



Gabriel Lourenço Silvestre dos Santos

**Análise de maturidade em Business Intelligence
como fator de criação de vantagem competitiva
e melhoria de performance:
Estudo de caso em uma empresa do setor farmacêutico**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-graduação em Administração de Empresas do Departamento de Administração da PUC-Rio.

Orientador: Prof. Fábio de Oliveira Paula

Rio de Janeiro,
Abril de 2023



Gabriel Lourenço Silvestre dos Santos

**Análise de maturidade em Business Intelligence
como fator de criação de vantagem competitiva
e melhoria de performance:
Estudo de caso em uma empresa do setor farmacêutico**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Administração de Empresas da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

Prof. Fábio de Oliveira Paula

Orientador

Departamento de Administração – PUC-Rio

Prof. Jorge Ferreira da Silva

Departamento de Administração – PUC-Rio

Prof. Paula Castro Pires de Souza Chimenti

UFRJ

Rio de Janeiro, 14 de abril de 2023

Todos os direitos reservados. A reprodução, total ou parcial, do trabalho é proibida sem autorização da universidade, do autor e do orientador.

Gabriel Lourenço Silvestre dos Santos

Graduou-se em Engenharia de Produção na UVA (Universidade Veiga de Almeida) em 2016. Cursou Especialização em Gerenciamento de Projetos na Coppead em 2018.

Ficha Catalográfica

Santos, Gabriel Lourenço Silvestre

Avaliação do uso de business intelligence para criação de Vantagem competitiva e melhoria de performance: estudo de caso em uma empresa do setor farmacêutico / Gabriel Lourenço Silvestre dos Santos ; Orientador: Fábio de Oliveira Paula. -2023.

150 f. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Administração, 2023.

Inclui bibliografia

1. Administração – Teses. 2. Business intelligence. 3. Maturidade. 4. Vantagem competitiva. 5. Performance. 6. Inteligência artificial. I. Paula, Fábio de Oliveira. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Administração. III. Título.

CDD. 658

Agradecimentos

A minha noiva, Lívia, por ter sido sempre minha grande incentivadora e fazer com que eu sempre acredite em mim. E por todo tempo extra dos seus dias dedicados a fazer as coisas darem certo, principalmente nos períodos mais pegados de trabalho e mestrado.

Aos meus queridos pais, Lourival e Claudia pelo apoio incondicional e por sempre estimularem que eu e a minha irmã, Gisely, buscássemos o caminho da educação.

A minha irmã Gisely por ter sido uma grande parceira durante toda a vida e por me apoiar em todos os momentos.

A minha avó Ieda, por ser uma grande fonte de inspiração e alegria para todos nós.

Ao meu orientador Fabio, pela amizade e apoio durante toda a construção desse trabalho, em especial quando ficou mais difícil conciliar a vida acadêmica com a profissional.

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (Capes) - Código do financiamento 001

Resumo

Santos, Gabriel Lourenço Silvestre; Paula, Fábio de Oliveira. **Análise de maturidade em Business Intelligence como fator de criação de vantagem competitiva e melhoria de performance: Estudo de caso em uma empresa do setor farmacêutico.** Rio de Janeiro, 2023. 150p. Dissertação de Mestrado - Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

O presente trabalho tem como objetivo analisar a percepção de uma amostra de funcionários, de diferentes departamentos e cargos, sobre o estágio de maturidade em *Business Intelligence* de uma empresa do setor farmacêutico. Posteriormente, pretende-se entender a relação entre a percepção de maturidade, e a percepção do potencial de criação de vantagem competitiva e melhoria na performance da empresa que a adoção de *Business Intelligence* pode trazer. Para atingir ao objetivo foram realizadas uma pesquisa via survey com 32 respondentes, para coletar sua percepção de maturidade da empresa em cinco dimensões de maturidade: Organização, Infraestrutura, Gestão de Dados, Análise e Governança a fim de enquadrar a empresa dentro de um estágio. Além disso, foram incluídas nos questionários perguntas relacionadas a percepção de criação de vantagem competitiva e melhoria de performance. A fim de entender melhor os resultados para posteriormente criar uma proposta de plano de melhoria para que a empresa avançasse no modelo, foram realizadas entrevistas em profundidade com quatro respondentes e uma análise de regressão com o objetivo de entender melhor a relação entre as variáveis. O trabalho delimitou-se em estudar a empresa no momento atual sem que fosse feito um acompanhamento da evolução ao longo do tempo, pesquisou apenas uma empresa do setor farmacêutico baseada no Brasil limitando comparações com benchmarkings entre países e setores. Além disso, o fato de o pesquisador conhecer e ser funcionário da mesma empresa dos respondentes pode ter gerado desconforto em parte deles, gerando possíveis vieses nas respostas. Com os resultados da pesquisa somados as melhores práticas de *BI* trazidas no referencial teórico, foi traçada uma proposta com um plano de melhoria que se implementado, acredita-se, que pode levar a empresa a avançar no estágio de maturidade.

Palavras-chave

Business Intelligence; Maturidade; Vantagem Competitiva; Performance; Inteligência Artificial; *Machine Learning*; Dados

Abstract

Santos, Gabriel Lourenço Silvestre; Paula, Fábio de Oliveira (Advisor). **Maturity analysis in Business Intelligence as a factor creating competitive advantage and performance improvement: Case study in a company in the pharmaceutical sector.** Rio de Janeiro, 2023. 150p. Dissertação de Mestrado - Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

The objective of this work is to analyze the perception of a sample of employees, from different departments and positions, about the stage of maturity in Business Intelligence of a company in the pharmaceutical sector. Subsequently, we intend to understand the relationship between the perception of maturity and the perception of the potential for creating competitive advantage and improving the company's performance that the adoption of Business Intelligence can trace. To achieve the objective, a survey was carried out with 32 respondents, to collect their perception of the company's maturity in five dimensions of maturity: Organization, Infrastructure, Data Management, Analysis and Governance to frame the company within a stage. In addition, the questionnaires included questions related to the perception of creating competitive advantage and improving performance. In order to better understand the results to later create a better plan proposal for the company to move forward in the model, we conducted in-depth interviews with four respondents and a regression analysis in order to better understand the relationship between the variables. The work is limited to studying the company today without having followed the evolution over time, researching only one company in the pharmaceutical sector based in Brazil, limiting comparisons with benchmarking between countries and sectors. Also, the fact that the researcher knows and is an employee of the same company two interviewees could cause discomfort on their part, generating the possibility of viewing the answers. With the research results added to the best BI practices developed without theoretical reference, a proposal was elaborated with a better plan that has been implemented, it is proven, that can lead the company to advance in its maturity stage.

Keywords

Business Intelligence; Maturity; Competitive advantage; Performance; Artificial intelligence; Machine Learning; Data

SUMÁRIO

1. Introdução	16
1.1 Contextualização da questão da pesquisa	16
1.2 Objetivo do Estudo	21
1.3 Delimitação do trabalho	22
1.4 Relevância do Estudo	22
1.5 Estrutura do trabalho	24
2. Referencial Teórico	25
2.1 O uso de dados nos negócios	25
2.1.1 A importância da qualidade no gerenciamento dos dados	28
2.1.2 Como são definidos os Indicadores e construídos os <i>Dashboards</i>	30
2.2 As habilidades para análise de dados complexos nas empresas	33
2.2.1 A limitação da capacidade humana em analisar dados	40
2.2.2 Ruídos: Tipos de ruídos que impactam as análises e como evitá-los	43
2.2.3 Como vieses e intuições prejudicam o processo de tomada de decisão	47
2.3 O uso de Inteligência Artificial (IA) como ferramenta de negócios	50
2.3.1 Finanças	51
2.3.2 Planejamento Estratégico	51
2.3.3 Gestão de Recursos Humanos	51
2.3.4 Empreendedorismo	52
2.3.5 Marketing	52
2.3.6 O uso de Inteligência Artificial (IA) focada em Marketing	53

2.3.2 Desafios para adoção de AI e <i>Machine Learning</i> para tomada de decisão e como isso ainda não é uma realidade	54
2.4 Modelo de Maturidade	57
2.4.1 Avaliação do estágio de maturidade da empresa quanto ao uso de dados	57
2.4.2 O uso de dados para criação de Vantagem Competitiva	59
2.4.3 Uso de dados para melhorar o desempenho	60
3. Metodologia	61
3.1 A Seleção do Caso	63
3.1.1 A empresa farmacêutica objeto de estudo	64
3.2 A Seleção dos Sujeitos	66
3.3 Coleta de dados	68
3.4 Análise e Tratamento dos dados	69
3.4.1 Análise de Fator	69
3.4.2 Regressão	71
4. Resultados	72
4.1 Avaliação de maturidade em <i>Business Intelligence</i>	73
4.1.1 Dimensão de Organização: FASE – Corporate Adoption	74
4.1.2 Dimensão da Infraestrutura: FASE – Early Adoption	77
4.1.3 Dimensão da Gestão de Dados: FASE – Early Adoption	79
4.1.4 Dimensão das Análises: FASE – Early Adoption	82
4.1.5 Governança: FASE – Corporate Adoption	84
4.2 A Relação entre a percepção de Maturidade em <i>BI</i> e a percepção de criação de Vantagem Competitiva e melhoria em Performance	86
4.2.1 Tratamento dos Dados	87

4.2.2	Análise de Fator	89
4.2.3	Resultados das Regressões	94
4.2.3.1	Regressão F1	94
4.2.3.2	Regressão F2	97
4.2.3.3	Regressão F3	100
4.2.3.4	Regressão F4	104
4.3	Discussão de Resultados	106
4.3.1	Discussão dos resultados do Modelo de Maturidade em Business Intelligence	106
4.3.2	A maturidade da empresa em <i>Business Analysis</i> e a criação de vantagem competitiva sustentada	108
4.3.3	A maturidade da empresa em <i>Business Intelligence</i> e o incremento na performance	112
4.3.4	Discussão sobre os resultados das regressões	116
4.3.5	Plano de melhorias por dimensão	118
4.4.1	Proposta de melhoria para dimensão de análises	120
4.4.2	Proposta de melhoria para dimensão de Infraestrutura	121
4.4.3	Proposta de melhoria para dimensão de Gestão de Dados	122
5.	Conclusão	124
5.1	Limitações do Estudo	126
5.2	Oportunidades para futuras pesquisas	126
6.	Referências	128

Lista de Figuras

Figura 1. Gastos globais totais em produtos farmacêuticos	16
Figura 2. Faturamento farmacêuticas nos BRICS	17
Figura 3. Cobertura Vacinal	19
Figura 4. Respostas dos médicos sobre interações com a indústria	20
Figura 5. A fábrica de dados ocultos	29
Figura 6. Classificação de habilidades em Business Analytics	35
Figura 7. Impacto de AI na linha de fundo dos líderes	37
Figura 8. Descrição da abordagem da sua organização para o desenvolvimento de insights para uso na tomada de decisões	56
Figura 9. Estágios do modelo de maturidade	58
Figura 10. Notícias PNI	62
Figura 11. Notícias Programa Nacional Aids	62
Figura 12. Resultados Financeiros	65
Figura 13. Divisão dos participantes da pesquisa	66
Figura 14. Resumo do resultado	74
Figura 15. Média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Organização	75
Figura 16. Média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Infraestrutura	78
Figura 17. Média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Gestão de Dados	80
Figura 18. Média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Análises	82
Figura 19. Média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Análises	85

Figura 20. Determinação do número ideal de fatores	91
Figura 21. Gráfico P-P Normal F1	94
Figura 22. Gráfico Homocedasticidade F1	95
Figura 23. Gráfico P-P Normal F2	98
Figura 24. Gráfico Homocedasticidade F2	98
Figura 25. Gráfico P-P Normal F3	101
Figura 26. Gráfico Homocedasticidade F3	101
Figura 27. Gráfico P-P Normal F4	104
Figura 28. Gráfico Homocedasticidade F4	104
Figura 29. Opção dos respondentes nas opções citadas	110
Figura 30. Opção dos respondentes nas opções citadas	113
Figura 31. Opção dos respondentes nas opções de Customer Recurrence e Market Share Evolution	114
Figura 32. Percepção dos respondentes ligada ao impacto pela maturidade no uso dos dados está relacionado ao clima organizacional.	115

Lista de Tabelas

Tabela 1. Scoring necessário em cada um dos estágios	59
Tabela 2. Análise de valores ausentes	87
Tabela 3. Estatísticas univariadas	88
Tabela 4. Teste de kmo e bartlett	89
Tabela 5. Matrizes anti-imagem	90
Tabela 6. Quantidade de variância nas variáveis originais contabilizada por cada componente	91
Tabela 7. Variância total explica	92
Tabela 8. Matriz de componentes	92
Tabela 9. Matriz de componentes rotativa	93
Tabela 10. Matriz de transformação de componentes	93
Tabela 11. Resumo do modelo F1	96
Tabela 12. Teste anova F1	96
Tabela 13. Coeficientes F1	97
Tabela 14. Resumo do modelo F2	99
Tabela 15. Teste anova F2	100
Tabela 16. Coeficientes F2	100
Tabela 17. Resumo do modelo F3	102
Tabela 18. Teste anova F3	102
Tabela 19. Coeficientes F3	103
Tabela 20. Resumo do modelo F4	105
Tabela 21. Teste anova F4	105
Tabela 22. Coeficientes F4	106
Tabela 23. Médias entre 5 dimensões	106

Lista de Quadros

Quadro 1. Linha do tempo - business intelligence	25
Quadro 2. Tarefas do time de liderança por trás de uma cultura de análise de dados	37
Quadro 3. Variáveis Inseridas/Removidas F1	96
Quadro 4. Variáveis Inseridas/Removidas F2	99
Quadro 5. Variáveis Inseridas/Removidas F3	102
Quadro 6. Variáveis Inseridas/Removidas F4	105
Quadro 7. Todas as dimensões de vantagem competitiva podem gerar impacto no uso adequado dos dados	108
Quadro 8. Estruturação das propostas de melhoria	120

Lista de Abreviaturas

P&D	Pesquisa e Desenvolvimento
DATASUS	Departamento de Informática do Sistema Único Saúde
MenACWY	Meningite do tipo ACWY
MenB	Meningite do tipo B
COVID-19	Corona Vírus Disease 2019
KPI	Key Performance Indicator
HIV	Human Immunodeficiency Vírus
ROI	Return of Investment
BI	Business Intelligence
B2B	Business to Business
CRM	Customer Relationship Management
BDA	Business Development Associate
IA	Inteligência Artificial
CEO	Chief Executive Officer
TI	Tecnologia da Informação
ML	Machine Learning
TDWI	Transforming Data with Intelligence
P&L	Profit and Loss
RH	Recursos Humanos
ANVISA	Agência Nacional de Vigilância Sanitária
B2B2B2C	Business to Business to Customer
PDV	Ponto de Venda

“Pois me achava enleado em tantas dúvidas e erros, que me parecia não haver obtido outro proveito, procurando instruir-me, senão o de ter descoberto cada vez mais a minha ignorância”.

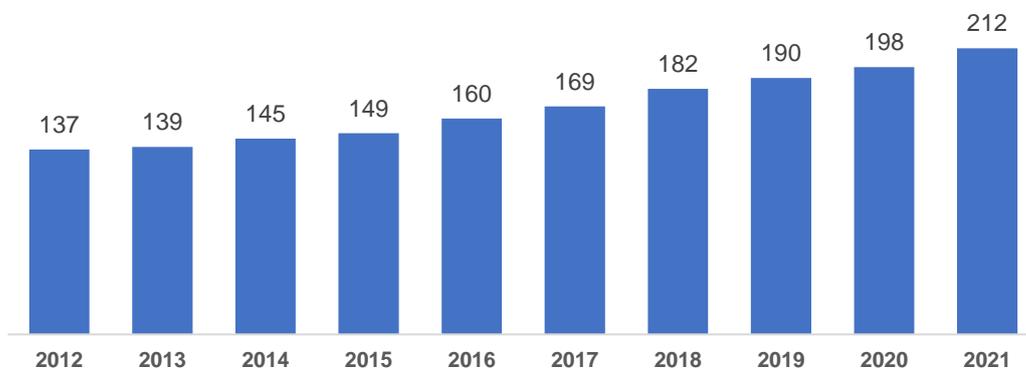
1. Introdução

1.1 Contextualização da questão da pesquisa

Segundo Fernando Americano (2021), cofundador da Le Wagon Latam, o efeito do aumento gigantesco no volume de dados coletados pelas empresas se parece com a chegada de um Tsunami numa cidade, por invadir a empresa por todos os lados e depois que chega muda completamente o cenário anterior. Nesse novo contexto, onde se gera mais dados do que nunca, o maior desafio para os tomadores de decisão dentro do ambiente de negócio é definir quais das evidências geradas são mais relevantes e geram maior impacto para os resultados desejados. Em geral, as decisões tomadas com base em análise de dados seguem a mesma lógica desde a adoção da ciência da informação como suporte ao processo de tomada de decisão, porém a capacidade do tomador de decisão de analisar os dados não cresceram na mesma proporção que a capacidade desenvolvida pelas empresas de capturá-los, gerando assim o desafio de evitar ruídos e tomar decisões assertivas em meio a tantos dados disponíveis.

Dentro desse novo cenário se encontra o setor farmacêutico, um setor que historicamente definiu como o principal fator para o sucesso de uma empresa sua capacidade de desenvolver novas moléculas e através de processos de reconhecimento de patentes, proteger seu mercado de atuação por um período. Tal estratégia competitiva se provou eficaz por um longo período, A. Fillietaz & S. Crispim (2010) indicam que empresas do setor investem em média 21,2% do seu faturamento em P&D enquanto em outros setores a média fica em torno de 4%.

Gasto total de empresas farmacêuticas com P&D (em bilhões de dólares)



Statista 2022 - Health, Pharma & Medtech | Pharmaceutical Product

Figura 1 Gastos globais totais em produtos farmacêuticos

Por outro lado, apesar de se manter um fator relevante, principalmente para empresas que optaram por direcionar seu planejamento estratégico para produtos de alto custo (biológicos e oncológicos), o pipeline de lançamentos ou novos produtos com patentes vigentes não é mais o único ativo intangível que as empresas farmacêuticas devem buscar para mostrar vantagem competitiva e criar valor para seus acionistas. Uma vez que o lançamento de um medicamento consome grandes somas para pesquisa e desenvolvimento, seus valores quando chegam ao mercado podem ser proibitivos para parte da população, sendo assim, encontrar meios de rentabilizar seu portfólio de produtos maduros, em especial em mercados emergentes, é fundamental para o sucesso das multinacionais do setor. De acordo com relatório do Goldman Sachs, as vendas do setor farmacêutico nesses mercados mais que dobraram entre os anos de 2012 e 2017, especialmente liderados por países do BRICS (Brasil, Rússia, Índia, China e África do Sul) e do MIST (Mexico, Indonésia, Coreia do Sul e Turquia), atingindo um percentual de 20% no *market share* global. Conforme podemos ver na figura abaixo, de acordo com relatório da Statista de 2022, até 2026 o mercado dos BRICS seguirá crescendo em ritmo acelerado, chegando próximo a casa dos 200b de dólares em 2026.

