

AIRTON MARTINS SILVA

**Fatores críticos de sucesso para a implementação de *Big Data* e *Big Data Analytics* na
gestão da cadeia de suprimentos**

Airton Martins Silva

Fatores críticos de sucesso para a implementação de *Big Data* e *Big Data Analytics* na gestão da cadeia de suprimentos

Dissertação apresentada à Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Produção.

Orientador: Prof. Dr. Claudemir Leif Tramarico.

S586f	Silva, Airton Martins Silva Fatores críticos de sucesso para a implementação de Big Data e Big Data Analytics na gestão de cadeia de suprimentos / Airton Martins Silva – Guaratinguetá, 2021. 66 f : il. Bibliografia: f. 59-66 Dissertação (Mestrado) – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2021. Orientador: Prof. Dr. Claudemir Leif Tramarico Coorientador: Prof. Dr. Jorge Muniz Junior 1. Processo decisório. 2. Planejamento estratégico. 3. Processamento de dados. I. Título. CDU 681.3(043)
-------	--

AIRTON MARTINS SILVA

**ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE
“MESTRE EM ENGENHARIA DE PRODUÇÃO”**

**PROGRAMA: ENGENHARIA DE PRODUÇÃO
CURSO: MESTRADO**

APROVADA EM SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO

**Profa Dra. Gislaine Cristina Batistela
Coordenadora**

BANCA EXAMINADORA:



Prof. Dr. CLAUDEMIR LEIF TRAMARICO

orientador - UNESP/FEG
participou por videoconferência



PROF. DR. FERNANDO AUGUSTO SILVA MARINS

UNESP/FEG
participou por videoconferência



PROF. DR. ANTÔNIO AUGUSTO CHAVES

UNIFESP
participou por videoconferência

Junho de 2021

DADOS CURRICULARES

AIRTON MARTINS SILVA

NASCIMENTO	20/01/1992 – Birigui/SP
FILIAÇÃO	José Antonio da Silva Clemilda das Graças Martins Silva
2010/2015	Graduação em Engenharia de Petróleo Centro Universitário Estácio Uni Radial de São Paulo
2017/2018	Pós-Graduação em Administração das Operações e Negócios – Faculdade e Instituto de Administração (FIA) da Universidade de São Paulo

Dedico este trabalho aos meus pais, que nunca deixaram de acreditar que um dia eu conseguiria alcançar o que para nós era impossível.

AGRADECIMENTOS

O meu maior agradecimento é a Deus, que sempre me deu saúde para acordar todos os dias e lutar por todos os meus sonhos.

Aos meus pais, a quem me ensinaram o grande poder de saber respeitar o próximo e sempre ter a humildade de saber enxergar nossos erros e a não os esconder, me torando assim, um ser humano cada dia melhor.

Ao meu amigo Bernardo Fraga, companheiro e irmão que sempre me incentivou a continuar tentando cada vez que eu errava.

À minha companheira Karina e seu filho de quatro patas Scott, que sempre tiveram paciência para entender sobre os momentos que precisamos abrir mão para que eu pudesse me dedicar a esse trabalho.

À toda minha família que sempre me apoiou e acreditou que um dia eu seria capaz de chegar na oportunidade de obter o título de mestre.

Ao grupo “mestrandos”, composto pelo Mauricio, Sassaki, Laís, Tati e Testoni, que fizeram e fazem do meu dia muito mais alegre.

Agradeço ao professor Dr. Jorge Muniz e em especial ao professor e orientador Dr. Claudemir Tramarico pela oportunidade de continuar com a bolsa de estudo.

Por fim, agradeço aos professores da banca de defesa que aceitaram participar do julgamento e defesa dessa dissertação.

“O homem não teria alcançado o possível se, repetidas vezes, não tivesse tentado o impossível”.

(Max Weber)

RESUMO

Os dados são uma das principais ferramentas utilizadas na tomada de decisão em uma organização. Eles podem auxiliar a empresa a definir novos investimentos, corte de gastos, otimizar processos, entre outras operações. Entretanto, de nada adianta ter informações disponíveis se a procedência dos dados é ultrapassada ou não foi devidamente validada. Com a utilização da tecnologia *Big Data* e *Big Data Analytics*, dados estruturados ou não, passam a ter uma relevância maior ainda nas tomadas de decisões, tornando o processo cada vez mais eficiente. Sendo assim, esta dissertação teve como objetivo propor um procedimento de análise da aplicação de *Big Data* e *Big Data Analytics* nos processos de distribuição da cadeia de suprimentos. A pesquisa buscou a identificação dos fatores críticos de sucesso e no uso de método de decisão multicritério, incluindo o *Analytic Hierarchy Process* (AHP) com os critérios de Benefícios, Oportunidades, Custos e Riscos (BOCR). Na avaliação das alternativas, *Big Data Analytics* apresentou maior destaque na prioridade com uma margem superior de 9 pontos percentuais sobre *Big Data*. Os resultados foram apresentados e validados pelos especialistas que consideraram os fatores julgados como os principais para o sucesso na implementação da tecnologia.

PALAVRAS CHAVES: *Analytic hierarchy process. Big data. Big data analytics.* Fatores críticos de sucesso. Gestão da cadeia de suprimentos.

ABSTRACT

Data are, the main input in decision making within an organization, data can help direct to a new investment decision, budget cutting, process optimization or many others. However, if the data is outdated or is not fully validated. Big Data and Big Data Analytics, structured data gained matter for decision making, turning the process more effective based on update data. Therefore, this dissertation aimed to propose a procedure for analyzing the application of Big Data and Big Data Analytics in the supply chain distribution processes. The research sought to identify the critical success factors and the use of a multicriteria decision method, including the Analytic Hierarchy Process (AHP) with the criteria of Benefits, Opportunities, Costs and Risks (BOCR). In the assessment of alternatives, Big Data Analytics showed greater prominence in the priority with an upper margin of 9 percentage points over Big Data. The results were presented and validated by the experts who considered the factors judged as the main factors for the successful implementation of the technology.

KEYWORDS: Analytic hierarchy process. Big data. Big data analytics. Critical success factors. Supply chain management.

LISTA DE FIGURAS

Figura 1 – Classificação da pesquisa	19
Figura 2 - Etapas da pesquisa	20
Figura 3 - Número de publicações por categorias e ano	22
Figura 4 - Rede de citação <i>Big Data</i> e SCM	23
Figura 5 - Hierarquia AHP	35
Figura 6 - Classificação BOCR	42
Figura 7 - Hierarquia para avaliação de Big Data e Big Data Analytics.....	43
Figura 8 - Análise de sensibilidade para o critério Benefício	50
Figura 9 - Análise de sensibilidade para o critério Oportunidades	51
Figura 10 - Análise de sensibilidade para o critério Custos	52
Figura 11 - Análise de sensibilidade para o critério Riscos	52

LISTA DE TABELAS

Tabela 1 - Resumo de dados	22
Tabela 2 - Prioridades dos critérios BOCR.....	44
Tabela 3 - Prioridade dos subcritérios Benefícios.....	45
Tabela 4 - Prioridade dos subcritérios Oportunidades	45
Tabela 5 - Prioridade dos Subcritérios Custos	46
Tabela 6 - Prioridade dos subcritérios Riscos	46
Tabela 7 - Prioridade global dos critérios e subcritérios.....	47
Tabela 8 - Escala para medição absoluta	48
Tabela 9 - Avaliação quantitativa de Big Data e Big Data Analytics	49

LISTA DE QUADROS

Quadro 1 - Lacuna de pesquisa	18
Quadro 2 - Fatores críticos de sucesso	31
Quadro 3 - Processo de julgamentos de decisão AHP	36
Quadro 4 - Índice Randômico	38
Quadro 5 - Caracterização dos especialistas	40
Quadro 6 - Resumo Siglas BOCR.....	41
Quadro 7 - Avaliação qualitativa de Big Data e Big Data Analytics.....	49

LISTA DE SIGLAS E ABREVIATURAS

AHP	<i>Analytics Hierarchy Process</i>
BOCR	Benefícios, Oportunidades, Custos e Riscos
IC	Índice de consistência
IR	Índice Randômico
MCDM	<i>Multiple Criteria Decision Making</i>
SCM	<i>Supply Chain Management</i>
SM	<i>Smart Factory</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	CONTEXTUALIZAÇÃO DO PROBLEMA E QUESTÃO DE PESQUISA	14
1.2	OBJETIVOS, DELIMITAÇÃO DA PESQUISA, JUSTIFICATIVAS E LACUNAS DE PESQUISA.....	16
1.3	ETAPAS E CLASSIFICAÇÃO DO MÉTODO DE PESQUISA	19
1.4	ESTRUTURA DO TRABALHO	21
2	REFERENCIAL TEÓRICO	22
2.1	PESQUISA BIBLIOMÉTRICA SOBRE <i>BIG DATA</i> EM SCM.....	22
2.2	BIG DATA ANALYTICS EM SUPPLY MANAGEMENT	26
2.2.1	<i>Big Data Analytics</i> nos Processos de Produção.....	26
2.2.2	<i>Big Data Analytics</i> nos Processos de Distribuição.....	29
2.3	FATORES CRÍTICOS DE SUCESSO	30
2.4	<i>ANALYTIC HIERARCH PROCESS</i>	33
2.5	DECISÃO EM GRUPO COM O MÉTODO AHP	38
2.6	MODELO BOCR	39
3	AVALIAÇÃO MULTICRITÉRIO DA APLICAÇÃO DE <i>BIG DATA</i> E <i>BIG DATA ANALYTICS</i>.....	40
3.1	CONTEXTO DA EMPRESA OBJETO DE ESTUDO	40
3.2	CLASSIFICAÇÃO DOS FATORES CRÍTICOS DE SUCESSO	40
3.3	DEFINIÇÃO DA HIERARQUIA	42
3.4	APLICAÇÃO DO MÉTODO AHP	44
4	CONSIDERAÇÕES FINAIS.....	54
4.1	VERIFICAÇÃO DOS OBJETIVOS E RESPOSTAS A QUESTÕES DE PESQUISA	54
4.2	CONTRIBUIÇÕES DO TRABALHO.....	54
4.3	CONCLUSÃO.....	55
4.4	SUGESTÕES PARA FUTURAS PESQUISAS	56
	REFERÊNCIAS.....	57

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO DO PROBLEMA E QUESTÃO DE PESQUISA

Big Data ganhou relevância e atenção das comunidades acadêmicas e profissionais nas últimas décadas, o termo foi cunhado por Doug Laney no início dos anos 2000. Para Grable e Lyons (2018) o conceito *Big Data* inclui três abordagens principais, quais sejam volume, velocidade e variedade de dados. Sob a perspectiva de Alahakoon et al. (2020) *Big Data* relaciona-se aos conjuntos de dados nos quais a sua principal função é direcionar a tomada de decisão em larga escala com uso de tecnologia avançada (ALAHAKOON et al., 2020).

Segundo Ali et al. (2020) observaram que a utilização de *Big Data* impactará de forma positiva as organizações na tomada de decisões. Uma pesquisa desenvolvida por Holmlund et al. (2020) mostrou que a grande maioria das organizações entendem o significado da captura de dados os quais entram em seus negócios somados ao valor obtido na análise dos dados capturados.

Para Barlette e Barlette (2020) grandes volumes de dados são gerados diariamente em uma velocidade sem precedentes e de diversos tipos de fontes heterogêneas. Os dados pertencentes às organizações muitas vezes estão na forma de dados textuais não estruturados, o que traz uma dificuldade no momento de sua utilização na perspectiva de uma tomada de decisão mais rápida, assertiva e eficiente. Neste sentido, *Big Data* proporciona velocidades e eficiência como benefícios da sua utilização.

Sob a ótica de Zhang (2019) diante desse cenário, a gestão de negócios tem se tornado cada vez mais complexa devido às inovações, no qual os executivos de negócios precisam de suporte de dados para a tomada de decisões. Assim, a tomada de decisão baseada em dados está se tornando cada vez mais importante.

Além do *Big Data*, que tem como característica principal um conjunto ou processamento de dados, existe também o *Big Data Analytics*, cujo principal papel é direcionar todo seu potencial a análise de dados, ou seja, um resumo mais qualitativo das características gerais (GROVER; KAR, 2017; BARLETTE, 2020).

Hassani, Huang e Silva (2019) definem que *Big Data Analytics* consiste na criação de novas tecnologias e arquiteturas projetadas para que de forma eficaz extraia valor de um grande volume de dados. Essa tecnologia atraiu a atenção de empresas ao longo dos anos para direcionar a tomada de decisão e ampliar as vantagens competitivas. Para as empresas que já

adotaram essa tecnologia, categorizaram sua utilização como uma divisão crucial para inovação, competição e produtividade (HASSANI; HUANG; SILVA, 2018).

Por meio da aplicação do *Big Data Analytics*, Richey, Morgan e Hall-Lindsey (2016) entendem que é possível identificar os dados, mesmo que de forma desestruturada, que ajudarão nos pontos mais difíceis de analisar. Em *Supply Chain Management* (SCM) ou gestão da Cadeia de Suprimentos, existe uma alta dinâmica e mudanças de processos constantes nos quais, com a ajuda do *Big Data Analytics*, é possível firmar análises qualitativas, além da possibilidade de entender melhor a cadeia de suprimentos e os principais pontos operacionais como volume, velocidade, variedade e veracidade.

Nos processos de SCM, *Big Data Analytics* também aparece como um ponto estratégico na colaboração e na tomada de decisão. Mangla, Raut e Narwane definem que a implementação de *Big Data Analytics* de forma controlada é um desafio, pois ainda existem oportunidades de exploração a serem realizadas no próprio contexto que liga do fornecedor ao cliente final (MANGLA; RAUT; NARWANE, 2020).

Segundo Gunasekaran et al. (2017) dado à complexidade de atuação em melhorar sua visibilidade, flexibilidade, integração dos processos na cadeia de suprimentos, SCM conta com *Big Data Analytics* para trazer uma eficiência nesses pontos. Grande parte da complexidade de SCM ocorre por conta das variações da demanda, que flutuam em altas escalas dependendo do movimento econômico mundial o qual pode alterar de um dia para o outro.

Dessa maneira, essa dissertação buscou trabalhar com os principais fatores críticos de sucesso para implementação do *Big Data* e *Big Data Analytics* em SCM. Por tratar-se de um problema multicritério, uma das formas eficientes que existe para trabalhar essa questão é por meio de Tomada de Decisão Multicritério ou *Multi-Criteria Decision Making* (MCDM).

Para Tramarico et al. (2015), um dos métodos que pode ser adotado para se trabalhar com MCDM é *Analytics Hierarchy Process* (AHP). Nesse contexto, AHP é um dos métodos mais utilizados em MCDM.

Apesar de o método AHP ser utilizado em momentos de decisões mais simples, é mais útil quando utilizado em problemas complexos, repercussão de longo-prazo, processos com dificuldade de quantificação ou comparação de elementos decisórios e problemas de comunicação entre os elementos. Com a utilização do modelo Benefícios, Oportunidades, Custos e Riscos (BOCR), é possível a construção de uma hierarquia para selecionar os principais critérios de decisão.

