

UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS BIOLÓGICAS
MESTRADO PROFISSIONAL EM INOVAÇÃO TECNOLÓGICA E PROPRIEDADE
INTELECTUAL

**INOVAÇÃO NO USO DE FERRAMENTAS E METODOLOGIAS DE *DATA*
ANALYTICS EM EMPRESAS DE MINAS GERAIS**

Artur Tancredo Guimarães de Alvarenga

Belo Horizonte
2022

Artur Tancredo Guimarães de Alvarenga

**INOVAÇÃO NO USO DE FERRAMENTAS E METODOLOGIAS DE *DATA*
ANALYTICS EM EMPRESAS DE MINAS GERAIS**

Dissertação apresentada ao Curso de Mestrado Profissional em Inovação Tecnológica e Propriedade Intelectual do Instituto de Ciências Biológicas da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre em Inovação Tecnológica e Propriedade Intelectual – Área de Concentração: Gestão da Inovação e Empreendedorismo.

Linha de pesquisa: Conhecimentos relacionados aos mecanismos de gestão do processo de inovação (modelos de negócios inovadores, portfólio para a inovação, projetos de inovação) e à estruturação organizacional para a inovação, incluindo construção de competências e aprendizagem organizacional.

Orientador: Dr. Allan Claudius Queiroz Barbosa

043

Alvarenga, Artur Tancredo Guimarães de.

Inovação no uso de ferramentas e metodologias de data analytics em empresas de Minas Gerais [manuscrito] / Artur Tancredo Guimarães de Alvarenga. – 2022.

116 f.: il. ; 29,5 cm.

Orientador: Dr. Allan Claudius Queiroz Barbosa.

Dissertação (mestrado) – Universidade Federal de Minas Gerais, Instituto de Ciências Biológicas. Mestrado Profissional em Inovação Tecnológica e Propriedade Intelectual.

1. Inovação. 2. Administração de pessoal. 3. Administração de dados. 4. Análise de dados. I. Barbosa, Allan Claudius Queiroz. II. Universidade Federal de Minas Gerais. Instituto de Ciências Biológicas. III. Título.

CDU: 608.5



**ATA DA DEFESA DA DISSERTAÇÃO DE MESTRADO Nº 159 DE
Artur Tancredo Guimarães de Alvarenga**

Às 14:00 horas do dia 22 de agosto de 2022, no auditório do Parque Tecnológico de Belo Horizonte - BHTEC, realizou-se a sessão pública para a defesa da Dissertação de Mestrado Profissional em Inovação Tecnológica e Propriedade Intelectual de Artur Tancredo Guimarães de Alvarenga. A presidência da sessão coube ao Prof. Dr. Allan Claudius Queiroz Barbosa, FACE/UFMG – Orientador. Inicialmente o Presidente fez a apresentação da Comissão Examinadora assim constituída: PROF. DR. REGINALDO DE JESUS CARVALHO LIMA, FPL; PROFA. DRA. GLAUCIENE SILVA MARTINS, CEFET/MG; PROF. DR. MARCUS VINICIUS GONÇALVES CRUZ, FJP (SUPLENTE) e PROF. DR. ALLAN CLAUDIUS QUEIROZ BARBOSA, PPGIT/FACE/UFMG – ORIENTADOR. Em seguida, o candidato fez a apresentação do trabalho que constitui sua Dissertação de Mestrado, intitulada "INOVAÇÃO NO USO DE FERRAMENTAS E METODOLOGIAS DE DATA ANALYTICS EM EMPRESAS DE MINAS GERAIS". Seguiu-se a arguição pelos examinadores e logo após a Comissão reuniu-se, sem a presença do candidato e do público e decidiu considerar aprovada a Dissertação de Mestrado. O resultado final foi comunicado publicamente ao candidato pelo Presidente da comissão. Nada mais havendo a tratar, o Presidente encerrou a sessão e lavrou a presente ata que, depois de lida e aprovada, será assinada pela Comissão Examinadora. Belo Horizonte, 22 de agosto de 2022.

Assinatura dos membros da banca examinadora:

Reginaldo de Jesus Carvalho Lima
Glauceine S. Martins
Artur Tancredo Guimarães de Alvarenga

AGRADECIMENTOS

A realização deste trabalho foi possível graças ao apoio e auxílio de pessoas, às quais gostaria de deixar registrados meus agradecimentos especiais.

Ao meu orientador, professor Allan Claudius Queiroz Barbosa, da Faculdade de Ciências Econômicas da UFMG, pelas ricas contribuições;

Aos profissionais e amigos das empresas pesquisadas;

À coordenação do curso de mestrado, pela atenção e amizade;

À minha família, especialmente a minha esposa, Jaíne Costa, e aos meus pais, Josemar Alvarenga e Lourdes Alvarenga, pelo apoio e compreensão.

RESUMO

Data analytics é o processo de examinar, explorar, transformar e analisar informações a partir de dados brutos, com o objetivo de identificar tendências e padrões que promovam *insights* e conclusões significativas que irão dar suporte ao processo de tomada de decisões. Este trabalho teve como objetivo identificar se a gestão de pessoas influencia a gestão da inovação, considerando o locus de empresas localizadas em Minas Gerais, que utilizam ferramentas e metodologias de *data analytics*, visando propor método(s) e/ou processo(s) para tornar os ciclos de gestão da inovação mais assertivos e ágeis. A estrutura do trabalho contempla no primeiro momento, uma discussão introdutória que recupera os aspectos conceituais - gestão da inovação, *data analytics* e gestão de pessoas - delineados para esse estudo. A segunda parte foi a definição dos aspectos conceituais e variáveis de análise para a pesquisa. Este arcabouço permitiu o levantamento de dados, primeiramente, através um de análise analítica na literatura, e logo depois a partir da implementação da metodologia *survey*, com a aplicação de um questionário em 28 profissionais que atuam com a inovação em Minas Gerais, de forma a obter uma visão mais ampla do cenário da inovação, os profissionais definidos para a pesquisa foram divididos em duas personas, clientes/consumidores/gestores/líderes e especialista/desenvolvedores/analistas, de forma a analisar suas visões e conceitos de forma distinta. A partir dos resultados foi possível validar o objetivo proposto nesse estudo, de tal forma que, foi possível encontrar nos resultados que a cultura e a estrutura organizacional foram as duas categorias que apresentaram maior influência quanto a gestão da inovação. Outro fator a ser considerado é como essas duas categorias influenciam esse processo, foi identificado que, para a cultura organizacional, a motivação e valorização dos profissionais, a proporção de uma metodologia de trabalho *data driven*, proporção de novos benefícios e flexibilidade de trabalho são os fatores dessa categoria, quanto que, para a estrutura organizacional são a definição quanto o tipo de contratação de serviço, estruturação de equipe, comunicação entre áreas e a padronização de documentos e processos. De tal forma, esses resultados levaram a conclusão de que, para a obtenção de sucesso na área de *data analytics* as empresas precisam focar na chave de sucesso da gestão da inovação, que são os profissionais da área. Logo, esse trabalho poderá servir como guia para as empresas que queiram implementar a inovação de *data analytics* em seu meio organizacional.

Palavras-chave: *data analytics*, gestão de pessoas, gestão da inovação, gestão de dados.

ABSTRACT

Data analytics is the process of examining, exploring, transforming and analyzing information from raw data, with the objective of identifying trends and patterns that promote meaningful insights and conclusions that will support the decision-making process. This study aimed to identify whether people management influences innovation management, considering the locus of companies located in Minas Gerais, which use data analytics tools and methodologies, in order to propose method(s) and/or process(es) to make innovation management cycles more assertive and agile. The structure of the work includes, at first, an introductory discussion that recovers the conceptual aspects - innovation management, data analytics and people management - outlined for this study. The second part was the definition of the conceptual aspects and analysis variables for the research. This framework allowed the collection of data, firstly, through an analytical analysis in the literature, and soon after, from the implementation of the survey methodology, with the application of a questionnaire to 28 professionals who work with innovation in Minas Gerais, in order to obtain a broader view of the innovation scenario, the professionals defined for the research were divided into two personas, customers/consumers/managers/leaders and specialist/developers/analysts, in order to analyze their views and concepts differently. Based on the results, it was possible to validate the objective proposed in this study, in such a way that it was possible to find in the results that culture and organizational structure were the two categories that had the greatest influence on innovation management. Another factor to be considered is how these two categories influence this process, it was identified that, for the organizational culture, the motivation and valorization of professionals, the proportion of a data driven work methodology, proportion of new benefits and work flexibility are the factors in this category, as for the organizational structure are the definition of the type of service contracting, team structuring, communication between areas and the standardization of documents and processes. In this way, these results led to the conclusion that, in order to be successful in the data analytics area, companies need to focus on the key to success in innovation management, which are professionals in the area. Therefore, this work can serve as a guide for companies that want to implement data analytics innovation in their organizational environment.

Keywords: data analytics, people management, innovation management, data management.

LISTA DE FIGURAS

Figura 1 - Estimativa de crescimento do volume de dados digitais de 2010 a 2020.....	20
Figura 2 - Pirâmide DIWK.....	22
Figura 3- Evolução das metodologias e frameworks de data analytics.....	38
Figura 4 - Comparação do uso das metodologias e frameworks de data analytics nos anos 2007 e 2014.	38
Figura 5 - Fases do CRISP-DM.....	40
Figura 6 - Ilustração do processo SEMMA.....	41
Figura 7 - Fases do Processo de KDD.....	43
Figura 8 - Recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz definidos pelo grupo: clientes/consumidor/gestores/team leader.....	63
Figura 9 - Pontos a serem melhorados em uma implementação ou rotina pelo grupo: clientes/consumidor/gestores/team leader.	65
Figura 10 - Percepção das skills e habilidades específicas dos profissionais de data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	73
Figura 11 - Metodologias e/ou frameworks conhecidos pelo grupo: especialista/desenvolvedores/analistas.	78
Figura 12 - Recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz definidos pelo grupo: especialista/desenvolvedores/analistas.....	79
Figura 13 - Pontos a serem melhorados em uma implementação ou rotina pelo grupo: especialista/desenvolvedores/analistas.	82
Figura 14 - Percepção das skills e habilidades específicas dos profissionais de data analytics pelo grupo: especialista/desenvolvedores/analistas.....	89

LISTA DE QUADROS

Quadro 1 - Síntese das categorias da gestão da inovação.....	49
Quadro 2 - Síntese das categorias da gestão de pessoas	49
Quadro 3 - Síntese da metodologia.....	50
Quadro 4 – Resultado das questões da gestão da inovação abordadas nos questionário do grupo A.....	76
Quadro 5 – Resultado das questões da gestão de pessoas abordadas nos questionários do grupo A.....	77
Quadro 6 – Resultado das questões da gestão da inovação abordadas nos questionário do grupo B.....	92
Quadro 7 – Resultado das questões da gestão de pessoas abordadas mps questionários do grupo B.....	93

LISTA DE TABELAS

Tabela 1 - Quantidade de respostas por geração.	56
Tabela 2 - Tempo de experiência dos profissionais.	59
Tabela 3 - Modelo de gestão da inovação para se trabalhar com dados pelo grupo: especialista/desenvolvedores/analistas.	81
Tabela 4 - Relação de como as variáveis dos aspectos conceituais se relacionam.	94
Tabela 5 - Visão conceitual da área acadêmica e do mercado em relação aos aspectos conceituais.....	100
Tabela 6 – Exemplo 1 de padrão de documentação.	104
Tabela 7 – Exemplo 2 de padrão de documentação.	105

LISTA DE GRÁFICOS

Gráfico 1 - Quantidade de respostas dos grupos definidos.	55
Gráfico 2 - Faixa etária dos profissionais.....	56
Gráfico 3 - Área de mercado/negócio das empresas	57
Gráfico 4 - Setores das organizações.....	57
Gráfico 5 - Faixa salarial.	59
Gráfico 6 - Modelo de gestão da inovação para se trabalhar com dados pelo grupo: clientes/consumidor/gestores/team leader.	64
Gráfico 7 - Percepção da influência do tipo de contratação de serviço em data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	66
Gráfico 8 - Tipo de contratação “ideal” para se trabalhar inicialmente com data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	67
Gráfico 9 - Tipo de contratação que possui mais risco para se trabalhar com data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	68
Gráfico 10 - Percepção da complexidade de alinhar valores e princípios da organização com os dos profissionais do data analytics pelo grupo: clientes/consumidor/gestores/team leader	69
Gráfico 11 - Percepção da diferença de cultura de profissionais de data analytics pelo grupo: clientes/consumidor/gestores/team leader	70
Gráfico 12 - Percepção da reação das pessoas/organização com a mudança de mindset para data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	71
Gráfico 13 - Percepção do interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de data analytics pelo grupo: clientes/consumidor/gestores/team leader	71
Gráfico 14 - Percepção da influência do processo de recrutamento e seleção na gestão de data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	72
Gráfico 15 - Percepção da influência da estrutura organizacional na gestão de data analytics pelo grupo: clientes/consumidor/gestores/team leader.....	74
Gráfico 16 - Estruturas organizacionais que mais agregam valor a data analytics pelo grupo: clientes/consumidor/gestores/team leader.	75
Gráfico 17 - Percepção da influência do tipo de contratação de serviço em data analytics pelo grupo: especialista/desenvolvedores/analistas.....	83
Gráfico 18 - Tipo de contratação “ideal” para se trabalhar inicialmente com data analytics pelo grupo: especialista/desenvolvedores/analistas.....	84

Gráfico 19 - Tipo de contratação que possui mais risco para se trabalhar com data analytics pelo grupo: especialista/desenvolvedores/analistas.....	85
Gráfico 20 - Percepção da influência da cultura organizacional em data analytics pelo grupo: especialista/desenvolvedores/analistas	86
Gráfico 21- Percepção da complexidade de alinhar valores e princípios da organização com os dos profissionais de data analytics pelo grupo: especialista/desenvolvedores/analistas	87
Gráfico 22 - Percepção da reação das pessoas/organização com a mudança de mindset para data analytics pelo grupo: especialista/desenvolvedores/analistas.....	87
Gráfico 23 - Percepção do interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de data analytics pelo grupo: especialista/desenvolvedores/analistas ...	88
Gráfico 24 - Percepção da influência do processo de recrutamento e seleção na gestão de data analytics pelo grupo: especialista/desenvolvedores/analistas.....	89
Gráfico 25 - Percepção da influência da estrutura organizacional na gestão de data analytics pelo grupo: especialista/desenvolvedores/analistas.....	91
Gráfico 26 - Estruturas organizacionais que mais agregam valor ao data analytics pelo grupo: especialista/desenvolvedores/analistas	91

SUMÁRIO

1. INTRODUÇÃO	20
1.1 Problema de Pesquisa	26
1.2 Objetivos.....	26
1.2.1 Objetivo geral	26
1.2.2 Objetivos específicos	26
2. REFERENCIAL TEÓRICO	28
2.1 Inovação e sua Gestão	28
2.2 <i>Data Analytics</i> – o que é.....	30
2.3 Ferramentas e metodologias complementares para o processo de <i>Data Analytics</i>	32
2.3.1 Big Data	32
2.3.2 Business Intelligence (BI).....	35
2.3.3 Data Driven	36
2.4 Métodos de gestão de <i>Data Analytics</i>	37
2.4.1 CRISP-DM	39
2.4.2 SEMMA	41
2.4.3 KDD	42
2.5 Gestão de pessoas	44
3. PROCEDIMENTOS METODOLÓGICOS	48
3.1 Levantamento de dados	51
3.2 As etapas da pesquisa	52
4. RESULTADOS DA PESQUISA	55
4.1 Entendimento das personas.....	55
4.2 Clientes/consumidores/gestores/team leaders	60
4.3 Especialista/desenvolvedores/analistas.....	78
4.4 Relação dos aspectos conceituais e suas variáveis	94

4.4.1 Análise da influência da gestão de pessoas na gestão da inovação.....	94
4.4.1.1 Tipo de contratação.....	95
4.4.1.2 Cultura Organizacional.....	96
4.4.1.3 Recrutamento e seleção	97
4.4.1.4 Estrutura Organizacional	98
4.4.2 Relação da visão conceitual da área acadêmica com a do mercado.....	100
5. CONSIDERAÇÕES FINAIS	102
REFERÊNCIAS BIBLIOGRÁFICAS.....	107
APÊNDICES	112


1. INTRODUÇÃO

Este estudo encontra o contexto atual, com o surgimento e a expansão da indústria 4.0 no início de 2010, como propícios à geração de uma enorme quantidade de dados, o que viabiliza maior acesso à informação. A indústria 4.0 transformou o mercado de dados, demonstrando a capacidade dos dados em gerar informações que contribuem para a tomada de decisão dentro das organizações (CHOI, WALLACE, WANG, 2018; CNI, 2018).

A Indústria 4.0 ou também denominada de 4ª Revolução Industrial é uma expressão que engloba tecnologias voltadas para a área de automação e troca de dados. O foco desse movimento está relacionado com a melhoria da eficiência e produtividade dos processos (CHOI, WALLACE, WANG, 2018).

O estudo “*A Universe of Opportunities and Challenges*”, desenvolvido pela consultoria EMC, aponta que, de 2006 a 2010, o volume de dados digitais gerados cresceu de 166 *Exabytes* para 988 *Exabytes*. Conforme a Figura 1, existe a perspectiva de que o volume de dados alcance a casa dos 40.000 *Exabytes*, ou 40 *Zettabytes* (ou 40 trilhões de *Gigabytes*) (GANTZ, REINSEL, 2012).

Figura 1 - Estimativa de crescimento do volume de dados digitais de 2010 a 2020.



Fonte: GANTZ, REINSEL, 2012.

No atual cenário tecnológico, o volume de dados aptos a serem explorados para a transformação de informação (valor analítico) deve alcançar apenas 33% do volume total de 40 *Zettabytes*. Com isso, é possível identificar oportunidade no uso dos dados, mesmo com um consumo de apenas 1/3 do volume de dados em 2020 para exploração e uso na tomada de decisão (GANTZ, REINSEL, 2012).

Segundo a Agência Brasileira de Desenvolvimento Industrial (ABDI), a indústria brasileira poderá ter uma redução próxima de R\$ 73 bilhões por ano com a migração da indústria para o conceito da indústria 4.0, sendo R\$ 35 bilhões com a diminuição de manutenções corretivas, cerca de R\$ 31 bilhões com ganhos de eficiência produtiva e R\$ 7 bilhões relacionadas com a redução do gasto com energia (FADUL, 2021).

Uma pesquisa realizada pela Confederação Nacional das Indústrias (CNI) demonstrou que, a partir de 2018, cerca de 48% das indústrias brasileiras pretendiam investir em tecnologias voltadas para a indústria 4.0. Além disso, a pesquisa também apresentou que, entre 2016–2018, o percentual das grandes empresas que utilizavam tecnologias digitais aumentou de 63% para 73%.

Diante das oportunidades proporcionadas pela aplicação de ferramentas e metodologias da indústria 4.0, o mercado começou a introduzir a mudança de pensamento de tomada de decisão voltado para o uso e a orientação para dados, em que os dados gerados começaram a tornar-se uma ferramenta fundamental para obtenção de informação (KAYSER, 2018).

Grande parte dessa informação transformou-se em força competitiva para a gestão estratégica organizacional, e, com isso, pôde-se observar que esse novo pensamento vem se tornando tendência dentro do mercado (KAYSER, 2018).

No que se refere à inovação tecnológica, a área de origem dessas inovações foi a tecnologia da informação (TI), a qual teve grandes marcos e evoluções, suprimindo rapidamente as características necessárias de volume, armazenamento e velocidade de processamento com o desenvolvimento de inovações tecnológicas e metodologias de dados.

As principais evoluções dessa área se destacam pelo aprimoramento de ferramentas com ênfase nas metodologias de *big data* (*Data Lake, Data Lakehouse, Hadoop, Apache Spark, Databricks, Data Factory*), *data analytics* (*Power BI, Tableau, Data Driven, Python, R*), *data science* (*Machine Learning, Python, R, Inteligência Artificial*) e outras ferramentas provindas do surgimento da indústria 4.0 (*Internet das coisas – IoT*), Inteligência Artificial etc) (PHILLIP, 2011; BUGANZA, TRABUCCHI, 2019).

As principais metodologias e ferramentas que foram redesenhadas e desenvolvidas se baseiam em arquitetura, armazenamento, processamento, visualização e análise de dados para o desenvolvimento de *machine learning, data science, inteligência artificial, análises descritivas, preditivas e prescritivas*, ressaltando que, a partir dessas análises e ferramentas,

as organizações são capazes de gerarem informações para desenvolverem cenários hipotéticos com o objetivo de contribuir nas tomadas de decisão das suas principais ações e atividades (ARDITO, PETRUZZELLI, 2018).

Analisando as inovações tecnológicas de destaque dentro do contexto de dados, o *data analytics* é um dos pontos de destaque de toda a revolução; mesmo com origens anteriores à indústria 4.0, a tecnologia de análise de dados — assim definida — teve seu aprimoramento e relevância após o crescimento dos dados, oriundos da indústria 4.0 (PHILLIP, 2011).

O conceito de *data analytics* está voltado para o contexto de obter informações a partir dos dados, e essa metodologia se categoriza de forma explícita pelo conceito de trabalhar com dados para tomar decisões mais assertivas (PHILLIP, 2011).

Data analytics ou análise de dados é o processo de examinar, explorar, transformar e analisar informações a partir de dados brutos, com o objetivo de identificar tendências e padrões que promovam *insights* e conclusões significativas que irão dar suporte ao processo de tomada de decisões (PHILLIP, 2011).

O processo de implementação e uso (início, meio e fim) de *data analytics* em uma organização pode ser expresso a partir da pirâmide do conhecimento ou, como também denominada, hierarquia DIWK (*Data-Information-Knowledge-Wisdom*). Essa pirâmide baseia-se em quatro 4 etapas/*steps* (FRICKE, 2009), tal como se ilustra a seguir.

Figura 2 - Pirâmide DIWK



Fonte: FRICKE, 2009.

Podem-se utilizar diversas ferramentas e metodologias dentro de cada etapa da pirâmide do conhecimento, porém, o foco desse projeto é trabalhar com *data analytics* e metodologias

complementares a essa inovação, como *big data*, *business intelligence e data*. Sendo assim, as etapas da hierarquia DIKW serão abordadas e explicadas com ênfase nessas três metodologias.

Na base da pirâmide, encontra-se a etapa de *DATA* (dados brutos), considerada a etapa inicial de qualquer projeto de *data analytics*. Nesse *step*, ocorrem os processos de obtenção de dados, estruturação e arquitetura, armazenamento, processamento e ETL — *Extract, Transform, Load* ou ELT — *Extract, Load, Transform* (PHILLIP, 2011).

Entre as metodologias propostas neste projeto, *big data* é a mais recomendada para suprir os requisitos da base da pirâmide do conhecimento; sendo assim, a base para se iniciar uma implementação de *data analytics* começa com as ferramentas presentes na metodologia de *big data* (PHILLIP, 2011).

A próxima etapa da hierarquia DIKW é a *INFORMATION* (informação), e, nesse *step*, considera-se que todos os dados foram coletados, tratados e estão prontos para gerarem informação. Com isso, o uso de ferramentas da área de *business intelligence* (BI) torna-se presente no processo de *data analytics*; a partir disso, essas ferramentas de BI são trabalhadas juntamente às ferramentas de *big data*, e os dados começam a serem transformados em *reports*, relatórios e *dashboards* (FRICKE, 2009).

O foco dessas ferramentas são criar análises descritivas e preditivas, para poder entender as informações que já aconteceram, que estão acontecendo e que podem acontecer dentro do cenário avaliado (FRICKE, 2009).

Sendo assim, a terceira etapa da pirâmide *KNOWLEDGE* (conhecimento) pode ser trabalhada tanto com ferramentas de BI quanto com *data driven*, uma vez que a informação já existe a partir dos dados e o conhecimento é gerado pelas ferramentas de BI. Com isso, a metodologia de *data driven* começa a ser presente pelo fato de se originar *insights* e aprendizados a partir das informações (BUGANZA, TRABUCCHI, 2019).

Por último, para finalizar o processo de *data analytics* com sucesso, tem-se a geração da *WISDOM* (sabedoria), camada final da pirâmide do conhecimento. Após obter a percepção da informação e do conhecimento, a sabedoria é formada, com isso, o processo de tomada de decisão torna-se presente no processo de *data analytics*, o que proporciona para as empresas a assertividade e agilidade quanto às ações tomadas (FADUL, 2021; BUGANZA, TRABUCCHI, 2019).

Por isso, a importância da gestão da inovação em *data analytics*, em que, cada vez mais, as empresas dentro do mercado buscam utilizar essa inovação, visto que, o uso de *data analytics*

se tornou uma força de diferenciação estratégica para as organizações e que, cada vez mais, faz sentido aderir e entender o benefício dessa inovação nas organizações

Porém, nota-se que muitas não obtém total efetividade da inovação, de tal forma, as empresas não conseguem agregar o real valor dessa inovação ao seu negócio, pois poucas conseguem alcançar a etapa de *data driven* com êxito; algumas até conseguem alcançar essa etapa, mas de maneira que não são capazes de absorver todo o potencial dessa metodologia, visto que as etapas anteriores (*DATA, INFORMATION e KNOWLEDGE*) não foram bem estruturadas, assim como apresentado a partir da hierarquia de DIKW (COUTO, 2020).

Outro fator a ser analisado é a baixa performance e gestão dos dados, aspecto que está relacionado à escassez de talentos para as organizações. Para se dimensionar essa escassez, menciona-se que, em 2018, nos Estados Unidos, havia um *gap* previsto de 140 a 190 mil profissionais com habilidades para análise de grandes bases de dados diante da demanda existente (GANTZ, REINSEL, 2012).

Já na camada gerencial, área responsável e com perfil de liderança e gestão, havia uma previsão do *gap* de cerca de 1,5 milhões de gestores e analistas com o *know-how* necessário para usar *big data* como subsídio para a tomada de decisão eficaz (GANTZ, REINSEL, 2012).

Ainda em relação à escassez de talentos, de acordo com um estudo da Associação das Empresas de Tecnologia da Informação e Comunicação (Brasscom), o déficit de profissionais no setor de *data analytics* pode chegar a mais de 400 mil profissionais até 2024 no Brasil (FADUL, 2021).

Além dessa “falta” de profissionais, outro fator que precisa ser notado para a gestão da inovação de *data analytics* é o *turnover* relacionado aos profissionais dessa área, na medida em que os profissionais com mão de obra qualificada nessa área são altamente solicitados pelo mercado e recebem constantemente propostas salariais superiores às que já recebem (COUTO, 2020).

