

Data Science for Business: benefícios, desafios e oportunidades

MAURICIUS MUNHOZ DE MEDEIROS

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL (UFRGS)

NORBERTO HOPPEN

UNIVERSIDADE DO VALE DO RIO DOS SINOS (UNISINOS)

Agradecimento à órgão de fomento:

Agradecemos à CAPES pelo apoio no desenvolvimento da pesquisa.

Data Science for Business: benefícios, desafios e oportunidades

INTRODUÇÃO

Os dados podem ser os únicos ativos realmente inimitáveis e estão se tornando rapidamente os mais valiosos para qualquer organização (Katri & Brow, 2010; Nielsen, 2017). As organizações estão tendo amplo acesso a um alto volume de dados de variadas fontes que, quando processados com velocidade, aumentam consideravelmente a probabilidade de se extrair *insights* acionáveis para orientar a tomada de decisão com base em dados (Chen, Chiang, & Storey, 2012; Waller & Fawcet, 2013). Neste contexto, a tomada de decisão orientada por dados é vislumbrada por pesquisadores e por profissionais como um caminho assertivo para agregar valor aos negócios (Günther et al., 2017; Livingston, 2017). Em entrevista publicada pela *McKinsey Global Institute*, Rob Roy, *Chief Digital Officer* (CDO) da Sprint, afirmou que: “Ter uma mentalidade de dados é um primeiro passo crucial, mas você precisa colocar em prática os processos e recursos para poder usar os dados.” (Roy & Seitz, 2018).

Mas, em geral, isso é difícil de operacionalizar no mundo real do gerenciamento corporativo. De acordo com estudo do *McKinsey Global Institute* (Chin et al., 2017) e pesquisas científicas (Comuzzi & Patel, 2016; Shamim et al, 2018), os desafios são complexos e contemplam, por exemplo: incorporar análise de dados em uma visão estratégica corporativa; limitação de conhecimento e comportamento dos agentes no uso de ferramentas analíticas; desenvolvimento de mecanismos e políticas de governança e gestão dos dados corporativos; assim como o investimento intensivo em recursos de tecnologia da informação.

Desenvolver capacidades associadas à *Big Data* envolve uma mudança de mentalidade que pode tornar-se um diferencial competitivo (Barton & Court, 2012). À medida que integram mais dados em seu processo decisório, as organizações têm adotado tecnologias e métodos analíticos avançados para a transformação de dados em informações (Livingston, 2017). *Business Intelligence & Analytics* (Chen, Chiang, & Storey, 2012) ou *Data Science for Business* suporta a coleta, o gerenciamento, a análise, e a visualização de *Big Data*, o que é de suma importância para o fornecimento de recomendações e *insights* aos gestores (Waller & Fawcet, 2013). Com uma compreensão básica da importância dos dados e o desenvolvimento de recursos e capacidades analíticas, é possível elevar o desempenho e agregar valor ao negócio (Abbasi, Sarker, & Chiang, 2016).

No entanto, o desenvolvimento de capacidades analíticas propícias, processos organizacionais e estruturas de gestão que permitam analisar grandes volumes de dados e criar valor através da geração de *insights* acionáveis consiste em um desafio relevante para as organizações, e é uma lacuna de pesquisa evidenciada em estudos recentes (Carillo, 2017; Galliers et al., 2017). Ademais, pesquisas recentes reforçam a necessidade de realização de estudos empíricos sobre as implicações de *Big Data* nas organizações (George, Haas, & Pentland, 2014; Günther et al., 2017; Markus, 2015).

Assim, as questões da pesquisa são: **Quais os benefícios de *Data Science for Business* para as organizações? Quais são os desafios associados ao desenvolvimento de recursos e capacidades analíticas?** O objetivo é identificar os benefícios de *Data Science for Business* para a melhoria das decisões e criação de valor para as organizações, evidenciando os pontos críticos, desafios e oportunidades relacionadas ao desenvolvimento dessa capacidade.

O tema é relevante, pois para obter vantagem competitiva sustentável, as organizações precisam utilizar os dados de suas operações de negócio como recursos para direcionar suas decisões (Erevelles, Fukawa, & Swayne, 2016). Contudo, para Ransbotham, Kiron e Prentice (2014), a principal barreira para a criação de valor de negócio a partir de *Data Science for Business* é tomar decisões de negócios com base nos resultados analíticos. As organizações que utilizam tecnologias de *Big Data* e *Data Science* podem auferir desempenho 6% superior

(Barton & Court, 2012; Brynjolfsson et al., 2011). Em estudo mais recente, os pesquisadores Müller, Fay e Von Brocke (2018) analisaram um conjunto de dados de 814 empresas durante os anos de 2008 a 2014 e descobriram que investimentos em *Big Data e Data Science* estão associados a uma melhoria de 3% a 7% na produtividade das empresas.

Este artigo está estruturado da seguinte forma: a segunda seção aborda a fundamentação teórica; a terceira discorre sobre o método de coleta e análise dos dados; a quarta contempla a análise qualitativa dos dados e a discussão dos achados da pesquisa; e, por fim, a quinta, consiste na exposição das considerações finais. Encerra-se esse estudo as referências.

2 FUNDAMENTAÇÃO TEÓRICA

Pesquisas empíricas emergentes sobre a adoção e o uso de *Big Data e Data Science* têm sido explicadas com base na RBV e na lente teórica de DC (Hazen et al., 2016; Fiorini et al., 2018). Logo, emprega-se tais teorias como lente analítica porque na literatura essas são utilizadas para explorar como as capacidades de sistema de informação afetam a inovação nas organizações (Tarafdar & Gordon, 2007). Nesta seção, apresenta-se a definição do termo *Data Science for Business* (DSB) e seus recursos e capacidades, assim como a síntese dos benefícios e desafios identificados na literatura por meio da construção de dois *frameworks*.

2.1 *Data Science for Business*

Para Chen, Chiang e Storey (2012), as tecnologias, métodos e aplicações avançadas de armazenamento, gerenciamento e visualização de dados, para orientar a tomada de decisão são associados ao termo *Business Intelligence & Analytics* (BI&A). De acordo com Newman et al. (2016), a capacidade de gerenciar *Data Science* tornou-se significativa para organizações que adotam a abordagem de BI&A. Waller e Fawcett (2013) consideram BI&A como equivalente à *Data Science* no contexto *Business*. *Data Science* é a área interdisciplinar que estuda como traduzir dados e transformá-los em informação e conhecimento (Newman et al., 2016; Waller & Fawcett, 2013), com a finalidade de melhorar a tomada de decisão, pois isso, geralmente, é de interesse primordial para os negócios (Provost & Fawcett, 2013). *Data Science* é amplamente aplicável em todas as áreas funcionais no negócio, como, por exemplo: a) em negócios em geral, a aplicação para a gestão de relacionamento com clientes, onde é possível analisar o comportamento do cliente, a fim de maximizar o valor esperado do cliente; b) na indústria financeira, o uso de ciência de dados para análise de crédito e de negociação; e c) nas operações via detecção de fraudes e gerenciamento de força de trabalho (Provost & Fawcett, 2013). Contempla o estudo dos princípios e métodos para criar, adquirir, processar, analisar, publicar, armazenar e reutilizar os dados, o que requer métodos para gestão de dados (Hoehndorf & Queralt-Rosinach, 2017).