Esta dissertação apresenta os principais fatores críticos de sucesso que podem apoiar o processo de tomada de decisão na escolha das melhores alternativas para implementação do *Big Data* e do *Big Data Analytics*.

Por meio das características de *Big Data* e *Big Data Analytics*, para entender a identificação, extração e organização de dados relevantes aplicados a SCM, esta dissertação buscará responder a seguinte questão: quais os principais fatores críticos de sucesso que possam contribuir na implantação de *Big Data* e de *Big Data Analytics* para tomada de decisão?

1.2 OBJETIVOS, DELIMITAÇÃO DA PESQUISA, JUSTIFICATIVAS E LACUNAS DE PESQUISA

No sentido de buscar respostas as questões de pesquisa, elencadas na seção anterior, o objetivo geral da pesquisa é propor um processo de análise da aplicação de *Big Data* e de *Big Data Analytics* em SCM.

Os objetivos específicos incluem:

- Identificar os principais fatores críticos de sucesso na implantação de *Big Data* e de *Big Data Analytics*.
- Explorar o uso dos fatores críticos de sucesso na implementação de *Big Data* e de *Big Data Analytics* em SCM;

A pesquisa delimita-se na avaliação da aplicação de *Big Data* e de *Big Data Analytics* em SCM nos processos de distribuição.

Na justificativa de pesquisa, para Fu *et al.* (2020), a quantidade de dados produzidos e compartilhados tem aumentado de ano para ano, criando desafios para as organizações em que é preciso trabalhar de forma inovadora diariamente. Isso faz com que as organizações que trabalhem de forma eficiente com banco de dados, consigam ter um desempenho mais competitivo.

Enquanto, há alguns anos, uma empresa reuniria dados, executaria análises e desenterraria informações que poderiam ser usadas em decisões futuras, Yuda, Ueda e Kisohara (2020) analisam que hoje essas empresas podem identificar ideias para decisões imediatas. A capacidade de trabalhar mais rápido e permanecer ágil dá às organizações uma vantagem competitiva que elas não tinham antes.

Assim, Tanwar *et al.* (2020) propõem que a exploração do *Big Data* tem como objetivo apoiar as perspectivas de agregação de valor e que essa tecnologia seja uma fonte para permitir

que gerentes industriais e executivos de negócios façam estratégias operacionais, decisões rápidas e mais eficientes no gerenciamento da produção. *Big Data* tem feito grandes avanços recentemente no mundo corporativo, trazendo uma solução possível e viável para que quase todos os desafios das operações organizacionais enfrentados pela indústria tenham uma maior eficiência nas tomadas de decisão (MILLER; GANSTER; GRIFFIS, 2018).

A utilização de tecnologia na era digital, segundo Sagaert et al. (2017), tem levado a aprimoração das análises de negócios a empresas de grande e médio porte, em que além da utilização do *Big Data*, as companhias contam com a aplicação do *Big Data Analytics* que tem como principal característica de *Big Data Analytics*, nesse contexto, é fornecer para as empresas uma segurança e agilidade maior nas tomadas de decisões estratégicas, nas quais automaticamente a empresa consegue ganhar vantagem competitiva de mercado.

Holmlund expõe que expectativas estão sendo cada vez mais criadas em relação ao *Big Data Analytics*. Conforme os resultados vão aparecendo, o de SCM ainda é pouco explorado, onde em que a dificuldade consiste em ligar todos os elos da cadeia. No momento em que a decisão precisar ser de todos que estão ligados aos processos, será fundamental e primordial que todos tenham conhecimento dessa ferramenta, considerando também os fornecedores externos. Somente em conjunto a tomada de decisão será mais eficaz.

Desse modo, embora a expectativa de adoção do *Big Data Analytics* para melhorar o desempenho em SCM seja bastante alta, ainda são poucas as empresas que já implementaram esse processo, seja em uma ou mais funções em SCM. As principais razões para a baixa aceitação são a falta de compreensão de como pode ser implementado, a incapacidade de identificar dados adequados, mudança nas rotinas, assimilação de uma nova metodologia com os processos atuais e segurança de dados (ECK; CAZAR; CALLEGARO, 2019).

Apesar da aplicação do *Big Data* trazer inúmeras vantagens com seu avanço tecnológico na qualidade de extrair dados, ainda não foi definida de fato o quanto a mão de obra fica afetada, visto que seu papel em alguns casos, será identificar algumas oportunidades operacionais o que poderá acarretar a redução de quadro de pessoas (SPANAKI; GURGUC; ADAMS, 2018).

No Quadro 1, observam-se as algumas lacunas identificadas na literatura nos últimos 5 anos.

Quadro 1 - Lacuna de pesquisa

Autoria	<i>Big Data</i>	<i>Big Data Analytics</i>	Tópicos
Spanaki; Gurguc; Adams (2018)	x		Consequências operacionais
Wang <i>et al.</i> (2016)	x		Usabilidade em tempo real
Tanwar <i>et al.</i> (2020)	x		Exploração em diversos setores
Song; Fisher; Robin (2020)		X	Exploração em diversos setores
Mishra <i>et al.</i> (2017)	x		Valor de investimento inicial
Winter; Hahn (2020)		X	Perfis de profissionais de trabalho
Dubey <i>et al.</i> (2020)	x		Testes iniciais antes de aplicação
Tenkorang; Helo (2016)	x		Sensibilidade de dados

Fonte: Autoria própria

Para Wang *et al.* (2016) O grande modelo de usabilidade atual do *Big Data* é posterior ao processo ou execução da produção. Apesar de sua grande característica já trazer grandes pontos de vantagens competitivos no mercado, para quem o usar, ainda não foi explorada de forma significativa a sua utilização na causa raiz e nem durante o processo, ou seja, de forma *on time* no processo de produção.

Big Data deveria ter sua usabilidade explorada não somente em empresas de cunho industrial como eletrônico, automobilístico e financeiro (TANWAR *et al.*, 2020), mas também e como modelo de aplicação em outros setores como Saúde e Ambiental (SONG; FISHER; ROBIN, 2020).

Além do olhar mais direcionado, para aos benefícios que *Big Data* traz como apoio com base de dados para a tomada de decisão, visto que sua grande competência é a facilidade de junção e extração de dados, Mishra *et al.* (2017) será de extrema importância o estudo de competências que consigam estimar o valor de investimento, tanto de implantação, quanto para manter profissionais especializados.

Winter e Hahn (2020) observaram que ainda é escasso no mercado mão de obra especializada com perfil de aplicação de *Big Data Analytics*. Esse profissional precisará garantir a implantação de forma eficiente, tanto pelo lado operacional quanto pelo financeiro. Com isso, as empresas terão uma certa dificuldade no modelo de contratação de pessoas para implementação e suporte.


Big Data tem mostrado ser promissor com sua utilização, porém, sua utilização que traz um destaque na inovação precisa ser estudada o máximo possível antes de ser incluso como parte principal de análise das empresas. *Big Data* precisa ser testado de diversas formas antes da sua implementação total (WAMBA; MISHRA, 2015).

Um fator primordial que deverá crescer na mesma escalabilidade que o *Big Data* é a questão da segurança das informações dos dados trabalhado nesse processo. *Big Data* fornece uma gama muito grande de dados e, com isso, a sensibilidade de utilização e guarda de dados ainda é algo a ser aprimorado (TENKORANG; HELO, 2016).

1.3 ETAPAS E CLASSIFICAÇÃO DO MÉTODO DE PESQUISA

Sob a ótica da Engenharia de Produção e da Metodologias Científicas, existem quatro Métodos principais que suportam uma pesquisa no direcionamento de torná-la quantitativa, sendo: Modelo de Pesquisa de Avaliação; Modelagem e Simulação; Experimento; Quase-Experimento (MIGUEL, 2018). Na Figura 1, observa-se a classificação da pesquisa, orientando e sendo base para toda essa dissertação. Os campos sublinhados são utilizados para explicação da classificação (KHOTARI; GARG, 2019)

Figura 1 – Classificação da pesquisa




Fonte: Adaptado de Khotari e Garg (2019).

Uma avaliação final é a validação para entendimento se o modelo feito de fato é semelhante aos objetivos esperados, no aspecto de questionar se esse modelo atende ou não, às finalidades para as quais foi construído, ou seja, se está dando resposta conveniente ao problema que foi levantado ao se iniciar o projeto de modelagem (RAHMAN; KAMAL; AYDIN, 2020).

Quanto aos procedimentos, pode-se classificar esta pesquisa como Modelagem, pois a utilização de modelos permite compreender o ambiente em questão, identificar e formular o problema e sistematizar o processo de tomada de decisão (MIGUEL, 2018).

O fluxograma de pesquisa (Figura 2) iniciou-se com a elaboração do referencial teórico, contendo pesquisa bibliométrica sobre *Big Data Analytics* em SCM, conceitos de *Big Data*, *Big Data Analytics* e fatores críticos de sucesso. Em seguida, identificaram-se e classificaram-se os fatores críticos de sucesso. Na etapa 3 do fluxo, classificaram-se os fatores críticos de sucesso no modelo BOCR e de acordo com a opinião dos especialistas.

Figura 2 - Etapas da pesquisa



Fonte: Autoria própria.

Na etapa 4, aplicou-se AHP com definição da hierarquia, apoiado por um Software para a execução dos cálculos, e Julgamento dos especialistas. Ainda nesta etapa, os principais processos executados no AHP foi o julgamento de cada fator BOCR. Na etapa 5, validaram-se

os resultados e como apoio para a verificação dos resultados, foi aplicado uma análise de sensibilidade para a garantia dos resultados encontrados anteriormente com os especialistas que contribuíram com os julgamentos iniciais. O Fluxograma de Pesquisa finalizou com a elaboração das conclusões finais, contemplando a verificação dos objetivos, contribuição do trabalho e sugestão para pesquisas futuras.

1.4 ESTRUTURA DO TRABALHO

O trabalho foi estruturado em mais três capítulos além dessa introdução, subdivididos em seções. O Capítulo 2 é composto pelo Referencial Teórico de *Big Data Analytics* em SCM na distribuição e na produção, além de descrever os principais fatores críticos de sucesso e sobre o método AHP.

O Capítulo 3 descreve a aplicação prática da execução dos fatores críticos de sucesso por meio do método AHP e do modelo BOCR na apresentação do problema encontrado, nos aspectos de *Big Data* e *Big Data Analytics* em SCM.


Por último, o Capítulo 4 apresenta as Considerações Finais da Dissertação. Após esse capítulo, encontram-se as Referências Bibliográficas.

2 REFERENCIAL TEÓRICO

2.1 PESQUISA BIBLIOMÉTRICA SOBRE *BIG DATA* EM SCM

A pesquisa foi realizada em agosto de 2020 na base de dados *Web of Science*. O intervalo (2015 a 2020) adotado gerou visões mais recentes para o trabalho. A pesquisa retornou 101 artigos, utilizando as palavras chaves “*Big Data*”, “*Big Data Analytics*”, “*Supply Chain*”. Na Figura 3, observa-se a quantidade de publicações divididas nas principais categorias da *Web of Science*: *Management*; *Business*; *Operation Research Management Science*; *Economics*; *Transportation*; *Transportation Science Technology*.

Figura 3 - Número de publicações por categorias e ano



Fonte: Web of Science (2020).

Na Tabela 1, observa-se o resumo da pesquisa.

Tabela 1 - Resumo de dados

Resumo de dados	Valor
Número de artigos	101
Número de referências citadas	2.408
Média de citação	24
Índice h	26


Fonte: Web of Science (2020).

O índice h encontrado na Tabela 1, tem como principal característica mostrar o resultado encontrado em uma lista de publicações classificados em ordem decrescente de acordo com o seu número de citações. Sendo assim, um índice h de 26 significa que existem 26 itens que possuem 26 citações ou mais (HIRSCH, 2005).

Os principais periódicos identificados foram: *Annals Of Operations Research*; *Business Process Management Journal*; *Decision Support Systems*; *European Journal Of Operational Research*; *Expert Systems With Application*; *Industrial Marketing Management*; *International Journal Of Logistics Management*; *International Journal Of Production Economics*; *International Journal of Production Research*; *Information Management*; *Journal Of Business Research*; *Journal of Enterprise Information Management*; *Journal of Manufacturing Systems*; *Management Decision*; *Mis Quarterly*; *Production Planning Control*; *Production And Operations Management*.

Na segunda etapa da pesquisa bibliométrica, criou-se uma rede de citação a partir da utilização do software *CitNetExplorer* na versão 1.0 desenvolvido pelo *Center for Science and Technology Studies* (CWTS, 2014) da Universidade de Leiden.

Figura 4 - Rede de citação *Big Data* e SCM



Fonte: CWTS (2014).

Na Figura 4 observa-se a rede de citação gerada a partir do software *CitNetExplorer*, onde cada círculo representa uma publicação e traz o sobrenome do primeiro autor. Observe-se que

uma publicação mencionando uma outra publicação está sempre localizada abaixo da última (ECK; WALTMAN, 2014).

Nota-se que os antecessores que dão início a essas publicações são Vera-Baquero *et al*, 2015; Schoenherr (2015). Identificou-se que o principal tópico citado foi *Big Data* com foco em *business*. *Big data* tornou-se capital para as empresas, algumas das maiores empresas de Tecnologia do mundo, tais como Apple, Microsoft e IBM tem como grande parte do seu valor extraídas de dados, que elas analisam constantemente para produzir mais eficiência e desenvolver novos produtos cada vez mais moldados às necessidades de seus públicos (MIKALEF *et al.*,2020).

Dada a enorme quantidade de dados criada por meio de transações de clientes em lojas de varejo, não é nenhuma surpresa que os varejistas estejam ativamente buscando iniciativas para alavancar os grandes dados e oferecer aos seus clientes serviços superiores que fornecem benefícios mútuos, anteriormente inatingíveis. No entanto, o cumprimento de tal objetivo estratégico requer que os clientes adotem e abracem serviços emergentes baseados em Tecnologia (ALOYSIUS, 2019; SONG; FISHER; WANG; CUI, 2016).

Tayal e Singh (2018) definem que os dados gerados dentro uma empresa e fora dela pela Internet para SCM é cada vez mais volumoso. Eles oferecem um enorme potencial para uma gestão mais eficaz da cadeia de suprimentos com base em grandes dados e análise preditiva, com estoque menor e mais rápido gerando benefício para a empresa e para o cliente.

Para Vera-Baquero *et al.* (2015), cinco fases são fundamentais na estruturação da metodologia de *Big Data* com visão em negócios. Na visão de Jeble, Kumari e Patil (2018) as fases são classificadas como Identificação do Processo, Estudos e Definições pós identificação, coleta de dados, monitoria e execução, análise e aproveitamento do resultado.

Segundo Qiu, Liu e Si (2017) seguindo o rápido desenvolvimento da Nuvem e da Internet Móvel, a conexão entre dados globais está aumentando rapidamente. O desenvolvimento da Nuvem e do armazenamento virtual fornece um método eficaz para reduzir o custo de armazenamento de *Big Data*. Isso pode ser uma das comprovações que oportunidades de desenvolvimento e aplicação de *Big Data* se formaram.

