

FUNDAÇÃO GETULIO VARGAS
ESCOLA DE ADMINISTRAÇÃO DE EMPRESAS DE SÃO PAULO

KAREN CRISTINA ARAUJO FACIO

***BIG DATA EM COMPRAS: UMA PESQUISA SOBRE O USO EM INDÚSTRIAS
BRASILEIRAS***

SÃO PAULO
2018

KAREN CRISTINA ARAUJO FACIO

***BIG DATA EM COMPRAS: UMA PESQUISA SOBRE O USO EM
INDÚSTRIAS BRASILEIRAS***

Trabalho Aplicado apresentado a Escola de
Administração de Empresas de São Paulo da
Fundação Getulio Vargas, em cumprimento
aos requisitos para a obtenção do título de
Mestre em Gestão para a Competitividade.

Campo de Conhecimento: Supply Chain

Orientadora: Prof.^a Dra. Cristiane Biazzin

SÃO PAULO
2018

KAREN CRISTINA ARAUJO FACIO

***BIG DATA EM COMPRAS: UMA PESQUISA SOBRE O USO EM
INDÚSTRIAS BRASILEIRAS***

Trabalho Aplicado apresentado à Escola de Administração de Empresas de São Paulo da Fundação Getulio Vargas, em cumprimento aos requisitos para a obtenção do título de Mestre em Gestão para a Competitividade.

Campo de Conhecimento: Supply Chain

Data de Aprovação: 12/11/2018

Banca Examinadora:

Prof. Dra. Cristiane Biazzin (Orientador)
FGV-EAESP

Prof. Dr. Fabio Viard de Campos da Silva Tescari (Co-orientador)
Instituto de Ensino e Pesquisa - Insper

Prof. Dra. Verônica Angélica Freitas de Paula
Universidade Federal de Uberlândia

SÃO PAULO
2018

Facio, Karen Cristina Araujo.

Big data em compras : uma pesquisa sobre o uso em indústrias brasileiras

/ Karen Cristina Araujo Facio. - 2018.

73 f.

Orientador(a): Cristiane Biazzin.

Dissertação (MPGC) - Escola de Administração de Empresas de São Paulo.

1. Aquisição de conhecimento (Sistemas especialistas). 2. Big Data. 3. Sistema de informação gerencial. 4. Sistemas de suporte de decisão. 5. Compras. I. Biazzin, Cristiane. II. Dissertação (MPGC) - Escola de Administração de Empresas de São Paulo. III. Título.

CDU 65.012.4

Ficha catalográfica elaborada por: Raphael Figueiredo Xavier CRB SP-009987/O
Biblioteca Karl A. Boedecker da Fundação Getulio Vargas - SP

Ao meu marido, à minha mãe e irmãs, que sempre me incentivaram, motivaram e acreditaram em mim, não permitindo que eu esmorecesse.

AGRADECIMENTOS

Meu principal agradecimento vai ao meu marido, que esteve presente nos momentos mais importantes e difíceis da minha vida, nestes últimos 10 anos, e, sempre me motivou a seguir em frente, e abdicou comigo de vários fins de semanas, viagens e momentos de convivência para que a realização de mais essa etapa da minha vida fosse concluída.

Gostaria de agradecer também a minha mãe e irmãs que sempre estiveram comigo, me apoiando, suportando e servindo como exemplo de que sempre chegaremos aonde queremos chegar, basta se dedicar e fazer o seu melhor. Vocês são e sempre serão o meu exemplo de vida.

Aos meus colegas e amigos do MPGC, obrigada por tantos finais de semana juntos, risadas, ombros amigos e principalmente, pelo apoio e troca de experiências. Tenho muito orgulho de fazer parte desta turma, que fez toda a jornada junta, sem esmorecer.

A todos os professores do curso de MPGC em Supply Chain por compartilhar seus vastos conhecimentos e experiências conosco, em especial ao Professor Fabio Tescari, que muito contribuiu para este trabalho.

E, finalmente, agradeço à minha orientadora, Prof. Cristiane Biazzin, pela paciência, dedicação e direcionamento; mas, principalmente, por estar nesta jornada comigo do início ao fim e por ter me motivado a estar aqui.

RESUMO

A utilização de *Big data* para tomada de decisão nos últimos anos tem-se tornado um ponto de discussão muito frequente nas organizações, inclusive do ponto de vista de capacidade analítica destes dados e impacto no desempenho destas organizações. No modelo de processo fabril, o papel da área de Compras é fundamental para o atingimento de resultados financeiros e deve estar sempre muito alinhada com a estratégia da organização, inclusive na gestão de dados complexos do *Big data*. A proposta deste estudo é fazer uma pesquisa exploratória sobre o uso de dados de *Big data*, a percepção dos executivos sobre o conhecimento da análise dos dados, seu alinhamento com a estratégia da empresa e os resultados obtidos com o uso de análises de dados complexos nos últimos três anos especificamente na área de Compras das Indústrias Brasileiras. Foi realizada uma *survey* com executivos da área de Compras e as questões foram agrupadas em 8 construtos (Uso, Planejamento, Coordenação, Controle, Conectividade, Conhecimento, Alinhamento e Resultado). Os resultados foram analisados estatisticamente com regressão linear para a verificação de correlações entre os construtos e comparação de média entre diferentes grupos amostrais dos respondentes, e também foi elaborado um Relatório Gerencial com as principais informações obtidas no estudo. De modo geral, os resultados obtidos demonstram que a grande maioria dos respondentes acredita que a utilização de *Big data* pode ajudar a organização a tomar decisões mais assertivas e afirmam que a sua utilização nos últimos três anos na área de Compras contribuiu para redução em custos. Por outro lado, são poucos os respondentes que acreditam que suas organizações trabalham com estes dados melhor do que seus concorrentes e afirmam que seus especialistas em análise de dados não estão preparados ou não conhecem mais profundamente as tendências tecnológicas.

Palavras-chaves: Big Data, Compras, Análise de Dados Complexos, Relatório Gerencial

ABSTRACT

The subject of using Big data for decision making has become a very frequent point of discussion in organizations in recent years, including the perspective of the analytical capacity related to these data and the impact on the performance and results of these organizations. From the manufacturing process model standpoint, the role of the Procurement area is fundamental for the attainment of financial results and must always be very much in line with the organization's strategy, including the management of complex Big data analytics. The purpose of this study is to conduct an exploratory research on the use of Big data, the perception of the executives about the knowledge of the data analysis, its alignment with the company strategy and the results obtained with the use of complex data analyzes in the last three years specifically in the Procurement Department in the Brazilian Industries segment. A survey was conducted Procurement executives and the questions were grouped into 8 constructs (Usage, Planning, Coordination, Control, Connectivity, Knowledge, Alignment and Result). The results were analyzed statistically through linear regression for the verification of correlations between the constructs and mean comparison between different sample groups of the respondents, and a Management Report with the main information obtained in the study was also created. Overall, the results show that the vast majority of respondents believe that the use of Big data can help the organization to make more assertive decisions and state that using Big data in the last 3 years in the Procurement area, contributed to a reduction in costs. On the other hand, only few of respondents believe that their organizations work with these data better than their competitors and say their data analysis experts are prepared or are more deeply aware of technological trends.

Key words: Big data, Procurement, Complex Data Analyzes, General Report

LISTA DE QUADROS

Quadro 1 - Conceitos de <i>Big data</i> identificados na literatura	19
Quadro 2: Áreas impactadas positivamente pela implementação das ferramentas que criam e evitam desperdícios de valor em compras	32
Quadro 3 – Matriz de amarração entre construtos, seus objetivos e questões e fontes acadêmicas.....	34
Quadro 4 - Resultados das Análises Estatísticas descritivas para amostras de grupos de respondentes por construto agrupado	44

LISTA DE FIGURAS

Figura 1: Dimensões e sub-divisões de BDAC	23
Figura 2: Aplicações Analíticas na Cadeia de Suprimentos	28
Figura 3: Ciclo potencial Transformador da Cadeia de Suprimentos	29
Figura 4: Fórmula Teste T de Amostras Independentes	44
Figura 5: Fórmula de regressão linear	46
Figura 6: Análise comparativa entre média geral dos respondentes vs média geral por construto.	50
Figura 7: Principais variações no percentual de respondentes da Seção 1: Como o <i>Big data</i> é utilizado	51
Figura 8: Principais variações no percentual de respondentes da Seção 2: Planejamento	52
Figura 9: Principais variações no percentual de respondentes da Seção 4: Controle.....	54
Figura 10: Principais variações no percentual de respondentes da Seção 5: Conectividade....	55
Figura 11: Principais variações no percentual de respondentes da Seção 7: Alinhamento	57

LISTA DE TABELAS

Tabela 1: Resumo das respostas	37
Tabela 2: Perfil dos respondentes	38
Tabela 3 – Resultados da análise estatística descritiva dos dados dos respondentes por questão	41
Tabela 4: Resultado na Inspeção Univariada de <i>Outliers</i>	42
Tabela 5: Matriz de Correlação	43
Tabela 6: Resultado bicaudal da análise de Teste t entre as duas amostras de cada dimensão	45
Tabela 7: Coeficiente R^2 de comparação entre os construtos agrupados	47
Tabela 8: Resultado R^2 de comparação entre os construtos de primeira ordem.....	48
Tabela 9: Principais variações no percentual de respondentes da Seção 3: Coordenação	53
Tabela 10: Variações no percentual de respondentes da Seção 6: Conhecimento	56

LISTA DE ABREVIATURAS E SIGLAS

BDAC – *Big data Analytics Capability* – Capacidade de Análises de dados do *Big data*

BDA – *Big data Analytics* – Análise de dados do *Big Data*

ERP – *Enterprise resource Planning* – Sistema de gestão Empresarial

GPS – *Global Positioning System* – Sistema de Posicionamento Global por satélite

HADOOP – Plataforma de *software* em Java de computação distribuída voltada para *cluster* e processamento de grandes volumes de dados com atenção a tolerância a falhas

OCR – *Optical Character Recognition* – Reconhecimento Optical de caracteres

POS – *Point of Sale* – Ponto de venda (local onde o cliente paga as suas compras)

RFID – *Radio Frequency Identification* – Identificação de Rádio Frequência

SUMÁRIO

1. INTRODUÇÃO	15
2. REFERENCIAL TEÓRICO	18
2.1 Conceito de <i>Big data</i>	18
2.2 Temas chaves do <i>Big data</i>	20
2.2.1 Informações	20
2.2.2 Tecnologia	20
2.2.3 Métodos	21
2.2.4 Impacto	22
2.3 Capacidades Analíticas do <i>Big data</i>	22
2.3.1 Capacidade Gerencial	23
2.3.2 Capacidade Tecnológica.....	24
2.3.3 Capacidade de talentos	25
2.4 Impacto de <i>Big data</i>	25
2.4.1 Nas organizações	25
2.4.2 Impacto <i>Big data</i> na Cadeia de Suprimentos	27
2.4.3 Impacto do <i>Big data</i> em Compras	30
3. METODOLOGIA	33
3.1 Instrumento de Pesquisa	33
3.2 Seleção da amostra e Coleta de dados	37
4. ANÁLISE DE DADOS.....	39
4.1 Análise descritiva.....	39
4.2 Inspeção Univariada de <i>Outliers</i>	41
4.3 Matriz de Correlação	42
4.4 Análise exploratória dos dados	43
4.4.1 Comparação de médias	43
4.4.2. Verificação de possíveis relações causais	46
5. PROPOSTA DE RELATÓRIO GERENCIAL.....	49
5.1 Entendimento do uso de <i>Big data</i> pelos respondentes.....	49
5.1.1 Como o <i>Big Data</i> é utilizado	51

5.1.2	Planejamento	52
5.1.3	Coordenação	52
5.1.4	Controle	53
5.1.5	Conectividade	54
5.1.6	Conhecimento	55
5.1.7	Alinhamento	56
5.1.8	Resultados.....	57
6.	CONCLUSÃO, LIMITAÇÕES E ESTUDOS FUTUROS	58
6.1	Conclusão.....	58
6.2	Limitações.....	60
6.3	Estudos futuros	60
	REFERÊNCIAS	62
	APENDICE A – Percentual de respondentes de cada questão.....	69
	APENDICE B – Percentual de respondentes por Seção	70

1. INTRODUÇÃO

Atualmente uma das principais discussões tem sido a contribuição do uso de dados complexos para uma melhor tomada de decisões. *Big data* tem se apresentado como um potencial caminho para otimização de custos, decisões e riscos em Compras (WANG et al, 2016). Recentes estudos demonstram que quase 90% das empresas acreditam que *Big data* trará impactos importantes em suas organizações e que empresas que não utilizarem análise de dados perderão participação em seus respectivos mercados nos próximos anos (SCHOEMAKER; TETLOCK, 2017). McAfee e Brynjolfsson (2012) observam que as empresas que se caracterizavam por serem mais orientadas a dados melhoram seu desempenho financeiro, sendo em média 5% mais produtivas e 6% mais lucrativas que seus competidores.

Não só a obtenção destes dados é importante; também a capacidade analítica da compreensão destes dados se torna primordial para a maneira como as empresas realizam negócios (BARTON; COURT, 2012), transformando a teoria em prática (GEORGE et al., 2014). Como informação não é mais poder, por estar amplamente disponível, a velocidade na tomada de decisões e o conhecimento em como utilizar os dados que se tem em mãos poderá levar organizações a entender como melhorar um produto, como criar uma estratégia de marketing mais eficiente, como cortar gastos, como produzir mais em menos tempo, como evitar o desperdício de recursos, como superar um concorrente, como disponibilizar serviços para um cliente especial de maneira satisfatória e assim por diante.

Em um estudo realizado por Manyika et al. (2011), foram detectadas cinco maneiras em que o uso de *Big data* pode criar valor. Primeiro, o *Big data* pode gerar um valor significativo ao tornar as informações transparentes e utilizáveis com uma frequência muito maior. Em segundo lugar, à medida que as organizações criam e armazenam mais dados transacionais em formato digital, elas podem coletar informações de desempenho mais precisas e detalhadas sobre tudo, desde inventários de produtos até dias de produção e, portanto, mostrar e detalhar itens de maior variabilidade e melhorar o desempenho. Terceiro, o *Big data* permite uma segmentação cada vez mais estreita dos clientes e, portanto, produtos ou serviços muito mais precisos. Em quarto lugar, análises sofisticadas podem melhorar substancialmente a tomada de decisões. Finalmente, *Big data* pode ser usado para melhorar o desenvolvimento da próxima geração de produtos e serviços (MANYIKA et al., 2011)

De acordo com o estudo de Bouleye, Riedstra e Spiller (2016), a análise avançada das informações contidas no *Big data* na Cadeia de Suprimentos ajudará as empresas a gerar novos *insights*, permitindo que eles colaborem em escala, com acesso a todos os dados relevantes sobre estruturas de custos, disponibilidade de fornecimento, prazos de entrega, riscos operacionais e métricas de serviço e qualidade. Isso elevaria o desempenho de Compras a um outro patamar, com tomadas de decisões mais ágeis e reação à cadeia em um modo muito mais assertivo. Neste cenário, *Big data* tem o potencial de revolucionar a dinâmica da Cadeia de Suprimentos (WALLER; FAWCETT, 2013).

Esta necessidade de dados mais robustos para melhorar o desempenho também aparece na área de Compras das organizações. A literatura reconhece a importância que o papel de Compras está ganhando em muitas empresas. Harland (1999) e Gonzalez-Benito (2007) definem que a estratégia de compra está diretamente ligada à estratégia global de negócios, em concordância com outros autores (por exemplo, COUSINS, 2005; NOLLET, 2005). Esta área pode criar valor às organizações a partir de muitas novas aplicações no futuro, considerando a função na intersecção de vários fluxos de dados entre a empresa e seus parceiros. Os executivos da área trabalham com dados históricos e projeções futuras de gastos e utilização gerados pelo planejamento de recursos empresariais da empresa (ERP) e sistemas de previsão. Eles recebem especificações do produto fornecidas por suas contrapartes de engenharia; monitoram aderência do contrato, o comportamento de faturamento e desempenho do fornecedor; geram perfis de fornecedores e planilhas de avaliações (*scorecards*), de acordo com McKinsey (2016). A área de Compras também utiliza várias fontes de dados externos, tais como séries temporais específicas do mercado de *commodities*, taxas de câmbio e inflação, dados fiscais e tarifários, ou dados de solvência, que precisam ser analisados e correlacionados.