Analisando esse contexto de gestão de pessoas, afirma-se que esse tipo de gerenciamento está diretamente ligado ao tipo de contratação de serviço que a organização define. Se a escolha pelo tipo de contratação for interno, a empresa se responsabiliza pelo fator de rotatividade e “falta” de profissionais para contratar; porém, se o tipo de contratação for externa, a empresa transfere a responsabilidade pela gestão e contratação de pessoas para a empresa terceira.

Sendo assim, a contratada se responsabiliza por esses fatores, enquanto a organização contratante tende a “trocar” o fator de gestão de pessoas (desenvolvedores/ especialistas/ analistas) pela gestão da empresa contratada. Com isso, a organização se responsabiliza pelo gerenciamento das atividades e entregas da empresa contratada.

Mediante a isso, quando avaliado o tipo de serviço interno, identifica-se que, por ser uma ferramenta voltada à área de TI, é muito comum que algumas organizações atribuam a responsabilidade para essa área. Todavia, como essa metodologia possui um viés muito relevante para a área de negócios e gestão, também é comum identificar áreas de gestão e/ou projetos sendo as responsáveis pela inovação. Por conseguinte, pode-se observar que a área/setor responsável pelo *data analytics* não é uma unanimidade nas organizações.

Quanto ao fato de o tipo de trabalho ser terceirizado, exemplo, se for prestado por uma consultoria, é importante o alinhamento acerca de qual setor da organização será o responsável pela comunicação e pelo relacionamento com a equipe da consultoria, isto é, uma área da organização será o ponto central da comunicação com a empresa terceira, ou cada área irá fazer solicitações a partir da sua respectiva necessidade ou demanda.

Sendo assim, a estrutura organizacional precisa estar alinhada com os objetivos estratégicos da organização, para que o processo de gestão da inovação de *data analytics* possa ser feito de forma mais assertiva e ágil possível (CHANDLER, 1962).

Outro ponto da gestão da inovação é identificar se a respectiva organização necessita inicialmente ter uma pessoa com *skills* e conhecimentos de *data analytics* específicos para fazer uma ponte de conhecimento interno e externo com a equipe de consultoria e, se realmente for necessário, identificar quais são as *skills* e os conhecimentos necessários para esse funcionário (VOLBERDA, VAN, 2013; KIPPING, ENGWALL, 2002).

A partir desses fatores contextualizados e de forma complementar, Larieira e Albertin (2013) abordam a necessidade de identificar a influência dos fatores organizacionais no gerenciamento de novos projetos e de inovações. Diante disso, foi delimitada a gestão de pessoas como o centro do estudo, visando analisar se esse fator influencia o processo de gestão da inovação no uso das ferramentas e metodologias de *data analytics* em empresas de Minas Gerais.

Com isso, espera-se que essa dissertação sirva como guia para as empresas do mercado que estão começando a trabalhar com a inovação ou até mesmo empresas consolidadas que não estão conseguindo extrair todo o benefício do uso de *data analytics*.

Para a área acadêmica, delimita-se que, esse estudo seja um dos precursores de pesquisa relacionando esses três temas, analisando de forma a entender como esses podem ser trabalhados de forma conjunta, para proporcionar um melhor aproveitamento da inovação.

Acredita-se que, com o avanço dessa tecnologia, mais estudos e entendimentos possam surgir, correlacionando esses fatores, por isso, esse estudo poderá servir como entrada para futuras formas de analisar e entender os impactos e influências organizacionais quanto *data analytics*.

A estrutura desta dissertação expõe, na sequência, o problema de pesquisa, os objetivos propostos, e o referencial teórico seguido do percurso metodológico. Por fim, são apresentados os resultados e as análises dos dados, com as considerações finais e as referências que nortearam a pesquisa.

1.1 Problema de Pesquisa

A gestão de pessoas influencia o processo da gestão da inovação considerando o locus de empresas localizadas em Minas Gerais, que utilizam ferramentas e metodologias de *data analytics*?

1.2 Objetivos

1.2.1 Objetivo geral

Mapear se a gestão de pessoas influencia no processo de gestão da inovação no uso das ferramentas e metodologias de *data analytics* no cenário organizacional de Minas Gerais.

1.2.2 Objetivos específicos

- Desenvolver um quadro teórico-metodológico que permita explorar as dimensões da gestão de pessoas quanto ao processo de gestão da inovação;
- Descrever a relação entre a gestão de pessoas quanto ao processo da gestão da inovação, a partir dos dados coletados da pesquisa bibliográfica e dos questionários respondidos;

- Analisar soluções para a gestão da inovação no uso de ferramentas e metodologias de *data analytics*.

2. REFERENCIAL TEÓRICO

O marco conceitual desta dissertação discutiu de forma articulada a gestão da inovação e as ferramentas e metodologias de *data analytics* no contexto organizacional. A partir da compreensão de cada um desses tópicos e dos seus respectivos relacionamentos, buscou-se delimitar, a partir do problema geral e do objetivo de estudo, um entendimento sobre se a gestão de pessoas influencia a inovação, *data analytics*, estabelecendo as bases das descrições e análises a serem realizadas durante a pesquisa.

No primeiro momento, foram coletadas 30 literaturas utilizando as variáveis de análise de forma conjunta, as buscas foram realizadas no google acadêmico e na plataforma capes, essas literaturas proporcionaram um maior entendimento de como as categorias de gestão de pessoas, gestão da inovação e *data analytics* se relacionam.

Foi identificada uma baixa abordagem dessas três variáveis em conjunto na literatura, até mesmo na variação de gestão de pessoas e da inovação com *data analytics*, o que demonstrou uma oportunidade para o estudo, porém uma dificuldade para o levantamento de dados. Essas literaturas podem ser observadas no APÊNDICE B.

De forma a complementar a interpretação de como essas três variáveis foram abordadas em conjunto na literatura, foi desenvolvido um segundo quadro, que pode ser encontrado no APÊNDICE C e nele foi apresentada essa relação entre as variáveis.

A partir desse entendimento, foi proposto em um segundo momento, analisar a gestão da inovação e suas variáveis de forma separada, além do conceito de gestão de pessoas; sendo assim, na sequência são abordados o conceito de *data analytics*, as ferramentas e *frameworks* que serão alvo de análise e discussão para a pesquisa.

2.1 Inovação e sua Gestão

Conceitualmente, a gestão da inovação está relacionada com a implementação de novas práticas de gestão, processos e estruturas que representam uma mudança das normas atuais — ao longo do tempo. Muitas das práticas, processos e estruturas que se observam nas organizações atuais foram desenvolvidas utilizando metodologias de gestão da inovação (BIRKINSHAW, MOL, 2006).

A gestão da inovação possui algumas peculiaridades que a coloca em um nível de maior complexidade do que a inovação tecnológica. O primeiro é que a implementação da gestão da inovação não é instantânea e ágil assim como a tecnológica; muitas das implementações dessa metodologia demoram anos para ter sucesso e, em alguns casos, é até complexo afirmar de que forma a inovação realmente ocorre, pois ela acontece de maneira tácita dentro da rotina da organização (BIRKINSHAW, MOL, 2006).

Sendo assim, a mensuração de resultados e benefícios torna-se abstrata para essa metodologia de gestão, porque é difícil precisar o momento de início, meio e fim (BIRKINSHAW, MOL, 2006).

Além do conceito apresentado anteriormente é importante ressaltar que há alguns pontos que diferem a gestão da inovação da inovação tecnológica; sem a difusão do conhecimento dessas áreas, dificulta-se o entendimento da gestão da inovação de forma clara, devido a complexidade em mensurar essa gestão (BIRKINSHAW, MOL, 2006).

Por tal complexidade, nas implementações de gestão da inovação, fazem-se necessários os especialistas internos/externos ou até mesmo agentes externos, como consultores. Como característica, a gestão da inovação é mais propensa a ser específica para o sistema em que foi criada, que geralmente são sistemas sociais, gerenciais, organizacionais, metodológicos e, principalmente, sistemas que envolvem a gestão do conhecimento (VOLBERDA, VAN, 2013).

De uma perspectiva externa, a gestão da inovação é conduzida por diferentes organizações intensivas em conhecimento que constroem conhecimento conforme seu principal processo de agregação de valor (KIPPING, ENGWALL, 2002).

Eles podem ser definidos como organizações em que os funcionários com um alto grau de conhecimento são fundamentais para a função primária da organização. Eles têm relativamente pouco capital financeiro, mas, em vez disso, contam com o conhecimento e a competência de seu pessoal como principais ativos (KIPPING, ENGWALL, 2002).

Dentro do contexto de *data analytics*, pode-se conceituar que o uso da gestão da inovação está implicitamente relacionado a entendimento de processos, *frameworks*, métodos, gestão dos dados, levantamento de conhecimento a partir dos dados, definição de ferramentas e metodologias, suporte em técnicas de gerenciamento de projeto e análise de projetos de terceirização, uma vez que a implementação e uso dessa inovação nas organizações tendem a ser considerados como um projeto interno ou externo, devido as suas complexidades e dimensões (HIDALGO, ALBORS, 2008).

Por ser complexo mensurar os seus resultados da gestão da inovação, torna-se abstrato para as organizações o real potencial dessa inovação, então, para as empresas, fica-se subentendido que está sendo feita a gestão dessa inovação apenas na aplicação e no desenvolvimento rotineiro, mesmo que o uso seja apenas de uma pequena fração do potencial da inovação (BIRKINSHAW, MOL, 2006).

Mediante a isso, Volberda, Van (2013) e Kipping, Engwall (2002) conceituam, que, há a necessidade de um especialista e/ou consultor externo que possua experiência em relação à inovação para que haja um gerenciamento eficiente, assertivo e com qualidade, mesmo que existam etapas e processos bem-definidos e mapeados.

Tal contexto corrobora os métodos nos quais as organizações aplicam na sua rotina, visto que o referido especialista tende a colaborar com o desenvolvimento e a estruturação dos processos e métodos de gerenciamento, e não simplesmente atribui a responsabilidade de desenvolver ferramentas na sua rotina. Notoriamente, essas qualidades estão correlacionadas a profissionais de categoria sênior e/ou especialistas.

Outro fator relevante para esse especialista e/ou consultor externo é dimensionar e avaliar a estrutura de dados da organização. Mesmo que esse processo seja custoso, é fundamental que ele consiga dimensionar todo o contexto da organização, para que possa atuar de forma sustentável dentro da estrutura de dados, criando e gerenciando ferramentas e processos que se desenvolvam de forma orgânica, para ser capaz de entregar à organização o real benefício do *data analytics*.

Por conseguinte, é preciso identificar os conceitos de *data analytics* e seus métodos de gestão. A partir disso, será possível analisar se a gestão de pessoas influencia no processo de gestão da inovação, uma vez que se pode avaliar e identificar a relevância da gestão de pessoas no processo de gestão da inovação.

2.2 *Data Analytics* – o que é

As inovações tecnológicas de *data analytics* teoricamente não são recentes no âmbito global, porém, dentro do contexto organizacional, essas ferramentas oriundas de dados começaram a ter destaque a partir da indústria 4.0. Doravante, essas ferramentas se tornaram fundamentais para a obtenção de informações por meio dos dados (PHILLIP, 2011).

Como já destacado, os dados estão onipresentes em qualquer sistema ou organização atual, sendo que as empresas utilizam as informações geradas a partir de dados para melhorar os seus processos e gerar resultados impactantes. Além disso, a capacidade de uma empresa de competir na economia digital requer decisões mais ágeis e assertivas, voltadas para o futuro.

Diante disso, as ferramentas de *data analytics* ganharam mais destaque e aplicação dentro do mercado de negócios, por isso, essas ferramentas foram consideradas como fenômeno de desenvolvimento econômico, devido ao fato de promover a “destruição criativa”, ou seja, a substituição de antigos produtos e hábitos de consumir por novos. Esse fato ocorre devido à migração do conhecimento tácito para o conhecimento explícito, baseado em dados reais, e não simplesmente pela experiência do profissional para tomar uma decisão (NONAKA, TAKEUCHI, 1997).

Além disso, nota-se uma mudança quanto a ferramentas de trabalho dos profissionais dessa área, na medida em que, devido ao aumento do volume dos dados e suas características, novos sistemas e ferramentas foram criados ou foram readequados ao novo contexto dos dados, o que proporcionou novas áreas de trabalho e novas demandas quanto a habilidades, *skills* e *know-how* para os profissionais que atuam com essa inovação (PHILLIP, 2011; CHOI, WALLACE, WANG, 2018).

Mediante a observância da mudança do *mindset* nos negócios, ressalta-se que as ferramentas e metodologias de *data analytics* contribuem para que as organizações possam investigar e descobrir o que vem acontecendo e como se deve reagir perante os negócios (PHILLIP, 2011).

Outrossim, a aplicabilidade do *data analytics* nos negócios não possui limite, logo, qualquer área organizacional pode usar esse processo, por exemplo, o setor financeiro, os de manutenção, TI, gestão, projetos, suprimentos, marketing, operação, expansão, vendas/comercial etc (PHILLIP, 2011).

As análises avançadas são as melhores práticas para se descobrir e entender novos segmentos de clientes, novos mercados, melhores fornecedores, para associar produtos, fazer controles financeiros, identificar lacunas e oportunidades em indicadores etc (CHOI, WALLACE, WANG, 2018).

Além disso, essas ferramentas viabilizam a redução do *lead time* e, de tal forma, promovem um maior tempo para a tomada de decisão a partir das análises dos dados, visto

que, quando desenvolvida e concluída uma ferramenta, não há mais gasto de energia para construir e/ou atualizar os dados, sendo que toda essa parte será automatizada. Com isso, o consumidor da informação, terá mais tempo para focar em análises e *insights* com as informações geradas (CHOI, WALLACE, WANG, 2018).

Por esses e outros fatores, cada vez mais as organizações buscam implementar e trabalhar com *data analytics* e, de forma a agregar a essa inovação, utilizam *big data*, *business intelligence* e *data driven*, de forma complementar. Quando essas ferramentas são trabalhadas em conjunto, proporcionam um aprimoramento do processo de gestão de dados para a obtenção da informação (MYTELKA, 2004; AUDRETSCH, 1991).

2.3 Ferramentas e metodologias complementares para o processo de *Data Analytics*

A metodologia de *data analytics*, como apontado, compreende todo o processo de obter e transformar os dados brutos em informação. Mediante o exposto, este estudo conceitua o processo de análises de dados a partir de três ferramentas/metodologias, *big data*, *business intelligence* e *data driven*, levando em conta que, usando essas ferramentas de forma complementar, é possível realizar todo o ciclo do *data analytics*.

O objetivo de se trabalhar com essas três vertentes da inovação é conseguir mapear e entregar valor de acordo com a pirâmide DIKW, objetivando usar essas ferramentas/metodologias para estruturar uma gestão eficiente e assertiva em *data analytics*. Com a aplicação desses métodos, será possível construir uma cadeia de processo adequada, desde a base até o topo da pirâmide DIKW.

2.3.1 *Big Data*

O termo *big data* (“grandes” dados) se refere às características do conjunto de dados, estando relacionado com os 7 Vs — volume, variedade, velocidade, valor, veracidade, visualização e variabilidade. Todos esses conceitos são direcionados ao processamento, estrutura, coleta e armazenamento de dados (ARDITO, SCUOTTO, *et al.*, 2019).

Um dos principais objetivos dessa tecnologia é o armazenamento, estruturação e processamento dos dados. Tal inovação permite um maior comprimento dos dados, o que

proporciona capacidade mais ampla de armazenamento e manipulação do dados (YANHONG, 2018).

Diante disso, o gerenciamento e a manipulação com as ferramentas de *software* convencionais foram substituídas por novos modelos de processamento para obter maior poder de tomada de decisão, *insights*, processos de otimização de capacidade massiva e altas taxas de crescimento e ativos de informação diversificados (dados estruturados, semiestruturados ou não estruturados) (YANHONG, 2018).

Um fator relevante para se estruturar e fazer uma gestão eficiente de *big data* são os tipos de sistemas de armazenamento de dados, visto que cada sistema poderá ser relevante para o tipo de gestão de dados que a organização coleta e processa na sua rotina.

Como mencionado anteriormente, ferramentas de armazenamento de dados como servidores estão sendo substituídos cada vez mais pelas empresas, e a tendência para o armazenamento dos conjuntos de dados — *big data* — para o futuro são uma combinação dos seguintes sistemas de armazenamento:

- O primeiro sistema em análise é o *data warehouses* (DW). Nesse tipo de sistema é fornecido um repositório centralizado para o armazenamento de todos os dados da organização; além disso, os DWs podem ser locais ou estarem armazenados na nuvem. O sistema de DW foi desenvolvido com foco principal em dados estruturados, proporcionando métodos simples e fáceis de limpar, consultar e estruturar os dados. Um dos principais desafios do sistema DW se refere a sua escalabilidade, o custo de novos armazenamentos é muito alto para construir, licenciar e manter, mesmo com a disponibilidade em nuvem. Além disso, por não conseguir trabalhar com dados não estruturados, o próprio sistema limita o potencial de informação que pode ser gerado através dos dados. De forma crítica, usar o DW é um grande avanço para qualquer organização que deseje trabalhar com dados tabulares e matriciais. Mesmo que possua suas limitações, é uma ferramenta muito eficiente para os primeiros passos de uma estruturação de *big data* dentro da organização (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

- O segundo sistema em análise é o *data lake*. Ao contrário dos DWs, aqui os dados são armazenados em seu formato bruto, podendo ser tanto estruturados, semiestruturados e não estruturados, o que proporciona horizontalmente a escalabilidade dos dados aos *data lakes*. Por ser um tipo de sistema de armazenamento em nuvem, o *data lake* é relativamente barato, o que permite que as organizações separem os custos de armazenamentos com os

custos de processamento dos dados, pois a organização só paga pelo custo de processamento quando ocorre alguma movimentação com os dados. O principal viés dos *data lakes* é quanto ao recurso denominado mão de obra qualificada, visto que, se a organização não possuir funcionários com conhecimentos e *expertises* para trabalhar e gerenciar as bases com os dados brutos, há a possibilidade de haver dificuldades em usar as ferramentas do *data lake* (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

Sendo assim, o tipo de sistema de armazenamento dos dados que for escolhido irá ditar o método de gerenciamento, levando em conta o fato de que não existe um sistema adequado e/ou certo para ser trabalhado. Os fatores dos 7 Vs precisam ser analisados e dimensionados para a escolha assertiva do tipo de armazenamento correto para cada organização (ZHOU, 2020).

Além dos fatores de armazenamento e processamento que *big data* oferecem, sublinham-se igualmente algumas técnicas fundamentais que podem ser trabalhadas com os dados, que são inteligência artificial, aprendizado de máquina, aprendizado profundo e ciência de dados. O uso e a aplicação dessas técnicas com certeza elevam o potencial de obter análises preditivas e prescritivas, o que acarreta a obtenção de informações hipotéticas, para descrever e fundamentar cenários futurísticos (ZHOU, 2020).

Além de entender as variedades de sistemas de armazenamento, é necessário entender os esqueletos para o processamento dos dados, visto que essas técnicas estão correlacionadas com a forma em que os dados são trabalhados na organização. Diante disso, os tipos de ingestão de dados podem ser divididos em dois métodos, *batch* e *streaming* (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

O método *batch* está caracterizado ao processo de carga de dados em lotes, o que possibilita que a ferramenta trabalhe com um grande volume de dados com pouco processamento, uma vez que seja viável fazer atualizações das bases de dados em lotes distintos, essa técnica é denominada carga incremental (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

No método *batch*, pode-se também utilizar a carga completa, e, nessa metodologia, os dados são carregados sempre em conjunto. Normalmente, esse tipo de processamento ocorre em horários com baixa competição de recursos de sistemas, o que proporciona um processamento volumoso dos dados (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

O método *streaming* está relacionado ao tipo de processamento conhecido como “quente”, na medida em que favorece as organizações de terem dados em tempo real ou com *delay* de milissegundos. Esse método é muito utilizado quanto a ferramentas de *IoT*, cujo objetivo é enviar alertas quando ocorre alguma diversidade dentro da rotina (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

Por último, e não menos importante, revela-se essencial entender o processo de tratamento dos dados, que irá caracterizar tanto o sistema de armazenamento quanto o processamento dos dados. Existem dois métodos de processo de tratamento dos dados; de forma implícita, as etapas são semelhantes, o que diferente é a ordem de cada etapa.

O processo de ETL (extração, tratamento e carregamento) é caracterizado pela transformação dos dados durante o processo da coleta, e de tal forma já são tratados e armazenamentos. Sendo assim, quando o processo termina, os dados já estão prontos para serem analisados (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

Já no processo de ELT (extração, carregamento e tratamento), os dados são transformados na camada de visualização ou no sistema de destino, isto é, o cliente dos dados será o responsável pelo tratamento dos dados a partir das demandas (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

Através do entendimento e gerenciamento dessas variáveis, é possível usar *big data* de forma que agregue valor à organização, tirando proveito dos reais benefícios desse processo.

2.3.2 Business Intelligence (BI)

O termo *business intelligence* (BI), considerado um conceito mais antigo no mercado, significa inteligência de negócios, isto é, recuperação automática de sistemas previamente processados, que contribuem para automatizar, agilizar, apresentar e criar *insights* dentro do processo de análise de dados em negócios (WASTOM, WIXOM, 2007).

Devido a sua flexibilidade e abrangência de aplicação, os sistemas de BI migraram rapidamente da área de TI para a área de negócios, proporcionando novas aplicações. Diante disso, a sua aplicação dentro das organizações se destaca desde a origem do processo organizacional até a ponta final do processo, que, no caso, é o cliente. Sendo assim, essas ferramentas de BI podem ser utilizadas para controle e gestão da logística até entendimento e estruturação do *marketing* e/ou *customers success* e/ou *customers experience* (PHILLIP, 2011).

Os objetivos centrais dessa ferramenta são transformar, analisar e apresentar os dados extraídos de sistemas de *big data* e/ou banco de dados em informação a partir de análises, com painéis gráficos e *dashboards*, com o intuito de criar indicadores operacionais, de performance e/ou financeiros a partir dos dados coletados (CHOI, CHAN, YUE, 2016).

Atualmente, empresas que aplicam sistemas de BI se destacam no mercado, devido a uma grande estrutura e armazenamento de dados, por possuírem sistemas integrados e análises instantâneas para a tomada de decisão (CHOI, CHAN, YUE, 2016).

Nas ferramentas de BI são feitos os cálculos e o desenvolvimento das regras de negócio com os dados. Nessa fase do *data analytics*, os dados possuem real benefício quando aplicados ao contexto de negócio da organização. Diante disso, a relação de *business* e *analytics* precisa ser gerenciada, para que as ferramentas de BI consigam entregar os seus objetivos centrais, de forma a gerar a informação a partir dos dados.

À medida que o seu real benefício é alcançado, a informação gerada pode ser trabalhada dentro dos setores e das equipes, a fim de haver a tomada de decisão a partir dos *dashboards* e *insights* que são gerados nas ferramentas de BI.

2.3.3 Data Driven

A metodologia de *data driven* está relacionada à maneira como os dados são utilizados dentro das organizações. Esse conceito significa ‘orientação para dados’, que contribui para a mudança do *mindset* de tomada de decisão a partir da intuição e experiência para dados e informações.

O intuito central de *data driven* é instituir a curiosidade, o aprendizado constante e o entendimento amplo do negócio, de maneira que as ações sejam tomadas de forma preditiva.

A metodologia de orientação para dados pôde ser dividida em cinco fases: (1) organização e estruturação, (2) construção de conhecimento para avaliação, (3) identificação de fontes de dados, (4) alinhamento de sistemas de dados e (5) alteração da forma de pensar (SORESCU, 2017).

Tal conceito surgiu logo após a consolidação da metodologia de *big data*. Foi observado que de nada adiantava possuir uma gama de dados, sem haver informação e/ou conhecimento. Ademais, não há utilidade em deter informações se for houver uma orientação para a análise dos dados.

Diante desse cenário, surgiu o conceito de *data driven*, metodologia que contribui para que os dados e as informações gerados das ferramentas de BI fossem usados para auxiliar no processo de tomada de decisão (MICHAEL, VINCENT, 2010).

O *data driven* é a ponta final do processo de *data analytics*. Nessa etapa, já se conta com todas as análises com os indicadores construídas (descritiva, preditiva, prescritiva) e *dashboards*, e, com base nisso, o cliente é capaz de identificar e criar *insights* a partir desses dados.

Outra parte do *data driven* que vem crescendo muito é a usabilidade de ferramentas de inteligência artificial, *machine learning* e *data science*, as quais são consideradas avançadas dentro do contexto de *data analytics* (SORESCU, 2017).

O interessante e proveitoso dessas ferramentas é que elas conseguem identificar padrões e criar análises, ofertando ao cliente informações e *insights* automáticos, sem que o cliente necessite fazer suas respectivas análises (SORESCU, 2017).

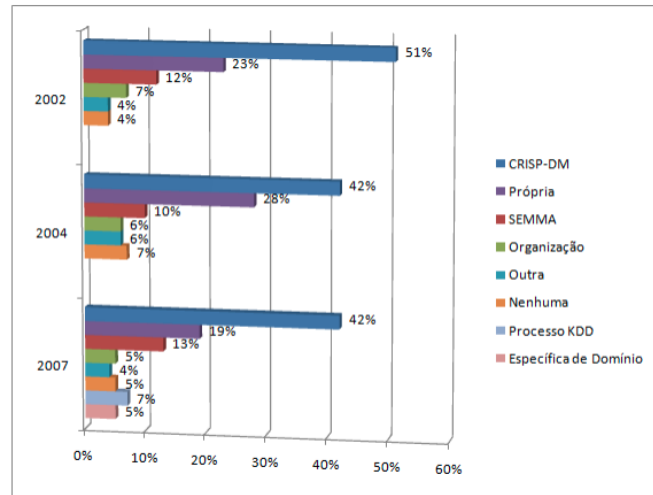
Isso acontece porque essas ferramentas, com a suas devidas programações e ensinamentos, conseguem fazer as análises com os dados, o que torna a informação e a tomada de decisão ainda mais assertivas para a organização, uma vez que não há “interferência” humana nas análises (SORESCU, 2017).

2.4 Métodos de gestão de *Data Analytics*

Após o entendimento do conceito de *data analytics* e das metodologias — delimitadas para esse estudo — que podem ser usadas de forma complementar à inovação, fez-se a necessidade de avaliar como esse processo de gestão da transformação de dados brutos em informação é realizado.