Uma das mudanças mais importantes, na ótica de Miller, Ganster e Griffis (2018); Li *et al.* (2018) no cenário de negócios mundiais é o aumento da disponibilidade de dados e consequentemente a habilidade para incorporar os mesmos ao tomar decisões. Embora o termo *Big Data* tenha várias definições (MISHRA *et al.*,2017), a maioria converge para os temas apresentados em que *Big Data*, em grande maioria, refere-se a uma grande quantidade de dados

em que os movimentos tradicionais não conseguem exercer uma boa manipulação, como por exemplos as planilhas.

Para Kache e Seuring (2017) *Big Data* tem sido fundamental para o desenvolvimento de novas soluções de gerenciamento de riscos, pode melhorar a eficácia dos modelos de gerenciamento de riscos e contribuir para a criação de estratégias mais inteligentes.

Hazen, Skipper e Ezzel (2016); Boone (2018) entendem que *Big Data* desempenha um papel crucial, quando utilizado na sua forma eficiente, considerando profissionais altamente qualificados. Ele ajudará a tangenciar na transformação do clima de negócio, trazendo potencialidade nos desafios das decisões. No entanto, existe um debate significativo sobre a avaliação de *Big Data Analytics* em SCM.

Big Data Analytics é um termo abrangente para técnicas, destinado a lidar com temas caracterizados por termos de alto volume, velocidade e variedade (GUNASEKARAN *et al.*, 2017; FERNANDO; CHIDAMBARAM; WAHYUNDI, 2018). *Big Data Analytics* pode ajudar a enfrentar os desafios críticos da análise preditiva que se referem à captura de dados, armazenamento, transferência e compartilhamento (ou seja, arquitetura do sistema).

Para Zhan e Tan (2020) garantir que as Tecnologias utilizadas na empresa sigam as evoluções que ocorrem praticamente todos os dias é crucial para as empresas continuarem se destacando no mercado econômico mundial. Por meio do *Big Data Analytics* é possível que as empresas criem produtos e inovações de acordo com o perfil do seu público, saindo do modelo tradicional de oferecer sempre o mesmo tipo de serviço.

Um tópico que está na mente de muitos profissionais de SCM, analisado por Schoenherr e Pero-Speler (2015) é como lidar com grandes quantidades de dados e como aproveitar e aplicar análises preditivas. Esse desafio é resultado direto da facilidade com que os dados puderam ser coletados por meio da Moderna Tecnologia da Informação, gerando volume, variedade e velocidade de dados sem precedentes.

Queiroz e Telles (2018) colocam que *Big Data Analytics* em SCM tem o potencial de melhorar a previsão de demanda, as comunicações e gerenciar melhor os recursos da cadeia de suprimentos. Apesar de tais benefícios reconhecidos e do aumento da pesquisa de *Big Data Analytics*, pouco se sabe sobre as abordagens gerais usadas para investigar nesse contexto. As abordagens preditiva e prescritiva são as utilizadas mais frequentemente em que os recursos organizacionais, tecnológicos e humanos são frequentemente gerenciados pelo *Big Data Analytics*.

Segundo Richey *et al.* (2016) consultores de empresas acreditam que *Big Data Analytics* vai revolucionar a indústria e a tomada de decisões. Mesmo com as especulações de

crescimento de forma exponencial do *Big Data Analytics*, alguns profissionais temem que o seu valor ainda é algo exagerado ou estipulado pelo lado das empresas de *Marketing* desse setor. Infelizmente, como é o caso de muitos tópicos populares ainda faltam pesquisa em SCM com utilizações mais úteis e diretas (RICHEY et al., 2016).

Com a grande capacidade de *Big Data Analytics*, Sander (2016) afirma que a previsão está mudando no que tange a conseguir informações mais precisas em relação à previsão de demanda, apoiando assim a companhia a tomar decisões em um tempo que permite manobras operacionais e financeiras mais rápidas.

Mais precisamente, *Big Data Analytics* requer processar, analisar, proteger e fornecer um acesso granular a conjuntos de dados armazenados. Dubey (2016) analisa que as empresas e indústrias estão mais conscientes de que a análise de dados tem se tornado, cada vez, mais um fator vital para ser competitivo, para descobrir novos *insights* e personalizar serviços (DUBEY, 2016).

Maehmood, Merition e Graham (2017) compartilham da ideia que a implementação do *Big Data Analytics* permite que as empresas de serviço melhorem os componentes do serviço e desempenho da cadeia de suprimentos por meio de maior flexibilidade, capacidade de resposta no atendimento ao cliente e na confiabilidade.

Para Barbosa (2020) a vantagem do *Big Data Analytics* para as empresas é que elas o estão utilizando para otimizar o preço cobrado de seus clientes. O objetivo é estabelecer os preços de forma que o lucro seja maximizado. Por meio do *Big Data Analytics*, as organizações analisam os valores que lhes renderam o máximo de lucro sob várias condições históricas de mercado. As soluções de dados definem o preço do produto de acordo com a disposição do cliente em pagar em diferentes circunstâncias.

2.2 BIG DATA ANALYTICS EM SUPPLY MANAGEMENT

2.2.1 *Big Data Analytics* nos Processos de Produção

As indústrias que trabalham com apoio de tecnologia e dados para as tomadas de decisões de forma rápida e inteligente, na visão de Liu, Agostinho e Duan (2020) são referenciadas pelos termos *Big Data* e *Big Data Analytics*, *Smart Factory*, Indústria 4.0 e Internet das Coisas. Esses termos estão diretamente ligados à quarta Revolução Industrial, que é caracterizada pela Inteligência Artificial e troca de dados em Tecnologias de fabricação.

Moktadir *et al.* (2019) observaram que mesmo as companhias que estão ligadas a um ambiente que utiliza dados globais, os processos de produção ainda são longos e complexos. O trabalho a ser realizado para otimizá-los deve ser apoiado pela capacidade de examinar cada item de seu processo e o pelo seu elo de abastecimento de matéria-prima. Apoiando-se na tecnologia *Big Data Analytics*, o processo da fábrica com o processo de abastecimento dos fabricantes tornar-se-á mais transparente e ágil, elevando o nível de eficiência operacional e financeira.

Para Ardito *et al.* (2019), *Big Data Analytics* exerce um papel fundamental para atingir ganhos de produtividade, além de possibilitar novos *insights* que impulsionam a inovação. Os fabricantes podem descobrir novas informações e identificar pontos em comum que possibilitarão a melhoria de processos, aumento da eficiência na cadeia de suprimentos e identificar variáveis que afetam a produção.

Coad e Shrhoj (2020) observam que atualmente a manufatura continua sendo uma parte importante no contexto econômico mundial. Sem dúvida, ainda é um fator importante na criação de empregos pelo mundo desenvolvido, mas, em Economias mais maduras, os fabricantes impulsionam ganhos e inovações em produtividade e eficiência.

Segundo Heeks (2020) para otimizar a qualidade e o rendimento da produção, fabricantes precisam ter um fluxo diário de dados de suas linhas de produção, a fim de detectar discrepâncias e oportunidades em tempo real. Isso inclui dados de sensores do maquinário de produção e de informações financeiras que estão adequadamente vinculados a dados operacionais para as análises.

Ahmad, Afzal e Alharbi (2020) notaram que essa afirmação é de fato algo que está sendo explorado mundialmente. Eles observam que grandes executivos de empresas mundiais estão apostando no *Big Data Analytics*. Em sua maioria, o entendimento é de que a utilização desse fator será necessária para competir com sucesso em uma Economia baseada em dados. Sabe-se que o fator de investimentos inicial para integração sistêmica, o que possibilitará o gerenciamento de dados e fará com que as empresas alcancem a transformação digital, é elevado.

Além da exploração do *Big Data Analytics* que tem sido trabalhada, Rialti (2020) enxerga que, por meio de um modelo eficiente de análise, os fabricantes podem examinar cada segmento do seu processo de produção e examinar as cadeias de suprimento, considerando as tarefas individuais. Além disso, eles entendem também que *Big Data Analytics* revela dependências, permitindo que as empresas aprimorem em sua produção os processos e criem rotas secundárias

para lidar com imprevistos internos (fonte de fornecimento) ou então, com as incertezas do mercado.

Contrariando essa visão, Bag (2020) enxerga oportunidade além da agilidade da produção convencional. Para ele, as grandes companhias mundiais estão concentradas em produção de escala única ou com baixa variável e com pouca visão em produção de produtos customizados e/ou personalizados, que estão focados com as empresas que atendem ao nicho de mercado. No passado, não fazia sentido personalizar devido ao tempo e ao esforço envolvidos para atrair um grupo menor de clientes, porém, *Big Data Analytics* tem mudado essa visão.

Nesse mesmo contexto de produção diferenciado do convencional, *Big Data Analytics* tem possibilitado uma mudança nas empresas que aplicam essa Tecnologia, permitindo prever com mais precisão de produtos personalizados (SUGANYA; MURUGAVALLI, 2019). O fator que possibilita esse processo, detecta mudanças no comportamento do cliente. Assim, sua análise permitirá mais tempo de processamento por parte do fabricante, oferecendo a oportunidade de criar e produzir produtos personalizados em uma eficiência quase tão grande do que a produção em escala única (BATISTIC; SASA, 2019).

Ao disponibilizar os insumos necessários para uma análise mais profunda dos processos, *Big Data Analytics* permite identificar pontos na da produção nos quais eles podem inserir processos diferenciados do que o mercado utiliza, gerando a possibilidade de entregar produtos customizados usando recursos internos (JAIN; NEELAKANTAN; KEY, 2020).

Um comparativo é firmado entre um ambiente de análise de dados tradicional e um relacionado ao *Big Data*. Em uma relação direta, o tempo de análise no modelo tradicional não trabalha em tempo real com as informações mesmo com dados estruturados, trazendo baixo valor aos dados trabalhados. No processo do ambiente com *Big Data*, é possível enxergar uma alta agregação de valor, uma vez que é possível trabalhar com dados estruturados e não estruturados, em tempo real com as informações e com grande agregação de valor.

Para as companhias que desejam implementar essa Tecnologia, Hogarth e Soyer (2015) afirmam que o grande desafio é sobre o Modelo de Implementação da Tecnologia *Big Data Analytics* e quais os tipos de profissionais para garantir suas análises. Essas informações são fontes importantes em de SCM para as tomadas de decisões.

2.2.2 *Big Data Analytics* nos Processos de Distribuição.

Uma pesquisa desenvolvida por Ogbuke (2020) apontou que aproximadamente 64% dos profissionais de SCM sentem a necessidade de rever os modelos dos processos existentes e adicionar flexibilidade às operações de negócio, de forma a garantir toda a distribuição, reduzir custos e dar resposta à constante mudança da procura do consumidor.

Mun *et al.* 2020 entenderam que, por conta da complexa dinâmica do processo de distribuição, existe uma alta exigência para que as empresas olhem atentamente para as soluções tecnológicas disponíveis. Transparência, agilidade e eficiência são pontos mais importantes que se impõem hoje em SCM, naturalmente, a área de logística e distribuição não fica de fora e só tem a ganhar se olhar para os seus dados.

Singh *et al.* (2019) observaram que em SCM, a Produção e a Distribuição são áreas complexas e que mais dados geram nas empresas. Com alterações não previstas diariamente das demandas, clientes e os parceiros exigem constantemente uma gestão das operações aprimorada com entregas mais rápidas e ao menor custo. Uma solução de *Big Data Analytics* permite gerar *insights* desses dados armazenados, o que irá proporcionar tomadas de decisão mais precisas e adequadas.

Com uma visão integrada da cadeia logística, para Perkhofer (2020) é possível otimizar as entregas, perceber as rotas mais eficientes, controlar com precisão os horários de entrega e fazer uma eficaz gestão dos pedidos. As soluções tecnológicas ajustadas à sua realidade permitem que esses sistemas funcionem em tempo real para todas as operações nacionais e internacionais.

Segundo Barham, Daim (2020) por meio do *Big Data Analytics* será possível melhorar toda a cadeia logística, fazer previsões da procura, de forma a efetuar entregas nos prazos corretos, e assim conseguir reduzir custos e desperdício, além de aprimorar a experiência junto ao cliente. Ao otimizar as tarefas mais rotineiras, ganhará ainda em produtividade e em todos os processos operacionais, o que impactará diretamente na distribuição.

Por tanto, para Kache e Seuring (2017), internamente toda a organização ganha em celeridade, produtividade e eficiência, com as soluções de *Big Data Analytics* que permitem aumentar a fluidez no relacionamento com os clientes e fornecedores, tornando as operações mais rápidas e simples. Com isso, gera-se um controle absoluto desde o momento em que recebe um pedido até este ser entregue ao seu cliente final.

Mantendo a afirmação de que trabalhando com *Big Data Analytics*, toda a cadeia logística ganha flexibilidade e agilidade que trarão mais eficiência para o negócio, diferenciação e

aumento das vendas. Tirawi e Khan (2020) afirmam que é possível gerar soluções mais disruptivas do mercado, além dos fatores internos como conseguir definir a melhor rota possível, estimar o tempo necessário e o tipo de condições adequadas à distribuição.

Assim, é possível entender que o *Big Data Analytics* gera eficiência operacional, o que trará eficiência financeira e, conseqüentemente, um lugar cada vez melhor no mercado econômico mundial. Isso é possível, porque as operações são otimizadas com um controle absoluto do armazém até a entrega com o *Big Data Analytics*.

Um serviço de excelência a custos reduzidos permite uma otimização do inventário com um conhecimento preciso da procura e das principais tendências do mercado, pois ao conhecer melhor os seus clientes e necessidades, consegue gerir melhor seu estoque, ajustar os custos e aumentar a rentabilidade.

2.3 FATORES CRÍTICOS DE SUCESSO

Segundo Tsoy e Staples (2010), fatores críticos de sucesso definem os principais temas-chaves que a companhia deverá trabalhar para garantir o sucesso de implementação de algum projeto ou processo, como por exemplo a Tecnologia *Big Data* e *Big Data Analytics*. Em contrapartida, quando esses mesmos fatores são negligenciados ou ignorados, contribui-se e muito para o fracasso da organização.

No Quadro 2, observam-se os principais fatores críticos de sucesso encontrados na literatura e considerados relevantes para essa pesquisa. Na sequência, pode-se identificar o descritivo de cada um dos fatores críticos de sucesso (AJAH; NEWKE, 2019; AL-SAI *et al.*, 2020; FELIX *et al.*, 2017; MCAFEE, 2012; GIUSTI, 2020; SONY; NAIL, 2020; HAHN, 2019).

