https://www.optimalworkshop.com/101/card-sorting>
- Phadtare, M. (2011). *Strategic management: Concepts and cases*. New Delhi, India: PHI Learning Pvt. Ltd.
- Ringle, C. M., Silva, D., & Bido, D. de S. (2014). Modelagem de equações estruturais com utilização do Smartpls. *Revista Brasileira de Marketing*, 13(2), 56-73. doi:10.5585/remark.v13i2.2717
- Tabesh, P., Mousavidin, E., & Hasani, S. (2019). Implementing *Big Data* strategies: A managerial perspective. *Business Horizons*, 62(3), 347-358. doi:10.1016/j.bushor.2019.02.001
- Vasconcelos, I. F. G. De, Mascarenhas, A. O., & Vasconcelos, F. C. De. (2006). Gestão do paradoxo “passado versus futuro”: Uma visão transformacional da gestão de pessoas. *RAE-Eletrônica*, 5(1). Retrieved from <https://rae.fgv.br/rae-eletronica/>
- Wang, Y., Kung, L. A., Wang, W. Y. C., & Cegielski, C. G. (2018). An integrated *Big Data* analytics-enabled transformation model: Application to health care. *Information and Management*, 55(1), 64-79. doi:10.1016/j.im.2017.04.001
- White, M. (2012). Digital workplaces: Vision and reality. *Business Information Review*, 29(4), 205-214. doi:10.1177/0266382112470412