

Pressões institucionais na configuração da capacidade de análise de *big data*

Luciana Klein¹

 <https://orcid.org/0000-0001-6815-1831>

E-mail: lucianaklein@ufpr.br

Ana Paula Sano Guilhem¹

 <https://orcid.org/0000-0002-3892-9515>


E-mail: anapolletti@hotmail.com

Henrique Adriano de Sousa^{1,2}

 <https://orcid.org/0000-0002-7740-3946>

E-mail: henriquesousa@prof.unipar.br

Everton Lucio Soares de Oliveira³

 <https://orcid.org/0000-0003-3586-651X>

E-mail: evertonadmcontabeis@outlook.com

¹ Universidade Federal do Paraná, Setor de Ciências Sociais Aplicadas, Departamento de Ciências Contábeis, Curitiba, PR, Brasil

² Universidade Paranaense, Departamento de Administração, Cascavel, PR, Brasil

³ Pesquisador independente não afiliado atualmente, São Manoel do Paraná, PR, Brasil

Recebido em 30.11.2021 – Desk aceite em 30.12.2021 – 8ª versão aprovada em 06.02.2023

Editor-Chefe: Fábio Frezatti

Editor Associado: Cláudio de Araújo Wanderley

RESUMO

O objetivo deste artigo é analisar a configuração dos recursos tangíveis e das habilidades humanas de *big data*, diante das pressões institucionais, na capacidade de análise de *big data* em empresas brasileiras. A inovação influencia o ambiente em que as empresas estão inseridas, aumentando as incertezas, resultando em modificações comportamentais dos atores sociais. Em resposta aos esforços individuais para lidar com as incertezas e restrições de forma racional emerge a homogeneização das organizações. No entanto, as pressões institucionais que influenciam a configuração de recursos específicos ainda não são totalmente entendidas pela literatura. Considera-se a replicação do estudo de Dubey (2019b), entendendo a tecnologia *big data* como uma inovação que tem causado mudanças no contexto social, assim, busca-se compreender a configuração dos recursos organizacionais de *big data* nas empresas brasileiras para o desenvolvimento da capacidade de ABD, devido às pressões institucionais. O estudo possibilita compreender como as pressões institucionais configuram a capacidade de ABD, podendo assim subsidiar decisões de alocação de investimento em tecnologia de dados ou aprimoramento de habilidades técnicas de gerenciais da equipe de *business intelligence*. O estudo trouxe a conhecimento a resposta ambiental, resultante da inovação tecnológica de *big data*, das empresas brasileiras. Isso demonstra que as organizações que aderiram a tecnologia *big data* selecionam seus recursos diante de diferentes pressões, a fim de desenvolver a capacidade de análise de *big data*. Esta pesquisa possui caráter descritivo e quantitativo e sua operacionalização ocorreu por uma *survey*. A população pesquisada consiste em empresas brasileiras que usam tecnologia com grande volume de dados estruturados e/ou não estruturados, para a geração de resultados e *insights*, que auxiliam na tomada de decisão. Os participantes da pesquisa foram colaboradores de empresas brasileiras que apresentem funções relacionadas ao desenvolvimento da capacidade de análise de *big data*, localizados por meio da plataforma *LinkedIn*. Foram obtidas 136 respostas válidas. Para testar as hipóteses se usou a técnica de Modelagem de Equações Estruturais empregando o *software Smartpls v. 3.2.3*. Este estudo contribui trazendo a compreensão do comportamento organizacional diante das pressões institucionais (coercitiva, normativa e mimética) na seleção dos recursos tangíveis e habilidades humanas de *big data* para o desenvolvimento da capacidade de ABD, fundamentado na Teoria Baseada em Recursos. Observa-se que a configuração da capacidade de ABD é influenciada por recursos tangíveis e habilidades humanas. Os recursos tangíveis são selecionados devido a pressões formais, condições competitivas e por imitação de padrões existentes no mercado. Enquanto, as habilidades humanas requeridas, são impactadas, por meio da legitimação e redes profissionais dos tomadores de decisão.

Palavras-chave: pressões institucionais, análise de *big data*, Teoria Baseada em Recursos, recursos organizacionais de *big data*, indústria 4.0.

Endereço para correspondência

Luciana Klein

Universidade Federal do Paraná, Setor de Ciências Sociais Aplicadas, Departamento de Ciências Contábeis

Avenida Prefeito Lothário Meissner, 632 – CEP 80210-170

Jardim Botânico – Curitiba – PR – Brasil

Este é um texto bilíngue. Este artigo também foi traduzido para o idioma inglês, publicado sob o DOI <https://doi.org/10.1590/1808-057x20231591.en> Trabalho apresentado no XXIV SemeAD, novembro de 2021.



1. INTRODUÇÃO

O avanço tecnológico desencadeado pela Indústria 4.0 impacta as organizações de forma exponencial, assim, para manter a competitividade de mercado, elas buscam implementar estratégias para aderir as inovações tecnológicas de modo a obter desempenho financeiro e posicionamento de mercado. No entanto, é necessário o desenvolvimento da capacidade organizacional e não apenas a implementação de novas tecnologias, obtida por meio da combinação de recursos tangíveis, intangíveis e habilidades humanas, conforme a Teoria Baseada em Recursos (Barney, 1991; Barney et al., 2011; Grant, 1991; Mikalef et al., 2018; Yu et al., 2018). Entretanto, o ambiente em que as organizações estão inseridas é incerto, o que impacta a competitividade.

DiMaggio e Powell (1983) apontam que fatores externos aumentam as incertezas e as restrições à organização, assim, a racionalidade dos atores organizacionais para lidar com as pressões conduz o campo organizacional à homogeneização, sendo esse fenômeno denominado *isomorfismo institucional*. O isomorfismo ocorre por meio de pressões institucionais em três aspectos: (i) coercitivo, que ocorre por meio de influências políticas e questões de legitimidade; (ii) mimético, resultando na padronização devido às incertezas; e (iii) normativo, que tem relação com as normas associadas à profissionalização (DiMaggio & Powell, 1983). Assim, em resposta aos esforços individuais para lidar com as incertezas e restrições de forma racional emerge a homogeneização da cultura, estrutura e resultados das organizações (DiMaggio & Powell, 1983).

Apesar das decisões racionais dos atores organizacionais restringirem as habilidades para mudanças futuras, há os que buscam melhorias adotando inovações organizacionais (DiMaggio & Powell, 1983), principalmente em aspectos que carecem de desenvolvimento das capacidades da organização (Oliver, 1997). Uma tecnologia que tem se destacado, dentro da Indústria 4.0, é o *big data*, entendido como uma ruptura tecnológica nos ecossistemas empresariais e acadêmicos desde a ascensão da *Internet* e da economia digital. O *big data* é definido pelo grande volume de dados de diversas fontes, estruturados ou não (Arunachalam et al., 2018; Brinch et al., 2018; Félix et al., 2018; Mikalef et al., 2019). Todavia, essa tecnologia por si só não proporciona benefícios, é necessário o desenvolvimento da capacidade de Análise de *Big Data* (ABD), definida pela combinação estratégica dos recursos tangíveis, intangíveis e habilidades humanas de *big data* (Gupta & George, 2016).

A capacidade de ABD foi relacionada a diversos benefícios, como tomada de decisão consubstanciada a partir do grande volume de informações, maior poder

de barganha com fornecedores e clientes (Falsarella & Jannuzzi, 2020), aprimoramento da cadeia de suprimentos, aperfeiçoamento do planejamento de demanda, melhora na capacidade de planejamento de vendas e operações e melhoria no desempenho financeiro (Cabrera-Sánchez & Villarejo-Ramos, 2019; Mikalef et al., 2018; Queiroz & Pereira, 2019; Schoenherr & Speier-Peró, 2015; Zhang et al., 2017).

Apesar da escassez da literatura resultar em um entendimento limitado do impacto nos controles gerenciais, Vitale et al. (2020) descobriram que o *big data* tem implicações diferentes nas dimensões formal e informal do sistema de controle gerencial de uma empresa de pequeno porte da Alemanha. Na dimensão formal, o *big data* reforça o processo orçamentário, mas não altera os artefatos formais, já a dimensão informal é fortalecida, racionalizada e formalizada. Já Bergmann et al. (2020) constataram que a sofisticação da infraestrutura de dados está positivamente associada ao uso de *business analytics* no processo orçamentário. Além disso, os autores concluíram que quanto mais uma empresa enfatiza a função de planejamento, mais o *business analytics* é usado. No Brasil, é possível destacar a importância desse estudo ao relacionar as derivações do *big data* com os sistemas de gerenciamento como, por exemplo, o *Business Intelligence* (BI) (Reginato & Nascimento, 2007). No mesmo sentido, evidencia-se a aplicação dos sistemas de *big data* atrelados às ferramentas de contabilidade e gestão como o *Balanced Scorecard* (Galas & Ponte, 2006).

Entretanto, a adoção dos recursos de *big data* nem sempre ocorre de forma estratégica, nesse sentido, questões institucionais relevantes são levantadas para explicar a origem e disseminação das tecnologias relacionadas à Indústria 4.0. Fogaça et al. (2022) argumentam que: (i) modos de justificação distintos e específicos são enfatizados por diferentes tipos de organizações (como empresas, sindicatos, universidades e governos) ao adotar a Indústria 4.0; (ii) é um movimento social que tem o governo alemão como um de seus grandes empreendedores institucionais; (iii) adquirirá significados distintos à medida que se difundir entre países com diferentes características institucionais.

Sob a ótica institucional, as empresas procuram atender as pressões dos diversos públicos de interesse e analisam o comportamento dos demais agentes do campo organizacional. Nesse sentido, as pressões institucionais (coercitiva, normativa e mimética) forçam a adoção da tecnologia *big data*, por meio da configuração de recursos-chave, recursos tangíveis e habilidades humanas. No

aspecto tangível, incluem tecnologia, recursos básicos e dados, já no aspecto humano é referente à habilidade analítica e técnica dos dados (Gupta & George, 2016).