Quadro 2 - Fatores críticos de sucesso

Fatores críticos de sucesso	Ajah e Newke (2019)	Al-Sai <i>et al.</i> , (2020)	Félix <i>et al.</i> , (2017)	McAfee (2012)	Giusti, (2020)	Sony e Naik (2020)	Hahn (2019)
Ambiente de teste				X		X	
Apoio dos executivos						X	
Arquiteto de <i>Big Data</i>	X						
Cultura empresarial					X		
Desafios de gestão	X		X		X	X	X
Desperdício de dados	X						
Digitalização da empresa		X				X	X
Equipe de análises	X	X	X	X		X	
Equipe de negócios	X	X	X	X		X	X
Estratégia organizacional						X	
Indicadores de desempenho		X			X		X
Investimento geral		X	X		X		
Líder técnico		X		X			
Melhoria contínua					X		
Melhorias nos dados				X		X	
Novos negócios		X	X		X		X
Processos	X		X	X			X
Retenção talentos			X				
Segurança da informação	X			X	X	X	
Tecnologia				X	X		X
Tomada de decisão		X	X			X	
Uso de consultores					X		

Fonte: Autoria própria.

Descrição dos fatores críticos de sucesso do Quadro 2:

- Ambiente de Teste: Local de testes após alguma iniciativa realizada por alguma das equipes de análises;
- Apoio dos Executivos: Após tomada de decisões baseada em dados, os executivos têm que estar cientes e de acordo mesmo com possíveis resultados negativos;
- Arquiteto de *Big Data*: Definição estratégica e tática de entregas a partir da implementação de *Big Data*;

- Cultura Empresarial: Aculturamento de boa parte ou da empresa inteira de que dados são importantes para o futuro da companhia, assim como se manter em alta no mercado macroeconômico;
- Desafio de Gestão: Trabalhar com diversos tipos de conhecimentos e pessoas, mantendo o alinhamento, desafio e objetivo de todos que trabalham com dados;
- Desperdícios de Dados: Entendimento de que, mesmo que os dados não estejam estruturados, eles não podem ser desperdiçados, ou seja, devem ser utilizados de alguma forma;
- Digitalização da Empresa: Promover discussões em que, cada vez mais, os funcionários novos e antigos devem ter suas análises pautadas em dados;
- Equipe de Análises: Especialistas técnicos que conheçam de Dados, levando o seu conhecimento ao nível de *Big Data* para composição da equipe;
- Equipe de Negócios: Para as áreas “não-técnicas”, é importante ter especialistas que saiba a importância de Dados para a composição do negócio;
- Estratégia Organizacional: Alinhamento entre Executivos, Diretores, Gerente e Especialistas sobre os principais objetivos da companhia com a implementação de *Big Data* para as tomadas de decisões, incluindo os riscos no processo;
- Indicadores de Desempenho: Métricas para acompanhamento operacional para tomadas de decisões pautadas em Dados, fornecidos por meio de *Big Data* e suas composições;
- Investimento Geral: Inclusão de recursos financeiros para a contratação de profissionais com perfil analítico sobre Dados e conhecimento atuais de Tecnologias; recursos financeiros para aprimoramento e conhecimento constante dos funcionários em Tecnologia de Dados;
- Líder Técnico: Especialista com alto conhecimento em *Big Data* e Dados para liderança dos outros funcionários que compõem seu time ou projeto;
- Melhoria contínua: Inovações devem ser sempre contempladas no ambiente de trabalho para a melhoria contínua da Tecnologia, cascadeando um efeito em processos e projetos;

- Melhoria nos Dados: Desafio de organização no modelo de guarda de Dados com foco em qualidade da informação, garantindo sempre uma facilidade maior na Tecnologia implementada e nos processos de análises;
- Novos negócios: Desenvolver novos produtos para garantir uma variedade maior de ofertas para o cliente, além da busca por mais resultados na empresa;
- Processos: Auxiliar nas rotinas que suportam o negócio de forma automatizada;
- Retenção de talentos: Olhar diferenciado para os profissionais que estão escassos no mercado, remunerando-os com valores acima da média;
- Segurança da Informação: Modalidade no qual garante que os Dados, sejam eles de formas estruturadas ou não, estejam protegidos de maneiras a que poucos tenham acesso e para que não ocorra vazamento de informação;
- Tecnologia: Disponibilizar a melhor solução que há no Mercado de Dados, o que fará com que a Área de Negócios tome ações mais rapidamente;
- Tomada de Decisão: Alinhamento entre os executivos para autonomia direta aos especialistas para as tomadas de decisões *on time* sem a necessidade da permissão para todo tipo de processo;
- Uso de Consultores: Análise do trabalho por meio de Consultores para garantir que o trabalho realizado pelos Especialistas esteja sendo realizado da forma mais eficiente possível para o projeto.

2.4 ANALYTIC HIERARCH PROCESS

AHP, que foi desenvolvida na década de 1970, é tida como uma Metodologia de escolha e decisão das alternativas com múltiplos critérios, tanto quantitativos, quanto qualitativos (GOMES; ARAYA; CARIGNANO, 2003).

Apesar de a linha de raciocínio do AHP ter surgido a há muito tempo, Matsumoto (2020) entende que sua utilização fornece um procedimento compreensivo e racional para modelar um problema de decisão, representando e quantificando as variáveis envolvidas em uma hierarquia de critérios ponderados por preferências. O resultado é um modelo que permite analisar várias alternativas e as comparar rapidamente, por isso conhecido como um Método de Decisão, tornando-se muito útil para reduzir falhas nesse processo.

Além disso, em problemas complexos, por existir uma grande variedade de alternativas, não é humanamente possível analisar todas as soluções individualmente nem as comparar (BONYADI; ASGHARI; KIAEI, 2020).

Uma vez modeladas as preferências (critérios e pesos), o AHP permite analisar muitas alternativas como:

- Atributos: As alternativas são comparadas em relação a um conjunto de critérios;
- Correlação Binária: Para cada critério, duas alternativas são comparadas binariamente, isto é, uma alternativa é preferível ou indiferente à outra;
- Escala Fundamental: A cada elemento se associa um valor de prioridade numa escala numérica; Hierarquia: conjunto de elementos ordenados por ordem de preferência em seus níveis hierárquicos.

Saaty (1991), salienta que, no geral, a tomada de decisão com o AHP envolve os seguintes passos:

- Planejamento;
- Geração do conjunto de alternativas;
- Estabelecimento de prioridades;
- Escolha da melhor política.
- Após definição do Conjunto de Alternativas;
- Alocação de recursos;
- Determinação dos requisitos;
- Previsão dos resultados;
- Projeto dos sistemas;
- Avaliação de desempenho;
- Garantia de estabilidade do sistema;
- Otimização; resolução de conflitos.

O AHP é dividido em três fases:


- Estruturação do problema de decisão;
- Avaliação comparativa de elementos;
- Síntese de prioridades.

AHP foi criado para lidar com problemas de decisão complexos e ajudar a identificar e atribuir pesos a múltiplos critérios de seleção relativos a alternativas existentes. O Método

incorpora medidas de avaliação objetivas e subjetivas e permite testar a sua consistência (SAATY, 2013). A estruturação do problema fica evidenciada em um diagrama, como o da Figura 5.

A primeira etapa para a utilização AHP, a construção de uma hierarquia. Constantino e Pellegrino (2010) mostram que a hierarquia precisa ter ao menos três níveis, como mostrado na Figura 5. O primeiro nível refere-se a meta (objetivo final da hierarquia), seguido pelo nível dois que é formado pelos critérios e subcritérios caso existam, e finaliza-se com o nível três que são as alternativas utilizadas como base para os níveis anteriores.

Figura 5 - Hierarquia AHP



Fonte: Constantino e Pellegrino (2010).

O AHP, assume um conjunto de critérios que tenha sido conectado e que esteja tentando estabelecer uma forma de normalização de pesos (ALIYEV; TEMIZKAN, 2020), como mostrada na Figura 5, sendo:

- **Decomposição:** O princípio da Decomposição pede a construção de uma rede hierárquica para representar um problema de decisão, representando θ no topo o objetivo global e os mais baixos níveis representam os critérios, subcritérios e alternativas;
- **Julgamentos Comparativos:** Solicita-se aos participantes do grupo de decisão a construção da matriz de comparação em cada Hierarquia, comparando pares de critérios e subcritérios. É apresentada nessa etapa uma escala de valores que variam de 1 (indiferença) a 9 (preferência extrema) para expressar a preferência de cada componente do grupo de discussão;
- **Síntese de Prioridades:** É a fase de calcular um peso composto para cada alternativa baseada em preferências derivadas da Matriz de Comparação.

Após o alinhamento da primeira etapa que foi a construção de uma hierarquia, deverá ser descrito a escala fundamental de Saaty, que trabalha sobre os intervalos de 1 a 9, sendo: 1 = Igualmente importante; 5 = Mais importante; 9 = Extremamente mais importante.

A terceira etapa consiste em aplicar o processo de Julgamento de Decisão. A estruturação hierárquica permite alinhar os julgamentos separadamente. A maneira mais eficiente de realizar os julgamentos, é tomar um par de elementos e compará-los em relação a uma única propriedade.

As comparações aos pares são usadas para determinar a prioridade dos critérios, em relação ao objetivo principal. Normalmente, os pares de comparação são executados por meio de uma hierarquia contida nas alternativas dos níveis mais baixos, em relação ao critério do nível mais alto.

O princípio dos julgamentos comparativos consiste no seguinte: tomando-se os elementos de um nível, comparam-se todos deste nível, par-a-par, com cada um dos elementos do nível imediatamente superior, medindo-se a intensidade de sua importância. Esse princípio auxilia o tomador de decisão munindo-o de um método padronizado de exercer as comparações.

A quantificação dos julgamentos, realizados par-a-par, é feita com a ajuda de uma escala padronizada. A escolha dos pesos pode ser feita a partir da escala numérica ou da equivalente escala qualitativa.

Saaty (2013) elenca o processo para decompor a decisão no AHP. Se não for satisfatório, refazer julgamentos, seguindo as etapas do Quadro 3.

Quadro 3 - Processo de julgamentos de decisão AHP

Passo	Execução
1	Foco somente no problema definitivo
2	Alinhar a matriz a matriz de decisores responsáveis
3	Trabalhar com matrizes de comparação em pares
4	Continuar o seu processo de comparação e priorizar os fatores decisivos
5	Calcular o índice de consistência

Fonte: Constantino e Pellegrino (2010).

Na sequência, faz-se necessário identificar a consistência das matrizes, observado por Tabatabaee *et al.* (2019) como o grau de confiabilidade que um conjunto de variáveis pretende medir. Saaty (2013) afirma que A é consistente se, e somente se $\lambda_{\max} \geq n$.

Os valores de a_{ij} não necessariamente precisam ser valores baseados em medidas exatas, mas em julgamentos subjetivos. A situação faz com que seus valores tenham um desvio em

relação à razão ideal, sendo necessário medir a consistência para verificar se sua proposição é no mínimo aceitável.

A consistência deve ser verificada por meio de dois axiomas, sendo o primeiro axioma:

- Existem λ_i , $i = 1, 2, \dots, n$, tal que satisfaça a equação: $Ax = \lambda x$.
- Em que x é um vetor de pesos.

Se a Matriz A é consistente, logo os autovalores serão iguais a zero, com exceção do n , o maior valor de λ_i .

O segundo considera que:

- Se a diagonal da Matriz A for de números com $a_{ij} = 1$, e se A for consistente, pequenas variações de a_{ij} manterão o maior autovalor próximo de n e os autovalores restantes próximos a zero.

Sendo assim, faz-se necessário encontrar o autovetor w de pesos que satisfaça a Equação (1):

$$Aw = \lambda_{\text{máx}} w \quad (1)$$

O autovetor w fornece a ordem por nível de importância dos critérios da Matriz A , que estimará pesos reais aos critérios que estão sendo comparados. Para as comparações de caráter subjetivo, precisa-se avaliar a proximidade entre $\lambda_{\text{máx}}$ e n , para isso precisa-se calcular a Razão de Consistência (RC), representada pela Equação (2):

$$RC = \frac{IC}{IR} \quad (2)$$

Índice de Consistência (IC), representado pela Equação (3):

$$IC = \frac{\lambda_{\text{máx}} - n}{n - 1} \quad (3)$$

No Quadro 4, apresenta-se Índice Randômico (IR) (SAATY, 2013).

Quadro 4 - Índice Randômico

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,48	1,56	1,57	1,59

Fonte: Saaty (2013).

Para Saaty (2013), considera-se aceitável o valor de inconsistência de $RC \leq 0,10$. Caso $RC > 0,10$, a qualidade dos julgamentos está comprometida, e deve ser melhorada.

2.5 DECISÃO EM GRUPO COM O MÉTODO AHP

As técnicas para tomada de decisão em grupo envolve a avaliação das alternativas apresentadas para resolver uma determinada questão. Elas podem ajudar na classificação e priorização das melhores alternativas apresentadas. No entanto, diversas etapas de escolhas são consideradas complexas, vistos as grandes variáveis e as incertezas que as influenciam. Para Peniwati (2006), há uma diversidade de ramificações envolvidas no processo de tomada de decisão, tais como intelectuais, psicológicas e os efeitos no ambiente do decisor.

Uma decisão em grupo envolve algumas complexidades naturais, além dos fatores de relações interpessoais de um dado grupo decisor. Em um grupo existe, geralmente, pluralidade de opiniões e de poderes de persuasão.

Segundo Cruz (2011), todos os fatores e critérios, sendo eles encontrados ou não na literatura, devem ser apresentados de forma clara aos julgadores, onde cada indivíduo poderá fazer seu julgamento de forma individual ou em grupo para chegar a um consenso.

Para Forman e Peniwati (1998), o fator que determinará será a forma com que os dados serão analisadas, agregadas e julgadas. Para a atuação de grupos que atuam em uma mesma unidade de negócios, proporcionando um entrosamento e conhecimento maior, será utilizada uma abordagem do AHP conhecida como Agregação Individual de Julgamento (AIJ). No caso de formação de grupos com julgadores sem uma associação de conhecimento ou entrosamento, cujo a prioridade será o julgamento individual, utiliza-se uma abordagem AHP chamada de Agregação Individual de Prioridades (AIP).

Quando os julgadores dispõem acima de tudo, da organização e o bem maior nas tomadas de decisões, colocando acima das suas próprias preferência a evolução dos processos, garantia da melhor escolha, valores e objetivos pautado na contribuição em grupo e sintonia entre si, a melhor abordagem para trabalhar será a de AIJ (CRUZ, 2011).

Em cada uma das etapas de escolha e julgamento, o consenso pode ser simulado de acordo com a média geométrica do julgamentos individuais, ou seja, a média geométrica assume o papel virtual da etapa de discussão e consenso, a fim de evitar qualquer desgaste em relação aos itens escolhido.

O desenvolvimento algébrico se faz necessário para calcular o autovetor principal associado a matriz de decisão. Para Oliveira e Belderrain (2008), a usabilidade do Método Numérico das Potências para a obtenção do vetor de prioridades de uma matriz de decisão e alertam quanto ao emprego de algoritmos aproximados (média aritmética ou geométrica) em matrizes inconsistentes.