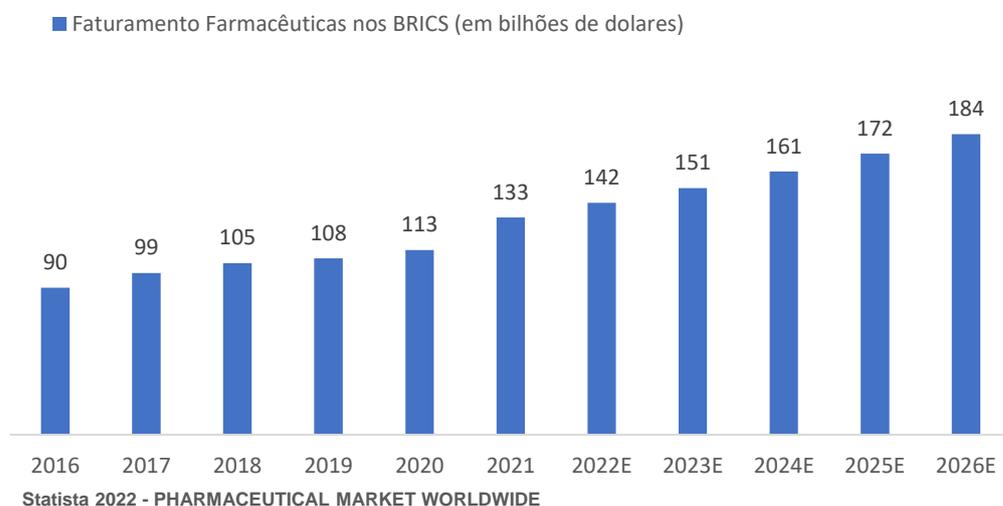


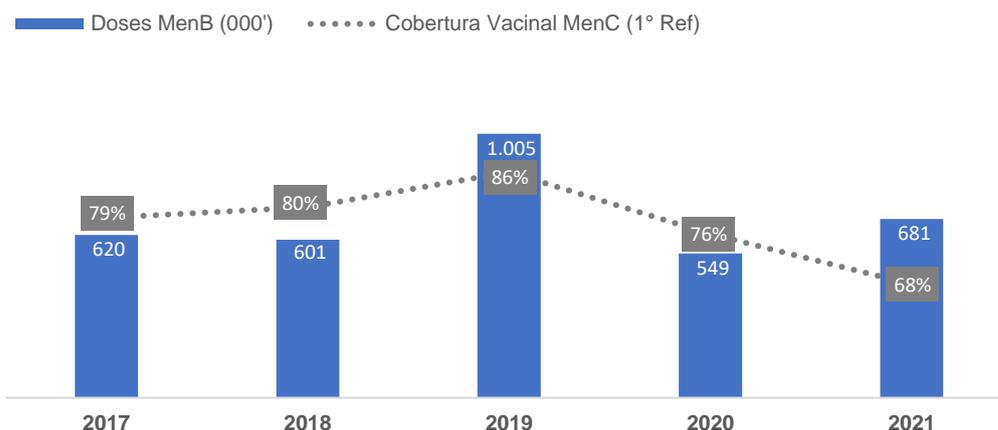
Figura 2. Faturamento farmacêuticas nos BRICS

Segundo Maya Tannoury e Zouhair Attieh (2017) esse crescimento, que pode ser atribuído a fatores como o crescimento das populações, o incremento na renda *per capita* e o aumento da expectativa de vida, fatores esses que devem se manter direcionalmente pelos próximos anos, irão tornar o *market share* dessa região cada vez mais representativo para as empresas, uma vez que, em mercados

desenvolvidos o crescimento segue achatado, limitado pelo crescimento populacional baixo e a expiração de patentes, o que vem levando a um *up-selling* de medicamentos genéricos. Nesses mercados, onde o ambiente se torna cada vez mais competitivo devido a entrada constante de *players locais* (fabricantes de genéricos e similares), a habilidade de se testar modelos inovadores e fazer correções rápidas de rotas, por meio de *early signs indicators*, se tornam os grandes geradores de vantagem competitiva. Tais diferenciais só podem ser obtidos através da coleta e tratamento apropriado dos dados disponíveis.

O presente trabalho se propõe a analisar se a maior quantidade de dados disponíveis está levando os times comerciais desse setor a tomarem melhores decisões. A pergunta que pode parecer óbvia a princípio na verdade é bastante complexa, uma vez que, o crescimento exponencial no número de indicadores disponíveis pode gerar dificuldade de separar casualidade e correlação entre os *outputs* dos diferentes investimentos feitos pelos times de marketing.

Um exemplo que pode ilustrar essa dificuldade em encontrar correlação pode ser o aumento do *share of mind* das vacinas com as taxas de cobertura vacinal. Em 2019, um evento amplamente divulgado na mídia, a morte de um dos netos do ex-presidente Luís Inácio Lula da Silva, que a princípio foi apontada erroneamente como em decorrência da meningite, levou as taxas de cobertura vacinal do primeiro reforço da vacina meningocócica C para níveis próximos a 90%, de acordo com o DATASUS, no PNI (programa nacional de imunização) e recordes de vendas nas vacinas disponíveis apenas no mercado privado (MenACWY e MenB). A indústria trabalhou com a hipótese de que manter alto nível de investimento em campanhas para público leigo sustentaria as altas coberturas no PNI e patamares de venda no mercado privado, o que acabou não se provando verdadeiro, conforme demonstra a figura abaixo:



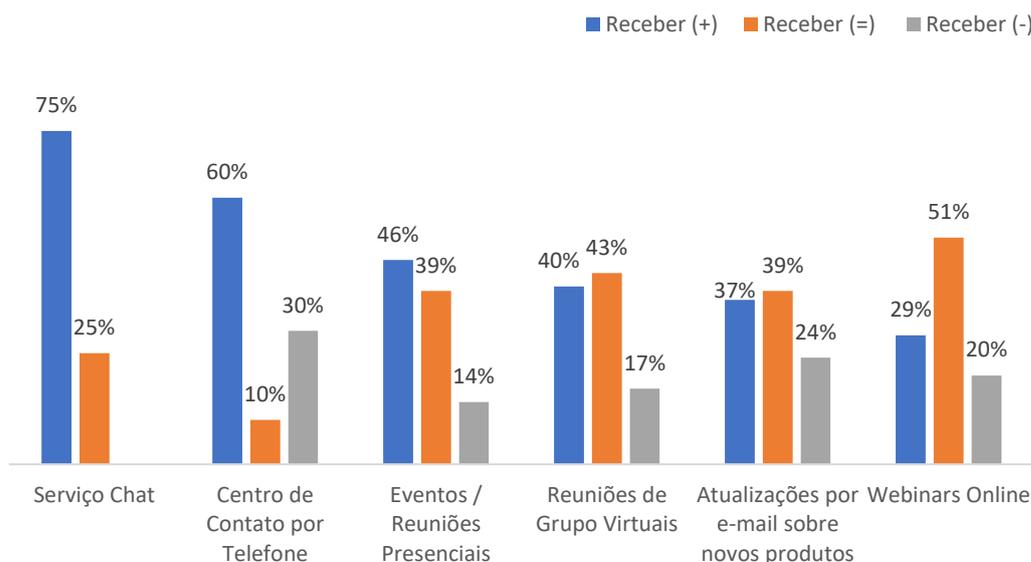
Cobertura Vacinal MenC fonte: DATASUS
Doses MenB fonte: Company Internal Information

Figura 3. Cobertura Vacinal

Em abril de 2020, outro evento espontâneo gerou grande *share of mind* para vacinas, a COVID-19. Nesse evento, as empresas trabalharam com a premissa de que o efeito Halo criado pela ampla divulgação da importância da vacinação geraria o mesmo efeito nas coberturas vacinais, porém nesse evento, todos os antígenos disponíveis no Programa Nacional de Imunização tiveram queda na sua cobertura vacinal.

Esse exemplo, mostra que (i) o maior conhecimento sobre os benefícios de um produto pode não necessariamente levar a uma maior adesão do paciente/consumidor a um tratamento ou procura pela prevenção; (ii) uma indicação positiva em um KPIs secundário pode não levar ao resultado esperado.

Levando em conta todas as novas pesquisas e indicadores criados na indústria nos últimos anos, profissionais responsáveis por tomar decisões de investimentos na áreas comerciais enfrentam um paradoxo, como no exemplo, acima quase que semanalmente e a indústria ainda carece de ferramentas automatizadas para ajudá-los a atribuir se o comportamento prescritivo de um médico é mais influenciado pelo número de visitas que recebe de um representante, ou pelo tempo que um material de ajuda visual lhe é apresentado, ou o número de aberturas que ele faz em e-mails enviados pela equipe de digital marketing.



Fonte: IPSOS 5º Panorama Farmacêutico - Respostas médicos sobre interações com a indústria

Figura 4. Respostas dos médicos sobre interações com a indústria

Hoje KPIs como os supracitados são disponibilizados diariamente a Gerentes de Produto e Gerentes de Trade para serem analisados e com os *insights* gerados serem definidas onde serão alocadas as verbas de marketing ou para quais clientes receberão o maior desconto em uma negociação. Além do excesso de dados disponibilizados, que é apontado pela IPSOS no seu relatório anual de Performance Farmacêutica como um dos fatores para o aumento em 17p.p nos casos de profissionais do setor que se sentem sobrecarregados, outros fatores afetam a capacidade desse tomador de decisão como por exemplo a grande quantidade de regulações no setor, que aumenta o número de decisões que devem ser tomadas em grupos (temas regulatórios, assuntos médicos, jurídicos e etc.) o que pode gerar uma amplificação no ruído, ou seja, fatores que a princípio deveriam ser irrelevantes para a tomada de decisão passam a influenciar, como por exemplo um orador que defende melhor seu ponto de vista, uma pessoa com um cargo mais sênior que se posiciona de determinada maneira ou mesmo a ordem que os pontos de vistas são compartilhados. Entende-se, assim, que pelos diversos fatores supracitados, é importante que o tomador de decisão busque definir de maneira clara quais as fontes de informação deverão ser buscadas, quais os *inputters* poderão influenciar na maneira como os *insights* são gerados, quais os KPIs deverão ser observados e quais testes poderão ser feitos para validar sua hipótese que levou a tal decisão. Somente dessa forma, será possível reduzir vieses e/ou ruídos e aumentar o uso produtivo de

dados para que melhores decisões sejam tomadas consistentemente a fim de gerar vantagem competitiva sustentada ao longo do tempo.

1.2 Objetivo do Estudo

O objetivo primário deste estudo é analisar a percepção de uma amostra de funcionários, de diferentes departamentos e cargos, sobre o estágio de maturidade em *Business Intelligence* de uma empresa do setor farmacêutico. Posteriormente, pretende-se entender a relação entre a percepção de maturidade, e a percepção do potencial de criação de vantagem competitiva e melhoria na performance da empresa que a adoção de *Business Intelligence* pode trazer.

A partir desse objetivo central, tem-se os seguintes objetivos secundários:

1. Identificar, por meio de uma revisão da literatura, um *framework* adequado para avaliar a maturidade em *Business Intelligence*. Escolheu-se aqui o modelo de maturidade *TDWI Analytics Maturity Model Guide* (Halper e Stodder, 2015);
2. Criar, por meio dessa revisão de literatura, um questionário para avaliar quanto a maturidade, o potencial de criação de vantagem competitiva e melhoria de performance da empresa;
3. Aplicar o modelo na empresa objeto de estudo por meio do questionário para a identificação do nível de maturidade, vantagem competitiva e performance da etapa anterior, com funcionários que atuam em áreas que lidam com tais temas; complementarmente, avaliar esses resultados através de entrevistas em profundidade com funcionários chave;
4. Avaliar quantitativamente a relação entre percepção da maturidade em BI e a percepção do potencial de criação de vantagem competitiva e desempenho por meio da adoção de BI;
5. Com base nos resultados aferidos apresentar um plano de melhorias em cada dimensão a fim de atingir o estágio de Corporate Adoption.

1.3 Delimitação do trabalho

Este estudo tem como delimitação medir somente a percepção de maturidade da empresa dentro do tema *Business Intelligence*, compará-la somente com a percepção de criação de vantagem competitiva e melhoria de performance. A empresa objeto de estudo atua no setor farmacêutico e uma vez que não houve respondentes de outros setores temos como referência somente esse setor. Apesar de, nem todos os respondentes serem brasileiros, a pesquisa se limitou a coletar dados em relação a percepção desses respondentes quanto a subsidiária brasileira. Do ponto de vista temporal, o levantamento de dados aconteceu entre os meses de janeiro e fevereiro e focou somente no estágio atual da empresa, sem que fosse feito um acompanhamento de sua evolução no modelo de maturidade ao longo do tempo.

1.4 Relevância do Estudo

Por muito tempo as áreas de marketing de empresas do setor farmacêutico conviveram com um cenário onde as altas margens garantiam uma lucratividade sem que os indicadores de rentabilidade fossem acompanhados de maneira adequada, um cenário relativamente comum em setores onde as barreiras de entradas permitem que os players dominantes trabalhem com margens maiores que as médias de outros setores.

Porém, em um cenário cada vez mais competitivo, onde todos os setores enfrentam a pressão inflacionária afetando sua lucratividade, as empresas começam a perceber que medir o retorno sobre o investimento de cada iniciativa pode gerar uma vantagem competitiva *versus* seus competidores, uma vez que essa maior rentabilidade poderá se traduzir em maior disponibilidade de caixa para investir em pipeline ou projetos inovadores. Além disso, esse melhor uso dos recursos faz com que a empresa se diferencie dos seus pares também nos canais de marketing onde irão impactar seus clientes, uma vez que, de acordo com dados da Rocketcontent somente 26% das empresas no Brasil medem o *ROI* das diferentes estratégias de marketing.

No setor farmacêutico, o uso de dados para que a decisão que entrega a melhor rentabilidade seja tomada, tem sido empregado aquém da capacidade instalada, tanto em termos de estruturas (capital humano), quanto em relação a sistemas e pesquisas disponibilizadas no mercado. A aceleração do *venture capital*

nos últimos anos criou um grande número de *startups* que revolucionaram o mercado ao focar em solucionar uma demanda não atendida por dados, em um setor onde os dados dos clientes são protegidos por lei e onde os diferentes agentes desse ecossistema (redes de farmácias, atacadistas, operadoras de saúde, hospitais..) tem baixo interesse em compartilhar dados, uma vez que, o maior acesso aos dados do consumidor final é percebido como uma maneira de capturar vantagem em uma eventual negociação com cliente ou fornecedor. Nesse novo cenário, é importante que tomadores de decisão observem essa evolução, não somente como uma forma de fazer pequenos ajustes de rota nas estratégias de marketing que tradicionalmente usadas (visitação de representante, congressos, eventos com sociedades médicas...) mas como um aliado estratégico para que suas alocações de investimento estejam mais alinhadas com as expectativas do cliente.

A maior parte dos estudos da literatura no Brasil sobre o uso de dados para tomada de decisão enfrenta como limitador a falta de acesso a gestores seniores do setor, e enfrentam assim a dificuldade de entender com mais profundidade e pela perspectiva desse cliente interno quanto a evolução na coleta, tratamento e análise de dados otimiza seu processo de tomada de decisão, e quanto dessa otimização se traduz em melhor desempenho com maiores vendas, crescimento, aumento da lucratividade e ganho de participação de mercado. A relevância desse trabalho está em consolidar em uma mesma fonte o estudo de caso com a evolução da estrutura e ferramentas usadas por um departamento responsável por coletar e tratar diferentes tipos de dados, a percepção de gestores sênior da empresa objeto de estudo e a percepção de funcionários de nível intermediário da mesma. Isso permite observar se a evolução no serviço prestado por esse departamento gerou uma mudança de *mindset* e levou decisores de diferentes níveis hierárquicos a mudarem a maneira como tomam decisões, ou seja, passaram a se ancorar em evidências tangíveis (baseadas em dados), se um nível se beneficiou mais que o outro ou se os dois níveis não observaram melhorias e seguem tomando decisões baseadas em grande parte em conhecimento empírico e experiências passadas.

Dessa forma, empresas do setor poderão avaliar, através da observação de erros e acertos mencionados no estudo de caso, se os investimentos relacionados ao desenvolvimento de pessoas, processos e ferramentas para melhoria de coleta e estruturação de dados poderão gerar uma mudança de comportamento nos

tomadores de decisão, saindo de decisões tomadas através do conhecimento empírico para decisões baseadas em dados.

1.5 estrutura do trabalho

Após o capítulo introdutório, os capítulos a seguir estão organizados da seguinte maneira: o capítulo 2 apresenta o referencial teórico do estudo, que fala sobre a relevância da análise dados na administração de um negócio, das limitações da capacidade humana em analisar todos os dados hoje disponibilizados para consulta e como o uso de Inteligência Artificial passou a ser usado para captura e geração de *insights* nas empresas. Apresenta o modelo de maturidade que será aplicado para a empresa objeto da pesquisa com o objetivo de entender a jornada de evolução que a empresa percorreu nesse aspecto, além disso introduz a teoria que servirá para embasar o questionário aplicado como parte da pesquisa. Já o capítulo 3 dedica-se a apresentar a empresa objeto do estudo e explicar os procedimentos metodológicos da pesquisa. Em seguida, o capítulo 4 analisa os dados coletados através de entrevista e questionário, por fim, no capítulo 5 se apresenta as principais conclusões do estudo.

2. Referencial Teórico

Este capítulo apresenta o referencial teórico no qual se baseia a pesquisa, dividido em quatro partes. A fim de contextualização, a primeira parte se propõe a apresentar o momento em que o uso de dados para tomada de decisão começou a ser observado de maneira processual e sistemática dentro do ambiente de negócios, focando em apresentar o funcionamento dos *databases* nos modelos atuais, assim como são definidos os indicadores e *dashboards* que serão acompanhados mensalmente. Em seguida, abordasse com a literatura a diferença entre a evolução na coleta de dados e proliferação de indicadores *versus* a capacidade humana em analisar dados.

Logo após, apresentam-se os conceitos relativos a Inteligência Artificial e *Machine Learning* para captura de dados para construção *de databases* que surgiram na indústria a partir dos anos 2000 como uma forma de acelerar os processos manuais de coleta e que atualmente são usados para cruzamento de dados para geração de *insight*.

2.1 O uso de dados nos negócios

De acordo com Cristina Lago (2018), um pensamento comum dentro de empresas dos seguimentos tradicionais é que usar dados dentro de um ambiente de negócios se trata do mesmo que analisar dados. Porém esse é o processo somente de estudar os dados para tirar conclusões sobre as informações nele contidas, no entanto, usar dados da maneira adequada envolve também os colocar no centro do processo de tomada de decisões estratégicas para a empresa. A esse conceito se deu o nome de *Business Intelligence*.

O termo Business Intelligence, foi usado pela primeira vez por Richard Millar Devens, no livro “Cyclopaedia of Commercial and Business Anecdotes” porém com o advento da digitalização dos dados e a criação de sistemas *de Business Intelligence* o termo se popularizou e passou a fazer parte das rotinas das empresas, conforme podemos observar na tabela abaixo:

Linha do Tempo - *Business Intelligence*

<p>1950 - O começo da Revolução digital</p>	<ul style="list-style-type: none"> ▪ Em 1956 a IBM inventa o disco rígido, com apenas 5MB de memória, mas com a capacidade de mover as informações do físico para o digital ▪ Em 1958 o pesquisador Hans Peter Luhn da IBM escreve um artigo chamado “A business Intelligence System”, onde descreve um sistema capaz de reconhecer uma informação e identificar quem precisa recebê-la
<p>1960 - O início da era dos Computadores e os primeiros databases</p>	<ul style="list-style-type: none"> ▪ Criado no início dos anos 60 o primeiro computador eletrônico, capaz de performar o mesmo trabalho de 50 mil pessoas ▪ Em 1969 o pesquisador da IBM Ted Codd, ele inventou um modelo para relacionar o banco de dados e com sistemas de gerenciamento de dados. Dessa forma o database deixou de ser um repositório de informações para uma ferramenta de consulta de dados para encontrar relações entre diferentes dados
<p>1970 - As primeiras empresas fornecedoras de “BI”</p>	<ul style="list-style-type: none"> ▪ Com o aparecimento de empresas como SAP e JD Edwards disponibilizando ferramentas para construção de <i>databases</i>, as informações passam a estar acessíveis e organizadas para outros negócios
<p>1980 - O nascimento dos “data warehouses”</p>	<ul style="list-style-type: none"> ▪ A década viu o nascimento dos <i>data warehouses</i>, que são sistemas usados para análise e relatórios de dados. Os <i>data warehouses</i> são usados como repositórios centrais de dados integrados de uma ou mais fontes diferentes. Eles armazenam dados atuais e históricos em um único local que é usado

	para criar relatórios analíticos para departamentos separados em uma empresa.
1990 - 2000 - <i>Business Intelligence</i> 1.0 e 2.0	<ul style="list-style-type: none"> ▪ Nos anos 90 houve uma proliferação de ferramentas, talvez a mais popular até hoje o <i>Enterprise Resource Planning</i> (ERP), que é um software de gestão que integra aplicativos para gerenciar e automatizar aspectos de um negócio. ▪ Os anos 2000 trouxeram uma aceleração no desenvolvimento de novas ferramentas de BI, que incorporaram em suas novas versões a capacidades de fazer análises preditivas via algoritmos e <i>machine learning</i> para prever mudanças futuras nos negócios.
2010 – Presente	<ul style="list-style-type: none"> ▪ O uso de ferramentas de BI se tornou padrão para empresas de médio ou grande porte de áreas diversas e funcionam em vários dispositivos usando análises visuais para aplicar raciocínio analítico aos dados por meio de interfaces visuais interativas.

Quadro 1. Linha do Tempo - Business Intelligence

Os sistemas de *Business Intelligence* fornecem informações de negócios de maneira atualizada e confiável permitindo ao usuário entender as implicações das informações de negócios por meio delas analisar os resultados. (Kyere & Ausloos, 2021; Haseeb et al., 2019). A integração da informação, do conhecimento e a sua

transformação em informação útil é feita por sistemas de *Business Intelligence*, o que melhora o fluxo de avaliação de desempenho entre gerentes de todos os níveis hierárquicos da empresa, levando a uma vantagem competitiva (Howson et al., 2018).

Trazendo o tema para realidade de um time comercial, Segundo (Lings & Greenley, 2009) o uso de *Business Intelligence* para o desempenho de vendas pode fornecer aos gerentes de vendas e seus representantes as informações analíticas apropriadas sobre produtos, flutuações de preços, clientes, dados demográficos de clientes, regiões e equipes de vendas. Essas informações podem ser acompanhadas de detalhes do número de vendas realizadas em diferentes períodos, o que acaba levando a tomar a decisão certa no tempo necessário para fornecer o produto certo e manter a quantidade e o nível de vendas da organização, o que leva a prevenção. (Zhi-xiong, Huang K.S.Savitab,2019).