As interações entre pressões institucionais, habilidades humanas e recursos tangíveis foram observadas em Dubey et al. (2019b), cujas evidências apontaram que pressões têm efeitos significativo na seleção de recursos tangíveis em empresas de manufatura da Índia, afetando diretamente a alocação dos recursos internos e a adoção de ABD. No entanto, os autores apontam que as pressões coercitivas, no contexto analisado, não têm um efeito significativo nas habilidades humanas. Bag et al. (2021), ao analisarem empresas automotivas que operam na África do Sul, encontraram uma relação significativa entre as pressões institucionais e a adoção dos recursos tangíveis, com destaque das pressões coercitivas sobre os recursos tangíveis. Os autores, afirmam ainda, que o governo sul africano, por meio do certificado Black Economic Empowerment (BEE) e do Skills Development Act (Lei de Desenvolvimento de Competências), solicita a atualização em programação e análise dos dados das empresas, para que haja qualificação dos recursos humanos para o crescimento da economia. Assim, as pressões institucionais, também, estão associadas as habilidades da força de trabalho.

Nesse sentido, as pressões institucionais orientam uma empresa a operar dentro das fronteiras sociais e a maioria dos países moldou suas estratégias digitais individuais para conduzir programas digitais dentro dessas fronteiras sociais (Gerrikagoitia et al., 2019). No Brasil, as pressões externas de agências governamentais, como o Sistema Nacional de Inovação (SNI), Ministério da Ciência, Tecnologia e Inovações e Comunicações (MCTIC) e o Ministério do Desenvolvimento da Indústria e Comércio Exterior e Serviços (MDIC) atuam como forças massivas para a inserção tecnológica, direcionando as empresas a se alinharem e operarem dentro da estratégia digital brasileira (Silva, 2019). As pressões de clientes, também, forçam os fornecedores a adotarem tecnologias digitais para configurar seus recursos e capacidades (Cabrera-Sánchez & Villarejo-Ramos, 2019; Félix et al., 2018).

Argumenta-se que as pressões institucionais influenciam a configuração de recursos-chave para desenvolver a capacidade de ABD, a qual pode auxiliar no desempenho competitivo e financeiro (Mikalef et al., 2018;

Yu et al., 2018). Portanto, replicou-se o estudo de Dubey (2019b), a fim de indicar como pressões institucionais levam ao desenvolvimento de capacidades de ABD. No Brasil, a transformação digital está sendo impulsionada, principalmente, pelas agências governamentais, dessa maneira, objetivo do estudo é analisar a configuração dos recursos tangíveis e habilidades humanas de *big data*, diante das pressões institucionais, na capacidade de ABD no contexto das empresas brasileiras.

É relevante compreender como as estruturais sociais influenciam e alteram processos e a estrutura organizacional, a fim de visualizar as oportunidades de negócios (Francisco et.al., 2020) e os possíveis impactos a nível gerencial das empresas. Isso posto, este estudo possibilita compreender como as pressões institucionais configuram a capacidade de ABD, podendo assim subsidiar decisões de alocação de investimento em tecnologia de dados ou aprimoramento de habilidades técnicas e gerenciais da equipe de *business intelligence*. Destarte, o estudo tem potencial, de destacar a importância das habilidades humanas na construção da vantagem competitiva, pois apenas os investimentos destinados a coletar grandes volumes de dados e ter acesso a tecnologias sofisticadas não garantem uma vantagem competitiva sustentada.

A criação e manutenção de um banco de dados para a tomada de decisão, na era da Indústria 4.0, promete alterar os papéis do CFO e do *controller*, nos níveis organizacional e pessoal. Schäfer e Weber (2018), apontam a necessidade de CFOs e *controllers* assumirem um papel ativo na abordagem das oportunidades digitais e nas mudanças correspondentes nos modelos de negócios e nas estratégias organizacionais, o que implica o desenvolvimento e adaptação de novos indicadores de desempenho, misturando modelos de negócios tradicionais com digitais. A criação e manutenção de um banco de dados para a tomada de decisão sempre foi a responsabilidade central do departamento de finanças, no entanto, esse papel é cada vez mais desafiado pelos cientistas de dados e outras funções da TI (Möller et al., 2020; Schäfer & Brueckner, 2019). Em nível pessoal a necessidade de desenvolver *expertise* em *big data* e *analytics* se torna latente. Assim, entender o papel das habilidades humanas e dos recursos tangíveis na capacidade de ABD poderá sustentar as mudanças nos níveis organizacional e pessoal das empresas brasileiras.

2. PRESSÕES INSTITUCIONAIS, RECURSOS, HABILIDADES E CAPACIDADE DE ANÁLISE *BIG DATA*

O comportamento das organizações sofre pressões exercidas pelas instituições, como forças sociais, regulatórias, relações de controle direto e em transações organizacionais,

derivadas do ambiente (DiMaggio & Powell, 1983; Guarido & Costa, 2012; Scott, 1994, 2008). Na perspectiva institucional, novas práticas organizacionais são orientadas

e moldadas por instituições externas e interações entre as organizações (DiMaggio & Powell, 1983; Guarido & Costa, 2012; Williams & Spielmann, 2019). A adesão às novas tecnologias e modificações comportamentais da organização ocorre no campo institucional por intermédio de pressões informais e formais (DiMaggio & Powell, 1983; Oliver, 1991). Essas pressões remetem à Teoria Institucional Sociológica, que possui como base três pilares: (i) cognitivo, relacionado às pressões miméticas, (ii) normativo, relativo às pressões normativas, e (iii) regulatório, pertinente às pressões coercitivas (Fonseca, 2003). Devido a essas pressões, as organizações se tornam homogêneas, fenômeno conhecido como *isomorfismo institucional*. O isomorfismo pode ser coercitivo, mimético e normativo (DiMaggio & Powell, 1983).

O isomorfismo coercitivo deriva de pressões informais e formais e expectativas culturais sofridas pelas organizações dependentes de outras. Essas pressões são explicadas por meio de persuasão e coerção, bem como por ordens governamentais (DiMaggio & Powell, 1983). O isomorfismo mimético proveniente da incerteza simbólica e quando há metas ambíguas. Uma resposta a essa incerteza é seguir um modelo já usado por outras organizações, encorajando a imitação. O isomorfismo normativo decorre da profissionalização, constituído de dois aspectos sendo o primeiro a legitimação de especialistas universitários e apoio à educação formal e o segundo a constituição de redes profissionais colaborando para difusão de modelos de forma rápida, como a compartilhamento de conhecimento entre profissionais e empresas de consultoria (Adjei et al., 2021; DiMaggio & Powell, 1983; Irwin et al., 2021).

O isomorfismo deve ser considerado agregado à competitividade (Hannan & Freeman, 1977), que ocorre por meio das pressões institucionais e estas têm uma relação positiva quanto à seleção de recursos das

organizações (Dubey et al., 2019b; Meyer & Rowan, 1977). As forças externas geram necessidade de adaptação nas organizações. Essa adaptabilidade é observada e requerida no contexto da quarta Revolução Industrial, também conhecida como Indústria 4.0, que inclui diversas tecnologias como *internet das coisas*, robótica e *big data*, fazendo com que organizações busquem inovações e adoção tecnológica motivada por tendências internacionais, nacionais e vantagem competitiva (Sakurai & Zuchi, 2018).

As pressões institucionais forçam a adoção de tecnologias da Indústria 4.0, por meio da configuração de recursos-chave, principalmente relacionados a recursos tangíveis e habilidades humanas (Chahal et al., 2020). A Teoria Baseada em Recursos (TBR) sustenta que os recursos organizacionais e o desenvolvimento de capacidades de forma estratégica podem propiciar vantagem competitiva (Barney, 1991, 2001; Chahal et al., 2020; Cruz & Haugan, 2019; Grant, 1991). Como exemplo de recursos, podem ser citados os bens ou *inputs* tangíveis que uma organização possui, controla ou a que tem acesso em base semipermanente (Helfat & Peteraf, 2003). Esses recursos são usados pelas empresas por meio de habilidades, que são constituídas por aspectos físicos e humanos necessários para que a empresa atenda seu cliente.

Sob o enfoque da TBR, os recursos são unidades básicas de análise, podendo ser de capital físico (equipamentos, tecnologia e matéria-prima), capital humano (*insights* de funcionários, experiência, treinamento, inteligência, julgamento e relacionamento) e capital organizacional (planejamento formal e informal, sistemas de controle e estrutura de relatórios), com caráter heterogêneo, devido às diferentes estratégias adotadas pelas organizações (Barney, 1991; Grant, 1991; Oliver, 1997). Ao aplicar os conceitos da TBR, Gupta e George (2016) classificam os recursos organizacionais de *big data* como mostra a Figura 1.

Recurso Tangível	Dados (internos, externos e fusão de ambos); Tecnologia; Recursos básicos (tempo e investimento).
Recurso Humano	Habilidades gerenciais (perspicácia analítica); Habilidades técnicas (educação e treinamentos relativos às habilidades específicas de <i>big data</i>).
Recurso Intangível	Cultura baseada em dados (decisões baseadas em dados, em vez de intuições); Intensidade de aprendizagem organizacional (capacidade de explorar, armazenar, compartilhar e aplicar conhecimentos).

Figura 1 Recursos organizacionais de *big data*

Fonte: Adaptada de Gupta e George (2016).

Gupta e George (2016) propuseram a ideia da capacidade de ABD desenvolvida com abordagem da TBR, que trata da relação entre recursos e capacidades, sendo os recursos fonte da capacidade organizacional.