No âmbito deste estudo, opta-se pelo termo “*Data Science for Business*” pelo fato desse ser mais amplamente difundido na acadêmica e entre praticantes de campos diversos, ao passo que o termo BI&A é mais comumente adotado na área de negócios. Tal definição contempla, também, o conceito de *Big Data Analytics*. *Data Science* inclui os V’s associadas à *Big Data*: *volume, variedade, velocidade, variabilidade, veracidade, validade, vulnerabilidade, volatilidade, visualização e valor* (Laney, 2001; Chen, Mao, & Liu, 2014; Firican, 2017; Newman et al., 2016). Embora essas várias características contribuam para a compreensão do fenômeno, o potencial real do *Big Data* não está em seus “V’s”, mas sim em sua capacidade de suportar recursos que são necessários para que a organização possa auferir os benefícios de *Big Data* (Markus, 2015).

A capacidade de *Big Data Analytics* (BDA) pode ser mensurada em três dimensões: recursos tangíveis, recursos humanos e recursos intangíveis; sendo que, a dimensão tangível é

formada por dados e recursos de tecnologia da informação, já a dimensão humana é refletida por habilidades técnicas e gerenciais, enquanto a dimensão intangível se reflete na cultura *data-driven* e na intensidade do aprendizado organizacional (Gupta & George, 2016; Müller & Jensen, 2017). Nas subseções, a seguir, serão revisados os recursos e capacidades analíticas relacionadas à *Big Data* e *Data Science*.

2.1.1 Recursos tangíveis: Dados e Sistemas de Informação

Isik, Jones e Sidorowa (2013) indicam que a qualidade dos dados, a acessibilidade para os usuários e a integração com outros sistemas são fundamentais para o sucesso de iniciativas analíticas. Para Redman (2013) o problema da qualidade dos dados emerge como uma implicação importante na análise de grandes dados, pois quando os dados não são confiáveis, os gerentes rapidamente desacreditam delas e recolhem-se à sua intuição para tomar decisões, orientar suas organizações e implementar suas estratégias. Para melhorar a qualidade dos dados, é necessário estabelecer uma melhor comunicação entre os criadores e os usuários dos dados (Redman, 2013). De acordo com Kitchens et al. (2018), para atingir vantagem competitiva sustentável, as organizações devem obter agilidade na rica combinação de dados em toda a organização, a fim de possibilitar que os gestores encontrem os dados que podem fornecer *insights* acionáveis e valiosos. Para alcançar esta agilidade, o desafio reside na identificação, coleta e integração de dados através de silos funcionais, dentro e fora da organização, pois é inviável integrar sistematicamente todos os dados disponíveis (Kitchens et al., 2018).

2.1.2 Recursos humanos: Perfis e Habilidades Analíticas

Para Davenport e Patil (2012), os cientistas de dados são a chave para perceber as oportunidades apresentadas pelo *Big Data*, pois eles podem ajudar a organização a encontrar padrões e aconselhar os executivos sobre as implicações desses para os produtos, processos e decisões. De acordo com Carillo (2017), o desenvolvimento de habilidades de análise não está restrito aos cientistas de dados. Para o autor, na era dos negócios orientados a dados, os gerentes devem se transformar em *Management-Scientists*, dotados de um conjunto de competências de natureza multidisciplinar que combine conhecimentos e habilidades de gerenciamento de dados, de ferramentas e técnicas de análise e modelagem, e de gestão negócios (Carillo, 2017).

Como as estratégias corporativas dependem cada vez mais dos dados, um número crescente de organizações está estabelecendo o papel do *Chief Data Officer* (CDO), uma nova geração de executivos posicionados para explorar o valor crítico que os dados podem fornecer (Lee et al., 2014). Para os autores, o CDO lidera os demais profissionais que atuam com análise e gerenciamento de dados, contribuindo para a eficácia da governança existente e colocando dados na agenda de negócios da organização e na mente dos demais executivos e diretores (Lee et al., 2014). Para desenvolver suas capacidades analíticas, as organizações relatam investimentos no treinamento de profissionais e gestores para que se faça melhor uso de *Analytics*. Contudo, à medida que uma organização tem capacidade para produzir análises cada vez mais sofisticadas, gera-se um desconforto aos gestores, por eles terem de tomar decisões com base em *insights* analíticos complexos que, por vezes, ainda não compreendem totalmente (Ransbotham, Kiron, & Prentice, 2014).

2.1.3 Recursos intangíveis: Cultura e Aprendizagem Organizacional

McAfee et al. (2012) asseveram que as organizações devem integrar todas as fontes internas e externas de dados e enfatizam a importância de adotar uma cultura de decisões orientada por dados (*data-driven*), em que os executivos tomam decisões com base em dados,

e não em seus instintos. Como trabalhar com *Big Data* requer novos tipos de habilidades técnicas e gerenciais, que não são comumente ensinadas em universidades, outro desafio é recrutar novos talentos e treinar os funcionários em habilidades específicas de ciência de dados, para que possam encontrar padrões em grandes conjuntos de dados e traduzi-los em informações úteis (Chin et al., 2017; McAfee et al., 2012).

De acordo com Ross, Beath e Quaadgras (2013), as organizações que adotam a tomada de decisão orientada por dados asseguram que todos os decisores tenham dados de desempenho em suas mãos diariamente, o que produz uma visão mais precisa dos custos e da rentabilidade, porém isso é uma grande mudança cultural e os gestores precisam aprender a tomar as suas decisões com base em dados, em vez de instinto (Ross, Beath, & Quaadgras, 2013). Os achados do estudo de Roberts, Campbell e Vijayasarathy (2016) indicam que o uso de BI&A está positivamente relacionado ao volume e à diversidade de ideias para a inovação organizacional, pois ajuda os gestores a analisarem os dados de várias fontes, proporcionando, assim, uma visão sobre as oportunidades potenciais, contribuindo para a compreensão comportamental de detecção, uma importante capacidade de gestão dinâmica (Roberts, Campbell, & Vijayasarathy, 2016).

2.2 Benefícios e Desafios relacionados às Capacidades Analíticas

O uso de *Data Science for Business* tem impactos significativos em dois tipos de criação de valor, em termos de produtividade e crescimento dos negócios (Chen, Preston, & Swink, 2015). Analisando-se organizações esportivas profissionais, Troilo et al. (2016) compararam o crescimento anual esperado para a indústria (3%) com o crescimento obtido pelas organizações que adotaram *Analytics* (7,2%), no ano seguinte à adoção. Com esses resultados, os autores argumentaram que examinar os dados para tomar decisões contribui de modo real e significativo para o crescimento das receitas (Troilo et al., 2016). Além disso, os resultados do estudo de Teo, Nishant e Koh (2016) mostram que as organizações que anunciam a implementação de *Business Analytics* (BA) obtêm reações do mercado de ações mais positivas em comparação com outras organizações, proporcionando, assim, a evidência empírica que os acionistas percebem BA como benéfico.