2.1.1 A importância da qualidade no gerenciamento dos dados

Muito se sabe que a competitividade de uma empresa depende de quão efetivamente ela pode fazer uso das informações (Menon & Varadarajan, 1992). Por outro lado, o maior número de dados disponíveis, vindos de diferentes fontes, gerou por consequência um grande aumento na quantidade de repositórios onde essas informações ficam salvas, fazendo com que localizar a base onde um dado específico está armazenado seja um investimento de tempo para o funcionário, além disso, o aumento de dados e repositórios tornou ainda maior o desafio de segregar informações relevantes de irrelevantes, confiáveis de não confiáveis.

Do ponto de vista da qualidade, apenas dois momentos importam na vida útil de um dado: o momento em que é criado e o momento em que é usado. A qualidade dos dados é fixada no momento da criação. Mas na verdade não julgamos essa qualidade até o momento do uso, Thomas Redman (2013). Focando no aspecto da confiabilidade e da qualidade da informação coletada, levando em conta que atualmente ferramentas de *Business Intelligence* já são usadas em todos os níveis de uma organização o potencial de uma informação gerada com base em dados incorretos se propagar por toda a empresa é muito maior que no passado. Conforme observamos na figura abaixo, por conta da maneira como as grandes empresas estão

estruturadas atualmente, o potencial de propagação de erro na coleta e uso de dados é muito grande e o trabalho usado para correção e reparação dos impactos gerados pelo erro demanda esforço em diferentes departamentos.

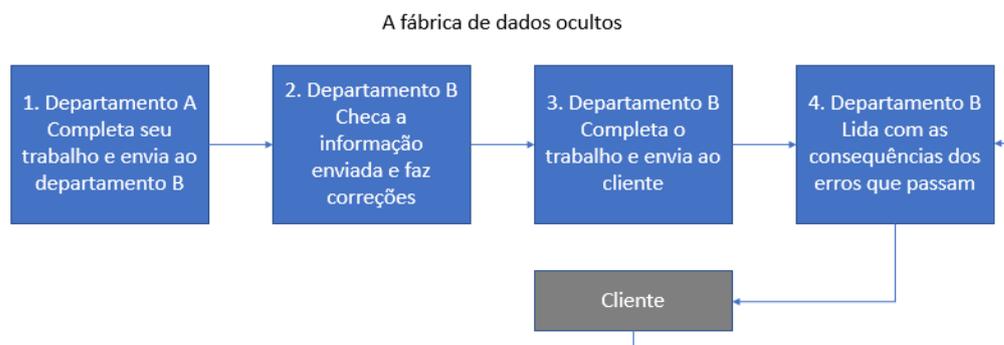


Figura 5. A fábrica de dados ocultos

Para as empresas, dados de má qualidade podem gerar sérios desdobramentos, como análises imprecisas, decisões estratégicas incorretas, impacto nos níveis de satisfação e recompra de clientes, além de multas e punições quando os erros são identificados por órgãos reguladores como no caso de instituições financeiras ou relatórios de pesquisa clínica. De acordo Thomas Redman (2016) a IBM estima que em 2016 o custo total gasto nos Estados Unidos por conta de má qualidade nos dados imputados nos sistemas foi de 3,1 trilhões de dólares. Esse custo percebido fez com que cada vez mais empresas invistam em equipe e soluções focadas no gerenciamento da qualidade dos dados, a fim de evitar problemas futuros e limpar da base dados não confiáveis que poderiam contaminar KPIs e prejudicar o processo de tomada de decisão.

Segundo Rui Pereira (2022), mantendo altos níveis de qualidade de dados as empresas podem se precaver de custos incrementais relacionados a identificar e reparar dados incorretos, evitar erros operacionais e falhas nos processos de negócios, o que no limite pode resultar em aumento nos custos operacionais. A precisão dos aplicativos de análise pode ser aprimorada por uma maior qualidade de dados, o que por sua vez podem aumentar as vendas e satisfação dos clientes, aprimorar os processos internos e oferecer às empresas uma vantagem competitiva sustentada sobre seus concorrentes. Além disso, o aumento da percepção da confiabilidade dos dados pode gerar uma mudança cultural dentro da empresa, uma

vez que, se os usuários tiverem mais confiança nos dados coletados estarão mais inclinados a depender deles, em vez de julgamentos empíricos, para tomar decisões. Por muito tempo, as melhorias relacionadas a qualidade no gerenciamento dos dados focaram na infraestrutura e integração entre os sistemas, no entanto à medida que as soluções de *bigdata* e computação em nuvem evoluíram o perfil de desafio relacionado ao gerenciamento dos dados também mudou. Os tipos de dados coletados atualmente, fluxos em sites, cliques, *log-on* em sistemas, abertura de mails, além do uso de novas tecnologias como *Artificial Intelligence* e *Machine Learning*, que são capazes de abastecer os repositórios com grande quantidade de dados 24 horas por dia, estão tornando o desafio do gerente de dados cada vez maior.

Estudos mostram uma disposição cautelosa entre o público em compartilhar dados de saúde para fins benéficos, desde que estejam confiantes em sua privacidade e segurança de dados (Amy Corman, Rachel Canaway, Chris Culnane, Vanessa Teague 2021), pela afirmativa acima, vinda como conclusão de estudo realizado na Austrália, um outro profissional que viu sua responsabilidade aumentar nesse processo foi o gestor de segurança da informação, uma vez que, se torna cada vez mais desafiador para as empresas serem capazes de extrair voluntariamente a maior quantidade de dados de uma pessoa, a fim de se gerar *insights* com eles, sem que nenhuma política de privacidade seja violada ou que um dado seja disponibilizado em um repositório onde outra pessoa ou empresa possa acessar informação.

Não enfrentar esses desafios pode ter consequências negativas graves para as empresas, no limite, sobrecarga de relatórios, má qualidade dos dados e mal gerenciamento de informações privadas, poderia impedir o uso mais eficaz das informações e por consequência enfraquecer de maneira significativa a competitividade. Além de que, levando em conta que mesmo profissionais de alto rendimento tem um limite de entrega, todo recurso de tempo investido pelo funcionário na consolidação, verificação e manutenção dos dados, significa uma diminuição no tempo que esse funcionário poderá investir em analisar tais dados e gerar *insights* com maior qualidade.

2.1.2 Como são definidos os Indicadores e construídos os *Dashboards*

O sucesso de uma empresa está relacionado a sua capacidade de estabelecer objetivos de curto e longo prazo. O caminho para esse objetivo idealizado é percorrido com base no planejamento estratégico definido pelo time de liderança da companhia. Em resumo, a estratégia de uma empresa é o “como” ela pretende entregar seus objetivos de médio a longo prazo. Para isso, é necessário que a estratégia seja repartida em ações e objetivos intermediários que podem ser monitorados para garantir que as ações de curto prazo da empresa estejam alinhados com sua estratégia para atingir sua visão de longo prazo. De acordo com Graham Kenny (2022), o primeiro passo dos indicadores é identificar os principais *stakeholder* interessados dentro da sua organização ou unidade *Business Unit*. Entenda que seu relacionamento com cada um é uma via de mão dupla, então desenvolva medidas em ambos os lados dessas relações. Pesquisadores de gestão empresarial e sistemas de informação estão cada vez mais focados no uso de inteligência de negócios (BI) para facilitar pacotes amplos de controles de gerenciamento e aprimorar o aprendizado e o desempenho organizacional (Elbashir et al., 2011). A maneira como as empresas optaram por consolidar seus principais indicadores em formato visuais integrados deu-se o nome de *Dashboards*.

Os *Dashboards* são parte integrante de como as informações e análises geradas pelos sistemas de BI são fornecidas aos tomadores de decisão em um formato utilizável. Sistemas de BI são definidos como sistemas que facilitam a análise de dados e a conversão dessa análise em informações acionáveis que podem ser apresentadas ao usuário em um formato que auxilie a tomada de decisão organizacional.

Os sistemas de BI consistem em quatro componentes críticos: (1) infraestrutura, (2) gerenciamento de dados, (3) análises de dados e (4) entrega de informações (Rikhardsson e Yigitbasioglu, 2018). A pesquisa conduzida por LaPointe 2008 aponta que a principal função de um *Dashboard* é apresentar as principais medidas de desempenho, que estão ligados a objetivos para o gestor, área funcional e/ou organização. Os Dashboards mantêm os gerentes focados em metas e objetivos, fornecendo orientação sobre quais atividades são importantes e precisam de atenção, bem como apoiar a tomada de decisões de qualidade (Peng et al., 2007). O desenvolvimento das ferramentas de visualização de dados permite análises mais elaboradas opções de apresentação de dados com funcionalidades

interativas, que permitem que os usuários manipulem e ajustem as informações retratadas para otimizar atender às suas solicitações específicas.

O uso da visualização de dados em formatos de painel está experimentando um crescimento exponencial, especialmente por recém-chegados aos campos B2B. Por exemplo, as principais empresas de software como Tableau e Qlik enfatizam fortemente o uso de sofisticadas ferramentas de visualização como parte da tradução de dados interpretando representações que podem ser compartilhadas facilmente e acionadas dinamicamente (Burns & Rouse, 2017).

Como *Dashboards* muitas vezes criam visões baseadas em métricas, elas melhoram a percepção e compreensão humana, reduzem vieses e aumentam o entendimento comum (Card, MacKinlay, & Schneiderman, 1999). A capacidade de decodificar dados complexos aumenta quando nós humanos mudamos de interpretações textuais para interpretações visuais, pois os estímulos visuais são processados de maneira que é percebida mais rapidamente do que o processamento associado ao verbal estímulo (Townsend & Kahn, 2014). De acordo com Graham Kenny (2020), é importante ver o desempenho como uma via de mão dupla e observar as conexões entre os indicadores e o impacto que um pode ter sobre o outro. E mais, esteja pronto para se adaptar às novas circunstâncias. A importância de evoluir com a cultura de dados dentro da empresa está conectada com os *outputs* positivos que uma implementação bem-sucedida pode entregar. Os ciclos virtuosos gerados pelo aprendizado habilitado por dados podem ser semelhantes aos dos efeitos regulares de rede, em que uma oferta - como uma plataforma de mídia social - se torna mais valiosa à medida que mais pessoas a usam e, finalmente, gera uma massa crítica de usuários que exclui os concorrentes. Mas, na prática, os efeitos de rede regulares duram mais e tendem a ser mais poderosos. Para estabelecer a posição competitiva mais forte, você precisa deles e do aprendizado habilitado por dados. No entanto, poucas empresas conseguem desenvolver as duas, porém sob as condições certas, os dados gerados pelo cliente podem ajudá-lo a construir defesas competitivas, mesmo que os efeitos de rede não estejam presentes (Andrei Hagiu & Julian Wright 2020). Tudo depende se os dados oferecem valor alto e duradouro, são proprietários, levam a melhorias que não podem ser facilmente imitadas ou geram *insights* que podem ser incorporados rapidamente. Essas características dão uma vantagem às empresas. Além disso pesquisa conduzida pela *Salesforce* com aproximadamente 7 mil respondentes demonstra os benefícios que uma empresa

que captura dados, aprende com eles e monta uma régua de relacionamento focada na necessidade que o cliente tem mais chances de colher:

- Lealdade a marca: 95%
- Recomendar a empresa para amigos/parentes: 93%
- Comprar mais produtos e serviços: 92%
- Visitar site ou loja física da marca com mais frequência: 91%
- Aumentar o ticket médio com a marca: 88%
- Compartilhar em suas redes sociais as experiências com produtos da marca: 86%

Os resultados positivos descritos acima podem ser melhor observados através do exemplo de duas empresas de diferentes seguimentos que através do uso adequado dos dados de sua base de clientes puderam escalar seu negócio em um momento crítico para seus setores durante a pandemia da COVID-19.

- 1) **Airstream:** À medida que a indústria de viagens mudava de forma imprevisível sob o bloqueio durante a pandemia da COVID-19, a marca de trailers de viagem Airstream *pivotou* seu negócio e se tornou um recurso do cliente para uma vida pandêmica, lançando produtos virtuais para oferecer a orientação necessária. Depois de reposicionar sua proposta de valor para melhor atender seus clientes, a Airstream teve um aumento de 45% nas vendas ano a ano em maio de 2020 e um aumento de 100% em junho.
- 2) **Lemonade:** A seguradora incorpora a equidade social em sua missão principal, oferecendo termos excepcionalmente flexíveis e doando prêmios não reclamados para organizações sem fins lucrativos à escolha de seus clientes. Em 2020, o CRM escalável da Lemonade e a distribuição suave de dados ajudaram a permitir que seus clientes mudassem de forma rápida e eficiente seus beneficiários sem fins lucrativos escolhidos para ajudar a combater o surto de coronavírus - e dezenas de milhares de seus clientes aproveitaram a oportunidade.

2.2 As habilidades para análise de dados complexos nas empresas

Relacionado à *business analytical*, o termo *big data analytics* descreve os novos métodos e aplicações usadas para em conjuntos de dados muito grandes e complexos para os métodos tradicionais (Chen et al., 2012). Aproveitar efetivamente os dados de negócios para a criação de valor exige que as empresas se concentrem além dos meros aspectos técnicos da implementação de *business analytical* (Vidgen et al., 2017). No entanto, as descobertas da pesquisa e da prática destacam que os principais desafios na obtenção de valor a partir de dados e análises não são tecnológicos, mas organizacionais (Vidgen et al., 2017). Nesse contexto, estudos recentes têm enfatizado que encontrar profissionais qualificados pessoal com o conjunto de habilidades necessárias constitui um grande desafio para empresas dadas as grandes lacunas de habilidades (Grover et al., 2018). A McKinsey previu que haverá uma escassez de 140.000 a 190.000 pessoas com habilidades analíticas, bem como um déficit de 1,5 milhão de gerentes e analistas para BDA e funções de tomada de decisão (J Manyika et al 2011). Tornar-se orientado por dados é complexo e multifacetado, exigindo mudanças em vários recursos organizacionais com envolvimento de vários níveis gerenciais. Abordando isso, o conceito de capacidade de análise de negócios surgiu para indicar a proficiência de uma empresa em alavancar efetivamente seus dados, tecnologia e talento para a geração de insights orientados por dados (Mikalef et al., 2018).

De acordo com Helen Mayhew, Tamim Saleh e Simon Williams em seu artigo Making data analytics work for you—instead of the other way around de 2016 para McKinsey Insights, montar uma grande equipe é um pouco como criar uma receita, é necessário misturar ingredientes e paixão. Os principais membros da equipe incluem cientistas de dados, que ajudam a desenvolver e aplicar métodos analíticos complexos; engenheiros com habilidades em áreas como micros serviços, integração de dados e computação distribuída; arquitetos de nuvem e dados para fornecer insights técnicos e de todo o sistema; e desenvolvedores de interface de usuário e designers criativos para garantir que os produtos sejam visualmente bonitos e intuitivamente úteis. Você também precisa de “tradutores”, homens e mulheres que conectam as disciplinas de tecnologia da informação e análise de dados com decisões e gerenciamento de negócios. A figura abaixo demonstra dentro desse contexto elementos que somente através do desenvolvimento de

cultura e *capabilities* podem levar a empresa a uma jornada bem-sucedida de *business intelligence*:

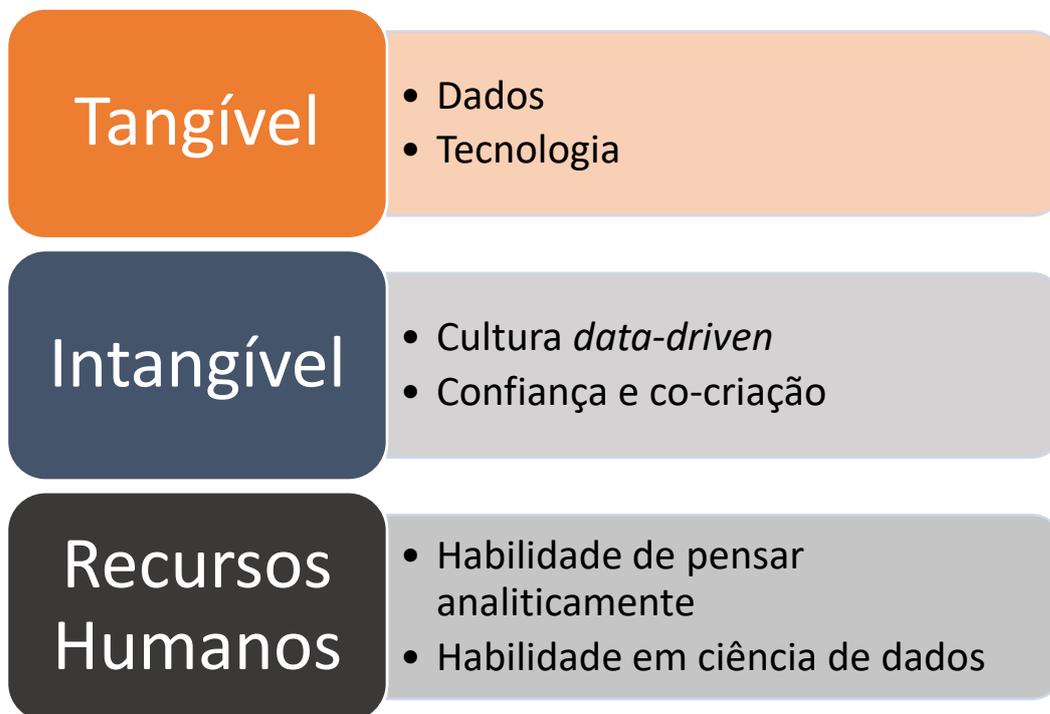


Figura 6. Classificação de habilidades em Business Analytics

As organizações devem ser capazes de implementar efetivamente os recursos de análise de big data para extrair informações valiosas e devem confiar e obter recursos-chave (Mikalef & Pateli, 2017). Em muitas empresas de serviços ao consumidor, a exploração de análises envolve a combinação de dados de transações em vários negócios ou canais. De acordo com Brad Brown, David Court e Paul Willmott, essa abordagem permite que empresas criem insights sobre como os consumidores interagem com sites da Web ou decidem entre fazer compras online ou em lojas físicas. Atualmente existe uma corrida entre as empresas para gerar vantagem competitiva através da coleta de uso de dados. Porém, enquanto algumas empresas se destacam em capitalizar os dados da sua base de cliente, como Amazon ou PanVel no Brasil a maior parte dos *players* ainda não tem confiança que possuem as *capabilities* certas para análise de dados ou mesmo se estão no caminho certo para ter. Um estudo realizado em 2021 pela New Advantage aponta que apenas 39% dos executivos seniores acreditam que suas empresas usam dados como um ativo; 24% desses acreditam que as decisões em suas empresas estão sendo tomadas

orientadas pelos dados. Outra pesquisa de 2021 conduzida pela VentureBeat mostra que apenas 13% dos executivos seniores acreditam que suas organizações estão entregando consistentemente sua estratégia de dados.

De acordo com artigo do *Indeed* Editorial Team, publicado em junho de 2022, o pensamento analítico permite que o funcionário encontre soluções para problemas compartilhados que ocorrem no local de trabalho e tome decisões fundamentadas sobre quais ações tomar. Mostrar esse tipo de iniciativa pode colocá-lo em primeiro plano na mente de qualquer gerente ao considerar funcionários para atividades mais complexas e cargos de liderança. Empresas e organizações precisarão de funcionários que entendem conceitos e métodos de IA, são capazes de usar seus conhecimentos e habilidades para gerenciar o local de trabalho aumentado por IA e são bem versados em colaborar com agentes de IA (Ransbotham, Kiron e Gerbert, 2017). Brad Brown, David Court, and Paul Willmott acreditam, o poder dos dados e da análise está alterando profundamente o cenário dos negócios e, mais uma vez, as empresas podem precisar de mais força da alta gestão (executivos seniores). Capturar oportunidades relacionadas a análise de dados para melhorar as receitas, aumentar a produtividade e criar negócios totalmente novos impõe novas demandas às empresas, exigindo não apenas novos talentos e investimentos em infraestrutura de informações, mas também mudanças significativas nas mentalidades e no treinamento de linha de frente.

De acordo com o predito nesse trabalho, torna-se evidente que, sem o engajamento e o poder de decisão atribuídos aos executivos seniores da organização, não é possível alimentar o ímpeto da análise de dados entre os cargos mais juniores ou pode se dizer que a empresa viveria momentos isolados de evolução, dependente de profissionais específicos, mas a cultura de dados não estaria permeada pela organização e a trajetória de evolução não seria uma constante. A figura abaixo demonstra que para 80% dos líderes entrevistados já entende que AI é um fator que impacta seu resultado financeiro.