O resultado da combinação de recursos com trabalho em equipe constitui a capacidade organizacional, a qual tem uma especificidade para cada empresa (Grant, 1991; Makadok, 2001).

Assim, com foco na tecnologia *big data* as organizações desenvolvem a capacidade de ABD a partir da combinação de recursos direcionada para essa tecnologia. As organizações são influenciadas pelo contexto que estão inseridas, devido às pressões institucionais (Grant, 1991; Gupta & George, 2016; Vidgen et al., 2017). Essas pressões impactam diretamente o acesso a recursos, pois estes se relacionam à melhoria da análise e à qualidade das informações, que refletem o desempenho da empresa (Dubey et al., 2016, 2019b).

A pressão coercitiva advém de outras organizações, expectativas socioculturais, órgãos externos que têm autoridade para interferir no comportamento e na estrutura organizacional, por meio de políticas, leis e regulamentações das empresas (DiMaggio & Powell, 1983). São exemplos associações empresariais, agências governamentais, normas da Organização Internacional de Normatização (ISO) e Lei Geral de Proteção de Dados (LGPD). A pressão pode ser exercida nos recursos tangíveis com intervenções governamentais por meio de normas regulamentares em relação aos dados, políticas nacionais e financiamentos para fomentar tecnologias (Bag et al., 2021; Dubey et al., 2019b). As habilidades humanas podem ser visualizadas no atendimento das expectativas de fornecedores, *stakeholders* e clientes (Dubey et al., 2015, 2016; Liang et al., 2007). Destarte, temos as seguintes hipóteses:

H_{1a}: Pressão coercitiva possui relação positiva com recursos tangíveis de *big data*.

H_{1b}: Pressão coercitiva possui relação positiva com habilidades humanas de *big data*.

A pressão normativa decorre da profissionalização, com base no processo de especialização, instituindo normas e valores na organização de modo a atingir metas estabelecidas com clientes e outros profissionais (Dubey et al., 2015, 2016; Liang et al., 2007). Tal pressão sobre os recursos tangíveis pressionam o desenvolvimento da organização, pois a inadequação tecnológica pode levar a intermitência nas negociações por parte de fornecedores e clientes (Bag et al., 2021). A influência da pressão normativa nas habilidades humanas pode ocorrer devido a treinamentos e oficinas regulares, que auxiliam a adaptação do profissional ao adequá-lo à instituição (Dubey et al., 2015). Por conseguinte, são propostas as seguintes hipóteses:

H_{2a}: Pressão normativa possui relação positiva com recursos tangíveis de *big data*.

H_{2b}: Pressão normativa possui relação positiva com habilidades humanas de *big data*.

As pressões miméticas nos recursos tangíveis estão relacionadas aos benefícios e à vantagem competitiva observada em outras empresas (Bag et al., 2021). Nas habilidades humanas, a gestão organizacional e relacionamento com fornecedores se alinham de acordo com as práticas existentes em organizações semelhantes (Dubey et al., 2015, 2016; Liang et al., 2007). Assim, temos estas hipóteses:

H_{3a}: Pressão Mimética possui relação positiva com recursos tangíveis *big data*.

H_{3b}: Pressão Mimética possui relação positiva com habilidades humanas *big data*.

O valor das empresas pode ser ampliado por meio de recursos disruptivos, todavia existe a necessidade de alinhar estratégias para adequar a implementação de *big data*, pois a partir dessas estratégias serão selecionadas a técnica e a velocidade adequada dos algoritmos (Gupta & George, 2016; Loshin, 2013). A integração de recursos compõe a construção da capacidade de ABD proposta por Gupta e George (2016) como a capacidade de desenvolvimento organizacional a partir da implantação, montagem e integração de recursos. Dessa maneira, para que os resultados sejam observados pela organização, é fundamental uma infraestrutura para realizar o processamento e análise de dados com agilidade, obtida a partir dos recursos tangíveis que dão base para um grande volume de dados de variadas fontes (Gunasekaran et al., 2017; Gupta & George, 2016; Srinivasan & Swink, 2018). Isso decorre da junção da tecnologia de *big data* com as habilidades humanas gerar capacidade de ABD, que possibilita análises preditivas, análises descritivas que incluem informações de tendência e análises prescritivas (Duan et al., 2020; Srinivasan & Swink, 2018).

Esses tipos de análises auxiliam na restrição da assimetria informacional, aprimoramento no desempenho da empresa, análise da performance, tomada de decisões, que contribuem no aperfeiçoamento de controle estratégico, qualidade nas informações gerenciais, seleção de novos investimentos, alocação eficiente do orçamento, possibilitando melhoria contínua (Akter et al., 2016; Dubey et al., 2019a; Madeira Pontes et al., 2021; Medeiros et al., 2021; Srinivasan & Swink, 2018). Assim, temos a seguinte hipótese:

H₄: Recursos tangíveis de *big data* possuem relação positiva na capacidade de ABD.

As habilidades humanas de ABD são dicotômicas, sendo gerenciais as habilidades que demandam conhecimento mais aprofundado para realizar o planejamento estratégico e técnicas aquelas habilidades que envolvem extração e limpeza de dados e compreensão de paradigmas de

programação. Essas habilidades abrangem conhecimento, julgamento, experiência adequada, educação correta e treinamentos para o ambiente que usa a ABD. As habilidades são fundamentais para compreender o negócio, clientes, fornecedores e coordenar efetivamente departamentos internos (Gupta & George, 2016). O conhecimento humano norteia em que setor e quais informações geradas serão mais cabíveis, podendo ser aplicadas de maneira estratégica, operacional ou tática (Pauleen & Wang, 2017). A partir desse conhecimento os analistas de dados realizam verificações e ofertam *insights* úteis à organização (Azeem et al., 2022). Portanto, formula-se a seguinte hipótese:

H₅: Habilidades humanas de big data possuem relação positiva na capacidade de ABD.

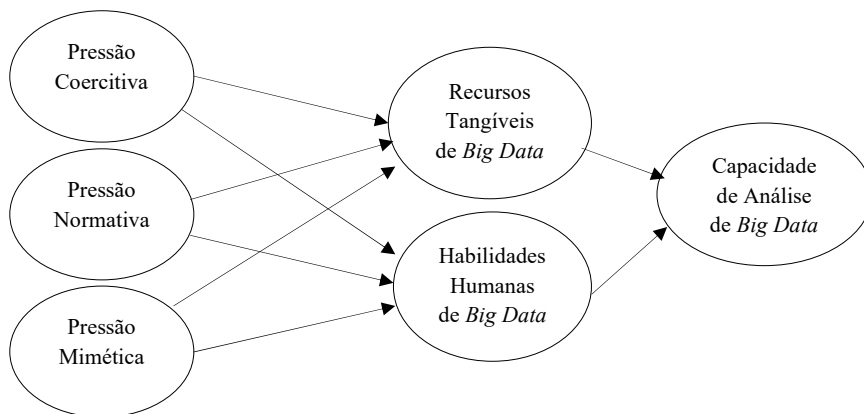


Figura 2 Modelo teórico da pesquisa

Fonte: Elaborada pelos autores.

No modelo não se considera o recurso intangível, identificado por Gupta e George (2016), cultura e aprendizagem organizacional de *big data*, pois a transição para uma cultura organizacional de tomada de decisão orientada por dados é complexa e nem sempre rápida, assim como intensificar a aprendizagem

Assim, para compreender a configuração da capacidade ABD é necessário considerar o contexto institucional, pois as pressões institucionais influenciam as configurações dos recursos internos da organização, fazendo com que os recursos tangíveis e habilidades humanas sejam selecionados de diferentes modos em respostas ao ambiente, proporcionando melhor explicação na decisão do processo de adoção de ABD (Dubey et al., 2019b). A partir das hipóteses enunciadas, a Figura 2 apresenta o modelo teórico, evidenciando a relação entre as pressões institucionais, os recursos organizacionais e a capacidade de ABD. Com o intuito de analisar o comportamento dos recursos tangíveis e habilidades humanas de *big data*, diante das pressões institucionais, no desenvolvimento da capacidade de ABD.

organizacional é um processo gradual. No Brasil, ainda, as principais barreiras enfrentadas pelas organizações que implantaram o *big data* são relacionadas ao estabelecimento de processos inovadores, à cultura da experimentação e às revisões de estrutura organizacional (Félix et al., 2018).

3. MÉTODO E PROCEDIMENTOS DA PESQUISA

3.1 Seleção da Amostra e Coleta dos dados

A população do estudo é composta por empresas brasileiras que usam a tecnologia de *big data*, para analisar grande quantidade de dados (estruturados e não estruturados) para a geração de resultados e *insights* importantes, que auxiliam a tomada de decisão (Gupta & George, 2016). Para acessar a população-alvo e compor a amostra, usuários da plataforma *LinkedIn* foram rastreados por meio dos termos “*big data*”, “*data analytics*” e “*data scientist*”; esses indivíduos são colaboradores de empresas

brasileiras com funções relacionadas ao desenvolvimento da capacidade de ABD. Assim, a amostra é composta por respondentes que exercem funções como: *Data Scientist*, *Manufacturing Excellence*, Analista de Infraestrutura, *Data Analyst*, *Manufacturing IT*, *Market Intelligence Analyst*, Analista de *Business Intelligence*, *Continuous Improvement Manager*, *Business Intelligence*, *Head of Manufacturing Excellence* e Gerente da Qualidade e Controller.

Em seguida, foram enviados 450 convites para conexão via *LinkedIn* com os colaboradores dessas empresas que tinham funções ligadas a gestão e a ABD, sendo

que 204 aceitaram compor a rede. Aos que aceitaram o convite foi enviado o *link* do instrumento de pesquisa via *Google Forms*. Para maior adesão, quando solicitado, o instrumento de pesquisa foi enviado via *e-mail*. O período de coleta de dados foi de 6 de maio a 1º de junho de 2021.