Para Wang, Kung e Byrd (2018) os benefícios de BDA podem ser: i) decorrentes do seu compartilhamento para suportar aplicações de negócio; ii) obtidos com a melhoria das atividades; iii) atingidos com as atividades de gerenciamento de negócios que envolvem alocação e controle dos recursos das empresas, monitoramento de operações e suporte de decisões estratégicas de negócios; iv) obtidos de atividades estratégicas, que envolvem planejamento de longo alcance em decisões de alto nível; e v) surgir quando o uso corporativo favorece a organização em termos de foco, coesão, aprendizagem e execução de suas estratégias escolhidas. Portanto, a percepção dos benefícios é relevante para o desenvolvimento dos recursos e capacidades de DSB. De acordo com Wimmer e Aasheim (2019) a intenção de adotar *Data Science* é influenciada pelo benefício percebido, que é determinado pela qualidade da informação, pela qualidade do sistema, pelas normas sociais e pelo comportamento de controle.

De acordo com a literatura, os recursos e as capacidades analíticas suportam melhores dados e avançados processos de análise, o que implica na melhoria da identificação e gestão das informações beneficiando a tomada de decisões e, conseqüentemente, a criação de valor para as organizações.

Na Figura 1, apresenta-se uma síntese sobre os benefícios relacionados às capacidades analíticas que contribuem para a melhoria das decisões e para a criação de valor.

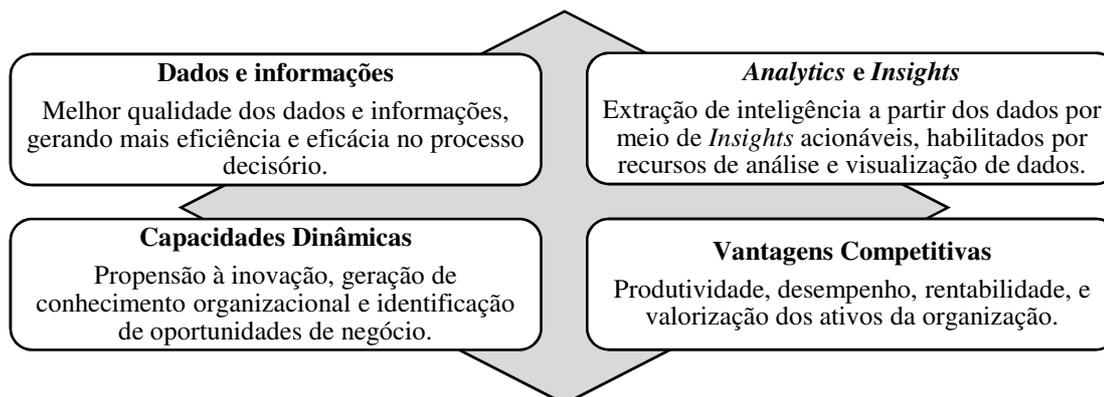


Figura 1. *Framework*: benefícios de DSB (Fonte: Elaborado pelos autores).

Observa-se que os benefícios categorizados no campo “dados e informações” estão diretamente associados aos recursos tangíveis de DSB. Já os benefícios categorizados como “*Analytics e Insights*” estão fortemente associados aos recursos humanos de DSB, ao passo que àqueles categorizados como “capacidades dinâmicas” dependem diretamente dos recursos intangíveis de DSB. Por fim, os benefícios categorizados como “Vantagens Competitivas” são um reflexo indireto da combinação de todos os recursos de *Data Science for Business*.

Para Frisk e Bannister (2017) o uso hábil de dados pode melhorar radicalmente o desempenho de uma organização, mas para se alcançar tais melhorias os gestores precisam mudar sua cultura de tomada de decisão e aumentar o grau de colaboração no processo de tomada de decisão. No entanto, a pesquisa dos autores Ransbotham, Kiron e Prentice (2014), indica que a principal barreira para a criação de valor de negócio, a partir de *Analytics*, é tomar decisões de negócios com base nos resultados analíticos, argumentando que há uma diferença entre produzi-los e aplicá-los eficazmente para questões de negócio.

Para a implementação de uma estratégia analítica, Barton e Court (2012) indicam que as organizações devem: i) identificar os dados certos para seu negócio, tentar adquirir a informação de maneira criativa a partir de diversas fontes, e garantir o necessário suporte de TI; ii) construir modelos analíticos para prever e otimizar resultados; e iii) transformar as suas capacidades e cultura, para que os dados e modelos resultem em melhores decisões. Vidgen Shaw e Grant (2017) asseveram que tornar-se *data-driven* não é apenas uma questão técnica e exige que as organizações: i) aparelhem suas áreas de *Business Analytics* para incluir analistas de negócios, cientistas de dados e profissionais de tecnologia da informação e; ii) alinhem a capacidade de análise de negócios à estratégia de negócios para enfrentar desafio de análise de uma forma sistêmica e integrada.

Além disso, de acordo com Grover et al. (2018) as organizações precisam: i) desenvolver padrões de qualidade de dados e métricas, bem como sistema para detecção e ajuste de anomalias de dados; ii) integrar de diferentes tipos de dados e formular estratégias para a resolução de inconsistências ou contradições entre as fontes diversas; iii) administrar a segurança dos dados em ambientes de armazenamento descentralizado; iv) identificar capacidades analíticas para pessoas e processos e adotar ferramentas de TI para suportá-las; v) definir o conjunto de capacidades distintas para um cientista de dados eficaz; vi) estudar a composição de estratégia, cultura e governança, ideal para facilitar a criação de valor.

Em síntese, McAfee et al. (2012) identificam cinco desafios para as organizações se tornarem orientadas a dados: liderança, recursos humanos, tecnologia, tomada de decisões e cultura. Já Shamim et al. (2018) evidenciam que a liderança, a gestão de talentos, a tecnologia e a cultura organizacional têm uma associação significativa com a capacidade de tomar decisões. Porém, essas dimensões não contemplam às características organizacionais, citados em outros estudos (Comuzzi & Patel, 2016; Dinter, 2012; Grover et al, 2018; Günther et al.,

2017; Krishnamoorthi & Mathew, 2018; Müller & Jensen, 2017). Assim, buscou-se a integração entre as dimensões apresentadas por Olzak (2014), por Vidgen, Shaw e Grant (2017) e por Shamim et al. (2018). Os elementos associados à estratégia, à estrutura e aos processos organizacionais foram agrupados em uma única dimensão. Contemplou-se, ainda, uma dimensão específica para os elementos relacionados à mentalidade dos líderes, à cultura e à intensidade da aprendizagem organizacional, em atenção aos desafios enfatizados por McAfee et al. (2012), Müller & Jensen (2017), Ransbotham, Kiron e Prentice (2014), Frisk e Bannister (2017), Vidgen, Shaw e Grant (2017) e Duan, Cao e Edwards (2018).

Na Figura 2, apresenta-se o segundo quadro conceitual, que consolida os principais desafios, categorizados nas dimensões: liderança e cultura organizacional, estratégia, estrutura e processos organizacionais, gestão de talentos e tecnologia da informação.