Apesar de estes dados e pesquisas sobre a relevância do *Big data* para a tomada de decisões na Cadeia de Suprimentos, poucos estudos retratam o uso e aplicabilidade em Compras especificamente, e não existe o mesmo nível de informação no que se refere ao Brasil. Desta forma, este trabalho visa responder a seguinte questão: “A análise de dados complexos tem sido explorada em Compras e há um reconhecimento de valor em seu uso?”.

Os objetivos deste trabalho são:

1. Entender o atual grau da utilização do *Big data* nas organizações, principalmente na área de Compras;

2. Verificar a percepção de uso e habilidade dos executivos para gerir *Big data* no Brasil;
3. Identificar se já existem benefícios percebidos na área de Compras com a utilização de *Big data*;
4. Gerar um relatório gerencial sobre o *status* da utilização de *Big data* em Compras no Brasil

Para tanto, foi construída uma *survey*, direcionada a profissionais da área de Compras em diferentes segmentos da indústria. A decisão de seguir com os respondentes do setor industrial se faz por razão da maior complexidade da área de Compras neste segmento e pelo impacto que a mesma representa, na receita bruta da empresa, que gira entre 50-90% (SANDERS, 2016), percentual este mais representativo do que no setor de serviços, onde a mão de obra é o principal custo.

Este trabalho está dividido em seis partes, incluindo a introdução. A segunda parte se refere à revisão de Literatura e as principais abordagens e definições de *Big data*, bem como seus impactos na organização e na área de Compras. A terceira parte descreve a metodologia utilizada, como os dados foram coletados e como os mesmos foram analisados. Na quarta seção, serão apresentados os resultados das análises e da pesquisa. Na quinta seção será apresentado o Relatório Gerencial e, na sexta seção, a conclusão mostrará o entendimento do estudo, suas limitações e possíveis recomendações para estudos futuros.

2. REFERENCIAL TEÓRICO

Este capítulo será dividido em três grandes blocos, onde no primeiro deles, serão descritas as principais definições acadêmicas sobre o termo *Big data* e suas possíveis variações. No segundo bloco deste capítulo, embasada na teoria, se dará a definição das Capacidades analíticas necessárias para a análise e interpretação dos dados extraídos do *Big data*. No terceiro e último bloco vê-se as principais definições e aplicações da utilização do *Big data* nas organizações, principalmente nas áreas de *Supply Chain* e Compras e os principais benefícios para estas áreas com a utilização dos dados extraídos do *Big data*.

2.1 Conceito de *Big data*

De acordo com Mauro, Greco e Grimaldi (2016), apesar de *Big data* ser amplamente utilizado na Literatura Acadêmica e no mundo dos negócios, existem várias definições para o termo, sendo usado ao se referir a uma variedade de entidades diferentes, incluindo – mas não limitando-se a fenômeno social, ativos de informação, conjuntos de dados, técnicas analíticas, tecnologias de armazenamento, processos e infraestruturas, sendo as definições divididas em 4 grupos distintos.

Um primeiro grupo de definições de *Big data* concentra-se em listar suas características, como uma estrutura tridimensional no aumento de dados de Volume, Velocidade e Variedade (LINEY, 2001). Um segundo grupo de definições enfatiza as necessidades tecnológicas por trás do processamento de grandes quantidades de dados. De acordo com a Microsoft (2013), *Big data* é sobre a aplicação de “sério poder de computação” a conjuntos massivos de informação; um terceiro grupo enfatiza o tamanho dos dados. Fisher (2012) sugere que o conceito de “grande” em termos de tamanho está relacionada com a Lei de Moore e, consequentemente, com a capacidade de soluções de armazenamento comercial. E um último grupo de definições destaca o impacto do avanço do *Big data* na sociedade. Boyd e Crawford (2012) observam que *Big data* é menos sobre dados que são grandes do que sobre uma capacidade de pesquisa, agregação e referência cruzada de grandes conjuntos de dados. O Quadro 1 apresenta as principais definições utilizadas e encontradas na literatura sobre o tema.

Quadro 1 - Conceitos de *Big data* identificados na literatura

Grupo	Definição	Fonte
Definição focada em listar suas características	Alto volume, velocidade e variedade de ativos de informação que exigem custos de demanda efectivos, formas de processamento de informação inovadoras para melhor percepção e tomada de decisão	Beyer and Laney (2012)
	As 4 características de definição do Big data são Volume, Velocidade, Variedade e Valor	Dijcks (2012)
	Complexos, não estruturados ou grande quantidades de dados	Intel report (2012)
	Pode ser definido usando 3 dados de características: Cardinalidade, Continuidade e Complexidade	Suthaharan (2014)
	<i>Big data</i> é a combinação de Volume, Variedade, velocidade e Veracidade que cria uma oportunidade para organizações ganharem uma vantagem competitiva no mundo digitalizado atual	Schroeck et.at. (2012)
Definição focada nas necessidades tecnológicas	Extensos conjuntos de dados, principalmente nas características de volumes, velocidade e / ou variedade, que requerem uma arquitetura escalável para eficientes armazenamento, manipulação e análise	NIST Big Data Public Working Group, B(2014).
	O armazenamento e a análise de conjuntos de dados grandes e complexos usando uma série de técnicas, incluindo, mas não se limitando a: NoSQL, MapReduce e aprendizado de máquina	Ward and Barker (2013)
	O processo de aplicar o poder de computação, o mais recente em aprendizado de máquina e inteligência artificial, a importantes conjuntos de informações maciças e geralmente muito complexas	Microsoft (2013)
Definição focada no tamanho dos recursos	Dados que excedam a capacidade convencional de processamento de sistemas de database	Dumbill (2013)
	Dados que não podem ser manuseados e e processados de um modo direto	Fisher, DeLine, Czerwinski, and Drucker (2012)
	Um conjunto de dados tão grande para caber em uma tela	Shneiderman (2008)
	Conjunto de dados que o tamanho ultrapasse a habilidade das ferramentas normais de um database em capturar, armazenar, gerenciar e analisar	Manyika, Chui, Brown, and Bughin (2011)
	Conjunto de dados e técnicas analíticas em aplicativos que são tão grandes e complexos que exigem tecnologias exclusivas e avançadas, de armazenamento, gerenciamento, análise e visualização de dados	Chen, Chiang, and Storey (2012)
Definição focada no impacto avanço do <i>Big data</i> na sociedade	Um fenômeno cultural, tecnológico e acadêmico que repousa na interação entre tecnologia, análise e mitologia	Boyd and Crawford (2012)
	Fenômeno que traz três mudanças fundamentais na forma como analisamos as informações que transformam como entendemos e organizamos a sociedade: 1.Mais dados; 2. Dados mais confusos (incompletos); 3. Correlação causa causalidade	Mayer-Schönberger and Cukier (2013)

Fonte: Adaptado pela autora, de Mauro, Greco e Grimaldi, 2016

Após análise da literatura existente e nos principais tópicos de pesquisa associados a ele, afirma que a definição consensual seria: “*Big Data representa os ativos de informação caracterizados por um Alto Volume, velocidade e variedade com uma Tecnologia e Métodos Analíticos específicos para sua transformação em Valor*” (MAURO; GRECO; GRIMALDI, 2016, p.130).

2.2 Temas chaves do *Big data*

No processo de definição de *Big data* e dos principais tópicos de pesquisa foram identificados também por Mauro, Greco e Grimaldi (2016) quatro elementos chaves de pesquisa associados a *Big data*.

2.2.1 Informações

Uma das principais razões para o sucesso e popularização do *Big data* é possibilidade de extensão e digitalização da informação. De acordo com Coyle (2006), a digitalização em massa é a tentativa de converter bibliotecas inteiras de livros impressos em coleções digitais, aproveitando *software* de reconhecimento de caracteres (OCR), a fim de minimizar a intervenção humana.

A digitalização e informatização só são possíveis devido a conexão entre sensores digitais e dispositivos, tais como: telemóveis, sensores, identificação por radiofrequência – etiquetas RFID, atualizadores, capazes de interagir uns com os outros e cooperar com outros dispositivos e sensores para alcançar objetivos comuns, que tem o nome de Internet das Coisas, Iot (ATZORI; IERA; MORABITO, 2010).

De acordo com Russom (2011), outra característica dos dados gerados hoje é sua crescente variedade no tipo. Dados estruturados (texto tradicional/informação numérica) juntam-se agora a dados não estruturados (áudio, vídeo, imagens, texto e linguagem humana) e dados semi-estruturados, como XML.

2.2.2 Tecnologia

As principais necessidades para operar e processar os dados de *Big data* envolvem armazenamento de memória e requisitos de desempenho computacional. De acordo com Google *Trends*, a tecnologia mais associada a este processamento é o Hadoop, uma estrutura

de código aberto que permite o processamento distribuído de grandes quantidades de dados usando um grupo de máquinas dispersas e modelos específicos de programação de computadores.

De acordo com Xiong et al. (2013), a natureza distribuída da informação exige um esforço tecnológico específico para a transmissão de grandes quantidades de dados e para monitorar o desempenho geral do sistema usando técnicas especiais de *benchmarking*. Um fator decisivo cujo esforço é contínuo, seria acompanhar o ritmo do aumento das capacidades necessárias, com a entrada de imagens, vídeo e sons, que utilizam muitos *bytes* de memórias (HILBERT e LOPEZ, 2011).

2.2.3 Métodos

Mauro, Greco e Grimaldi (2016) afirmam que a análise de grandes quantidades de dados e a necessidade de compreender o valor dos comportamentos individuais requer métodos de processamento que vão além das técnicas estatísticas tradicionais. O conhecimento de tais métodos, de seus potenciais e, acima de tudo, de suas limitações exigem habilidades específicas que são difíceis de encontrar no mercado de trabalho atual.

A linha proposta por Manyika et al. (2011) e Chen, Chiang e Storey (2012), destaca uma lista de Métodos Analíticos de *Big data*, que inclui: Teste A / B, Aprendizado da regra de associação, Classificação, Análise de dimensão, Fusão e Integração de dados, Aprendizagem de conjunto, Algoritmos genéticos, Aprendizado de máquina, Processamento de linguagem natural, Redes Neurais, Análise de redes, Reconhecimento de padrões, Modelagem preditiva, Regressão, Análise de sentimentos, Processamento de Sinal, Análise espacial, Estatística, Aprendizagem supervisionada e não supervisionada, Simulação, Análise de séries temporais e Visualização.

Ainda de acordo com Chen, Chiang e Storey (2012), existe a necessidade das empresas investirem em educação formal para *Business Intelligence* e análise de dados, que seria interdisciplinar e cobriria habilidades críticas analíticas e de TI, conhecimento e domínio de negócios, e habilidades de comunicação necessárias em um ambiente de negócios complexo e centrado em dados.

2.2.4 Impacto

De acordo com Mauro, Greco e Grimaldi (2016), a utilização do *Big data* tem causado impactos importantes na nossa sociedade, como por exemplo o uso da mesma base de dados para estudos de natureza diversa (desemprego, resfriado e inflação), através da correlação dos dados. Não somente a sociedade, mas também as empresas são fortemente impactadas pela ascensão do *Big data*: a utilização desta tecnologia também pode trazer vantagem competitiva quando transforma os dados em conhecimento do cliente e redireciona a empresa e o negócio nesta direção (MCAFEE; BRYNJOLFSSON, 2012). Este tema é de tal forma complexo e abrangente que teremos uma seção inteira dedicada a ele.

2.3 Capacidades Analíticas do *Big data*

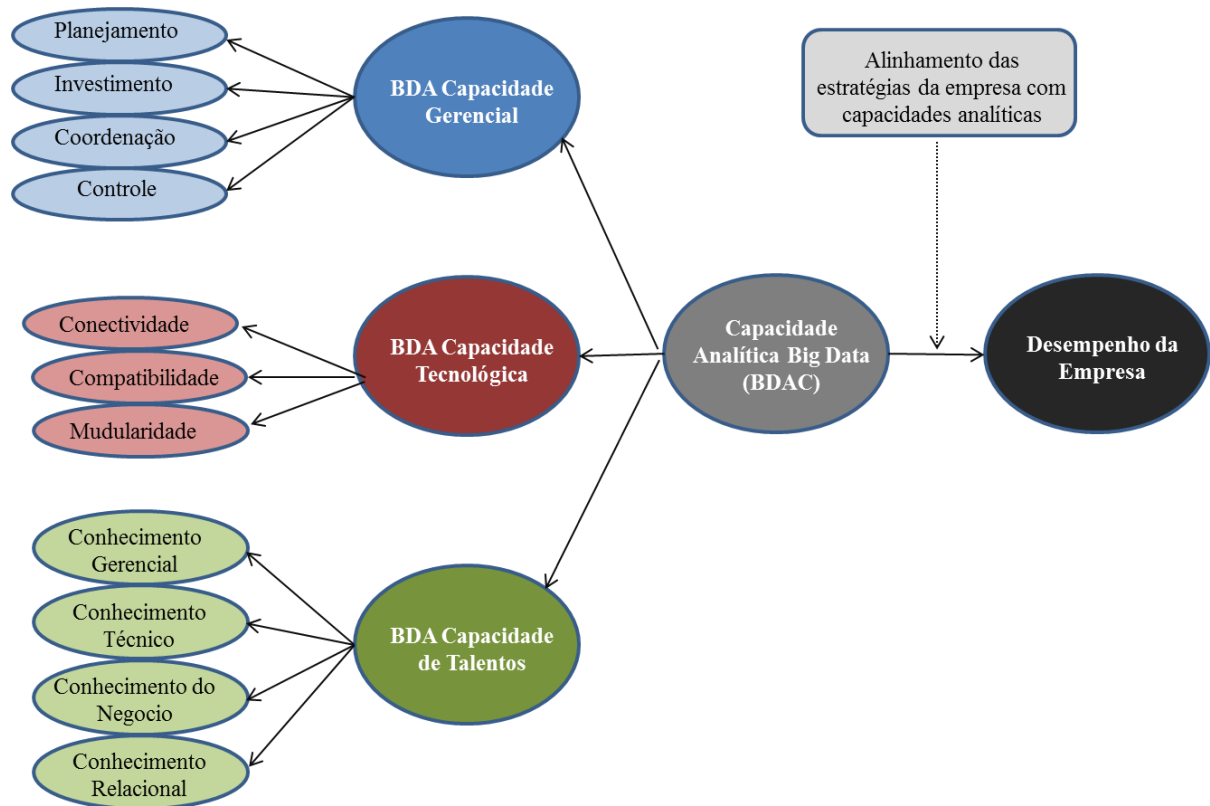
Capacidade Analítica do *Big data* (sigla BDAC em inglês – *Big data analytics capability*), é um termo entendido como a competência para fornecer *insights* de negócios usando a capacidade de gerenciamento de dados, infraestrutura (tecnologia) e talentos (pessoal) para transformar a estratégia de negócios em uma força competitiva (KIRON et al., 2014). Já Lavallo et al. (2011) identificam BDAC como a habilidade em usar *Big data* para a tomada de decisão que é essencialmente conectada com a estratégia de negócios da empresa.

Embora as dimensões do BDAC sejam diferentes em sua terminologia, os esquemas de taxonomia propostos pela literatura são semelhantes, pois refletem a capacidade de gerenciamento do BDA, a infraestrutura do BDA e a capacidade de talentos do BDA como aspectos relacionados (AKTER et al., 2016). Ainda de acordo com Akter et al. (2016), a literatura em *Big data* identifica 3 blocos de construção principais de BDAC: organizacional (isto é, BDA gerencial), físico (isto é, infraestrutura de TI) e humana (por exemplo, conhecimento).

McAfee e Brynjolfsson (2012) identificam os desafios críticos da BDAC como gestão administrativa, a estrutura de TI, e capacidade de tomada de decisão em diferentes funções. Além disso, Kiron et al. (2014), ao considerar as principais dimensões do BDAC, focam na cultura do gerenciamento, gestão de infraestrutura e habilidades. Um ponto em que poucos estudiosos discordam é a inclusão da capacidade de gestão do BDA, capacidade de infraestrutura do BDA, e capacidade de talentos como as principais dimensões do BDAC.