Com isso, buscou-se identificar alguns das principais metodologias e *frameworks* voltados ao contexto de gestão do processo de *data analytics*. Pode-se observar, a partir das figuras 3 e 4, as metodologias e *frameworks* mais utilizado nos anos de 2002, 2004, 2007 e 2014.

Figura 3- Evolução das metodologias e frameworks de data analytics



Fonte: MONTEVECCHI, 2012

Figura 4 - Comparação do uso das metodologias e frameworks de data analytics nos anos 2007 e 2014.

	2014 poll	2007 poll
CRISP-DM (86)	43%	42%
My own (55)	27.5%	19%
SEMMA (17)	8.5%	13%
Other, not domain-specific (16)	8%	4%
KDD Process (15)	7.5%	7.3%
My organizations' (7)	3.5%	5.3%
A domain-specific methodology (4)	2%	4.7%
None (0)	0%	4.7%

Fonte: KDNUGETTS, 2014.

A partir das figuras 3 e 4, é possível identificar que, nesses anos (2002, 2004, 2007 e 2014), o mais utilizado foi o CRISP-DM, que é vinculado à ferramenta mais vendida no mercado, o software SPSS-Clementine.

Outro software de destaque é o SEMMA, desenvolvida pela SAS, que foi o terceiro mais utilizada nos anos analisados, e, por fim, o KDD é a metodologia mais recente entre os três analisados, sendo que, em 2007, teve uma relevância significativa de uso no mercado.

O destaque para esses três tem significado, pois esses métodos possuem um padrão e uma definição concisas das etapas técnicas e processos de como fazer a gestão em *data analytics*, enquanto é possível notar que os demais com participação relevante no mercado são métodos variáveis, isto é, são diferentes entre profissionais (Própria), organizações (Organização), sendo que, em alguns casos, nem existe uma definição de metodologia para trabalho (Nenhuma) (MONTEVECCHI, 2012; KDNUGETTS, 2014).

Diante disso, este estudo irá analisar esses três principais *frameworks* destacados quanto à implementação e ao desenvolvimento que são o CRIPS-DM, SEMMA e o KDD, já que possuem um escopo padrão.

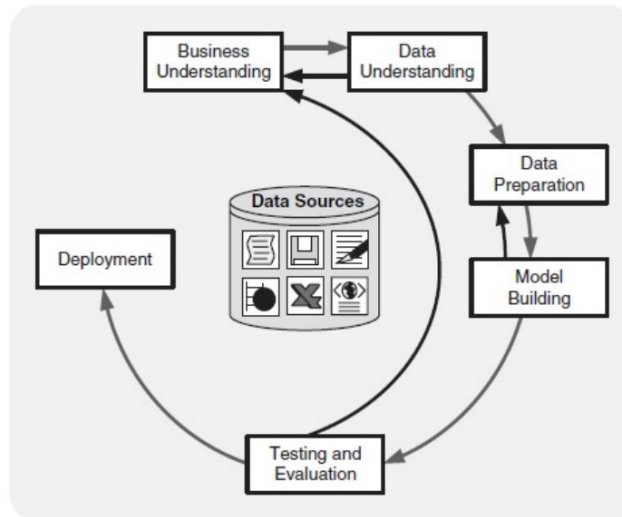
Esses *frameworks* possuem como princípio determinar as etapas do processo de gestão no contexto de *data analytics*, cujo objetivo é determinar etapas para a exploração, gestão e entendimento dos dados, e, em paralelo, identificar como e quando as ferramentas podem ser aplicadas de forma a tornar o processo de *data analytics* mais afirmativo e ágil (MONTEVECCHI, 2012).

2.4.1 CRISP-DM

Criado em 1996, CRISP-DM (*Cross Industry Standard Process for Data Mining*) consiste em um conjunto de boas práticas (metodologia) para trabalhar com projetos de *data analytics*. Essa metodologia proporciona para as empresas a capacidade de transformar os dados em conhecimento e informação, *data driven* (NOGUEIRA, 2014; DANTAS, *et al.*, 2008).

Ademais, proporciona uma visão geral do ciclo de vida de um projeto, sendo esse método, dividido em 6 fases que são ilustradas na Figura 5 (CHAPMAN, CLINTON, KERBER, 2010).

Figura 5 - Fases do CRISP-DM



Fonte: CHAPMAN, CLINTON, KERBER, 2010.

As setas identificadas entre os *steps* indicam as dependências mais importantes e frequentes entre as fases. Dependendo do projeto e dos resultados obtidos num determinado *step*, pode ser necessário retroceder para uma fase anterior. Assumindo que o projeto seja totalmente implementado, o processo não é terminado até que uma solução chegue à última fase do ciclo (NOGUEIRA, 2014).

Sendo assim, as 6 fases da metodologia CRISP-DM são:

- *Business Understanding* – é a fase em que se identifica o problema que será resolvido com o projeto de *data analytics*, com isso, são expostos os objetivos do projeto e as métricas que serão trabalhadas e monitoradas;
- *Data Understanding* – trata-se da fase de coletar, interpretar e explorar os dados para verificar se esses dados serão suficientes para alcançar os objetivos propostos;
- *Data Preparation* – é a fase de preparação dos dados, os quais, assim, sofrem o processo de ETL ou ELT e, adiante, os conjuntos de dados são criados e integrados. Em síntese, trata-se da fase de modelagem dos dados;
- *Model Building* – constitui a fase de construção dos modelos e parâmetros de cálculo;
- *Testing and Evaluation* – é a fase em que se estimam os resultados, sendo assim, é avaliado se o processo conseguiu cumprir com os objetivos propostos no início do projeto;

- *Deployment* – trata-se da fase final do processo, cujo objetivo é colocar o modelo validado em utilização.

2.4.2 SEMMA


Além do CRISP-DM, outra metodologia utilizada para projetos de *data analytics* é a SEMMA (Sample, Explore, Modify, Model, Assess). SEMMA tem características semelhantes à metodologia CRISP-DM, porém o foco dessa metodologia está na criação de modelos de exploração e, por isso, possui um viés de negócio um pouco inferior quanto ao CRISP-DM (NOGUEIRA, 2014; DANTAS, *et al.*, 2008).

Esse foco é devido ao fato de o SEMMA consistir em um processo para aplicar ferramentas do SAS Enterprise Miner, oferecendo aos usuários uma maior facilidade quanto à organização e adequação do desenvolvimento e manutenção dos projetos.

Diante disso, o objetivo dessa metodologia é facilitar a aplicação de técnicas de visualização e exploração estatística, selecionar e transformar as variáveis mais significativas e modelar as variáveis a fim de prever resultados (NOGUEIRA, 2014).

A metodologia SEMMA possui 5 etapas, que, de forma conceitual, representa as siglas da sua nomenclatura (SAMPLE – amostragem, EXPLORE – exploração, MODIFY – modificação, MODEL – modelagem, ASSESS – avaliação), sendo que tais fases podem ser identificadas na Figura 6 (NOGUEIRA, 2014).

Figura 6 - Ilustração do processo SEMMA



Sendo assim, as 5 fases da metodologia SEMMA podem ser definidas como:

- Amostragem – consiste na separação de uma amostra de dados para extrair a informação necessária em cima da análise destes dados, e recomenda-se que sejam criadas partições dos dados, para treino e validação dos modelos;
- Exploração – é a fase de explorar os dados, entendendo, assim, quais são os padrões existentes, as tendências, as anomalias, de forma a obter uma melhor percepção dos conjuntos de dados. Essa etapa ajuda a redirecionar e refinar o processo de descoberta de conhecimento a partir dos dados, o que é vital para a sequência das demais etapas;
- Modificação – constitui a fase de ajustar, transformar e preparar os dados. Nem sempre todo o conjunto de dados possui uma grande acuracidade; sendo assim, nessa etapa busca-se identificar métodos para preencher valores ausentes dentro da base de dados, para que possa aumentar a veracidade dos conjuntos de dados, de forma a obter o máximo de conhecimento possível com os dados;
- Modelagem – é a fase de aplicar as técnicas de modelagem e cálculos das regras de negócio, considerando que cada modelo e projeto possui o seu propósito e deve ser definido com relação aos objetivos propostos e dados disponíveis;
- Avaliação – é a fase de verificar se os resultados obtidos estão aderentes aos objetivos propostos no início do projeto, e, se o modelo estiver válido, o mesmo deve seguir para as etapas de teste e homologação, para que seja utilizado pelos clientes.


Ao analisar os resultados obtidos dentro de cada etapa do SEMMA, é possível modelar novas questões de negócio que possam surgir, de tal forma a reiniciar o ciclo do SEMMA, para realizar um refinamento adicional dos dados.

2.4.3 KDD

O KDD (*Knowledge Discovery in Databases*) é uma técnica criada na década de 80. Assim como os demais, o KDD abarca um conjunto de passos e/ou processos que tem como premissa a descoberta e o conhecimento de informação a partir dos dados (DANTAS, *et al.*, 2008).

De acordo com Fayyad, *et al.* (1996), o processo de KDD é constituído de cinco grandes fases, sendo elas ilustradas na Figura 7.

Figura 7 - Fases do Processo de KDD



Fonte: FAYAAD, *et al.* 1996.

Por conseguinte, as 5 fases da metodologia KDD podem ser definidas como:

- *Selection* (seleção) – é a fase de obter e analisar os dados que serão usados para a elaboração do projeto;
- *Preprocessing* (pré-processamento) – trata-se da fase de avaliar a veracidade dos dados, quando os processos de ETL/ELT são trabalhados de forma a ter a melhor preparação para o conjunto de dados;
 - *Transformation* (transformação) – é a etapa de preparação dos dados para o modelo, avaliando a granularidade, agregações, categorizações etc;
- *Data Mining* (mineração dos dados) – é a fase de construção do modelo e aplicação dos cálculos das regras de negócio;
- *Interpretation/Evaluation* (interpretação e avaliação de padrões) – constitui a fase final de avaliação do modelo, a sua qualidade, relevância, acuracidade, e sua validação ao ser entregue aos usuários. Obtem-se, logo, o objetivo da metodologia, que é o conhecimento a partir dos dados.

Como identificado nessas três principais metodologias e *frameworks* de gestão da inovação em *data analytics*, o foco deles está relacionado a delinear técnicas para identificar e tornar as etapas e os processos de *data analytics* mais assertivos, a fim de que a implementação e o desenvolvimento possam ser gerenciados através de *steps*, e que se possam criar e agregar cada vez mais valor ao benefício dessa inovação para as empresas.

Mediante isso, é importante destacar que esses métodos atribuem maior destaque a etapas técnicas e processos de modelagem e estruturação dos dados, e fundamentalmente não enfatizam a presença e/ou influência das pessoas/profissionais e gestão das pessoas no processo de gestão da inovação.

A partir disso, entender a presença e influencia da gestão de pessoas no processo de *data analytics* torna-se relevante, para analisar os aspectos pessoais dessa área.

2.5 Gestão de pessoas

Dutra (2009) define a gestão de pessoas como “[...] um conjunto de estratégias, técnicas e procedimentos focados na mobilização de talentos, potenciais, experiências e competências de colaboradores de uma organização, bem como a gestão e a operacionalização das normas internas e legais incidentes”. Para Ribeiro (2007), a “[...] gestão de pessoas é uma área ou departamento da organização que se ocupa com um conjunto de atividades relacionadas às pessoas. Não há organização sem pessoas”.

A gestão de pessoas surgiu em razão da demanda de atividades para o cumprimento das leis trabalhistas e para adotar medidas de controle, principalmente disciplinares. O objetivo central do sistema de gestão de pessoas é contribuir para que as organizações consigam desenvolver competências diferenciadas e que conquistem consistentemente um desempenho melhor, de forma a crescer e se desenvolver, juntamente aos profissionais ligados a ela (FILIPPIM, GEMELLI, 2011).

Quando se fala de gestão de pessoas, não se refere apenas à área de recursos humanos (RH), mas também envolve todos os demais setores da organização, com objetivo de prover maior eficácia e eficiência na prestação dos serviços (FILIPPIM, GEMELLI, 2011).

Diante desse objetivo, faz sentido entender o tipo de contratação de serviço dos profissionais. Quando as contratações são internas/primárias, o setor de recursos humanos torna-se uma peça fundamental juntamente às lideranças solicitantes (AZEVEDO, SOUZA, VACCARO, 2014).

Nesse sentido, o RH se envolve com os setores para desenvolver e entender as questões necessárias para as contratações. Mas, quando há a necessidade de um serviço externo/terceiro, o RH tende a transferir a gestão de pessoas para os setores requisitantes desse serviço terceirizado (AZEVEDO, SOUZA, VACCARO, 2014).

Quando se avalia o contexto do tipo de contratação de serviço interno/primário, a gestão e gerenciamento dos elementos internos da organização, como os funcionários, administradores, estrutura organizacional, cultural organizacional, suas instalações etc, são de responsabilidade interna da empresa, tanto do RH quanto do setor adjunto à contratação (DUTRA, 2009).

Nesse tipo de contexto, a organização é responsável pelo funcionário e suas respectivas atividades. Sendo assim, cabe à empresa gerenciar a sua cultura organizacional, delimitar seus objetivos estratégicos, alocar esses objetivos e atividades aos funcionários e a suas respectivas posições dentro de uma estrutura organizacional (IVANCEVICH, 2011).

Além disso, a empresa se torna a responsável em contribuir para a evolução dos funcionários (treinamento e cursos) e também pelo controle na rotatividade (*turnover*) de pessoas na empresa (KING, 2016; IVANCEVICH, 2011).

Mediante isso, o funcionário torna-se um capital para organização, também denominado capital humano, uma vez que a empresa proporciona investimento, recursos e conhecimentos para que o profissional possa evoluir e contribuir mais para a organização (KING, 2016; IVANCEVICH, 2011).

No tipo de serviço externo, normalmente, a organização tende a contratar uma empresa de consultoria, visando ao *know-how* e à experiência que a consultoria pode agregar para a organização. Outro método de contratação de serviço externo é a contratação de MEI ou ME que são pequenas empresas.

Na maioria dos casos, essas pequenas empresas são um conjunto de 1 ou 2 pessoas, que são contratadas para executar um projeto específico ou para uma área na qual a empresa vem tendo dificuldades em encontrar no mercado. Nesse caso, é comum que esse cargo seja para um gerente ou um especialista de uma tecnologia nova no mercado, esse que possui conhecimento para gerenciar a inovação (VOLBERDA, VAN, 2013).

Ainda nesse tipo de serviço, a organização que fez a contratação da empresa externa se responsabiliza apenas pelos recursos e investimentos em *softwares* e sistemas, e a empresa terceira se torna a responsável pelo funcionário. Frente a tal cenário, independentemente dos motivos que impulsionem a empresa, a organização contratante solicita que esteja presente o capital humano para executar as demandas e atividades solicitadas (ANGELICA, AJAX, 2012).

Sendo assim, a empresa contratante não assume os riscos de investimentos com profissionais e com indicadores de rotatividade, além é claro, de contratar uma empresa com

um conhecimento específico, e não apenas um funcionário, reduzindo, assim, o risco de “falta” de conhecimento para as atividades solicitadas (KING, 2016).

Esse fator de tipo de contratação é algo muito relevante para ser considerado pelas organizações que buscam utilizar as ferramentas e metodologias do *data analytics*, visto que alguns fatores são importantes para serem considerados quanto a uma contratação interna, como, a empresa irá criar um setor específico para essa área, quais são as *skills* necessárias para os profissionais, quais são os *softwares* necessários para cada tipo de ferramenta (*big data*, *business intelligence*, *data driven*), qual o custo desse investimento para a organização e outros fatores (VOLBERDA, VAN, 2013).

Quando avaliada a questão de recrutamento e seleção, a empresa precisa iniciar a gestão desde esta fase, porque, se a contratação não for aderente a *skills* necessárias para a área e se a pessoa contratada não possuir *know-how* tanto na inovação quanto no seu gerenciamento, a gestão da inovação terá “defasagem” desde a contratação dos profissionais (IVANCEVICH, 2011).

Além disso, a empresa terá um segundo investimento, a saber, em treinamentos e especialização para esses novos profissionais (IVANCEVICH, 2011).

Então, é pragmático o contexto de contratação interna para essa área, uma vez que é uma inovação cobiçada por várias organizações. Sendo assim, as empresas, para “blindar” os seus bons funcionários, precisam oferecer altos salários e benefícios, senão, os indicadores de rotatividade tenderão a ser altos (MATTOS, *et al.*, 2014).

Contudo, se a organização contratar pessoas com baixo/médio conhecimento e investir neles, com treinamentos e especializações, haverá um risco de que, quando esses profissionais atingirem um alto grau de conhecimento na inovação, irão buscar maiores salários (KING, 2016).

Referente à estrutura organizacional, faz-se necessário avaliar a hierarquia mais adequada para a área, porque os fatores de motivação, treinamento e liderança podem afetar diretamente os profissionais da área. Por conseguinte, é fundamental ter o alinhamento entre o recrutamento e a seleção com a área, para que a contratação seja a mais assertiva para a organização (MATTOS, *et al.*, 2014).

Porém, quando a empresa faz uma contratação de uma empresa terceira, a principal dúvida a ser analisada é concernente ao valor do serviço e, claro, aos sistemas e *softwares* necessários. Ademais, contratar uma empresa de consultoria proporciona tempo para a empresa contratante, para a mesma ir amadurecendo no contexto de *data analytics*, pois a organização

pode acompanhar e aprender com o desenvolvimento da empresa de consultoria (ANGELICA, AJAX, 2012).

3. PROCEDIMENTOS METODOLÓGICOS

Este trabalho é uma pesquisa descritiva qualitativa com uma abordagem interpretativa usada para entender os dados e sua relação com as questões de pesquisa, se a gestão de pessoas influencia a gestão da inovação no uso de metodologias e ferramentas de *data analytics*. Esse desenvolvimento do relacionamento é realizado por meio de um processo iterativo que começa com uma compreensão inicial dos fenômenos que estão sendo pesquisados.

Esse entendimento é, então, refinado com a adição de novos dados e a análise desses dados, até que haja um entendimento profundo dos fenômenos a ser alcançados (BENBASAT, GOLDSTEIN, MEAD, 1987; MILES, HUBERMAN, 1994; EISENHARDT, GRAEBNER, 2007).

O método definido para o projeto foi o *survey*, conforme ressalta Babbie (2003), essa metodologia contribui para que os achados possam ser replicados entre vários subconjuntos da amostra, sendo que a reaplicação dos achados em subgrupos diferentes fortalece a certeza de que corresponde a um fenômeno geral.

Mediante a isso, foi utilizado o método *survey* através de um roteiro, que foi elaborado para a aplicação do questionário com 38 questões (APÊNDICE A), onde foram contempladas questões sobre a gestão de pessoas (tipo de contratação de serviço interno e/ou externo, cultura organizacional, estrutura corporativa, recrutamento e seleção), gestão da inovação e *data analytics*.

É possível identificar, a partir dos quadros 1 e 2, os dois aspectos conceituais definidos para este estudo e suas respectivas categorias e variáveis de análise que foram abordadas nos questionários.

No quadro 1, o foco está na obtenção de dados para entender como os respondentes visualizam a gestão da inovação em *data analytics*.

Para a definição dessas questões, foram analisadas as principais considerações e contextos que o meio acadêmico aborda quanto à gestão da inovação, buscando investigar o conhecimento dos profissionais quanto aos métodos de gestão do mercado, metodologias de gestão de conhecimento, recursos necessários, modelo de formação de equipes e pontos a serem melhorados dentro dos projetos e das rotinas.

Quadro 1 - Síntese das categorias da gestão da inovação.

Aspecto conceitual	Perguntas do questionário
Gestão da inovação	1) Quais são as Metodologias e/ou <i>frameworks</i> voltados para a área de dados?
	2) As organizações utilizam as metodologias de gestão do conhecimento após uma implementação e/ou na rotina?
	3) Quais são os recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz?
	4) Existe algum modelo ideal para trabalhar com dados?
	5) Pontos a serem melhorados em uma implementação ou até mesmo na rotina?

Fonte: próprio autor, 2022.

No quadro 2, o foco está na obtenção de dados para entender se a gestão de pessoas pode influenciar a gestão da inovação em estudo. De forma geral, esse quadro tende a resumir os conceitos apresentados, juntamente às variáveis a serem investigadas.

Quadro 2 - Síntese das categorias da gestão de pessoas

Aspecto conceitual	Categoria	Perguntas do questionário
Gestão de pessoas	Tipo de contratação de serviço	1) De 1 a 4, quanto tipo de contratação do serviço (interno/externo) influencia a gestão das empresas quanto a <i>data analytics</i> ?
		2) Qual tipo de contratação de serviço é o ideal para se trabalhar inicialmente com <i>data analytics</i> ?
		3) Qual tipo de contratação possui mais risco para a empresa?
	Cultura organizacional	1) De 1 a 4, como a cultura organizacional influencia a gestão das empresas quanto a <i>data analytics</i> ?
		2) De 1 a 4, qual a complexidade em alinhar os valores e princípios da organização com os dos profissionais da área de <i>data analytics</i> ?
		3) Como é a reação das pessoas com a mudança de <i>mindset</i> para o <i>data analytics</i> ?
		4) De 1 a 4, qual é o interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de <i>data analytics</i> ?

	Recrutamento e Seleção	1) Quais as <i>skills</i> necessárias para essa inovação?
		2) Qual o perfil de profissionais nessa área?
	Estrutura organizacional	1) De 1 a 4, como a estrutura organizacional influencia a gestão das empresas quanto a <i>data analytics</i> ?
		2) Qual é o tipo de estrutura organizacional que agrega valor para a gestão dessa inovação?
		3) Qual é a estrutura de equipe mais aderente para atuar com <i>data analytics</i> ?

Fonte: próprio autor, 2022.

Para um melhor entendimento da metodologia, foi desenvolvido o quadro 3, que expõe de forma sucinta a síntese metodológica e as variáveis do estudo, tanto do referencial teórico quanto do questionário.

Quadro 3 - Síntese da metodologia

	Descrição
Objetivo da pesquisa	Identificar a partir de coletas de dados se a gestão de pessoas influencia o processo de gestão da inovação das ferramentas e metodologias de <i>data analytics</i> .
Natureza da Pesquisa	Descritiva qualitativa
Método de Pesquisa	Aplicação de um questionário com base no roteiro definido em APÊNDICE A.
Variáveis em Análise	<i>Data analytics, big data, business intelligence, data driven, innovation management, people management, data management.</i>
Universo e Amostra da Análise	O objetivo foi coletar informações de 50 profissionais, sendo consultores e analistas de <i>data analytics</i> , gerentes de áreas de suprimentos, <i>marketing/CX/CS, team leaders</i> , POs (gerente de produto) e operação. Quanto à análise analítica, o objetivo foi coletar 30 literaturas, a partir de pesquisa das variáveis em análise.

<p>Coleta de dados</p>	<p>Aplicação do questionário com especialistas/desenvolvedores e clientes/consumidores de <i>data analytics</i> que atuam em organizações de Minas Gerais (consultoria, produção de cerveja, atacarejo, mineração, bancário e tecnologia).</p> <p>Artigos na literatura com as seguintes palavras-chaves: <i>data analytics, big data, business intelligence, data driven, innovation management, people management, data management</i>.</p>
<p>Resultados Esperados</p>	<p>Identificar as lacunas e desafios existentes na gestão da inovação em <i>data analytics</i>.</p> <p>Entender se a gestão de pessoas influencia no processo de gerenciamento dessas ferramentas e metodologias.</p>

Fonte: próprio autor, 2022.

3.1 Levantamento de dados

Foi determinado o levantamento das literaturas através das palavras-chaves (*data analytics, big data, business intelligence, data driven, innovation management, people management, data management*) que de forma geral, representam os aspectos do estudo.

Para tal levantamento, foi determinada de forma aleatória uma coleta de 30 literaturas, de diversos jornais, revistas e plataformas, nos quais, as variáveis desse estudo estavam presentes como tema central ou palavras-chaves nessas bibliografias.

Essas buscas foram realizadas nas plataformas CAPES e Google Acadêmico, de forma que, as variáveis foram usadas de forma conjunta nas pesquisas, como, *big data people management innovation management, data analytics innovation management*, e etc.

O objetivo dessa coleta de dados foi proporcionar o entendimento e de forma paralela serviu para contextualizar como as variáveis em estudo estão difundidas no meio acadêmico, e de tal forma, explorar como essas variáveis são relacionadas quando abordadas em conjunto.

A outra coleta de dado utilizada foi o desenvolvimento do questionário estruturado para o levantamento de dados. Para esse levantamento, foram selecionados 50 profissionais (no qual o autor desta pesquisa já possuía contato direto, por já ter trabalhado com esses, ou os conhecidos em algum curso de especialização ou evento online) de diferentes cargos e empresas de Minas Gerais, por isso, a definição de 50 profissionais.

O objetivo desses levantamentos foram para obter a perspectiva dos profissionais que atuam com a inovação em estudo, de forma a enriquecer esse entendimento, esses 50

profissionais foram separados/agrupados em duas personas/grupos – especialistas/desenvolvedores/analistas e o outro foi os clientes/consumidores/gestores.

De tal forma, foi definido coletar 30 respostas do primeiro grupo e 20 do outro grupo, visto que, acredita-se que, a percepção do primeiro grupo tenha um maior impacto quanto a vivência prática na área da inovação em estudo, ao mesmo tempo quem o segundo grupo, possui uma visão mais holística do uso da inovação, por isso, essa ponderação de 60%/40%, primeiro e segundo grupo, respectivamente.

Mediante a isso, buscou entender a partir da aplicação do questionário, quais os principais desafios/gargalos da gestão da inovação e entender a partir das questões propostas nos quadros 1 e 2, se a gestão de pessoas influencia a gestão da inovação em relação a inovação em estudo, *data analytics*.

E posteriormente, se o resultado for positivo, delinear um quadro de forma a analisar como a gestão de pessoas e a gestão da inovação se relacionam, se o resultado for negativo, avaliar o motivo ou o porque esses aspectos conceituais não se relacionam.

A partir disso, foram relacionadas as informações obtidas da literatura com os questionários, para descrever a relação entre a gestão de pessoas e gestão da inovação, além de associar a visão do mercado e a do meio acadêmico sobre o tema em estudo.

3.2 As etapas da pesquisa

A pesquisa foi realizada em quatro etapas. A primeira delas consistiu na definição das variáveis e categorias do estudo, identificadas no quadros 1, 2 e 3, após essa identificação, foi possível delimitar as etapas de levantamento de dados.