2.6 MODELO BOCR

Segundo Tramarico *et al.* (2012), com a aplicação do BOCR, os critérios julgados são organizados em pares opostos, em que B se opõe a C e O se opõe a R. Como classificação, B e O são categorias positivas, que geram ou remetem aos fatores que o acompanham a certeza ou a possibilidade futura de receita/lucro. Como definição, B é a sigla da palavra Benefícios e O representa a palavra Oportunidade.

De uma forma “não-positiva”, as siglas C e R são categorias de importância negativa, direcionadas a perdas e prejuízos. Como definição, C é a sigla da palavra Custo e R representa a palavra Riscos.

Com a aplicação desse Modelo, é possível extrair análise mais complexa e mais eficiente do que um simples Modelo abordado para avaliação de Custo x Benefícios, em que não são considerados possíveis variáveis (positivas e negativas).

O modelo BOCR permite o agrupamento de critérios e de subcritérios, além de possuir vantagem de distribuir os fatores analisados de acordo com as necessidades da empresa ou projeto. Sendo assim, é possível atribuir maior peso às categorias que se mostrarem mais relevantes para o processo de decisão.

Nesta dissertação, a complexidade e as diversas etapas e fatores a serem considerados na seleção dos principais fatores críticos de sucesso, justificam a utilização do modelo BOCR combinado com AHP (SAATY, 2010).

3 AVALIAÇÃO MULTICRITÉRIO DA APLICAÇÃO DE *BIG DATA* E *BIG DATA ANALYTICS*

3.1 CONTEXTO DA EMPRESA OBJETO DE ESTUDO

A pesquisa de avaliação de *Big Data* e *Big Data Analytics* foi realizada em empresa do ramo tecnológico de grande porte, presente no Brasil e em outros países de América do Sul e do Norte, cuja principal unidade localizada em São Paulo conta com mais de 1.500 funcionários administrativos. Ela está entre as maiores empresas tecnológica de distribuição de refeição, cuja solicitação é feita por meio de aplicativo no celular.

A empresa possui uma área diretamente relacionada com *Big Data* e *Big Data Analytics*, a qual mais de 100 funcionários trabalharam diariamente para suportar os avanços da tecnologia e o crescimento da empresa. Essa área especialista em dados suporta todas as outras áreas da empresa, ajudando nas decisões diárias.

3.2 CLASSIFICAÇÃO DOS FATORES CRÍTICOS DE SUCESSO

BOCR foi o meio utilizado para a classificação dos principais fatores críticos de sucesso (Quadro 2). A classificação foi realizada pelos especialistas de duas áreas da empresa objeto de estudo, sendo *Data Science* e *Data Analytics* focadas em atender as áreas: Distribuição, Fraudes, *Compliance*, Finanças e *Customer Experience* (Quadro 5).

Quadro 5 - Caracterização dos especialistas

Área dos Especialistas	Cargo dos Participantes	Tempo de vínculo com a Empresa	Área de Formação
<i>Data Science</i>	Data Lead	Até 2 anos	Ph. D. (Inteligência Artificial)
	Analista de dados IV	Até 2 anos	Especialista em Ciência de Dados
	Analista de Dados	Até 2 anos	Especialista em Ciência de Dados
	Analista de Dados II	Até 3 anos	Especialista em Ciência de Dados
<i>Data Analytics</i>	Data Lead	Até 2 anos	Mestre em Ciência da Computação
	Analista de Dados IV	Até 2 anos	Especialista em Ciência de Dados

Fonte: Autoria própria.

Os especialistas concluíram que os 22 fatores críticos de sucesso (Quadro 2) eram elegíveis para compor o estudo.

Para que a pesquisa tivesse um direcionamento único, foi elaborada uma reunião de grupo de trabalho para que a pesquisa fosse respondida em uma única agenda com todos os especialistas presentes. Antes da etapa de resposta da pesquisa, foi abordada uma explicação geral do tema BOCR para que todos pudessem entender como a classificação dos critérios deveriam ser realizadas (Quadro 6).

Quadro 6 - Resumo Siglas BOCR

Siglas	Resumo	Fator na classificação
B	Benefícios	Positivo
O	Oportunidades	Positivo
C	Custos	Negativo
R	Riscos	Negativo


Fonte: Autoria própria

Descrição do BOCR:

- Benefícios: Fator que trata consistência positiva para a empresa quando citados fatores financeiros e ou qualitativos e quantitativos nos processos;
- Oportunidades: Processo de melhoria com a implementação do fator crítico de sucesso mapeado, visando a resultados positivos sobre a ótica de Finanças ou de Processos;
- Custos: Fator que gerará despesas iniciais para a empresa, visando a trazer benefícios ao médio/longo prazo (financeiramente e processual);
- Riscos: Aplicações que não necessariamente garantirão um fator positivo com sua aplicação.

A classificação gerou discussão inicialmente em 3 fatores antes da discussão, sendo: Desperdício de Dados, melhoria nos Dados e uso de consultores. Após a discussão novamente do significado do BOCR, os especialistas chegaram a uma conclusão, fazendo assim a classificação (Figura 6).

Figura 6 - Classificação BOCR




Fonte: Autoria própria.

A classificação foi pautada na perspectiva e na experiência que os especialistas tiveram ao implementar o *Big Data* e *Big Data Analytics* na empresa estudada. Na visão deles, o termo Custos é o que servirá de base para todo o momento de implementação, pois de maneira unânime eles concordaram que a tecnologia muda diariamente e, se a empresa quiser se manter na frente com o uso de dados, deverá se inovar, fazendo assim, sempre novos investimentos.

3.3 DEFINIÇÃO DA HIERARQUIA

Após a conclusão da definição dos fatores críticos de sucesso e sua classificação ao modelo BOCR, foi criada uma hierarquia para a aplicação do método AHP, observado na Figura 7.

Figura 7 - Hierarquia para avaliação de *Big Data* e *Big Data Analytics*

A Figura 7 apresenta uma hierarquia correlacionada e dividida em 4 níveis. No primeiro nível, definiu-se como objetivo “Avaliação Multicritério na aplicação de *Big Data* e *Big Data Analytics*”. No segundo nível, definiu-se como critérios: Benefício, Oportunidade, Custos e Riscos. No terceiro nível, definiu-se como subcritérios: Digitalização da Empresa (B1); Estratégia Organizacional (B2); Novos Negócios (B3); Processos (B4); Tecnologia (B5); Apoio dos Executivos (O1); Cultura Empresarial (O2); Indicadores de Desempenho (O3); Melhoria Contínua (O4); Melhoria nos Dados (O5); Ambiente de Teste (C1); Arquiteto de *Big Data* (C2); Equipe de Análise (C3); Equipe de Negócio (C4); Investimento Geral (C5); Uso de consultores (C6); Desafio de Gestão (R1); Desperdício de Dados (R2); Líder Técnico (R3); Segurança da Informação (R4); Tomada de Decisão (R5); Retenção de Talentos (R6). No quarto e último nível, definiram-se as alternativas: *Big Data* e *Big Data Analytics*.

3.4 APLICAÇÃO DO MÉTODO AHP

No caso desta pesquisa, onde os julgadores trabalham de forma sincronizada, compartilhando conhecimento no dia a dia, a abordagem escolhida no AHP foi a AIJ. Como apoio em seu desenvolvimento, utilizou-se o *Software Excel* para a execução dos cálculos de acordo com os critérios e julgamentos dos especialistas e obtenção dos resultados de acordo com o método AHP.

Na Tabela 2, uma análise par a par foi realizada para os critérios BOCR. As prioridades foram obtidas com a normalização do autovetor da matriz de comparações, em que o resultado apresentado serviu de base para a definição dos pesos de cada critério e que posteriormente foi utilizado na Tabela 7.

Tabela 2 - Prioridades dos critérios BOCR

	B	O	C	R	Autovetor	Prioridade
Benefícios (B)	1,00	3,00	1/5	1/3	0,67	13,17%
Oportunidades (O)	1/3	1,00	1/3	1/3	0,44	9,13%
Custos (C)	5,00	3,00	1,00	1,00	1,97	40,94%
Riscos (R)	3,00	3,00	1,00	1,00	1,73	36,03%
Total	9,33	10,00	2,53	2,67	4,81	100,00%

Fonte: autoria própria.

Na Tabela 2, os critérios BOCR foram analisados. Custos foi o critério que apresentou maior prioridade, seguido por Riscos. Após a análise, a Razão de Consistência ficou em 5,42% e ficou abaixo do limite tolerável de 10%. Portanto, esta matriz de julgamento pôde ser aceita.

Na etapa seguinte, iniciaram-se as comparações par a par entre os subcritérios definidos e apresentados na Figura 7. Assim como na etapa anterior, as prioridades foram obtidas com a normalização do autovetor da matriz de comparações.

As Tabelas 3, 4, 5 e 6 apresentam os resultados de prioridade para os subcritérios de Benefícios, Oportunidades, Custos e Riscos.

Tabela 3 - Prioridade dos subcritérios Benefícios

	B1	B2	B3	B4	B5	Autovetor	Prioridade
Digitalização da empresa (B1)	1,00	3,00	5,00	3,00	1/5	1,55	20,26%
Estratégia organizacional (B2)	1/3	1,00	3,00	1,00	1/7	0,68	8,85%
Novos negócios (B3)	1/5	1/3	1,00	1/3	1/7	0,32	4,13%
Processos (B4)	1/3	1,00	3,00	1,00	1/7	0,68	8,85%
Tecnologia (B5)	5,00	7,00	7,00	7,00	1,00	4,43	57,91%
Total	6,87	12,33	19,0	12,33	1,63	7,66	100%

Fonte: Autoria própria.

Na Tabela 3, cinco subcritérios de Benefícios foram analisados. Tecnologia foi o subcritério que apresentou maior prioridade, seguido por digitalização na empresa, estratégia organizacional, processos e novos negócios. Após a análise, a Razão de Consistência ficou em 6,75% e ficou abaixo do limite tolerável de 10%. Portanto, esta matriz de julgamento pôde ser aceita.

Tabela 4 - Prioridade dos subcritérios Oportunidades

	O1	O2	O3	O4	O5	Autovetor	Prioridade
Apoio dos executivos (O1)	1,00	1/5	1/3	3,00	1,00	0,72	11,31%
Cultura empresarial (O2)	5,00	1,00	1,00	7,00	3,00	2,54	39,57%
Indicadores de desempenho (O3)	3,00	1,00	1,00	5,00	3,00	2,14	33,40%
Melhoria Contínua (O4)	1/3	1/7	1/5	1,00	3,00	0,49	7,66%
Melhoria nos dados (O5)	1,00	1/3	1/3	1/3	1,00	0,52	8,07%
Total	10,33	2,68	2,87	16,33	11,0	6,41	100,00%

Fonte: Autoria própria.

Na Tabela 4, cinco subcritérios de Oportunidade foram analisados. Cultura Empresarial foi o subcritério que apresentou a maior prioridade, seguido por Indicadores de Desempenho, Apoio dos Executivos, Melhoria nos Dados e Melhoria Contínua. Após a análise, a Razão de Consistência ficou em 7,22% e ficou abaixo do limite tolerável de 10%. Portanto, esta matriz de julgamento pôde ser aceita.

Tabela 5 - Prioridade dos Subcritérios Custos

	C1	C2	C3	C4	C5	C6	Autovetor	Prioridade
Ambiente teste (C1)	1,00	1/3	3,00	5,00	1/3	1,00	1,09	15,69%
Arquiteto de <i>Big Data</i> (C2)	1/3	1,00	5,00	5,00	1/3	3,00	1,42	20,52%
Equipe de análise (C3)	1/3	1/5	1,00	5,00	1/3	1,00	0,69	9,99%
Equipe de negócio (C4)	1/5	1/5	1,00	1,00	1/7	1/5	0,25	3,56%
Investimento geral (C5)	3,00	3,00	3,00	7,00	1,00	1,00	2,40	34,52%
Uso de consultores (C6)	1,00	1/3	1,00	5,00	1,00	1,00	1,09	15,69%
Total	5,87	5,07	13,20	28,0	3,14	7,20	6,94	100%

Fonte: Autoria própria.

Na Tabela 5, seis subcritérios de Custos foram analisados. Investimento Geral foi o subcritério que apresentou a maior prioridade, seguido por arquiteto de *Big Data*, Ambiente de Teste, Uso de Consultores, equipe de análise e equipe de negócios. Após a análise, a Razão de Consistência ficou em 7,95% e ficou abaixo do limite tolerável de 10%. Portanto, esta matriz de julgamento pôde ser aceita.

Tabela 6 - Prioridade dos subcritérios Riscos

	R1	R2	R3	R4	R5	R6	Autovetor	Prioridade
Desafio de gestão (R1)	1,00	1/5	5,00	3,00	1/7	1,00	0,86	13,05%
Desperdício de dados (R2)	1/3	1,00	1,00	3,00	1/7	3,00	0,86	13,05%
Líder técnico (R3)	1/5	1,00	1,00	5,00	1/5	1,00	1,20	18,04%
Segurança na informação (R4)	1/3	1/3	1/5	1,00	1,00	1/5	0,31	4,66%
Tomada de decisão (R5)	7,00	7,00	1/3	5,00	1,00	3,00	2,50	37,58%
Retenção de talentos (R6)	1,00	1/3	1,00	5,00	0,33	1,00	0,90	13,62%
Total	9,87	9,87	8,53	22,0	4,82	9,20	6,66	100,00%

Fonte: Autoria própria.

Na Tabela 6, seis subcritérios de Riscos foram analisados. Tomada de Decisão foi o subcritério que apresentou a maior prioridade, seguido por Líder Técnico, Retenção de Talentos, Desafio de Gestão, Desperdício de Dados e Segurança da Informação. Após a análise, a Razão de Consistência ficou em 7,34% e ficou abaixo do limite tolerável de 10%. Portanto, esta matriz de Julgamento pôde ser aceita.

Após a validação das matrizes, realizada pelos especialistas (Quadro 5) seguiu na etapa de definição de prioridade para cada critério BOCR. O peso aplicado para essa etapa, foram os mesmos valores obtidos em prioridades da Tabela 2, ou seja, Benefícios (13,17%),

Oportunidades (9,13%), Custos (40,94%) e Riscos (36,03%). Com isso, observa-se na Tabela 7 a prioridade global dos critérios e subcritérios, elaborado pela multiplicação dos pesos dos critérios BOCR pelos valores de prioridade de cada subcritério.