Akter et al., (2016) apresentam 11 subdivisões para as três principais dimensões do BDAC, que são distintas, mas que estão entrelaçados para se apoiar mutuamente e se reforçar no ambiente de *Big data* para atingir as metas de negócios, conforme demonstrado na Figura 1, aonde se vê que o desempenho da empresa depende das três dimensões e sub-divisões cujo resultado final é a capacidade analítica de interpretação dos dados, e com o alinhamento das estratégias da empresa.

Figura 1: Dimensões e sub-divisões de BDAC



Fonte: adaptado pela autora de Akter et al. (2016)

2.3.1 Capacidade Gerencial

A Capacidade Gerencial é um aspecto importante do BDAC, garantindo que as decisões de negócios sólidas sejam tomadas aplicando-se a estrutura adequada de gerenciamento. Quatro temas centrais foram encontrados para constituir percepções deste construto: planejamento, investimento, coordenação e controle da BDA.

- 1) Planejamento de BDA: identifica oportunidades de negócios e determina como os grandes modelos baseados em dados podem melhorar o desempenho da empresa (BARTON e COURT, 2012).
- 2) Decisões de investimento do BDA: são aspectos de análises de custo-benefício que, segundo Ramaswamy (2013), empresas com grandes investimentos em *Big data* geram retornos excedentes e ganham vantagens competitivas, colocando em risco as empresas sem investimentos significativos em *Big data*. Desta maneira, o gerenciamento desta capacidade é imprescindível para melhorar as atividades geradoras de receita, impulsionando o crescimento (AKTER et al. 2016).
- 3) Coordenação do BDA: representa uma forma de capacidade de rotina que estrutura a sincronização multifuncional de atividades analíticas em toda a empresa (KIRON et al., 2014).
- 4) Funções de Controle BDA: garantir o devido comprometimento e a utilização dos recursos, incluindo orçamentos e recursos humanos (AKTER et al. 2016)

2.3.2 Capacidade Tecnológica

De acordo com Akter et al. (2016), a Capacidade tecnológica refere-se à flexibilidade da plataforma BDA (por exemplo, conectividade de dados multifuncionais, compatibilidade de múltiplas plataformas, modularidade na construção de modelos, etc.) em relação à capacitação de cientistas de dados para desenvolver, implantar e suportar rapidamente recursos de uma empresa. Três temas centrais sustentam este construto: conectividade, compatibilidade e modularidade.

- 1) Conectividade entre diferentes unidades de negócios na obtenção e análise de uma variedade de dados de diferentes funções (por exemplo, gerenciamento da cadeia de Compras, gerenciamento de relacionamento com o cliente etc.).
- 2) Compatibilidade, que possibilita fluxos contínuos de informações para decisões em tempo real. Também ajuda as operações de limpeza a sincronizar e mesclar dados sobrepostos e a corrigir informações ausentes.
- 3) Modularidade: incorpora um desenvolvimento de plataforma flexível que permite a adição, modificação ou remoção de recursos do modelo, ou a partir dele, conforme necessário.

2.3.3 Capacidade de talentos

Capacidade de Talento refere-se à capacidade de um profissional de análise (por exemplo, alguém com habilidades ou conhecimento de análise) para executar tarefas atribuídas no ambiente de *big data*. Este "*know-how*" e outros tipos de conhecimento são referidos como capacidades neste contexto, e podem criar ou sustentar vantagem competitiva (CONSTANTIOU; KALLINIKOS, 2014). Os quatros temas centrais deste construto são: conhecimento técnico; conhecimento de gerenciamento de tecnologia; conhecimento de negócios e conhecimento relacional.

- 1) Conhecimento técnico refere-se ao conhecimento sobre elementos técnicos, incluindo sistemas operacionais, estatísticas, linguagens de programação e sistemas de gerenciamento de banco de dados.
- 2) Conhecimento de gerenciamento refere-se ao conhecimento de gerenciamento de recursos de *Big data* que é necessário para dar suporte aos objetivos de negócios, por exemplo, ferramentas de visualização e gerenciamento e implantação de técnicas
- 3) Conhecimento do negócio refere-se à compreensão de várias funções de negócios e do ambiente de negócios, por exemplo, compreensão de metas de curto e longo prazo
- 4) Conhecimento relacional se refere à capacidade de os profissionais de análise se comunicarem e trabalharem com pessoas de outras funções de negócios. Os cientistas de dados precisam de um relacionamento próximo com o resto do negócio.

2.4 Impacto de *Big data*

2.4.1 Nas organizações

Muitos fornecedores de TI e fornecedores de soluções usam o termo "*Big data*" como uma palavra de ordem para uma análise de dados mais inteligente e perspicaz (DAVENPORT; BARTH; BEAN, 2012). Mas o *Big data* é realmente muito mais que isso. De fato, empresas que aprendem a vantagem de usar as informações do *Big data* em tempo real através de sensores, RFDI e outros dispositivos de identificação para entender seu ambiente de negócios em um nível mais granular, para criar produtos e serviços e responder às mudanças nos padrões de uso assim que ocorrerem. Estas organizações diferem das demais em três maneiras principais: 1) Prestam atenção aos fluxos de dados em oposição às ações; 2)

Confiam em cientistas de dados e desenvolvedores de produtos e processos, em detrimento a analista de dados; e 3) Estão movendo a análise de dados de dentro das áreas de Informática para as áreas de operações.

McAfee e Brynjolfsson (2012) investigaram qual seria a evidência de que, usando a Inteligência do *Big data*, poderia aumentar o desempenho do negócio. Para tanto os autores desenvolveram entrevistas estruturadas, realizadas pela MIT Center para Negócios Digitais, em parceria com o escritório da McKinsey, com 330 executivos de empresas dos Estados Unidos. As empresas que se diziam mais direcionadas à utilização de *Big data* eram 5% mais produtivas e 6% mais rentáveis em comparação com as que não são inclinadas a utilizar estes dados.

Os mesmos autores abordam que, sem mudança de cultura na tomada de decisões da empresa, não é possível se beneficiar adequadamente das vantagens que a utilização do *Big data* pode trazer; e indicam cinco desafios importantes que são: Liderança, Gerenciamento de Talentos; Tecnologia, Tomada de decisões e Cultura da empresa e sugerem quatro estágios para iniciar a implementação, sendo: 1) Escolher uma unidade de negócios; que deve ter líderes amigáveis cercados por um time de cientistas de dados para iniciar a implantação; 2) Desafiar as funções chaves a identificar oportunidades de negócios baseadas em *Big data*, a serem implementadas em um curto espaço de tempo por uma equipe enxuta; 3) Implementar um processo de inovação que inclua quatro passos: experimentação, medição, compartilhamento e replicação e, 4) Ter em mente que a maior parte das pessoas espertas trabalham para outras pessoas; compartilham informações.

Schoemaker e Tetlock (2017) abordam duas forças, a tecnologia e a racionalidade humana, para a tomada de decisões e o aumento da Inteligência Empresarial, a partir do *Big data*. Em seu estudo eles identificam cinco capacidades estratégicas para auxiliar as empresas não só a usar os dados do *Big data* como também usá-los da melhor maneira possível.

- a) Encontrar a vantagem estratégica: com base na avaliação das previsões organizacionais passadas, determinar áreas internas onde melhorar previsões subjetivas pode realmente fazer a diferença; em outras palavras, seja estratégico nas decisões de quais problemas você deve priorizar;
- b) Promover torneios de previsão: descobrir os melhores métodos de previsão incentivando a competição, a experimentação e a inovação entre as equipes;

- c) Modelar os especialistas em seu meio: identifique as pessoas ao interno da organização, que demonstram *insights* superiores nas principais áreas de negócios e aproveite sua sabedoria usando modelos lineares simples;
- d) Experimentar a Inteligência Artificial: ir além dos modelos lineares simples e usar redes neurais profundas em domínios de tarefas limitadas para superar os especialistas;
- e) Mudar a maneira como a organização opera: promover uma cultura exploratória que busca melhoramento contínuo na maneira de combinar as capacidades humanas e digitais (máquinas).

2.4.2 Impacto *Big data* na Cadeia de Suprimentos

De acordo com Sanders (2016), os aplicativos de análise que podem fornecer uma vantagem competitiva aparecem ao longo de todo o espectro de decisões da cadeia de Suprimentos – desde o marketing direcionado com base na localização até a otimização dos inventários da cadeia de fornecimento para permitir uma avaliação robusta do risco do fornecedor. A cadeia de fornecimento gera enormes quantidades de dados que as empresas podem transformar em inteligência por meio de análises, desde POS, GPS e RFID até *feeds* de mídia social. A grande maioria das empresas está repleta de dados, mas não sabe ao certo como usá-los para impulsionar suas Cadeias de Suprimentos.

Chen, Preston e Swink (2015) investigaram: 1) Como as organizações usam dados analíticos provenientes do *Big data* para crescer e aumentar a sua produtividade e 2) Quais são os fatores chaves para a utilização dos dados analíticos de uma organização e usaram seu questionário nos domínios da Cadeia de Suprimentos pois este é um domínio particularmente importante porque as empresas estão cada vez mais dependentes da aprendizagem organizacional e da criação de conhecimento para alcançar o sucesso da gestão da cadeia de Suprimentos (HULT et al. 2006).

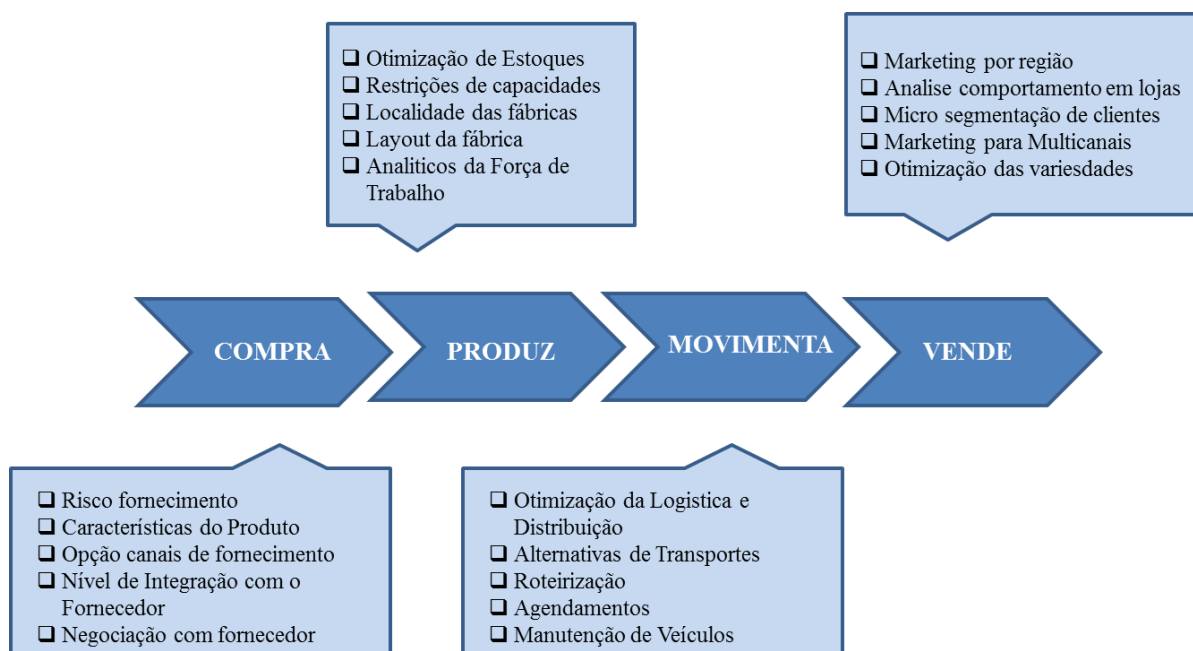
Rai, Patnayakuni e Seth (2006) afirmam que tradicionalmente considerado como um domínio de pesquisa de gerenciamento de operações, a Cadeia de Suprimentos tem recentemente recebido considerável atenção de estudiosos de sistemas de informação (IS) porque a área também pode ser conceituada como um agrupamento de processos entre empresas ativados digitalmente. Cadeias de Suprimentos baseadas em sistemas de Informática permitem uma empresa focal a integrar o fluxo de informações, materiais e finanças com seus parceiros da Cadeia de Suprimentos, contribuindo assim para os resultados organizacionais

(DEHNING; RICHARDSON; ZMUD, 2007). Como tal, é possível afirmar que o domínio Cadeia de Suprimentos fornece um contexto ideal para utilizar os dados analíticos do *Big data*.

Além disso, o uso extensivo de analíticos em áreas da Cadeia de Suprimentos, pode estimular aprendizagens interorganizacionais, entre uma empresa e seus parceiros da Cadeia de Suprimentos (KLEIN; RAI, 2009). Por exemplo, a análise de dados que descreve os padrões de aquisição e entrega pode levar potencialmente a uma maior otimização dos recursos de transporte de forma a aumentar o uso de ativos de transporte. De forma semelhante, os cronogramas de produção podem ser aprimorados para usar totalmente os ativos de produção. Coletivamente, essas melhorias podem potencialmente refletir-se em taxas de giro de ativos mais altas e outros indicadores de produtividade de ativos (CHEN; PRESTON; SWINK, 2015).

De acordo com o estudo realizado por Sanders (2016), embora recursos de análise profunda estejam sendo desenvolvidos para sub-funções ao longo da Cadeia de Suprimentos, eles são muitas vezes hiper-especializados. A menos que os *insights* oferecidos por essas aplicações funcionais possam ser vinculados ao restante da Cadeia de Suprimentos, sua produção pode não proporcionar benefícios tangíveis e propõe que as aplicações analíticas sejam feitas ao longo da cadeia conforme demonstrado na Figura 2.

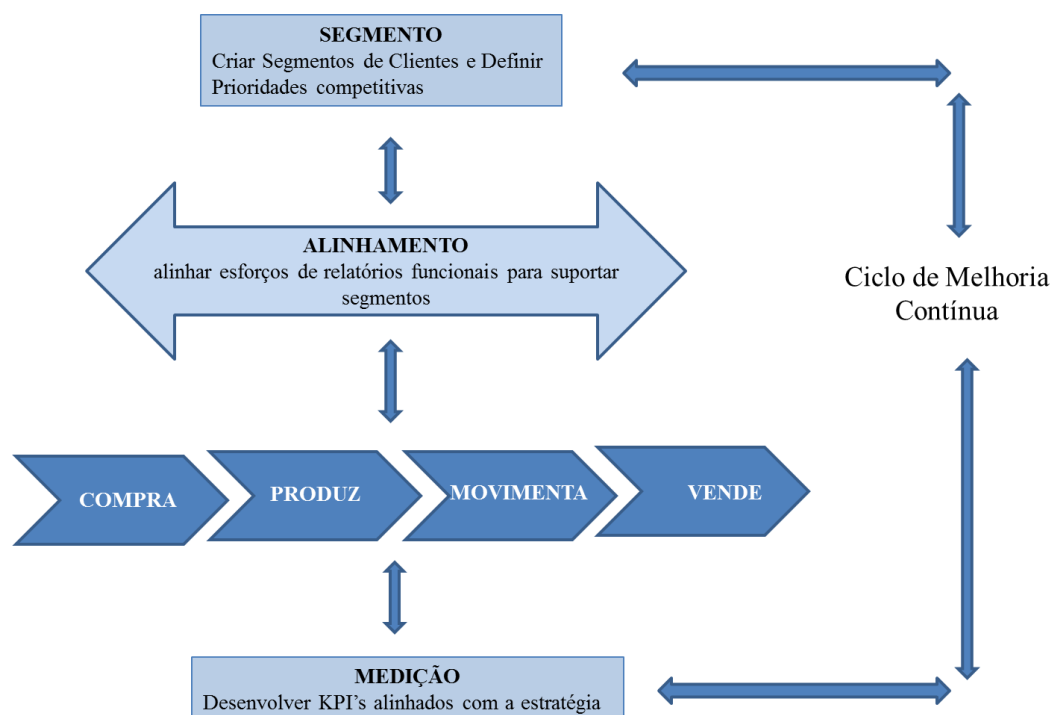
Figura 2: Aplicações Analíticas na Cadeia de Suprimentos



Fonte: adaptado pela autora, de Sanders (2016)

O estudo realizado por Sanders (2016) também define que a análise de *Big data* tem um potencial transformador para o gerenciamento da Cadeia de Suprimentos e destaca três pontos importantes para o sucesso de implementação de dados analíticos do *Big data* na Cadeia de Suprimentos, que são: 1) Esforços devem ser dirigidos para apoiar a estratégia da empresa ao invés de esforços aleatórios de exploração; 2) Utilização de aplicativos em todas as funções da Cadeia de Suprimentos de forma coordenada ao invés de otimizar apenas uma função; 3) Medição do desempenho através de métricas cuidadosamente selecionadas e usadas para melhoria contínua, orientando ainda mais seus esforços analíticos. A Figura 3 demonstra este ciclo de melhoria contínua e quais são as principais ações a serem tomadas para que se obtenha sucesso nesta implementação.