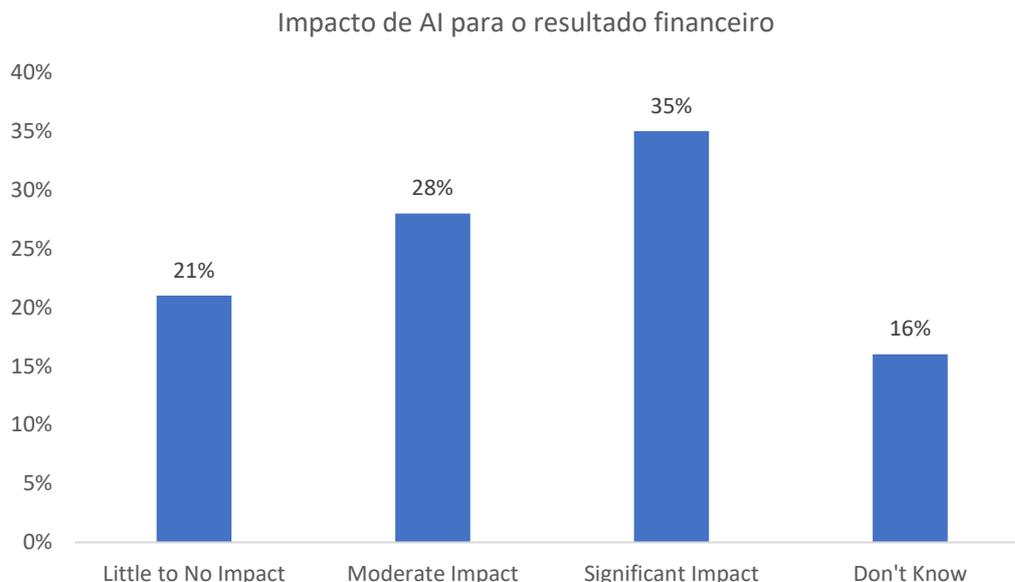


Figura 7. impacto de AI na linha de fundo dos líderes

Fonte: HBR ANALYTIC SERVICES SURVEY, NOVEMBER 2018

Na tabela abaixo, Brad Brown, David Court, and Paul Willmott em seu artigo *Mobilizing your C-suite for big-data analytics* para a McKinsey Insights incluem uma lista de seis recomendações para que o time de liderança implemente uma cultura de tomada de decisão baseada em dados em sua empresa:

Seis tarefas do time de Liderança por trás de uma cultura de análise de dados:

1. Estabelecer novas mentalidades	As equipes seniores que embarcam nessa jornada precisam adquirir conhecimento de análise de dados para que possam entender o que está se tornando viável rapidamente e abraçar a ideia de que os dados devem ser essenciais para seus negócios. Somente quando essa perspectiva de alto nível estiver em vigor é que as mudanças comportamentais duradouras podem se irradiar por toda a organização. Uma pergunta importante a ser feita no início é “Onde a análise de dados pode fornecer saltos quânticos no desempenho?” Este exercício deve ocorrer dentro de cada unidade de negócios significativa e
--------------------------------------	--

	organização funcional e ser conduzido por um executivo sênior com influência e autoridade para inspirar a ação.
2. Definindo uma estratégia de análise de dados	<p>Como qualquer nova oportunidade de negócios, a análise de dados não cumprirá seu potencial sem uma estratégia clara e iniciativas bem articuladas e referências para o sucesso. Muitas empresas vacilam nessa área, seja porque ninguém na equipe principal está explicitamente encarregado de elaborar um plano ou porque não há discussão ou tempo suficiente para obter o alinhamento das prioridades. Em uma empresa de telecomunicações, o CEO estava ansioso para avançar com a análise de dados, principalmente para melhorar os <i>insights</i> sobre retenção de clientes e preços. Embora a empresa tenha se movido com entusiasmo para contratar um líder sênior de análise, o esforço estagnou com a mesma rapidez. Para ter certeza, a equipe de análise fez sua parte, mergulhando na modelagem e na análise. No entanto, os colegas das unidades de negócios demoraram a treinar seus gerentes de nível médio sobre como usar os novos modelos: eles não viam o potencial, que, francamente, não fazia parte de “suas” prioridades estratégicas.</p>
3. Determinar o que construir, comprar, pedir emprestado ou alugar	<p>Outro conjunto de decisões que exige autoridade e experiência de um líder sênior envolve a coleta de dados e a construção de modelos e ferramentas de análise avançada projetadas para melhorar o desempenho. As demandas de recursos muitas vezes são consideráveis. Com uma infinidade de fornecedores externos agora capazes de fornecer dados, modelos e ferramentas essenciais, a experiência da alta administração é necessária para trabalhar nas compensações “construir versus comprar”. Os imperativos estratégicos e as melhorias de desempenho esperadas justificam o desenvolvimento interno e a propriedade intelectual totalmente personalizada em</p>

	<p>análises? Ou atingir a escala rapidamente é tão importante que a experiência e o talento dos fornecedores devem ser utilizados? A criação de ativos de dados poderosos também pode exigir a participação da liderança sênior. Bloquear o acesso a dados externos valiosos, por exemplo, pode depender do estabelecimento de parcerias de alto nível com clientes, fornecedores ou outros atores ao longo da cadeia de valor.</p>
<p>4. Protegendo a experiência analítica</p>	<p>Em praticamente qualquer cenário estratégico, as organizações precisarão de mais especialistas em análise que possam prosperar em meio a mudanças rápidas. O jogo de análise de dados hoje é jogado em uma infraestrutura aberta e (frequentemente) baseada em nuvem que torna possível combinar novos dados externos e internos prontamente e de maneira amigável. O novo ambiente também requer habilidades de gerenciamento para envolver um número crescente de especialistas em estatística profundos que criam os modelos preditivos ou de otimização que garantirão o crescimento.</p>
<p>5. Mobilizando recursos</p>	<p>As empresas geralmente se surpreendem com o árduo esforço de gerenciamento envolvido na mobilização de recursos humanos e de capital em muitas funções e negócios para criar ferramentas de suporte à decisão e ajudar os gerentes de linha de frente a explorar modelos de análise avançada. Um participante sênior capacitado é vital para quebrar as barreiras institucionais que frequentemente dificultam os esforços para turbinar as decisões por meio da análise de dados. O sucesso exige que um grupo diversificado de gerentes se una em torno da mudança, incentivando o alinhamento em uma ampla falange de TI, linhas de negócios, análises e especialistas em treinamento. A possibilidade de fracasso é alta quando as empresas não comprometem a liderança.</p>

<p>6. Construindo capacidades de linha de frente</p>	<p>As soluções analíticas sofisticadas que os estatísticos e cientistas concebem devem ser incorporadas em ferramentas de linha de frente tão simples e envolventes que os gerentes e funcionários da linha de frente ficarão ansiosos para usá-las diariamente. A escala e o escopo desse esforço de adoção – que também deve envolver treinamento formal, treinamento no trabalho e métricas que definem claramente o progresso – não devem ser subestimados. Em nossa experiência, muitas empresas gastam 90% de seus investimentos na construção de modelos e apenas 10% no uso da linha de frente, quando, na verdade, quase metade do investimento em análise deveria ir para as linhas de frente.</p>
--	--

Quadro 2. Tarefas do time de Liderança por trás de uma cultura de análise de dados

Quadro tirado do artigo: *Mobilizing your C-suite for big-data analytics*

2.2.1 A limitação da capacidade humana em analisar dados

Nas economias atuais baseadas em informação, as organizações estão coletando dados de diferentes pontos de contato. No entanto, apenas uma porcentagem mínima desses dados é utilizada para tomada de decisão eficaz. As organizações estão enfrentando uma escassez de profissionais qualificados que podem entender e analisar uma big data e convertê-lo em informações significativas. Um gerente, usando técnicas quantitativas, pode tornar um problema complexo em um problema gerenciável (Sonali Singh, Richa Misra, Shalini Srivastava 2017). As mudanças no ambiente de negócios gerada pela mudança de comportamento dos consumidores criou uma grande oportunidade para as empresas, uma vez que, o mapeamento de toda a jornada do consumidor passou a ser possível já que grandes *players* passaram a atuar não somente como operadores logísticos da última perna da jornada, mas também como ponto de contato entre as indústrias e seus clientes. Além disso se tornaram os principais detentores de informações desse consumidor final. Tal movimento gerou uma inversão de valores dentro da cadeia, uma vez que, o dono da marca passa a não ser mais o principal conhecedor do seu consumidor fazendo com que os que antes atuavam como

prestadores de serviço logístico possam atuar como prestadores de outros tipos de serviços como consultorias, venda de base de clientes e espaço em sites ou grade do time de promoção. Além da inversão de papéis esse movimento acelerou o crescimento exponencial de uma nova indústria focado no armazenamento e organização dos dados que passaram a serem capturados. A transformação digital dos negócios e da sociedade tem aumentado a quantidade de dados disponíveis para análise (Grover et al., 2018). Em pesquisa e na prática, esse volume crescente de dados é chamado de *big data*, esse é o termo usado para descrever conjuntos de dados excessivamente grandes e complexos e extraídos de diferentes fontes, que requerem técnicas avançadas de armazenamento, gerenciamento, análise e visualização (Chen et al., 2012). Esses avançados métodos estatísticos, de processamento e análise são mais conhecidas sob o termo *big data* ou *Business Analytics* (Chen et al., 2012). Do ponto de vista técnico, os *Business Analytics* mais comuns incluem técnicas avançadas com diferentes níveis de inteligência, como descritiva, preditiva, prescritiva e análises autônomas, que por sua vez devem contribuir em diferentes níveis de vantagem competitiva para a organização (Davenport & Harris, 2017).

Por outro lado, os avanços previamente descritos nas áreas de armazenagem e organização dos dados não espelhou na mesma proporção o avanço da capacidade do cérebro humano em analisar, gerar insights ou tomar decisões com base em estruturas complexas de dados. É evidente que a mente, como propriedade emergente de sistemas vivos suficientemente complexos, tem em seu histórico a característica de adaptação ao ambiente, e que suas funções aumentaram com a evolução de sistemas simples para sistemas mais complexos (Roth, 2015). Tendo em vista a importância central dada à evolução do cérebro para explicar o sucesso da espécie, pode-se perguntar se existem limites físicos que restringem seu poder de processamento e potencial evolutivo. O cérebro humano, como vimos, evoluiu de um conjunto de estruturas subjacentes que restringem seu tamanho e a quantidade de informação que pode armazenar e processar. Na verdade, há um número de fatores relacionados que interagem para limitar o tamanho do cérebro humano, fatores que podem ser divididos em duas categorias: (1) restrições energéticas e (2) processamento neural restrições (Herculano-Houzel, 2009;).

Além das restrições espaciais e energéticas, também existem restrições biofísicas relacionadas ao tempo de processamento, indicando que o cérebro

humano atingiu algo próximo dos limites de processamento de informações que um sistema baseado em neurônios permite. Por modelagem a capacidade de processamento de informações por unidade de tempo de um cérebro do tipo humano como função de interconectividade e velocidade de condução axonal, Cochrane et al. (1995) na verdade, a evolução potencial revolucionária do nosso cérebro é limitada pelo delicado equilíbrio mantido entre velocidade de condução, tempo de processamento sináptico e densidade neuronal.

A capacidade do processamento cognitivo dos seres humanos é afetada tanto pela quantidade de dados para processamento quanto pela maneira como os dados são apresentados (Sweller, van Merriënboer, & Paas, 1998). Se o formato das visualizações sobrecarrega a capacidade cognitiva, então seu valor é diminuído (Paas et al., 2003). Ou seja, quando é atingido o ponto de inflexão quando a visualização de dados de informações complexas não é mais vantajosa. Uma variável influente é a sobrecarga cognitiva, fator crítico para o sucesso da visualização de dados em *dashboards*. Ela se ocupa com o esforço mental gasto quando uma determinada tarefa é realizada ou analisada (Paas, Tuovinen, Tabbers e van Gerven, 2003). A presença de grandes conjuntos de dados pode causar sérios problemas nos sistemas de apoio à decisão de uma organização. Um grande volume de dados obscurece padrões, tendências, surpresas, e outras características importantes. A visualização de dados ajuda na tomada de decisões, a descobrir padrões e tendências, melhorando a eficiência e eficácia do decisor. No entanto, visualizar toda a gama de grandes dados é muitas vezes inviável. A Exploração, manipulação e análise de dados tornam-se mais complexa e o consumo de recursos cresce à medida que os tamanhos dos conjuntos de dados aumentam. Por outro lado, a capacidade dos tomadores de decisão de filtrar, sintetizar e utilizar dados diminui na mesma proporção. (Stephen Russell, Aryya Gangopadhyay, Victoria Yoon 2008). De acordo com Justin Fox da Harvard Business Review, os pesquisadores nos confrontaram nos últimos anos com exemplos de como humanos, erram quando se trata de tomar decisões. Se entende mal a probabilidade, tem miopia sobre os dados, prestam atenção nas coisas erradas e geralmente não tomam a decisão ótima. Os estudos sobre “heurísticas e vieses”, iniciados nos anos 70 pelos psicólogos Daniel Kahneman e Amos Tversky em Stanford, alertaram para as falhas nas tomadas de decisão que o cenário macroeconômico há muito encobria e geraram

contribuições e inovações no planejamento da aposentadoria e nas políticas governamentais.

Outro fator limitante para o melhor uso dos dados capturados é a maneira como matérias quantitativas como Cálculo ou estatística é percebida pelos estudantes de escolas e universidades. O entendimento sobre o valor gerado pelos cursos (matérias) tem um enorme impacto na motivação para a aprendizagem de disciplinas quantitativas. Uma vez que os alunos encontram estes cursos quantitativos difíceis, seu interesse diminui e isso, por sua vez, afeta sua compreensão (Pajares & Graham, 1999). Para cursos de graduação onde a carreira do profissional está direcionada para análises quantitativas como estatísticos ou cientistas da computação fica claro a importância de se aprofundar nesse conteúdo, porém para alunos de cursos que combinam disciplinas de negócios com cálculo, como Engenharia de produção ou Administração de empresas estabelecer a relação que um aprendizado desses métodos quantitativos iria ajudá-los a melhorar a sua aptidão, habilidades analíticas e tem aplicabilidade nos seus empregos futuros, não é tão fácil, eles não são incapazes de entender sua relevância em seu esforço profissional. A relevância pode ser definida como algo que é benéfico e se tem mérito em saber, logo se o conteúdo do curso é considerado relevante alunos farão o possível para aprender. O objetivo do ensino superior é desenvolver a empregabilidade dos estudantes. O currículo é concebido de tal forma que motiva os alunos a ingressarem no ensino superior. Uma pesquisa com alunos da escola estabeleceu que a maioria dos alunos indicou que a justificativa para ir para a universidade é 'estudar em um curso que realmente me convém', juntamente com três razões: (i) ter uma carreira profissional, (ii) melhorar minhas perspectivas de emprego, (iii) entrar em uma carreira bem remunerada' (O'Connor, Bredenkamp, Rutter et al., 1999).

2.2.2 Ruídos: Tipos de ruídos que impactam as análises e como evitá-los

Além das limitações humanas no que tange capacidade de armazenar e analisar dados, outro fator que pode comprometer uma análise são os Ruídos. Diferentemente das limitações cognitivas antes mencionadas, que impedem que a análise seja realizada, esse fator não impede que a análise gere um *insight* para o profissional que a realiza, porém leva a uma captura ou análise errônea dos dados e

por consequência uma tomada de decisão errada, ainda que a princípio se mostre uma decisão *data-driven*. Trataremos de 3 tipos de Ruídos identificados durante a pesquisa: (i) o ruído estatístico; (ii) ruído na mineração de dados; (iii) ruído na interpretação dos dados (Gareth M.James 2018; Hand et al., 2000; Fournier, 2005)

Ruído Estatístico: Ao longo do século passado, o campo da estatística deu contribuições significativas aos esforços voltados para o desenvolvimento racional e interpretações objetivas de dados e informações em geral. Além disso, pode haver pouca dúvida de que a proeminência e as estaturas voltadas a esse campo cresceram consideravelmente nos últimos 20 anos. Esse crescimento foi impulsionado principalmente pelos desenvolvimentos fora das estatísticas, em particular os avanços tecnológicos que criaram vastas quantidades de novos e complexos tipos de dados, e correspondentemente nos forneceu o mecanismo para sua análise (Gareth M.James 2018). O crescimento das bases e automatização das análises aumentou os casos desse tipo de ruídos nas análises. O ruído estatístico pode ser definido como um termo que se refere à variação inexplicável ou aleatoriedade que é encontrada dentro de um determinado dado amostral. Existem duas formas primárias disso: erros e residuais. Um erro estatístico é simplesmente a parte do valor final que difere do valor esperado que foi assumido como sendo a resposta correta, já um resíduo é o resultado de uma estimativa mais casual de o resultado esperado. A noção geral por trás do ruído estatístico é que um determinado conjunto de dados não é necessariamente preciso e pode não ser capaz de ser duplicado se a mesma informação for coletada ou calculado mais de uma vez.

Conforme mencionado acima, com o aumento na capacidade de captura de dados muitas empresas aumentaram sua demanda por habilidades relacionadas ao conhecimento em estatísticas. Esse novo modelo faz com que informações sejam usadas para identificar preferências do cliente, hábitos de compra ou eficiência de estruturas operacionais, porém embora gerar *insights* com bases estatísticas é uma ótima maneira de obter uma melhor compreensão de como tomar decisões dentro de um ambiente de negócios, o processo também pode gerar *insights* sem valor e isso é onde o ruído estatístico deve ser considerado. Como exemplo podemos mencionar um fabricante de embalagens que faz análises com base na capacidade máxima de suas máquinas dentro de um período de tempo, mas não considera fatores que influenciam tal capacidade como qualidade do produto, qualidade da matéria-prima, avarias nas máquinas ou erro do operador. Ruído estatístico seria

levado em consideração, removendo os efeitos daqueles elementos que são simplesmente improvável que ocorra durante um turno típico, porque incluí-los não resultaria em uma imagem verdadeira da média produção.

Ruído na mineração de dados: A mineração de dados é o processo de identificar padrões interessantes de grandes quantidades de dados (Hand et al., 1999), onde a análise de dados exploratórios estatísticos não conseguiu descobrir dados úteis insights (Hand et al., 2000). A mineração de dados fornece a metodologia e a tecnologia para trans-transformar grandes quantidades de dados em *insights* úteis para decisões de negócios (Dash et al., 2019). Dentro do processo de mineração pode-se identificar esse tipo de ruído, que acontece quando uma grande base de dados inclui dados adicionais que não agregam para a análise, podendo se tratar de dados corrompidos ou dados que uma ferramenta ou profissional não consegue entender e interpretar corretamente. Como por exemplo, ferramentas que não conseguem analisar com base em textos não estruturado. Dados ruidosos afetam negativamente os resultados de qualquer análise de dados e gerar conclusões distorcidas se não receberem o tratamento adequado, como por exemplo uma análise estatística que pode usar informações de dados históricos para eliminar dados ruidosos, porém procedimentos inadequados de tratamento dos dados podem levar a uma falsa sensação de precisão ou validar falsas conclusões. Além disso, os dados ruidosos aumentam desnecessariamente a quantidade de espaço de armazenamento necessário.

Ruído na análise dos dados: A avaliação é orientada por valores (Fournier, 2005), coloca todos os aspectos naturais e ciências sociais para trabalhar, baseia-se em um kit de ferramentas metodológicas bem abastecido (Scriven, 2003). Assim, valor, métodos e usabilidade são os três ramos da 'árvore da teoria da avaliação', a metáfora influente que descreve o surgimento da avaliação como uma disciplina e exhibe os nomes de eminentes pensadores de avaliação (Alkin e Christie, 2004). Por outro lado, conforme expõe Calaprice (2000) Toda teoria é baseada em suposições que não são totalmente verdadeiras. Isso é o que torna a teoria. O que separa a boa e a má teoria é o limite definido pela versão de Einstein da Navalha de Occam: “Tudo deve ser feito o mais simples possível, mas não mais simples”. Ainda sobre manter o julgamento disciplinado a pesquisa de Gigerenzer (2014) mostra que na tomada de decisões muitas vezes menos é mais e realmente precisamos mantê-lo simples, ou pelo menos torná-lo simples para evitar agir estupidamente.

Quando se trata do ambiente de negócios as organizações esperam ver consistência nas decisões de seus funcionários, mas os humanos não são confiáveis. Os julgamentos podem variar muito de um indivíduo para outro ainda que esses analisem os mesmos dados e tenha as mesmas informações em mãos, para a esse fenômeno podemos chamar ruído na análise dos dados. Alguns trabalhos são livres de ruído. Os funcionários de um banco ou correios realizam tarefas complexas, mas devem seguir regras rígidas que limitam o julgamento subjetivo e garantem, por design, que casos idênticos serão tratados de forma idêntica. Em contraste, profissionais médicos, agentes de crédito, gerentes de projeto, juízes e executivos fazem julgamentos, que são guiados pela experiência informal e princípios gerais, e não por regras rígidas. E se eles não chegarem exatamente à mesma resposta que qualquer outra pessoa em seu papel, isso é aceitável; isso é o que queremos dizer quando dizemos que uma decisão é “uma questão de julgamento”. Uma empresa cujos funcionários exercem julgamento não espera que as decisões sejam totalmente isentas de ruído (Gonny Gong 2016), porém conforme sinaliza Gonny Gong em seu artigo para Harvard Business School o ruído costuma ser insidioso: faz com que até empresas bem-sucedidas percam quantias substanciais de dinheiro sem perceber e completa indicando que “o valor capturado ao reduzir o efeito do ruído nas decisões, ainda que em poucos pontos percentuais, seria na casa das dezenas de milhões de dólares, valor significativo mesmo para uma grande empresa, mas surpreendentemente, as organizações não demonstram o mesmo apetite em reduzir seus efeitos em comparação com o que demonstram para lançar novas linhas de negócios ou encontrar novas fontes de receitas.”