Tabela 7 - Prioridade global dos critérios e subcritérios

	Critérios e Subcritérios	Prioridade Local	Prioridade Global
Benefícios		13,17%	13,17%
	Digitalização da empresa (B1)	20,26%	2,67%
	Estratégia organizacional (B2)	8,85%	1,17%
	Novos negócios (B3)	4,13%	0,54%
	Processos (B4)	8,85%	1,17%
	Tecnologia (B5)	57,91%	7,63%
Oportunidades		9,13%	9,13%
	Apoio dos executivos (O1)	11,31%	1,03%
	Cultura empresarial (O2)	39,57%	3,61%
	Indicadores de desempenho (O3)	33,40%	3,05%
	Melhoria contínua (O4)	7,66%	0,70%
	Melhoria nos dados (O5)	8,07%	0,74%
Custos		40,94%	40,94%
	Ambiente teste (C1)	15,69%	6,43%
	Arquiteto de <i>Big Data</i> (C2)	20,52%	8,40%
	Equipe de análise (C3)	9,99%	4,09%
	Equipe de negócio (C4)	3,56%	1,46%
	Investimento geral (C5)	34,53%	14,14%
	Uso de consultores (C6)	15,69%	6,43%
Riscos		36,03%	36,03%
	Desafio de gestão (R1)	13,05%	4,70%
	Desperdício de dados (R2)	13,05%	4,70%
	Líder técnico (R3)	18,04%	6,50%
	Segurança na informação (R4)	4,66%	1,68%
	Tomada de decisão (R5)	37,58%	13,54%
	Retenção de talentos (R6)	13,62%	4,91%

Fonte: Autoria própria

Ao analisar os resultados apresentados na Tabela 7, nota-se que a maior prioridade global de Benefício concentrou-se em Tecnologia, com 7,63%, seguido por Digitalização da Empresa (2,67%). Em Oportunidades, observa-se que a maior prioridade global está em Cultura Empresarial, com 3,61%, seguido por Indicadores de Desempenho, com 3,05%,

seguido por Apoio dos executivos (1,03%). Em Custos, a maior prioridade global está em Investimento Geral, com 14,14%, seguido por Arquiteto de *Big Data* (8,40%). Por último, em Riscos, o principal subcritério, com a maior prioridade Global, foi Tomada de Decisão, com 13,54%, seguido por Líder técnico 6,50%

Em continuidade à aplicação do AHP, a Avaliação das Alternativas foi realizada de modo qualitativo. Para tanto, utilizou-se a escala para medição absoluta, que contempla os níveis de qualidade e os valores de desempenho para cada um dos níveis (TRAMARICO *et al.*, 2019). Assim, apresenta-se a escala para medição absoluta na Tabela 8.

Tabela 8 - Escala para medição absoluta

Nível	Prioridade
N1 – Excelente	1,00
N2 - Muito bom	0,83
N3 - Entre bom e muito bom	0,67
N4 - Bom	0,50
N5 – Entre fraco e bom	0,25
N6 - Fraco	0,00

Fonte: Adaptado de Tramarico *et al.* (2019).

A avaliação qualitativa das alternativas foi realizada para todos os subcritérios, conforme exposto no Quadro 7; logo, compreende-se os seguintes resultados para *Big Data* (A1): N1 para B1, N3 para B2, N3 para B3, N3 para B4, N1 para B5, N2 para O1, N4 para O2, N2 para O3, N4 para O4, N3 para O5, N4 para C1, N2 para C2, N4 para C3, N4 para C4, N1 para C5, N4 para C6, N4 para R1, N3 para R2, N4 para R3, N2 para R4, N2 para R5 e N4 para R6. Para *Big Data Analytics* (A2), adotou-se o mesmo processo de avaliação.

Quadro 7 - Avaliação qualitativa de *Big Data* e *Big Data Analytics*

Alternativas/Subcritérios	B1	B2	B3	B4	B5	O1	O2	O3	O4	O5	C1	C2	C3	C4	C5	C6	R1	R2	R3	R4	R5	R6
<i>Big Data</i> (A1)	N1	N3	N3	N3	N1	N2	N4	N2	N4	N3	N4	N2	N4	N4	N1	N4	N4	N3	N4	N2	N2	N4
<i>Big Data Analytics</i> (A2)	N3	N2	N3	N2	N4	N2	N2	N3	N2	N2	N2	N2	N3	N3	N1	N2	N3	N2	N2	N2	N1	N2

Fonte: Autoria própria

Tabela 9 - Avaliação quantitativa de *Big Data* e *Big Data Analytics*

SUBCRITÉRIOS																						
Alternativas	B1	B2	B3	B4	B5	O1	O2	O3	O4	O5	C1	C2	C3	C4	C5	C6	R1	R2	R3	R4	R5	R6
<i>Big Data</i> (A1)	1,00	0,67	0,67	0,67	1,00	0,83	0,50	0,83	0,50	0,67	0,50	0,83	0,50	0,50	1,00	0,50	0,50	0,67	0,50	0,83	0,83	0,50
<i>Big Data Analytics</i> (A2)	0,67	0,83	0,67	0,83	0,50	0,83	0,83	0,67	0,83	0,83	0,83	0,83	0,67	0,67	1,00	0,83	0,67	0,83	0,83	0,83	1,00	0,83

Fonte: Autoria própria.

Na Tabela 9, as prioridades da Tabela 8 substituem os julgamentos qualitativos apresentados no Quadro 7. Logo, compreendem-se os seguintes resultados para *Big Data* (A1): 1,00 para B1, 0,67 para B2, 0,67 para B3, 0,67 para B4, 1,00 para B5, 0,83 para O1, 0,5 para O2, 0,83 para O3, 0,50 para O4, 0,67 para O5, 0,50 para C1, 0,83 para C2, 0,50 para C3, 0,50 para C4, 1,00 para C5, 0,50 para C6, 0,50 para R1, 0,67 para R2, 0,50 para R3, 0,83 para R4, 0,83 para R5 e 0,50 para R6. Para *Big Data Analytics* (A2), adotou-se o mesmo processo de avaliação.


O desempenho quantitativo baseia-se na escala de mediação absoluta (Tabela 8), no desempenho qualitativo (Quadro 7) e nas prioridades globais (Tabela 7). O cálculo da prioridade para a alternativa *Big Data* (A1) foi realizado e obteve 72,71%, conforme detalhado:

$$\begin{aligned} A1 = & 1,00 \times 2,67\% (B1) + 0,67 \times 1,17\% (B2) + 0,67 \times 0,54\% (B3) + 0,67 \times 1,47\% (B4) \\ & + 1,00 \times 7,63\% (B5) + 0,83 \times 1,03\% (O1) + 0,5 \times 3,61\% (O2) + 0,83 \times 3,05\% (O3) + 0,50 \times \\ & 0,70\% (O4) + 0,67 \times 0,74\% (O5) + 0,5 \times 6,43\% (C1) + 0,83 \times 8,40\% (C2) + 0,5 \times 4,09\% (C3) \\ & + 0,5 \times 1,46\% (C4) + 1,00 \times 14,14\% (C5) + 0,5 \times 6,43\% (C6) + 0,5 \times 4,70\% (R1) + 0,67 \times \\ & 4,70\% (R2) + 0,5 \times 6,50\% (R3) + 0,83 \times 1,68\% (R4) + 0,83 \times 13,54\% (R5) + 0,5 \times 4,91\% (R6) \\ = & 72,41\%. \end{aligned}$$

O mesmo procedimento foi elaborado para *Big Data Analytics* (A2), que apresentou uma prioridade de 81,96%. No resultado da Avaliação, a alternativa *Big Data Analytics* (A2) apresentou maior prioridade sobre *Big Data* (A1), com uma margem superior de aproximadamente 9 pontos percentuais.

Foi possível realizar uma análise de sensibilidade dos critérios Benefício, Oportunidade, Custos e Riscos

Figura 8 - Análise de sensibilidade para o critério Benefício




Fonte: Autoria própria.

Na Figura 8, a linha vertical preta representa a prioridade para o critério Benefício. Para Benefícios, a prioridade obtida foi de 13,17 % (Tabela 7) na qual a alternativa A2 apresenta-se em vantagem. Observa-se que ao alcançar a prioridade 27,5% há uma inversão e a alternativa A1 torna-se a mais vantajosa.

Na Figura 9, a linha vertical preta representa a prioridade para o critério Oportunidade. Para Oportunidade, a prioridade obtida foi de 9,13 % (Tabela 7) na qual a alternativa A2 apresenta-se em vantagem. Observa-se que para quaisquer valores acima deste, a alternativa A2 se mantém vantajosa.


Figura 9 - Análise de sensibilidade para o critério Oportunidades



Fonte: Autoria própria.

Na Figura 10, a linha vertical preta representa a prioridade para o critério Custos. Para Custos, a prioridade obtida foi de 40,94 % (Tabela 7) na qual a alternativa A2 apresenta-se em vantagem. Observa-se que para quaisquer valores acima deste, a alternativa A2 se mantém vantajosa.


Figura 10 - Análise de sensibilidade para o critério Custos



Fonte: Autoria própria.

Na Figura 11, a linha vertical preta representa a prioridade para o critério Custos. Para Riscos, a prioridade obtida foi de 36,03% (Tabela 7) na qual a alternativa A2 apresenta-se em vantagem. Observa-se que para quaisquer valores acima deste, a alternativa A2 mantém vantagem.

Figura 11 - Análise de sensibilidade para o critério Riscos



Fonte: Autoria própria.

Pelos resultados obtidos, entende-se que para as companhias que desejam começar a implementar essa Tecnologia haverá alguns processos a serem seguidos. A primeira etapa, seria a implementação da Tecnologia *Big Data Analytics*, que tem objetivo direcionar todo seu potencial a análise de dados, ou seja, um resumo mais qualitativo das características gerais. Dentro desse critério, existem, também, os principais subcritérios que precisam ser levados em consideração, como os destaques Tecnologia (critério Benefício), Cultura Empresarial (critério Oportunidade), Investimento Geral (critério Custos) e Tomada de Decisão (critério Riscos).

Após a implementação da Tecnologia *Big Data Analytics*, com maior prioridade, a qual demandará uma nova cultura empresarial, conclui-se que pode seguir para a próxima etapa, que é a implementação de *Big Data*.

O resultado foi apresentado para os especialistas que, em comum acordo, concordou com a importância destacada de cada alternativa.

4 CONSIDERAÇÕES FINAIS

4.1 VERIFICAÇÃO DOS OBJETIVOS E RESPOSTAS A QUESTÕES DE PESQUISA

O objetivo geral desta dissertação foi alcançado, no qual se apresentou um procedimento, utilizando MCDM a seleção dos principais fatores críticos de sucesso na implementação de *Big Data* e *Big Data Analytics* em SCM. A identificação de critérios existentes na literatura permitiu a definição da estrutura pelos especialistas. O Resultado da Avaliação mostrou claramente a classificação das alternativas *Big Data* e *Big Data Analytics*.

Em resposta a questão de pesquisa, foram identificados 22 critérios de fatores críticos de sucesso que contribuem de forma parcial ou total no sucesso da implantação das tecnologias *Big Data* e *Big Data Analytics*.

Esse trabalho entregou por meio da literatura, em resposta a questão de pesquisa, os principais fatores críticos de sucesso, sendo 22 no total, para a implementação do *Big Data* e *Big Data Analytics* em SCM. Para este desenvolvimento, foram utilizados os métodos e modelos AHP e BOCR, respectivamente nesta ordem.

4.2 CONTRIBUIÇÕES DO TRABALHO

Usando uma aplicação real, este trabalho contribuiu na identificação da literatura dos principais fatores críticos de sucesso para a implementação do *Big Data* e *Big Data Analytics*. Ilustrou como um procedimento para avaliação da implantação de *Big Data* e *Big Data Analytics* em SCM deve ser aplicado e contribuiu significativamente para a literatura AHP, *Big Data* e *Big Data Analytics*.

Como forma prática de aplicação do *Big Data Analytics* é a escolha de parceiros para fornecimento de dados para a empresa. Atualmente, somente ter uma boa base de dados não é mais suficiente para se destacar no mercado. O aprimoramento da usabilidade de dados é visto como uma forma mais eficiente a partir da usabilidade dentro da tecnologia *Big Data Analytics*. Essa conexão de dados com tecnologia é o fator mais positivo na contratação de um fornecedor para os negócios.

Outro grande benefício encontrado na utilização do *Big Data Analytics* é a possibilidade de analisar e obter dados em tempo real de diversos elementos da operação. Isso trará uma imagem mais nítida e realista para definir o êxito da empresa por meio de tomadas de decisões.

Em linhas gerais, percebe-se que o *Big Data Analytics* identifica e possibilita os gestores na atualização de produtos em tempo real.

A utilização do *Big Data Analytics* facilita a identificação dos diversos padrões de comportamento (mesmo com as sazonalidades), previamente as expectativas e as diversas características de cada categoria de clientes. Esse processo de conhecer antes o cliente e de maneira mais profundo ajuda a otimizar as ações de marketing e de comunicação, tornando-as mais eficientes.

A redução de custos orçamentários tem sido grandes pontos de atenção nas companhias e por meio do *Big Data Analytics* é possível entender e visualizar falhas nos processos de SCM, gargalos e pontos deficientes que geram altos gastos e nem sempre mantêm um bom nível de atendimento. Com aplicação do *Big Data* e *Big Data Analytics* é possível aprimorar a eficiência operacional.

4.3 CONCLUSÃO

Com a pesquisa, foi possível identificar um procedimento para avaliação dos principais fatores críticos de sucesso para a implementação do *Big Data* e *Big Data Analytics* em SCM.

É de extrema importância trabalhar em sinergia com especialistas para que possam julgar os principais fatores abordados. A utilização do modelo BOCR para classificação dos fatores críticos de sucesso foi fundamental, visto que, assimilada a utilização do AHP, pode-se julgar quais são os fatores mais prioritários para o processo;

Após a Avaliação Multicritério, estabelecida por meio de uma estrutura dos principais fatores críticos de sucesso, obteve-se o resultado no qual a alternativa *Big Data* destacou-se frente à alternativa *Big Data Analytics*, conclui-se assim que no momento da implementação dessas tecnologias, a alternativa *Big Data*, juntamente com seus critérios julgados, teve um destaque maior.

A avaliação apresentada não é sem limitações. Este resultado não pode ser simplesmente generalizado como estudos futuros necessários para estender as descobertas a outras organizações. No entanto, a mesma estrutura, bem como o mesmo procedimento, podem ser usados para avaliar as implementações de *Big Data* e *Big Data Analytics*. Afirma-se que as implementações de *Big Data* e *Big Data Analytics* devem ser comparadas a partir de múltiplas perspectivas, portanto, uma abordagem multicritério pode ser usada.

Em ambientes e cenários mais complexos, em que se requer a avaliação de diversos dados, organizados ou não, para uma visão mais completa e eficiente, o *Big Data Analytics* é a

melhor solução. A leitura e cruzamento de dados favorece, por exemplo, uma avaliação em alto nível de recepção de determinados produtos em um ou mais locais específicos.

4.4 SUGESTÕES PARA FUTURAS PESQUISAS

Como proposta para trabalhos futuros, sugere-se realizar um Estudo com Fatores Críticos de Sucesso na implementação de *Big Data* e *Big Data Analytics* com outros métodos diferente do AHP, como por exemplo *Analytic Network Process* (ANP) e *Measuring Attractiveness by a Categorical Based Evaluation Technique* (MACBETH). A razão da escolha dos métodos a serem aplicados foi devido ao fato de que todos os métodos são discretos (ISHIZAKA; NEMERY, 2013).