<p style="text-align: center;">Liderança e Cultura</p> <ul style="list-style-type: none"> • Mudança de mentalidade e incorporação da cultura de tomada de decisão <i>data-driven</i>. • Aumentar a qualidade das decisões por meio do uso dos resultados analíticos de modo eficaz para o direcionamento estratégico do negócio. • Estimular a prontidão e agilidade organizacional para a reestruturação de capacidades. 	<p style="text-align: center;">Gestão de Talentos</p> <ul style="list-style-type: none"> • Limitação cognitiva e comportamental dos agentes. • Definição de papéis (<i>Data Scientist; Management-Scientist; Chief Data Officer</i>). • Treinamento, desenvolvimento e educação para o desenvolvimento de habilidades analíticas. • Habilidades de comunicação para tradução dos dados em informações de negócio.
<p>Desafios para o desenvolvimento de Data Science for Business</p>	
<p style="text-align: center;">Estratégia, Estrutura e Processos</p> <ul style="list-style-type: none"> • Identificação dos dados críticos de negócio. • Qualidade dos dados de fontes diversas. • Definição da estratégia e arquitetura de dados. • Construção de modelos analíticos. • Estabelecimento de mecanismos e políticas de governança de dados. 	<p style="text-align: center;">Tecnologia da Informação</p> <ul style="list-style-type: none"> • Investimento intensivo em recursos e ativos de informação e de tecnologia da informação. • Integração de sistemas para combinação de fontes de dados internas e externas. • Adoção e uso de <i>Big Data Analytics</i>. • Acessibilidade e administração da segurança dos dados em ambientes descentralizados.

Figura 2. Framework: Desafios para o desenvolvimento de DSB (Fonte: Elaborado pelos autores).

Observa-se que os desafios classificados no campo “tecnologia da informação” e “gestão de talentos” correspondem respectivamente aos recursos tangíveis e recursos humanos de DSB, ao passo que àqueles classificados nos campos “liderança e cultura” e “estratégia, estrutura e processos” estão predominantemente associados aos recursos intangíveis.

A seguir, prossegue-se com a metodologia, e a análise dos dados, com base nos fundamentos teóricos revisados.

3 METODOLOGIA

Trata-se de um estudo qualitativo desenvolvido em duas etapas. Primeiro, para definir os principais conceitos e vislumbrar a agenda de debate no estado da arte da pesquisa sobre o tema, realizou-se uma revisão de literatura por meio de uma narrativa subjetiva, a fim de reunir os resultados dos estudos analisados (Jones & Gatrell, 2014; Paré et al., 2015). O objetivo da etapa conceitual foi identificar os fundamentos teóricos para a elaboração dos o esquema de codificação que emergiu do cruzamento dos elementos teóricos com os dados empíricos, sob a lente analítica das teorias *Resouce Based View (RBV)* e *Dynamic Capabilities (DC)*. Posteriormente, com intuito de captar uma vasta quantidade de pontos de vista, foram coletados dados por meio de uma entrevista eletrônica estruturada, executando-se a etapa empírica para analisar evidências sobre a percepção de usuários de DSB.

Quanto à validade da pesquisa qualitativa, adotam-se nesse estudo os parâmetros sugeridos por Venkatesh et al. (2013): validade de projeto, validade analítica e validade inferencial. Nas próximas subseções essas verificações de validade são comentadas.

3.1 Delineamento do instrumento de pesquisa e seleção dos informantes

O delineamento do instrumento baseou-se nos achados teóricos e nas questões de pesquisa. Para garantir a estabilidade dos dados e maximizar a confiabilidade da pesquisa, o estudo usa um questionário estruturado, contendo perguntas abertas. Inicialmente, para qualificação da amostra, foram solicitados dados dos informantes. A seguir, os informantes foram convidados a responder questões abertas sobre como o uso de BI&A ou *Data Science for Business* pode beneficiar a tomada de decisões nas organizações, e sobre quais os pontos críticos, desafios e oportunidades são vislumbrados em relação as capacidades analíticas.

Os dados foram coletados, em 2018, por meio de um formulário eletrônico via *Google Forms*. Foram convidados 369 indivíduos, considerados potenciais participantes, por integrarem associações profissionais, ou por possuírem interesses declarados em redes profissionais relacionados a *BI, BA, Big Data, Data Science*, governança de dados e de tecnologia da informação. Dessa população, foram recebidas 211 respostas. No presente estudo, garantimos a validade de projeto (Venkatesh et al. 2013) mantendo rigor na seleção dos informantes e dando-lhes liberdade para comunicar seus pontos de vista.

3.2 Procedimentos de análise dos dados

A análise de conteúdo teve como objetivo vincular os *insights* de pesquisa identificados durante a análise da literatura com os dados, suas categorias e contextos obtidos durante a pesquisa qualitativa (Bardin, 2009; Creswell, 2008). O esquema de codificação emergiu do cruzamento dos elementos teóricos com os dados empíricos, sob a lente analítica das teorias *Resource Based View (RBV)* e *Dynamic Capabilities (DC)*. Após a codificação, executou-se a categorização, que consistiu na classificação e agrupamento conteúdo de acordo com os critérios previamente definidos (Bardin, 2009). Os procedimentos foram realizados com suporte computacional do *software QSR NVivo V11*.

Em cada etapa de análise dos dados os pesquisadores verificaram a validade analítica ao estabelecer e executar os procedimentos de coleta e análise dados com rigor na aplicação dos métodos para que os achados sejam confiáveis, consistentes e plausíveis, e a validade inferencial por meio do rigor na interpretação dos dados (Venkatesh et al. 2013), o que aumenta a confiabilidade da pesquisa (Creswell, 2008).

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

4.1 Análise descritiva dos informantes

Do total de 369 convidados, 211 (57%) apresentaram suas respostas. Todos os informantes confirmaram que na organização na qual atuavam utilizava-se *Data Science for Business*. Mais de 72% possui nível de pós-graduação. Aproximadamente 75% dos participantes têm formação nas áreas de Administração, Tecnologia, Sistemas de Informação e Estatística. Mais de 70% atua como analistas e gestores de nível intermediário, e 25% encontram-se posicionados hierarquicamente em nível estratégico. A maioria dos participantes (61%) atua em organizações do setor de serviços, no qual se destacam as áreas de tecnologia

da informação (18%), de gestão de negócios, *marketing* e inteligência de mercado (18%), e de serviços financeiros e bancários (11%). Na Tabela 1 resume-se o perfil dos informantes.

Tabela 1.
Perfil dos informantes.

Total de informantes (n = 211)									
Idade (anos)	(%)	Experiência profissional	(%)	Porte da organização	(%)	Setor econômico	(%)	Frequência de uso de BI&A/DSB	(%)
≤25	6	≤2	3	Pequeno	24	Serviços	61	1-Raramente	1
26≤x≤35	41	2≤x≤5	9	Médio	31	Indústria	14	2	7
36≤x≤45	34	6≤x≤10	31	Grande	45	Governo	12	3	19
46≤x≤55	13	11≤x≤15	23			Comércio	6	4	26
x>55	6	x>15	34			Outros	7	5-Frequentemente	47

A seguir, parte-se para a análise de conteúdo a fim de se estabelecer o exame detalhado dos dados e a discussão dos resultados.

4.2 Benefícios percebidos pelos usuários de *Data Science for Business*

Os benefícios de DSB para a tomada de decisão são reconhecidos por meio de 11 indicadores. Na tabela 2, consta a frequência das referências por indicador de benefício, destacando-se as principais evidências observadas nas respostas.

Observa-se que os indicadores 1 e 2 dizem respeito à mudança de mentalidade e à consolidação de uma cultura de decisão orientada por dados no intuito de se melhorar a qualidade das decisões, corroborando-se com os achados dos estudos de Ghasemaghæi, Ebrahimi e Hassanein (2018) e de Shamim et al. (2018).