Conforme mencionado acima, observamos que os ruídos fazem parte de toda a jornada, desde a captura dos dados, passando pelo modelo matemático usado para modelar a análise até o próprio julgamento humano, seus impactos são subdimensionados pelas empresas, mas acredita-se com base na pesquisa para construção deste trabalho que o impacto na economia americana seja na casa dos bilhões de dólares. Daniel Kahneman, reconhecidamente um dos maiores especialistas sobre o tema aponta em seu livro Ruído: Uma falha no julgamento humano, alguns elementos que se adotados pelas empresas poderiam ajudar na mitigação dos impactos gerados pelo Ruído na análise dos dados, (i) como a realização de uma auditoria de ruído, onde um cientista comportamental apoia na análise das escolhas realizadas por diferentes membros da equipe e gera um

relatório com o objetivo de melhorar a compreensão do entendimento do pensamento de membros da equipe ou aumentar a utilidade das ferramentas de suporte a tomada de decisão; (ii) descartando o ruído, onde busca-se reduzir o efeito do ruído através da criação de regras padrão, ou algoritmos de tomada de decisão, minimizando o elemento humano dentro do processo, pode-se observar bastante benefício quando o único foco é prevenir erros, porém pode engessar o processo e impossibilitar *inputs* valiosos ou falhar em eventos com *outliers* (iii) Trazendo disciplina ao julgamento, pode ser uma alternativa ao (ii) descartando o ruído, se tratam de procedimentos que promovam a consistência, garantindo que os funcionários na mesma função usem métodos semelhantes para buscar informações, integrá-las em uma visão do caso e traduzir essa visão em uma decisão.

2.2.3 Como vieses e intuições prejudicam o processo de tomada de decisão

Os modelos de tomada de decisão com base em preferências fazem com que o comportamento do tomador de decisão seja influenciado por seu ponto de vista ou referências anteriores. No entanto, pontos de vista não são naturalmente observáveis, o que significa que para analisar uma decisão tomada com base em um ponto de vista ou experiência anterior do tomador de decisão é preciso analisar como eles foram gerados. (David J. Freeman 2017). Ariely, Loewenstein e Prelec (2003) demonstram que a primeira escolha em um ambiente novo, mesmo quando arbitrária, pode servir como a base sobre a qual as escolhas subsequentes se baseiam e com os quais são comparados. As experiências iniciais podem afetar as preferências, elementos que validam tal afirmativa podem ser encontrados através de testes dos mecanismos de ancoragem e ajuste de acionamento (Chapman & Johnson, 1999). Hoeffler e Ariely (1999) examinaram o processo como preferências são aprendidas e desenvolvidas ao longo do tempo em um ambiente completamente novo. Estruturaram os estudos com sujeitos fazendo uma série de escolhas, analisando os resultados Hoeffler e Ariely descobriram que o tipo de experiência inicial, por exemplo, escolhas fáceis ou escolhas difíceis tiveram um efeito duradouro nas escolhas subsequentes dos sujeitos em um ambiente semelhante. Notavelmente, as primeiras experiências tendiam a ter efeito mais duradouro quando a escolha foi tomada deliberadamente, isso é, quando as pessoas consideram

explicitamente os trade-offs implícitos em suas decisões. Além disso, pesquisas com agentes inteligentes colaborativos demonstraram que os agentes que baseiam suas recomendações em experiências anteriores favoráveis continuam a recomendar as mesmas opções e não conseguem dar um feedback claro com o diagnóstico de porquê escolheu uma opção em meio a diferentes opções (Ariely, Lynch, & Aparicio, 2004). Tal contexto teórico pode ser melhor entendido como exemplo a seguir de pesquisa conduzida por Blue em 2002 em seu guia sobre vinhos, Quase toda semana alguém me pergunta: “Como devo começar se eu quiser aprender sobre vinho?” Comece com vinhos simples e baratos, e suba até as garrafas de maior qualidade. Tente a maior variedade de vinhos. Tentando tudo é a única maneira de construir sua memória sensorial e descobrir seus próprios gostos. Você nunca fará nenhuma progressão com vinhos se mantiver os mesmos Chardonnay ou Cabernet Sauvignon, não importa o quanto você goste deles. Os resultados desta pesquisa sugerem que o progresso no desenvolvimento de preferências por vinhos é dificultado pela tendência de ficar com seus favoritos. Nós discutimos que a seleção inicial de favoritos cria um viés na exploração de preferências, em que produtos potencialmente superiores não são avaliados de maneira adequada (Hoeffler, Ariely, & West 2006).

Além das primeiras experiências criarem uma memória que pode gerar um viés apontando para uma decisão específica, pode também criar uma miopia para outras alternativas, focando somente em alternativas que correspondam às suas preferências. Além disso, envolve um conflito entre dois objetivos: um desejo de curto prazo de experimentar resultados favoráveis e um desejo de longo prazo de aprender, a fim de aumentar o número de experiências que terão utilidade no futuro. Os sujeitos que foram expostos a uma perspectiva de longo prazo mostraram menos efeitos de miopia e estavam dispostos aceitar mais riscos em suas escolhas (Benartzi & Thaler, 1999). Este conflito é impulsionado pelos custos associados com a vida de uma pessoa experimentando alternativas potencialmente inferiores na rota para finalmente encontrar os superiores (Moorthy, Ratchford, e Talukdar, 1997). Qualquer tipo de aprendizagem, emana do desejo de melhorar no longo prazo, não está claro se os tomadores de decisão a paciência que tal processo requer (Laibson, 1997).

Outro efeito que impacta tanto decisões de negócios, investimentos e consumo, e por consequência o cenário macroeconômico, são os vieses. A visão

tradicional em economia e finanças é que apenas os resultados importam, isso leva a uma forte presunção de que os vieses comportamentais não desempenham um papel no agregado porque eles são calculados pela média ou são corrigidos por arbitragem racional, ou seja, se assume que os vieses podem apontar para os dois lados e seus efeitos se anulariam. No entanto, Barberis e Thaler (2003) argumentam que a arbitragem não pode eliminar todos os efeitos dos vieses comportamentais nos mercados. Mas ainda que possam no nível macroeconômico, no nível individual certamente ainda seria uma informação valiosa se alguém pudesse de alguma forma discriminar entre indivíduos que são menos ou mais afetados por fenômenos comportamentais. Por exemplo, esta informação seria útil quando aplicada a potenciais funcionários ou clientes. Em particular, se estivesse disponível um teste conciso que pudesse ser administrado em poucos minutos, mas revelaria muito sobre a probabilidade de que esses indivíduos tenham uma série de vieses bem conhecidos na tomada de decisões, tal teste deve ser bastante instrutivo (Oechssler, Roeder, & Schmitz 2009).

Os vieses podem também ter um papel relevante no processo de planejamento estratégico e de cenários das empresas, Schoemaker (1993) e Bradfield (2008) foram os primeiros a analisarem empiricamente a influência dos vieses no planejamento estratégico e de cenários. Eles se basearam inicialmente nos benefícios cognitivos do método de planejamento de cenários, mostrando que poderia reduzir o viés de excesso de confiança e o viés de confirmação (P.J.H. Schoemaker 1993), (R.M. Bradfield 2008). Porém eles não conseguiram demonstrar através de sua pesquisa se o planejamento de cenários também reduz outros vieses cognitivos e em quais etapas do processo do planejamento de cenários geram o efeito de *debiasing*. (Meissner & Wulf 2012). Uma vez identificado que os vieses podem impactar no processo de planejamento estratégico de uma organização, alguns pesquisadores voltaram seus estudos para técnicas que ficaram conhecidas como *debiasing*. As técnicas de *debiasing* são métodos que neutralizam os erros de julgamento e melhoram a qualidade das decisões estratégicas (K.L. Milkman, D. Chugh, M.H. Bazerman, 2009) reduzindo vieses através dessas técnicas as decisões são tomadas de maneira mais racionais (D.J. Koehler, N. Harvey 2004). O planejamento de cenários pode ser uma técnica apropriada de eliminação de vieses devido às suas características cognitivas positivas. Um primeiro benefício observado no planejamento de cenários reside no fato de que

visa desenvolver múltiplas visões de possíveis dos futuros, fornecendo diferentes visões dos resultados das estratégias e dos diferentes planos de contingências que precisariam ser criados para implementação (K. van der Heijden 2005). Dessa forma faz com que tomadores de decisão considerem diferentes elementos que poderiam ter sido desconsiderados ou ignorados anteriormente. Tal método, gera uma ampliação de perspectivas que tem se mostrado eficaz para reduzir vieses e melhorar a qualidade das decisões (J.B. Soll, J. Klayman 2004). O planejamento de cenários promove mudança cognitiva nos modelos mentais dos tomadores de decisão, desafiando as suposições existentes e abrindo o leque de possibilidades desenvolvimentos futuros que são considerados (P. Wack, 1985). Outro fator que deve ser observado para implementação do método é o processo feedback, uma vez que, isso aumenta o nível de troca de informações entre os participantes e pode alterar suposições e crenças existentes (A.D. Galinsky, L.J. Kray 2004).

2.3 O uso de Inteligência Artificial (IA) como ferramenta de negócios

A evolução da inovação tecnológica nas organizações tem recebido maior atenção no meio acadêmico, uma vez que, as empresas vêm alavancando cada vez mais projetos para o desenvolvimento de novas tecnologias para melhorar sua capacidade inovar e colher os frutos dessa inovação (Wamba-Taguimdje et al.2020). As organizações reconheceram que ao incorporar tecnologias modernas suas capacidades de gerar negócios e operações podem aumentar sua vantagem competitiva, se colocando a frente dos competidores em processos de inovação (Spanjol et al., 2018). A inteligência artificial (AI) é uma das tecnologias que permitem que os negócios avancem e cresçam na era digital, influenciando como as empresas inovam (Verganti et al., 2020). Além disso, pode desenvolver-se com base em novas informações ou como resultado de experimentação. Tudo isso pode acontecer em uma escala que um ser humano não seria capaz de calcular e, portanto, foi sugerido que as tecnologias habilitadas pela inteligência artificial podem tornar-se uma clara fonte de vantagem competitiva para as organizações (Kumar et al, 2019).

De acordo com pesquisa realizada pela Harvard Business Review com mais de 400 líderes empresariais, a automação aprimorada por meio de inteligência artificial (IA) é fundamental para capacidade das organizações de competir e sobreviver nos próximos anos. Os entrevistados dizem que, para serem bem-

sucedidas, suas organizações devem incorporar mais AI e automação em seus processos de negócios. No entanto, poucos têm feito isso de forma significativa. É uma situação perigosa, pois os próprios entrevistados dizem que as consequências de não investir seriam devastadoras para o longo prazo saúde de seus negócios. No mundo dos negócios, a percepção de valor capturado com AI é em última análise, ligada à sustentabilidade e ao sucesso contínuos de um negócio (H. Chen, Chiang, Storey, & Robinson, 2012). De acordo com Marcello M. Mariani, Isa Machado & Satish Nambisan (2022) em seu artigo *Types of innovation and artificial intelligence: A systematic quantitative literature review and research agenda*, a AI se tornou relevante para diferentes áreas da organização:

2.3.1 Finanças

A implementação da IA em finanças tem sido investigada em relação ao desenvolvimento de produtos e serviços financeiros (Alidrisi, 2021) assim como para desempenho e previsão de resultados (Manuylenko et al., 2021)

2.3.2 Planejamento Estratégico

Projetar e implementar processos baseados em AI permite que as empresas melhorem suas estratégias para criar valor para o cliente, aprimorando produtos e serviços (Chaudhuri et al., 2021). Com AI, as empresas podem aprimorar seus processos gerando desenvolvimento sustentável de processos de inovação e operação (Makowski & Kajikawa, 2021). Além disso, a AI desempenha um papel importante na inovação dos modelos de negócios das empresas, apoiando a reconfiguração de estratégias e negócios para o sucesso (Burstrom et al., 2021; Fukawa et al., 2021)

2.3.3 Gestão de Recursos Humanos

O capital humano é crucial para o sucesso das empresas, o investimento em habilidades de recursos humanos e a educação é um fator importante para a implantação de sistemas de AI. A implementação de sistemas de AI tem sido investigada em relação à produtividade e desempenho (Cheah e Wang, 2017), design, desenvolvimento e planejamento de rotinas de trabalho (Jazdauskaite et al., 2021; Prem, 2019) e compliance (Arias-Perez & Velez-Jaramillo, 2022). A IA

contribui para criar profissões, prever a rotatividade e gerenciar a força de trabalho (Jazdauskaite et al., 2021; Prem, 2019)

2.3.4 Empreendedorismo

A IA foi examinada em relação ao empreendedorismo digital (Battistiet al., 2022; Yu et al., 2016) e ecossistemas empreendedores (Cetindamar et al., 2020; Sun & Zhang, 2021). A implantação da IA desempenha um papel fundamental no desenvolvimento do empreendedorismo digital; customização de produtos e serviços como um meio competitivo e estratégia empreendedora, identificar e adquirir conhecimentos, gerenciando projetos de inovação para novos produtos e serviços por meio da análise de inovação (Kakatkar et al, 2020; Mariani & Nambisan, 2021). A IA também desempenha um papel fundamental nos ecossistemas do empreendedorismo para compartilhar informações, criar e difundir novos produtos e fomentar a evolução da inovação.

2.3.5 Marketing

A implementação da IA para área de Marketing tem sido investigada em relação ao comportamento do consumidor (Acar & Toker, 2019; Masih & Joshi, 2021), análise do consumidor (Erevelles et al.,2016; Johnson et al., 2019), análise de serviço (Aker et al., 2021) e capacidades de gerenciamento de marketing, atividades e estratégias. Embora a maior parte do interesse de marketing nesta área se concentra nas respostas do consumidor à inteligência artificial, sua prática e aplicação, os resultados desta quarta revolução industrial permanecem abertos a várias possibilidades (Syam & Sharma, 2018). Existem amplas oportunidades para usar tecnologias de IA em marketing: por exemplo, para identificar e entender clientes existentes (Loureiro, Guerreiro, & Tussyadiah, 2021); para gerar insights de dados de compra do cliente (Wright et al., 2019); identificar concorrentes atuais (Huang & Rust, 2021); e para segmentar e atingir novos clientes (Martínez-Lopez & Casillas, 2013). A respeito disso, adotamos a definição de Marketing AI como o desenvolvimento de agentes artificiais que, dadas as informações que possuem sobre os consumidores, competidores e a empresa, sugerem ou aceitam ações para alcançar o melhor resultado de marketing (Overgoor et al., 2019). Avanços tecnológicos frequentemente levam a mudanças estruturais nos paradigmas de

negócios, como é o caso da AI em marketing (Kumar, Rajan, Venkatesan, & Lecinski, 2019). As melhorias nas AIs disponíveis permitem que as empresas se mantenham competitivas em cenários de marketing cada vez mais orientados a dados (Yoganathan, Corporan, Jansen, & Jung, 2019; Smart Insights, 2018), muitas empresas vem investindo nelas para facilitar várias tarefas relacionadas ao marketing, como chatbots, otimização da jornada do cliente, pesquisa e criação de conteúdo, gerenciamento de relacionamento com o cliente, reconhecimento de imagem, mecanismo de pesquisas de otimização, personalização do cliente, criação e planejamento estratégico (Haenlein & Kaplan, 2019; Zhao, 2013).

2.3.6 O uso de Inteligência Artificial (IA) focada em Marketing

A adoção de inteligência artificial em diferentes processos de marketing está abrindo várias oportunidades para os profissionais de marketing e gerando interesse quanto às suas diferentes aplicações entre os praticantes (Fagella, 2018). De uma perspectiva estratégica, a AI está se tornando cada vez mais importante em marketing, empresas como Google, Spotify e Under Armor estão entre as empresas que aprimoram seu desempenho por meio da adoção de plataformas baseadas em AI. Essa abordagem aumenta a interação com os clientes em todos os canais de marketing e melhora a previsão dos movimentos de mercado e a automação de processos (Bozidar Vlacica et al 2022). Por consequência, a AI tem sido reconhecida como a tecnologia mais influente para os negócios, com crescimento esperado de US\$ 10,1 bilhões em 2018 para US\$ 126 bilhões até 2025 (Tractica, 2020). Uma pesquisa recente entre líderes empresariais revelou que uma área prioritária para aplicação da AI é em vendas e marketing, com 24% das empresas americanas que já usam AI e 60% esperam usá-la até 2022 (MIT Technology Review Insights (2020).

O marketing depende cada vez mais de seus algoritmos, que imitam as funções cognitivas humanas e exibem aspectos da inteligência humana (Huang & Rust, 2018; Rangaswamy et al., 2020). 72% dos profissionais de marketing citam a AI como uma vantagem competitiva, os consumidores se beneficiam dessas aplicações na forma de redução de custos, canais de atendimento mais diversificados, avanços inovadores, e oportunidades para expandir a criatividade e engenhosidade humana quando tarefas tediosas e repetitivas são executadas pela AI (Haenlein & Kaplan, 2019; PricewaterhouseCoopers, 2017). Essa revolução do uso

da IA no marketing e seu potencial para produzir resultados de valor superior, despertou atenção substancial da pesquisa (Davenport, Guha, Grewal e Bressgott, 2020), levando, por exemplo, aplicações de inteligência tecnológica (Marinova, de Ruyter, Huang, Meuter, & Challagalla, 2017), descrições de serviços habilitados, facilitados e entregues por várias tecnologias (Rust & Huang, 2012), investigações em robótica (Lu et al., 2020; Wirtz et al., 2018), inovação em estratégias de marketing e vendas lideradas por AI (Davenport et al., 2020); considerações de como a entrega habilitada por AI pode levar a um serviço econômico de excelência (Wirtz & Zeithaml, 2018; Wirtz, 2020), propostas de modelos de negócios em plataformas digitais (Wirtz, So, Mody, Liu e Chun, 2019), investigações sobre o impacto das divulgações do chatbot de AI em compras de clientes (Luo, Tong, Fang, & Qu, 2019), considerações de efeitos nas forças de trabalho (Davenport & Kirby, 2015), redefinições de locais de trabalho (Chui, Manyika, & Miremadi, 2015); e discussões das tecnologias digitais como forças motrizes do trabalho e da vida (McAfee & Brynjolfsson, 2016).

2.3.2 Desafios para adoção de AI e *Machine Learning* para tomada de decisão e como isso ainda não é uma realidade

Apesar dos grandes avanços descritos nos capítulos anteriores, a literatura mostra que ainda existem pontos de desconforto entre os tomadores de decisão de seguir uma recomendação de uma AI ou ML sem que seja criticada por um humano. Pesquisas mostram que os humanos tendem a rejeitar decisões tomadas por IAs, em particular quando ocorrem erros (Moon, 2003; Dietvorst, Simmons, & Massey, 2015) ou quando os humanos se sentem menos responsáveis (Promberger & Baron, 2006). De acordo com Davenport (2015) mesmo quando a automação inteligente não requer intervenção humana, algumas empresas permitem que os funcionários substituam as decisões no início, até que eles reúnam dados suficientes para provar resultados. Os humanos tendem a preferir conselhos de algoritmos ao julgamento humano apenas em certas situações como tarefas objetivas ou numéricas (Castelo, Bos, & Lehmann, 2019). Não é de surpreender, portanto, que muitos gerentes de marketing continuem cautelosos sobre a utilização total de IA e ML na tomada de decisões, apesar de reconhecer seu potencial. (Davenport & Kirby, 2016). Além disso, conforme evidenciado na literatura, o uso desproporcional de ferramentas de AI por gerentes seniores pode gerar tensões entre a ferramenta de AI e os gerentes

subordinados, que podem se sentir menos valorizados ou compreendidos (Wortmann, Fischer, & Reinecke, 2018). Em última análise, o nível de utilização das AIs pode provocar medo de substituição da mão-de-obra humana pela robótica (Granulo et al., 2019) prejudicando assim a uma relação entre a empresa e seus consumidores (Fuchs, Schreier, & van Osselaer, 2015; van Osselaer et al., 2020). Por exemplo, em um estudo feito usando mensagens idênticas, uma gerada por um computador e a outra por um humano mostrou que a gerada pelo humano foi avaliada como significativamente mais agradável que a gerada pelo computador (Gray, 2012). Isso levanta questões sobre se a migração massiva de processos para AI pode fazer as empresas perderem seus clientes (Leung, Paolacci, & Puntoni, 2018). Além disso, se AI e ML forem utilizados para identificar, segmentar e reter clientes-chave por meio de ofertas personalizadas, empresas devem adaptar suas atividades para evitar a violação da privacidade dos dados (Leslie, Kim, & Barasz, 2018).