A estimativa da amostra necessária foi realizada por meio do *software G*PowerWin 3.1.9.4* (Faul et al., 2009), seguindo as recomendações de Cohen (1988) e Hair et al. (2014), ao usar o poder do teste 0,80, f^2 mediano = 0,15, a amostra mínima definida para o estudo foi de 77 casos, considerando o construto com o maior número de ligações (Figura 2). Foram obtidas 154 respostas, porém, foram excluídos 17 questionários em que a pergunta que remete ao uso de *big data* não foi respondida de forma positiva. Assim, a amostra não aleatória foi constituída como 136 respostas adequadas. Ademais, os procedimentos éticos foram garantidos por meio do anonimato dos

respondentes, sigilo aos dados obtidos, bem como da análise e divulgação dos resultados.

3.2 Construtos da Pesquisa e Mensuração das Variáveis

A pesquisa possui três construtos principais, sendo as pressões institucionais, que envolvem as pressões coercitiva, normativa e mimética (DiMaggio & Powell, 1983), recursos organizacionais de *big data*, caracterizados pelos recursos tangíveis e habilidades humanas (Gupta & George, 2016) e capacidade de ABD (Srinivasan & Swink 2018). Os construtos foram mensurados por meio de itens múltiplos e o nível concordância dos respondentes a partir de uma escala *Likert*, variando de (1) discordo totalmente e (5) concordo totalmente, como mostra a Figura 3.

Construtos	Definição operacional	Escala	Autores
Pressão Coercitiva	A pressão coercitiva compreende: (i) leis de proteção de dados; (ii) normas e regulamentos; (iii) pressão social.	5 indicadores Escala Likert 5 pontos	Liang et al. (2007) e Dubey et al. (2019b)
Pressão Normativa	A pressão normativa é constituída por: (i) promoção de extensão tecnológica por meio de associações; (ii) fornecedores e clientes da empresa aderem a tecnologia <i>big data</i> .	5 indicadores Escala Likert 5 pontos	Dubey et al. (2019b)
Pressão Mimética	A pressão mimética é observada por meio da adesão dos concorrentes ao <i>big data</i> e os benefícios obtidos e percebidos como favoráveis.	5 indicadores Escala Likert 5 pontos	Liang et al. (2007) e Dubey et al. (2019b)
Recursos Tangíveis de <i>Big Data</i>	Os recursos tangíveis são apontados por meio de uso de: (i) grande volume de dados estruturados ou não; (ii) tecnologias para dar suporte aos dados; (iii) integração de dados internos e externos a empresa.	5 indicadores Escala Likert 5 pontos	Dubey et al. (2019b)
Habilidades Humanas de <i>Big Data</i>	As habilidades humanas são observadas por meio de recrutamento, seleção e treinamento com foco no desenvolvimento de tomada de decisão em dados.	5 indicadores Escala Likert 5 pontos	Dubey et al. (2019b)
Capacidade de Análise de <i>Big Data</i>	A capacidade de ABD foi capturada por meio da facilidade de integração dos recursos tecnológicos (<i>dashboards</i>) e de técnicas analíticas para o desenvolvimento de rotinas baseada em dados.	4 indicadores Escala Likert 5 pontos	Dubey et al. (2019b)

Figura 3 Constructos, definição operacional e escala

Fonte: Elaborada pelos autores.

Para capturar as pressões institucionais, foram usadas 15 assertivas, sendo 5 para cada pressão institucional, coercitiva, normativa e mimética adaptadas de Liang et al. (2007) e Dubey et al. (2019b). Os recursos tangíveis e habilidades humanas de *big data* tiveram, também, 5 assertivas cada, derivadas de Dubey et al. (2019b). Para mensurar a capacidade de ABD foram usadas 4 assertivas com origem no trabalho de Srinivasan e Swink (2018). Como as assertivas se originaram de instrumentos estrangeiros, aplicou-se o processo de tradução e tradução reversa (Pedroso et al., 2004), e subsequentemente se realizou o pré-teste, com profissionais da área e alunos de doutorado, a fim de adequar e validar o questionário à realidade, cultura e legislação brasileira.

Além das 29 assertivas (Apêndice A) que buscam mensurar os construtos da pesquisa, o instrumento de pesquisa usou uma pergunta controle, a fim de selecionar empresas que usam grande volume de dados estruturados e/ou não estruturados.

3.3 Procedimentos para Análise dos Dados

As hipóteses foram testadas usando a técnica de Modelagem de Equações Estruturais por meio do *software Smartpls v. 3.2.3*. Como a coleta de dados recorreu a apenas um método, seguiram-se as recomendações de Podsakoff et al. (2003), para evitar o viés do método comum. Para tanto, primeiro, as assertivas do questionário

foram organizadas de forma aleatória, a fim de evitar possível associação entre os construtos por parte do respondente. Em seguida, o questionário foi encaminhado diretamente aos respondentes. Após a coleta, foi realizado o teste de fator único de Harman, no qual uma quantidade elevada de variância compreendida por um único fator pode indicar viés do método comum (Podsakoff et

al., 2003); realiza-se o teste a partir da análise fatorial exploratória incluindo todas as variáveis, independentes e dependentes, e espera-se que apenas um fator não corresponda mais que 50% da variância. Nesse sentido, observa-se que um único fator representou 24,24% da variância, sugerindo não haver problemas de viés do método comum.

4. ANÁLISE DOS DADOS

4.1 Características da Amostra

Cada resposta recebida equivale a uma empresa pesquisada. Assim, em relação às características empresariais, de acordo com a Tabela 1, as empresas nas

quais os respondentes exercem suas funções, 93,43% possuem mais de 99 colaboradores, evidenciando que a amostra desta pesquisa em sua maioria compreende empresas de grande porte.

Tabela 1

Características da empresa

Porte da empresa	Frequência	%	Setores	Frequência	%
Até 9 empregados	1	0,73	Tecnologia	12	8,76
De 10 a 49 empregados	4	2,92	Automotivo	13	9,49
De 50 a 99 empregados	4	2,92	Cosméticos	13	9,49
Mais de 99 empregados	128	93,43	Mineração	6	4,38
Setores	Frequência	%	Farmacêutica e hospitalar	6	4,38
Alimentício	38	27,74	Construção civil	6	4,38
Agronegócio	19	13,87	Confecção	3	2,19
Outros	18	13,14	Serviços	3	2,19

Fonte: Elaborada pelos autores.

Ao analisar o setor de atuação, identificou-se que houve 3 grandes grupos com maior frequência. O primeiro foi o alimentício, representando 27,74% dos setores, o segundo foi o agronegócio, com 13,87%, e o terceiro, identificado como outros, com 13,14%, composto pelos seguintes setores: aeronáutico, transporte, pesquisa, meio ambiente, qualidade, suprimentos, papel e celulose, bens e consumo, eletrodomésticos e engenharia elétrica.

4.2 Avaliação do Modelo de Mensuração

A avaliação do modelo de mensuração reflexivo inclui avaliar a confiabilidade dos indicadores que compõem o construto, confiabilidade composta, validade convergente (*average variance extracted* – AVE) e validade discriminante. Primeiro, avalia-se a confiabilidade dos indicadores que compõem o instrumento de pesquisa, segundo Hair et al. (2021)

cargas acima de 0,708 indicam que o construto explica mais de 50% da variância do indicador. Em pesquisas sociais, é comum cargas mais fracas, principalmente em instrumentos exploratórios, situação observada nesta pesquisa. Nesse sentido, os autores aconselham avaliar os efeitos da remoção de indicadores, sendo apenas recomendado quando aumenta a confiabilidade composta ou a validade convergente. Desse modo, efetuou-se a exclusão de 8 indicadores, sendo 3 assertivas referente ao construto de pressões coercitiva, 2 assertivas sobre pressões normativas, 2 assertivas sobre o construto de recursos tangíveis e 1 assertiva do construto de habilidades humanas (Tabela 2).

Os itens excluídos não afetaram a validade de conteúdo do construto. Ademais, conforme Tabela 2, todos os construtos, após as exclusões, apresentaram valores acima do indicado para confiabilidade composta (0,70) e AVE (0,50) (Hair et al., 2021).

Tabela 2
Índices de adequação do modelo

	Cargas dos indicadores	Confiabilidade Composta	Validade Convergente (AVE)	Cargas dos indicadores	Confiabilidade Composta	Validade Convergente (AVE)
		Antes	Antes		Depois	Depois
Pressão Coercitiva	q1 = 0,498	0,465	0,289	–	0,869	0,625
	q2 = 0,697			q2 = 0,842		
	q3 = 0,806			q3 = 0,789		
	q4 = 0,008			–		
	q5 = 0,249			–		
Pressão Normativa	q6 = 0,748	0,806	0,457	q6 = 0,801	0,885	0,661
	q7 = 0,647			–		
	q8 = 0,521			–		
	q9 = 0,702			q9 = 0,630		
	q10 = 0,737			q10 = 0,834		
Pressão Mimética	q11 = 0,756	0,94	0,758	q11 = 0,765	0,799	0,666
	q12 = 0,891			q12 = 0,896		
	q13 = 0,920			q13 = 0,919		
	q14 = 0,925			q14 = 0,921		
	q15 = 0,851			q15 = 0,842		
Recursos Tangíveis	q16 = 0,578	0,773	0,405	–	0,94	0,758
	q17 = 0,637			–		
	q18 = 0,628			q18 = 0,677		
	q19 = 0,652			q19 = 0,697		
	q20 = 0,683			q20 = 0,815		
Habilidades Humanas	q21 = 0,595	0,878	0,595	–	0,802	0,578
	q22 = 0,707			q22 = 0,695		
	q23 = 0,894			q23 = 0,898		
	q24 = 0,844			q24 = 0,854		
	q25 = 0,781			q25 = 0,791		
Capacidade de ABD	q26 = 0,798	0,869	0,625	q26 = 0,796	0,775	0,536
	q27 = 0,853			q27 = 0,857		
	q28 = 0,794			q28 = 0,792		
	q29 = 0,711			q29 = 0,710		

AVE = validade convergente (average variance extracted).