Já os indicadores 3, 4 e 5 estão relacionados benefícios associados aos recursos suportados por *Big Data* e *Analytics*, que possibilitam à agilidade na tomada de decisão a partir da exploração de grandes massas de dados e, ainda, viabiliza a análise e a visualização das informações de negócios, de modo inteligível e comunicável, bem como os benefícios em se adotar modelos analíticos para melhorar a acuidade de análises preditivas e de otimização (Bendole, 2016; Murray, 2017; Saggi & Jain, 2018; Sivarajah et al., 2017).

Conforme evidências apontadas nos indicadores 6 e 7, verifica-se que a adoção e uso dessas tecnologias facilita o compartilhamento de dados, a integração de informações, a comunicação e a elaboração de análises de modo colaborativo – estimulando à aprendizagem organizacional e à geração do conhecimento (Comuzzi & Patel, 2016; Gupta & Geoge, 2016).

Já os indicadores 8 e 9 evidenciam os benefícios relacionados à obtenção de capacidades dinâmicas (Olszak, 2014; Roberts; Campbell; Vijayasarathy, 2016). Endereça-se os benefícios à melhoria no sensoriamento e no aproveitamento de oportunidades, e à agilidade na implementação de mudanças, o que enseja o crescimento e o aumento de valor da organização.

Os indicadores 10 e 11 refletem os benefícios relacionados à obtenção de valor e à melhoria da competitividade organizacional por meio das capacidades analíticas, no que concerne ao incremento da produtividade e do desempenho organizacional e, logo, da rentabilidade do negócio. Essas contribuições evidenciadas estão em consonância com os achados dos estudos empíricos precedentes que relacionam o uso de *Data Science for Business* à obtenção de desempenho superior em relação a seus pares (Brynjolfsson et al., 2011; Barton & Court, 2012; Müller, Fay, & Von Brocke, 2018).

Após a análise dos benefícios percebidos pelos usuários, parte-se para a análise dos desafios, pontos críticos e oportunidades comentadas pelos informantes.

Tabela 2.Análise de frequência e evidências detalhada por indicador: Benefícios de *Data Science for Business* [grifos nossos].

Indicador	Ref.	Freq. (%)	Evidências
1. Viabiliza a tomada de decisão orientada por dados.	24	15,1%	<ul style="list-style-type: none"> • <i>Diminuir o impacto de opiniões</i>, focando-se no que é fato e quantificável. (I059). • <i>Criando uma cultura de decisão baseada em fatos</i> e eliminando a variabilidade do processo decisório. (I174).
2. Reduz incertezas e melhora a confiança.	15	9,4%	<ul style="list-style-type: none"> • Pode dar <i>maior consistência e permitir maior confiança</i> no que é apresentado para subsidiar decisões. (I004). • <i>Contribui para a diminuição das incertezas na tomada de decisões</i>. (I020).
3. Amplia a visão gerencial sobre <i>Big Data</i> .	7	4,4%	<ul style="list-style-type: none"> • Pode dar uma <i>visão mais ampliada sobre as informações</i>. (I006). • <i>Estamos inundados por dados. Sem apoio de tecnologia para analisar Big Data, o olhar holístico é prejudicado</i>. (I167).
4. Suporta a análise, avaliação, predição e otimização.	33	20,8%	<ul style="list-style-type: none"> • <i>Compreendendo padrões de comportamento</i> interno, de concorrentes, clientes e fornecedores. (I068). • Auxilia na tomada de decisões e <i>obtenção de insights diferenciados</i>, bem como <i>diminuição do risco operacional a partir de modelos preditivos</i>. Também, é capaz de <i>otimizar os processos, aumentando o lucro</i>. (I137). • Os modelos preditivos e analíticos são fundamentais para as decisões a serem tomadas pelos gestores de negócio. (I286).
5. Fornece <i>insights</i> acionáveis e análises de dados com agilidade.	26	16,4%	<ul style="list-style-type: none"> • Na <i>organização dos dados, cruzamentos de informações, insights rápidos, e drivers de escolha</i>. (I035). • Informação interpretada no <i>timing certo</i> e que gere recomendações de ação. (I039). • Contribui para uma <i>análise mais rápida dos dados</i>. (I246).
6. Facilita a integração e a comunicação.	7	4,4%	<ul style="list-style-type: none"> • <i>Desconstruindo silos de informação e criando repositórios integrados</i>. (I014). • Facilita a comunicação entre áreas, ajuda a encontrar oportunidades e reduz tempo de discussão sobre estratégias. (I276).
7. Auxilia a geração de conhecimento.	6	3,8%	<ul style="list-style-type: none"> • Extraíndo vantagens de seus dados, <i>alavancando esses dados e transformando-os em conhecimento</i>. (I131). • <i>A transformação de informação em conhecimento deve ser considerada um ativo de alto valor para a empresa</i>. (I275).
8. Facilita a compreensão do ambiente de negócios e o sensoriamento de oportunidades.	12	7,5%	<ul style="list-style-type: none"> • <i>Facilita na compreensão</i> de posicionamento, atuação e ação da empresa, tanto no mercado em que atua, bem como pode compreender todos os atores do mercado, evitando assim possíveis dependências e ou ameaças não identificadas. (I063). • Pode contribuir com a <i>compreensão, de fato, do negócio</i>. O conhecimento adquirido <i>possibilita projetar tomadas de decisão que criem vantagens para a empresa</i>. (I081). • <i>Identificando oportunidades de negócios de forma rápida e em tempo real</i>. (I242). • Pode contribuir para <i>evitar, por exemplo, fraudes em sistemas bancários, utilizando modelos preditivos</i>. (I303).
9. Facilita a identificação e priorização de mudanças estratégicas.	9	5,7%	<ul style="list-style-type: none"> • <i>Identificando os elementos críticos para priorizar a tomada de decisão e as ações de mudança</i>. (I017). • Pode contribuir <i>fornecendo maiores informações</i> o cliente para <i>alterar a estratégia mais rapidamente</i>. (I267). • Utilizar os dados coletados para <i>criar novos produtos</i> para os clientes e/ou novos atributos. (I228).
10. Melhora a gestão do desempenho organizacional.	12	7,5%	<ul style="list-style-type: none"> • <i>Facilita o controle dos KPI's, alertando rapidamente para algum problema ou oportunidade. Facilita o cruzamento de dados, ampliando a visão dos gestores sob a performance</i> da empresa e os movimentos do mercado. (I091). • <i>Mesurando e acompanhando os processos para analisar sua eficácia e possibilidade de melhorias; medindo performance geral ou individual para apoiar os resultados positivos e recalibrar os negativos</i>. (I119).
11. Viabiliza a competitividade organizacional.	8	5,0%	<ul style="list-style-type: none"> • Quem utiliza essas ferramentas adequadamente vai sempre <i>estar à frente da concorrência</i>. (I046). • <i>É essencial para o sucesso</i> de qualquer empresa. Não tem como atuar em um mercado competitivo sem saber como ele se comporta, sem acompanhar as tendências e evoluções suscetíveis. (I209).

Nota: Ao todo foram codificadas 159 referências.

4.3 Desafios para o desenvolvimento de *Data Science for Business*

As perspectivas vislumbradas pelos informantes para melhorar a capacidade analítica nas organizações concentram-se nas dimensões identificadas. A Tabela 3, abaixo, contém a frequência por categoria.

Tabela 3.
Frequência detalhada por indicador: desafios.