As variáveis e categorias de estudo foram definidas a partir da visão que o autor identificou de oportunidade e necessidade de informações sobre a abordagem desses temas no mercado profissional, analisando a partir do tempo de experiência de atuação na área em pesquisa, como analista de dados, consultor de *data analytics* e *developer* de BI em empresas de Minas Gerais.

A segunda etapa consistiu no levantamento de dados de forma analítica através da literatura, para identificar a correlação das variáveis em estudo dentro do cenário acadêmico. Esse mapeamento permitiu sintetizar um quadro teórico-metodológico para explorar as dimensões da gestão de pessoas quanto ao processo de gestão da inovação, além de descrever a relação dessas variáveis dentro do cenário acadêmico.

Quanto a parte de coleta de dados, essa etapa teve como objetivo o contato do autor com os profissionais que foram definidos como *target* para responder os questionários, sendo assim, foi marcado um tempo de aproximadamente 15-20 minutos com cada pessoa, para explicar o motivo do estudo e como seria realizado a aplicação do questionário, explicando a esses, as etapas dos aspectos conceituais propostos nesse estudo.

A terceira etapa abrangeu o desenvolvimento e o envio dos questionários, essa etapa foi desenvolvida no Google Forms, através de um formulário enviado para as 50 pessoas delimitadas para o estudo, que ficou em aberto durante os dias 28 de março de 2022 até dia 08 de abril de 2022, a partir desse link: “https://docs.google.com/forms/d/e/1FAIpQLSehG95iwZKR1_qnE6tSUV36xzzv8AWfb6q_bZqJb1qxKBnQMg/viewform?usp=sf_link”.

Durante esse tempo, o autor entrou em contato com o público alvo apenas para relembrar a esses sobre a relevância dos mesmos responderem o questionário, esses contatos foram realizados nos dias 01, 05 e 08 de abril de 2022 via e-mail e mensagem no WhatsApp.

Esse mapeamento viabilizou a delineação de desafios e oportunidades do *data analytics* a partir da percepção de profissionais da área. De forma complementar, foi possível levantar entendimentos para relacionar a gestão de pessoas e gestão da inovação, para o contexto do mercado, e, com isso, correlacionar a visão do mercado com a do meio acadêmico.

Na quarta e última etapa foi realizado o tratamento dos dados tanto da análise analítica quanto dos questionários. O tratamento da base de dados do questionário foi a partir do Excel, visto que, como no questionário havia algumas perguntas em aberto, foram parametrizadas as respostas e identificados os *clusters* para fazer coincidir as respostas com características e definições mais próximas, de forma a obter um grupo de respostas.

Os *clusters* foram parametrizados a partir das palavras chaves descritas nas questões de campo aberto do questionário, mediante a isso, foi lido cada comentário, e inicialmente, os comentários que tinha palavras semelhantes e/ou similares, foram separadas, logo depois, foi realizado um processo de análise crítica a partir do conhecimento do autor quanto as frases separadas, para agrupar aqueles comentários que possuíam o mesmo sentido ou contexto.

Já para outras perguntas do questionário, foi aplicado a escala de Likert, de forma a metrificar as variáveis categoricas propostas nas questões. Com isso, foi delineado para essas questões, 4 opções de respostas para o público, sendo elas, 1 – Pouca(o) influencia, 2 – Razoável influencia, 3 – Considerável influencia e 4 – Muita(o) influencia.

Mediante a isso, esses campos categoricos foram usados posteriormente como métricas, visto que, esses foram ponderados, para as categorias, 1 – 25%, 2 – 50%, 3 – 75% e 4 – 100%.

E por último, outras perguntas foram tratadas apenas em campos fechados no questionário, sendo assim, essas tiveram nenhum tratamento, foi apenas realizado a contagem de respostas para cada opção.

Após o tratamento foi desenhando uma estrutura de base de dados no Excel, sendo que, cada linha representou uma resposta distinta e as colunas às perguntas do questionário, num formato de matriz, e mediante isso foi realizado o processo de ETL, onde foi transformado os dados das coletas em informação a partir da ferramenta de BI da Microsoft, Power BI.

Com isso, foram construídos os gráficos e *dashboards* que foram utilizados como base para os resultados e as análises da pesquisa, a partir dessa ferramenta, também foi possível cruzar os questionários de ambos os grupos, para interpretar de forma distinta as visões e percepções de cada persona/grupo.

4. RESULTADOS DA PESQUISA

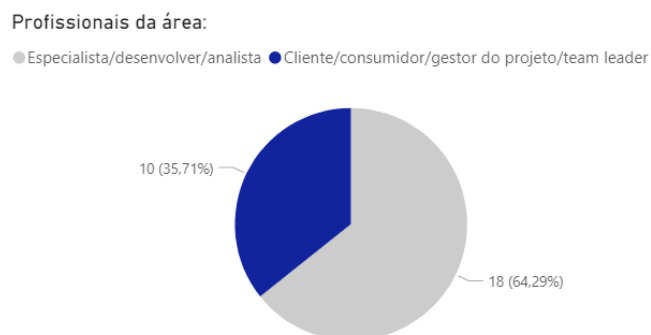
Para a melhor forma de apresentação dos resultados, este tópico foi dividido em três estruturas. A primeira etapa foi usada para contextualizar as personas; a segunda estrutura irá descrever de forma detalhada a visão das duas personas definidas quanto às variáveis e categorias propostas para este estudo. A última sequência dos resultados teve como finalidade correlacionar a visão das categorias e variáveis de *data analytics* do meio acadêmico com a do mercado.

4.1 Entendimento das personas

Neste tópico, foram contextualizados os tópicos iniciais do questionário, visando apresentar as personas e algumas informações relevantes da área de *data analytics*. O retorno do questionário teve uma taxa de 56%, o que corresponde a 28 respostas, sendo que a amostragem definida na metodologia foi de 50 respostas.

Dentro do público-alvo definido de profissionais foi possível coletar 18 respostas do grupo especialista/desenvolvedor/analista (grupo A) e 10 respostas do grupo cliente/consumidor/gestor do projeto/*team leader* (grupo B), resultando em um total de 28 retornos. Esses dados podem ser analisados a partir do gráfico 1.

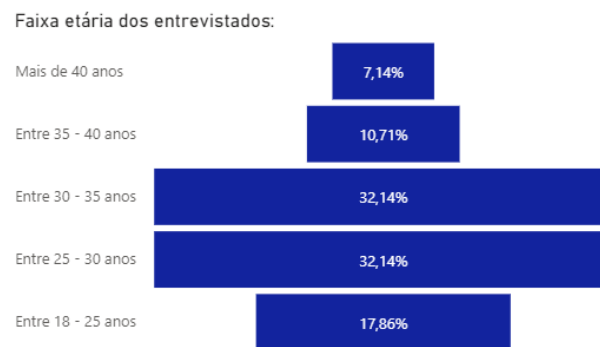
Gráfico 1 - Quantidade de respostas dos grupos definidos.



Fonte: próprio autor, 2022.

Outro entendimento na pesquisa foi a faixa etária dos profissionais dentro desse mercado, observa-se, a partir do gráfico 2 e da tabela 1, que a faixa etária e as gerações dos profissionais dessa área são:

Gráfico 2 - Faixa etária dos profissionais



Fonte: próprio autor, 2022.

Nota-se que aproximadamente 64% das pessoas que responderam possuíam uma idade entre 25 a 35 anos e que, de forma crescente, pessoas entre 18 a 25 anos vêm tendo espaço dentro desse mercado de tecnologia.

Para validar essa percepção da idade das pessoas foi também perguntado quais são as gerações mais predominantes no mercado, porém essa pergunta foi de campo aberto, uma vez que não existe uma resposta única. Portanto, foram coletados 40 retornos dessa pergunta, e os dados podem ser avaliados na tabela 1.

Tabela 1 - Quantidade de respostas por geração.

Geração	Quantidade de respostas
Geração Y ou Millennials (1981–1996)	22
Geração Z (1997–2010)	17
Geração X (1965–1980)	1

Fonte: próprio autor, 2022.


A partir dessa informação coletada, pode-se inferir que as pessoas que responderam confirmam que aquelas da geração Y — faixa etária de 25–40 anos — são predominantes nesse mercado. Todavia, verifica-se que existe uma grande tendência nesse mercado para profissionais da geração Z (BRITO, 2013).

Destaca-se, a partir dessa informação coletada das gerações, a presença de uma pequena fração das pessoas acima de 40 anos ou geração X nesse mercado. Mesmo que a área de *analytics* tenha tido um maior crescimento após a década de 2010, alguns conceitos e metodologias dessa inovação possuem raízes na década de 1980–1990 (FRICKE, 2009).

As informações da área de mercado/negócio e setores também foram importantes dentro da coleta de dados. Apesar de ter acontecido uma maior concentração em alguns mercados/negócio e setores (devido a proximidade do autor com o público alvo), houve uma coleta com uma grande variabilidade de respostas, o que proporciona um conhecimento superficial de outras áreas do mercado e setores de atuação.

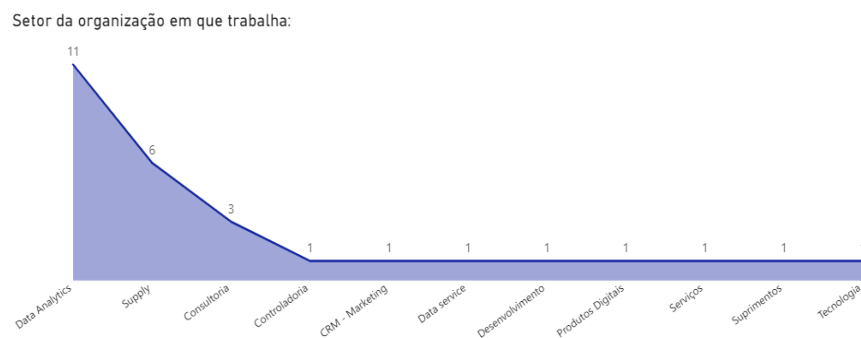
Com esses pontos contextualizados, podem-se avaliar as informações da área de negócio das empresas e setores de atuação a partir dos gráficos 3 e 4, respectivamente.

Gráfico 3 - Área de mercado/negócio das empresas



Fonte: próprio autor, 2022.

Gráfico 4 - Setores das organizações



Fonte: próprio autor, 2022.

Mesmo com uma grande dispersão na coleta desses dados, pode-se inferir que essa inovação está presente em vários tipos de mercado/negócio, o que constitui uma inovação considerada fundamental para as empresas, independentemente da área de atuação.

Assim como Phillip (2011) apresenta na literatura, é possível verificar a presença dessa inovação em vários setores das organizações, com alguns setores ganhando mais destaque, por já ter uma estrutura definida adequadamente e por ser voltada exclusivamente para a área ou até mesmo pelo potencial de retorno que a área possui para as companhias.

Já outros departamentos, com características bastante distintas da área de *analytics*, demonstram aplicabilidade, na medida em que essa inovação tem como objetivo trabalhar com dados e gerar informação. Então, como todo os setores de uma empresa tendem a gerar dados, é possível aplicar essa tecnologia em qualquer setor organizacional (PHILLIP, 2011).

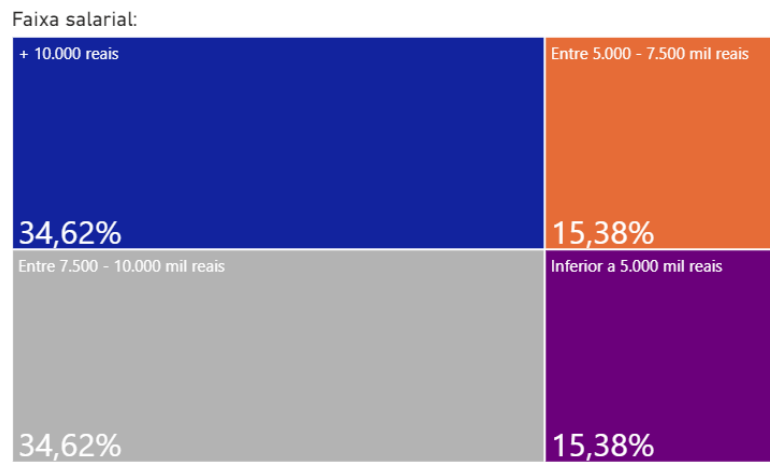
Por meio do que foi exposto, essas duas informações coletadas revelam que a inovação de *data analytics* não possui restrições e consegue gerar valor em qualquer área de aplicação.

Um dos fatores relevantes dos questionários foi quanto à demanda de mão de obra para essa área, no qual abordou a questão de que se o mercado solicita constantemente profissionais qualificados para trabalhar com *data analytics*.

Todos os 28 responderam que “SIM”, que o mercado a todo momento oferta novas vagas de emprego e busca bons profissionais. Tal aspecto representa um fator que será discutido mais a frente, a saber, a questão do *turnover*/rotatividade de pessoas dessa área dentro do mercado (COUTO, 2020).

Ainda dentro desse contexto de mão de obra qualificada, uma pergunta do questionário foi sobre a faixa salarial desses profissionais. Podem-se avaliar, a partir do gráfico 5, as respostas a partir dos *clusters* criados.

Gráfico 5 - Faixa salarial.



Fonte: próprio autor, 2022.

A partir do gráfico 5, estima-se avaliar como os profissionais dessa área são altamente valorizados, já que cerca de 68% dos respondentes possuem uma faixa salarial mensal superior a R\$ 7.500,00 reais, o que representa aproximadamente 3 vezes mais que o salário médio brasileiro em 2022, que é R\$ 2.510,00 reais (IBGE, 2022).

Um detalhe importante a ser contextualizado, ainda na faixa salarial, é o tempo de experiência desses profissionais. Observa-se pela tabela 2 que aproximadamente 70% das pessoas que responderam possuem menos de 5 anos de experiência quanto a *data analytics*, o que enfatiza que, mesmo sendo uma inovação recente, os profissionais do mercado ainda estão em evolução e aprendizado quanto a essa tecnologia, demonstrando o tamanho e a capacidade que esse mercado ainda tende a evoluir (CHOI, WALLACE, WANG, 2018; CNI, 2018).

Ademais, valida-se a hipótese de como esses profissionais são valorizados pelo mercado, pois, a despeito de não ter experiência de muitos anos com essa inovação, boa parte desses profissionais possuem uma faixa salarial superior à média brasileira.

Tabela 2 - Tempo de experiência dos profissionais.

Experiência	Frequência absoluta	Frequência relativa	Frequência acumulada
mais de 5 anos	9	32%	100%
3–5 anos	5	18%	68%
2–3 anos	9	32%	50%
1–2 anos	2	7%	18%

menos de 1 ano	3	11%	11%
----------------	---	-----	-----

Fonte: próprio autor, 2022.

4.2 Clientes/consumidores/gestores/team leaders

Conforme apresentado no gráfico 1, para essa persona, foram coletados 10 retornos. Conforme contextualizado anteriormente, esse público abarca aqueles profissionais que solicitam e utilizam essas ferramentas nas suas rotinas. São essas pessoas que precisam da informação para tomar alguma ação e/ou atitude a partir dos dados.

Então, acredita-se que a percepção desse membro do *data analytics*, seja voltada para uma visão mais gerencial, com um maior entendimento do impacto da gestão de pessoas na inovação, uma vez que essas são as pessoas que irão obter o conhecimento e a informação a partir dos dados e irão difundi-los para a organização.

Diante disso, nos próximos tópicos, será contextualizada a visão desse grupo dentro das variáveis e categorias definidas para os aspectos conceituais deste estudo.

No aspecto conceitual de gestão da inovação, assim como definido no quadro 1, foram delineadas cinco categorias de análise nos questionários.

Na primeira categoria, foi identificado que a maior parte desse grupo desconhece algumas metodologias e/ou *frameworks* presentes no mercado, e, comumente, esses profissionais utilizam metodologias “próprias” ou se adaptam à metodologia que a organização utiliza. Apenas 20% das respostas foram destinadas a algumas metodologias e/ou *frameworks* de *data analytics*.

Já aproximadamente 40% das respostas foram atreladas a metodologias da organização; em 30% delas, há metodologias próprias, e 10% trabalham com metodologias de gestão ágil, como *Kanban* e *Scrum*, que, tecnicamente, são utilizadas para gerenciar atividades e entregas.

Essa análise se torna concreta quando comparado com as literaturas de Montevecchi (2012) e Kdnugetts (2014), que também demonstram um *gap* de conhecimento dos profissionais com as principais metodologias da área, o que possibilita uma oportunidade para melhoria e evolução aos profissionais, obtendo o conhecimento dessas metodologias e *frameworks*.

O fato de tal grupo utilizar a metodologia da organização faz com que esses profissionais possivelmente tenham nos primeiros meses na organização uma dificuldade de acompanhar e agregar conhecimento ao processo, visto que desconhecem as metodologias principais do

mercado. Esse fator pode ocasionar várias perdas para a empresa, uma vez que esse grupo solicitante não consegue acompanhar ou entender de forma crítica as entregas recebidas.

Quanto ao fato de usarem a própria metodologia, evidência o fato de que a organização não possui uma estrutura metodológica delineada para se trabalhar com dados, considerando que essa circunstância pode afetar a comunicação, agilidade e assertividade entre esse grupo de clientes com os desenvolvedores (MONTEVECCHI, 2012).

Tende-se a mensurar que cada grupo trabalha com a sua própria metodologia ou com metodologias que se distinguem em algumas etapas e/ou processos. Portanto, em algum momento dentro do processo de desenvolvimento, implementação e/ou rotina, haverá *gaps* não preenchidos, na medida em que a estrutura de trabalho de cada grupo funcional do projeto trabalhou com metodologias distintas.

A segunda categoria foi trabalhada com algumas opções de resposta e com campo aberto, mas, quase com unanimidade, a opção mais escolhida foi “NÃO”, com quase 80% desse grupo dizendo que não utilizam nenhuma metodologia para fazer a gestão do conhecimento.

Relevante avaliar esse valor, ainda mais numa área que possui características e fatores para um alto indicador de rotatividade de pessoas. A gestão do conhecimento é fundamental, pois, a partir desse processo de gestão, é possível transformar o conhecimento tácito em conhecimento explícito, de forma a “tirar” o conhecimento da “cabeça” das pessoas e transformar em conhecimento para a organização (CHANDLER, 1962; KIPPING, ENGWALL, 2002).

As outras duas metodologias respondidas são bastante interessantes e frequentemente são as mais usadas em organizações que adotam processos de gestão do conhecimento. A gestão de portfólio, vocábulo este que representa o conjunto de projetos, é uma metodologia fundamental para a documentação dos programas (DANTAS, *et al.*, 2008).

Talvez, o critério mais relevante a se destacar para essa metodologia é um padrão que possa ser preenchido e documentado de forma rápida e assertiva. Há controvérsias de que a documentação de projetos torna o processo de desenvolvimento oneroso, devido ao fato de demandar a documentação de todas as etapas do processo, bases de dados, regras de negócio, cálculos etc (DANTAS, *et al.*, 2008).

Mediante tal aspecto, é provável que desenvolver um padrão harmônico, de fácil preenchimento e entendimento, seja o principal *gap*, para se trabalhar com essa categoria (DANTAS, *et al.*, 2008).

Dentro da área de *analytics*, esse é o grupo que gerência os projetos, de tal forma, esses são os maiores interessados em ter uma boa documentação dos projetos. Toma-se como

hipótese a seguinte situação: o desenvolvedor do projeto foi promovido ou saiu da organização, questiona-se, então, como será o processo de conhecimento do próximo desenvolvedor (BOENTE, OLIVEIRA, ROSA, 2007).


Ele terá que recomeçar todo o trabalho e de tal forma ele ficará horas estudando as bases de dados, as regras de negócio e cálculos servem para isso, inteirar os novos profissionais de uma forma simples e sucinta todo o projeto. Pensando em termos de agilidade e assertividade, conclui-se que um padrão de documentação é fundamental para os projetos de *data analytics* (BOENTE, OLIVEIRA, ROSA, 2007).

A outra metodologia apresentada, o *sharing knowledge*, possui características bem semelhantes à gestão de portfólios/projetos, sendo que o contexto de documentação tende a ter os mesmos benefícios e adversidades. Em comparação com a outra metodologia já discutida, o principal ponto de aperfeiçoamento desta é que ela promove uma série de discussões e conversas para padronizar o desenvolvimento de forma a seguir as boas práticas, com o objetivo que vai além de transformar o conhecimento em explícito.

Para um bom aproveitamento dessa metodologia, a presença desse grupo de clientes agrega valor, de forma a tentar conduzir as reuniões para obter um conhecimento além de uma série de documentos. Esse método pode proporcionar mais agilidade ao cliente, uma vez que ele pode obter conhecimento a partir de uma “roda de conversa” em vez de ficar horas lendo um documento. Assim, ele guardaria a documentação para dúvidas específicas e/ou para novas pessoas que entrarem no projeto.

A terceira categoria foi trabalhada apenas com campo aberto, portanto, houve uma grande quantidade de respostas, que foram analisadas e *clusterizadas* - assim como contextualizado na metodologia - de forma a resumir de forma mais coerente os contextos respondidos. Diante disso, foram coletadas cerca de 28 comentários, que foram sintetizados para 10 palavras-chaves relacionadas, os quais podem ser visualizados a partir da figura 8.

Figura 8 - Recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz definidos pelo grupo: clientes/consumidor/gestores/team leader.



Fonte: próprio autor, 2022.

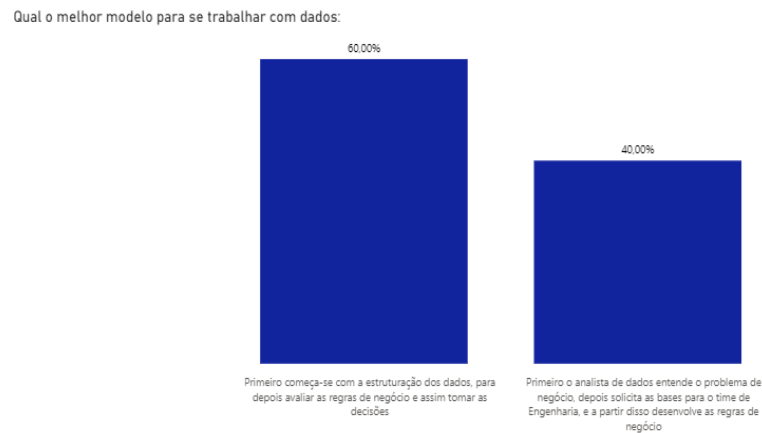
A partir da figura 8, pode-se observar que os recursos infraestrutura, ferramenta e mão de obra qualificada foram os *clusters* mais relevantes para esse grupo. Mediante isso, esses profissionais acreditam que os principais suportes para se trabalhar com dados estão na questão de investimentos em boas ferramentas e infraestruturas.

Contudo, o interessante para essa discussão é o fato de ressaltar a questão da mão de obra qualificada, que, nesse caso, está diretamente relacionada à gestão de pessoas para executar as melhores atividades e processos, o que igualmente demanda grande investimento, independentemente da forma de contratação. Esse levantamento confirma o que foi dito na literatura por Kipping e Engwall (2002), sobre o fato de haver necessidade de pessoas qualificadas para executarem processos de gestão da inovação dentro das organizações.

Outros dois pontos, significativos a serem ressaltados, mas que não tiveram grande relevância, tocam a questão da cultura e dos treinamentos, que estão também diretamente relacionados com a forma de gerenciar as pessoas e a maneira de executar as atividades na organização.

A quarta categoria foi trabalhada com opções fechadas e um campo em aberto. Porém, esse grupo escolheu apenas as opções de múltipla escolha. As respostas para essa pergunta podem ser observadas no gráfico 6.

Gráfico 6 - Modelo de gestão da inovação para se trabalhar com dados pelo grupo: clientes/consumidor/gestores/*team leader*.



Fonte: próprio autor, 2022.

A quarta categoria é uma discussão objetiva de como se gerenciar os profissionais para executarem as atividades dentro de um projeto. Tal etapa é fundamental, porque todo o planejamento e gerenciamento da inovação serão definidos a partir do método a ser trabalhado.

Fica nítido, a partir do gráfico 6, que o método de trabalho não é unânime para esse grupo, visto que 60% das pessoas definiram que a primeira parte do projeto deve ser a estruturação dos dados, em seguida a equipe avalia as regras de negócio e desenvolve as ferramentas para gerar informação, levando, assim, o conhecimento para os clientes tomarem suas decisões.

Todavia, na íntegra, escalonar um grupo para esse tipo de estrutura significa ter uma equipe de engenharia de dados, visando estabelecer as bases e preparar as estruturas (DW, *Data Lake*, etc). A partir disso, há a presença de um analista de dados ou profissional de BI, para transformar os dados em informação com base nas ferramentas de BI (*Power BI*, *Tableau*, etc). Esse método possui processos semelhantes ao KDD, apresentado na literatura por Boente, Oliveira e Rosa (2007), onde avalia-se etapas específicas de trabalho dentro de um ciclo de atividades.

Considerando a outra opção, que teve 40% de representatividade, tem-se que a primeira etapa de um processo de *analytics* deve começar com a equipe de negócios entendendo o problema a ser resolvido e, posteriormente, buscando as bases e a estrutura de dados.

Na sequência, com o recebimento das bases, são desenvolvidas as regras de negócio específicas para obter as informações necessárias. Esse método possui processos semelhantes ao CRISP-DM, exposto na literatura por Champman, Clinton e Kerber (2010).

A principal diferença entre esses dois métodos está na forma de gerenciar as pessoas e recursos investidos, e a definição do melhor modelo para se trabalhar depende muito dos recursos de estrutura da empresa, do tipo de contratação das pessoas que estão atuando no projeto e, principalmente, a forma como os clientes gerenciam as suas equipes.

A quinta categoria foi trabalhada apenas com campos em aberto. Frente a isso, constatou-se uma grande quantidade de respostas, as quais foram analisadas e *clusterizadas* - de acordo com a metodologia - de forma a resumir coerentemente os contextos respondidos.

Diante disso, foram coletados cerca de 14 comentários, que foram sintetizados para 10 palavras-chaves relacionados. Esses grupos podem ser visualizados a partir da figura 9.

Figura 9 - Pontos a serem melhorados em uma implementação ou rotina pelo grupo: clientes/consumidor/gestores/team leader.

Pontos a serem melhorados em uma implementação ou rotina:



Fonte: próprio autor, 2022.