Figura 3: Ciclo potencial Transformador da Cadeia de Suprimentos



Fonte: adaptado pela autora de Sanders, (2016)

Em um modo geral, entende-se nesta seção o impacto que o uso dos dados do *Big data* pode trazer para a Cadeia de Suprimentos e quais são as principais ações para a implementação de um ciclo de melhoria contínua na Cadeia de Suprimentos nas quatro principais atividades, que são, Compra, produção, Movimentação e Vendas. Na próxima seção, falaremos especificamente do impacto do uso de dados *Big data* na área de Compras.

2.4.3 Impacto do *Big data* em Compras

De acordo com Leenders et al. (2010), os aplicativos de análise estão se tornando cada vez mais importantes na área de Compras e são os que mais crescem. Considerando que, na maioria das organizações de manufatura, Compras representa a maior categoria de gastos para a empresa, variando de 50 a 90% da receita, o potencial de economia com a utilização dos dados de *Big data* é considerável.

Várias empresas informam que usam a análise de dados para otimizar as opções de canal de Compras e integrar fornecedores em suas próprias operações. Algumas aplicações segmentam fornecedores com base em características-chave, ajudando na estratégia de terceirização e equilibrando custo versus risco (SANDERS, 2016). A Amazon, por exemplo, usa análise para determinar a estratégia de terceirização ideal e gerenciar toda a logística para entregar um produto diretamente do fabricante ao cliente final. As análises são usadas para determinar a combinação certa de reposição conjunta, reposição coordenada e abastecimento único. Na verdade, a Amazon aplica análises avançadas em todas as suas funções de cumprimento, expansão de capacidade, gerenciamento de estoque, aquisição e logística, a fim de coordenar todos os processos de gerenciamento da Cadeia de Suprimentos (STONE, 2010).

O *Google Analytics* também pode ser usado para oferecer suporte às negociações dos fornecedores, fornecendo uma análise completa das preferências dos clientes e dos comportamentos de compra. Esta informação pode ser usada para informar as negociações com os fornecedores, fornecendo alavancagem factual. Por exemplo, as empresas podem usar informações sobre preços e transações para negociar concessões sobre produtos-chave. Por fim, a análise está sendo usada para o gasto final, automatizando o processo de gerenciamento dessa categoria, já que as empresas reconhecem cada vez mais seu valor monetário considerável.

A literatura acadêmica sobre o impacto de dados analíticos para área de Compras ainda é escassa, sendo basicamente abordada como um apêndice dos impactos e aplicações do *Big data* na Cadeia de Suprimentos, e não avaliada como ente único. Um estudo recente, realizado por Bouleye, Riedstra e Spiller (2016), apresentou quais seriam as ferramentas adequadas a uma implantação e quais áreas seriam afetadas, e também faz uma correlação entre estas ferramentas e potenciais impactos na organização.

As aplicações digitais que farão diferença real no desempenho da área de Compras de uma empresa se dividem em duas grandes áreas: ferramentas que identificam e criam valor

e ferramentas que evitam desperdício de valor, que demonstra não só quais são estas ferramentas mas também os 12 principais indicadores de performance da área poderiam ser gerenciados por elas, que variam do impacto da área no resultado da empresa, passando por um raio x completo dos fornecedores e seus indicadores, através de um *dashboard*.

Estas ferramentas são divididas em dois grandes blocos:

- 1) Ferramentas que identificam e criam valor: estas ferramentas por sua vez são subdivididas em a) Visibilidade de gastos e b) Compras Avançadas e Colaborativas;
- 2) Ferramentas que evitam desperdício: também subdivididas em 2 subcategorias: a) Sistema de Informação de pagamento da compra e b) gerenciamento de performance.

Ainda de acordo com o relatório da McKinsey (2016), estas 12 ferramentas trarão uma contribuição significativa para três importantes dimensões, que são a efetividade, eficiência e sustentabilidade da área e do negócio, muitas vezes conseguindo melhorar mais do que uma construto apenas, de acordo com o quadro 2.

Quadro 2: Áreas impactadas positivamente pela implementação das ferramentas que criam e evitam desperdícios de valor em compras

		Áreas de Impacto		
		Efetividade	Eficiência	Sustentabilidade
Visibilidade de gastos	1 Inteligência de gastos avançada e insights de fornecimento automatizado	✓		
Compras colaborativa e avançada	2 Portal de fluxo de trabalho de categoria	✓		✓
	3 Soluções analíticas de categoria	✓	✓	✓
	4 Folha em branco e prováveis análises de custos	✓		✓
	5 Portais para colaboração em negócios	✓	✓	✓
	6 Qualificação e seleção de fornecedores: raio X de fornecedores			✓
	7 Eventos de compras eletrônicos: e-RFX, e-catalogos, e-leilões		✓	
	8 Plataformas de colaboração com fornecedores	✓		✓
Sistema de Informação da Compra ao pagamento	9 Fluxos de Processos para P2P		✓	
	10 Gerenciamento de compliance automatizado		✓	
Gerenciamento de Performance	11 Scorecards de desempenho de fornecedores			✓
	12 Scorecards de desempenho da área de Compras			✓

Fonte: Adaptado pela autora, de McKinsey Digital Procurement Service Line (2016)

Não são todas as soluções apresentadas que se adequam a todas as empresas. Para decidir qual é a ideal, é preciso que as empresas entendam o valor proposto por cada uma delas e a aderência das mesmas aos seus processos e times, para que o benefício da utilização destas ferramentas de *Big data* seja potencializado e traga retorno ao investimento.

3. METODOLOGIA

Este capítulo tem como objetivo esclarecer qual a metodologia de pesquisa e a proposta de aplicação para este projeto. O tipo de pesquisa adotada neste projeto é a descritiva, que, de acordo com Forza, (2002), visa entender a relevância de um determinado fenômeno e descrevendo a distribuição do fenômeno em uma população. Seu objetivo principal não é o desenvolvimento da teoria, embora através dos fatos descritos pode fornecer dicas úteis tanto para a construção da teoria ou o refinamento teórico (DUBIN, 1978 apud FORZA, 2002).

3.1 Instrumento de Pesquisa

O estudo foi realizado com dados coletados por meio de questionário tipo *survey* (FORZA, 2002). Segundo Barbosa (1999), o questionário é um dos procedimentos mais utilizados para obter informações e de elevada confiabilidade se aplicado com critério. A escala utilizada para este questionário é a de cinco pontos de Likert, que seria um tipo de escala de resposta psicométrica usada habitualmente em questionários. Ao responderem a um questionário baseado nesta escala, os respondentes especificam seu nível de concordância com uma afirmação, sendo que o formato utilizado nesta pesquisa tem seis escalas, variando de (1) discordo totalmente, até a escala (5), Concordo totalmente. A sexta escala (6) se refere a resposta Não se Aplica, no caso da questão não ser relevante ou não fazer parte do universo do respondente.

O questionário foi elaborado e dividido em construtos com base no artigo de Akter et al. (2016), que aborda como melhorar o desempenho das empresas e alinhar a estratégia de negócios com a utilização de *Big data*, e adaptada pelo Observatório de Compras da Escola de Administração de Empresas de São Paulo (EAESP) da Fundação Getúlio Vargas para a atuação na área de Compras. O questionário completo contempla 61 questões, as quais consideram outras dimensões do uso de *Big data*. Para o presente estudo e de forma a atender os objetivos de pesquisa, 31 questões foram selecionadas e utilizadas nesta análise pela autora.

As questões apresentadas aos respondentes foram agrupadas em oito diferentes dimensões, para um melhor entendimento das respostas e possíveis conclusões, baseadas em aspectos relevantes da capacidade analítica do *Big Data* e a área de Compras das organizações. O quadro 3 relata as questões utilizadas durante o questionário bem como a

referência teórica em cujas questões foram baseadas e faz uma amarração quanto aos construtos e seus objetivos.

Quadro 3 – Matriz de amarração entre construtos, seus objetivos e questões e fontes acadêmicas

Objetivo Geral		Problema de Pesquisa		Questões e Referencias na Literatura	
Entender o grau de utilização, conhecimento e benefícios percebidos pelos respondentes sobre o uso de <i>Big data</i> nas organizações, principalmente na área de Compras.		A análise de dados complexos tem sido explorada em Compras e há um reconhecimento de valor em seu uso?		Descrição das perguntas contidas no questionários e suas respectivas referências na literatura acadêmica	
Objetivo Especifico	Fonte	Construto	Questões	Perguntas	Fontes
Identificar a percepção dos respondentes sobre como as áreas de Compras estão utilizando os dados do <i>Big data</i>	Questionário	1 - Como usamos o <i>Big data</i>	USO1	Nesta organização, temos muitos dados, mas não estão facilmente acessíveis para Compras	Akter et al. (2016); Davis (1989); Schoenherr & Speier Pero (2015)
			USO2	Eu acredito que usando <i>Big data</i> eu posso tomar melhores decisões em Compras	
			USO3	É claro para mim como coletar dados complexos para tomar decisões em Compras	
			USO4	Nesta organização, temos dados estruturados em em tempo real para tomar decisões	
			USO5	Não compreendo como usar <i>big data</i> na minha rotina diária	
			USO6	Em nossa área de Compras os critérios de desempenho são claros	
Identificar a percepção dos respondentes sobre como planejamos a utilização do <i>Big data</i>		2 - Planejamento	PLAN1	Nesta organização, examinamos continuamente as oportunidades inovadoras para o uso estratégico de <i>big data</i>	Akter et al.(2016); Kim, Shin & Kwon (2012); Byrd, & Turner (2000)
			PLAN2	Realizamos planos adequados para a introdução e utilização de análise de <i>Big data</i> em Compras	
			PLAN3	Realizamos um planejamento para análise de <i>Big data</i> de forma sistemática e formalizada	
Identificar a percepção dos respondentes sobre compartilhamento de informação		3 - Coordenação	COOR1	Em nossa organização, analistas de negócios e pessoas de Compras se reúnem frequentemente para discutir questões importantes de formal e informalmente	
			COOR2	Em nossa organização, analistas de negócios e pessoas de vários departamentos frequentemente participam de reuniões multifuncionais	
			COOR3	Em nossa organização, a informação é amplamente compartilhada entre analistas de negócios e pessoas de Compras para que tenham acesso a todos os conhecimentos disponíveis para desenvolvimento de seus trabalhos	
Identificar a percepção dos respondentes sobre responsabilidade de dados		4 - Controle	CTRL1	Em nossa organização, a responsabilidade pelo desenvolvimento da analise de dados complexos é clara	
Identificar a percepção dos respondentes sobre conexão de dados		5 - Conectividade	CONE1	Comparando com nossa concorrência, nossa organização possui um dos melhores sistemas de análises de <i>Big data</i> disponível	
			CONE2	Se estiver fora da organização, em visita a fornecedores por exemplo, eu tenho acesso remoto aos dados conectados ao escritório central	

Objetivo Especifico	Fonte	Construto	Questões	Perguntas	Fontes
Identificar a percepção dos respondentes sobre o conhecimento dentro da organização sobre analise de <i>Big data</i>	Questionário	6 - Conhecimento	CONH1	Nosso pessoal de análise de dados em Compras possui um alto conhecimento de programação	Akter et al.(2016); Kim, Shin & Kwon (2012); Byrd, & Turner (2000)
Identificar a percepção dos respondentes sobre o alinhamento da analise de dados com a estratégia da organização			CONH2	Nosso pessoal de análise de dados em Compras mostra uma compreensão superior das tendências tecnológicas	
			CONH3	Nossa equipe de análise de dados em Compras compreende nossas políticas e plano organizacionais em níveis muito altos	
			CONH4	Nosso pessoal de análise de dados em Compras é muito bem informado sobre o ambiente de negócios	
		7 - Alinhamento	ALIN1	O plano de análise de dados em Compras alinha-se com a missão, objetivos e estratégia da empresa	
ALIN2			O plano de análise de dados em Compras contém metas e objetivos quantificados		
ALIN3			O planejamento de análise de dados contém planos de ação detalhados que apoiam a direção da empresa		
ALIN4			Priorizamos os principais investimentos am análise de <i>Big data</i> pelo impacto esperado no desempenho do negócio		
Identificar a percepção dos respondentes sobre os resultados e beneficios da utilização de <i>Big data</i> na área de Compras nos últimos 3 anos		8 - Resultados da utilização de <i>Big data</i>	RESU1	Considerando os últimos 3 anos, eu aprendi a analisar dados complexos	Akter et al.(2016); Caniato, Luzzini & Ronchi (2014)
			RESU2	Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras melhorou a qualidade geral dos fornecimentos	
			RESU3	Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras melhorou a acuracidade de entrega dos fornecedores	
			RESU4	Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras contribuiu para redução de custos em Compras	
	RESU5		Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras reduziu os riscos de fornecimento em geral		
	RESU6		Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras melhorou a velocidade de atendimento ao requisitante interno		
	RESU7		Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras melhorou a previsibilidade e planejamento em Compras		
	RESU8		Considerando os últimos 3 anos, a análise do <i>Big data</i> em Compras trouxe maior governança ao processo de Compras		

Fonte: elaborado pela autora (2018)

3.2 Seleção da amostra e Coleta de dados

Os dados foram coletados através de uma *survey*, com executivos brasileiros da área de Compras de diversos segmentos, através da rede de contatos do Observatório de Compras do CELOG (Centro de Excelência em Logística e Supply Chain) da EAESP/FGV. A escolha por direcionar o questionário a executivos em Compras se dá devido à opinião de especialistas no tema geralmente ser a melhor fonte para questão de pesquisas (VAN WEELE; RAAIJ, 2014). Os dados coletados foram os respondidos entre os dias 16 de Março e 27 de Abril de 2018, totalizando 270 respondentes. Deste total, apenas 220 responderam 100% das perguntas e os que trabalhavam no Setor Industrial totalizavam 131 respondentes.

Devido a número de dados faltantes (*missing data*), foi definido que respondentes cujo percentual de dados faltantes fosse superior a 20% fossem desconsiderados, o que reduziu o número de respondentes de 131 para 94, conforme resumido na Tabela 1. A inexistência de padrão configura um nível de aleatoriedade que pode ser considerado “completamente perdido ao acaso” (HAIR et al., 2009). Os dados faltantes dos demais respondentes foram estimados pela média das respostas da respectiva questão.

Tabela 1: Resumo das respostas

Total de Respondentes	270
Total com 100% de respostas	220
Setor Industrial	131
Setor Industrial com menos de 20% de N/A	94

Fonte: tabela criada pela autora a partir dos dados do questionário (2018)

O perfil dos respondentes, de acordo com as informações coletadas, demonstrado na Tabela 2, é diversificado e engloba respondentes de várias faixas etárias, diferentes posições hierárquicas, variadas formações acadêmicas e foi subdividido em sete sub-categorias que são: Gênero, Faixa etária, Formação Acadêmica, Grau de Instrução, Posição Hierárquica, Tipo de Indústria em que atua e Tamanho da empresa, considerando número de funcionários. Estas sub-categorias foram criadas para que se agrupasse determinados tipos de respondentes e se verificasse a existência ou não de um maior número de respondentes dentro de algum segmento.

A maioria dos respondentes é do sexo masculino (72,3%), tem entre 31 e 40 anos (51.1%), tem formação em Administração de empresas (53,2%), tem pós-graduação ou MBA (66%) e trabalha em empresas que tem mais de 1.000 colaboradores (58,5%).