Dimensão	Indicador	Referências		Frequência (%)	
		Item	Dimensão	Item	Dimensão
Liderança e Cultura	• Cultura de decisão orientada por dados	48	59	26,67%	32,78%
	• Patrocínio da Alta Administração	7		3,89%	
	• Resistências às mudanças	4		2,22%	
Estratégia, Estrutura e Processos	• Governança de dados	8	46	4,44%	25,55%
	• Obtenção de valor a partir dos dados	8		4,44%	
	• Qualidade dos dados	7		3,89%	
	• Compartilhamento de dados	7		3,89%	
	• Arquitetura da informação	6		3,33%	
	• Estrutura organizacional	5		2,78%	
	• Procedimentos de análise	5		2,78%	
Gestão de Talentos	• Capacitação em Ciência de Dados	29	41	16,11%	22,78%
	• Engajamento de usuários	7		3,89%	
	• Transformação de dados em conhecimento	5		2,78%	
Tecnologia da Informação	• Investimento em evolução tecnológica	24	34	13,33%	18,88%
	• Inteligência Artificial	6		3,33%	
	• Integração e segurança dos dados	4		2,22%	

Nota: Ao todo foram codificadas 180 referências.

Nas próximas subseções, apresentam-se os resultados e a discussão específica sobre os desafios e as oportunidades associados a cada dimensão.

4.3.1 Liderança e Cultura

Os aspectos da dimensão cultural são os que prevalecem nas respostas (59 referências). Essas apontam para a necessidade de mudança no modelo cognitivo gerencial predominante, a fim de viabilizar a tomada de decisão orientada por dados (*data-driven decision making*), como citado pelo informante I167: “O maior desafio ainda é a barreira cultural [grifo nosso]. Impressionantemente, ainda há gestores que tomam decisões baseados em instinto exclusivamente [grifo nosso].” E, ainda, a respeito do desafio de engajar altos executivos e enfrentar resistências às mudanças nos diversos níveis organizacionais: “Como desafio, fica a necessidade de *convencimento da alta direção sobre a necessidade de que as decisões sejam embasadas por dados, e não "feelings", que é um dos pontos pelos quais mais lutamos atualmente* [grifo nosso].” (I272).

Os desafios mencionados pelos informantes evidenciam a importância de as organizações atentarem para o desenvolvimento de uma cultura *data-driven* direcionada por uma mentalidade dominante no corpo executivo que considere incorporar os resultados analíticos para qualificar efetivamente a visão estratégica e os processos decisórios, conforme preconizado por Duan, Cao e Edwards (2018), Gupta e George (2016), Günther (2017), Ghasemaghaei, Ebrahimi e Hassanein (2018), McAfee et al. (2012) e Shamim et al. (2018).

4.3.2 Estratégia, Estrutura e Processos

Esta dimensão foi a segunda mais representativa nas respostas (46 referências). Nela, destacam-se as referências sobre a gestão do ciclo de vida dos dados, que contempla a coleta, o compartilhamento de dados, os procedimentos de análise, a integração de informações em painéis, a transformação de dados em conhecimento, a definição políticas e de estruturas organizacionais de gestão ilustram-se com as respostas a seguir: “É necessário ter procedimentos definidos e ferramentas adequadas, além dos *objetivos bem definidos para que os dados úteis sejam identificados* [grifo nosso].” (I019); “(...) é fundamental ter uma *estrutura bem organizada para o fluxo de dados -da empresa* [grifo nosso].” (I266); “*Integração total dos dados da organização em ambiente de colaboração* [grifo nosso] e que permita a produção de análises ad hoc.” (I111).

Esses desafios dizem respeito à necessidade de se estabelecer uma estratégia corporativa de dados e de se configurar o modelo de governança e de gestão dos dados corporativos ideal para facilitar os processos de criação de valor (Comuzzi & Patel, 2016; Frisk & Bannister, 2017; Grover et al., 2018; Sharma, Mithas, & Kankanhalli, 2014; Günther et al., 2017; Katri & Brow, 2010; Nielsen, 2017; Tallon, Ramirez, & Short, 2013).

4.3.3 Gestão de Talentos

Os aspectos relacionados ao fator humano representam 41 referências, que concentram-se na necessidade de se desenvolver competências em métodos de inteligência e análise de dados por meio da capacitação dos gestores e analistas em gestão, estatística, tecnologia e ciência de dados, como assevera o informante I227: “*as empresas devem investir mais em treinamentos para habilitar seus profissionais, tornando-os habilitados para realizarem análises de dados mais eficientes e eficazes, gerando insights que agreguem valor a organização* [grifo nosso].”. Tais competências e complementariedades são necessárias para que as equipes possam extrair valor a partir dos dados. “*O ponto crítico são as pessoas* [grifo nosso], novas formações de times com características complementares diferentes dos times anteriores são necessárias para que se aproveite a mina de ouro escondida nos dados.” (I283).

A limitação de conhecimento e comportamento dos agentes no uso de ferramentas analíticas é um ponto crítico para se explorar o valor que os dados podem fornecer (Lee et al., 2014; Merendino et al., 2018). Além disso, novos papéis especializados em ciência, modelagem, análise, tradução, gestão e governança de dados estão emergindo no campo organizacional, como, por exemplo, *Data Scientist*, *Management-Scientist* e *Chieff Data Officer*, e isso requer o preparo corporativo para a identificação da necessidade desses recursos humanos especializados, para a captação e aproveitamento dessa força de trabalho, bem como a definição de estratégias de capacitação e a realização de investimentos em desenvolvimento de conhecimentos, habilidades e comportamentos, para que esses papéis possam ser plenamente desempenhados e a organização se beneficie ao máximo com essas novas competências, ainda raras no mercado de trabalho (Carillo, 2017; Chin et al., 2017; Davenport & Patil, 2012; Grover et al., 2018; Lee et al., 2014).

4.3.4 Tecnologia da Informação

Na dimensão tecnológica, foram observadas 34 referências que tangenciam a necessidade de se promover investimentos para o desenvolvimento das tecnologias da informação que suportam *Data Science for Business*, tais como *Big Data* e Inteligência Artificial. As respostas a seguir representam bem essa perspectiva: “*A análise de Big Data é o grande desafio para identificar tendências e padrões de comportamento no mercado* [grifo

nosso].” (I002). “Utilização de técnicas de *machine learning* para automatizar trabalhos manuais.” (I219). “Acredito que a incorporação da Inteligência Artificial para a análise de dados já qualificados pode aumentar em muito a assertividade [grifo nosso] das tomadas de decisão.” (I288). De fato, para o desenvolvimento, adoção, manutenção e aperfeiçoamento contínuo das tecnologias analíticas mais sofisticadas é requerido um investimento intensivo em recursos e ativos de informação e de tecnologia da informação (Comuzzi & Patel, 2016; Grover et al., 2018) e, portanto, embora menos frequente nos relatos, essa dimensão não é menos relevante que as demais.

Por fim, a resposta apresentada a seguir explana uma visão holística, como indicado por Gupta e George (2016), Müller e Jensen (2017), e Vidgen, Shaw e Grant (2017) sobre os desafios nessas diferentes dimensões.