Como se pode observar pela figura 9, houve uma grande variabilidade de respostas, sendo que não se verificou uma resposta com mais variância que as demais. Portanto, torna-se complexo fazer alguma aferição perante as respostas coletadas, porém, é possível identificar de forma superficial os pontos que esse grupo considera importantes a serem trabalhados.

Como mencionado anteriormente, no método de se gerenciar a inovação, o tema otimização de tempo é novamente relevante aos projetos de *analytics*. Como já dito, a forma de organizar a(s) equipe(s) se torna fundamental para agregar benefício a inovação.

Além do tempo, a questão de gerenciar as pessoas é novamente validada como ponto de atenção e melhoria; a partir da experiência os clientes começam a ter um maior *know-how* de como atuar com esses projetos, assim, a definição do tipo de contratação do serviço e os processos tornam-se mais direcionados (COUTO, 2020).

Outros dois pontos dentro dessas respostas são os fatores de sustentabilidade dos projetos e o fato de ser mais *data driven*. O fator relacionado à presença de projetos sustentáveis está caracterizado por projetos que não precisaram de manutenção ou alterações manuais ao longo do tempo, é claro, se não houver uma modificação de regra de negócio e/ou base.

Porém, para se conseguir esse feito, são necessários profissionais qualificados, que possam desenvolver projetos, que não gerem possíveis retrabalhos e adição de novos custos aos clientes (CHEN, CHIANG, 2012; HU, WEN, CHUA, 2014).

O fato de ser mais *data driven* está concernente à obtenção de uma maior quantidade de informação a partir dos dados. Contar com análises mais inteligentes proporciona mais agilidade e assertividade aos clientes, e, considerando uma empresa na qual os projetos serão destinados ao time de operação, essas análises tendem a ser as mais objetivas e conclusivas possíveis, para agregar valor às equipes (MICHAEL, VINCENT, 2010).


Nesse sentido, as pessoas da operação não precisariam destinar tempo para entender o que aconteceu; ao contrário, os próprios dados gerariam as informações (MICHAEL, VINCENT, 2010).

Para o aspecto conceitual de gestão de pessoas, assim como definido no quadro 2, foram delineadas quatro categorias de análise no questionário.

A primeira categoria abordada foi o tipo de contratação de serviço, interno ou terciário, sendo estipuladas três questões para entender como essa categoria influencia o processo de gestão da inovação de *data analytics*. Na primeira questão, foi usada a escala de Likert, para a coleta dos dados; já para as demais questões, foi empregada a múltipla escolha.

As três questões podem ser analisadas a partir dos gráficos 7, 8 e 9.

Gráfico 7 - Percepção da influência do tipo de contratação de serviço em *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*



Fonte: próprio autor, 2022.


A partir do gráfico 7, pode-se avaliar que 60% desse grupo informaram que o impacto do tipo da contratação é “3 – Considerável”, o que corresponde a 75% de impacto. Já os demais

informaram que a influência é direta, isto é, a forma de contratar profissionais para trabalhar nessa área, impacta “4 – Muito” a forma de se gerenciar essa inovação.

Fazendo uma análise probabilística, é possível estimar que o impacto registrado por esse grupo quanto à influência do tipo de contratação para a gestão da inovação em *data analytics* é de 85%.

Gráfico 8 - Tipo de contratação “ideal” para se trabalhar inicialmente com *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*

Qual o tipo de contratação de serviço é o “ideal” para trabalhar inicialmente com *data analytics*:



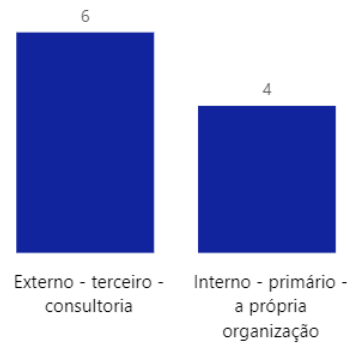
Fonte: próprio autor, 2022.

Entendendo melhor como essa categoria influencia a gestão da inovação, o gráfico 8 proporciona a visão acerca do modelo “ideal” para se trabalhar inicialmente com *data analytics*, revelando que 70% do público identificou que a contratação interna é a forma ideal. Essa visão é muito interessante para se analisar, já que esse grupo é o responsável pela gestão das atividades e demandas dos projetos.

O motivo para essa escolha de contratação pode estar relacionado com a forma de gerenciar as pessoas, visto que, quando a contratação é externa, a responsabilidade pela gestão dos profissionais não está vinculada aos clientes. Por essa razão, faz mais sentido ter uma equipe interna, para haver uma relação direta com os profissionais.

Gráfico 9 - Tipo de contratação que possui mais risco para se trabalhar com *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*

Qual o tipo de contratação possui mais "risco" para a empresa quanto a *data analytics*:



Fonte: próprio autor, 2022.

Objetivando a complementação da informação apresentada no tópico anterior, a partir do gráfico 9, é possível identificar qual tipo de contratação possui mais “risco” para as empresas. Estabelecendo uma relação direta com a informação apresentada no gráfico 8, pontua-se que a contratação interna possui uma melhor percepção e adoção desse grupo quanto à forma de recrutamento de profissionais para essa área.

O fato que pode estar relacionado a essas respostas deve ser o receio desse grupo quanto às entregas de demandas, métodos de gestão e/ou cultura das empresas externas, uma vez que o investimento com serviços externos tende a ser maior do que o investimento de um profissional interno. Possivelmente, esse grupo de clientes possui a percepção de que o custo/benefício apresenta um maior risco para a organização.

O motivo quanto aos métodos de gestão pode estar relacionado ao fato contextualizado na análise do gráfico 8, no qual verifica-se que esse grupo, possivelmente, possui a preferência de manter a gestão das pessoas na sua estrutura. Já a cultura representa outro motivo que pode agravar o contexto do tipo de contratação, já que a empresa externa possui valores e princípios diferentes da empresa contratante, esse fator pode gerar alguns entraves entre as empresas.

Relevante também analisar com outra perspectiva quanto ao tipo de contratação, visto que 40% das respostas demonstraram que existe risco em trabalhar com a equipe interna, o que pode ser associado principalmente a fatores de contratação de profissionais sem o *know-how* adequado para as demandas solicitadas, desenvolvimento de conhecimento dentro da organização e rotatividade nessa área de *analytics* (KING, 2016; IVANCEVICH, 2011).

Assim como destacado por Filippim e Gemelli (2011), é relevante para a empresa analisar quais influências que podem ser mitigadas com uma boa gestão da organização, para conseguir definir qual o melhor tipo de contratação para se trabalhar com *data analytics*, pois ambos os tipos de contratação possuem vantagens e desvantagens. Destaca-se que, para esse seletivo grupo, a melhor forma de contratação para essa área são de profissionais internos.


Analisando a segunda categoria desse aspecto conceitual, a cultura organizacional, nota-se que foram estipuladas quatro questões para entender como essa categoria influencia o processo de gestão da inovação de *data analytics*.

Em todas as questões dessa categoria, foram utilizadas a escala de Likert, para o levantamento dos dados. As questões podem ser analisadas a partir dos gráficos 10, 12 e 13.

Observou-se que, quase de forma unânime, 90% das respostas desse grupo informaram que o impacto da cultura organizacional é demasiado (“4–Muito”), o que corresponde a 100% de influência dessa categoria quanto à forma de se gerenciar essa inovação.

Através de uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto à influência da cultura organizacional para a gestão da inovação em *data analytics* é de aproximadamente 97,5%.

Gráfico 10 - Percepção da complexidade de alinhar valores e princípios da organização com os dos profissionais do *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*



Fonte: próprio autor, 2022.

De forma a complementar o entendimento de como essa categoria influencia a gestão da inovação, a partir do gráfico 10, é possível identificar que 50% desse grupo informaram que há 75% (“3 – Considerável”) de complexidade em realizar o alinhamento de valores e princípios da organização com os dos profissionais da área. Em contrapartida, outros 30% afirmaram que é bastante (4–“Muito”) complexo fazer essa relação de cultura com os profissionais.

Empreendendo uma análise probabilística das respostas, estima-se que o impacto registrado por esse grupo quanto à complexidade desse alinhamento é de aproximadamente 75%.


Essa percepção de complexidade pode estar associada com as características da área, o estilo de vida e os benefícios que esses profissionais buscam, porque, por ser uma inovação associada a dados e a desenvolvimento de programação em ferramentas, por ter dependência total de um computador/*notebook* e por não haver uma necessidade exclusiva de contato físico entre as pessoas, esses profissionais costumam preferir um estilo de trabalho em *home office*, com uma maior flexibilidade quanto às horas de trabalho, alternando dia com noite, ou até mesmo os dias da semana com os finais de semana (MIRANDA, 2022).

Pode-se avaliar, por meio do gráfico 11, que esse impacto é algo considerável para esse grupo de clientes, visto que 80% responderam que profissionais dessa área possuem uma cultura diferente.

Gráfico 11 - Percepção da diferença de cultura de profissionais de *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*

A cultura de um profissional de *data analytics* é diferente? Estilo de vida? Horário de trabalho? Benefícios? Home office?

● Sim ● Não




Fonte: próprio autor, 2022.

O que foi exposto demonstra que o fator cultura pode ser um motivo da complexidade de se alinhar os valores e princípios da organização com esses profissionais.

Mediante a isso, muitas organizacionais estão tentando se adaptar a esses fatores característicos da inovação de *data analytics*, tanto que, segundo o site de vagas do Brasil, Empregos.com.br, houve um crescimento de 140% de vagas home office em janeiro de 2022, em comparação a janeiro de 2021, representando um aumento de aproximadamente 1.245 vagas, com 41,17% dessa composição para a área de tecnologia (MIRANDA, 2022).

Gráfico 12 - Percepção da reação das pessoas/organização com a mudança de *mindset* para *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*



Fonte: próprio autor, 2022.

Outro fator para entender essa categoria é avaliar como é a reação dos profissionais da organização com a mudança de *mindset* para dados, visto que, por anos, a forma de tomar decisões a partir da experiência e do conhecimento tácito foi utilizada pelas organizações.


Através da evolução do uso dos dados, essa mudança de *mindset* vem crescendo no mercado, na medida em que a tomada de decisão a partir de dados acontece de forma explícita, que diverge com o que era utilizado pelas organizações (CHOI, WALLACE, WANG, 2018; KAYSER, 2018).

Em vista disso, é viável analisar, a partir do gráfico 12, que 40% desse grupo acreditam que a reação das pessoas é de “4– Dificil adaptação”, enquanto 30% acreditam que seja “3 – Considerável” e, para outros 30%, “2 – Razoável”.

Fazendo uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto à reação das pessoas com essa mudança é de aproximadamente 78%.

Por isso, as organizações poderiam trabalhar com seus profissionais de forma a associar essa mudança de cultura de uma forma mais natural e gradativa, principalmente para aqueles com maior tempo de experiência, considerando que, para esses, uma mudança radical tende a ser mais complexa (MATTOS, *et al.*, 2014).

Gráfico 13 - Percepção do interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*



Fonte: próprio autor, 2022.

A última questão dessa categoria busca investigar se existe interesse de profissionais que não são da área para migrar para *data analytics*.

Essa análise poderia ser feita dentro das organizações, pois está diretamente relacionado com a questão do tipo de contratação, uma vez que, se a empresa contratar um serviço terceiro em vez de promover oportunidades na organização, esse fator pode gerar insatisfação e/ou desmotivação nos funcionários, fazendo com que os índices de rotatividades tendam a crescer, assim como ressalta King (2016) e Ivancevich (2011), a importância de cultivar o treinamento e desenvolvimento dos profissionais dentro da organização.


Acerca do que foi ressaltado, é possível ver, a partir do gráfico 13, que 60% desse grupo acreditam que o interesse é “3 – Considerável”, 20% identificam que existe “4 – Muito” interesse, e, para outros 20%, o interesse é “2 – Razoável”.

De forma geral, procedendo uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto ao interesse das pessoas em migrarem de área para *data analytics* é de aproximadamente 75%, o que demonstra que as organizações precisam saber gerenciar e ter atenção quanto a esse detalhe cultural dentro da organização.

A terceira categoria é recrutamento e seleção. Para essa categoria, foram estipuladas duas questões para entender como ela influencia o processo de gestão da inovação de *data analytics*.

Na primeira questão, foi utilizada a escala de Likert, e, na segunda questão, foi empregado um campo em aberto para o levantamento dos dados. As duas questões podem ser analisadas a partir do gráfico 14 e figura 10.

Gráfico 14 - Percepção da influência do processo de recrutamento e seleção na gestão de *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*



Fonte: próprio autor, 2022.

A partir do gráfico 14, pode-se avaliar que 70% desse grupo informaram que o impacto do processo de recrutamento e seleção é “3 – Considerável”, e os outros 30% disseram que essa categoria influencia “4 – Muito” o método de gestão dessa inovação.

Fazendo uma análise probabilística das respostas, estima-se que o impacto registrado por esse grupo quanto à influência desse processo para a gestão da inovação em *data analytics* é de aproximadamente 83%.

Figura 10 - Percepção das skills e habilidades específicas dos profissionais de data analytics pelo grupo: clientes/consumidor/gestores/team leader.

Skills e habilidades específicas de profissionais da área de data analytics:



Fonte: próprio autor, 2022.

Para entender como esse processo influencia a gestão de *analytics*, é preciso primeiramente entender se o perfil que as empresas estão contratando estão aderente a *skills* e habilidades específicas para a área. Mediante o exposto é possível fazer tal análise a partir da figura 10, que apresenta essas informações coletadas.

Examinando a figura 10, fica evidente que, para esse grupo, a qualidade fundamental que os profissionais dessa área precisam ter é “Perfil Analítico”, com quase 50% de representatividade dentro da amostra. As características complementares são “Aprendizado Contínuo”, “Raciocínio Lógico” e “Autogerenciamento”.

A partir disso, é preciso ver o quão difundida essa informação está para as pessoas que promovem os processos de recrutamento e seleção, visto que, se não existir uma comunicação desse grupo com a área de RH, todo o processo de *analytics* pode ser prejudicado com uma contratação ruim (AZEVEDO, SOUZA, VACCARO, 2014).

Além de uma possível contratação não qualificada para a área, outros fatores são fundamentais para a área de RH. Assim como mencionado no gráfico 9, existe a necessidade de promover treinamentos e desenvolvimento de lideranças para a área em estudo, e o setor de

RH é fundamental nesse processo de evolução do “capital humano” (KING, 2016; IVANCEVICH, 2011).

Com isso, o conhecimento além dessas habilidades “comuns” da área se revela crucial, fazendo-se necessário conhecer de forma mais profunda as técnicas e métodos da área para contribuir no desenvolvimento de líderes, além de conseguir contribuir no desenvolvimento com treinamentos e cursos que agreguem valor para os profissionais e para a organização (KING, 2016; IVANCEVICH, 2011).

A quarta e última categoria abordada foi a estrutura organizacional. Para essa categoria, foram estipuladas três questões para entender como ela influencia o processo de gestão da inovação de *data analytics*.

Na primeira questão, foi utilizada a escala de Likert, e, na segunda questão, empregou-se um campo de múltipla escolha para o levantamento dos dados. As duas primeiras questões podem ser analisadas a partir dos gráficos 15 e 16.

Gráfico 15 - Percepção da influência da estrutura organizacional na gestão de *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*.




Fonte: próprio autor, 2022.

Analisando o gráfico 15, pode-se avaliar que 60% desse grupo informaram que há “4 – Muito” impacto da estrutura organizacional no processo de gestão de *data analytics*, enquanto os outros 40% disseram que essa categoria influencia de forma “3 – Considerável” a inovação.

Desenvolvendo uma análise probabilística das respostas, avalia-se que o impacto registrado por esse grupo quanto à influência da definição da estrutura organizacional para a gestão da inovação em *data analytics* é de aproximadamente 90%.

Gráfico 16 - Estruturas organizacionais que mais agregam valor a *data analytics* pelo grupo: clientes/consumidor/gestores/*team leader*.

Quais estruturas organizacionais propostas podem agregar mais valor as empresas que trabalham com *data analytics*:



Fonte: próprio autor, 2022.

De forma a compreender essa influência, os dados apresentados no gráfico 16 contribuem nesse entendimento. A informação coletada demonstra que 60% desse grupo acredita que a estrutura “Matricial” é a que mais agrega valor para se trabalhar com *analytics*.

Essa definição deve-se pelo fato dessa estrutura proporcionar um trabalho multidisciplinar dentro da organização, visto que, essa estrutura proporciona uma área específica para o time de dados, e as outras áreas são formadas pelos demais setores, o que é uma característica da própria inovação, tanto que a terceira questão dessa categoria aborda como deveriam ser estruturadas as equipes de *data analytics* (SBRAGIA, 1978).

De forma unânime, a escolha definida foi que a formação mais aderente é composta por Engenheiro de dados, Analista de dados, Analista de Negócios, sendo que estes atuem de forma paralela nos projetos, de forma que agregue valor às etapas da gestão da inovação.

Por ser uma inovação que pode ser trabalhada em qualquer área é fundamental esse relacionamento matricial, visto que os profissionais da área de dados não possuem conhecimento das regras de negócio de outros setores. Por conseguinte, é necessária essa interação de um analista de negócios da área de dados com os profissionais da área de negócios que solicitam os projetos.

E nessa forma estrutural, existe a necessidade de uma área própria de *data analytics*, em que a gestão dos dados e processos são feitos, e, após o desenvolvimento, são disponibilizados para a equipe de negócios, na forma *self-service* ou como um produto final (SBRAGIA, 1978).

A outra estrutura que também teve destaque, a *Large Scale Scrum*, é bem similar à estrutura organizacional “Matricial”, porém é fundamentada pela metodologia e estrutura de

projetos, em que existe a necessidade de pessoas específicas em cada projeto, como *Product Owner*, *Scrum Master* e etc.

Essa estrutura talvez faça mais sentido para contratações de serviço externo, quando se cria uma equipe de projetos para ser ponto focal das demandas da companhia, e somente essa área irá se relacionar com a equipe de terceiros, traduzindo as demandas e necessidades da companhia.

Ambas as estruturas possuem suas vantagens quanto à necessidade de aplicação, e, assim como foi respondido por esse grupo de clientes, as duas comportam as melhores características para potencializar a gestão da inovação de *data analytics*.

Os quadros 4 e 5 abaixo, apresentam um resumo sintético das questões respondidas por esse grupo.

Quadro 4 – Resultado das questões da gestão da inovação abordadas nos questionários do grupo A.

Aspecto Conceitual	Perguntas do questionário	Respostas do Grupo A
Gestão da inovação	1) Conhecem quais são as metodologias e/ou frameworks voltados para a área de dados?	Não conhecem as principais metodologias e/ou frameworks. Usam metodologias da organização ou a própria.
	2) As organizações utilizam as metodologias de gestão do conhecimento após uma implementação e/ou na rotina?	Não utilizam nenhuma metodologia.
	3) Quais são os recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz?	Infraestrutura; Ferramentas; Mão de obra qualificada; Cultura.
	4) Existe algum modelo ideal para trabalhar com dados?	Primeiro o analista de dados entende o problema de negócio, depois solicita as bases para o time de Engenharia e, a partir disso, desenvolve as regras de negócio.
	5) Pontos a serem melhorados em uma implementação ou até mesmo na rotina?	Gestão do tempo; Planejamento; Usuário.

Fonte: próprio autor, 2022.

Quadro 5 – Resultado das questões da gestão de pessoas abordadas nos questionários do grupo A.

Aspecto Conceitual	Categoria de análise	Perguntas do questionário	Respostas do Grupo A
Gestão de pessoas	Tipo de contratação de serviço	1) De 1 a 4, quanto o tipo de contratação do serviço (interno/externo) influencia a gestão das empresas quanto a <i>data analytics</i> ?	85% ~3,4
		2) Qual o tipo de contratação de serviço é o ideal para se trabalhar inicialmente com <i>data analytics</i> ?	Contratação interna
		3) Qual o tipo de contratação possui mais risco para a empresa?	Contratação Externa
	Cultura organizacional	1) De 1 a 4, quanto a cultura organizacional influencia a gestão das empresas quanto a <i>data analytics</i> ?	97,5% ~3,9
		2) De 1 a 4, qual a complexidade em alinhar os valores e princípios da organização com os dos profissionais da área de <i>data analytics</i> ?	75% ~3
		3) Como é a reação das pessoas com a mudança de <i>mindset</i> para o <i>data analytics</i> ? (1-Fácil adaptação, 2-Adaptação razoável, 3-Adaptação Considerável e 4-Difícil Adaptação)	78% ~3,1
		4) De 1 a 4, quanto é o interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de <i>data analytics</i> ?	75% ~3
	Recrutamento e Seleção	1) De 1 a 4, quanto o processo de recrutamento e seleção influencia a gestão das empresas quanto a <i>data analytics</i> ?	83% ~3,3
		2) Quais as <i>skills</i> necessárias para essa inovação?	Perfil Analítico Autogerenciamento Aprendizado Contínuo
	Estrutura organizacional	1) De 1 a 4, quanto a estrutura organizacional influencia a gestão das empresas quanto a <i>data analytics</i> ?	90% ~3,6
		2) Qual é o tipo de estrutura organizacional que agrega valor para a gestão dessa inovação?	Matricial
		3) Qual é a estrutura de equipe mais aderente para atuar com <i>data analytics</i> ?	Multidisciplinar - Engenheiro de dados, Analista de dados, Analista de Negócios

Fonte: próprio autor, 2022.

4.3 Especialista/desenvolvedores/analistas

Como apresentado no gráfico 1, para essa persona foram coletadas 18 respostas. Como contextualizado anteriormente, esse público são os profissionais que executam o desenvolvimento da transformação de dados em informação a partir das ferramentas nas suas rotinas.

Então, acredita-se que a percepção desse membro do *data analytics* tenha uma visão mais técnica e gerencial dos processos, uma vez que esses são os profissionais que utilizam as ferramentas nas suas rotinas de desenvolvimento.

Diante disso, nos próximos tópicos será contextualizada a visão desse grupo dentro das variáveis e categorias definidas para os aspectos conceituais deste estudo.

No aspecto conceitual da gestão da inovação, assim como definido no quadro 3, foram delineadas cinco categorias de análise no questionário. A primeira categoria foi abordada com algumas opções de resposta e com campo aberto; diante disso, foram coletados 32 registros de respostas, que sucederam em 6 grupos. É possível identificar esses grupos a partir da figura 11.

Figura 11 - Metodologias e/ou *frameworks* conhecidos pelo grupo: especialista/desenvolvedores/analistas.

Metodologias e/ou frameworks utilizados:

CRISP-DM
Própria
Organização
SEMMA
TDSP
KDD

Fonte: próprio autor, 2022.

Assim como se esperava, esse grupo possui mais conhecimento de metodologias *de data analytics* do que o grupo dos clientes. Cerca de 30% das respostas citaram a metodologia CRISP-DM, e aproximadamente 20% citaram os outros *frameworks* conhecidos do mercado, SEMMA, KDD, TDSP.

Os outros 50% foram divididos quanto ao uso da metodologia da organização ou a própria. Assim como comentado para o grupo dos clientes, há algumas adversidades quanto à usabilidade dessas duas metodologias, por possuírem características própria de uma pessoa ou organização.

A ação mais relevante a se tomar quanto a esse uso sem padrão seria primeiramente definir uma metodologia “ideal” para se trabalhar, estruturar a área de *analytics* na organização e difundir esse conhecimento primeiramente para a equipe do setor e, na sequência, levar o conhecimento para as áreas que solicitam as informações.

A segunda categoria foi trabalhada com algumas opções de resposta e com campo aberto, mas, quase com unanimidade, a opção mais escolhida foi que “NÃO” utilizam metodologias de gestão do conhecimento na organização.

Assim como analisado para o grupo dos clientes, esse grupo também não atua com nenhuma metodologia de gestão do conhecimento. A metodologia de documentação e/ou geração de portfólio é comumente apresentada na maioria dos cursos de dados. Então a questão a ser entendida é o motivo de equipes não atuarem com esse recurso, na medida em que ele agrega resultado para as organizações (DANTAS, *et al.*, 2008).

A terceira categoria foi trabalhada apenas com campo aberto, logo, emergiu uma grande quantidade de respostas, as quais foram analisadas e *clusterizadas*, - assim como definido na metodologia - de forma a resumir de forma mais coerente os contextos respondidos.

Diante disso, foram coletados cerca de 50 registros, que foram sintetizados para 12 palavras-chaves relacionadas. Esses grupos podem ser visualizados a partir da figura 12.

Figura 12 - Recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz definidos pelo grupo: especialista/desenvolvedores/analistas.

Recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz :



Fonte: próprio autor, 2022.

Assim como o grupo de clientes, os desenvolvedores também citaram que os principais recursos necessários são ferramentas, infraestrutura e mão de obra qualificada.

Por conseguinte, fica nítido que esses fatores são fundamentais para o sucesso dessa inovação dentro das organizações, a saber, o investimento para se trabalhar com as melhores ferramentas, com uma infraestrutura adequada para conseguir gerenciar todos os processo e, claro, profissionais que possuam *know-how* para conseguir trabalhar com os demais recursos citados.

No entanto, além desses fatores, faz sentido ressaltar alguns outros citados, como cultura, processos definidos, treinamentos e comunicação entre as áreas, com a respectiva quantidade de citações, 5, 4, 3 e 3, que representa aproximadamente 30% dos registros coletados.

Essas informações podem se tornar relevantes, quando se discute a influência da gestão de pessoas na gestão da inovação de *data analytics*, visto que todos esses fatores impactam a forma de uma organização se estruturar e se planejar para trabalhar com dados.

Não adianta uma organização ter ótimos recursos, se tiver uma cultura burocrática ou que não permita a autonomia e crescimento dos seus profissionais, denominada cultura “engessada”.

Além disso, a questão de processos definidos está diretamente relacionada com o tipo de metodologia e/ou *frameworks* utilizados para se gerenciar essa inovação na organização. Se não há processos definidos, a autonomia se torna uma “bagunça”, visto que cada grupo da área irá realizar atividades de forma solitária.

Outro fator quanto à forma de gerenciar as pessoas é o treinamento; esse grupo em específico precisa estar em constante evolução, buscando sempre novos cursos e treinamentos para se capacitar quanto a melhores ferramentas do mercado (KING, 2016; IVANCEVICH, 2011).

Diante disso, as organizações precisam avaliar a melhor maneira para se trabalhar, isto é, as organizações irão dar treinamentos para os seus profissionais, de forma a evoluir junto a seus funcionários, ou irão contratar empresas de consultorias ou profissionais com características mais sêniores para atuar nos desenvolvimentos (PHILLIP, 2011; CHOI, WALLACE, WANG, 2018).