De acordo com a pesquisa *The rise of automation* realizada pela Harvard Business Review - *Analytic Services Survey* (2018), que entrevistou cerca de 400 leitores vindos de diferentes indústrias e com níveis diferentes de senioridade, especialistas acreditam que o emparelhamento AI com um ser humano é essencial para o adoção segura e bem-sucedida de AI para além das tarefas repetitivas e rotineiras que já foram implementadas na maioria das organizações. Precisamos descobrir como vamos auditar as decisões que as máquinas estão tomando, ou precisamos manter um humano no circuito (Forrester Gownder 2018). Colaborar com as AIs exige que os próprios funcionários e gerentes mudem a forma como eles trabalham. Mais de dois terços entrevistados (68%) dizem que o atributo organizacional mais crítico para ser bem-sucedido na implementação de AI é ter uma cultura que suporta a tomada de decisão baseada em dados. Esse movimento está começando a acontecer, com líderes empresariais começam a passar de uma cultura de tomada de decisão e geração de insights com base em experiências prévias ou intuição (11% de todos os entrevistados) para baseá-lo em dados e análises. No entanto, a maioria (60%) ainda dependem principalmente de fontes de dados internas e análises padrão. Apenas os líderes estão tomando decisões com base em várias fontes de informações internas, dados externos e fazendo análises sofisticadas (Forrester Gownder 2018; Gioia Volkmar, Peter M. Fischer, Sven Reinecke 2022; Mekhail Mustak, Joni Salminen, oic Ple, Jochen Wir 2020). A

figura abaixo demonstra a maneira como os insights para tomada de decisão são gerados dentro do negócio dos entrevistados:

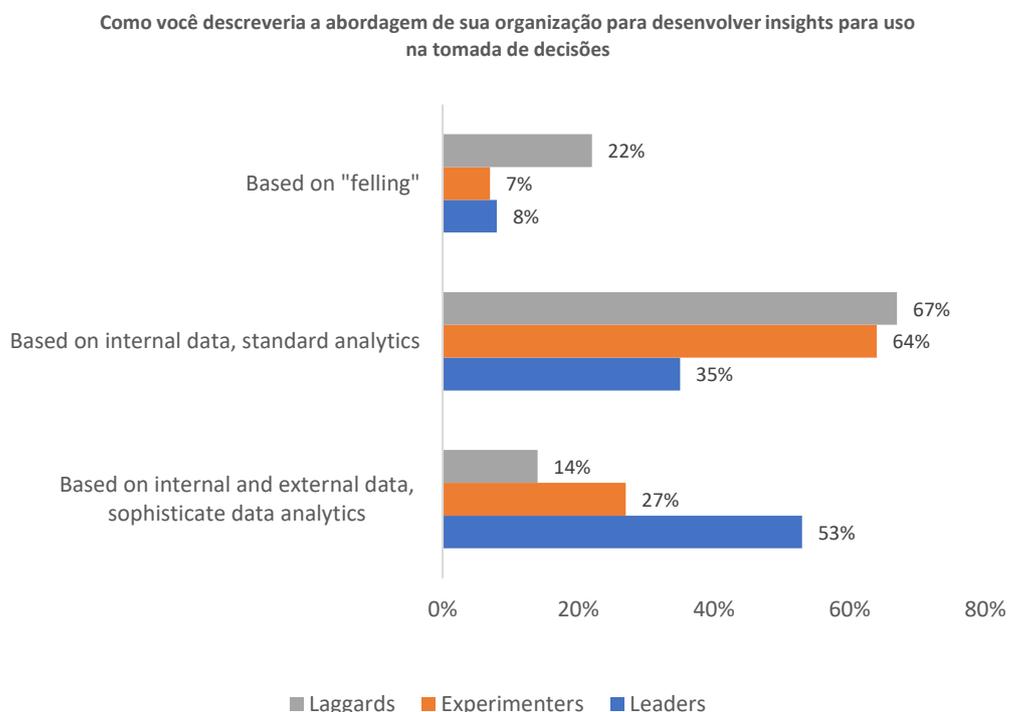


Figura 8. Descrição da abordagem da sua organização para o desenvolvimento de insights para uso na tomada de decisões

Embora a implementação do AI para tomada de decisões seja mais um projeto para o futuro que a realidade para a maioria das organizações, a sua chegada é iminente. Líderes empresariais entrevistados para a pesquisa, acreditam que é muito importante para que se mantenham competitivos estarem um passo à frente da evolução do uso de AI. Muitos processos ainda irão manter um ser humano, ao menos até que o sistema prove sua confiabilidade, ainda assim considerando que os sistemas de AI, aprendem e, portanto, mudam, os estudos e ferramentas para que auditorias precisam evoluir a fim de garantir que seguirão funcionando como pretendido (Gownder 2018; Volkmar, Fischer, Sven Reinecke 2022; Mustak, Salminen, Plec, Wir 2020).

2.4 Modelo de Maturidade

Foram avaliados diversos modelos de maturidade durante a construção do trabalho e entendeu-se que o modelo escolhido oferecia uma visão horizontalizada entre as diferentes dimensões que impactariam a maturidade da empresa em *Business Intelligence*. Tal característica seria relevante para a construção do plano de melhoria para que a empresa avançasse no estágio de maturidade.

2.4.1 Avaliação do estágio de maturidade da empresa quanto ao uso de dados

Atualmente as empresas investem muito dinheiro em *business intelligence*, porém este investimento deve ser avaliado e justificado, o que requer medição e controle do seu valor comercial gerado, para tornar possível as comparações com sistemas semelhantes em outras empresas. Nesse sentido, um modelo de maturidade oferece uma linha de base para fazer tal comparação, através de níveis de eficiência, capacidade de gestão e desempenho (Niño, Niño, Ortega. 2018).

Transforming Data with Intelligence (TDWI) desenvolveu um modelo de maturidade em 2004, que foi renovado durante 2014, incorporando tendências como big data, governança, dados não estruturados, *machine learning*, mineração de dados, cultura de análise, *software* livres, computação em nuvem, mobilidade, metodologias ágeis, internet das coisas, entre outros aspectos. TDWI forneceu uma estrutura para empresas entenderem onde estão, onde estiveram e quais *gaps* precisam cobrir (Halper & Stodder,2014).

O modelo de maturidade da TDWI *Analytics* propõe uma série de perguntas divididas em 5 dimensões a serem avaliadas, são elas: Organização, Infraestrutura, Gerenciamento dos dados, Análise e Governança. O objetivo consiste em enquadrar a empresa objeto de estudo em 1 dos 5 estágios de maturidade desenvolvidos pelo modelo proposto conforme mostra a figura abaixo:

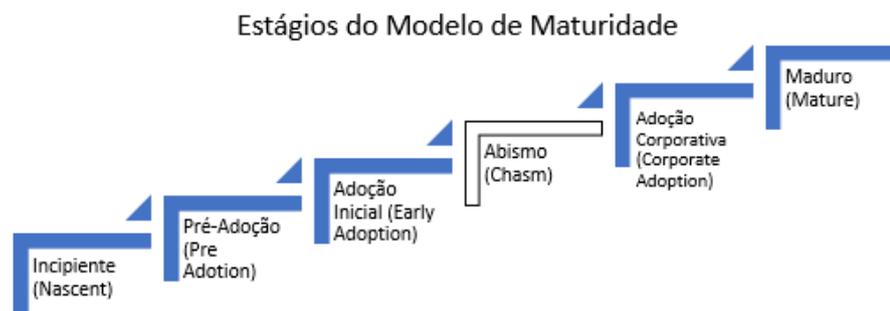


Figura 9. Estágios do modelo de maturidade

De acordo com Ortega (2018) cada um dos estágios pode ser definido como:

Incipiente: neste estágio, a maioria das empresas não está usando ferramentas de análises, exceto em planilhas. A organização não tem compromisso ou cultura de BI. Além disso, não há gerenciamento de dados.

Pré-adoção: a equipe está lendo sobre o tópico e talvez participando de seminários ou conferências. Algumas organizações nesta fase investem em um Tecnologia de BI, mineração de dados ou data *warehouse*. As pessoas estão começando a entender o poder da análise para melhorar as decisões e, finalmente, os resultados de negócios.

Adoção Inicial: a organização incorpora metodologias para análise, tendo consciência da importância da gestão de dados, geração de relatórios e *scorecards*. O TI e o negócio começam a funcionar juntos, focando no fato de que os problemas de negócios exigem mais análise para tomada de decisão. Além disso, a governança de BI tem maior relevância.

Abismo (Chasm): BI e *analytics* são incorporados pelos diferentes departamentos, querendo dar um salto para a adoção corporativa. No entanto, dar este passo leva mais tempo porque as dificuldades podem se manifestar, como: qual departamento possui os dados? Que visão particular é implementada?

Adoção Corporativa: BI impacta os resultados de negócios em grande extensão. O BI se move por toda a organização e a empresa se torna consciente de que o BI lhes confere um diferencial competitivo. TI e Negócios fazem parte da

mesma equipe. Além disso, a organização possui um centro de excelência onde estão incorporados cientistas de dados.

Maduro/Visionário: Poucas organizações estão neste estágio. Eles têm uma infraestrutura altamente sintonizada com as demandas dos negócios e com governança estabelecida. A análise impulsiona a inovação na organização.

Para que a empresa possa ser enquadrada em um dos estágios do modelo acima, foram atribuídos valores a cada uma opção de respostas incluídas no questionário (apêndice 2). Dessa forma, é possível se chegar a um *scoring* com base nos sujeitos selecionados para pesquisa. A tabela abaixo demonstra o *scoring* necessário para ser enquadrado em cada um dos estágios:

Estágio de Maturidade	Scoring para Enquadramento
Nascent – Nascente	4.0 – 7.1
Pre-Adoption – Pré Adoção	7.2 – 10.1
Early Adoption – Adoção Antecipada	10.2 – 13.3
Corporate Adoption – Adoção Corporativa	13.4 – 16.6
Mature/Visionary – Maduro/Visionário	16.7 – 20.0

Tabela 1. Scoring necessário em cada um dos estágios

2.4.2 O uso de dados para criação de Vantagem Competitiva

A vantagem competitiva dá a uma empresa a alavancagem que ela precisa para diferenciar-se dos concorrentes superando as expectativas dos compradores em relação ao valor agregado. Quando uma empresa atinge uma vantagem competitiva sustentada, seus produtos, serviços e valor de marca se diferenciam dos competidores. A visão baseada em recursos retrata como uma empresa pode otimizar os que são insubstituíveis, únicos e valiosos para alcançar vantagem competitiva sustentada (Wernerfelt, 1984).

De acordo com Porter (1985), um conceito importante que destaca o papel da tecnologia da informação no âmbito da concorrência é a cadeia de valor. Esse conceito divide as atividades de uma empresa entre tecnológica e econômicas. O valor que uma empresa cria é medido pelo valor que os compradores estão dispostos a pagar por um produto ou serviço. Para obter vantagem competitiva sobre seus rivais, uma empresa deve realizar suas atividades operacionais a um custo menor

ou realizá-las de forma que leve a diferenciação do produto *versus* seu competidor, de modo que possa aplicar um preço *premium*. Em qualquer empresa, a tecnologia da informação tem um efeito poderoso sobre a vantagem competitiva em custo ou diferenciação. A tecnologia afeta as próprias atividades de valor ou permite que as empresas ganhem vantagem competitiva explorando mudanças no escopo competitivo (Porter, 1985). Por isso, além das perguntas do modelo de maturidade TDWI, foram acrescentadas perguntas relacionadas a percepção de criação de vantagem competitiva nas 4 áreas indicadas por Porter: *Lowering Cost; Enhancing Differentiation; Changing Competitive Scope e Spawning New Business*.

2.4.3 Uso de dados para melhorar o desempenho

Além do modelo para apuração do estágio de maturidade da empresa e das variáveis relacionadas a sua conexão com a criação de vantagem competitiva, também foram adicionadas ao questionário perguntas sobre a relação entre o melhor uso dos dados e o desempenho da empresa objeto de estudo. Verificou-se que a tomada de decisão baseada em dados tem um impacto positivo no desempenho da empresa, indicando que as empresas que usam dados e BI para a tomada de decisão alcançam maior produtividade (Brynjolfsson, McElheran 2016).

De acordo com Liang, You, Liu (2010) O uso adequado de BI contribui tanto para o desempenho financeiro quanto para a eficiência interna da empresa. Evidências sugerem que o impacto dos investimentos em BI possui correlações altas com métricas baseadas no demonstrativo contábil (Lim, Dehning, Richardson, Smith 2011). Além disso, o valor comercial do uso adequado de BI pode ser criado através de diferentes mecanismos, como melhor desempenho organizacional, melhoria de processos de negócios, maior taxa de sucesso no lançamento de produtos e serviços, experiência do consumidor, aprimoramento do entendimento de mercado, valor funcional (incremento em ROI e ROS), *employer branding*, implementação de rotinas e melhoria no clima organizacional (Grovet et al 2018; Mariani, Machado & Nambisan 2022).

3. Metodologia

Este capítulo tem como objetivo apresentar os procedimentos metodológicos da pesquisa. Serão abordados a seleção do caso, seleção dos sujeitos, coleta de dados, análise e tratamento dos dados e limitações mercadológicas.

Optou-se neste estudo pela utilização de uma abordagem quantitativa, para identificar a maturidade de uma empresa do setor farmacêutico em *Business Intelligence*. As vantagens de se utilizar um estudo de caso de uma única empresa está em se investigar os desdobramentos da aplicação de um tema atual com mais profundidade, utilizando-se de teoria e de outras fontes de evidências. O estudo de caso pode ser diferenciado em termos de seu propósito, sendo um caso instrumental único, um estudo multi casos ou um estudo de caso intrínseco (CRESWELL et al., 2007).

A fim de complementar a pesquisa, realizar-se-á uma análise quantitativa, por meio de regressão múltipla, para entender a relação entre a percepção de maturidade e a percepção de potencial de vantagem competitiva e performance trazidos pela adoção de BI. Uma vez que estudos como o de Kaplan e Duchon e Wynekoop mostram como a combinação de técnicas fornecem um contexto mais rico para interpretar e validar os resultados de pesquisa (M. Wood et Al 1999).

Através desse estudo pretende-se contribuir com a literatura avaliando um paralelo entre a maneira como os funcionários descrevem a maturidade da empresa quanto aos seus processos de *business intelligence* e como se avalia a relação entre o uso adequado dos dados e o desempenho da empresa. De acordo com Porter (1985) a maioria dos gerentes gerais sabem que a revolução está em andamento e poucos contestam sua importância. À medida que cada vez mais tempo e capital de investimento são absorvidos pela Tecnologia da Informação e seus efeitos, os executivos têm uma consciência crescente de que a tecnologia não pode mais ser o território exclusivo dos departamentos de *Tech*. Ao verem que seus rivais usam as informações para obter vantagem competitiva, esses executivos reconhecem a necessidade de se envolverem diretamente no gerenciamento da nova tecnologia. Dado o enorme potencial da BI para a criação de valor para os negócios e para a sociedade, uma crescente de vários estudos de diversas disciplinas de pesquisa tenta

examinar o funcionamento do mecanismo de criação de valor das *BIs* (P Mikalef, IO Pappas, J Krogstie, PA Pavlou 2020).

Foram incluídas fontes secundárias, de notícias relacionadas a empresa objeto de estudo em sites especializados como: Medway e Agenciaaids.com.br, conforme vemos nas figuras abaixo, pois em um estudo de caso, segundo os autores Yin (1994); Creswell (2010), é importante o uso de múltiplas fontes de evidências.



Figura 10. Notícias PNI



Figura 11. Notícias sobre a importância da empresa para o SUS

Embora a riqueza de estudos sobre o valor comercial do uso de *Business Intelligence* tenha contribuído para o corpo de conhecimento, fornecendo informações valiosas sobre aspectos específicos do mecanismo de criação de valor, o trabalho destacou a necessidade de um quadro mais consistente, especialmente no que diz respeito à questão de como os fatores contextuais influenciam os resultados de desempenho devido ao uso de *Business Intelligence*.

Tendo como referência o plano genérico de procedimentos utilizados em pesquisas quantitativas, a mesma segue a seguinte estrutura para as etapas de revisão de literatura, pesquisa via survey e entrevista em profundidade:

1ª Fase: Definição do problema. Realização da revisão de literatura referente ao uso de *Business Intelligence*, *AI* e *Machine learning* no ambiente de negócios.

2ª Fase: Preparação e coleta de dados, definição e seleção das pessoas que farão parte da pesquisa como respondente do questionário.

3ª Fase: Coleta de dados via questionário, entrevistas em profundidade, e triangulação com dados secundários para *survey* a fim de identificar o estágio de maturidade da empresa quanto a *Business Intelligence* e investigar as razões por trás dos resultados aferidos.

4ª Fase: Tratamento, Análise Quantitativa e interpretação dos dados, para entender a relação entre o nível de maturidade em BI e a percepção de o quanto a adoção de BI contribui para vantagem competitiva e performance da empresa contemplando:

1. Consolidação, enquadramento tratamento de dados e verificação de premissas (normalidade, homoscedasticidade, linearidade) para rodar a análise de fator e regressão múltipla na ferramenta SPSS
2. Análise de Fator com rotação Varimax a fim de reduzir as variáveis dependentes (vantagem competitiva e performance) com significado prático e teórico semelhantes
3. Análise com Regressão Múltipla a fim de identificar os preditores mais importantes (dimensões de maturidade de BI: Organização, Infraestrutura, Gestão de Dados, Análises e Governança) associados as variáveis dependentes (fatores de vantagem competitiva e performance)
4. Elaboração do relatório final da pesquisa, com o resultado, discussão do resultado como um plano de propostas de melhoria e conclusões.

3.1 A Seleção do Caso

Observou-se a relevância de se realizar uma pesquisa em uma empresa do setor farmacêutico pois se trata de um mercado onde a proteção intelectual dos

produtos através de patentes permite com que a empresa pratique margens financeira que cobrem as ineficiências na cadeia de produção e promoção. Além disso, o meio é regulado por agências independentes o que restringe a quantidade de dados coletados e a maneira como os produtos podem ser promovidos para os clientes. Por fim, esse mercado possui diversas empresas que fornecem bases com informações de mercado para toda a indústria, dentre elas destacam-se em participação de mercado a IQVIA e a CloseUp.

Nesse contexto, a empresa foi selecionada pois parte relevante do seu faturamento vem de produtos sem patente, ou seja, produtos que competem com genéricos. Essa informação muda completamente a dinâmica mencionada acima, uma vez que, o mercado de genéricos tende a se assimilar mais com o mercado de consumo, onde o processo de tomada de decisão dos pacientes ou *shopper*, acontece dentro da loja (Farmácia).

Considerando esse fator, a empresa nos últimos anos passou a acelerar sua agenda de Inovação com foco em se tornar uma empresa *data-driven* onde a maior parte das decisões são tomadas com base em dados coletados e trabalhados internamente. Além disso, o autor do estudo tem acesso a pessoas relevantes dentro da operação da empresa facilitando assim o processo de coleta e análise de dados.

3.1.1 A empresa farmacêutica objeto de estudo

A empresa objeto de estudo se trata da filial brasileira de uma farmacêutica, abaixo a maneira como a empresa se apresenta ao investidor em seu reporte anual:

“Desenvolvemos e fornecemos medicamentos, vacinas e produtos de saúde de consumo que impactam a saúde humana em grande escala. Nossas operações abrangem a cadeia de valor desde a identificação, pesquisa, desenvolvimento e teste de descobertas inovadoras até a aprovação regulatória, fabricação e comercialização. Nosso pessoal é fundamental para o nosso sucesso: especialistas em ciência, tecnologia, fabricação, regulamentação, propriedade intelectual e comercialização. Também colaboramos com especialistas líderes mundiais e formamos parcerias estratégicas para complementar nossas capacidades existentes. A maior contribuição que fazemos é melhorar a saúde das pessoas em todo o mundo. Em 2021, isso incluiu a entrega de 1,7 bilhões de medicamentos, mais de 767 milhões de vacinas e 3,7 bilhões de produtos de saúde de consumo.”

Olhando para o futuro, tem uma clara ambição de impactar positivamente a saúde de mais de 2,5 bilhões de pessoas nos próximos dez anos. Criamos valor para os acionistas que investem em nossos negócios para fornecer retorno aos acionistas e, em 2021, pagamos um dividendo de 80 pence por ação. Assumimos novos compromissos com o crescimento e uma mudança radical no desempenho nos próximos cinco anos. Nosso objetivo é ser um empregador moderno, desenvolvendo nosso pessoal e oferecendo uma ampla gama de benefícios, incluindo serviços de saúde preventiva, que nos ajudam a atrair e reter as melhores pessoas. Empregamos mais de 90.000 pessoas em 92 países e trabalhamos diretamente com 37.500 fornecedores. Em 2021, pagamos £ 1,3 bilhão em impostos corporativos, bem como uma quantia significativa de outros impostos comerciais e trabalhistas”.