Fonte: Elaborada pelos autores.

Pode-se afirmar que, após a adequação do modelo de mensuração, os itens do instrumento de pesquisa não apresentam redundância nem padrões de respostas indesejáveis e, também, que os construtos explicam 53,6% (Capacidade ABD) ou mais da variância dos indicadores que compõem o construto. Em seguida, estima-se a validade discriminante dos construtos para aferir a independência entre eles, isto é, se há distinção

empírica entre os construtos. Foi identificado, como demonstra a Tabela 3 (sombreado), que há validade discriminante. Como análise discriminante adicional, avalia-se o *heterotrait–monotrait ratio* (HTMT) 0.85. Henseler et al. (2015) propõem o valor limite de 0,85 para modelos estruturais com construtos conceitualmente mais distintos, confirmando a distinção empírica entre os construtos.

Tabela 3*Validade discriminante*

	C. ABD	H. Hum.	P. Coerc.	P. Mím.	P. Norm.	R. Tang.
C. ABD	0,791*					
H. Hum.	0,602	0,719**	0,813*			
P. Coerc.	0,086	0,233	0,046	0,135**	0,816*	
P. Mím.	0,338	0,390	0,317	0,352	0,212	0,313**
P. Norm.	0,276	0,393	0,375	0,497	0,378	0,669
R. Tang.	0,377	0,574	0,279	0,415	0,407	0,766

* Critério de Fornell-Larcker; ** Heterotrait–monotrait ratio (HTMT).

Fonte: Elaborada pelos autores.

Destarte, pode-se afirmar que o modelo de mensuração permite estimar de forma satisfatória as relações entre pressões institucionais (coercitiva, mimética e normativa), recursos organizacionais (tangíveis e habilidades humanas) e a capacidade de ABD.

4.3 Avaliação do Modelo Estrutural e Teste das Hipóteses

O próximo passo é avaliar o modelo estrutural, para tanto se avaliam os Coeficientes de Determinação de Pearson (R^2), *Variance Inflation Factor* (VIF) e Relevância Preditiva (Q^2). Os valores de R^2 indicam a qualidade do modelo, apontando o percentual de variância de uma variável endógena explicada pelo modelo estrutural (Ringle et al., 2014). Para Cohen (1988) os efeitos nas

ciências sociais podem ser classificados assim: $R^2 = 2\%$ como efeito pequeno; $R^2 = 13\%$ como efeito médio; e $R^2 = 26\%$ como efeito grande.

Observa-se na Tabela 4 que os menores R^2 entre os construtos foram de 17,1% para “Habilidades humanas”, resultados considerados medianos para a literatura. Por outro lado, os R^2 de “Recursos tangíveis” (26,6%) e “Capacidade de ABD” (41%) são considerados como efeitos grandes. Para Chin (1998), quando os valores para relevância preditiva (Q^2) são maiores que zero nas variáveis latentes endógenas há relevância preditiva, dessa forma, observa-se que o modelo estrutural não possui nenhum valor abaixo de zero, conferindo a relevância preditiva. A métrica padrão para avaliar a colinearidade é o fator de inflação de variância (VIF), quando os valores de VIF de 5 ou maiores indicam problemas de colinearidade (Hair et al., 2021).

Tabela 4*Ajustes do modelo estrutural*

	R^2	Q^2	VIF		
			Capacidade de ABD	Habilidades Humanas	Recursos Tangíveis
Capacidade de ABD	0,410	0,242			
Habilidades Humanas	0,171	0,101	1,085		
Recursos Tangíveis	0,266	0,112	1,085		
Pressão Coercitiva				1,167	1,167
Pressão Mimética				1,395	1,395
Pressão Normativa				1,555	1,555

Fonte: Elaborada pelos autores.

Em seguida, as hipóteses foram testadas para cada diagrama de caminho do modelo estrutural (Tabela 5).

Tabela 5*Teste das Hipóteses – Efeitos diretos e indiretos*

Relações estruturais	Diretos	Indiretos	Teste t	Valor p
Pressão Coercitiva -> Recursos Tangíveis	0,308		3,723	0,000***
Pressão Coercitiva -> Habilidades Humanas	-0,114		0,826	0,409
Pressão Normativa -> Recursos Tangíveis	0,117		1,081	0,280
Pressão Normativa -> Habilidades Humanas	0,331		3,126	0,002**
Pressão Mimética -> Recursos Tangíveis	0,255		2,855	0,004**
Pressão Mimética -> Habilidades Humanas	0,165		1,531	0,126
Habilidades Humanas -> Capacidade de ABD	0,539		6,882	0,000***
Recursos Tangíveis -> Capacidade de ABD	0,227		2,751	0,006**
Pressão Coercitiva -> Capacidade de ABD		0,009	0,098	0,922
Pressão Normativa -> Capacidade de ABD		0,205	3,315	0,001***
Pressão Mimética -> Capacidade de ABD		0,147	2,192	0,028**

 $P < 0,001$ *** $P < 0,05$ **.**Fonte:** Elaborada pelos autores.

Os resultados da Tabela 5 mostram que as habilidades humanas são impactadas pela pressão normativa (0,331, $p < 0,001$), enquanto os recursos tangíveis sofrem pressões coercitivas (0,308, $p < 0,001$) e miméticas (0,255, $p < 0,005$). Em relação ao desenvolvimento da capacidade de ABD, os

resultados apontam que tanto Recursos Tangíveis (0,227, $p < 0,005$) quanto Habilidades Humanas (0,539, $p < 0,000$) estão correlacionadas, sendo que a Pressão Mimética possui um papel indireto nessa correlação (0,147, $p < 0,005$), bem como a Pressão Normativa (0,205, $p < 0,001$).

Tabela 6*Teste das Hipóteses – Efeito indireto específico*

Relações estruturais	Específico	Teste t	Valor p
P. Coercitiva->Recursos Tangíveis->Capacidade de ABD	0,070	2,095	0,036**
P. Coercitiva->Habilidades Humanas->Capacidade de ABD	-0,061	0,802	0,423
P. Normativa->Recursos Tangíveis->Capacidade de ABD	0,026	1,014	0,311
P. Normativa->Habilidades Humanas->Capacidade de ABD	0,178	3,279	0,001***
P. Mimética->Recursos Tangíveis->Capacidade de ABD	0,058	1,770	0,077
P. Mimética->Habilidades Humanas->Capacidade de ABD	0,089	1,371	0,170

 $P < 0,001$ *** $P < 0,05$ **.**Fonte:** Elaborada pelos autores.

Na Tabela 6 se apresenta o efeito indireto específico das hipóteses H_{11} , H_2 , H_3 , H_4 e H_5 . Os resultados mostram que os recursos tangíveis medeiam a pressão coercitiva e a capacidade de ABD (0,070, $p < 0,005$), observa-se também a mediação das habilidades humanas com a pressão normativa e capacidade de ABD (0,178, $p < 0,001$).

4.4 Análise e Discussão das hipóteses

A primeira hipótese (H_{1a}) procurou verificar se a pressão coercitiva possui correlação positiva com recursos tangíveis de *big data*. Os resultados foram significativos em $p < 0,001$, estando a pressão coercitiva associada aos recursos tangíveis de *big data*, como forças de legislações e condições competitivas. Esse achado corrobora os resultados de Dubey et al. (2019b) e Bag et al. (2021), que demonstraram que recursos tangíveis

são influenciados por normas de regularização de dados, políticas nacionais e financiamento para investimento em tecnologias. No contexto brasileiro, Silva (2019) aponta que o SNI, MCTIC e o MDIC atuam como influenciadores tecnológicos, impulsionando a estratégia digital brasileira.

A H_{1b} busca analisar se a pressão coercitiva possui relação positiva com as habilidades humanas de *big data*, os resultados não foram significativos. Logo, essa relação não é observada na amostra, sendo necessário investigar sob diferentes perspectivas, pois outros resultados apresentam relações significativas em contextos regulatórios diferentes, como é o caso de Bag et al. (2021) na África do Sul. Neste caso, o governo sul-africano solicita a atualização em programação e análise dos dados, das empresas, para que haja qualificação dos recursos humanos e consequente crescimento econômico.

A H_{2a} busca verificar se a pressão normativa possui correlação positiva com recursos tangíveis de *big data*, observa-se que não foram significativos, isto é, na perspectiva adotada neste estudo, não é possível afirmar que há legitimação de recursos tangíveis específicos por especialistas e/ou da educação formal, ou recomendação por parte de redes profissionais que contribuam na adesão de recursos como *Hadoop*, computação em nuvem ou *dashboards*. Esse resultado pode estar alicerçado na recente inserção tecnológica de *big data* no Brasil, assim é possível que não haja consenso de quais tecnologias sejam desejadas, o que possibilitaria uma recomendação de quais recursos tangíveis de *big data* fossem adotados.

Já a H_{2b} , que buscou analisar a relação entre as habilidades humanas de *big data* e a pressão normativa, apresentou consequência significativa para $p < 0,05$, depreende-se desse resultado, que as empresas priorizam funcionários com *insights* tecnológicos e usam política de recursos humanos com a finalidade de captar habilidades humanas. Em outros termos, os membros de uma organização definem condutas organizacionais por meio de treinamentos e regulamentos internos para orientar seus profissionais resultando na legitimação consonante com as expectativas de clientes, fornecedores e demais *stakeholders* (Liang et al., 2007; Dubey et al., 2015). No contexto brasileiro, a pressão para a atualização das habilidades humanas é interna (Félix et al., 2018) e, considerando o entendimento de ecossistema (Francisco et al., 2020), altera-se o ambiente externo por meio das redes profissionais.