Tabela 2: Perfil dos respondentes

Perfil dos respondentes		
Variável	Frequencia	%
Genero		
Feminino	26	27,7%
Masculino	68	72,3%
Idade		
20-30 anos	9	9,6%
31-40 anos	48	51,1%
41-50 anos	18	19,1%
Acima de 50 anos	19	20,2%
Formação		
Administração e afins	50	53,2%
Engenharia e Afins	36	38,3%
Relações Internacionais	2	2,1%
Logística	2	2,1%
Comercio Exterior	2	2,1%
Secretariado	1	1,1%
Agropecuária	1	1,1%
Grau de Educação		
Ensino Médio Completo	2	2,1%
Superior Completo	25	26,6%
MBA ou Especialização	62	66,0%
Mestrado	4	4,3%
Doutorado	1	1,1%
Posição Hierarquica		
CPO/Diretor ou similar	12	12,8%
Gerente ou similar	19	20,2%
Supervisor ou similar	31	33,0%
Comprador ou similar	31	33,0%
Business Development	1	1,1%
Indústria		
Quimica/Farmaceutica	22	23,4%
Base	10	10,6%
Eletro/Eletronico/Branca	6	6,4%
Automotiva	33	35,1%
Alimentos	18	19,1%
Aeroespacial	1	1,1%
Embalagens	2	2,1%
Confecção	1	1,1%
Papeleira	1	1,1%
Número de empregados da empresa (tamanho)		
0-100	4	4,3%
101-500	20	21,3%
501-1000	15	16,0%
1.000 +	55	58,5%

Fonte: Tabela criada pela autora, com dados do questionário (2018)

4. ANÁLISE DE DADOS

Os dados quantitativos, antes de serem processados e analisados, têm pouco significado à maioria das pessoas. Esses dados precisam, portanto, serem processados para que sejam úteis, quando transformados em informação (REATEGUI, 2018). De acordo com Saunders, Lewis e Thornhill (2009), técnicas de análise quantitativa como gráficos, tabelas e estatísticas nos permitem compreender, ajudando a explorar, apresentar, descrever e examinar relações e tendências dentro de dados.

4.1 Análise descritiva

O objetivo da análise descritiva é resumir as principais características de um conjunto de dados por meio de tabelas, gráficos e resumos numéricos (GUIMARÃES, 2008). Para a análise das respostas foi utilizada estatística descritiva, através do cálculo de médias, medianas, mínimos e máximos e desvio padrão, atribuindo-se uma pontuação de 1 a 5 pontos, escala *Likert*, considerando 5 pontos para aqueles que assinalaram a resposta concordo totalmente, 4 pontos para os que assinalaram concordo parcialmente, 3 pontos para os que não concordam nem discordam, 2 pontos para aqueles que assinalaram que discordam parcialmente e 1 ponto para os que discordam totalmente.

Neste estudo foram utilizadas as medidas de Posição ou de Tendência Central, que visam determinar o centro de distribuição dos dados observados através de: 1) Média aritmética, que é a soma de todos os valores da variável, dividida pela frequência total (número total de observações); 2) Mediana: é a realização que ocupa a posição central da série de observações quando estas estão ordenadas segundo suas grandezas $((n+1)/2)$; 3) Moda, que é o valor da variável que corresponde à frequência máxima, isto é, é o valor mais frequente; 4) Mínimo: trata-se do valor mínimo pontuado no questionário e 5) Máximo, que é o valor máximo de pontuação dado ao questionário (SWEENEY; WILLIAMS; ANDERSON, 2013).

Outra medida utilizada para a análise descritiva dos dados foi a de Dispersão, que visa indicar o quanto os dados se apresentam dispersos em torno da região central, que caracterizam, portanto, o grau de variação (variabilidade) existente no conjunto de dados, através do cálculo de desvio padrão que calcula a diferença entre cada valor e a média aritmética da distribuição.

Os resultados da análise estatística descritiva são apresentados no Tabela 3. Todos os indicadores referem-se às respostas dos 94 respondentes considerados. A média mais alta

encontrada foi de 4,35 na Questão USO2 (Eu acredito que usando *Big data* eu posso tomar melhores decisões em Compras) e a menor 2,23 na USO5 (Não compreendo como usar *Big data* na minha rotina diária), o que já era esperado, já que se trata de uma questão invertida.

Analisando o resultado das medianas, vê-se que a grande maioria se concentra em 4 e 3, com apenas uma ocorrência em 5 (na questão USO2 – Eu acredito que usando *Big data* eu posso tomar melhores decisões em Compras) e em 2 (na questão USO5 – Não compreendo como usar *Big Data* na minha rotina diária), sem nenhuma ocorrência em 1. Como mínimo e máximo, em todas as questões têm-se respondentes que discordam totalmente das afirmações (pontuação 1) e os que concordam totalmente (pontuação 5).

Na análise por desvio padrão encontra-se o menor desvio 0,78 na questão USO2 (Eu acredito que usando *Big data* eu posso tomar melhores decisões em Compras) e o maior desvio (1,57) na questão CONE2 (Se estiver fora da organização, em visita à fornecedores, por exemplo, eu tenho acesso remoto aos dados conectados ao escritório central). Isso pode significar que esta questão obteve um maior número de respostas distante da média.

Tabela 3 – Resultados da análise estatística descritiva dos dados dos respondentes por questão

Construto	Questões	Média	Mediana	Moda	Desvio padrão
Como usamos o Big Data	USO1	3,22	4	4	1,28
	USO2	4,35	5	5	0,78
	USO3	3,83	4	4	1,20
	USO4	3,10	4	4	1,33
	USO5	2,23	2	1	1,25
	USO6	3,85	4	5	1,27
BDC Planejamento	PLAN1	3,07	3	4	1,33
	PLAN2	2,98	3	4	1,28
	PLAN3	2,85	3	4	1,34
BDC Coordenação	COOR1	3,54	4	4	1,35
	COOR2	3,53	4	4	1,27
	COOR3	3,40	4	4	1,34
BDC Controle	CTRL1	3,20	4	4	1,33
BDC Conectividade	CONE1	2,80	3	4	1,26
	CONE2	3,63	4	5	1,57
BDC Conhecimento	CONH1	2,79	3	4	1,27
	CONH2	2,90	3	2	1,08
	CONH3	3,41	4	4	1,14
	CONH4	3,34	4	4	1,11
BDC Alinhamento Estratégico	ALIN1	3,83	4	5	1,17
	ALIN2	3,62	4	4	1,30
	ALIN3	3,43	4	4	1,28
	ALIN4	3,09	3	4	1,17
Resultados	RESU1	3,80	4	4	0,95
	RESU2	3,78	4	4	1,05
	RESU3	3,58	4	4	1,05
	RESU4	4,02	4	4	1,02
	RESU5	3,71	4	4	1,05
	RESU6	3,68	4	4	1,09
	RESU7	3,85	4	4	1,07
	RESU8	3,92	4	4	1,06

Fonte: elaborado pela autora, à partir dos dados da pesquisa (2018)

4.2 Inspeção Univariada de *Outliers*

Segundo Figueira (1998), *Outlier* é caracterizado pela sua relação com as restantes observações que fazem parte da amostra. O seu distanciamento em relação a essas observações é fundamental para se fazer a sua caracterização.

Neste estudo específico, fez-se o cálculo de *Outliers* dos oito construtos considerados, considerando a soma das questões em cada construto, ao invés de simplesmente as médias, por conta do caráter subjetivo de se classificar nos intervalos internos e não considerar só os extremos e o resultado da análise está na Tabela 4.

Tabela 4: Resultado na Inspeção Univariada de *Outliers*

	USO	PLANEJAMENTO	COORDENAÇÃO	CONTROLE	CONECTIVIDADE	CONHECIMENTO	ALINHAMENTO	RESULTADO
MÉDIA	20,58	8,90	10,47	3,20	6,42	12,44	13,96	26,54
QUARTIL 1	19,00	6,00	8,00	2,00	5,00	10,00	11,75	24,75
QUARTIL 3	22,00	12,00	13,00	4,00	8,00	15,84	17,00	30,01
IQR	3,00	6,00	5,00	2,00	3,00	5,84	5,25	5,26
LIMITE SUPERIOR (LS)	25,08	17,90	17,97	6,20	10,92	21,21	21,84	34,43
LIMITE INFERIOR (LI)	16,08	-0,10	2,97	0,20	1,92	3,67	6,09	18,66
Nº OUTLIERS LS	3	0	0	0	0	0	0	8
Nº OUTLIERS LI	5	0	0	0	0	0	5	8
NOVA MÉDIA	20,78						14,49	27,17
DIFERENÇA MÉDIAS	1%						4%	2%

Fonte: elaborada pela autora à partir dos dados de pesquisa (2018)

Com base nos resultados encontrados, entende-se que existem *Outliers* encontrados em apenas 3 dos 8 construtos e que a comparação das médias calculadas com e sem *Outliers* são muito próximas, sendo as suas diferenças de 1% no construto Uso, 4% no construto Alinhamento e 2% no construto Resultado, e, portanto, não altera significativamente os achados, o que fez com que os dados não fossem desconsiderados.

4.3 Matriz de Correlação

A matriz de correlação mostra os valores de correlação de Pearson, que medem o grau de relação linear entre cada par de itens ou variáveis. Os valores de correlação podem cair entre -1 e +1 (REIS, 1994).

Valores de correlação altos e positivos indicam que os itens medem a mesma habilidade ou característica. Se os itens não estão altamente correlacionados, os itens podem medir diferentes características ou podem não estar claramente definidos. De acordo com Loesch e Hoeltgebaum (2012), quanto mais o coeficiente R^2 aproximar-se de 1, mais próximos os pontos estarão situados ao lugar geométrico determinado pela equação de regressão. Autores como Mukaka (2012) e Dancey e Reidy (2006) costumam qualificar a correlação de acordo com o intervalo em que seu valor absoluto fica situado, sendo acima de

0,70 uma correlação forte, entre 0,30 e 0,70 uma correlação moderada e abaixo de 0,30 indica uma correlação fraca.

Os resultados encontrados nos testes de correlação entre os construtos demonstram que a correlação entre eles não é alta, já que nenhum dos resultados encontrados está acima de 0,7, conforme Tabela 5.

Tabela 5: Matriz de Correlação

	USO	PLAN	COOR	CTRL	CONE	CONH	ALIN	RESU
USO	1,0000							
PLAN	0,4972	1,0000						
COOR	0,4577	0,6341	1,0000					
CTRL	0,5307	0,6589	0,6040	1,0000				
CONE	0,4020	0,5840	0,4305	0,3957	1,0000			
CONH	0,4921	0,6403	0,5023	0,5540	0,5528	1,0000		
ALIN	0,4970	0,6380	0,6164	0,5916	0,4985	0,6949	1,0000	
RESU	0,4083	0,4387	0,3966	0,4204	0,3538	0,4420	0,4985	1,0000

Fonte: elaborado pela autora a partir dos dados de pesquisa (2018)

4.4 Análise exploratória dos dados

4.4.1 Comparação de médias

Para entender como as populações, dentro das dimensões do perfil de respondentes responderam afirmativamente às questões e compará-las entre si, decidiu-se aplicar o teste de comparação, de duas amostras, independentes, com as médias populacionais para os grandes cinco construtos (Uso, Capacidade Gerencial, Conhecimento Técnico, Alinhamento e Resultados), sub-agrupando as dimensões sempre em duas categorias de respondentes conforme Quadro 4.

Quadro 4 - Resultados das Análises Estatísticas descritivas para amostras de grupos de respondentes por construto agrupado

	Número respondentes	% Total	USO		Cap Gerencial		Cap Técnica		Alinhamento		Resultado	
			Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
<i>Gênero</i>												
Masculino	68	72,34%	3,51	0,45	3,46	0,80	3,29	0,88	3,62	0,97	3,83	0,78
Feminino	26	27,66%	3,21	0,53	2,77	0,82	2,82	0,92	3,16	1,04	3,71	0,88
<i>Faixa Etária</i>												
até 37 anos	45	47,87%	3,37	0,54	3,12	0,84	3,07	0,91	3,35	1,05	3,91	0,70
acima de 37 anos	49	52,13%	3,48	0,43	3,41	0,86	3,24	0,92	3,62	0,95	3,68	0,88
<i>Formação Acadêmica</i>												
Humanas	58	61,70%	3,37	0,55	3,14	0,92	3,12	0,98	3,39	1,04	3,72	0,88
Exatas	36	38,30%	3,53	0,35	3,49	0,72	3,22	0,80	3,65	0,94	3,92	0,66
<i>Grau de Instrução</i>												
Até Superior Completo	27	28,72%	3,30	0,47	3,06	0,96	2,98	1,03	3,12	1,21	3,60	0,86
de MBA a Doutorado	67	71,28%	3,48	0,49	3,35	0,81	3,23	0,86	3,64	0,87	3,87	0,77
<i>Posição Hierárquica</i>												
Colaborador	32	34,04%	3,34	0,60	3,11	0,93	2,78	0,84	3,23	0,95	3,81	0,75
Liderança	62	65,96%	3,47	0,42	3,35	0,82	3,35	0,90	3,63	1,00	3,78	0,84
<i>Tamanho de Empresa</i>												
até 1.000 funcionários	39	41,49%	3,27	0,54	3,05	0,90	3,06	0,96	3,25	1,04	3,74	0,83
> de 1.000 funcionários	55	58,51%	3,55	0,41	3,42	0,80	3,23	0,88	3,66	0,95	3,83	0,79

Fonte: elaborado pela autora, a partir dos resultados de pesquisa (2018)

O teste escolhido para esta análise é o Teste t de *Student*, que é um teste de hipótese que usa conceitos estatísticos para rejeitar ou não uma hipótese nula quando a estatística de teste (t) segue uma distribuição t de *Student*. Este teste se aplica a planos amostrais quando o objetivo é comparar duas populações quanto a uma variável quantitativa, é muito comum que os pesquisadores não conheçam os parâmetros de nenhuma delas, isto é, sejam desconhecidas as médias (μ) e também os desvios padrão (σ) populacionais; cuja fórmula é:

Figura 4: Fórmula Teste T de Amostras Independentes

$$\text{Teste T de Amostras Independentes} = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{s^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

Fonte: adaptado pela autora de Sweeney, Williams e Anderson (2013)

Onde:

X1 = Média aritmética da amostra 1; X2 = Média aritmética da amostra 2

s1 = Desvio padrão da amostra 1; s2 = Desvio padrão da amostra 2

N1 = Número de casos da amostra 1; N2 = Número de casos da amostra 2

GL = Graus de Liberdade = [(N1 + N2) - 2]

Teste bicaudal (2Q , na Tabela)

O resultado da aplicação do Teste t, com uma significância de 5%, considerando o valor de diferenças entre as médias de 0, é visto na Tabela 6. Não se realizou o teste na dimensão Tipo de Empresa por não ser possível agrupar os subgrupos em apenas dois grupos amostrais por ter-se muitas respostas diversas.

Tabela 6: Resultado bicaudal da análise de Teste t entre as duas amostras de cada dimensão

Resultado bicaudal entre as duas amostras de cada variável						
CONSTRUTO	Gênero	Faixa Etária	Formação	Grau de Escolaridade	Posição Hierárquica	Tamanho Empresa
USO	0,015	0,265	0,080	0,110	0,275	0,009
CAPACIDADE GERENCIAL	0,001	0,094	0,040	0,163	0,218	0,044
CAPACIDADE TECNICA	0,027	0,375	0,577	0,273	0,031	0,367
ALINHAMENTO ESTRATÉGICO	0,054	0,190	0,215	0,051	0,064	0,051
RESULTADO	0,055	0,160	0,215	0,156	0,886	0,615
$p > 0,05$						

Fonte: elaborado pela autora a partir dos dados da pesquisa

Os resultados obtidos na análise realizada em excel, entre grupos de respondentes por construtos, separados por dois grupos amostrais, utilizando o Test t, onde os valores encontrados, para demonstrar que são diferentes entre si, devem-se encontrar abaixo de 0,05, tem-se:

- Dimensão Gênero: nesta dimensão, nos construtos Uso, Capacidade Gerencial e Capacidade Técnica, vê-se que não existe uma igualdade nas respostas, o que demonstra uma desigualdade entre as amostras 1 (grupo de respondentes do sexo masculino) e 2 (grupo de respondentes do sexo feminino), sendo o grupo do sexo masculino mais positivo em relação às afirmações do questionário.
- Dimensão Faixa Etária: neste teste, os números encontrados estão acima do limite de variância: 0,05. Portanto, conclui-se que não existem diferenças importantes entre as respostas dos dois grupos de amostra (respondentes com faixa etária abaixo ou igual a 37 anos e os acima de 37 anos).
- Dimensão Formação: neste grupo amostral encontram-se diferenças nas respostas em concordância do grupo de respondentes em dois construtos que são Uso e Capacidade Gerencial, onde o grupo amostral que tem sua formação na área de Humanas é mais positivo em relação às afirmações em comparação com o grupo amostral 2, que tem sua formação base na área de Ciências Exatas.