A questão cultural pode afetar diretamente essa parte de definição de treinamentos. Se as organizações não quiserem promover treinamentos e proporcionar crescimento aos seus profissionais, talvez faça sentido buscar empresas de consultoria ou profissionais mais sêniores,

porém, é preciso estar consciente de que esses profissionais ou empresas irão ter um alto custo financeiro.

Mas, se as empresas quiserem ofertar treinamentos e cursos para os seus funcionários, podem avaliar a possibilidade de ter políticas organizacionais que contribuam na retenção desses talentos na organização (KING, 2016; IVANCEVICH, 2011).

Para concluir essa terceira categoria, a questão de comunicação entre as áreas é relevante quando se determina a estrutura organizacional a ser trabalhada com a área de *analytics*. É preciso delinear muito bem a estrutura, que se adeque à cultura da organização, para que a comunicação entre as áreas de negócio, de dados e TI possa ser a mais produtiva e ágil possível.

A quarta categoria é uma discussão objetiva acerca de como se gerenciar os profissionais para executarem as atividades dentro de um projeto. Essa etapa revela-se fundamental, porque todo o planejamento e gerenciamento da inovação será definido a partir do método a ser trabalhado. Podem-se observar os resultados coletados dessa categoria a partir da tabela 3.

Tabela 3 - Modelo de gestão da inovação para se trabalhar com dados pelo grupo: especialista/desenvolvedores/analistas.

Modelo para se trabalhar com dados	Frequência absoluta
Primeiro o analista de dados entende o problema de negócio, depois solicita as bases para o time de Engenharia e, a partir disso, desenvolve as regras de negócio.	16
Primeiro começa-se com a estruturação dos dados, para depois avaliar as regras de negócio e, assim, tomar as decisões.	1
Acredita-se que os primeiros passos são reuniões do time de dados como um todo para entender o negócio e o objetivo da solução. Depois, é importante entender de onde vêm os dados e quais as formas de obtê-los para, em seguida, entender qual a periodicidade de disponibilização, volumetria, etc para determinar a infraestrutura necessária. Por fim, define-se a arquitetura de disponibilização de relatórios contendo os dados, KPIs e métricas desejados.	1

Fonte: próprio autor, 2022.

Interessante esse levantamento quando comparado com as respostas do grupo de clientes. Verificou-se que não havia um modelo único para aquele grupo, já, para os desenvolvedores, o modelo “ideal” para se trabalhar com dados está diretamente relacionado com o entendimento do problema, para atuar depois com as demais atividades, levantamento de dados, estruturação dos dados etc.

Como visto anteriormente, esse grupo possui um maior conhecimento das metodologias do mercado, o que não se atestou com o grupo de clientes. Esse entendimento de como se trabalhar com dados é importante, porque, conforme já exposto, a falta dessa definição de processos impacta diretamente a forma de gerenciar a inovação.

Dessa maneira, a gestão de pessoas pode ser trabalhada de forma errônea, uma vez que a alocação de pessoas pode ser mal realizada pelos clientes do projeto (MONTEVECCHI, 2012; KDNUGETTS, 2014).

A quinta categoria foi trabalhada apenas com campos em aberto, portanto, houve uma grande quantidade de respostas, que foram analisadas e *clusterizadas*, - assim como apresentado na metodologia - de forma a resumir de forma mais coerente os contextos respondidos.

Diante disso, foram coletados cerca de 32 registros, que foram sintetizados para 12 palavras-chaves relacionadas. Esses grupos podem ser visualizados a partir da figura 13.

Figura 13 - Pontos a serem melhorados em uma implementação ou rotina pelo grupo: especialista/desenvolvedores/analistas.

Pontos a serem melhorados em uma implementação ou rotina:



Fonte: próprio autor, 2022.

Assim como o grupo de clientes, a questão de otimização de tempo foi a mais respondida, ficando evidente oportunidades em melhorias dentro desse processo de *data analytics*. Mas, além desse fator, destaca-se que esse grupo também ressaltou questões de processo e de relacionamento com os *stakeholders*.

Quanto a processos, foram citadas as questões de melhoria na forma de planejar as atividades, melhor qualidade com a estrutura de dados, padronização e, de forma geral, o fato de ser *mais data driven*. Esses processos são relevantes de se destacarem porque estão diretamente relacionados com a forma de gerenciar as pessoas e estruturas, e, de forma geral,

demonstram como a gestão de pessoas se torna relevante para essa inovação. Tais pontos, também são apresentados como relevantes por Gantz e Reinsel (2012) na literatura.

Quanto à questão de relacionamento com os *stakeholders*, ficam evidentes aspectos como a melhoria da experiência do usuário, na comunicação e gestão de pessoas. Estes são tópicos que demonstram como esse grupo pensa além da questão técnica do desenvolvimento, ou seja, a inovação de *data analytics* tem que ser visualizada mais do que dados estruturados, *dashboards*, painéis etc (FRICKE, 2009).


É um conjunto de técnicas e processos, para tornar os dados em informação. E não se faz isso somente com ferramentas é preciso envolver e relacionar pessoas, para que haja um processo adequado no gerenciamento dessa inovação (FRICKE, 2009).

Para esse aspecto conceitual de gestão de pessoas, assim como definido no quadro 3, foram delineadas quatro categorias de análise no questionário.

A primeira categoria abordada foi o tipo de contratação de serviço, interno ou terceiro, sendo estipuladas três questões para entender como essa categoria influencia o processo de gestão da inovação de *data analytics*.

Na primeira questão dessa categoria, foi usada a escala de Likert, para a coleta dos dados, enquanto as demais questões foram de múltipla escolha. As três questões podem ser analisadas a partir dos gráficos 17, 18 e 19.

Gráfico 17 - Percepção da influência do tipo de contratação de serviço em *data analytics* pelo grupo: especialista/desenvolvedores/analistas.



Fonte: próprio autor, 2022.

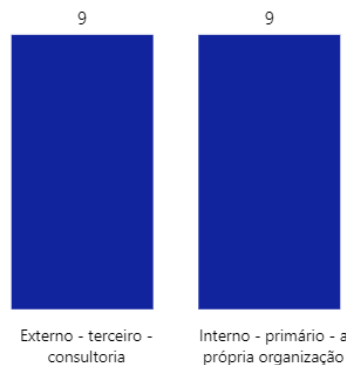
A partir do gráfico 17, pode-se avaliar que aproximadamente 56% desse grupo informaram que há “4 – Muito” impacto do tipo da contratação na forma de se gerenciar essa inovação, enquanto aproximadamente 40% disseram que o impacto é “3 – Considerável”, e, para o restante, é “2 – Razoável”.

Fazendo uma análise probabilística, avalia-se que o impacto registrado por esse grupo quanto à influência do tipo de contratação para a gestão da inovação em *data analytics* é de

88%. Na visão desse grupo, essa categoria tem 3 p.p. a mais de influência do que o grupo de clientes informou.

Gráfico 18 - Tipo de contratação “ideal” para se trabalhar inicialmente com *data analytics* pelo grupo: especialista/desenvolvedores/analistas

Qual o tipo de contratação de serviço é o “ideal” para trabalhar inicialmente com *data analytics*:



Fonte: próprio autor, 2022.

Entendendo melhor como essa categoria influencia a gestão da inovação, o gráfico 18 proporciona a visão acerca do modelo “ideal” para se trabalhar inicialmente com *data analytics*, e, para esse grupo, não existe uma diferença quanto ao tipo de contratação.

Logo, é possível observar que esse grupo se sente confortável para trabalhar de ambas as formas, tanto como interno ou externo, o que demonstra que esses profissionais acreditam que o conhecimento da inovação pode ser trabalhado desde o início pela empresa ou que a contratação de uma empresa terceira com maior *know-how* também pode proporcionar ganhos e aprendizados no desenvolvimento.

O que foi exposto também pode ser considerado como normal, visto que esses profissionais podem atuar em empresas de consultorias ou como MEI/ME, enquanto os clientes, na maior parte dos casos, atuam de forma interna, contudo, é interessante correlacionar essa informação com a obtida pelos clientes.

Na percepção do primeiro grupo, fica evidente o interesse dos mesmos em possuir uma equipe própria de desenvolvedores, para gerenciá-los. Já para o grupo em questão, não há distinção quanto a quem e quanto à forma de ser gerenciado.


Outro motivo desse equilíbrio nas respostas talvez seja o fato de profissionais dessa área estarem buscando oportunidades como MEI ou ME, para atuar em projetos

específicos ou de curto a médio prazo e, por isso, acreditam que não há distinção quanto ao modelo de contratação.

Além disso, profissionais que atuam com esses tipos de microempresas tendem a buscar um maior salário do que um profissional interno, uma vez que esses prestadores de serviço são contratados através de CNPJ, em vez de CLT, o que reduz taxas de imposto, tanto para as empresas quanto para os profissionais que recebem o salário.

Gráfico 19 - Tipo de contratação que possui mais risco para se trabalhar com *data analytics* pelo grupo: especialista/desenvolvedores/analistas

Qual o tipo de contratação possui mais "risco" para a empresa quanto a *data analytics*:



Fonte: próprio autor, 2022.

De forma a complementar a informação apresentada no tópico anterior, a partir do gráfico 19, é possível identificar o tipo de contratação que possui mais “risco” para as empresas. Indo contra a visão de equilíbrio do tópico anterior, esse grupo tende a acreditar que o tipo de contratação de terceiros possui um maior risco para a organização, sendo que quase 80% possuem essa percepção.

Como comentado, talvez esse percepção faça sentido quando uma empresa contratante de médio a grande porte faz uma contratação de uma MEI/ME, acreditando que aquela pequena empresa irá conseguir contribuir para a evolução da empresa contratante.

Difícilmente, microempresas irão conseguir estruturar uma metodologia de *analytics*, esse tipo de contratada tende a colaborar mais no desenvolvimento de projetos de micro/médio prazo, em que a entrega esteja relacionada com o a rotina.

Esse risco também pode estar associado com a questão da gestão do cliente e certeza de que o profissional está com foco total na empresa, visto que, quando a contratação é interna, tem-se a garantia de um contrato de trabalho e das horas trabalhadas pelo profissional.


Já em uma contratação externa, o profissional pode executar múltiplas atividades ou atuar em mais de um projeto, além de que talvez a gestão da rotina desse profissional não seja bem gerenciada pela empresa terceira, e, no caso de MEI/ME, pelo próprio responsável (FILIPPIM, GEMELLI, 2011).

Isso mostra que, mesmo a empresa assumindo todo o “risco” de recrutamento e seleção, gestão das pessoas, treinamento, rotatividade do mercado, ainda sim, há menos risco para as organizações do que buscar um serviço terceirizado, a partir da visão desse grupo (FILIPPIM, GEMELLI, 2011).

Analisando a segunda categoria desse aspecto conceitual, a cultura organizacional, foram estipuladas quatro questões para entender como essa categoria influencia o processo de gestão da inovação de *data analytics*.

Em todas as questões, foi utilizada a escala de Likert, para o levantamento dos dados. As quatro questões podem ser analisadas a partir dos gráficos 20, 21, 22 e 23.

Gráfico 20 - Percepção da influência da cultura organizacional em *data analytics* pelo grupo: especialista/desenvolvedores/analistas




Fonte: próprio autor, 2022.

A partir do gráfico 20, pode-se avaliar que, quase de forma unânime, aproximadamente 95% desse grupo informaram que o impacto da cultura organizacional é grande (“4 – Muito”), o que corresponde a 100% de influência dessa categoria quanto à forma de se gerenciar essa inovação.

Por meio de uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto à influência da cultura organizacional para a gestão da inovação em *data analytics* é de aproximadamente 99%. Na visão desse grupo, essa categoria tem aproximadamente 1,5 p.p. a mais de influência do que na visão do grupo de clientes.

Gráfico 21- Percepção da complexidade de alinhar valores e princípios da organização com os dos profissionais de *data analytics* pelo grupo: especialista/desenvolvedores/analistas




Fonte: próprio autor, 2022.

De forma a complementar o entendimento de como essa categoria influencia a gestão da inovação, a partir do gráfico 21, é possível identificar que cerca de 44% desse grupo informaram que existe 75% de complexidade em realizar o alinhamento de valores e princípios da organização com os dos profissionais da área, enquanto os outros 56% foram divididos igualmente, quanto a “4 – Muito” e “2 – Razoável” impacto nesse alinhamento.

Ao proceder uma análise probabilística das respostas, avalia-se que o impacto registrado por esse grupo quanto à complexidade desse alinhamento é de aproximadamente 75%. Frente a tal dado, é possível aferir que ambos os grupos possuem a mesma conclusão quanto a essa influencia.

Gráfico 22 - Percepção da reação das pessoas/organização com a mudança de *mindset* para *data analytics* pelo grupo: especialista/desenvolvedores/analistas



Fonte: próprio autor, 2022.

Quanto a essa questão, pode-se aferir, a partir do gráfico 22, que aproximadamente 67% desse grupo acreditam que a influência dessa mudança é “3 – Considerável” para as pessoas e para as organizações, enquanto, para o restante do grupo, essa mudança é de “4 – Difícil Adaptação”.


Por meio de uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto à reação das pessoas com essa mudança é de aproximadamente

83%. Logo, esse grupo acredita que tal questão tem aproximadamente 5 p.p. a mais de influência do que na visão do grupo de clientes.

Diante disso, observar-se uma oportunidade das organizações trabalharem com seus profissionais de forma a associar essa mudança de cultura de uma forma mais natural, principalmente para aqueles com maior tempo de experiência, visto que, para esses, a mudança pode ser mais complexa.

Demonstrando de forma crescente que a tomada de decisão a partir dos dados agrega valor para a organização, a mudança não pode ser integral/radical em curto/médio prazo, pois isso pode gerar desconforto aos profissionais que possuem dificuldade para trabalhar com dados.

Gráfico 23 - Percepção do interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de *data analytics* pelo grupo: especialista/desenvolvedores/analistas



Fonte: próprio autor, 2022.

Na última questão dessa categoria, é possível identificar pelo gráfico 23 que aproximadamente 56% acreditam que há “4 – Muito” interesse em migrar de área, 33% informaram que é “3 – Considerável” o interesse, e, para o restante, o interesse é “2 – Razoável”.


De forma geral, analisando probabilisticamente as respostas, estima-se que o impacto registrado por esse grupo quanto ao interesse das pessoas em migrarem de área para *data analytics* é de aproximadamente 86%. Na visão desse grupo, há um interesse de mais de 11 p.p. de migração da área dos profissionais, quando comparado com a visão do grupo de clientes.

Esse aumento possivelmente deve-se estar relacionado com o próprio histórico dos profissionais que responderam, por conhecerem outros profissionais em transição em algum curso de dados e/ou até mesmo por um possível contato de pessoas de outras áreas com esses profissionais de *data analytics*, por isso, essa percepção é maior do que o outro grupo.

A terceira categoria é o recrutamento e seleção. Para essa categoria, foram estipuladas duas questões para entender como ela influencia o processo de gestão da inovação de *data analytics*.

Na primeira questão, foi utilizada uma adaptação da metodologia de escala de Likert, e, na segunda questão, empregou-se um campo em aberto para o levantamento dos dados. As duas questões podem ser analisadas a partir dos gráficos 24 e a figura 14.

Gráfico 24 - Percepção da influência do processo de recrutamento e seleção na gestão de *data analytics* pelo grupo: especialista/desenvolvedores/analistas



Fonte: próprio autor, 2022.

Analisando o gráfico 24, pode-se avaliar que aproximadamente 67% desse grupo informaram que há “4 – Muito” impacto do processo de recrutamento e seleção quanto à forma de fazer a gestão dessa inovação. O restante, 33%, é distribuído nas demais opções.

Fazendo uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto à influência desse processo para a gestão da inovação em *data analytics* é de aproximadamente 85%, tendo um aumento de 2 p.p. quanto ao grupo de clientes.

Essa percepção deve estar atrelada a experiências desses profissionais quanto aos processos de recrutamento e seleção, e até mesmo à dimensão de treinamento e capacitação, para aumentar o conhecimento quanto a ferramentas e metodologias da área.

Figura 14 - Percepção das skills e habilidades específicas dos profissionais de *data analytics* pelo grupo: especialista/desenvolvedores/analistas.

Skills e habilidades específicas de profissionais da área de *data analytics*:



Fonte: próprio autor, 2022.

Quem melhor para saber essas necessidades de *skills* e habilidades que esse próprio grupo? Possivelmente as respostas geradas na figura 14 estão associadas ao que esses profissionais são demandados a obter na sua rotina, ou, até mesmo, estão relacionadas aos principais requisitos solicitados em vagas, e que, possivelmente desenvolvem ao longo do tempo a partir de cursos e treinamentos.

De tal forma, é possível aferir que esse grupo definiu, como principais qualidades fundamentais, “Lógica de Programação”, “Raciocínio Lógico” e “Perfil Analítico”, sendo o último também citado como qualidade fundamental pelo outro grupo.

Importante destacar que ambos os grupos citaram com certa relevância o “Perfil Analítico” como *skills/* habilidades para os profissionais dessa área, o que demonstra que a visão analítica é importante para criticar os dados de forma a torná-los em informação, uma vez que ter apenas dados sem o seu entendimento e importância no processo não gera valor ao negócio, assim como ressalta Michael e Vincent (2010).

Além disso, também importante sublinhar que o grupo de desenvolvedores possui uma visão mais técnica do processo, por isso, a identificação de *skills/* habilidades voltadas para um pensamento mais rápido/ágil e destinado à lógica de programação.

A partir disso, é preciso ver o quão difundida essa informação está para as pessoas que promovem os processos de recrutamento e seleção, visto que, se não existir uma comunicação desse grupo com a área de RH, todo o processo de *analytics* pode ser prejudicado com uma contratação ruim (FILIPPIM, GEMELLI, 2011).

Além de uma possível contratação não qualificada para a área, outros fatores são fundamentais para a área de RH. Assim como mencionado nos gráficos 8 e 9, existe a necessidade de promover treinamentos e desenvolvimento de lideranças para a inovação em estudo, e o setor de RH é fundamental nesse processo de gestão do “capital humano/intelectual” (KING, 2016; IVANCEVICH, 2011).

Com isso, essa área precisa conhecer além dessas habilidades “comuns” da área, é necessário conhecer de forma mais profunda as técnicas e métodos da área para contribuir no desenvolvimento de líderes, além de conseguir contribuir no desenvolvimento com treinamentos e cursos que agreguem valor para os profissionais e para a organização (KING, 2016; IVANCEVICH, 2011).

A quarta e última categoria abordada foi a estrutura organizacional. Para essa categoria, foram estipuladas três questões para entender como ela influencia o processo de gestão da inovação de *data analytics*.

Na primeira questão, foi utilizada a escala Likert, e, na segunda questão, utilizou-se um campo de múltipla escolha para o levantamento dos dados. As duas primeiras questões podem ser analisadas a partir dos gráficos 25 e 26.

Gráfico 25 - Percepção da influência da estrutura organizacional na gestão de *data analytics* pelo grupo: especialista/desenvolvedores/analistas



Fonte: próprio autor, 2022.

Analisando o gráfico 25, é possível aferir que cerca de 72% desse grupo informaram que há “4 – Muito” impacto da estrutura organizacional no processo de gestão de *data analytics*, enquanto os outros 22% disseram que essa categoria influencia de forma “3 – Considerável” a inovação.

Através de uma análise probabilística das respostas, pode-se avaliar que o impacto registrado por esse grupo quanto à influência da definição da estrutura organizacional para a gestão da inovação em *data analytics* é de aproximadamente 92%, sendo um aumento de 2 p.p. quando comparado com o outro grupo.

Gráfico 26 - Estruturas organizacionais que mais agregam valor ao *data analytics* pelo grupo: especialista/desenvolvedores/analistas



Fonte: próprio autor, 2022.

De forma análoga ao outro grupo, este também acredita que a estrutura “Matricial” é a hierarquia que mais agrega valor para se trabalhar com *analytics*, com cerca de 56% das respostas apresentadas no gráfico 26.

Ademais, ambos os grupos concordam com a questão de que a formação de uma equipe de dados deve ser a partir de uma estrutura multidisciplinar com pessoas atuando de forma paralela, para conseguirem entregar valor dentro de suas respectivas etapas.

Os quadros 6 e 7 abaixo, apresentam um resumo sintético das questões respondidas por esse grupo.

Quadro 6 – Resultado das questões da gestão da inovação abordadas nos questionários do grupo B.

Aspecto Conceitual	Perguntas do questionário	Grupo B
Gestão da inovação	1) Conhecem quais são as metodologias e/ou frameworks voltados para a área de dados?	Conhecem as principais metodologias e/ou frameworks.
	2) As organizações utilizam as metodologias de gestão do conhecimento após uma implementação e/ou na rotina?	Não utilizam nenhuma metodologia.
	3) Quais são os recursos necessários para uma organização trabalhar com dados de forma eficiente e eficaz?	Infraestrutura; Ferramentas; Mão de obra qualificada; Cultura.
	4) Existe algum modelo ideal para trabalhar com dados?	Primeiro o analista de dados entende o problema de negócio, depois solicita as bases para o time de Engenharia e, a partir disso, desenvolve as regras de negócio.
	5) Pontos a serem melhorados em uma implementação ou até mesmo na rotina?	Gestão do tempo; Planejamento; Usuário.

Fonte: próprio autor, 2022.

Quadro 7 – Resultado das questões da gestão de pessoas abordadas nos questionários do grupo B.

Aspecto Conceitual	Categoria de análise	Perguntas do questionário	Grupo B
Gestão de pessoas	Tipo de contratação de serviço	1) De 1 a 4, quanto o tipo de contratação do serviço (interno/externo) influencia a gestão das empresas quanto a <i>data analytics</i> ?	88% ~3,5
		2) Qual o tipo de contratação de serviço é o ideal para se trabalhar inicialmente com <i>data analytics</i> ?	Não houve unanimidade nas respostas
		3) Qual o tipo de contratação possui mais risco para a empresa?	Contratação Externa
	Cultura organizacional	1) De 1 a 4, quanto a cultura organizacional influencia a gestão das empresas quanto a <i>data analytics</i> ?	99% ~3,9
		2) De 1 a 4, qual a complexidade em alinhar os valores e princípios da organização com os dos profissionais da área de <i>data analytics</i> ?	75% ~3
		3) Como é a reação das pessoas com a mudança de <i>mindset</i> para o <i>data analytics</i> ? (1-Fácil adaptação, 2-Adaptação razoável, 3-Adaptação Considerável e 4-Difícil Adaptação)	83% ~3,3
		4) De 1 a 4, quanto é o interesse dos profissionais que não atuam com essa tecnologia em migrar para essa área de <i>data analytics</i> ?	86% ~3,4
	Recrutamento e Seleção	1) De 1 a 4, quanto o processo de recrutamento e seleção influencia a gestão das empresas quanto a <i>data analytics</i> ?	85% ~3,4
		2) Quais as <i>skills</i> necessárias para essa inovação?	Perfil Analítico Raciocínio Lógico Lógica Programação
	Estrutura organizacional	1) De 1 a 4, quanto a estrutura organizacional influencia a gestão das empresas quanto a <i>data analytics</i> ?	92% ~3,6
		2) Qual é o tipo de estrutura organizacional que agrega valor para a gestão dessa inovação?	Matricial
		3) Qual é a estrutura de equipe mais aderente para atuar com <i>data analytics</i> ?	Multidisciplinar - Engenheiro de dados, Analista de dados, Analista de Negócios

Fonte: próprio autor, 2022.

4.4 Relação dos aspectos conceituais e suas variáveis

Esta subseção tem, como finalidade, avaliar a relação entre os aspectos conceituais desenvolvidos nos quadros 1 e 2, com suas respectivas categorias, de forma a entender se as dimensões da gestão de pessoas influencia a gestão da inovação; além disso, apresenta a relação entre os conceitos e as visões da área acadêmica e do mercado empresarial quando esses temas são abordados de forma conjunta para *data analytics*.

4.4.1 Análise da influência da gestão de pessoas na gestão da inovação

A presente análise foi realizada partindo das variáveis categóricas descritas no quadro 4, sobre a gestão de pessoas. O foco desta análise é validar a proposta de se há influência da gestão de pessoas na gestão da inovação em *data analytics*.

Para isso, foi desenvolvida, na tabela 4, os principais pontos de como essas variáveis se relacionam, de forma a obter o melhor entendimento de como e quais os pontos que existem a influência entre esses aspectos conceituais.

Tabela 4 - Relação de como as variáveis dos aspectos conceituais se relacionam.

Gestão de pessoas	Gestão da inovação
Tipo de contratação	.Estruturação de equipe .Definição de processos .Mitigação de riscos em projetos
Cultura Organizacional	.Motivação e valorização dos profissionais .Promover uma metodologia de trabalho mais <i>data driven</i> .Padronização de documentos e processos
Recrutamento e seleção	.Promover contratações assertivas baseadas nas <i>skills</i> e habilidades específicas da área .Treinamento e capacitação .Mitigação de perda de "capital intelectual"
Estrutura Organizacional	.Estruturação de equipe .Comunicação entre áreas .Padronização de setores e áreas de trabalho

Fonte: próprio autor, 2022.

A partir da síntese realizada na tabela 4, é possível verificar a existência da influência e como ela ocorre para cada variável da gestão de pessoas quanto à gestão da inovação. Mediante isso, é preciso um aprofundamento em cada tópico, para o entendimento de como emerge essa influencia entre os aspectos conceituais.

4.4.1.1 Tipo de contratação

- Estruturação de Equipe

A influência dessa relação entre as variáveis está condicionada com o fato de que, dependendo do tipo de contratação do serviço, interno ou externo, a gestão da inovação é totalmente impactada, devido às diferentes formas de trabalhar com as pessoas, os processos e as estruturas das organizações. Diante disso, a formação de uma equipe para se trabalhar com *data analytics* está condicionada com o tipo de serviço que será contratado.

Se for uma contratação externa, faz-se necessário um profissional que seja o ponto focal para receber as demandas e fazer a solicitação para a empresa terceira. Possivelmente, um analista de dados agregue valor para a empresa contratante, pois o mesmo poderá facilitar a comunicação entre as áreas.

Porém, no caso de uma contratação interna, a empresa possivelmente terá uma estrutura e equipe exclusivas para a área de *analytics* atuar com as demais áreas da organização.