A H_{3a} apontou uma associação positiva entre pressões miméticas e os recursos tangíveis de *big data*, sendo considerada significativa em $p < 0,05$. Portanto, pode-se afirmar que as empresas brasileiras são encorajadas a selecionar recursos tecnológicos já aceitos por empresas do campo organizacional, por seus concorrentes. Isto é, os recursos tecnológicos são aderidos por uma empresa quando benefícios são observados em outras organizações, principalmente em ambientes com grandes incertezas ambientais (Bag et al., 2021; Dubey et al., 2015; Liang et al., 2007). Todavia, não houve significância na hipótese H_{3b} , o que leva à não afirmação de que as empresas observam e internalizam os requisitos de outras organizações em relação as necessidades de habilidades técnicas e gerenciais de seus colaboradores.

Na quarta hipótese (H_4) se observa a relação positiva significativa entre recursos tangíveis de *big data* e a capacidade de ABD ($p < 0,05$), denota-se que empresas usam serviços de nuvem e sistemas que dão suporte ao processamento de dados, como *Hadoop*, além de usar diferentes ferramentas para visualização de dados e computação em nuvem. Quando esses recursos são aplicados a ferramentas complementares auxiliam a

visualização e processamento de dados, auxiliam na geração da capacidade de ABD, que agrega valor à organização (Gunasekaran et al., 2017; Gupta & George, 2016).

Na hipótese cinco (H_5) se analisaram as habilidades humanas de *big data* e sua relação positiva com ABD, nota-se significância para $p < 0,001$, isto é, as empresas buscam profissionais com habilidades técnicas, de modo a recrutar novos funcionários com experiência em *big data* e análises preditivas, bem como a desenvolver habilidades certas nas equipes de ABD para que o trabalho tenha sucesso. Além disso, também empregam habilidade gerenciais por meio de gestores que têm uma visão estratégica de negócios para que consigam integrar de modo efetivo todos os departamentos e partes relacionados à empresa. Corroborando Bag et al. (2021), Dubey et al. (2019) e Gupta e George (2016), que relataram a essencialidade de treinamentos para o desenvolvimento de habilidades de ABD, pois a partir de conhecimentos, julgamentos e experiências essas habilidades servem para identificar estratégias adequadas e *insights* úteis para a coordenação efetiva da empresa (Azeem et al., 2022; Gupta & George, 2016; Pauleen & Wang, 2017).

Com base na TBR, se observa que a empresas participantes deste estudo obtêm a capacidade de ABD investindo com maior intensidade nas habilidades humanas de *big data*, já em relação aos recursos tangíveis se observa menor intensidade. Mesmo que os recursos tangíveis de *big data* são base para o processamento de dados, o investimento em profissionais com habilidades técnicas e gerenciais são fundamentais, sendo ambos necessárias para gerar a capacidade de ABD, como apontado por Gupta e George (2016). Analisando, ainda, o efeito indireto nas relações entre as pressões institucionais e a capacidades de ABD, pode-se aferir que as pressões normativas e miméticas possuem relação positiva com a capacidade de ABD, com $p < 0,05$. Assim, é demonstrado que as redes profissionais e empresas consideradas como referência exercem influência no desenvolvimento da capacidade de ABD com vistas a reduzir incertezas ambientais.

Quando se analisam os efeitos indiretos específicos observa-se que os recursos tangíveis medeiam a pressão coercitiva e a capacidade de ABD ($p < 0,05$), caracterizando que o desenvolvimento da capacidade de ABD é influenciado pela pressão das agências governamentais na adoção recursos tangíveis de *big data*, a fim de impulsionar a estratégia digital brasileira. Observa-se, também, que a habilidade humana medeia a relação entre com a pressão normativa e capacidade de ABD, assim, as redes profissionais influenciam as habilidades humanas requeridas para o desenvolvimento da capacidade de ABD.

5. CONSIDERAÇÕES FINAIS

O objetivo desta pesquisa foi analisar a configuração dos recursos tangíveis e habilidades humanas de *big data*, diante das pressões institucionais, na capacidade de ABD em empresas brasileiras. Para tanto, um *survey* foi aplicado a empresas brasileiras de diversos setores que usam a tecnologia *big data*, a amostra foi constituída de 136 respondentes. Para analisar os dados foi usada a Modelagem de Equações Estruturais (SEM).

Os resultados sugerem que as empresas da amostra adotam os recursos tangíveis de *big data* como respostas às pressões coercitivas e miméticas. Do ponto de vista prático, isso quer dizer que essas empresas são influenciadas por fatores impostos pela competição de mercado, pela influência do SNI, MCTIC e o MDIC que impulsionam a estratégia digital brasileira, conforme já apontado por Silva (2019), e ainda, por observarem que outras empresas que aderiram a tecnologia *big data* obtiveram sucesso. Além disso, as habilidades humanas de *big data* são selecionadas em resposta a pressão normativa, sendo questões de profissionalização e especialização voltadas para constituir a capacidade de ABD.

Em relação aos recursos e a capacidade de ABD, fundamentado na TBR, observa-se a combinação dos recursos tangíveis com as habilidades humanas contribuem para a capacidade de ABD, porém as habilidades humanas têm maior significância diante dos recursos tangíveis. Assim, é possível verificar a importância do conhecimento técnico e gerencial de análise de dados, demonstrando que a capacidade organizacional é obtida pela combinação dos recursos organizacionais, como apontado por Grant (1991) e Makadok (2001). Quanto às relações entre as pressões institucionais e capacidade de ABD, nota-se que existe significância entre as pressões mimética e normativa. Dessa maneira, as empresas que seguiram os modelos de adoção da tecnologia *big data*, bem como aquelas que aderiram às redes profissionais, desenvolveram uma equipe capaz de trabalhar com os dados de forma eficiente.

Além da existência da relação indireta, a relação entre a pressão normativa e a capacidade de ABD é mediada pelas habilidades humanas, identificando

que empresas brasileiras configuram a capacidade de ABD com habilidades técnicas e gerenciais, estando as necessidades de habilidades influenciadas pela percepção de especialistas e profissionais que compõem a rede profissional dos tomadores de decisão. Também, observa-se que as empresas adotam os recursos tangíveis para o desenvolvimento da capacidade de ABD devido a pressões de agências governamentais, bem como por condições de competitividade.

A introdução de tecnologias de análise de dados e previsão automatizada já se faz presente, à vista disso, identificar e aplicar adequadamente técnicas e direcionadores apropriados e a combinação certa entre o julgamento humano e perspicácia nos negócios com o uso extensivo de dados e tecnologia é fundamental. Além disso, novas rotinas de informações podem levar a um ambiente de tomada de decisão e relatórios mais descentralizados e baseados em autoatendimento que pode alterar a natureza do controle, bem como o papel dos *controllers* (Möller et al., 2020). Nas organizações, a capacidade de ABD permite novas formas de cooperação intraorganizacional por meio de recursos e habilidades que podem ser moldados pelas pressões do ambiente. Ademais, a capacidade de ABD atrelada a pressões institucionais pode influenciar de forma recursiva a relação entre empresas, fornecedores, clientes e funcionários, levando a novas configurações de produtos, serviços e dinâmicas organizacionais.

A amostra por acessibilidade é a principal limitação desse artigo, nesse sentido, futuros estudos poderiam debruçar-se sobre setores específicos, para poder concluir sobre potenciais diferenças entre os diversos setores empresariais. Além disso, devido às preocupações ambientais e de segurança da informação, recomenda-se estudos voltados ao desenvolvimento sustentável e governança da tecnologia da informação. Sugere-se, também, avaliar como as tecnologias digitais influenciam os papéis que os CFOs e *controllers* desenvolvem nas organizações. E recomenda-se, ainda, buscar um maior entendimento do impacto das tecnologias da Indústria 4.0, de forma geral, no sistema de controle gerencial.