- d) Dimensão Grau de Escolaridade: nesta análise os grupos amostrais foram divididos entre os que têm até Nível de Ensino Superior e aqueles que têm MBA, Especialização, Mestrado e Doutorado e o resultado do Test T em todos os construtos demonstra que não existem diferenças entre as respostas dos dois grupos.
- e) Dimensão Posição Hierárquica: somente no Construto Conhecimento Técnico vê-se uma distinção entre as afirmações dos dois grupos amostrais, sendo que os líderes (Supervisores, Gerentes e Diretores de Compras) entendem que as empresas em que atuam têm pessoas capacitadas para extrair e analisar dados do *Big data*.
- f) Dimensão Tamanho de Empresa: neste teste os respondentes foram divididos em dois grupos, os que trabalham em empresas com até 1.000 funcionários e os que trabalham em empresas com mais de 1.000 funcionários e os resultados encontrados foram que, nos construtos Uso e Capacidade gerencial, o grupo de respondentes que trabalham em empresas acima de 1.000 funcionários é mais positivo em relação aos dados do *Big data*.

4.4.2. Verificação de possíveis relações causais

Em estatística, regressão linear é uma equação para se estimar a condicional (valor esperado) de uma variável y , dados os valores de algumas outras variáveis x . A regressão, em geral, tem como objectivo tratar de um valor que não se consegue estimar inicialmente. A regressão linear é chamada "linear" porque se considera que a relação da resposta às variáveis é uma função linear de alguns parâmetros (REIS, 1994). A fórmula para cálculo manual da regressão linear é:

Figura 5: Fórmula de regressão linear

$$\boxed{y = ax + b} \quad a = \frac{\sum xy - n\bar{x}\bar{y}}{\sum x^2 - n(\bar{x})^2}$$

$$b = \bar{y} - a\bar{x}$$

Fonte: adaptado pela autora de Sweeney, Williams e Anderson (2013)

Neste trabalho a utilização da regressão linear é devido à necessidade de correlacionar as respostas obtidas nos construtos entre si, para a conclusão ou não da importância dos conhecimentos técnicos ou gerenciais e do alinhamento estratégico das organizações com o uso de dados complexos de *Big data* e na visão dos respondentes nos resultados obtidos nos últimos três anos.

Para a análise e correlação entre as BDAC descritas por Akter (2016), os construtos foram agrupados em: 1) Uso (que compreende o construto Como usamos o *Big data*); 2) Capacidade gerencial (com a integração dos construtos Planejamento, Coordenação e Controle); 3) Conhecimento Técnico (integração dos construtos Conectividade e Conhecimento); 4) Alinhamento Estratégico e 5) Resultados. Este agrupamento foi embasado na literatura, onde as variáveis já foram validadas em estudos anteriores (AKTER, 2016), considerando-se assim desnecessário o desenvolvimento de testes confirmatórios. Foi então aplicada uma regressão linear, conforme Tabela 7 e onde os construtos foram comparados entre si.

Tabela 7: Coeficiente R² de comparação entre os construtos agrupados

Construto	Resultado R ²	
	USO	RESULTADO
Capacidade Gerencial	0,440	0,247
Conhecimento Técnico	0,253	0,2
Alinhamento	0,247	0,249
USO	-	0,167
Resultado	0,167	-

Fonte: Elaborado pela autora a partir dos dados da pesquisa (2018)

Buscou-se avaliar a relação entre o uso de *Big data* e os resultados percebidos nos últimos três anos e as dimensões Capacidade Gerencial, Conhecimento Técnico e Alinhamento. Apesar desses construtos já estarem previamente validados na literatura, não foi possível identificar resultados significativos. Dessa forma, decidiu-se analisar as dimensões de primeira ordem diretamente. Assim, comparou-se “o uso de *Big data*” com os demais 7 construtos, bem como o construto “Resultados” com os demais. Os resultados obtidos demonstram que, mesmo em comparação com as dimensões de primeira ordem, não existe correlação significativa entre eles, conforme Tabela 8.

Tabela 8: Resultado R² de comparação entre os construtos de primeira ordem

Construto	Resultado R ²	
	USO	RESULTADO
Planejamento	0,247	0,192
Coordenação	0,209	0,157
Controle	0,282	0,177
Conectividade	0,162	0,125
Conhecimento	0,242	0,195
Alinhamento	0,247	0,249
USO	-	0,167
Resultado	0,167	-

Fonte: elaborado pela autora a partir dos dados da pesquisa (2018)

Analisando-se os resultados encontrados no teste de regressão linear entre os construtos, para avaliar se existe correlação entre eles, seja de modo agrupado ou utilizando os construtos de primeira ordem, não se encontra correlação significativa entre as respostas de cada construto, já que o resultado mais alto é de 0,44 na análise dos construtos USO x Capacidade Gerencial. Neste tipo de teste estatístico, quanto maior o percentual encontrado, com a proximidade ao número 1, maior a correlação entre eles.

Isso demonstra que não existe uma relação imediata no modo em que os dados do *Big data* são utilizados, em relação a como estes dados estão correlacionados entre si, com base na literatura citada no referencial teórico.

5. PROPOSTA DE RELATÓRIO GERENCIAL

Como produto do presente estudo, pretende-se apresentar, em um formato gerencial, a apreciação dos resultados da análise do questionário. A análise dos dados, para este relatório gerencial, foi realizada de modo a entender em termos percentuais, como os respondentes visualizam o uso do *Big data* e seus impactos nas organizações, bem como o quanto o uso do *Big data* está alinhado com a estratégia das organizações, o nível de conhecimento dos principais usuários e o resultado da utilização deste recurso nos últimos três anos, considerando o percentual de respostas em concordância total ou parcial com as afirmações do questionário. O quadro completo com o número absoluto e percentual dos respondentes por questão, na distribuição da escala, está no Apêndice A deste trabalho.

Para melhor entendimento deste Relatório Gerencial, por parte dos respondentes, re-nomeamos os construtos por seção, sendo que o agrupamento das questões, nestas seções continua o mesmo em relação ao apresentado no Trabalho Aplicado.

De modo geral, vê-se que a grande maioria dos respondentes (87%) acredita que a utilização de dados do *Big data* pode ajudar a organização a tomar decisões mais assertivas e 81% afirmam que a utilização do *Big data* nos últimos três anos na área de Compras contribuiu para redução em custos. Por outro lado, apenas 36% dos respondentes acreditam que suas organizações trabalham com estes dados melhor do que seus concorrentes e somente 34% afirmam que seus especialistas em análise de dados estão preparados ou conhecem mais profundamente as tendências tecnológicas.

A dimensão com maior percentual de respondentes em concordância com as afirmações do questionário é o de Resultados, aonde vê-se que 72% identificam benefícios e melhorias nos principais indicadores de desempenho da área de Compras nos últimos três anos, com a utilização de *Big data*.


5.1 Entendimento do uso de *Big data* pelos respondentes

O percentual médio de respondentes para em todas as seções que concordam total ou parcialmente com as afirmações do questionário sobre como usar o *Big data*, sua relação com as demais áreas da empresa, conhecimento e capacidades técnicas para analisar estes dados e seus resultados é de 55%, enquanto que o percentual de respondentes que não vê estes dados como positivos, pois discordaram total ou parcialmente das afirmações, é de 22%.

Através da análise das médias por processo, nota-se que a variação de respondentes em concordância com as questões ou em discordância, sofrem variações importantes, como demonstrado na Figura 6, onde vê-se que as seções Como usamos o *Big data*, Coordenação e Resultados estão com percentuais altos (acima de 60%) para os respondentes em concordância, enquanto que nos processos Planejamento e Conhecimento os percentuais entre os respondentes que concordam ou discordam das afirmações são muito mais próximos entre si.

Nas próximas seções deste estudo, foram selecionadas somente as diferenças percentuais de maior relevância (acima de 10%) para cada construto, porém todos os resultados estarão disponíveis como anexo deste trabalho.

Figura 6: Análise comparativa entre média geral dos respondentes vs média geral por construto.



Fonte: elaborado pela autora à partir dos dados de pesquisa (2018)


5.1.1 Como o *Big Data* é utilizado

Na análise desta seção não se detecta uma variação superior a 10% na maioria das dimensões separadas pelo perfil dos respondentes. O percentual médio de respostas em concordância com as afirmações sobre como os dados do *Big data* são usados e se os respondentes sabem como extraí-los é próximo aos 61%, sendo que os homens são mais otimistas (63%) em relação à utilização dos dados de *Big data* em comparação com as mulheres (55%) e também vemos aqui os cargos de hierarquia mais alta (CPO, por exemplo), respondendo de maneira mais positiva (64%) em detrimento aos compradores (58%).

As principais diferenças estão retratadas no tipo de indústria, aonde os respondentes da Indústria Alimentícia são mais positivos (69%) em comparação aos respondentes de Segmentos Diversos, classificados como Outros (57%) e por tipo de empresa, com as empresas com maior número de colaboradores concordando em 64% contra 55% das empresas com até 500 colaboradores.

Estes dados são confirmados pela análise estatística de comparação de médias, onde nota-se também esta diferença nas respostas entre o grupo de respondentes na dimensão Gênero, com os homens mais positivos em relação ao uso dos dados de *Big data* e na dimensão tamanho de empresa, com as empresas com maior número de colaboradores também enxergando o uso de forma mais positiva.

Figura 7: Principais variações no percentual de respondentes da Seção 1: Como o *Big data* é utilizado




Fonte: elaborado pela autora, a partir dos dados de pesquisa (2018)

5.1.2 Planejamento

Nesta seção, o objetivo foi avaliar, dentro do perfil dos respondentes, como os mesmos visualizam o planejamento para a utilização dos dados do *Big data* dentro das organizações e a resposta em concordância com as afirmações neste quesito está abaixo da média geral, girando em torno a 44%, sendo possível também visualizar uma diferença maior que 10% em três dimensões, em Faixa etária, onde os respondentes acima de 37 anos são os mais positivos (50%) em relação ao planejamento em comparação com os mais jovens (39%) e também é possível notar que na dimensão de Posições hierárquicas, os compradores são menos positivos (38%) do que os respondentes em posições hierárquicas mais altas, como Diretor de Compras ou CPO (56%).

Observando estes resultados, é possível inferir que pessoas com mais experiência visualizam melhor a conexão entre o planejamento de suas organizações para o uso dos dados do *Big data*, provavelmente por terem mais acesso às informações e resultados das análises de dados complexos, pela posição que ocupam em suas organizações.

Figura 8: Principais variações no percentual de respondentes da Seção 2: Planejamento



Fonte: elaborado pela autora à partir dos dados de pesquisa (2018)

5.1.3 Coordenação

Esta seção tem, basicamente, a finalidade, de analisar como os respondentes entendem que as informações circulam nas empresas e de que modo a área de Compras está envolvida

no processo. Neste quesito, nota-se uma disparidade importante nas respostas em todas as dimensões de perfil de respondentes analisados. Um ponto que chama a atenção é que 73% dos respondentes na faixa etária acima de 37 anos acreditam que o nível de coordenação das suas empresas é alto e alinhado com as demais áreas; por outro lado, somente 46% dos respondentes da posição hierárquica comprador, veem esta coordenação e troca de informações nas suas empresas. A Tabela 9 demonstra claramente estas diferenças entre os respondentes em quase todas as dimensões de perfil. Levando em consideração todas as diferenças, nota-se que quanto maior a experiência do respondente, seja do ponto de vista profissional, de faixa etária ou grau de instrução, maior é o entendimento positivo sobre a coordenação das áreas ao interno das organizações.

Tabela 9: Principais variações no percentual de respondentes da Seção 3: Coordenação

Dimensão	Resultado
Gênero	Maior concordância: Homem (72%) Menor concordância: Mulher (45%)
Faixa Etária	Maior concordância: Acima de 37 anos (73%) Menor concordância: até 37 anos (54%)
Escolaridade	Maior concordância: MBA ou Especialização (71%) Menor concordância: Superior Completo (44%)
Formação	Maior concordância: Engenharia ou afins (69%) Menor concordância: Administração e afins (51%)
Posição Hierárquica	Maior concordância: CPO (78%) Menor concordância: Comprador (46%)
Tipo de Indústria	Maior concordância: Automotiva (76%) Menor concordância: Outros (49%)
Tamanho empresa	Maior concordância: Acima 1000 (68%) Menor concordância: Até 500 (53%)


Fonte: elaborado pela autora a partir dos dados de pesquisa (2018)

5.1.4 Controle

Analisando o resultado específico desta seção, não se nota grandes divergências entre as respostas na maioria das dimensões. A média de respostas em concordância total ou parcial com as afirmações é de 51%, alinhando com a média geral, de 55%. Neste construto encontram-se diferenças importantes na dimensão Faixa Etária, onde os respondentes acima de 37 anos veem que a responsabilidade sobre a extração dos dados é clara, dentro das suas

organizações (59%) em detrimento aos mais jovens, cujo percentual de concordância é de apenas 31%. Verifica-se também que na dimensão por tamanho da empresa, percebe-se uma diferença significativa entre o grupo de respondentes que trabalham em empresas com mais de 1.000 funcionários (62%), em comparação com respondentes que trabalham em empresas com até 500 funcionários (33%).

Figura 9: Principais variações no percentual de respondentes da Seção 4: Controle




Fonte: elaborado pela autora a partir dos dados de pesquisa (2018)

5.1.5 Conectividade

Nesta seção as análises mostram respostas muito alinhadas entre si e com a média total do construto, que é de 51%. Apenas as dimensões Posição Hierárquica e Tipo de Indústria demonstram divergências entre os respondentes maiores do que 10%. Nas questões que fazem parte desta seção está a parte em que se analisa a conexão dos dados e parte de Gerenciamento de Infraestrutura, bem como se compara a organização em que o respondente trabalha com seus concorrentes. Estas variações podem demonstrar que, a Indústria Alimentícia, nesta seção específica, está mais estruturada do ponto de vista de Infraestrutura que as demais indústrias respondentes (por exemplo, a Indústria Automotiva). Nota-se também que a posição hierárquica Gerente tem uma visão mais otimista sobre este construto do que colaboradores na posição Comprador.

Figura 10: Principais variações no percentual de respondentes da Seção 5: Conectividade



Fonte: elaborado pela autora a partir dos dados de pesquisa (2018)

5.1.6 Conhecimento

Vê-se nesta seção o menor número de respostas em concordância com as afirmações do questionário, como média total, sendo seu percentual 44%; é neste construto que se avalia o nível de conhecimento, ao interno das organizações, das pessoas que trabalham com dados extraídos do *Big data*. O percentual mais baixo como média em todas as seções pode significar que as organizações ainda não estão priorizando a gestão dos dados, com profissionais especializados em capacidade analítica. Em quase todas as dimensões de perfil tem-se respostas bem diferentes entre os respondentes, sendo somente na dimensão Formação que não se vê uma diferença percentual maior do que 10%. Na tabela 10 vemos as diferenças percentuais entre os grupos de respondentes que enxergam nas organizações um nível de conhecimento mais elevado em relação à utilização dos dados em comparação com os grupos de respondentes que são menos otimistas em relação a este quesito.

Nesta seção também foi verificado, na análise estatística de comparação de médias uma diferença na dimensão Posição Hierárquica, no grupo de respondentes entre os colaboradores e líderes, onde vê-se que os líderes identificam nas organizações uma capacidade mais elevada de conhecimento e análise de dados da equipe que é responsável por estes dados dentro das organizações.

Tabela 10: Variações no percentual de respondentes da Seção 6: Conhecimento

Dimensão	Resultado
Gênero	Maior concordância: Homem (48%) Menor concordância: Mulher (33%)
Faixa Etária	Maior concordância: Acima de 37 anos (48%) Menor concordância: abaixo de 37 anos (38%)
Escolaridade	Maior concordância: MBA ou Especialização (46%) Menor concordância: Superior Completo (32%)
Posição Hierárquica	Maior concordância: CPO (56%) Menor concordância: Comprador (31%)
Tipo de Indústria	Maior concordância: Alimentos (56%) Menor concordância: Outros (35%)
Tamanho empresa	Maior concordância: acima de 1.000 (47%) Menor concordância: entre 501 a 1.000 (35%)

Fonte: elaborado pela autora a partir dos dados de pesquisa (2018)


5.1.7 Alinhamento

Nesta seção se analisa o quanto a análise, o planejamento e os investimentos em dados do *Big data* em Compras estão alinhados com a estratégia da Organização. Esse alinhamento é primordial para que a contribuição da área de Compras atenda às expectativas da organização, bem como aporte vantagem competitiva para o negócio da empresa.