Resumo resultados financeiros:

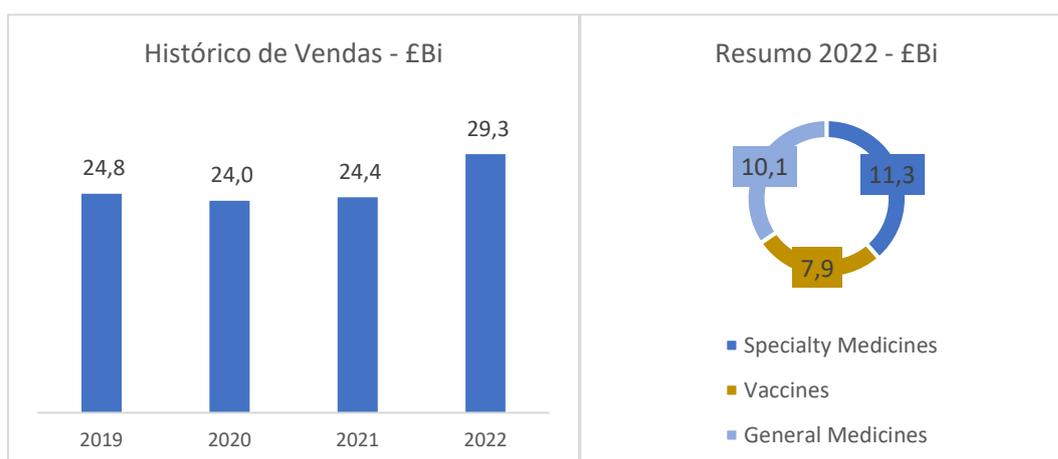


Figura 12. Resultados Financeiros

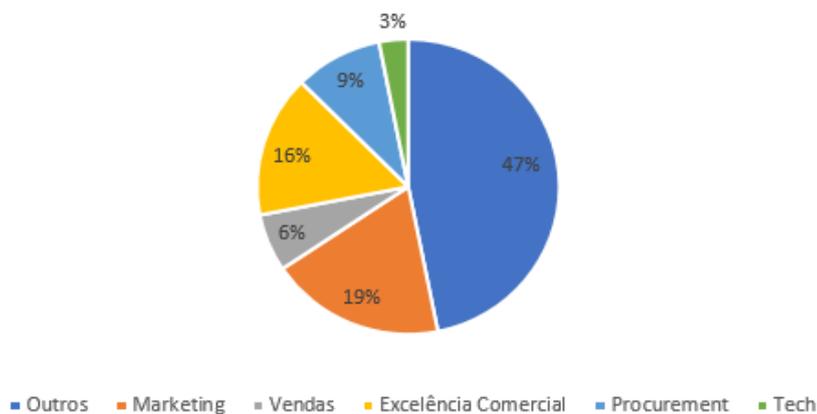
No Brasil, a empresa está presente desde 1908 contribuindo para a saúde dos brasileiros. Atualmente a empresa emprega diretamente cerca de 1.5 pessoas divididas entre profissionais baseados nos campos. Possui em seu portfólio de produtos clássicos que já fazem parte da vida do Brasileiro, como Clavulanato + Amoxicilina e Sabultamol, produtos inovadores na área de Oncologia como Niraparibe e Dostarlimab, importantes tratamentos para câncer de Ovário e Intestino, além de Vacinas que contribuem para saúde dos Brasileiros desde os primeiros meses, distribuídas através do programa nacional de imunização.

3.2 A Seleção dos Sujeitos

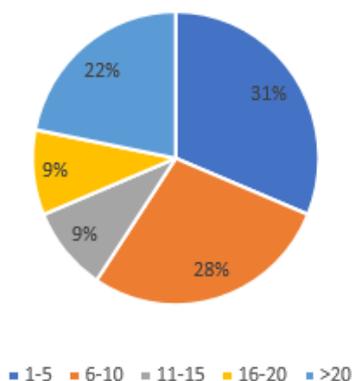
Os sujeitos selecionados para pesquisa são funcionários, de diferentes setores e níveis hierárquicos, da empresa objeto de estudo que participam de forma direta dos processos operacionais e estratégicos da empresa.

Nesse contexto, foram selecionados previamente um total de 48 profissionais, sendo os profissionais escolhidos: Gerentes Gerais, Diretores, Gerentes, Especialistas e Analistas. Dentre os 48 profissionais selecionados, que receberam ao link para responder a pesquisa *via Whatsapp* entre os dias 03 e 20 de janeiro, 32 responderam ao questionário (ligeiramente maior do que o número mínimo de 30 casos sugerido por Hair et al, 20010) através da ferramenta *Google Forms*. Podemos demonstrar através das figuras abaixo a composição entre a amostra de 32 participantes:

Em qual departamento trabalham os respondentes?



Há quantos anos trabalha no setor farmacêutico?



Qual a última posição no setor farmacêutico?

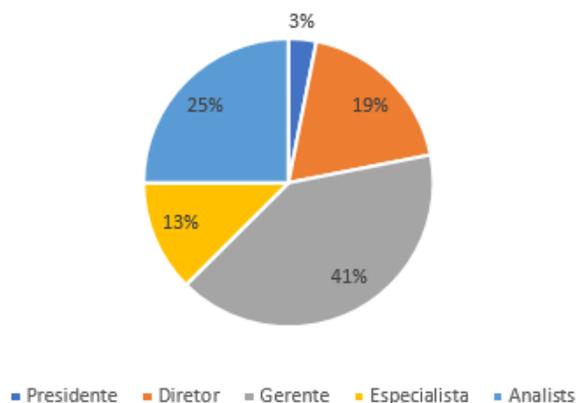


Figura 13. Divisão dos participantes da pesquisa

Além disso, foram selecionados 4 profissionais, entre os respondentes, para uma entrevista com mais profundidade, com o objetivo de triangular os dados quantitativos coletados na *survey* com as percepções coletadas durante a entrevista a fim de investigar as razões por trás dos resultados aferidos. As entrevistas aconteceram entre os dias 03 e 15 de fevereiro, seguindo o roteiro citado no apêndice 3, sendo três presenciais e uma virtual através do MS Teams. Entre os profissionais selecionados para a entrevista estão a *Chief of Tech Office*, um ex-funcionário que exerceu o papel de *Chief of Staff* entre 2020 e 2021, um Analista de *Comex &* um Analista de *Finance Supply*. As entrevistas levaram um tempo médio de 45 minutos cada para ser realizada e por questão de confidencialidade não foram gravadas, por isso foram parcialmente transcritas pelo pesquisador.

3.3 Coleta de dados

A coleta de dados foi realizada através de uma survey enviada via google forms, entre dezembro de 2022 e janeiro de 2023, para um grupo de 48 pessoas, todas funcionários ou ex-funcionários da empresa objeto de estudo, obtendo um total de 32 respostas entre os meses de janeiro e fevereiro de 2023. Dentre os 32 respondentes foram selecionados 4 para que fosse feita uma entrevista (presencial ou via Teams) para aprofundamento de respostas e análise conjunta dos resultados.

Os dados e comentários foram coletados em duas etapas: a primeira através de aplicação do questionário baseado no modelo de maturidade “*TDWI Analytics Maturity Model Assessment*” (Halper e Stodder, 2014) com o intuito de classificar, de acordo com a percepção dos respondentes, o estágio de maturidade da empresa em cada uma das 5 dimensões de maturidade (Organização, Infraestrutura, Gestão de Dados, Análise, Governança) em *Business Intelligence*, já mencionados durante a revisão de literatura. Além das perguntas relacionadas ao modelo de maturidade, foram adicionadas duas sessões ao questionário. A primeira baseada no artigo *How Information Gives You Competitive Advantage*, (Porter, 1985) que tem como objetivo coletar a percepção dos respondentes quanto a capacidade do uso de *Business Intelligence* para criação de Vantagem Competitiva. A segunda, que tem como objetivo avaliar a percepção dos participantes da pesquisa quanto ao potencial de *Business Intelligence* em melhorar a performance da empresa. As perguntas do questionário e as possíveis respostas estão refletidas no apêndice 1.

Na segunda etapa, já com os resultados calculados pelo modelo, foram selecionados 4 respondentes, ainda buscando ter diferentes níveis hierárquicos e setores representados, foi realizada uma entrevista buscando aprofundar as respostas, coletar comentários em relação aos resultados e sugestões de caminhos por onde a empresa poderia buscar evoluir em cada uma das dimensões.

Como os dados foram coletados por mais de uma fonte, por meio de questionários e informações estratégicas internas da empresa, eles foram triangulados, visando a convergência dos dados e o reforço da validade da avaliação do estudo de caso (REMENYI et al., 2000). A fim de garantir a validade da pesquisa e cruzar elementos tangíveis com a percepções respondidas no questionário (Net Sales, Profit, *Operating Margin*), foram consultados resultados financeiros, sites relacionados ao setor com informações relevantes relacionadas a empresa objeto de estudo e pesquisas de mercado para validação das percepções. A

triangulação de dados, por meio do uso de diversas fontes primárias e secundárias, aumenta a validade e a confiabilidade da pesquisa (YIN, 2003).

3.4 Análise e Tratamento dos dados

Os dados coletados por meio de um questionário, tratados através de uma atribuição de valor numérico a cada resposta (apêndice 2), alinhado com o *guidance*, com o intuito de classificar a empresa em um dos estágios preconizado pelo modelo. Para isso foram levadas em conta as percepções dos entrevistados sobre cada um dos aspectos analisados, alinhado com as diretrizes (descritas na tabela 3, no capítulo 2.4.1) a fim de apontar o estágio de evolução da empresa dentro de cada uma das 5 dimensões de maturidade (Organização, Infraestrutura, Gestão de Dados, Análise, Governança).

Uma vez coletados e tratados os dados, foram selecionados 4 respondentes para avaliar os resultados aferidos (*Chief of Tech Office*, ex-funcionário *Chief of Staff* entre 2020 e 2021, *Analista de Comex & Analista de Finance Supply*), a fim de triangular os resultados da *survey* com as percepções e inconsistência que deveria ser investigada. Além disso, durante a entrevista foram questionados possíveis caminhos pelos quais a empresa poderia evoluir a fim de avançar para o próximo nível do estágio no modelo.

A fim de complementar a análise, os dados coletados via *survey* foram consolidados e formatados a fim de rodar uma análise de fator na ferramenta SPSS. Para que fosse possível rodar a análise optou-se por tratar os dados faltantes com substituição pela média, nos casos de faltas completamente aleatórias, e eliminação de todas as respostas do respondente no caso da falta aleatória. Com isso, foi possível realizar a análise de fator reduzindo o número de variável para um total de 4 variáveis. Para cada uma dessas variáveis, foi rodada uma regressão a fim de determinar se existia alguma relação estatisticamente significativa entre as variáveis dependentes e preditores.

3.4.1 Análise de Fator

Segundo Hair et al. (2010), a análise de fator é um método estatístico usado para identificar dimensões subjacentes, ou fatores, que explicam as relações entre um conjunto de variáveis. Tatham et al (1996), a análise de fator pode ser definida como um método de redução de dados que extrai um número menor de fatores

latentes de um conjunto maior de métodos variáveis observados, enquanto ainda retém o máximo possível da variabilidade original nos dados. Esses fatores são interpretados como dimensões ou construtos subjacentes que explicam a variância comum nas variáveis observadas.

Quanto ao objetivo com a aplicação do método, Hair et Al (1998) afirma que, o ponto de partida na análise de fator, como em outras técnicas estatísticas, é o problema de pesquisa. O objetivo geral das técnicas de análise de fator é encontrar uma maneira de condensar a informação contida em um número de variáveis originais em um conjunto menor de novas dimensões compostas ou variáveis com uma perda mínima de informação, ou seja, procurar e definir os construtos ou dimensões fundamentais assumidas como subjacentes às variáveis originais. Sendo assim, podemos abrir os objetivos em duas linhas de objetivos macro:

- Identificando a estrutura através do resumo de dados: A análise de fator pode identificar a estrutura das relações entre variáveis ou respondentes examinando as correlações entre as variáveis ou a correlação entre os respondentes
- Redução de dados: A análise de fator também pode identificar variáveis representativas de um conjunto muito maior de variáveis para uso em análises multivariadas subsequentes ou criar um conjunto totalmente novo de variáveis muito menores em número, para substituir parcial ou completamente o conjunto original de variáveis

No presente trabalho foram seguidos os seguintes passos para atingir os objetivos de se fazer uma análise de fator: (i) foram realizados os testes KMO e Bartlett que indicaram a adequação; (ii) análise da matriz anti-imagem para observar se alguma variável deveria ser eliminada; (iii) foi usado o gráfico *scree plot* para definição do número de fatores que deveria ser extraído; (iv) método de extração: análise de componente principal e método de rotação: varimax com normalização de Kaiser.

3.4.2 Regressão

Segundo Hair et al. (2017), a análise de regressão é uma técnica estatística usada para examinar a relação entre uma ou mais variáveis independentes e uma variável dependente. A variável dependente é a variável de interesse que queremos explicar ou prever, enquanto as variáveis independentes são as variáveis que acreditamos estar relacionadas à variável dependente. Montgomery et Al. (2012) afirmam que a análise de regressão é uma técnica utilizada para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes, com o objetivo de prever o valor da variável dependente com base nos valores das variáveis independentes.

Os objetivos da execução de uma análise de regressão são variados, porém alguns dos objetivos comuns de se executar uma análise de regressão podem incluir:

- Conforme observado por Kutner et al. (2004), a análise de regressão pode ser usada para determinar se existe uma relação estatisticamente significativa entre as variáveis dependentes e independentes.
- Para Hair et al. (2017), o objetivo primário da análise de regressão é fazer previsões sobre o valor da variável dependente com base nos valores das variáveis independentes.
- De acordo com Gujarati e Porter (2009), a análise de regressão pode ser usada para identificar as variáveis independentes que têm a associação mais forte com a variável dependente e para quantificar a força dessa associação.

Em resumo, o objetivo de executar uma análise de regressão é entender a relação entre a variável dependente e uma ou mais variáveis independentes, sendo assim, os pesquisadores podem gerar insights sobre os fatores que afetam a variável dependente e tomar decisões informadas com base nisso. No presente trabalho foram seguidos os seguintes passos para atingir aos objetivos com as regressões: (i) Testes de Normalidade e Homocedasticidade; (ii) Resumo do modelo com r quadrado e Durbin-Watson; (iii) Teste Anova; (iv) Análise dos Coeficientes.

4. Resultados

Para contextualização e melhor entendimento dos resultados, nessa sessão será feita uma breve descrição do que a empresa possui atualmente em relação ao quadro de funcionários, diretorias e ferramentas para gestão de dados. Nessa sessão, serão consideradas somente as diretorias de Tech e Operações Comerciais, uma vez que, essas estão diretamente envolvidas nos projetos de implementação de novos sistemas ou processos relacionados a *Business Intelligence*.

A diretoria de *Tech* possui uma diretora *Head* do departamento e está dívida entre quatro gerências. Conforme supracitado, o modelo de trabalho dessa equipe passou a ser no formato de *Business Partners*, logo entre os quatro gerentes da área três fazem o papel de *Business Partner* para Unidades de negócio ou área de suporte. Dessa forma, esse profissional fica responsável por gerenciar ou apoiar na gestão de projetos relacionados a implementação de novos sistemas, criação de processos ou treinamentos relacionados a inovação dentro das áreas clientes, além de sugerir a implementação de soluções de mercado (parcerias com startups ou consultoria) para atender a necessidades identificadas pela área. A outra gerência da área fica responsável pelo gerenciamento dos *devices* utilizados pelos funcionários da empresa e pela gestão dos contratos com terceiros responsáveis por executar funções específicas de acordo com o *workload* de projetos na empresa, como por exemplo, a contratação de terceiros para construção de *PowerBIs*. Somados funcionários e terceirizados, a força de trabalho dessa diretoria pode chegar a cerca de 60 funcionários sendo desses, 70% focados em funções tradicionais de IT Service, como gestão de celulares, *Ipads* e computadores e o restante trabalhando com projetos de Inovação e construção de visões em Power BIs.

Na diretoria de Operações Comerciais, possui um diretor Head da área e está dívida entre 5 gerências: PBM, Digital, *Business Intelligence & Sales Force Effectiveness*, Treinamento de Vendas e Operações. As principais responsabilidades dívidas entre as gerências são a gestão do PBM (*Pharmacy Benefit Management*), liderar a implementação da estratégia do canal digital da empresa, comprar e gerar insights com base em pesquisas de mercado, capturar e gerar dashboards com base nos *KPIs* de força de vendas e capacitação do time de

vendas. A área possui aproximadamente 65 pessoas entre funcionários e terceirizados, entre essas cerca de 15 pessoas dedicam 90% do seu tempo de trabalho em análise de dados e geração de *insights* focada no suporte as unidades de negócios. Além disso, o departamento fica responsável pela contratação de consultorias estratégicas como McKinsey e Accenture para suportar na construção da estratégia de negócios e compra de dados disponibilizados por consultorias especializadas no setor como IQVIA e CloseUp.

Quanto a sistemas já implementados, a empresa utiliza uma série de diferentes provedores de *software* para melhor atender a necessidade específica de cada área, conforme correlacionado na lista abaixo:

1. SAP – Finanças e *Supply*
2. *SalesForce & Veeva* – Força de Vendas
3. *Microsoft Teams e Project* – Gerentes de Projetos
4. *Microsoft PowerBI – Marketing*
5. *Content Lab – Marketing*

4.1 Avaliação de maturidade em *Business Intelligence*

O capítulo de resultados vai expor e analisar os resultados quanto a maturidade em *Business Intelligence* da empresa usando o modelo de maturidade proposto. Além disso, essa etapa pretende atender ao objetivo secundário 3 mencionado no capítulo 1.2, relacionado a aplicação do modelo de maturidade em *BI* para avaliação identificação da percepção do nível de maturidade da empresa *BI* e da percepção do impacto na criação de Vantagem Competitiva e melhoria de Performance. As descobertas desse estudo apontam que a empresa objeto de estudo está em um estágio de maturidade **Early Adoption** em *Business Intelligence*, tendo como fortalezas a Organização e a Governança por trás dos processos, mas tendo como pontos de melhoria sua Infraestrutura por conta de sua baixa capacidade em integrar dados e a gestão dos dados devido a diferentes níveis de maturidade entre departamentos da empresa. Além disso, os resultados desse estudo foram usados pelo pesquisador para desenvolver um roteiro com pontos de melhoria, que se implementados, podem levar a empresa ao próximo estágio no modelo maturidade.

Através da aplicação do modelo de maturidade “*TDWI Analytics Maturity Model Assessment*” e da utilização dos *scoring* preconizados pelo modelo e citados

na tabela 3 desse trabalho, chegamos a seguinte classificação da empresa objeto de estudo:

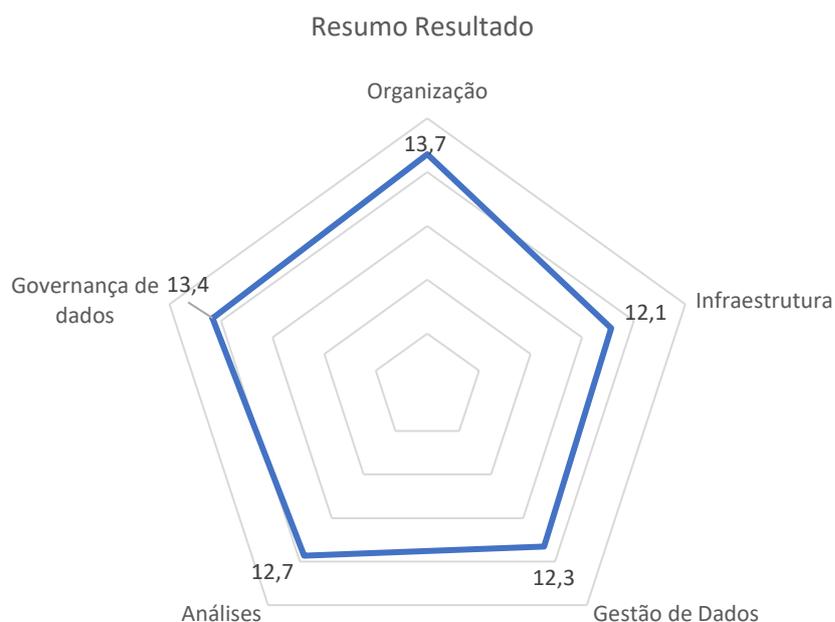


Figura 14. Resumo do resultado

Em resumo a empresa foi enquadrada como **Early Adoption** pelo modelo. Para cada uma das diferentes dimensões os criadores do modelo, (Halper & Stoodder 2015), oferecem uma descrição sobre o estágio da empresa e as características comuns que podem caracterizá-lo. A descrição oferecida pelos autores do modelo foi adicionado comentários relacionados ao momento vivido pela empresa, assim como transcrições de trechos de entrevistas realizadas com 4 membros da equipe para coletar suas percepções sobre os resultados aferido.