REFERÊNCIAS

- Adjei, J. K., Adams, S., & Mamattah, L. (2021). Cloud computing adoption in Ghana; Accounting for institutional factors. *Technology in Society*, 65, 101583. <https://doi.org/10.1016/j.techsoc.2021.101583>
- Akter, S., Wamba, S. F., Gunasekaran, A., Dubey, R., & Childe, S. J. (2016). How to improve firm performance using big data analytics capability and business strategy alignment? *International Journal of Production Economics*, 182, 113-131. <https://doi.org/10.1016/j.ijpe.2016.08.018>
- Arunachalam, D., Kumar, N., & Kawalek, J. P. (2018). Understanding *big data* analytics capabilities in supply chain management: Unravelling the issues, challenges and implications for practice. *Transportation Research Part E: Logistics and Transportation Review*, 114, 416-436. <https://doi.org/10.1016/j.tre.2017.04.001>
- Azeem, M., Haleem, A., Bahl, S., Javaid, M., Suman, R., & Nandan, D. (2022). Big data applications to take up major challenges across manufacturing industries: A brief review. *Materials Today: Proceedings*, 49, 339-348. <https://doi.org/10.1016/j.matpr.2021.02.147>
- Bag, S., Pretorius, J. H. C., Gupta, S., & Dwivedi, Y. K. (2021). Role of institutional pressures and resources in the adoption of big data analytics powered artificial intelligence, sustainable manufacturing practices and circular economy capabilities. *Technological Forecasting and Social Change*, 163, 120420. <https://doi.org/10.1016/j.techfore.2020.120420>
- Barney, J. B. (1991). Firm resources and sustained competitive advantage. *Journal of Management*, 17(1), 99-120. <https://doi.org/10.1177/014920639101700108>
- Barney, J. B. (2001). Is the resource-based “view” a useful perspective for strategic management research? Yes. *Academy of Management Review*, 26(1), 41-56. <https://doi.org/10.5465/amr.2001.4011938>
- Barney, J. B., Ketchen, D. J., Jr., & Wright, M. (2011). The future of resource-based theory: Revitalization or decline? *Journal of Management*, 37(5), 1299-1315. <https://doi.org/10.1177/0149206310391805>
- Bergmann, M., Brück, C., Knauer, T., & Schwering, A. (2020). Digitization of the budgeting process: determinants of the use of business analytics and its effect on satisfaction with the budgeting process. *Journal of Management Control*, 31(1-2), 25-54.
- Brinch, M., Stentoft, J., Jensen, J. K., & Rajkumar, C. (2018). Practitioners understanding of big data and its applications in supply chain management. *The International Journal of Logistics Management*, 29(2), 555-574. <https://doi.org/10.1108/IJLM-05-2017-0115>
- Cabrera-Sánchez, J. P., & Villarejo-Ramos, Á. F. (2019). Fatores que afetam a adoção de análises de big data em empresas. *Revista de Administração de Empresas*, 59(6), 415-429. <https://doi.org/10.1590/S0034-759020190607>
- Chahal, H., Gupta, M., Bhan, N., & Cheng, T. C. E. (2020). Operations management research grounded in the resource-based view: A meta-analysis. *International Journal of Production Economics*, 230, 107805. <https://doi.org/10.1016/j.ijpe.2020.107805>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences*. Routledge.
- Cruz, A. M., & Haugan, G. L. (2019). Determinants of maintenance performance: A resource-based view and agency theory approach. *Journal of Engineering and Technology Management*, 51, 33-47. <https://doi.org/10.1016/j.jengtecman.2019.03.001>
- DiMaggio, P. J., & Powell, W. W. (1983). The iron cage revisited: Institutional isomorphism and collective rationality in organizational fields. *American Sociological Review*, 147-160. <https://doi.org/10.2307/2095101>
- Duan, Y., Cao, G., & Edwards, J. S. (2020). Understanding the impact of business analytics on innovation. *European Journal of Operational Research*, 281(3), 673-686. <https://doi.org/10.1016/j.ejor.2018.06.021>
- Dubey, R., Gunasekaran, A., & Ali, S. S. (2015). Exploring the relationship between leadership, operational practices, institutional pressures and environmental performance: A framework for green supply chain. *International Journal of Production Economics*, 160, 120-132. <https://doi.org/10.1016/j.ijpe.2014.10.001>
- Dubey, R., Gunasekaran, A., Childe, S. J., Blome, C., & Papadopoulos, T. (2019b). *Big data* and predictive analytics and manufacturing performance: Integrating institutional theory, resource-based view and big data culture. *British Journal of Management*, 30(2), 341-361. <http://dx.doi.org/10.1111/1467-8551.12355>
- Dubey, R., Gunasekaran, A., Childe, S. J., Papadopoulos, T., Luo, Z., Wamba, S. F., & Roubaud, D. (2019a). Can big data and predictive analytics improve social and environmental sustainability? *Technological Forecasting and Social Change*, 144, 534-545. <https://doi.org/10.1016/j.techfore.2017.06.020>
- Dubey, R., Gunasekaran, A., Childe, S. J., Wamba, S. F., & Papadopoulos, T. (2016). The impact of big data on world-class sustainable manufacturing. *The International Journal of Advanced Manufacturing Technology*, 84(1-4), 631-645. <https://doi.org/10.1007/s00170-015-7674-1>
- Falsarella, O. M., & Jannuzzi, C. S. C. (2020). Inteligência organizacional e competitiva e big data: Uma visão sistêmica para a gestão sustentável das organizações. *Perspectivas em Ciência da Informação*, 25, 179-204. <http://dx.doi.org/10.1590/1981-5344/3497>
- 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. <http://doi:10.3758/brm.41.4.1149>
- Félix, B. M., Tavares, E., & Cavalcante, N. W. F. (2018). Critical success factors for big data adoption in the virtual retail: Magazine Luiza case study. *Revista Brasileira de Gestão de Negócios*, 20(1), 112-126. <https://doi.org/10.7819/rbgn.v20i1.3627>

- Fogaça, D., Grijalvo, M., & Sacomano, M., Neto (2022). An institutional perspective in the industry 4.0 scenario: A systematic literature review. *Journal of Industrial Engineering and Management*, 15(2), 309-322. <http://dx.doi.org/10.3926/jiem.3724>
- Fonseca, V. D. (2003). A abordagem institucional nos estudos organizacionais: Bases conceituais e desenvolvimentos contemporâneos. In M. M. F. Vieira, & C. A. Carvalho (Eds.), *Organizações, instituições e poder no Brasil* (pp. 47-66). Ed. FGV.
- Francisco, E. D. R., Kugler, J. L., Kang, S. M., Silva, R., & Whigham, P. A. (2020). Além da tecnologia: Desafios gerenciais na era do Big Data. *Revista de Administração de Empresas*, 59, 375-378. <https://doi.org/10.1590/S0034-759020190603>
- Galas, E. S., & Ponte, V. M. R. (2006). O *Balanced Scorecard* e o alinhamento estratégico da tecnologia da informação: Um estudo de casos múltiplos. *Revista Contabilidade & Finanças*, 17(40), 37-51. <https://doi.org/10.1590/S1519-70772006000100004>
- Gerrikagoitia, J. K., Unamuno, G., Urkia, E., & Serna, A. (2019). Digital manufacturing platforms in the industry 4.0 from private and public perspectives. *Applied Sciences*, 9(14), 29-34. <https://doi.org/10.3390/app9142934>
- Grant, R. M. (1991). The resource-based theory of competitive advantage: Implications for strategy formulation. *California Management Review*, 33(3), 114-135. <https://doi.org/10.2307/41166664>
- Guarido, E. R., Filho, & Costa, M. C. (2012). Contabilidade e institucionalismo organizacional: Fundamentos e implicações. *Revista Contabilidade e Controladoria*, 4(1), 20-41. <http://dx.doi.org/10.5380/rcc.v4i1.26685>
- Gunasekaran, A., Papadopoulos, T., Dubey, R., Wamba, S. F., Childe, S. J., Hazen, B., & Akter, S. (2017). Big data and predictive analytics for supply chain and organizational performance. *Journal of Business Research*, 70, 308-317. <https://doi.org/10.1016/j.jbusres.2016.08.004>
- Gupta, M., & George, J. F. (2016). Toward the development of a big data analytics capability. *Information & Management*, 53(8), 1049-1064. <https://doi.org/10.1016/j.im.2016.07.004>
- Hair, J. F., Jr., Sarstedt, M., Hopkins, L., & Kuppelwieser, V. G. (2014). Partial least squares structural equation modeling (PLS-SEM): An emerging tool in business research. *European Business Review*, 6(2), 106-121. <https://doi.org/10.1108/EBR-10-2013-0128>
- Hair, J. F., Jr., Hult, G. T. M., Ringle, C. M., Sarstedt, M., Danks, N. P., & Ray, S. (2021). *Partial least squares structural equation modeling (PLS-SEM) using R: A workbook*. Springer Nature.
- Hannan, M. T., & Freeman, J. (1977). The population ecology of organizations. *American Journal Of Sociology*, 82(5), 929-964. <http://www.jstor.org/stable/2777807>
- Helfat, C. E., & Peteraf, M. A. (2003). The dynamic resource-based view: Capability lifecycles. *Strategic Management Journal*, 24(10), 997-1010. <https://doi.org/10.1002/smj.332>
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43, 115-135.
- Irwin, A., Vedel, J. B., & Vikkelsø, S. (2021). Isomorphic difference: Familiarity and distinctiveness in national research and innovation policies. *Research Policy*, 50(4), 104220. <https://doi.org/10.1016/j.respol.2021.104220>
- Liang, H., Saraf, N., Hu, Q., & Xue, Y. (2007). Assimilation of enterprise systems: The effect of institutional pressures and the mediating role of top management. *MIS Quarterly*, 31(1), 59-87. <https://doi.org/10.2307/25148781>
- Loshin, D. (2013). *Big data analytics: from strategic planning to enterprise integration with tools, techniques, NoSQL, and graph*. Elsevier.
- Madeira Pontes, M. D., Duarte Pontes, T. L., & Dutra de Andrade, R. (2021). A adoção de sistemas de Business Intelligence & Analytics na contabilidade de gestão por entidades da Administração Pública: Uma revisão da literatura. *Revista Facultad de Ciencias Económicas: Investigación y Reflexión*, 29(1), 95-114. <https://doi.org/10.18359/rfce.5273>
- Makadok, R. (2001). Toward a synthesis of the resource-based and dynamic-capability views of rent creation. *Strategic Management Journal*, 22(5), 387-401. <http://dx.doi.org/10.1002/smj.158>
- Medeiros, M. M., Maçada, A. C., & Hoppen, N. (2021). O papel da administração e análise de big data como habilitadoras da gestão do desempenho corporativo. *Revista de Administração Mackenzie*, 22(6), eRAMD210063. <https://doi.org/10.1590/1678-6971/eramd210063>
- Meyer, J. W., & Rowan, B. (1977). Institutionalized organizations: Formal structure as myth and ceremony. *American Journal of Sociology*, 83(2), 340-363. <https://doi.org/10.1086/226550>
- Mikaléf, P., Boura, M., Lekakos, G., & Krogstie, J. (2019). Big data analytics and firm performance: Findings from a mixed-method approach. *Journal of Business Research*, 98, 261-276. <https://doi.org/10.1016/j.jbusres.2019.01.044>
- Mikaléf, P., Pappas, I. O., Krogstie, J., & Giannakos, M. (2018). Big data analytics capabilities: A systematic literature review and research agenda. *Information Systems and e-Business Management*, 16(3), 547-578. <https://doi.org/10.1007/s10257-017-0362-y>
- Möller, K., Schäffer, U., & Verbeeten, F. (2020). Digitalization in management accounting and control: an editorial. *Journal of Management Control: Zeitschrift für Planung und Unternehmenssteuerung*, 31(1), 1-8. <https://doi.org/10.1007/s00187-020-00300-5>
- Oliver, C. (1991). Strategic responses to institutional processes. *Academy of Management Review*, 16(1), 145-179. <https://doi.org/10.2307/258610>
- Oliver, C. (1997). Sustainable competitive advantage: Combining institutional and resource-based views. *Strategic Management Journal*, 18(9), 697-713. <https://www.jstor.org/stable/3088134>
- Pauleen, D. J., & Wang, W. Y. (2017). Does big data mean big knowledge? KM perspectives on big data and