A média de respostas em concordância com a questão neste construto é de 57%, muito alinhado com a média geral dos respondentes em todos os construtos, que é de 55%, não sendo notadas diferenças significativas nas dimensões Faixa Etária, Formação e Tipo de Indústria.

Importante salientar as diferenças encontradas na dimensão Escolaridade, onde vê-se os respondentes com MBA ou Especialização em concordância com as afirmações em 60%, em comparação com os respondentes com nível Superior Completo, que somam 42% e na posição hierárquica, com as posições mais elevadas com 75% em concordância total ou parcial e apenas 48% entre os compradores.

Figura 11: Principais variações no percentual de respondentes da Seção 7: Alinhamento



Fonte: elaborado pela autora a partir dos dados de pesquisa (2018)

5.1.8 Resultados

Nesta seção encontram-se as questões relacionadas aos resultados obtidos, nos últimos três anos, com a utilização do *Big data* nos principais indicadores de desempenho, que vão desde a acuracidade de entregas por parte dos fornecedores, até a melhoria da Governança na área de Compras, passando por quesitos como Qualidade, redução de custos e redução do risco. De modo geral, o nível de resposta em concordância com as afirmações do questionário é o mais alto entre os construtos (72%), sendo que todas as dimensões por perfil de respondentes estão alinhadas com esta média, sem nenhuma exceção.

6. CONCLUSÃO, LIMITAÇÕES E ESTUDOS FUTUROS

6.1 Conclusão

O objetivo principal deste estudo era responder a pergunta “*A análise de dados complexos tem sido explorada em Compras e há um reconhecimento de valor em seu uso?*” através da análise dos dados extraídos de uma *survey* com executivos da área de Compras das Organizações, bem como gerar um relatório gerencial com os achados mais importantes, mostrado na seção 5 deste trabalho.

A resposta a esta questão principal foi dada ao longo deste trabalho, através das análises estatísticas e percentuais, onde conclui-se que as indústrias brasileiras tem usado dados complexos, já que 61% dos respondentes afirmam saber usar e extrair dados complexos, porém, que estes dados ainda têm um valor restrito dentro das organizações, já que apenas 44% dos respondentes acreditam que suas organizações têm as pessoas certas para analisar estes dados, o que significa que ainda existe um espaço importante a ser explorado pelo uso e análise de *Big data*.

Em relação ao reconhecimento de seu valor, a grande maioria dos respondentes (72%) reconhece uma melhora importante nos resultados de desempenho e principais indicadores da área de Compras nos últimos três anos em razão do uso de dados complexos, o que demonstra que o retorno de investimentos nesta área, sejam em ferramentas ou em pessoas capazes de analisar estes dados traz a melhora da performance em Compras.

Considerando os achados da análise da pesquisa, é possível inferir sobre três pontos, que são:

- 1) Empresas com maior número de funcionários visualizam melhor o uso de *Big data* e a capacidade gerencial de analisar estes dados, provavelmente por terem acesso a tecnologias mais avançadas e estarem de posse há mais tempo destas análises.
- 2) Nos construtos de Uso e Capacidade Gerencial vê-se que respondentes formados em Ciências Humanas enxergam de modo mais positivo que os formados em Ciências Exatas, possivelmente por conseguirem conectar mais rapidamente os dados extraídos com o impacto gerencial nas organizações.
- 3) Respondentes do sexo masculino tendem a ser mais positivos em relação ao uso de dados complexos extraídos do *Big data*, ao seu alinhamento com as estratégias da organização e aos resultados obtidos nos últimos três anos, em relação aos principais indicadores de desempenho da área de Compras.

Especificamente no ponto 3, sobre as diferenças encontradas entre o grupo de respondentes homens e mulheres, podemos inferir que ocorrem por dois fatores distintos, sendo um deles a diferença de valores entre homens e mulheres. De acordo com Oliveira (1993), as mulheres são diferentes dos homens, porque no centro de sua existência está o ênfase no relacionamento interpessoal, já que a sua identidade provém da interação com os outros. Isso pode levar as mulheres a não enxergar nas suas organizações esta interligação entre os controles, análises e gestão dos dados analíticos do *Big data*.

Outro ponto bem interessante que pode ser inferido é que por mulheres serem ainda minoria em posições de liderança, somente 37% de mulheres no Brasil estão em posição de liderança (ALMEIDA, 2017) e um dos pontos percebido nas comparações percentuais, mas não confirmado pela análise estatística de comparação de médias, é que a positividade em relação às afirmações do questionário é ligeiramente mais alta no perfil de respondentes com posições hierárquicas mais altas, e por mulheres estarem em menor número nesta posição, não são muito positivas em relação as afirmações do questionário.

Com base nestas afirmações, é possível concluir que o cenário atual da utilização de dados analíticos nas indústrias brasileiras, especificamente na área de Compras, é positivo no que se refere ao conhecimento dos colaboradores da área sobre extração e análise de dados, alinhamento com as estratégias corporativas e resultados efetivos, principalmente nos respondentes do sexo masculino, com formação em Ciências Humanas e que trabalham em empresas com maior número de colaboradores, porém ainda está longe de representar uma unanimidade entre indústrias e ainda existe um longo caminho a ser percorrido sobre interpretação de dados e conhecimento efetivo da ferramenta.

A principal contribuição deste estudo é entender o *status* do uso do *Big data* na área de Compras das indústrias brasileiras, para que as organizações consigam visualizar quais são os principais pontos a serem trabalhados e direcionar esforços e investimentos no sentido de canalizar ao máximo o potencial ganho que as organizações teriam estendendo a utilização destes dados.

Outra contribuição é que este estudo também amplia a literatura sobre o impacto do *Big data* na área de Compras, que pode ser útil tanto ao universo acadêmico quanto aos usuários e colaboradores que atuam nesta área em suas organizações, levando os mesmos a trabalhar de uma maneira mais eficaz ou buscar conhecimento para o tratamento e aplicação dos dados levantados e sua importância dentro da sobrevivência das organizações através de vantagem competitiva.

6.2 Limitações

Uma limitação deste estudo é o baixo número de respondentes considerados ($n=94$), o que não permite que o estudo seja considerado como verdade absoluta e sim, como tendência do cenário atual da utilização do *Big data* nas indústrias brasileiras, especificamente na área de Compras.

Devido ao baixo número de respondentes, algumas comparações de médias entre grupos amostrais de respondentes ficaram com populações abaixo do esperado, tais como o grupo amostral mulheres, onde tivemos apenas 26 respondentes, em comparação com 68 respondentes no grupo amostral homens. Isso também pode causar distorção dos dados ou inferência incorreta. De acordo com Hair et al. (2009), o tamanho da amostra frente ao número de variáveis independentes é baixo, o que limita o poder estatístico.

Para corrigir esta limitação, sugere-se aumentar o número de respondentes para que a amostra dentro deste segmento seja maior. Wiswanathan, Sudman e Johnson (2004) afirmam que, em uma amostra pequena, um grande número de itens pode não ter uma base adequada a uma análise estatística.

6.3 Estudos futuros

Como sugestão para estudos futuros, com o intuito de aprofundar ou complementar os dados extraídos neste estudo, identificam-se três caminhos distintos que são, além do aumento do número de respondentes, para uma amostra mais significativa, a continuação da investigação dos dados, com a realização de uma pesquisa qualitativa, que se preocupa com os aspectos da realidade que não podem ser quantificados, concentrando-se no significado dos temas e aprofundamento dos aspectos relevantes (GERHARDT e SILVEIRA, 2009), através de entrevistas estruturadas com amostragem em todos os perfis de respondentes para que sejam identificados modelos de implementação e/ou utilização de *Big data* nas indústrias com percentuais positivos em concordância com as afirmações.

Uma segunda recomendação seria um estudo específico sobre a percepção maior de concordância com as afirmações do questionário em todos os construtos entre o grupo de respondentes mais experientes, seja por idade ou por posição hierárquica, dentro das organizações. Provavelmente com o aumento do número de participantes da pesquisa, pode-se avaliar se realmente esta percepção se confirma, já que vemos um resultado discreto neste sentido na análise de percentuais, mas os dados não são confirmados pela análise estatística.

Última sugestão, mas não menos importante, seria um estudo sobre a existência ou não de correlação entre a percepção do grupo amostral de mulheres com a posição ocupada por elas dentro da organização, para comprovar se o fato das mulheres possuírem uma visão mais positiva em relação ao uso de *Big data* dentro das organizações, seja do ponto de vista de conhecimento, planejamento ou mesmo seus resultados, como demonstrado no resultado estatístico de comparação de amostras, está mais relacionado com os valores das mulheres, com a posição que ocupam dentro das organizações ou outros fatores.

REFERÊNCIAS

- Akter, S; et al. 2016. “How to improve firm performance using big data analytics capability and business strategy alignment?” *Intl. J. Production Economics* 182, 113-131
- Almeida, C. 2017. “Mulheres estão em apenas 37% dos cargos de chefia nas empresas”. *Site oglobo.com.br*; <https://oglobo.globo.com/economia/mulheres-estao-em-apenas-37-dos-cargos-de-chefia-nas-empresas-21013908>; acesso: 08/10/2018
- Atzori, L.; Iera, A.; & Morabito, G, 2010, *Comput. Networks* 54, 2787.
- Barbosa, E. F. 1999. “Instrumentos de coleta de dados em pesquisa.” Belo Horizonte: *CEFET-MG*.
- Barton, D.; & Court, D. 2012. “Making Advanced Analytics Work for You.” *Harvard Business Review* 90:79-83
- Beyer, M.A.; and Laney, D. 2012. “The Importance of Big Data: A Definition”, *Gartner report* pp. 1–9.
- Big Data Interoperability Framework: Definitions (2014); *NIST Big Data Public Working Group*
- Byrd, T. A., & Turner, D. E., 2000. “Measuring the Flexibility of Information Technology Infrastructure: Exploratory Analysis of a Construct.” *Journal of Management Information Systems*, 17(1), 167-208.
- Bouleye, P.; Riedstra, P.; Spiller, P.; 2016. “Driving superior value through digital procurement.” *McKinsey & Co., Inc*
- Boyd, D.; & Crawford, K., 2012. “Information.” *Commun.Soc.* 15, 662
- 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 System* 32, 4 – pp 4-39

Chen, H.; Chiang, R.; & Storey, V. 2012. "Business Intelligence and Analytics: From Big Data to Big Impact." *MIS Quartely* 36(4): 1 165-88

Caniato, F., Luzzini, D., & Ronchi, S., 2014. "Purchasing performance management systems: an empirical investigation." *Production Planning & Control*, 25(7), 616-635

Constantiou, I.D., Kallinikos, J., 2014. "New games, new rules: big data and the changing context of strategy" *J. Inf. Technol.*

Cousins, P.D. 2005, "The alignment of appropriate firm and supply strategies for competitive advantage", *International journal of operations production management*, vol. 25, no. 5, pp. 403.

Coyle, K. 2006. *J. Acad. Librariansh.* 32, 641

Dancey, C.; Reidy, J. (2006). "Estatística Sem Matemática para Psicologia: Usando SPSS para Windows". Porto Alegre, *Artmed*.

Davenport, T.H.; Barth. P.; & Beand R. 2012. "How Big Data is Different." *MIT Sloan Management Review* 54 21-24

Davis, F. D. , 1989. "Perceived usefulness, perceived ease of use, and user acceptance of information technology." *MIS quarterly*, 319-340.

Dehning, B.; Richardson, V.J.; and Zmud, R.W. 2007. "The financial performance effects on TI-based Supply Chain management system in manufacturing firms." *Journal of Operations Management*, 25, 806-824

Dijcks, J. 2012 "Big Data for the Enterprise", *Oracle report*.

Dumbill, E. 2013. " Big data". *Making Sense of Big Data* 1, 1.

Figueira, M. 1998. "Identificação de Outliers". *Millenium*, 12

Fisher, D.; DeLine, R.; Czerwinski, M.; and Drucker, S.; 2012. "Interactions with Big Data Analytics." *ACM Interactions*, 19 (3)

Forza, C., 2002. "Survey research in operations management: a process-based perspective", *International Journal of Operations & Production Management*, Vol. 22 Iss 2 pp. 152 - 194

George; et.al. 2014. "Big data and Management." *Academy of Management Journal*. Vol 57 nr. 2 – pp.321-326

Gerhardt, T.E.; Silveira, D.T. 2009 "Métodos de Pesquisa." *Universidade Federal do Rio Grande do Sul*, ISBN 978-85-386-0071-8 - EAD

Gonzalez-Benito, J. 2007, "A theory of purchasing's contribution to business performance", *Journal of Operations Management*, vol. 25, no. 4, pp. 901-917.

Guimarães, P.R.B., 2008. "Métodos Quantitativos Estatísticos". Curitiba. *IESDE Brasil S.A.*

Hair, J. F., JR ; Black, W. C.; Babin, B. J.; Anderson, R. E.; Tatham, R. L. 2009 "Análise multivariada de dados". Porto Alegre : *Bookman*, 6 ed..

Harland, C.M. 1999, "Developing the concept of supply strategy", *International journal of operations production management*, vol. 19, no. 7, pp. 650.

Hilbert, M.; & López, P. 2011. *Science* 332, 60

Hult, G.T.M.; et al. 2006. "Knowlegde as a strategic resource in Supply Chain." *Journal of Operations Management*., 24, 458-485

Intel, Big Data Analytics. 2012. "Intel's IT Manager Survey on How Organizations Are Using Big Data", *Intel report*.

Kim, G., Shin, B., & Kwon, O., 2012. "Investigating the value of sociomaterialism in conceptualizing IT capability of a firm." *Journal of Management Information Systems*, 29(3), 327-362.

Kiron, D., Prentice, P.K., Ferguson, R.B., 2014. "The analytics mandate". *MIT Sloan Management Rev.* 55, 1-25.

Klein, R.; and Rai, A. 2009. "Inter-firm strategic information flows in supply chain logistics relationships." *MIS Quarterly*, 33, 4, pp 735-762.

Laney, D., 2001. META Gr.Res Note 6

Lavalle, S., Lesser, E., Shockley, R., Hopkins, M.S., Kruschwitz, N., 2011. "Big data, analytics and the path from insights to value." *MIT Sloan Management Rev.* 52, 21-32.

Leenders, M.R.; et al. 2010. "Purchasing and Supply Management." New York, NY: *McGraw-Hill, Irwing*), p.6

Loesch, C.; Hoeltgebaum, M. (2012). "Métodos Estatísticos Multivariados." São Paulo, *Editora Saraiva*.

Maniyka, J.; Chui, M.; Brown, B.; & Bughin, J. 2011. "Big Data: The next frontier for Innovation, Competition and Productivity."

Mauro, A; Greco, M.; & Grimaldi, M. 2016. "A formal definition of Big Data based on its essential features", *Library Review*, Vol. 65 Issue: 3, pp.122-135, <https://doi.org/10.1108/LR-06-2015-0061>

Mayer-Schönberger V. and Cukier K., 2013. "Big Data: A Revolution That Will Transform How We Live, Work and Think." *Houghton Mifflin Harcourt*.

McAfee, A.; & Brynjolfsson, E. 2012. "Big Data: The Management Revolution." *Harvard Business Review* 90:60-68

Microsoft, 2013, available at <https://www.microsoft.com/en-us/news/features/2013/feb13/02-11bigdata.aspx>

Mukaka, M.M. (2012). "Statistics corner: A guide to appropriate use of correlation coefficient in medical research". *Malawi Medical Journal*. 24, 69–71.

Nollet, J. 2005, "About "strategy" and "strategies" in supply management", *Journal of purchasing and supply management*, vol. 11, no. 2-3, pp. 129.

Oliveira, R. D. 1993. "Elogio da diferença. O feminino emergente." São Paulo: *Brasiliense*

Rai, A.; Patnayakuni, R.; and Seth, N. 2006. "Firm performance impacts of digitally enabled supply chain integration capabilities." *MIS Quarterly*, 29, 4, pp. 625–652

Ramaswamy, S., 2013. "What the Companies Winning at Big Data Do Differently". *Bloomberg*, United States <http://www.bloomberg.com/news/2013-06-25/what-the-companies-winning-at-big-data-do-differently.html>.