REFERÊNCIAS

- AHMAD, S.; AFZAL, M. M.; ALHARBI, A. Big Data Analytics with Fog Computing in integrated Cloud Fod and IoT Architecture for Smart Devices. **International Journal of Computers Science and Network Security**, v. 20, n. 6, p. 171-177, 2020. Disponível em: http://paper.ijcsns.org/07_book/202006/20200620.pdf. Acesso em: 05 jan. 2021.
- AJAH, I. A.; NWEKE, H. F. Big Data and Business Analytics: Trends, Platforms, Success Factor and Applications. **Big Data and cognitive computing**, v. 1, n. 3, p. 1-30, 2019. Disponível em: <https://www.mdpi.com/2504-2289/3/2/32/htm>. Acesso em: 20 out. 2020.
- ALAHAKOON, D.; NAWARATNE, R.; XU, YAN.; SILVA, D.; GUPTA, B. Self-Building Artificial Intelligence and Machine Learning to empower Big Data Analytics in Smart Cities. **Information System Frontiers Journal**, v. 14, n. 3, p. 123-141, 2020. Disponível em: <https://link.springer.com/article/10.1007/s10796-020-10056-x>. Acesso em: 13 dez. 2020.
- ALI, Q.; SALMAN, A.; YACOOB, K.; ZAINI, Z.; ABDULLAH, R. Does Big Data Analytics enhanced Sustainability and financial performance? The Case of ASEAN Banks. **Journal Research e ORCID**, v. 7, n. 7, p. 1-13, 2020. Disponível em: <https://www.koreascience.or.kr/article/JAKO202020952022381.page>. Acesso em: 14 jan. 2021.
- ALIYEV, R.; TEMIZKAN, H. Fuzzy Analytic Hierarchy Process-Based Multi-Criteria Decision Making for university Ranking. **Symmetry-Basel**, v. 12, n. 10, p. 431-442, 2020. Disponível em: <https://www.mdpi.com/2073-8994/12/8/1351>. Acesso em: 07 out. 2020.
- AL-SAI, Z. A.; ABDULLAH, R.; HUSIN, M. H. Critical Success Factors for Big Data: A **Systematic Literature Review**. **IEEE Access**, v. 1, n. 8, p. 1-19, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9127414>. Acesso em: 29 set. 2020.
- ALOYSIUS, J.; Shoplifting in mobile checkout setting cybercrime in retail store. **Information technology and people**, v.32, n. 14, p.1234-1261, 2019.
- ARDITO, L. SCUOTTO, V.; GIUDICE, M.; PETRUZZELI, A. M.; A blibliometric analysis of research on big data. **International Journal Management of research**, v. 13, n. 5, p. 321-334, 2019.
- BAG, S. The order-n-minors of certain (n plus k) x n matrices. **Linear Algebra and its Applications**, v. 603, n. 2, p. 368-389, 2020.
- BARBOSA, M. Sustainable Strategic Management (GES): Sustainability in small business. **Journal of cleaner production**, v. 258, n. 8, p. 2134-2147, 2020.
- BARHAM, H.; DAIM, T. The use of readiness assessment for big data projects. **Sustainable Cities and society**, v. 60, n. 14, p. 1-20, 2020.
- BARLETTE, Y.; BAILLETE, P. Big Data Analytics in turbulent contexts: toward organizational change for enhanced agility. **Production Planning & Control: The Management of Operation**, v. 16, n. 8, p. 411-426, 2020.

BATISTIC, S.; SASA, V. P.; History, Evolution and future of big data and analytics: A Bibliometric analysis of its relationship to performance in organizations. **British journal of management**, v. 30, n. 11, p. 229-251, 2019. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/1467-8551.12340>. Acesso em: 22 ago. 2020.

BONYADI, N.; ASGHARI, H.; KIAEI, M. Identification and prioritization of Employee Satisfaction Strategies in Tehran Regional Water Company using Analytics Hierarchy Process (AHP). **Tehnicki Glasnik-Technical Journal**, v. 14, n. 8, p. 251-256, 2020.

BOONE, C. A.; HAZEN, B. T.; SKIPPER, J. B. A framework for investigating optimization of service parts performance with big data. **Annals of operations research**, v. 270, n. 4, p. 65-74, 2018. Disponível em: <https://link.springer.com/article/10.1007/s10479-016-2314-1>. Acesso em: 04 mar. 2021.

CHIDAMBARAM, S.; SARASWATI, S.; RAMACHANDRA, R. JVM characterization framework of workload generated as per Machine Learning Benchmark and spark Framework. **IEE international conference on recent in electronics, information & communication**, v.1, n. 2, p. 1598-1602, 2018.

COAD, A.; SHRHOJ, S.; Catching Gazelles with a Lasso: Big data techniques for the prediction of high-growth firms. **Small Business Economics**, v. 55, n. 12, p. 541-565, 2020. Disponível em: <https://link.springer.com/article/10.1007/s11187-019-00203-3>. Acesso em: 07 mai. 2021.

CONSTANTINO, N.; PELLEGRINO, R. Choosing between single and multiple sourcing based on supplier default risk: A real options approach. **Journal of Purchasing and Supply Management**, v. 16, n. 3, p. 27-40, 2010. Disponível em: https://www.sciencedirect.com/science/article/pii/S1478409209000582?casa_token=0k9umwHATCMAAAAA:1E_f8jIBlGl8LGhQcpYsE40L2bSw__EgdoooPIIdArVJtDcofiAjJ-xwfKd7ZUxP2BNBfUGjBUxo. Acesso em: 02 out. 2020.

CRUZ, M. H. **Utilização de uma Metodologia de apoio a decisão na análise de outsourcing em uma empresa metalúrgica**. 2011. Dissertação (Mestrado em Engenharia) – Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2011. Disponível em: http://repositorio.unicamp.br/bitstream/REP_OSIP/263744/1/Cruz_MarcosHenglerda_M.pdf. Acesso em: 30 jul. 2021.

CURTO, H. **Problemas na tomada de decisão?** Saiba como o método AHP pode ajudar. Disponível em: <https://netproject.com.br/blog/problemas-na-tomada-de-decisao-saiba-como-o-metodo-ahp-pode-te-ajudar/>. Acesso em: 04 nov. 2020.

DUBEY, R.; GUNASEKARAN, A.; CHILDE, S.L.; BRYDE, D.J.; GIANNAKIS, M; FOROPON, C.; ROUBAUD, D.; HAZEN, B.T. Big data analytics and artificial intelligence pathway to operational performance under the effects of entrepreneurial orientation and environmental dynamism: a study of manufacturing organizations. **International Journal of Production economics**, v. 226, n. 9, p. 2763-2781, 2020.

ECK, A.; CAZAR, A. L. C.; CALLEGARO, M. Big data meets survey Science. Social Science **Computer Review**, v.13, n. 6, p. 139-148, 2019. Disponível em: <https://journals.sagepub.com/doi/full/10.1177/0894439319883393>. Acesso em: 02 dez. 2020.

ECK, N. J. V.; WALTMAN, L. CitNetExplorer: A new software tool for analysing and visualizing citation networks. **Journal of Informetrics**, v. 8, n. 11, p. 802–823, 2014.

FELIX, B. M.; TAVARES, E.; CAVALCANTE, N. W. F. Critical success factors for Big Data adoption in the virtual: Magazine Luiza case study. **Revista Brasileira de Gestão de Negócios. Review of Bussiness Management**, v. 20i, n. 21, p. 112-127, 2017. Disponível em: <https://www.scielo.br/j/rbgn/a/YJCMw9MBLV5nVWVT54cPvFp/?format=html&lang=en>. Acesso em: 07 abr. 2021.

FERNANDO, Y.; CHIDAMBARAN, R. R. M.; WAHYUNI-TD, I. S. The Impact of Big Data analytics and data security practices on service supply chain performance. **International journal of research**, v. 25, n. 3, p. 4009-4034, 2018. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/BIJ-07-2017-0194/full/html>. Acesso em: 04 dez. 2020.

FORMAM, E.; PENIWATI, K. Aggregating individual judgements and priorities with the Analytic Hierarchy Process, **European Journal of Operational Research**, v. 108, n. 5, p. 165-169, 1998. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0377221797002440>. Acesso em: 02 mai. 2021.

FISHER, C. M.; ROBIN, T.; Using Big Data to investigate disparities in cervix cancer survival: Racial and ethnic minorities and those with income and insurance disparities have worse overall survival from cervix cancer. **Cancer epidemiology biomarkers & prevention**, v. 29, n. 6, p. 411-423, 2020. Disponível em: https://cebp.aacrjournals.org/content/29/6_Supplement_1/B019.abstract. Acesso em: 21 set. 2020.

FU, W.; CHIEN, C.; TANG, L. Bayesian network for integrated circuit testing probe card fault diagnosis and troubleshooting to empower Industry 3.5 smart production and an empirical study. **Journal of intelligent manufacturing**, v. 14, n. 16, p. 376-389, 2020. Disponível em: <https://link.springer.com/article/10.1007/s10845-020-01680-0>. Acesso em: 07 jan. 2021.

HAZEN, B. T.; RUSSO, I.; C. I. Circular Economy: Recent Technology Management considerations supply chain innovation key to business-to-consumer close-loop system. **Johnson Matthey technology review**, v. 64, n. 3, p. 69-75, 2020. Disponível em: <https://www.ingentaconnect.com/content/matthey/jmtr/2020/00000064/00000001/art00009> . Acesso em: 19 out. 2020.

HAZEN, B. T.; SKIPPER, J. B.; EZZEL, J.; D. Big data and predictive analytics for supply chain sustainability: A Theory-driven research agenda. **Computers & Industrial Engineering**, v. 101, n. 3, p. 592-598, 2016. Disponível em: <https://www.infona.pl/resource/bwmeta1.element.elsevier-edd5dfcc-f874-3d85-ac61-e2dbc091d2bb>. Acesso em: 19 nov. 2020.

HOGARTH, R. M.; SOYER, E. Using simulated Experience to make sense of big data. **Mit Sloan management review**, v. 56, n.1, p. 49-54, 2015. Disponível em: <https://dialnet.unirioja.es/servlet/articulo?codigo=5130977> . Acesso em: 21 dez. 2020.

GIUSTI, R. Syncromodal logistics: An overview of critical success factors, enabling technologies, and open research issues. **Transportation research part e-logistics and transport review**, v. 129, n. 7, p. 92-110, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1366554519303928>. Acesso em: 04 set. 2020.

GOMES, L. F. A. M.; ARAYA, M. C. G.; CARIGNANO, C. Tomada de Decisões em Cenários Complexos. **São Paulo: Pioneira Thomson Learning**, 2003.168 p.

GRABLE, J.; LYONS, A. C. An Introduction to Big Data. **Economics & Investment Management**. v. 72, p. 17-20, 2018.

GROVER, P. KAR, A. K. Polarization and acculturation in US Election 2016 – Can twitter analytics predict changes in voting preferences. **Technological forecasting and social change**, v. 145, n. 11, p. 438-460, 2017.

GUNASEKARAN, A.; PAPADOPOULOS, T.; DUBEY, R.; WAMBA, S. F.; CHILDE, S. J.; HAZEN, B.; AKTER, S. Big Data and Predictive Analytics for Supply Chain and Organizational Performance. **Journal of Business Research**, v. 70, n. 7, p. 308-317, 2017.

HAHN, G. J. Industry 4.0: a supply chain innovation perspective. **International Journal of Production Research**, v. 58, n. 12, p. 1425-1441, 2020. Disponível em: https://www.tandfonline.com/doi/full/10.1080/00207543.2019.1641642?casa_token=3HAT7RSIlg6gAAAAA%3AsnSQgsYpAI9HBqr7HKYa0IFbsLmrniExI3Il-uHvhvuXZJ-EqG9TkQKPFTAd94nAhBewEeGJ9B9jKw. Acesso em: 02 mai. 2021.

HASSANI, H.; HUANG X.; SILVA, E. Banking with blockchain- ed big data. **Journal of management analytics**, v. 5, n. 19, p. 256-275, 2018.H. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/23270012.2018.1528900>. Acesso em: 07 abr. 2021.

HEEKS, R. Datafication, value and power in developing countries: Big data in two Indian public organization. **Development Policy Review**, v. 14, n. 5, p. 123-141, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/epdf/10.1111/dpr.12477>. Acesso em: 09 dez. 2020.

HIRSCH, J. E. An index to quantify an individual's scientific research output. **Proceedings of the National Academy of Sciences of the United States of America**, v. 102, n. 12, p. 16569–16572, 2005. Disponível em: <https://www.pnas.org/content/102/46/16569?pagewanted=all>. Acesso em: 14 dez. 2020.

HOLMLUND, M.; VARENBERGH, Y. V.; CIUCHITA, R.; RAVALD, A.; SARANTOPOULOS, P.; ORDENES, F. V.; ZAKI, M. Customer Experience management in the age of big data analytics; A Strategic framework. **Journal of Business research**, v. 116, n.16, p. 356-365, 2020.

ISHIZAKA, A.; NEMERY, P. Multi-criteria decision analysis. Chichester: **Wiley**, v. 2, n. 4, p. 281-296, 2013.

JAIN, K.; NEELAKANTAN, M; KEY, P. Limitations in the analysis of atherectomy Using Medicare big data. **Journal of endovascular Therapy**, v. 14, n.9, p. 204-218, 2020. Disponível em: https://journals.sagepub.com/doi/full/10.1177/1526602820951917?casa_token=hlVhubI6oQAAAAA%3AEAoUMB7nTIyuLxivUWQ1SHki7dW8k0NUK02qUTUhCMLuweDP-0-u03KMCf068UTllgtY4bkNIZlZHA. Acesso em: 19 nov. 2020.

JEBLE, S.; KUMARI, S.; PATIL, Y.; Roles of big data in decision Making. **Operations and supply chain management-an international journal**, v. 11, n. 2, p. 36-44, 2018. Disponível em: <https://journal.oscm-forum.org/publication/article/role-of-big-data-in-decision-making> . Acesso em: 14 ago. 2020

KACHE, F.; SEURING, S. Challenges and opportunities of digital information at the intersection of big data analytics and supply chain management. **International Journal of operation & production management**, v. 37, n. 18, p. 10-36, 2017. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/IJOPM-02-2015-0078/full/html>. Acesso em: 19 ago. 2020.

KOTHARI, C. R.; GARG, G. **Research methodology methods and techniques**. 4. ed. Nova Deli: New Age International, 2019.

LI, Y.; MA, C.; XU, L.; SHEN, X. D.; LI, M. Z. MapReduce-based parallel GEP algorithm for efficient function mining in big data applications. **Concurrency and computation-practice & experience**, v. 30, n. 12, p. 431-444, 2018.

LIU, G.; AGOSTINHO, F.; DUAN, H. Environmental impacts characterization of packaging waste generated by urban food delivery services. A big-data analysis in Jing-Jin-Ji region (China). **Waste Management**, v. 117, n. 2, p. 157-169, 2020.

MCAFEE, A. Big Data: The Management Revolution. **Harvard Business Review**, v. 1, n. 1, p. 1-9, 2012.