- analytics. *Journal of Knowledge Management*, 21(1), 1-6. <http://dx.doi.org/10.1108/JKM-08-2016-0339>
- Pedroso, R. S., Oliveira, M. D. S., Araujo, R. B., & Moraes, J. F. D. (2004). Tradução, equivalência semântica e adaptação cultural do Marijuana Expectancy Questionnaire (MEQ). *Psico-usf*, 9, 129-136.
- Podsakoff, P. M., MacKenzie, S. B., Lee, J. Y., & Podsakoff, N. P. (2003). Common method biases in behavioral research: a critical review of the literature and recommended remedies. *Journal of Applied Psychology*, 88(5), 879.
- Queiroz, M. M., & Pereira, S. C. F. (2019). Intention to adopt big data in supply chain management: A Brazilian perspective. *Revista de Administração de Empresas*, 59, 389-401. <https://doi.org/10.1590/S0034-759020190605>
- Reginato, L., & Nascimento, A. M. (2007). Um estudo de caso envolvendo Business Intelligence como instrumento de apoio à controladoria. *Revista Contabilidade & Finanças*, 18(Spec), 69-83. <https://doi.org/10.1590/S1519-70772007000300007>
- Ringle, C. M., Silva, D., & Bido, D. S. (2014). Modelagem de equações estruturais com utilização do SmartPLS. *Revista Brasileira de Marketing*, 13(2), 56-73. <https://doi.org/10.5585/remark.v13i2.2717>
- Sakurai, R., & Zuchi, J. D. (2018). As revoluções industriais até a Indústria 4.0. *Revista Interface Tecnológica*, 15(2), 480-491. <https://doi.org/10.31510/infa.v15i2.386>
- Schäfer, U., & Brueckner, L. (2019). Rollenspezifische Kompetenzprofile für das Controlling der Zukunft. *Controlling & Management Review*, 63(7), 14-30. <https://doi.org/10.1007/s12176-019-0046-1>
- Schäfer, U., & Weber, J. (2018, 26 März). Der Controller verliert die Kontrolle. *Frankfurter Allgemeine Zeitung*.
- Schoenherr, T., & Speier-Pero, C. (2015). Data science, predictive analytics, and big data in supply chain management: Current state and future potential. *Journal of Business Logistics*, 36(1), 120-132. <https://doi.org/10.1111/jbl.12082>
- Scott, W. R. (1994). Institutions and organizations: Toward a theoretical synthesis. In W. R. Scott, & J. W. Meyer (Orgs.), *Institutional environments and organizations: structural complexity and individualism* (pp. 55-78). SAGE.
- Scott, W. R. (2008). *Institutions and organizations: Ideas and interests*. SAGE.
- Silva, E. (2019). Análise de políticas públicas brasileiras em ciência, tecnologia e inovação com foco na cultura de inovação e atuação integrada de agentes do sistema de inovação. *RDBCI: Revista Digital de Biblioteconomia e Ciência da Informação*, 17, e019019. <https://doi.org/10.20396/rdbci.v17i0.8654693>
- Srinivasan, R., & Swink, M. (2018). An investigation of visibility and flexibility as complements to supply chain analytics: An organizational information processing theory perspective. *Production and Operations Management*, 27(10), 1849-1867. <https://doi.org/10.1111/poms.12746>
- 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. <https://doi.org/10.1016/j.ejor.2017.02.023>
- Vitale, G., Cupertino, S., & Riccaboni, A. (2020). Big data and management control systems change: The case of an agricultural SME. *Journal of Management Control*, 31, 123-152.
- Williams, C., & Spielmann, N. (2019). Institutional pressures and international market orientation in SMEs: Insights from the French wine industry. *International Business Review*, 28(5). <https://doi.org/10.1016/j.ibusrev.2019.05.002>
- Yu, W., Chavez, R., Jacobs, M. A., & Feng, M. (2018). Data-driven supply chain capabilities and performance: A resource-based view. *Transportation Research Part E: Logistics and Transportation Review*, 114, 371-385. <https://doi.org/10.1016/j.tre.2017.04.002>
- Zhang, Y., Ren, S., Liu, Y., & Si, S. (2017). A big data analytics architecture for cleaner manufacturing and maintenance processes of complex products. *Journal of Cleaner Production*, 142, 626-641. <https://doi.org/10.1016/j.jclepro.2016.07.123>

FINANCIAMENTO

Os autores agradecem à Coordenação de Aperfeiçoamento Pessoal de Nível Superior (Capes) pelo apoio financeiro na realização desta pesquisa.

APÊNDICE A

Instrumento de Pesquisa

Construto	Questão	Questões	Derivações
Pressão Coercitiva (PC)	Q1	A Lei Geral de Proteção de Dados (LGPD) exige que nossa empresa use os dados com segurança.	Adaptado de Liang et al. (2007) e de Dubey et al. (2019b)
	Q2	Nossa empresa utiliza grande quantidade de dados devido às exigências por condições competitivas.	
	Q3	Nossa empresa utiliza ferramentas tecnológicas para mineração de dados devido às exigências por condições competitivas.	
	Q4	Nossa empresa utiliza dados e ferramentas tecnológicas a fim de atender as exigências das ISOs.	
	Q5	Nossa empresa utiliza dados e ferramentas tecnológicas por pressões de agências governamentais.	
Pressão Normativa (PN)	Q6	Nossa empresa prioriza funcionários com insight tecnológicos a fim de atender condições competitivas.	Adaptado de Liang et al. (2007) e de Dubey et al. (2019b)
	Q7	Nossos fornecedores utilizam <i>big data</i> e análises preditivas para a tomada de decisões.	
	Q8	Nossos clientes utilizam <i>big data</i> e análises preditivas para a tomada de decisões.	
	Q9	A extensão da promoção de <i>big data</i> e análise preditiva das associações do setor influenciam nossa empresa a usar <i>big data</i> e análises preditivas para a tomada de decisões.	
Pressão Mimética (PM)	Q10	Nossa empresa utiliza uma política de recursos humanos a fim de captar e manter especialistas em gestão de dados.	Adaptado de Liang et al. (2007) e de Dubey et al. (2019b)
	Q11	Nossos concorrentes que adotaram <i>big data</i> e análises preditivas se beneficiaram muito.	
	Q12	Nossos concorrentes que adotaram <i>big data</i> e análises preditivas são favoravelmente percebidos pelos outros do mesmo setor.	
	Q13	Nossos concorrentes que adotaram <i>big data</i> e análises preditivas são favoravelmente percebidos por seus fornecedores.	
	Q14	Nossos concorrentes que adotaram <i>big data</i> e análises preditivas são favoravelmente percebidos por seus clientes.	
Recursos Tangíveis de Big Data (RT)	Q15	Nossos concorrentes que adotaram <i>big data</i> e análises preditivas possuem modelos de capacitação de pessoal que proporcionam resultados positivos.	Dubey et al. (2019b)
	Q16	Nossa empresa faz a integração de dados de várias fontes em um único sistema.	
	Q17	Nossa empresa integra dados externos com internos para facilitar a análise do nosso ambiente de negócios.	
	Q18	Nossa empresa utiliza abordagens de computação paralela (por exemplo, Hadoop) para processamento de dados.	
	Q19	Nossa empresa utiliza diferentes ferramentas de visualização de dados.	
Habilidades Humanas de Big Data (HH)	Q20	Nossa empresa explora serviços baseados em nuvem para processamento de dados.	Dubey et al. (2019b)
	Q21	Nossa empresa fornece treinamento relacionado a <i>big data</i> para nossos colaboradores.	
	Q22	Nossa empresa recruta novos funcionários que tenham experiência em <i>big data</i> e análises preditivas.	
	Q23	Nossa equipe de análise de <i>big data</i> possui as habilidades certas para fazer o trabalho com sucesso.	
	Q24	Nossos gestores de <i>big data</i> e análise preditiva têm forte compreensão dos negócios.	
Capacidade de Análise de Big Data (ABD)	Q25	Nossos gestores de <i>big data</i> e análise preditiva são capazes de coordenar efetivamente todos os departamentos intra, fornecedores e clientes.	Adaptado de Dubey et al. (2019b)
	Q26	Nossa empresa combina e integra facilmente informações de muitas fontes de dados para uso na tomada de decisões.	
	Q27	Nossa empresa utiliza técnicas analíticas avançadas (por exemplo, simulação, otimização, regressão) para melhorar a tomada de decisões.	
	Q28	Nossa empresa usa rotineiramente técnicas de visualização de dados (por exemplo, <i>dashboards</i>) para ajudar usuários ou tomadores de decisão a entender informações complexas.	
	Q29	Nossos <i>dashboards</i> nos dão a capacidade de decompor informações para ajudar na análise de causas básicas e na melhoria contínua.	

Fonte: Elaborado pelos autores.