- Definição de processos

Assim como a estruturação de equipe, a definição de processos possui grande impacto quanto ao tipo de contratação, de tal forma que os processos ainda sofrem grande influência da própria estrutura de equipe definida, porque a forma e o método de gerenciar os processos tornam-se diferentes a partir dos recursos de mão de obra que se possui.

Se a contratação for externa, pode existir uma diferença entre a preferência de uso de metodologia/*framework* entre as empresas, contratante e contratada. Além disso, as diretrizes de gestão da rotina tendem a ser diferentes entre um tipo de serviço interno contra um serviço externo, devido às distintas formas pelas quais as demandas e cobranças são realizadas nos tipos de serviços.

- Mitigação de riscos em projetos

Por último, a mitigação do risco na gestão da inovação também é uma derivação do tipo de contratação. Assim como apresentado nos resultados, as pessoas demonstraram uma visão de que o serviço interno possui menos riscos do que uma contratação externa.

Esse fato tende a estar relacionado com a estrutura de equipe e definição de processos, visto que, se a gestão e orientação da rotina acontecem dentro da própria organização, os gestores possivelmente possuem mais capacidades para gerenciar os projetos e desenvolvimentos das equipes, o que tende a reduzir os riscos de atraso e/ou pausa nos projetos devido a variáveis relacionadas com pessoas externas.

4.4.1.2 Cultura Organizacional

- **Motivação e valorização dos profissionais**

A motivação e valorização dos profissionais foi um tópico de destaque dentro dos resultados. É possível considerar – a partir dos resultados coletados nos questionário respondidos - que os profissionais dessa área possuem salários consideravelmente altos para a média brasileira, por isso, as empresas precisam estar dispostas a pensar em outras alternativas de benefício de forma a reter e manter esses profissionais nas organizações (MATTOS, *et al.*, 2014; MIRANDA, 2022).

Se o salário for a única variável de definição de emprego, esses profissionais possivelmente irão ter uma troca constante de emprego, uma vez que foi identificado, através das respostas, que o mercado busca incessantemente profissionais dessa área, diante disso, sempre havendo uma proposta superior ao atual salário, será um motivo de roatividade (MIRANDA, 2022).

Além do que foi mencionado, outro ponto destacado nos resultados é a questão relacionada ao fato de profissionais que possuem o interesse de migrar de área para *data analytics*. As organizações precisam identificar tais profissionais e saber gerenciá-los, de forma a não desmotivá-los e poderem proporcionar oportunidades para aqueles que buscam essa oportunidade.

- **Promover uma metodologia de trabalho mais *data driven***

Outro fator ressaltado por Buganza e Trabucchi (2019), Sorescu (2017) e também nos resultados dos questionários foi de se trabalhar dentro da cultura da organização o *mindset* dos profissionais que atuam com dados, tanto de quem desenvolve quanto de quem utiliza os dados para a tomada de decisão.

As empresas precisam incentivar a metodologia de *data driven*, principalmente para as lideranças, porque são estes na maioria das vezes os responsáveis pelas ações (MICHAEL, VINCENT, 2010).

Então as organizações precisam mapear as pessoas que possuem dificuldade e/ou complexidade em trabalhar com dados, e ajudá-las a entender a importância de se trabalhar com essa informação. Outrossim, deve-se ensiná-los que há formas de realizar análises através de dados, para alcançar essa informação.

- Padronização de documentos e processos

Por último, a padronização de documentos e processos foi um fator destacado por Dantas, *et al.*, (2010), e também de relevância nos resultados dos questionários, como ponto para se analisar dentro da cultura empresarial. Essa questão é importante de ser analisada, pois é necessário que exista uma documentação dos projetos, com, obviamente, um padrão para os processos serem executados, de forma que todos possam conhecer e segui-los.

Esse tópico pode ser tornar muito complexo quando há muita burocratização nas etapas de trabalho. As empresas precisam saber gerenciar esses conflitos de forma a tornar, na medida do possível, os processos mais fluidos, sem que haja a perda e/ou exposição de dados e informação e tempo despendido com padrões que não gerem valor ao resultado final (DANTAS, *et al.*, 2010).

4.4.1.3 Recrutamento e seleção

- Promover contratações assertivas baseadas nas *skills* e habilidades específicas da área
Talvez esse seja o ponto mais importante após a definição do tipo de serviço para o sucesso da gestão da inovação, visto que, se as contratações não forem definidas de acordo com a real características da área, a gestão do “capital humano” pode estar comprometida desde o início (FILIPPIM, GEMELLI, 2011).

Por isso, é fundamental que os profissionais do RH conheçam muito bem as habilidades e *skills* necessárias para os profissionais dessa área, porque o custo para se contratar uma mão de obra qualificada em *analytics* é consideravelmente alta, então, não se podem cometer erros quanto à contratação, pois, do contrário, gastos desnecessários serão gerados (FILIPPIM, GEMELLI, 2011).

- Treinamento e capacitação

A questão de treinamento e capacitação também é fundamental para os profissionais dessa área. Sublinha-se que, nos últimos anos, muitas metodologias e ferramentas evoluíram, e a usabilidade dessas foram sendo alteradas por novas.

Mediante tal aspecto, as pessoas que trabalham com *analytics* precisam estar em constante evolução, buscando sempre novos cursos e capacitações, pontos esses, que King (2016) e Ivancevich (2011), destacam como relevantes no desenvolvimento dos profissionais.

A partir disso, as empresas precisam avaliar a possibilidade em investir nesses profissionais, talvez como uma forma de benefício além do salário, considerando que, se as empresas investirem nos seus funcionários, esses irão trazer novos conhecimentos e metodologias de trabalho, de forma a agregar com a evolução da área, o que tende a afetar diretamente a gestão dessa inovação.

- Mitigação de perda de “capital intelectual”

A mitigação de perda de “capital intelectual” constitui um aspecto fundamental a ser trabalhado nas organizações, tanto pelo setor de RH quanto da área de dados. Assim como exposto, o mercado em *analytics* está solicitando constantemente profissionais, o que tende a aumentar os indicadores de *turnover* nas organizações (FILIPPIM, GEMELLI, 2011).

Em vista disso, os fatores de uma contratação assertiva e oferta de cursos e treinamentos são categorias fundamentais para fazer com que esses indicadores de rotatividade não sejam expressivos.

Além disso, o fator cultural tende a contribuir muito para essa mitigação, visto que profissionais dessa área buscam empresas com valores e princípios mais flexíveis para trabalhar, assim como apresentado no gráfico 15 e por Miranda (2022).

Com isso, uma boa gestão do “capital intelectual” pode reduzir o retrabalho da área de RH e proporcionar à área de *analytics* uma maior longevidade, tendo profissionais com melhores formações de competências e qualificações, o que tende a melhorar a gestão dessa inovação, visto que não haverá uma constante troca de pessoas na área, pontos esses que Volberda e Van (2013) e Kipping e Engwall (2002) destacam como fundamentais para o processo da gestão da inovação.

4.4.1.4 Estrutura Organizacional

- Estruturação de Equipe

A formação de equipe também está diretamente relacionada com a estrutura organizacional proposta para a empresa. Dependendo da escolha a ser utilizada pela organização, as equipes podem ser formadas com profissionais atuando em pontos específicos, de forma paralela ou até mesmo de forma independente.

Isso tende a ter influência quanto à forma de gerenciar essa inovação, pois a estrutura da equipe pode afetar a forma de comunicação da área de negócio com a de *analytics* e os processos e etapas dessa inovação podem ser centralizados ou não para uma equipe específica dependendo dessa formação.

Assim como apresentado por Monteverchi (2012) e Kdnugetts (2014), e nos resultados coletados é fundamental conhecer as metodologias e *frameworks* da inovação, para as empresas conseguirem estruturar suas equipes e hierarquias de forma que proporcionem e agreguem mais valor para a área de *analytics*, além de proporcionar uma maior fluidez na gestão de atividades e otimização de tempo.

- Comunicação entre áreas

A comunicação entre as áreas foi outro ponto de relevância obtido nos resultados, em que foi sinalizada a importância de proporcionar uma estrutura organizacional flexível para que haja essas comunicações com maior agilidade e assertividade possíveis, importante ressaltar que, a partir dos resultados, foi possível avaliar que a estrutura matricial proporcionar esse melhor contato entre áreas.

É crucial destacar que o trabalho de um profissional de dados é proporcionar informações com maior qualidade para as pessoas das organizações; por isso, é fundamental que exista uma comunicação fluída e saudável entre a área de *analytics* e as áreas de negócio.

De forma que haja o entendimento da necessidade para a entrega acontecer com qualidade e assertividade, ainda mais em um contexto em que a experiência do usuário é essencial, visto que, esse fator tende a proporcionar uma maior adoção das pessoas a cultura *data driven*, assim como destacado por Michael e Vincent (2010) e Sorescu (2017).

Senão houver essa comunicação saudável entre as áreas, possivelmente a gestão da inovação dos projetos será prejudicada, pois todo o entendimento de como fazer os dados se tornarem informação poderá ser comprometido.

- Padronização

Outro fator relevante do tipo de estrutura organizacional a ser trabalhado nas organizações é quanto ao fator de padronização. Uma empresa que não possui uma

centralização de dados para uma equipe de *analytics* possivelmente terá falta de padrão quanto a *layout*, nomeclaturas de banco de dados, metodologias de gestão da inovação, gestão do conhecimento e até mesmo regras de negócio.

Isso se torna prejudicial para a organização, já que falta de padrão pode proporcionar visões incomparáveis entre os mesmos dados e cada área aplica a sua própria regra de negócio para gerar a informação.

Além disso, esse fator de despadrão torna o processo complexo para uma futura normatização e união dos dados da companhia, pois cada área possivelmente terá identificado os dados de uma forma distinta.

A partir disso, destaca-se que, após a definição do tipo de estrutura organizacional, seja criado um padrão para as áreas trabalharem com os dados, mesmo que não haja uma área específica de *analytics*, para que, quando for necessário unificar todos os dados em uma mesma estrutura, esse processo seja mais ágil e assertivo.

4.4.2 Relação da visão conceitual da área acadêmica com a do mercado

Para finalizar os resultados e a análise dos dados, esta subseção tem, como finalidade, avaliar a relação entre os aspectos conceituais desenvolvidos nos resultados referentes os quadros 1 e 2, com suas respectivas categorias, visando comparar e correlacionar como as dimensões da gestão de pessoas e a gestão da inovação são contextualizadas e trabalhadas a partir de conceitos e visões da área acadêmica e do mercado empresarial para *data analytics*.

Tabela 5 - Visão conceitual da área acadêmica e do mercado em relação aos aspectos conceituais

Visão conceitual	Gestão de pessoas	Gestão da inovação
Acadêmica	.Liderança .Estrutura organizacional .Mão de obra qualificada - "capital intelectual"	.Uso de IoT na rotina .Gestão do conhecimento .Como melhorar a tomada de decisão
Mercado	.Mão de obra qualificada - "capital intelectual" .Treinamentos .Estrutura organizacional .Cultura organizacional	.Otimização de tempo (ágil) .Definição de processos e planejamento .Comunicação entre áreas .Gestão dos dados .Atuar de forma <i>data driven</i>

Fonte: próprio autor, 2022.

O que se pode aferir, a partir dessas informações apresentadas na tabela 5, – delineada a partir dos resultados identificado nos questionários e as literaturas apresentadas no APÊNDICE C - é que, quanto à gestão de pessoas, tanto a visão do mercado como a área acadêmica possuem pontos semelhantes, ou seja, ambos buscam contextualizar a importância da mão de obra qualificada e a questão da estrutura organizacional, como fatores de influência da gestão de pessoas na gestão da inovação.

Além disso, a visão acadêmica tende a focar também na relevância de uma boa liderança para o sucesso em trabalhar com dados, enquanto a visão do mercado foca nas questões da cultura organizacional e treinamentos, como fatores impactantes para a área de *analytics*.

Quando se compara a visão desses dois ecossistema ao tema de gestão da inovação, apenas um ponto de semelhança foi identificado, a saber, a questão de atuar mais de forma *data driven* para melhorar a tomada de decisão nas organizações. Ambos os ambientes acreditam que existe uma maior necessidade de atenção das empresas para usarem cada vez mais essa metodologia de forma a obter melhores informações e, assim, conseguir alcançar as melhores tomadas de decisões.

Frente a isso, a área acadêmica acredita que, além do que foi apresentado, outros fatores relevantes são o contexto de gestão do conhecimento para as organizações e o maior uso de IoT (Internet das Coisas) na rotina dos times, sendo que ambos podem ser usados de forma a proporcionarem um maior conhecimento dos dados para as equipes.

Já o mercado demonstrou uma percepção maior quanto aos seguintes fatores, otimização do tempo (ágil) com a gestão da inovação, melhores definições de processos e planejamentos (assertivo), comunicação entre as áreas e gestão e estruturação dos dados na organização.

Mesmo com visões distintas, ambos os ambientes apresentam foco na melhoria da rotina a partir de uma boa gestão dessa inovação, demonstrando que ainda existem *gaps* e oportunidades que podem ser estudados e trabalhados quanto à gestão da inovação dessa pesquisa, além do fato de validar a hipótese de que há a influência da gestão de pessoas na gestão da inovação de *data analytics*.

5. CONSIDERAÇÕES FINAIS

Logo, pode-se concluir que o objetivo central deste estudo foi alcançado, uma vez que foi possível identificar e comprovar a existência da influência da gestão de pessoas na gestão da inovação de *data analytics*.

Para estudos futuros, sugere-se escolher um desses aspectos conceituais propostos na pesquisa e avaliar como esse fator influencia a inovação em estudo.

A partir de um estudo de caso em uma organização, possivelmente, o fator mais relevante para complemento dessa pesquisa seja a cultura organizacional - analisando o impacto dessa quanto a definição do tipo de serviço, a escolha da formação da estrutura empresarial, método de gestão e capacitação de “capital humano”, definição de benefícios secundários - uma vez que esse fator se relaciona com todos os demais fatores.

A fim de validar essa hipótese de futuro estudo, a questão da cultura organizacional foi o aspecto conceitual mais ressaltado dentro dos resultados, por isso essa sugestão. Interessante analisar essa variável, visto que é uma categoria que, assim como a inovação, ambas tendem a evoluir durante o tempo, e essa percepção identificada nos resultados com a cultura pode ser um ponto de atenção dos profissionais do mercado com o que as empresas estão proporcionando atualmente.

Em complemento a essa análise cultural, é relevante pensar em novas formas/métodos de se trabalhar com as pessoas que tomam as decisões e que possuem objeções em usar os dados e as informações para as tomadas de decisão, todo o processo de desenvolvimento poderá não gerar valor, e essas pessoas ainda podem gerar empecilhos e atrasar a evolução da área.

Diante disso, o uso de metodologias de troca de conhecimento e aprendizado, possam ser um caminho para o aprimoramento do conhecimento e quebra do paradigma da mudança cultural. O apoio da organização é fundamental, uma vez que, os funcionários com maiores dificuldades culturais, tendem a se sentir apoiados pela organização.

Outro fator que pode contribuir para essa gestão cultural é o fomento de treinamentos entre as áreas de negócio com a área de *analytics*, visando criar um melhor vínculo e relacionamento entre os setores e promover o conhecimento *data driven* para as áreas que precisam tomar as decisões de negócio a partir dos dados.

Se o conhecimento não estiver claro para toda a organização, possivelmente haverá inseguranças para aquelas pessoas com maiores dificuldades, por isso, há importância de promover treinamentos e uso de metodologias de gestão e impulsão do conhecimento.

Evidencia-se também mais um fator relevante para futuros estudos, que é o aspecto conceitual da estrutura organizacional, esse contexto da hierarquia das empresas é algo muito relevante para o sucesso das empresas com *data analytics*, pois todo o embasamento de custos, investimentos, recursos, infraestrutura e pessoas está diretamente relacionado.

O uso de uma estrutura bem definida, proporciona um direcionamento e segmentação do que a empresa aumeja em trabalhar com dados, e isso, tende a reduzir incertezas e possíveis retrabalhos.

Dessa maneira, os funcionários irão buscar conhecimentos que tendem a agregar valor para a direção a qual a organização deseja alcançar, o que de forma indireta potencializa o conhecimento e a inovação dentro da organização.

Sendo assim, esse aspecto pode potencializar o uso de *analytics*, mas ao mesmo tempo, se não for bem estruturado, pode gerar retrabalho para os funcionários da organização, proporcionando até mesmo insatisfação quanto a mudanças de ferramentas e metodologias.

Mediante a isso, pode-se delinear um estudo analisando formas/métodos de se trabalhar com a estrutura matricial nas organizações voltado para *data analytics*, propõem-se esta hierarquia, devido os resultados encontrados, onde deve-se avaliar a formação de uma equipe/área de *analytics*, com profissionais multidisciplinares, que atuam de forma paralela nos projetos, agregando o máximo de valor a etapas e processos.

Logo, para promover uma redução da rotatividade nesse tipo de contratação, faz-se necessário que as empresas promovam outros benefícios (treinamentos, capacitação) que cultivem a retenção dos profissionais, além de promoverem uma cultura organizacional flexível e harmônica, para que esses profissionais se sintam confortáveis pelo modelo de trabalho da organização, fazendo com que a remuneração salarial não seja ponto central de definição de trabalho.

De forma geral, a maior parte dos tópicos identificados na matriz cruzada de gestão de pessoas e gestão da inovação estão relacionados ao ser humano, isto é, o profissional da área, o que demonstra que, se não existir uma mão de obra qualificada, não há êxito no desenvolvimento da gestão da inovação, sendo essa uma abordagem apresentada também na literatura.

Com esse estudo, reforça-se ainda mais esse conceito e importância para o sucesso da gestão da inovação, principalmente para a área de *data analytics*, em que, mesmo com vários fatores e categorias de análise da gestão de pessoas, o foco central que influencia a gestão da inovação são os profissionais da área.

Por isso, é fundamental que as organizações visualizem que esses funcionários são uma forma de “capital intelectual” e são chaves para o sucesso dessa inovação nas organizações.

Identifica-se que esses pontos que foram apresentados são os focos centrais para um futuro estudo, mas, além desses fatores, pode-se avaliar a necessidade de aprendizado e entendimento da área de negócios com as metodologias de dados, para que, haja uma comunicação fluida e harmônica entre ambos os grupos de trabalho.

Os métodos apresentados nesse projeto (CRISP-DM, SEMMA, KDD) já são metodologias testadas e validadas, então, ressalta-se a importância de um conhecimento das mesmas, para definir um processo de trabalho.

Mesmo que não se trabalhe com cada etapa de um desses *frameworks*, é importante ter o conhecimento, para se desenhar uma metodologia concisa de trabalho entre a área de dados e negócio.

Outro fator que também precisa ser destacado é a questão de padronização e documentação de projetos. Como apresentado nos resultados, esse é um recurso importante para a gestão do conhecimento na organização, por isso, trabalhar com a padronização de portfólio/projetos e/ou *sharing knowledge* sejam alternativas que podem agregar valor e conhecimento para as organizações.

Mediante o exposto, esses fatores estão correlacionados diretamente com a cultura organizacional e a estrutura corporativa, por isso, não existe uma padrão para todas as organizações; porém são necessários documentos objetivos, que promovam o conhecimento, e não o desperdício de tempo.

A partir disso, podem-se observar, nas tabelas 6 e 7, dois exemplos de padrões para documentação, que, possivelmente, podem ser aplicados juntos, podem ser reestruturados, mas que possuem campos fundamentais para uma visão macro e objetiva dos projetos.

Tabela 6 – Exemplo 1 de padrão de documentação.

Projeto	Descrição	KPIs Envolvidos	Responsável	Data de Início	Data do Fim	Solução Desenvolvida	Link de Acesso

Fonte: próprio autor, 2022.

Campos da tabela 6:

- Projeto: nome do projeto definido;
- Descrição: qual o objetivo desse projeto, o que ele representa, quem são os *stakeholders* envolvidos ;
- KPIS Envolvidos: quais são as regras de negócio, indicadores a serem calculados, como esses indicadores são calculados ;
- Responsável: quem é o ponto focal do projeto, para possíveis dúvidas, tanto de negócio quanto de dados ;
- Data de Início: data de início do projeto ;
- Data do Fim: data de término do projeto ;
- Solução Desenvolvida: o que foi desenvolvido, um *dashboard*, um painel, uma tabela, uma consulta, um banco de dados, um ETL/ELT; quais foram/são as principais dificuldades e/ou complexidades do projeto ;
- Link de Acesso: onde é possível encontrar essa entrega, se for um banco de dados, quais são os acessos de usuário e senha, ou o local da rede/*web*/site em que esse projeto foi homologado/entregue.

Tabela 7 – Exemplo 2 de padrão de documentação.

NOME DA FONTE DE DADOS	NOME DO ATRIBUTO	TIPO DO ATRIBUTO	CONCEITO	REGRA DE NEGÓCIO

Fonte: próprio autor, 2022.

Campos da tabela 7:

- Nome da fonte de dados: qual o nome da origem da base de dados, qual o banco de dados, qual a consulta/script ;
- Nome do atributo: o que esse atributo representa, qual a sua relevância para o projeto;
- Tipo do atributo: int, string, qual a importância do seu formato ;
- Conceito: o que esse indicador representa ao negócio ;
- Regra de negócio: quais as fórmulas e/ou cálculos que utilizam essa base.

Tais fatores contextualizados, se trabalhados juntamente de forma correta, tendem a potencializar a inovação, proporcionando as organizações e lideranças uma melhor gestão da inovação para *data analytics*.

A partir dos resultados obtidos com este estudo, acredita-se que algumas questões e pontos merecem novas análises, pois, nesta pesquisa, não foi possível executar um estudo de caso, e talvez esse seja um dos pontos de mais enriquecimento para futuros estudos. Seguem alguns desses pontos:

- Definir uma categoria do aspecto conceitual de gestão de pessoas, preferencialmente cultura organizacional e avaliar como essa variável influencia no processo de gestão da inovação em um estudo de caso, partindo das informações proporcionadas por este estudo, sobre os campos da cultura organizacional;
- Realizar um estudo de caso em uma empresa que esteja começando a trabalhar com a inovação, para analisar quais são as variáveis iniciais que influenciam o processo de *data analytics* em empresas com menor *know-how* da inovação e de forma análoga comparar com as variáveis apresentadas nesse estudo;
- Analisar se existe alguma outra variável da gestão de pessoas que não foi analisada neste estudo que se relaciona com a gestão da inovação, e se houver, avaliar como ocorre essa influência;
- A partir de um estudo de caso, ajudar uma organização a implementar o modelo de estrutura matricial proposta nesse estudo e avaliar como essa variável afeta as definições de processos metodológicos, documentação de dados e comunicação entre as áreas;
- Fazer um estudo próprio com profissionais da área de Recursos Humanos que trabalham em empresas de *data analytics* e avaliar, com esses profissionais, como são os comportamentos, valores, princípios, benefícios para os funcionários da área de *analytics*, além de avaliar quais são os desafios de contratação de novos profissionais, de retenção de talentos e validação das *skills* e habilidades apresentadas nesse projeto.
- Esse estudo apresentado, proporciona novos caminhos para o entendimento do uso de *data analytics* para diversos setores da organização, mas acredito que a aplicação dessa inovação para o setor de RH seja interessante, uma vez que, esse setor tem como princípios e valores a gestão de pessoas, então seria interessante avaliar e comparar como aconteceria a evolução dessa inovação nessa área.

REFERÊNCIAS BIBLIOGRÁFICAS

ANGELICA, T, S, C.; AJAX, D, K, R. **O gerenciamento da alteração de escopo na contratação externa de serviços de desenvolvimento/manutenção de software**, In: ASSE 2012 - Simposio Argentino de Ingeniería de Software, 13. 2012, La Plata, **Anais eletrônicos** [...]. La Plata: ASSE, 2012. p. 75-90.

ARDITO, L.; SCUOTTO, V.; *et al.* A bibliometric analysis of research on Big Data analytics for business and management. **Management Decision**, Emerald Publishing Limited, v. 57, n. 8, p. 1993-2009, 2019. DOI: <https://doi.org/10.1108/MD-07-2018-0754>. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/MD-07-2018-0754/full/html>. Acesso em: 29/12/2020.

ARDITO, L.; PETRUZZELLI, A, M. Mapping innovation dynamics in the Internet of Things domain: evidence from patent analysis, **Technological Forecasting and Social Change**, Elsevier, v. 136, p. 317-330, 2018. DOI: <https://doi.org/10.1016/j.techfore.2017.04.022>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0040162517305498>. Acesso em: 29/12/2020.

AUDRETSCH, D, B. New-Firm Survival and the Technological Regime. **The Review of Economics and Statistics**, MIT PRESS, v. 73, n. 3, p. 441–50, ago. 1991.

AZEVEDO, D.; SOUZA, T, A.; VACCARO, G, L. R. Redesenho de Processos de RH com Aplicação da Metodologia Lean Seis Sigma: Um Estudo em uma Cooperativa Agroindustrial. **La Administración y los Estudios Organizacionlaes en el Contexto Lationamericano**, Porto Alegre, ago. 2014. Disponível em: https://www.academia.edu/26287425/Redesenho_de_Processos_de_RH_com_Aplica%C3%A7%C3%A3o_da_Metodologia_Lean_Seis_Sigma_Um_Estudo_em_uma_Cooperativa_Agroindustrial. Acesso em: 08/01/2021.

BABBIE, E. Métodos de Pesquisa de Survey. **Editora UFMG**, Belo Horizonte, n. 3, p. 179-212, 2003.

BENBASAT, I.; GOLDSTEIN, K.; MEAD, M. The Case Research Strategy in Studies of Information Systems. **Management Information Systems Research Center**, Minnesota, v. 11, n. 3, p. 369-386, set. 1987. DOI: <https://doi.org/10.2307/248684>. Disponível em: <https://www.jstor.org/stable/248684>. Acesso em: 08/12/2021.

BIRKINSHAW, J.; MOL, M. 2006. How Management Innovation Happens. **Management Review**, MIT Sloan, v. 47, n. 4, p. 81-88, 2006.

BOENTE, A. N. P.; OLIVEIRA, F. S. G.; ROSA, J. L. A. **Utilização de Ferramentas de KDD para Integração de Aprendizagem e Tecnologia em Busca da Gestão Estratégica do Conhecimento na Empresa**, Anais do Simpósio de Excelência em Gestão e Tecnologia, v. 1, p. 123-132, 2007.

BRITO, M, P, V. **As gerações boomer, baby boomer, x, y e z**. 2013. Disponível em: <http://advivo.com.br/blog/marco-paulo-valeriano-de-brito/as-geracoes-boomer-baby-boomer-x-y-z>. Acesso em: 08/12/2021.