O resultado só poderá ser alcançado se a organização possuir pessoas e cultura voltadas para a gestão, análise e uso da informação [grifo nosso]. Além disso, não ocorrerão mudanças significativas se não houver compromisso e envolvimento dos tomadores de decisão. A tecnologia tem que ser vista como ferramenta e não um fim em si mesma, são as pessoas que fazem a diferença, de nada vale tanta tecnologia se as pessoas não estiverem capacitadas, interessadas, familiarizadas e com uma forte cultura voltada para produção e aplicação do conhecimento (Inteligência), com finalidade e propósito [grifo nosso]. (I197).

Com a apresentação dessa citação encerra-se esta seção de análise e discussão dos resultados. Assim, parte-se para a descrição das considerações finais.

5 CONSIDERAÇÕES FINAIS

Este estudo investigou como o uso de *Data Science for Business* beneficia as organizações, e quais os pontos críticos, desafios e oportunidades associados ao desenvolvimento dessa capacidade na era do *Big Data*. Para a definição conceitual, foram revisados os elementos teóricos sobre *Business Intelligence & Analytics*, *Data Science for Business*, *Big Data* e *Big Data Analytics*. As teorias Visão Baseada em Recursos (VBR) e Capacidades Dinâmicas (CD) foram adotadas como lentes analíticas. Os dados foram coletados por meio de questões abertas dispostas em uma entrevista eletrônica estruturada.

Foram analisadas as respostas de 211 informantes e, com isso, são entregues três contribuições teóricas. A primeira diz respeito ao mapeamento do estado da arte sobre a pesquisa em relação ao tema, a fim de se organizar e sintetizar os benefícios e os desafios relatados na literatura. A segunda e a terceira estão relacionadas à ampliação do conhecimento científico, com base na análise das evidências à luz das teorias adotadas, por meio da entrega de uma síntese descritiva das 11 indicadores de benefícios associados ao uso de DSB e, ainda, da identificação de 16 perspectivas de desafios para o desenvolvimento das capacidades analíticas, dentre as quais se destacam: cultura *data-driven*, capacitação em ciência de dados, alocação de investimentos em tecnologias analíticas, governança de dados e qualidade dos dados. Com a consolidação de diferentes pontos de vista a respeito dos benefícios efetivos e da integração de desafios e oportunidades são indicados direcionamentos gerenciais.

Pese o conteúdo tenha sido coletado a partir de uma quantidade abrangente de informantes, esse estudo é uma pesquisa qualitativo que representa perspectivas particulares, o que, de fato, impede à generalização dos achados e conclusões. A partir deste estudo, emergem oportunidades de pesquisas futuras, que podem, por exemplo, aprofundar a compreensão de cada uma das dimensões específicas, em especial para compreender os desafios atinentes à

tomada de decisão orientada por dados e à governança de dados, face às barreiras culturais, estratégicas e organizacionais identificadas neste estudo. Além disso, são necessários estudos empíricos com profissionais que desempenham funções relacionadas à *Data Science for Business*, com vistas à análise do comportamento de uso das tecnologias analíticas emergentes, a fim de compreender como esses novos perfis profissionais podem auxiliar a organização a desbloquear o valor dos dados.

Por fim, espera-se, com este estudo, contribuir para a ampliação do conhecimento e qualificação das práticas de gestão estratégica da informação nas organizações, auxiliando na difusão dos benefícios e desafios atinentes ao desenvolvimento de capacidades analíticas. Essas contribuições abrangem a necessidade de mudança de mentalidade executiva por meio do estímulo à cultura *data-driven* e da formulação de estratégias e mecanismos de governanças dados, assim como à renovação das competências dos analistas, gestores e diretores de gestão de estratégica de dados, e, ainda, a evidenciação da necessidade de alocação de investimentos nos ativos de informação e de tecnologia da informação, a fim de se explorar o potencial valor que pode ser obtido por meio do *Big Data*.

REFERÊNCIAS

- Abbasi, A., Sarker, S., & Chiang, R. H. (2016). Big data research in information systems: Toward an inclusive research agenda. *Journal of the Association for Information Systems*, 17(2).
- Bardin, L. (2009). *Análise de Conteúdo*. Lisboa: Edições, 70.
- Barton, D., & Court, D. (2012). Making advanced analytics work for you. *Harvard Business Review*, 90(10), 78-83.
- Brynjolfsson, E., Hitt, L. M., & Kim, H. H. (2011). *Strength in numbers: How does data-driven decisionmaking affect firm performance?*.
- Carillo, K. D. A. (2017). Let's stop trying to be "sexy"—preparing managers for the (big) data-driven business era. *Business Process Management Journal*, 23(3), 598-622.,
- Chen, D. Q., Preston, D. S., & Swink, M. (2015). How the use of big data analytics affects value creation in supply chain management. *Journal of Management Information Systems*, 32(4), 4-39.
- Chen, H., Chiang, R. H., & Storey, V. C. (2012). Business intelligence and analytics: from big data to big impact. *MIS quarterly*, 1165-1188.
- Chen, M., Mao, S., & Liu, Y. (2014). Big data: A Survey. *Mobile networks and applications*, 19(2), 171-209.
- Chin, J. K., Hagstroenm, M., Libarikian, A., & Rifai, K. (2017). Advanced analytics: Nine insights from the C-suite. *McKinsey Global Institute*. Disponível em: <https://www.mckinsey.com/business-functions/mckinsey-analytics/our-insights/advanced-analytics-nine-insights-from-the-c-suite>.
- Comuzzi, M., & Patel, A. (2016). How organizations leverage big data: A maturity model. *Industrial Management & Data Systems*, 116(8), 1468-1492.
- Creswell, J. W. (2008). *Research design: Qualitative, quantitative, and mixed methods approaches*. Los Angeles, CA: Sage.
- Davenport, T. H., & Patil, D. J. (2012). Data scientist. *Harvard business review*, 90(5), 70-76.
- Dinter, B. (2012). The maturing of a business intelligence maturity model. *Proceedings AMCIS, Decision Support*, 37.
- Duan, Y., Cao, G., & Edwards, J. S. (2018). Understanding the Impact of Business Analytics on Innovation. *European Journal of Operational Research*.

- Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897-904.
- Fiorini, P. C., Seles, B. M. R. P., Jabbour, C. J. C., Mariano, E. B., & de Sousa Jabbour, A. B. L. (2018). Management theory and big data literature: From a review to a research agenda. *International Journal of Information Management*, 43, 112-129.
- Firican, G. (2017). The 10 vs of big data. TDWI, Inc. Retrieved online from <https://upside.tdwi.org/articles/2017/02/08/10-vs-of-big-data.aspx>.
- Frisk, J. E., & Bannister, F. (2017). Improving the use of analytics and big data by changing the decision-making culture: A design approach. *Management Decision*, 55(10), 2074-2088.
- Galliers, R. D., Newell, S., Shanks, G., & Topi, H. (2017). Datification and its human, organizational and societal effects. *The Journal of Strategic Information Systems*, 26(3), 185-190.
- George, G., Haas, M. R., & Pentland, A. (2014). Big data and management. *Academy of Management Journal*, 57 (2), 321-326.
- Ghasemaghaei, M., Ebrahimi, S., & Hassanein, K. (2018). Data analytics competency for improving firm decision making performance. *The Journal of Strategic Information Systems*, 27(1), 101-113.
- Grover, V., Chiang, R. H., Liang, T. P., & Zhang, D. (2018). Creating Strategic Business Value from Big Data Analytics: A Research Framework. *Journal of Management Information Systems*, 35(2), 388-423.
- Günther, W. A., Mehrizi, M. H. R., Huysman, M., & Feldberg, F. (2017). Debating big data: A literature review on realizing value from big data. *The Journal of Strategic Information Systems*, 26(3), 191-209.
- Gupta, M., & George, J. F. (2016). Toward the development of a big data analytics capability. *Information & Management*, 53(8), 1049-1064.
- Hazen, B. T., Skipper, J. B., Ezell, J. D., & Boone, C. A. (2016). Big Data and predictive analytics for supply chain sustainability: A theory-driven research agenda. *Computers & Industrial Engineering*, 101, 592-598.
- Hoehndorf, R., & Queralt-Rosinach, N. (2017). Data science and symbolic AI: Synergies, challenges and opportunities. *Data Science*, (Preprint), 1-12.
- Işık, Ö., Jones, M. C., & Sidorova, A. (2013). Business intelligence success: The roles of BI capabilities and decision environments. *Information & Management*, 50(1), 13-23.
- Jones, O., & Gatrell, C. (2014). The future of writing and reviewing for IJMR. *International Journal of Management Reviews*, 16(3), 249-264.
- Khatri, V., & Brown, C. V. (2010). Designing data governance. *Communications of the ACM*, 53(1), 148-152.
- Kitchens, B., Dobolyi, D., Li, J., & Abbasi, A. (2018). Advanced Customer Analytics: Strategic Value Through Integration of Relationship-Oriented Big Data. *Journal of Management Information Systems*, 35(2), 540-574.
- Krishnamoorthi, S., & Mathew, S. K. (2018). Business analytics and business value: A comparative case study. *Information & Management*, 55(5), 643-666.
- Laney, D. (2001). 3D data management: Controlling data volume, velocity and variety. Stamford, CT: *META Group Research Note*.
- Lee, Y., Madnick, S. E., Wang, R. Y., Wang, F., & Zhang, H. (2014). *A cubic framework for the chief data officer: Succeeding in a world of big data*.
- Livingston, J. (2017). The secret of successful business is data-driven decision-making. *IDG Communications, Inc.* Disponível em: <https://www.cio.com/article/3229853/cio-role/the-secret-of-successful-business-is-data-driven-decision-making.html>.

- Mao, Y., & Quan, J. (2015). IT enabled organisational agility: Evidence from Chinese firms. *Journal of Organizational and End User Computing (JOEUC)*, 27(4), 1-24.
- Markus, M. L. (2015). New games, new rules, new scoreboards: the potential consequences of big data. *Journal of Information Technology*.
- McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J., & Barton, D. (2012). Big data: the management revolution. *Harvard business review*, 90(10), 60-68.
- Müller, O., Fay, M., & Vom Brocke, J. (2018). The effect of big data and analytics on firm performance: An econometric analysis considering industry characteristics. *Journal of Management Information Systems*, 35(2), 488-509.
- Müller, S. D., & Jensen, P. (2017). Big data in the Danish industry: application and value creation. *Business Process Management Journal*, 23(3), 645-670.
- Murray, S. (2017). *Interactive Data Visualization for the Web: An Introduction to Designing with*. O'Reilly Media, Inc.
- Newman, R., Chang, V., Walters, R. J., & Wills, G. B. (2016). Model and experimental development for Business Data Science. *International Journal of Information Management*, 36(4), 607-617.
- Nielsen, O. B. (2017). A Comprehensive Review of Data Governance Literature. *Selected Papers of the IRIS, Issue Nr 8 (2017)*. 3.
- Olszak, C. M. (2014, September). Towards an understanding Business Intelligence. A dynamic capability-based framework for Business Intelligence. In *Computer Science and Information Systems (FedCSIS), 2014 Federated Conference on* (pp. 1103-1110). IEEE.
- Paré, G., Trudel, M. C., Jaana, M., & Kitsiou, S. (2015). Synthesizing information systems knowledge: A typology of literature reviews. *Information & Management*, 52(2), 183-199.
- Provost, F., & Fawcett, T. (2013). Data science and its relationship to big data and data-driven decision making. *Big Data*, 1(1), 51-59.
- Ransbotham, S., Kiron, D., & Prentice, P. K. (2015). Minding the analytics gap. *MIT Sloan Management Review*, 56(3), 63.
- Redman, T. C. (2013). Data's credibility problem. *Harvard Business Review*, 91(12), 84-88.
- Roberts, N., Campbell, D. E., & Vijayarathy, L. R. (2016). Using information systems to sense opportunities for innovation: Integrating postadoptive use behaviors with the dynamic managerial capability perspective. *Journal of Management Information Systems*, 33(1), 45-69.
- Ross, J. W., Beath, C. M., & Quaadgras, A. (2013). You may not need big data after all. *Harvard Business Review*, 91(12), 90.
- Roy, R. & Seitz, B. (2018). How to build a data-first culture for a digital transformation. *McKinsey Global Institute*. Disponível em: <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/how-to-build-a-data-first-culture>.
- Saggi, M. K., & Jain, S. (2018). A survey towards an integration of big data analytics to big insights for value-creation. *Information Processing & Management*, 54(5), 758-790.
- Shamim, S., Zeng, J., Shariq, S. M., & Khan, Z. (2018). Role of big data management in enhancing big data decision-making capability and quality among Chinese firms: A dynamic capabilities view. *Information & Management*.
- Sharma, R., Mithas, S., & Kankanhalli, A. (2014). Transforming decision-making processes: a research agenda for understanding the impact of business analytics on organizations. *European Journal of Information System*, 23, 433-441.
- 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.

- Tallon, P. P., Ramirez, R. V., & Short, J. E. (2013). The information artifact in IT governance: toward a theory of information governance. *Journal of Management Information Systems*, 30(3), 141-178.
- Tarafdar, M., & Gordon, S. R. (2007). Understanding the influence of information systems competencies on process innovation: A resource-based view. *The Journal of Strategic Information Systems*, 16(4), 353-392.
- Teo, T. S., Nishant, R., & Koh, P. B. (2016). Do shareholders favor business analytics announcements?. *The Journal of Strategic Information Systems*, 25(4), 259-276.
- Troilo, M., Bouchet, A., Urban, T. L., & Sutton, W. A. (2016). Perception, reality, and the adoption of business analytics: Evidence from North American professional sport organizations. *Omega*, 59, 72-83.
- Vasarhelyi, M. A., Kogan, A., & Tuttle, B. M. (2015). Big Data in accounting: An overview. *Accounting Horizons*, 29(2), 381-396.
- Venkatesh, V., Brown, S. A., & Bala, H. (2013). Bridging the qualitative-quantitative divide: Guidelines for conducting mixed methods research in information systems. *MIS Quarterly*, 37(1).
- Vidgen, R., Shaw, S., & Grant, D. B. (2017). Management challenges in creating value from business analytics. *European Journal of Operational Research*, 261(2), 626-639.
- Waller, M. A., & Fawcett, S. E. (2013). Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management. *Journal of Business Logistics*, 34(2), 77-84.
- Wang, Y., Kung, L., & Byrd, T. A. (2018). Big data analytics: Understanding its capabilities and potential benefits for healthcare organizations. *Technological Forecasting and Social Change*, 126, 3-13.
- Wimmer, H., & Aasheim, C. (2017). Examining Factors that Influence Intent to Adopt Data Science. *Journal of Computer Information Systems*, 1-9.