Reis, E., 1994. "Estatística Descritiva" Lisboa: *Edições Sílabo*, (2^a ed.)

Russom, P., 2011. *TDWI Best Practice Report*, Fourth Quarter

Sanders, N. 2016. "How to use Big data to Drive Your Supply Chain." *University of California, Berkeley* Vol 50, number 3

Saunders, M.; Lewis, P.; Thornhill, A.; 2009. "Research methods for business students". 5 ed. England. *Pearson Education Limited*.

Schoemaker, P.J.H.; & Tetlock P.E. 2017. "Building a more Intelligent Enterprise." *MIT Sloan Management Review* 58:3 27-38

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.

Schroeck, M.; et al. 2012. “Analytics: The Real-World Use of Big Data”, *IBM Report*, pp 1-20

Shneiderman, B.; in Proc. 2008 ACM SIGMOD *Int. Conf. Manag. Data*, pp. 3–12.

Stone B; 2013. “The Secrets of Bezos: How Amazon Became the Everything Store,” *Bloomberg Businessweek*, October 10, 2013, <www.businessweek.com/articles/2013-10-10-/jeff-bezosand-the-age-amazon-excerpts-fr om-the-everything-store-by-brad-stone.

Sweeney, D. J., Williams, T. A., & Anderson, D. R. 2013. “Estatística aplicada à administração e economia”. São Paulo, *CENGAGE Learning*.

Suthaharan, S., 2014. *ACM SIGMETRICS Perform. Eval. Rev.* 41, 70

Van Weele, A.J.; van Raaij, E.M., 2014. “The future of purchasing and supply management research: about relevance and rigor”. *Journal of Supply Chain Management*, 50(1), 56-72

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, G; Gunasekaran, A.; Ngai, E.W.T.; Papadopoulos, T.; 2016. “ Big Data analytics in logistic and supply chain management: certain investigations for researches and applications”. *International Journal of Production Economics*, 176; 98-110

Ward, J.; Barker, A.; 2013. “Undefined by Data: A Survey of Big data Definitions”.

[arXiv:1309.5821](https://arxiv.org/abs/1309.5821) [cs.DB]

Wiswanathan, M.; Sudman, S.; Johnson, M.; 2004. "Maximum versus meaningful discrimination in scale response: implications for validity of measurement of consumer perception about products." *Journal of Business Research* v.57 (2), 08-24

Xiong, W.; et al. 2013. "Big Data". *IEEE International Conference*", pp 118-115

APENDICE A – Percentual de respondentes de cada questão

Construto	Questões	DT	%	DP	%	N	%	CP	%	CT	%	N/A	%
Como usamos o Big Data	USO1	11	12%	22	23%	8	9%	38	40%	13	14%	2	2%
	USO2	1	1%	1	1%	9	10%	35	37%	47	50%	1	1%
	USO3	8	9%	7	7%	7	7%	43	46%	29	31%	0	0%
	USO4	14	15%	24	26%	7	7%	37	39%	12	13%	0	0%
	USO5	33	35%	29	31%	10	11%	13	14%	6	6%	3	3%
	USO6	7	7%	12	13%	5	5%	34	36%	36	38%	0	0%
BDC Planejamento	PLAN1	16	17%	20	21%	9	10%	34	36%	12	13%	3	3%
	PLAN2	15	16%	23	24%	13	14%	33	35%	9	10%	1	1%
	PLAN3	19	20%	24	26%	14	15%	26	28%	11	12%	0	0%
BDC Coordenação	COOR1	11	12%	16	17%	2	2%	41	44%	24	26%	0	0%
	COOR2	7	7%	20	21%	5	5%	39	41%	22	23%	1	1%
	COOR3	10	11%	20	21%	7	7%	33	35%	22	23%	2	2%
BDC Controle	CTRL1	15	16%	15	16%	13	14%	33	35%	15	16%	3	3%
BDC Conectividade	CONE1	21	22%	16	17%	17	18%	28	30%	6	6%	6	6%
	CONE2	19	20%	7	7%	3	3%	22	23%	40	43%	3	3%
BDC Conhecimento	CONH1	18	19%	23	24%	14	15%	23	24%	9	10%	7	7%
	CONH2	8	9%	30	32%	16	17%	27	29%	5	5%	8	9%
	CONH3	6	6%	18	19%	12	13%	38	40%	14	15%	6	6%
	CONH4	6	6%	17	18%	20	21%	36	38%	12	13%	3	3%
BDC Alinhamento Estratégico	ALIN1	5	5%	10	11%	13	14%	32	34%	32	34%	2	2%
	ALIN2	7	7%	19	20%	4	4%	33	35%	28	30%	3	3%
	ALIN3	8	9%	19	20%	11	12%	29	31%	22	23%	5	5%
	ALIN4	11	12%	17	18%	20	21%	27	29%	10	11%	9	10%
Resultados	RESU1	2	2%	10	11%	11	12%	53	56%	18	19%	0	0%
	RESU2	3	3%	12	13%	9	10%	45	48%	22	23%	3	3%
	RESU3	5	5%	12	13%	13	14%	49	52%	13	14%	2	2%
	RESU4	3	3%	8	9%	5	5%	44	47%	32	34%	2	2%
	RESU5	4	4%	10	11%	14	15%	43	46%	20	21%	3	3%
	RESU6	3	3%	15	16%	12	13%	42	45%	21	22%	1	1%
	RESU7	3	3%	12	13%	7	7%	45	48%	26	28%	1	1%
	RESU8	3	3%	9	10%	11	12%	39	41%	31	33%	1	1%

DT: Discordo Totalmente

DP: Discordo Parcialmente

N: Não concordo nem discordo

CP: Concordo Parcialmente

CT: Concordo Totalmente

N/A: Não se aplica

APENDICE B – Percentual de respondentes por Seção

1. Como usamos o *Big data*

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	13%	17%	8%	35%	25%	1%	61%
Feminino	17%	17%	10%	37%	19%	1%	55%
Masculino	12%	17%	8%	35%	28%	1%	63%
Ate 37 anos	16%	17%	6%	35%	25%	1%	60%
Acima de 37 anos	11%	17%	10%	36%	26%	1%	62%
Superior Completo	20%	15%	7%	31%	27%	1%	57%
MBA	12%	17%	8%	35%	27%	1%	62%
Humanas	13%	15%	6%	28%	20%	1%	48%
Exatas	10%	14%	9%	31%	18%	1%	49%
CPO	7%	17%	13%	49%	15%	0%	64%
Gerente	9%	18%	12%	35%	25%	1%	61%
Supervisor	16%	17%	5%	30%	32%	1%	62%
Comprador	16%	17%	8%	35%	23%	2%	58%
Automotiva	13%	18%	11%	36%	22%	1%	59%
Alimentos	8%	14%	8%	40%	30%	0%	69%
Quimica	15%	16%	7%	39%	22%	2%	61%
Outros	16%	19%	6%	27%	30%	2%	57%
até 500	20%	19%	5%	33%	22%	1%	55%
501 a 1000	9%	19%	13%	39%	20%	0%	59%
acima de 1000	11%	15%	8%	36%	28%	1%	64%

2. Planejamento

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	18%	24%	13%	33%	11%	1%	44%
Feminino	26%	27%	18%	23%	5%	1%	28%
Masculino	15%	23%	11%	37%	14%	1%	50%
Ate 37 anos	18%	26%	16%	31%	7%	1%	39%
Acima de 37 anos	18%	22%	10%	35%	15%	1%	50%
Superior Completo	17%	28%	15%	33%	5%	1%	39%
MBA	19%	25%	11%	30%	13%	2%	43%
Humanas	16%	18%	13%	33%	19%	2%	52%
Exatas	9%	22%	5%	41%	22%	1%	63%
CPO	6%	22%	17%	56%	0%	0%	56%
Gerente	25%	26%	11%	23%	14%	2%	37%
Supervisor	18%	20%	9%	35%	17%	0%	53%
Comprador	18%	24%	17%	29%	9%	3%	38%
Automotiva	14%	25%	10%	32%	17%	1%	49%
Alimentos	15%	30%	7%	39%	7%	2%	46%
Quimica	23%	14%	20%	32%	9%	3%	41%
Outros	21%	27%	14%	30%	8%	0%	38%
até 500	24%	22%	6%	36%	8%	4%	44%
501 a 1000	13%	20%	27%	36%	4%	0%	40%
acima de 1000	16%	25%	12%	31%	15%	1%	45%

3. Coordenação

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	10%	20%	5%	40%	24%	1%	64%
Feminino	19%	32%	4%	37%	8%	0%	45%
Masculino	6%	15%	5%	41%	30%	1%	72%
Ate 37 anos	13%	26%	5%	36%	18%	1%	54%
Acima de 37 anos	7%	14%	5%	44%	30%	1%	73%
Superior Completo	17%	33%	4%	25%	19%	1%	44%
MBA	8%	16%	5%	43%	28%	1%	71%
Humanas	17%	24%	8%	34%	16%	1%	51%
Exatas	6%	18%	6%	43%	27%	0%	69%
CPO	3%	11%	6%	53%	25%	3%	78%
Gerente	2%	16%	2%	54%	26%	0%	81%
Supervisor	14%	16%	3%	40%	26%	1%	66%
Comprador	14%	30%	9%	25%	22%	1%	46%
Automotiva	5%	13%	6%	49%	26%	0%	76%
Alimentos	7%	15%	4%	43%	28%	4%	70%
Quimica	11%	24%	9%	38%	18%	0%	56%
Outros	19%	30%	0%	25%	24%	2%	49%
até 500	21%	24%	3%	35%	18%	0%	53%
501 a 1000	4%	13%	13%	51%	18%	0%	69%
acima de 1000	7%	20%	4%	39%	28%	2%	68%

4. Controle

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	16%	16%	14%	35%	16%	3%	51%
Feminino	27%	31%	8%	27%	4%	4%	31%
Masculino	12%	10%	16%	38%	21%	3%	59%
Ate 37 anos	18%	18%	16%	36%	11%	2%	47%
Acima de 37 anos	14%	14%	12%	35%	20%	4%	55%
Superior Completo	28%	12%	12%	36%	12%	0%	48%
MBA	13%	19%	15%	29%	19%	5%	48%
Humanas	14%	26%	7%	33%	21%	0%	53%
Exatas	6%	14%	8%	39%	28%	6%	67%
CPO	0%	0%	33%	50%	8%	8%	58%
Gerente	11%	32%	11%	26%	21%	0%	47%
Supervisor	19%	19%	16%	23%	19%	3%	42%
Comprador	23%	10%	6%	45%	10%	6%	55%
Automotiva	9%	24%	6%	36%	21%	3%	58%
Alimentos	6%	28%	22%	28%	17%	0%	44%
Quimica	27%	5%	14%	32%	14%	9%	45%
Outros	24%	5%	19%	43%	10%	0%	52%
até 500	25%	21%	13%	29%	4%	8%	33%
501 a 1000	13%	33%	13%	27%	13%	0%	40%
acima de 1000	13%	9%	15%	40%	22%	2%	62%

5. Conectividade

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	21%	12%	11%	27%	24%	5%	51%
Feminino	27%	15%	4%	31%	17%	6%	48%
Masculino	19%	11%	13%	25%	27%	4%	52%
Ate 37 anos	24%	12%	9%	22%	28%	4%	50%
Acima de 37 anos	18%	12%	12%	31%	21%	5%	52%
Superior Completo	32%	8%	6%	26%	24%	4%	50%
MBA	19%	15%	12%	24%	24%	5%	48%
Humanas	22%	18%	14%	29%	12%	4%	41%
Exatas	14%	14%	19%	38%	10%	6%	47%
CPO	4%	17%	8%	38%	25%	8%	63%
Gerente	11%	11%	8%	37%	26%	8%	63%
Supervisor	26%	6%	11%	24%	32%	0%	56%
Comprador	29%	16%	13%	19%	16%	6%	35%
Automotiva	26%	12%	17%	26%	18%	2%	44%
Alimentos	8%	11%	6%	36%	28%	11%	64%
Quimica	18%	14%	7%	27%	25%	9%	52%
Outros	29%	12%	10%	19%	31%	0%	50%
até 500	23%	13%	4%	29%	25%	6%	54%
501 a 1000	23%	10%	13%	20%	30%	3%	50%
acima de 1000	20%	13%	13%	27%	23%	5%	50%

6. Conhecimento

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	10%	23%	16%	33%	11%	6%	44%
Feminino	21%	28%	15%	29%	4%	3%	33%
Masculino	6%	22%	17%	35%	13%	8%	48%
Ate 37 anos	13%	23%	15%	29%	9%	10%	38%
Acima de 37 anos	7%	23%	18%	36%	12%	3%	48%
Superior Completo	15%	33%	15%	20%	12%	5%	32%
MBA	9%	21%	18%	36%	10%	6%	46%
Humanas	15%	20%	14%	30%	16%	5%	46%
Exatas	11%	22%	8%	28%	22%	8%	50%
CPO	2%	13%	21%	42%	15%	8%	56%
Gerente	8%	28%	17%	39%	8%	0%	47%
Supervisor	10%	22%	9%	36%	15%	8%	51%
Comprador	15%	24%	23%	23%	7%	8%	31%
Automotiva	9%	29%	14%	34%	7%	7%	41%
Alimentos	1%	24%	17%	42%	14%	3%	56%
Quimica	13%	11%	23%	39%	11%	3%	50%
Outros	17%	27%	13%	18%	13%	12%	31%
até 500	11%	28%	13%	33%	7%	7%	41%
501 a 1000	17%	25%	17%	32%	3%	7%	35%
acima de 1000	8%	21%	18%	33%	14%	6%	47%

7. Alinhamento

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	8%	17%	13%	32%	24%	5%	57%
Feminino	14%	18%	15%	33%	14%	5%	47%
Masculino	6%	17%	12%	32%	28%	5%	60%
Ate 37 anos	12%	18%	9%	31%	22%	7%	53%
Acima de 37 anos	5%	16%	16%	34%	27%	3%	60%
Superior Completo	17%	25%	12%	24%	18%	4%	42%
MBA	6%	15%	13%	33%	27%	6%	60%
Humanas	9%	17%	13%	36%	22%	3%	58%
Exatas	3%	17%	13%	33%	29%	4%	62%
CPO	0%	13%	10%	52%	23%	2%	75%
Gerente	4%	18%	18%	22%	28%	9%	50%
Supervisor	9%	16%	10%	34%	29%	2%	63%
Comprador	14%	19%	11%	29%	19%	7%	48%
Automotiva	7%	17%	13%	34%	26%	3%	60%
Alimentos	1%	18%	15%	26%	31%	8%	57%
Quimica	5%	18%	16%	33%	23%	6%	56%
Outros	20%	15%	7%	33%	19%	5%	52%
até 500	17%	23%	6%	35%	13%	6%	48%
501 a 1000	3%	15%	20%	40%	17%	5%	57%
acima de 1000	6%	15%	14%	29%	32%	5%	60%

8. Resultado

Dimensão	DT	DP	Neutro	CP	CT	N/A	% respostas em concordância
Total	3%	12%	11%	48%	24%	2%	72%
Feminino	7%	9%	11%	52%	20%	2%	72%
Masculino	2%	13%	11%	46%	26%	2%	72%
Ate 37 anos	4%	6%	11%	52%	26%	1%	78%
Acima de 37 anos	3%	17%	11%	44%	23%	2%	67%
Superior Completo	8%	12%	10%	54%	16%	2%	69%
MBA	2%	12%	9%	46%	29%	2%	75%
Humanas	7%	12%	11%	49%	19%	3%	67%
Exatas	1%	14%	14%	42%	26%	3%	69%
CPO	0%	17%	15%	42%	26%	1%	68%
Gerente	5%	9%	12%	43%	26%	5%	69%
Supervisor	3%	14%	7%	54%	22%	0%	75%
Comprador	4%	9%	12%	47%	26%	1%	73%
Automotiva	3%	13%	10%	45%	26%	3%	72%
Alimentos	0%	9%	14%	51%	24%	2%	75%
Quimica	3%	11%	16%	46%	23%	1%	69%
Outros	8%	13%	4%	51%	24%	0%	74%
até 500	8%	4%	11%	56%	20%	1%	76%
501 a 1000	0%	16%	13%	48%	17%	7%	64%
acima de 1000	3%	14%	10%	44%	28%	1%	73%