BUGANZA, T.; TRABUCCHI, D. 2019. Data-driven innovation: switching the perspective on Big Data. **European Journal of Innovation Management**, Emerald Publishing Limited, v. 22, n.1, p. 23-40, 2019. DOI: <https://doi.org/10.1108/EJIM-01-2018-0017>. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/EJIM-01-2018-0017/full/html>. Acesso em: 08/12/2021.

CHAMPMAN, P.; CLINTON, J.; KERBER, R. **CRISP-DM 1.0 Step-by-step data mining guide**, CRISP-DM consortium: NCR Systems Engineering Copenhagen (USA and Denmark) DaimlerChrysler AG (Germany), SPSS Inc.\ (USA) and OHRA Verzekeringen en Bank Groep B.V (The Netherlands), 2010. Disponível em: <https://docplayer.net/202628-Crisp-dm-1-0-step-by-step-data-mining-guide.html>. Acesso em: 08/01/2022.

CHANDLER, A, D. Strategy and structure. **Chapters in the History of the Industrial Enterprise (Garden City NY 1966)**, 1962.

CHEN, H.; CHIANG, C. Business intelligence and analytics: From big data to big impact. **Management Information Systems Research Center**, Minnesota, v. 36, n.4, p. 1165-1188, dez. 2012. DOI: <https://doi.org/10.2307/41703503>. Disponível em: <https://www.jstor.org/stable/41703503>. Acesso em: 22/02/2021.

CHOI, T.; CHAN, H.; YUE, X. 2016. **Recent Development in Big Data Analytics for Business Operations and Risk Management**. IEEE Transactions on Cybernetics, v. 47, n. 1, p. 81-92, jan. 2017. DOI: <https://doi.org/10.1109/TCYB.2015.2507599>. Disponível em: <https://ieeeprojects.eminent.in/uploads/basepaper/ETSBD008-2016.pdf>. Acesso em: 22/02/2021.

CHOI, T.; WALLACE, S.; WANG, Y. Big Data Analytics in Operations Management. **Production and Operations Management**, Wiley Online Library, v. 27, n. 10, p. 1868-1883, dez. 2017. DOI: <https://doi.org/10.1111/poms.12838>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/poms.12838>. Acesso em: 22/02/2021.

CNI. **Investimentos em Indústria 4.0**. 2018. Disponível em: <http://www.portaldaindustria.com.br/estatisticas/pqt-investimentos-em-industria-40/>. Acesso em: 15/11/2021.

COUTO, F. **Turnover e TI: como analisar e criar estratégias para evitá-lo**. IT FORUM. 2020. Disponível em: <https://itforum.com.br/colunas/investimento-de-estrutura-de-ti-para-empresas-de-logistica/>. Acesso em: 10/02/2022.

DANTAS, E.; *et al.* **O Uso da Descoberta de Conhecimento em Base de Dados para Apoiar a Tomada de Decisões**. SEGET. 2008. Disponível em: https://www.aedb.br/seget/arquivos/artigos08/331_331_Artigo_SEGET_EJDR_Versao_Final_010808.pdf. Acesso em: 10/02/2022.

DUTRA, Ademar. Gestão de pessoas na área pública. **Apostila curso de Especialização em Administração Pública**, Atlas S. A, São Paulo, p. 27. 2009.

EISHENARDT, K.; GRAEBNER, M. Theory Building form Cases: Opportunities and Challanges. **The Academy of Management Journal**, Academy of Management, v. 50, n. 1, p.

25-32, fev. 2007. DOI: <https://doi.org/10.5465/amj.2007.24160888>. Disponível em: <https://www.jstor.org/stable/20159839>. Acesso em: 10/02/2022.

FADUL, C. **Big Data**: aumento de produtividade com uso de dados confiáveis na indústria 4.0. *A voz da indústria*. 2021. Disponível em: <https://avozdaindustria.com.br/colunistas/big-data-aumento-de-produtividade-com-uso-de-dados-confiaveis-na-industria-40>. Acesso em: 10/02/2022.

FAYYAD, U.; *et al.* **Advances in Knowledge Discovery and Data Mining**, AAAI/MIT Press, Cambridge, Mass., 1996.

FILIPPIM, E.; GEMELLI, I. Gestão de pessoas na administração pública: o desafio dos municípios. **RACE: Revista de Administração, Contabilidade e Economia**, Editora Unoesc, v. 9, n. 1-2, p. 153-180, jan. 2011. Disponível em: https://www.rhbusiness.net.br/material_estudo/gp_adm_publica_o_desafio_dos_municipios.pdf. Acesso em: 10/02/2022.

FRICKE, M. The knowledge pyramid: A critique of the DIKW hierarchy. **Journal of Information Science**, v. 35, n. 2, p. 131-142, abr. 2009. DOI: <https://doi.org/10.1177/0165551508094050>. Disponível em: <https://journals.sagepub.com/doi/abs/10.1177/0165551508094050>. Acesso em: 10/02/2022.

GANTZ, J.; REINSEL, D. The Digital Universe in 2020: Big Data, Bigger Digital Shadows, and Biggest Growth in the Far East. **IDC's Digital Universe Study Executive Summery**, EMC, dez. 2012. Disponível em: <https://www.cs.princeton.edu/courses/archive/spring13/cos598C/idc-the-digital-universe-in-2020.pdf>. Acesso em: 08/01/2022.

HIDALGO, A.; ALBORS, J. Innovation management techniques and tools: A review from theory and practice. **R&D Management**, Wiley Online Library, v. 38, n. 2, p. 113-127, fev. 2008. DOI: <https://doi.org/10.1111/j.1467-9310.2008.00503.x>. Disponível em: <https://onlinelibrary.wiley.com/action/showCitFormats?doi=10.1111%2Fj.1467-9310.2008.00503.x>. Acesso em: 08/01/2022.

HU, H.; WEN, T.; CHUA, X. **Toward scalable systems for big data analytics: A technology tutorial**. *IEEE Transactions on Cybernetics*, v. 2, p. 652-687, 2014. DOI: <https://doi.org/10.1109/ACCESS.2014.2332453>. Disponível em: <https://ieeexplore.ieee.org/document/6842585>. Acesso em: 22/02/2021.

IBGE. **Renda média do brasileiro recua 9% em um ano, afirma IBGE**. 2022. Disponível em: <https://economia.ig.com.br/2022-04-30/renda-media-brasileiro-recu-em-um-ano.html>. Acesso em: 08/01/2022.

IVANCEVICH, J. M. Gestão de recursos humanos. **AMGH editora LTDA**, São Paulo, 10º ed, 2011.

KAYSER, V.; NEJRKE, B. Data Science as an Innovation Challenge: From Big Data to Value Proposition. **Technology Innovation Management Review**, CC BU 4.0, v. 8, n. 3, p. 16-25, mar. 2018. DOI: <https://doi.org/10.22215/timreview/1143>. Disponível em: <https://timreview.ca/article/1143>. Acesso em: 10/02/2021.

KDNUGETTS. **What main methodology are you using for your analytics, data mining, or data science projects?** Out. 2014. Disponível em: <https://www.kdnuggets.com/polls/2014/analytics-data-mining-data-science-methodology>. Acesso em: 15/12/2021.

KING, G. K. Data analytcs in human resources: a case study and critical review. **Human Resource Development Review**, SAGE, v. 15, n. 4, p. 487-495, nov. 2016. DOI: <https://doi.org/10.1177/1534484316675818>. Disponível em: <https://journals.sagepub.com/doi/abs/10.1177/1534484316675818>. Acesso em: 02/01/2021.

KIPPING, M.; ENGWALL, L. Management Consulting. **Oxford University Press**, Oxford, ago. 2002.

LARIEIRA, C.; ALBERTIN, L. Fatores Organizacionais em Gestão de Portfólio de Projetos: Uma Proposta de Estrutura Conceitual à Luz da Literatura. **Revista de Gestão e Projetos**, GEP, v. 4, n. 2, p. 1-26, 2013. DOI: <https://doi.org/10.5585/gep.v4i2.97>. Disponível em: https://pesquisa-eaesp.fgv.br/sites/gvpesquisa.fgv.br/files/arquivos/albertin_-_fatores_organizacionais_em_gestao_de_portfolio_de_projetos_uma_proposta_de_estrutura_conceitual_a_luz_da_literatura.pdf. Acesso: 15/11/2021.

MATTOS, A.; *et al.* Proposta de reestruturação de uma organização: Mudança no processo de departamento pessoal para as práticas de gestão de pessoas. **Revista Espacios**, v. 34, n. 12, p. 21, 2014. Disponível em: <https://www.revistaespacios.com/a13v34n12/13341222.html>. Acesso em: 30/12/2020.

MICHAEL, J.; VINCENT, A. Data-Driven Decision Making, **Middle School Journal**, Taylor Francis Online, v. 42, n. 2, p. 56-63, nov. 2010. DOI: <https://doi.org/10.1080/00940771.2010.11461758>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/00940771.2010.11461758>. Acesso em: 26/12/2020.

MILES, N.; HUBERMAN, A. Qualitative Data Analysis: An expanded source book. **SAGE Publications**, Londres, 2º ed. 1994.

MIRANDA, I. CARREIRA - Mercado de trabalho: vagas home office crescem 140% em 2022. **ESCRITÓRIO DE CONTABILIDADE**, mar. 2022. Disponível em: <https://www.sitecontabil.com.br/view/E1802/noticias-ler.php?id=6656&p=5®iao=brasil>. Acesso em: 08/01/2022.

MONTEVECCHI, A. PICTOREA: UM MÉTODO PARA DESCOBERTA DE CONHECIMENTO EM BANCO DE DADOS CONVENCIONAIS. **PUC-MINAS**. 2012. Disponível em: http://www.biblioteca.pucminas.br/teses/Informatica_MontevecchiAL_1.pdf. Acesso em: 15/12/2021.

MYTELKA, L. Catching up in new wave technologies. **Oxford Development Studies**, Taylor Francis Journals, v. 32, n. 3, p. 389-405, fev. 2004. DOI: <https://doi.org/10.1080/1360081042000260593>. Disponível em: <https://ideas.repec.org/a/taf/oxdevs/v32y2004i3p389-405.html>. Acesso em: 10/02/2021.

NOGUEIRA, D. Agile Data Mining: Uma metodologia ágil para o desenvolvimento de projetos de data mining. **Universidade do Porto**, FEUP, jul. 2014. Disponível em: https://sigarra.up.pt/fbaup/pt/pub_geral.pub_view?pi_pub_base_id=31966. Acesso em: 15/02/2022.

NONAKA, I.; TAKEUCHI, H. Criação de conhecimento na empresa: como as empresas japonesas geram a dinâmica da inovação. **Editora Campus**, Rio de Janeiro, 7^o ed. 1997.

PHILLIP, R. Big Data Analytics. **TDWI best practices report**, The Data Warehousing Institute, TDWI RESEARCH, 2011. Disponível em: http://download.101com.com/pub/tdwi/Files/TDWI_BPReport_Q411_Big_Data_Analytics_Web.pdf. Acesso em: 15/02/2021.

RIBEIRO, E. **Gestão de pessoas**. Associação Educacional Leonardo da Vinci (Asselvi). Indaial: Asselvi, 2007. Tópico 1.

SBRAGIA, R. Algumas características da estrutura matricial. **Revista De Administração**, São Paulo, v. 13, n. 1, p. 45-66, mar. 1978. DOI: <https://doi.org/10.1016/rausp.v13i1.166439>. Disponível em: http://www.ijsn.es.gov.br/ConteudoDigital/20120815_ij00705_seminariosobreareestruturacao_organizacionalnoijsn_anexo.pdf. Acesso em: 08/02/2022.

SORESCU, A. Data-Driven Business Model Innovation. **Journal of Product Innovation Management**, Wiley Online Library, v. 34, n. 5, p. 691-696, jun. 2017. DOI: <https://doi.org/10.1111/jpim.12398>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/jpim.12398>. Acesso em: 15/11/2021.

VOLBERDA, W.; VAN, D. Management Innovation: Management as Fertile Ground for Innovation. **European Management Review**, Wiley Online Library, v. 10, n. 1, p. 1-15, mar. 2013. DOI: <https://doi.org/10.1111/emre.12007>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/emre.12007>. Acesso em: 27/02/2021.

WATSON, H.; WIXOM, B. **The current state of business intelligence**. IEEE Xplore, v. 40, n. 9, p. 96-99, set. 2007. DOI: <https://doi.org/10.1109/MC.2007.331>. Disponível em: <https://ieeexplore.ieee.org/document/4302625>. Acesso em: 27/02/2021.

YANHONG, M. Research on Technology Innovation Management in Big Data Environment. **IOP Conference Series Earth and Environmental Science**, IOP Publishing Ltf, v. 113, n. 1, p. 12- 141, fev. 2018. DOI: <https://doi.org/10.1088/1755-1315/113/1/012141>.

ZHOU, R. Application of Big Data Technology in Innovation Management System. **Journal of Physics: Confere Series**, v. 1648, p. 42-45. 2020.

APÊNDICES

APÊNDICE A – PERGUNTAS DO QUESTIONÁRIO

Pergunta	Descrição da Pergunta	Categoria da Pergunta	Campo das perguntas
1	Qual o seu papel em <i>Data Analytics</i> ?	Persona	Fechado
2	Qual é a sua idade?	Persona	Fechado
3	Nome da empresa em que trabalha?	Persona	Aberto
4	Mercado/negócio da empresa em que trabalha?	Persona	Aberto
5	Tamanho da organização?	Persona	Fechado
6	Setor em que você trabalha na organização?	Persona	Aberto
7	Cargo em que você trabalha atualmente?	Persona	Aberto
8	Qual é a faixa salarial em que você se encontra atualmente?	Persona	Fechado
9	Qual é o seu tempo de vivência trabalhando com tecnologia /dados?	Persona	Fechado
10	Você acredita que o mercado solicita constantemente mão de obra qualificada para essa área?	Persona	Fechado
11	Já participou de quantos projetos de <i>Data Analytics</i> ?	<i>Data Analytics</i>	<i>Fechado</i>
12	Seus projetos são voltados para qual "grande" área de dados?	<i>Data Analytics</i>	Fechado
13	O que você espera entregar em um projeto? Cite no máximo 3.	<i>Data Analytics</i>	<i>Aberto</i>
14	Quais os principais desafios que você já teve durante uma implementação/rotina nesses projetos? Cite no máximo 5.	<i>Data Analytics</i>	<i>Aberto</i>
15	Quais as oportunidades que você vê para uma organização que trabalha com dados? Cite no máximo 3.	<i>Data Analytics</i>	<i>Aberto</i>
16	Existe algum modelo ideal para trabalhar com dados? Se concorda, consegue citar?	<i>Data Analytics</i>	<i>Fechado</i>

17	O que você considera como informação?	<i>Data Analytics</i>	Aberto
18	Cite 3 principais ferramentas que você usa no dia a dia?	Gestão da Inovação	Aberto
19	Conhece alguma metodologia e/ou <i>framework</i> voltado para dados?	Gestão da Inovação	Aberto
20	Usa alguma metodologia de gestão do conhecimento após uma implementação e/ou na rotina?	Gestão da Inovação	Aberto
21	Segue algum padrão de documentação, e, se sim, poderia compartilhar um exemplo?	Gestão da Inovação	Aberto
22	O que você sempre tenta melhorar em uma implementação ou até mesmo na sua rotina?	Gestão da Inovação	Aberto
23	Quais são os recursos que você acredita que sejam necessários para uma organização trabalhar com dados de forma eficiente e eficaz? Cite no máximo 3.	Gestão da Inovação	Aberto
24	Como o tipo de contratação do serviço (interno/externo) influencia a gestão das empresas quanto a <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado – usando a escala de Likert
25	Qual tipo de contratação de serviço é o ideal para se trabalhar inicialmente com <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado
26	Considerando que, na área, existe uma grande rotatividade de profissionais e que muitas empresas não possuem grandes <i>expertises</i> , qual tipo de contratação possui mais "risco" para a empresa, falando em <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado
27	Como a cultura organizacional influencia a gestão das empresas quanto a <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado – usando a escala de Likert
28	Qual é a complexidade de se gerenciar um projeto de <i>Analytics</i> na organização?	Gestão de Pessoas	Fechado – usando a escala de Likert
29	Entre os profissionais que não atuam com essa tecnologia, existe um grande interesse em migrar para essa área de <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado – usando a escala de Likert

30	Como é a reação das pessoas/organização com a mudança de <i>mindset</i> para os dados?	Gestão de Pessoas	Fechado – usando a escala de Likert
31	A cultura de um profissional de <i>Analytics</i> é diferente? Estilo de vida? Horário de trabalho? Benefícios? Home office?	Gestão de Pessoas	Fechado
32	Qual é a complexidade em alinhar os valores e princípios da organização com os dos profissionais dessa área?	Gestão de Pessoas	Fechado – usando a escala de Likert
33	Como o processo de recrutamento e seleção influencia a gestão das empresas quanto a <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado – usando a escala de Likert
34	Profissionais dessa área possuem <i>skills</i> e habilidades específicas? Se sim, cite no máximo 3.	Gestão de Pessoas	Aberto
35	Quais são as gerações predominantes que trabalham com <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado
36	Como a estrutura organizacional influencia a gestão das empresas quanto a <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado – usando a escala de Likert
37	Entre as estruturas organizacionais propostas, quais podem agregar mais valor às empresas que trabalham com <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado
38	Qual é a formação de equipe mais aderente para atuar em projetos de <i>Data Analytics</i> ?	Gestão de Pessoas	Fechado

APÊNDICE B - Literaturas coletadas na análise analítica.

Título	Autor(es)	Data	Fonte/Revista/ Jornal	Categorias de análise
Data-Driven Business Model Innovation	SORESCU, A.	2017	Product Development & Management Association	Gestão de pessoas, <i>Data analytics</i>
Data-driven innovation: switching the perspective on Big Data	BUGANZA, D.	2018	The European Journal of Innovation Management	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Innovation management techniques and tools: a review from theory and practice	ALBORS, A.	2008	R&D Management	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Big Data Analytics	RUSSOM, P.	2011	TDWI BEST PRACTICES REPORT	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Continuous results-driven innovation management program	SIBELE, S; BERNARDES, P; RAMALHO, F; IAKOVLEVITCH, E; SILVA, M.	2019	Revista de Gestão	Gestão de pessoas, <i>Data analytics</i>
Data-Driven Innovation through Open Government Data	THEOR, J.	2014	The Journal of Theoretical and Applied Electronic Commerce Research	Gestão da inovação
Data Science as an Innovation Challenge: From Big Data to Value Proposition	KAYSER, V; NEHRKE, B; ZUBOVIC, D.	2018	Technology Innovation Management Review	<i>Data analytics</i>

Over the mask of innovation management in the world of Big Data	CAPUTO, F; MAZZOLENI, A; MULLER, A.	2020	Journal of Business Research	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Research on Technology Innovation Management in Big Data Environment	YANHONG, M.	2018	Earth and Environmental Science	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Innovation and Big Data in Smart Service Systems	MAGLIO, P; LIM, C.	2016	Journal of Innovation Management	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Big Data: Innovation and Competitive Advantage in an Information Media Analytics Company	PRESCOTT, M.	2016	Journal of Innovation Management	Gestão de pessoas, <i>Data analytics</i>
Innovation management in a digital world	HOERLSBERG, M.	2019	The Journal of Manufacturing Technology	Gestão da inovação, <i>Data analytics</i>
An empirical study of the rise of big data in business scholarship	FRIZZO, J; BARKER, P.	2016	The International Journal of Information Management	<i>Data analytics</i>
Application of Big Data Technology in Innovation Management System	ZHOU, R.	2020	The Journal of Physics: Conference Series	Gestão da inovação, <i>Data analytics</i>
Big data for open innovation in SMEs and large corporations: Trends,	VECCHIO, P; MININ, A; PANNIELLO, U; PIRRI, S.	2017	Creativity and innovation management	Gestão da inovação, <i>Data analytics</i>

opportunities, and challenges				
Perspectives to Definition of Big Data: A Mapping Study and Discussion	YLIJOKI, O; PORRAS, J.	2016	Journal of Innovation Management	Gestão da inovação, <i>Data analytics</i>
Influência dos fatores organizacionais no sucesso de projetos no setor automotivo	SANTOS, I.	2015	Repositório da UNESP	Gestão de pessoas
A Influência de Fatores Organizacionais no Desempenho do Gerenciamento de Projetos: uma Pesquisa de Campo em Empresas Brasileiras de Tecnologia da Informação	SCHNEIDER, R; BARBOSA, J; BOUZADA, M; GONÇALVES, A.	2013	Encontro de Administração da Informação	Gestão de pessoas, <i>Data analytics</i>
PICTOREA: um método para descoberta de conhecimento em bancos de dados convencionais	MONTEVECCHI, A.	2012	Biblioteca Digital Brasileira de Teses e Dissertações	Gestão de pessoas
Algoritmos e Ferramentas de Descoberta de Conhecimento em Bancos de Dados Geográficos	BOGORNÝ, V.	2003	UFSC Departamento de informática e estatística	<i>Data analytics</i>

O Uso da Descoberta de Conhecimento em Base de Dados para Apoiar a Tomada de Decisões	DANTAS, E; ALMEIDA, J; JUNIOR, P.	2010	Associação Educaional Dom Bosco	Gestão da inovação, <i>Data analytics</i>
Utilização de Ferramentas de KDD para Integração de Aprendizagem e Tecnologia em Busca da Gestão Estratégica do Conhecimento na Empresa	BOENTE, A.	2007	SEGET	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
Business Intelligence: Business Evolution after Industry 4.0	ROMERO, C.	2021	The Digital Revolution in Sustainable Business Models and Finance Management	Gestão da inovação, <i>Data analytics</i>
Business Intelligence and Analytics: An Understanding of the Industry Needs for Domain- Specific Competencies	GURCAN, F.	2019	IEEE	<i>Data analytics</i>
Business Intelligence e Analytics: do Big Data ao Big Impact	CHEN, H.	2012	MIS Quarterly	<i>Data analytics</i>
Business Intelligence and Analytics Education, and Program Development: A	CHIANG, R.	012	The ACM Transactions on Management Information System	<i>Data analytics</i>

Unique Opportunity for the Information Systems Discipline				
Big data and management	HAAS, G.	2015	Academy of Management Journal	Gestão da inovação, Gestão de pessoas, <i>Data analytics</i>
An overview of big data analytics application in supply chain management published in 2010-2019	GHALEHKHOND, A; AHMADI, I; MAIHAMI, E.	2020	Scielo	<i>Data analytics</i>
Marketing de serviços orientado a dados em um mundo conectado	KUMAR, V; MAN, V; NEGHINA, C.	2013	Jornal de Gerenciamento de Serviços	Gestão da inovação, <i>Data analytics</i>
Big Data Analytics in Operations Management	CHOI, T. D; WALLACE, S; WANG, Y.	2017	Production and Operations Management	Gestão da inovação, <i>Data analytics</i>

APÊNDICE C - Quadro teórico-metodológico da análise analítica

Título	<i>Data analytics</i>	Gestão de pessoas	Gestão da inovação
Data-driven innovation: switching the perspective on Big Data	Esta literatura trata do aumento da disponibilidade dos dados e busca entender melhores formas de se trabalhar com dados.	Esta literatura aborda como os gerentes devem trabalhar com os dados de forma a conseguir inovar dentro de uma empresa.	De acordo com esta, a Internet das Coisas permite que as empresas consigam reunir uma quantidade e variedade de dados consideráveis, que estão tendo um impacto significativo na gestão da inovação.
Innovation management techniques and tools: a review from theory and practice	Este referencial evidencia que novas tendências e tipos de dados na economia apoiaram a ideia de conhecimento como recurso.	Esta literatura ressalta que a inovação tecnológica está relacionada a novos modelos de negócios e novas formas de organização do trabalho,	Esta literatura identifica as principais técnicas de gestão da inovação (IMTs) visando à melhoria da competitividade das empresas por meio de gestão do conhecimento.

		inovação em <i>design</i> e em <i>marketing</i> .	
Over the mask of innovation management in the world of Big Data	Esta literatura procura entender quais são as condições necessárias para a gestão eficaz de <i>Big Data</i> a partir do <i>Systems Thinking</i> e <i>Service Logic</i> .	Esta literatura aborda a relevância de uma relação positiva entre o número de indivíduos de recursos humanos altamente especializados envolvidos em P&D e Avaliação de Tecnologia dentro da empresa e o ROI de Empresas de <i>Big Data</i> . Ademais, enfatiza a relevância de recursos humanos para garantir a sobrevivência de uma empresa em rápidas mudanças ambientes.	Busca analisar a gestão da inovação em termos da capacidade de adquirir e explorar novas informações.
Research on Technology Innovation Management in Big Data Environment	Esta pesquisa aborda o contexto de como usar a tecnologia de <i>big data</i> para processar e analisar dados de informações rapidamente, melhorando o nível de gerenciamento a partir de <i>big data</i> .	Esta literatura aborda como a falta de gerenciamento profissional da tecnologia de <i>big data</i> é um importante problema de gestão da inovação.	Esta literatura especifica como o modelo bidirecional de tomada de decisão de gestão da inovação tecnológica é mais evidente na educação em rede da educação comunitária.
O Uso da Descoberta de Conhecimento em Base de Dados para Apoiar a Tomada de Decisões	Esta literatura discute como o <i>Data Mining</i> ou Mineração de Dados é o processo de pesquisa em grandes quantidades de dados para extração de conhecimento, utilizando técnicas de Inteligência Computacional.	Segundo este referencial, apenas os recursos tecnológicos, não garantirão uma perfeita gestão da inovação; é necessário um capital humano bem-treinado e com experiência de mercado para interpretar as informações e conhecimentos disponibilizados.	Esta literatura aborda que a gestão do conhecimento é necessária para se decidir e/ou avaliar uma decisão, em que conhecimento torna-se disponível por meio de informações documentadas.

Utilização de Ferramentas de KDD para Integração de Aprendizagem e Tecnologia em Busca da Gestão Estratégica do Conhecimento na Empresa	Esta literatura aborda a descoberta de conhecimento em bases de dados a partir do método KDD.	Segundo este referencial, é de responsabilidade do chamado “analista humano” a árdua tarefa de orientar a execução do processo de KDD para a gestão estratégica do conhecimento.	Essa literatura debate como o processo de transformação de informação em conhecimento é agilizado através do emprego de tecnologia da informação.
---	---	--	---