MAEHMOOD, R.; MERITION, R.; GRAHAM, G.; This is a repository copy of exploring the influence of big data on city transport operations: a Markovian approach. **Journal of Operations and Production Management**, v. 37, n, 18, p. 75-104, 2017.

MANGLA, S. K.; RAUT, R.; NARWANE, V. Mediating effect of big data analytics on projects performance of small and medium enterprises. **Journal of Enterprise information management**, v. 31, p. 116-132, 2020.

MATSUMOTO, L. **Analytics Hierarchy process: método de apoio a decisões**. Disponível em: <https://leonardo-matsumota.com/2018/04/20/analytic-hierarchy-process-ahp-metodo-de-apoio-a-decisoes-complexas/>. Acesso em: 04 nov. 2020.

MIGUEL, P. A. C. **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. 3. ed., São Paulo: Elsevier, 2018. 220p.

MIKALEF, P.; BOURA, M.; LEKAKOS, G. The role of information governance in big data analytics driven innovation. **Information & Management**, v. 57, n. 14, p. 612-619, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378720620302998>. Acesso em: 11 jan. 2020.

MILLER, J. W.; GANSTER, D. C.; GRIFFIS, S. E. Leveraging Big Data to Develop Supply Chain Management Theory: The Case of Panel Data. **Journal Of Business Logistics**, v. 39, n.6, p. 182-202, 2018.

MISHARA, D.; LUO, Z.; JIANG, S.; PAPADOPOULOS, T.; DUBEY, R. A Bibliographic study on big data: concepts, trends and challenges. **Business Process Management Journal**, v. 23, n. 17, p. 555-573, 2017.

MOKTADIR, M. A.; ALI, M.; KUSI, S.S.; SHAIKH, M.A.A. Assessing challenges for implementing Industry 4.0: Implications for process safety and environmental protection. **Process safety and environmental protection**, v. 117, n. 11, p. 730-741, 2019. Disponível em: https://www.sciencedirect.com/science/article/pii/S0957582018301344?casa_token=9df83g0t7aUAAAAA:j6dGNQIlcNgekwhTZVZ0CHL7rRsqliMh0nJg0ZBOreZDbQCnowApmjdIRKA7XSTbqsdZwHxi0q4. Acesso em: 29 set. 2020.

MUN, J.; HOUSEL, T.; JONES, R.; CARLTON, B.; SKOTS, V. Acquiring Artificial Intelligence System: Development challenges, implementation, risks, and cost/benefits **Opportunities**. **Naval Engineers Journal**, v. 132, p. 79-94, 2020. Disponível em: <https://www.ingentaconnect.com/content/asne/nej/2020/00000132/00000002/art00019>. Acesso em: 01 set. 2020.

OGBUKE, N. Big data supply chain analytics: ethical, privacy and security challenges posed to business, industries, and Society. **Production Planning & Control**, v.8, n. 2, p. 1-15, 2020.

OLIVEIRA, C. A.; BELDERRAIN, M. C. C. Considerações sobre a obtenção de vetores de prioridades no AHP, **Anales - Encuentro de Docentes de Investigación Operativa Primera Reunión**, v. 1, n. 10, p. 1-33, 2008.

PENIWATI, K. Criteria for evaluating group decision-making methods, **Mathematical and Computer Modelling**, v. 46, n. 8. p. 935-947, 2006. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0895717707001021>. Acesso em: 14 mai. 2020.

PERKHOFER, L.; WALCHSHOFER, C.; HOFER, P. Does design matter when visualizing Big Data? An empirical study to investigate the effect of visualization type and interaction use. **Journal of Management control**, v. 31, n. 11, p. 55-95, 2020.

QIU, T.; LIU, J.; SI, W. A Data-Driven Robustness Algorithm for the Internet of Things in Smart Cities. **IEEE Communications Magazine**, v. 55, n.1, p. 18-23, 2017.

QUEIROZ, M. M; TELLES, R. Big data analytics in supply chain and logistics: an empirical approach. **International Journal of logistics management**, v. 29, n. 7, p. 767-783, 2018. Disponível em: https://www.emerald.com/insight/content/doi/10.1108/IJLM-05-2017-0116/full/html?casa_token=uhR93sA_jkYAAAAA:5vLYwqG0hMpF3KF_hNO3HlAqR0aqczAQpjb7RpiMjHHXe0qpq7Ctce-_LkplKj_34Xf78VPUXYVl5WtDTJnHA2AadXKS30-M7oIF-HqO4uo8_EPAiF-. Acesso em: 07 mai. 2021.

RAHMAN, M.; KAMAL, M. M.; AYDIN, E. Impact of Industry 4.0 drivers on the performance of the service sector: comparative study of cargo logistic firms in developed and developing regions. **Production Planning & Control**, v. 10, n. 5, p 113-121, 2020.

RIALTI, R.; MARZI, G; CAPUTO, A. Achieving strategic flexibility in the era of big data the importance of knowledge management and ambidexterity. **Management Decision**, v. 4, n.18, p. 74-82, 2020.

RICHEY JR, R. G.; MORGAN, T. R.; HALL-LINDSEY, K.; ADAM, F. G. A Global exploration of big data in the supply chain. **International Journal oh Physical Distribution & Logistics**, v. 46, n. 2, p. 710-739, 2016.

SAATY, T. L. “How to make a decision: the analytic hierarchy process”. **European Journal of Operational Research**. Amsterdam, v. 48, n. 7, p. 9-26, 1991.

SAATY, T. L. **Principia Mathematica Decernendi**: mathematical principles of decision-making. Pittsburgh: RWS, 2010.

SAATY, T. L. The Modern Science of Multicriteria Decision Making and Its Practical Applications: **The AHP/ANP Approach**. **Operations Research**, [S. l.], v. 61, n. 5, p. 1101-1118, 2013.

SAGAERT, Y. R.; AGHEZZAF, E.; KOURENZES, N.; DESMET, B. Temporal Big Data for tire industry Tactical Sales Forecasting. a literature reviews. **Business Process Management Journal**, v. 28, n. 7, p. 619-632, 2017. Disponível em: <https://eprints.lancs.ac.uk/id/eprint/84497/>. Acesso em: 04 mar. 2021.

SANDER, N. R.; How to use big data to drive your supply chain. **Carolina management review**, v. 58, n. 15, p. 26-48, 2016. Disponível em: https://journals.sagepub.com/doi/abs/10.1525/cmr.2016.58.3.26?casa_token=ZKsK-PleJZYAAAAA:xsw0Hd8wIOvuvvm2dqm1m2dRfPG9Fpe5lw4wR4ExkQu7Cw1TWq6oGohdSsJOdD8o0d7UvhAkHB4eYRQ. Acesso em: 02 fev. 2021.

SCHOENHERR, T.; PERO-SPELER, C. Data Science, Predictive Analytics, and Big Data in Supply Chain Management: Current State and Future Potential. **Journal of Business Logistics**, v. 36, p. 120-132, 2015.

SINGH, P.; KAUR, A.; KUMAR, N. A reliable and cost-efficient code dissemination scheme for smart sensing device with mobile vehicles in smart cities. **Sustainable cities and society**, v. 62, n. 21, p. 12-29, 2019.

SONG, M.; FISHER, R.; WANG, J.; CUI, L. Environmental performance evaluation with big data: theories and methods. **Science Business Media Journal**, v. 270, p. 459-472, 2016. Disponível em: <https://link.springer.com/article/10.1007/s10479-016-2158-8>. Acesso em: 04 jan. 2021.

SONY, M.; NAIK, S.; Critical factors for the successful implementation of industry 4.0: a review and future research direction. **Production Planning & Control: The Management of Operations**, v. 31, n. 6, p. 799-815, 2020.

SPANAKI, K.; GURGUC, Z.; ADAMS, R.; Data Supply chain (DSC): Research synthesis and future directions. **Computers in industry**, v. 94, n. 19, p. 52-61, 2018. Disponível em: https://www.tandfonline.com/doi/full/10.1080/00207543.2017.1399222?casa_token=odG8prK0CJYAAAAA%3AY5zNNt32pLhZ-DiXV_6POYilx8V3PH1Uu4xA2cZY1yz-qnlYcDc2U-EOCCXcG-6r9cvk0TX2pZXCfG. Acesso em: 08 nov. 2020.

SUGANYA, T. S.; MURUGAVALLI, S.; A hybrid group search optimization: firefly algorithm-based big data framework for ancient script recognition. **Soft Computing**, v. 24, p. 10933-10941, 2019. Disponível em: <https://link.springer.com/article/10.1007/s00500-019-04596-x>. Acesso em: 03 jan. 2021.

TABATABAEE, S.; MAHDYYAR, A.; DUDRDYEV, S.; MOHANDÉS, S. R. An assessment model of benefits, opportunities, costs, and risk of green roof installation: A multi criteria decision making approach. **Journal of Cleaner Production**, v. 238, n. 17, p. 1314-1321, 2019. Disponível em: https://www.sciencedirect.com/science/article/pii/S0959652619328264?casa_token=SA0HZCX5hEkAAAAA:dL1S3Yz2Gc3FqIRwJGADSjLaQzUPNjIoq1kHYZA2URj5vGHsqiW7TYSJA2Ox_w1tWyIsVLscKCI. Acesso em: 04 dez. 2020.

TANWAR, A. S.; EVANGELATOS, N.; VENNE, J. Global Open Health Data Cooperatives Cloud in an Era of COVID-19 and planetary Health. **Omics-a Journal of Integrative Biology**, v. 2, n. 8, p. 23-35, 2020. Disponível em: <https://www.liebertpub.com/doi/full/10.1089/omi.2020.0134>. Acesso em: 02 abr. 2021.

TAYAL, A.; SINGH, S. P.; Integrating big data analytics and hybrid firefly-chaotic simulated annealing approach for facility problem. **Big Data analytics in operations & Supply Chain Management Journal**, v. 270, n. 3, p. 489-514, 2018. Disponível em: <https://link.springer.com/article/10.1007/s10479-016-2237-x>. Acesso em: 04 set. 2020.

TENKORANG, R. A.; HELO, P. T.; Big Data application in operations / supply-chain management: A literature review. **Computers & Industrial Engineering**, v. 101, n. 11, p. 528-543, 2016. Disponível em: https://www.sciencedirect.com/science/article/pii/S0360835216303631?casa_token=2GveSsrB6mYAAAAA:iKar1N5LScvW7HHx6ydlbydpAB_ts9IFCPPgqMs2eCkxGGrZHRHIwUvHMMjOLtvPtbal4YH6PAY. Acesso em: 04 dez. 2020.

TIWARI, K.; KHAN, M. S. Sustainability accounting and reporting in the industry 4.0. **Journal of Cleaner production**, v. 258, n. 8, p.211-234, 2020. Disponível em: https://www.sciencedirect.com/science/article/pii/S0959652620308301?casa_token=MrReNR TKJwwAAAAA:M1VfsSG8z7NLsodbQl4TRhTbCp2MfkQzWZOZBwiCx1HdwpQRZjXgU2b3ct2HYaw8bGGUkUoA24I. Acesso em: 07 mai. 2020.

TRAMARICO, C. L.; SALOMON, V. A. P.; MARINS, F. A. S.; MUNIZ JR, J. Modelagem com AHP e BOCR para seleção de prestadores de serviços logísticos. **PODes - Revista Eletrônica Pesquisa Operacional para o Desenvolvimento**, Rio de Janeiro, v. 4, n. 2, p. 139-159, 2012.

TRAMARICO, C. L.; MIZUNO, D.; SALOMON, V. A. P.; MARINS, F. A. S. M. Analytics Hierarchy Process and Supply Chain Management: a bibliometric study. **Information Technology and quantitative management (ITQM 2015)**, v. 55, p. 441-450, 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050915014805>. Acesso em: 10 fev. 2021.

TRAMARICO, C. L.; KARPAK, B.; SALOMON, V. A. P.; SILVEIRA, C. A. M.; MARINS, F. A. S. Multi-criteria analysis of professional education on supply chain management. **Research Article**, v. 29, 2019. Disponível em: <https://www.scielo.br/j/prod/a/LW3fNxVVCTLTqT5c59RtCfn/?lang=en>. Acesso em: 10 fev. 2021.

TSOY, M.; STAPLES, D. S.; What are the critical success factors for agile analytics projects? **Information System Management**, v. 4, n. 2, p. 41-57, 2020.

VERA-BAQUERO, A.; MOLLOY, O.; COLOMO-PALACIOS, R.; ELBATTAH, M.; Bussiness process improvement by means of big data based Decision support systems: a case study on call centers. **International journal of information systems and project management**, v. 3, n. 2, p. 5-26, 2015.

VIET, Q. P.; BAO, K. Q. N.; BINH, V. T. Critical Success Factors of Project Management: The Case of Construction Related Projects in Vietnam. **Journal of Asian finance economics and business**, v. 6, n. 7, p. 223-230, 2019. Disponível em: <https://www.koreascience.or.kr/article/JAKO201915658234994.page>. Acesso em: 14 mai. 2021.

WAMBA, S. F.; MISHRA, D. Big Data integration with business process: a literature review. **Business Process Management Journal**, v. 23, p. 477-492, 2015.

WANG, G.; GUNASEKARAN, A.; NGAI, E. W. T.; PAPADOPOULOS, T. Big Data analytics in logistics and supply chain management: Certain investigations for research and applications. **International Journal productions economics**, v. 176, n. 11, p. 98-110, 2016.

WEB OF SCIENCE. **Big Data Analytics, and supply chain management**. Disponível em: http://appwebofknowledge.ez87.periodicos.capes.gov.br/Search.do?product=WOS&SID=5ABtIGB7iFg6Ae8Lzgj&search_mode=GeneralSearch&prID=71857046-3062-4a3a-afeb-2ce3601ac6de. Acesso em: 08 nov. 2020.

WINJMALEN, D. J. D. Analysis of benefits, opportunities, costs, and risks (BOCR) with the AHP-ANP: A critical validation. **Mathematical and computer Modeling**, v. 46, n. 18, p. 892-905, 2007.

WINTER, N. R.; HAHN, T.; Big Data, ai and Machine Learning for precision Psychiatry: How are they changing the clinical practice? **Fortschritte der neurologie psychiatrie**, v. 4, n. 14, p. 86-101, 2020. Disponível em: <https://europepmc.org/article/med/32998163>. Acesso em: 04 nov. 2020

YUDA, E.; UEDA, N.; KISOHARA, M. Redundancy among risk predictors derived from heart rate variability and dynamics: ALLSTAR big data analysis. **Annals of noninvasive electrocardiology**, v. 21, n. 9, p. 201-209, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/anec.12790>. Acesso em: 02 nov. 2020.

ZHAN, Y.; TAN, K. H. An analytic infrastructure for harvesting big data to enhance supply chain performance. **European Journal of Operation research**, v. 281, n. 18, p. 559-574, 2020.

ZHANG, Y.; A big data-driven framework for sustainable and smart additive manufacturing. **Robotics and computer-integrated manufacturing**, v. 67, n. 5, p. 341-365, 2020.