4.1.1 Dimensão de Organização: FASE – Corporate Adoption

A fase **Corporate Adoption** é a principal fase de cruzamento na jornada analítica de qualquer organização. Durante essa fase os usuários finais geralmente se envolvem e a análise transforma a forma como eles fazem negócios. Uma vez enquadrada como **Corporate Adoption** na dimensão Organização, espera-se que empresa tenha percebido que o *analytics* é um diferencial competitivo e tem projetos de sucesso ou pelo menos protótipos maduros que o comprovem essa percepção. A inovação em coleta e análise de dados é um valor central e uma cultura analítica prevalece. A estratégia de negócios é geralmente uma mistura de *top-down* e *bottom-up*, com uma infraestrutura de dados que pode suportar isso. Áreas de *negócios* e *Tech* se veem como uma equipe e têm experiência em trabalhar juntos em projetos analíticos. Uma crescente da cultura *data-driven* permeia a organização. Essas organizações geralmente pensam fora da caixa expandindo o alcance das análises, até mesmo realizando competições e outros eventos.

A figura abaixo representa a média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Organização. Importante destacar que a nomenclatura de cada barra no eixo x, (O-1, O-2, etc.) representa um código que pode ser encontrado no apêndice 2.

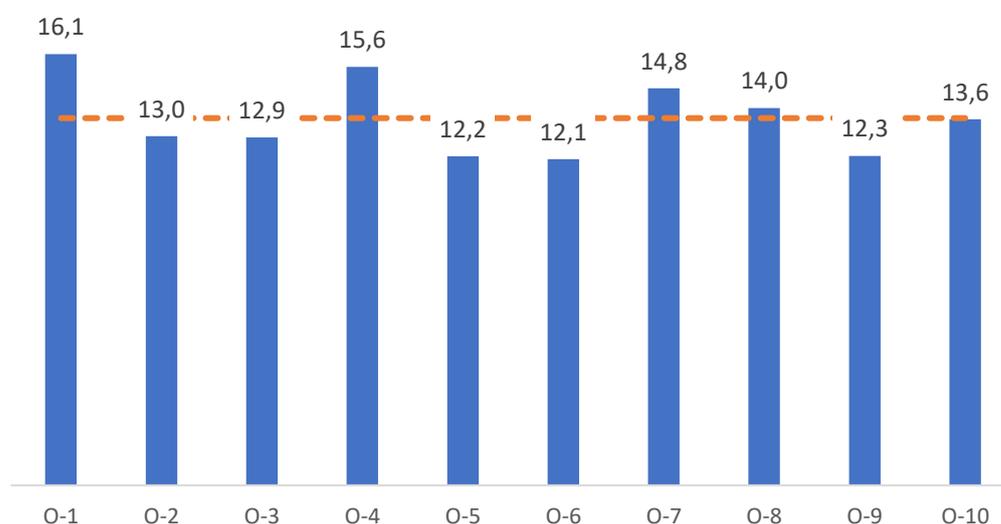


Figura 15. Média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Organização

Através da análise das respostas, é possível observar que a empresa objeto de estudo vive um momento de transformação, trazendo *business intelligence* e

inovação para o centro da estratégia empresarial, através de projetos e novas estruturas. Esses movimentos vêm sendo cascadeados e compartilhados dentro da companhia e geram um aumento no *share of mind* sobre o uso de dados entre as áreas de negócios. Um resultado que valida esse *assumption* é que a pontuação mais alta dentre a dimensão de Organização é: “Você tem patrocínio, dos times comercial e de TI para implementar iniciativas de análise?” (O-1). Isso mostra que a percepção da amostra de participantes da pesquisa é que existe suporte por parte do time de negócios para apoiar com alocação de verbas e priorização de iniciativas dentro das estratégias de marca. Além disso, confirma que existe a confiança que a equipe de *IT* pode prover o suporte técnico necessário para que as novas iniciativas sejam implementadas sem impactos na operação. Um ponto de atenção foi o resultado da pergunta que teve média mais baixa entre as respostas dessa dimensão, refletida na figura na coluna (O-6) “Temos um roteiro analítico em vigor que foi acordado em toda a empresa e a disciplina para alterar o roteiro, se necessário”. Isso aponta que mesmo com os esforços da empresa em criar jornadas de inovação cross-funcionais e inclusivas, eles podem não estar sendo vistos como uma agenda de evolução em *business intelligence*, sendo entendido apenas como uma agenda de automatização e melhoria de processos ou ainda existe uma oportunidade de melhoria no *endomarketing* com o objetivo de dar maior visibilidade para os respondentes em relação as jornadas que estão acontecendo na empresa.

Ademais, parte dos participantes da pesquisa fazem parte de equipes como o time médico, que estão acostumadas com análises de estudos clínicos, *Finance* e *Procurement*, uma vez que essas equipes usam basicamente *outputs* de análises para tomada de decisão sua maturidade é mais alta que do restante da organização, puxando a média da empresa para cima.

De acordo com o **Chief Tech Office** existem diferentes níveis de maturidade dentro da organização:

“a empresa ainda trabalha em silos. Existe uma área que centraliza a criação de dashboards e atualização de sistemas, mas para que os mesmos se convertam em insights depende da maturidade da área cliente em transformá-los. Pode ser observado que o time de marketing, responsável pela alocação de parte significativa dos investimentos, ainda não possui capabilities para analisar dados e tomar decisão com base no ROI gerado por cada ação”.

E o *Chief of Staff* conclui que existe o desafio de que profissionais com perfil técnico tenham capacidade de entender as necessidades do negócio, ou que profissionais dos negócios consigam enxergar a capacidade das ferramentas de solucionar suas dores:

“existe uma vontade por parte da organização em permear a cultura data-driven entre as diferentes áreas, isso é um fato. Porém ainda existe o desafio de fazer com que os profissionais responsáveis por criar os relatórios e dashboards falem a mesma língua dos profissionais que analisam as informações. Essa expertise precisa ser formada em casa ou comprada de profissionais mais experientes que já tenham atuado em modelos onde a área de criação de reports já ia para as reuniões com os insights prontos, ou no mínimo com a hipótese que foi testada. Hoje ainda não chegamos nesse nível e ainda não temos clareza se iremos formar esses profissionais em casa ou contratar”.

Além disso, o **Analista de Comex** comenta que as áreas não têm isonomia para criar os *KPIs* que serão acompanhados:

“cada área procura criar KPI que mostram uma melhor performance, ou seja, os dados são observados com parâmetros distintos se analisados por um analista de Comex ou de Supply”.

Em resumo, os resultados dessa dimensão mostram quem existe a percepção entre a amostra de respondentes de que a empresa possui profissionais com habilidades adequadas em BI, existe suporte por parte da alta gestão das unidades de negócio para que projetos e que os gestores de iniciativas estão aptos a traduzir os benefícios das mesmas para executivos mais *seniors*. Por outro lado, ainda existe a percepção de que a empresa não tem um plano centralmente estruturado, com tempos, investimentos e treinamentos para disseminar a cultura e há entre todos os departamentos.

4.1.2 Dimensão da Infraestrutura: FASE – Early Adoption

Durante a fase de **Early Adoption**, a empresa está implementando ferramentas e metodologias de análises. Em uma empresa nessa fase na dimensão de Infraestrutura, pode haver tecnologia de análise em vigor, mas normalmente não requer uma plataforma de análise dedicada ou dispositivo para análise, a menos que esteja em uma prova de conceito. A empresa também pode estar pensando em uma arquitetura unificada que permita aos usuários acessar várias fontes e diferentes tipos de dados, incluindo conteúdo não estruturado. A empresa pode considerar a implementação de sistemas de análise na nuvem ou desenvolver *Sistemas Hadoop* para aumentar a flexibilidade e reduzir os custos de algumas de suas iniciativas analíticas.

A figura abaixo representa a média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Infraestrutura:

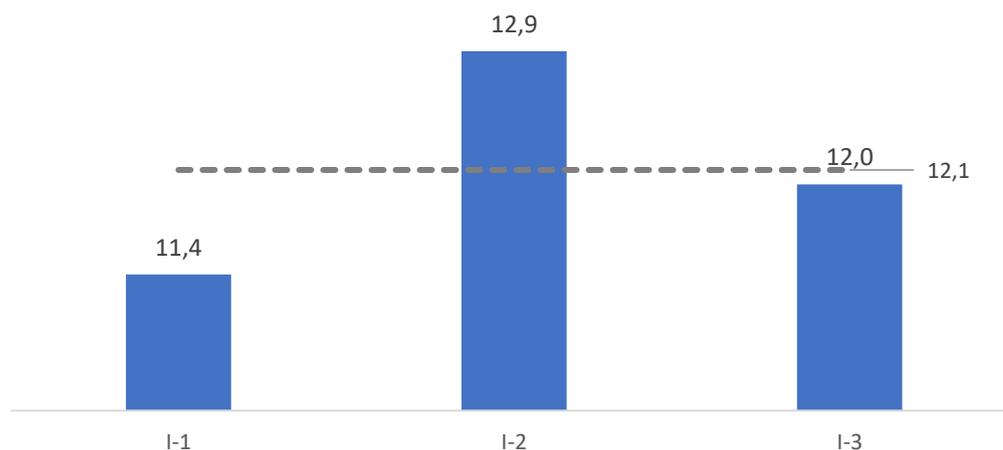


Figura 16. Média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Infraestrutura

Diante desse cenário, compreende-se que o resultado reflete exatamente o momento vivido pela empresa. Existem iniciativas e projetos em diferentes áreas focados em integrar as diferentes bases de dados usadas. Inclusive algumas iniciativas combinam dados utilizados por diferentes áreas, como por exemplo sistemas que geram informações como o alcance de iniciativas de marketing, a venda no período e o *gross to net* investido no produto. Informações que podem ser analisadas tanto por equipes de Finanças, Marketing e Trade Marketing. Porém para alguns departamentos o uso de planilhas como principal ferramenta para

armazenagem e análise de dados ainda é uma realidade. Essa variação de maturidade entre áreas pode ser validada pelo resultado da pergunta “Quais tecnologias de infraestrutura você utiliza atualmente para seus esforços analíticos?” (I-1) onde cerca de um quarto dos participantes respondeu que sua área ainda utiliza planilhas como principal ferramenta e outro quarto responde que tem em seu pool de ferramentas uma série de sistemas que formam um ecossistema de análises. Sendo assim, a empresa ainda precisa caminhar em direção a uma melhor harmonização entre os níveis de maturidade para avançar no modelo.

A **Chief Tech Office** da empresa argumenta que por falta de conhecimento ou capacidade técnica a empresa utiliza menos da infraestrutura instalada do que poderia:

“não exploramos a potencialidade do pool de ferramentas disponibilizados pela empresa. Não usamos ferramentas que geram insights com base em dados não estruturados através do uso de Machine learning e Artificial Intelligence, isso é uma fraqueza”.

Adicionalmente o **Analista de Supply** entrevistado acredita que ainda existe muito trabalho manual antes que o dado possa ser incluído em um sistema:

“as interfaces dos sistemas principais funcionam bem, mas isso ainda não é standard em todos os sistemas usados pelo departamento. Isso quer dizer que em muitos casos o dado precisa ser tratado manualmente antes de subir em um sistema, o que aumenta a chance de erro e o workload da área”.

Em síntese, as respostas das perguntas listadas para essa dimensão sinalizam que apesar da percepção de que existem habilidades para construção da infraestrutura de dados parte dos departamentos representados pela amostra de respondentes acreditam que ainda não tem a infraestrutura ideal para apoiar na análise de dados e que os profissionais responsáveis pela criação dessa infraestrutura não trabalham perto suficiente dos negócios para entender as dores e necessidades.

4.1.3 Dimensão da Gestão de Dados: FASE – Early Adoption

Uma empresa **Early Adoption** quanto a Gestão de Dados normalmente tem um data *warehouse*, apenas para dados estruturados. Em alguns casos, pode ser que a empresa esteja trabalhando principalmente fora de seus arquivos simples de planilha, e pode funcionar, desde que haja uma maneira de garantir a integridade dos dados. Do ponto de vista da estratégia de dados, muitas vezes há metadados atribuídos no nível departamental. No entanto, gerenciamento do processo de ciclo de vida de dados e audibilidade são imaturos ou inexistentes.

A figura abaixo representa a média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Gestão de Dados:

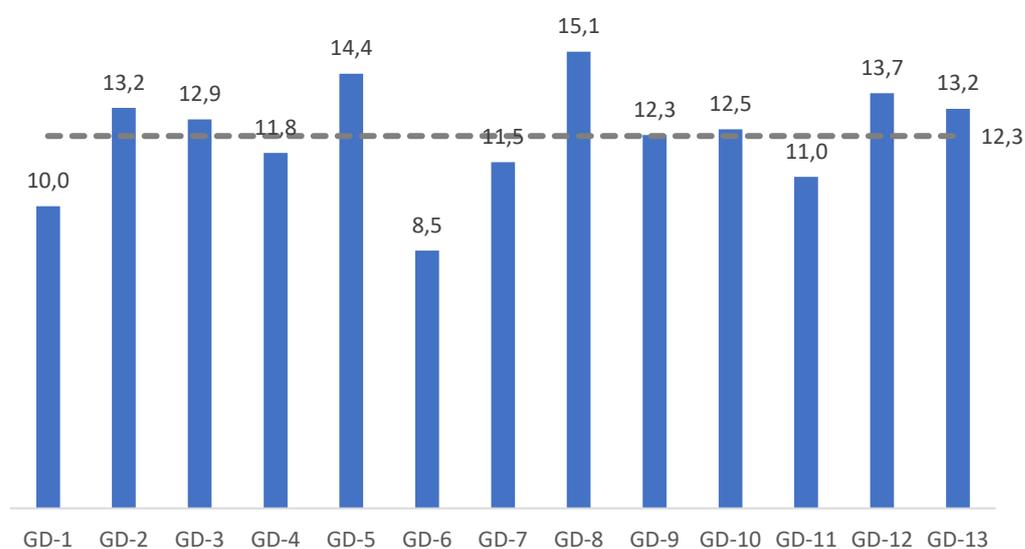


Figura 17. Média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Gestão de Dados

Portanto, o resultado reflete bem o status da empresa. Apesar de 50% dos participantes da pesquisa informarem que suas equipes já utilizam *dashboards* e ferramentas para geração de relatórios em *real-time* e dos dados estruturados possuírem repositórios e auditorias estabelecidas, a garantia de visibilidade e acesso por parte de diferentes equipes e a integração entre sistemas ainda são pontos de melhoria para a empresa. Essa afirmativa pode ser confirmada pelo fato da segunda pontuação mais baixa entre todas as respostas dos participantes foi para a pergunta “Como você integra seus dados?” (GD-6) onde mais de 50% dos participantes afirmam que “Ainda não temos uma boa maneira de integrá-lo”. Tais pontos estão sendo endereçado pela atual gestão, conforme supracitado na dimensão de infraestrutura. Além disso, para dados não estruturados não existe um processo de gestão ou governança e ainda não existem iniciativas para avançar nesses pontos.

A **Chief Tech Office** afirma que o desconhecimento dos caminhos para coletar os dados e dos serviços disponíveis as equipes ainda investem tempo na criação de dados que já estão disponíveis de forma automática:

“não temos um catálogo ou dicionário de dados de todos os serviços, dashboards, ferramentas que estão disponíveis para o usuário. Isso acaba gerando retrabalho, cruzamento manual de dados levando a reprodução de informações incorretas. Uma vez implementado esse processo haveria um avanço pois os profissionais com capacidade analítica poderiam usar as ferramentas de maneira self-service, aumentando a autonomia para gerar visões e insights”

Chief of Staff adiciona que houve evolução na gestão de dados táticos para a operação da empresa, mas que a cultura *data-driven* ainda não está permeada para dados e informações estratégicas:

“dados relacionados a rotinas são bem armazenados, não é difícil encontrar nos sistemas e as fontes são bem documentadas. Acredito que o desafio nessa gestão está relacionado aos dados mais estratégicos. Por exemplo eu consigo facilmente extrair a venda da empresa para uma farmácia em Manaus, mas vou demorar horas para encontrar o dado e a fonte da nossa meta de venda para 2028”.

A preocupação em relação a pouca evolução quanto a integração dos dados ainda é um tema que faz parte das discussões de equipe, conforma comentário do **Analista de Comex:**

“existem fontes diversas de dados auditáveis, mas o cruzamento desses dados, a fim de gerar insights ou tomada de decisão, ainda é feito manualmente. Criando uma dependência do componente humano para correlacionar uma fonte a outra”.

Em resumo, a percepção dos respondentes é de que a empresa consegue armazenar de maneira adequada seus dados e que para boa parte dos departamentos a construção de dashboards para melhorar a visualização e apoiar no processo de tomada de decisão já é uma realidade quando se tratam de dados auditáveis e operacionais. Por outro lado, ainda se observa uma necessidade de evolução no mapeamento e comunicação do repositório onde cada informação pode ser

encontrada e como os dados podem ser integrados a fim de facilitar sua localização e cruzamento.

4.1.4 Dimensão das Análises: FASE – Early Adoption

Quando se trata de uma empresa na fase **Early Adoption** quanto a dimensão Análises, pode haver iniciativas na construção de *Power BIs*, descoberta de dados ou ferramentas de análise em todo a organização. Normalmente, essas são ferramentas de autoatendimento que permitem fatiar e dividir dados e a visualização destes. Pode haver alguns grupos ou indivíduos, com algum histórico de realização de análise de dados para tarefas como aprovações de empréstimos ou análise de risco por exemplo. Esses já são adeptos de análises mais avançadas, como modelagem preditiva, mas podem estar alinhados no nível de departamento ou linha de negócios. Também pode haver consultorias externas que estão ajudando a definir a estratégia de análise ou têm colaboradores no local, que realizam análises avançada. Ter equipes com os conjuntos de habilidades apropriados para análise dos dados disponíveis pode ser um problema.

A figura abaixo representa a média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Análises:

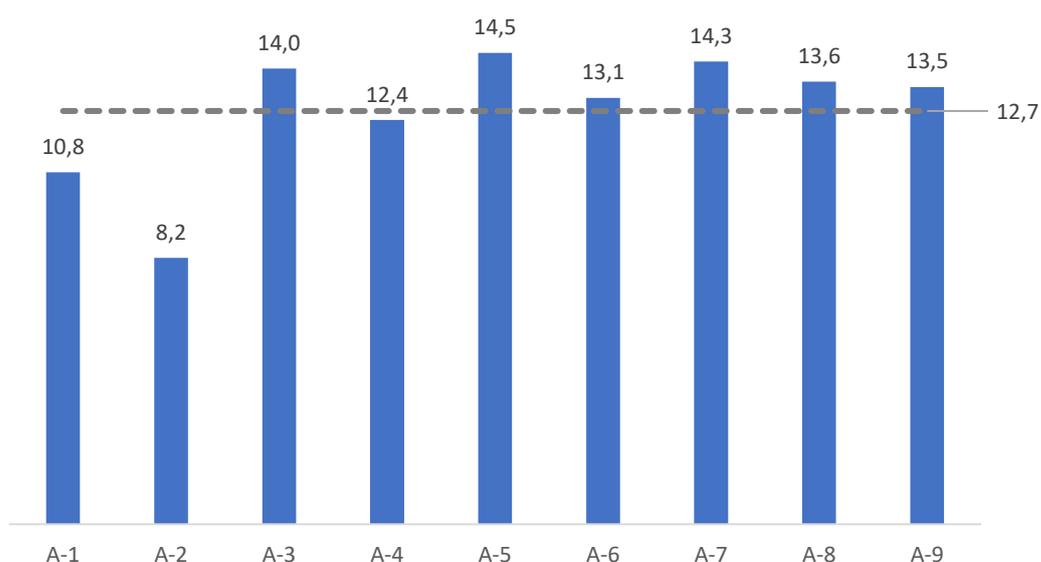


Figura 18. média entre a pontuação das respostas obtidas na survey para as perguntas relacionadas a dimensão de Análises

A respeito da dimensão de análises, o resultado faz sentido com o momento vivido pela empresa, uma vez que, iniciativas de construção *de BIs* vêm sendo exploradas por diferentes áreas da empresa, ainda que a construção deles seja através do trabalho de consultorias externas por falta de mão-de-obra apta a executar esse tipo de projeto entre o quadro efetivo. Além da dificuldade de encontrar profissionais capazes de trabalhar internamente na construção de *BIs* a empresa ainda não possui dentro das áreas um *expert* responsável por esse tipo de iniciativa e acaba se tornando dependente de times como o de *Tech* e *Business Excellence* para avançar nessas agendas. Essa afirmativa gera um ponto de atenção, uma vez que, aproximadamente 60% dos respondentes acreditam que menos de 20% dos integrantes dos times de negócio possuem capacidade de criar *PowerBIs* ou ferramentas automatizadas de análise. Em contrapartida cerca de 57% dos participantes da pesquisa acreditam que “possuem uma boa ideia das perguntas que gostariam que fossem respondidas através da análise dos dados”.

O Chief Tech Office expõe que a empresa está criando uma *Academy* para desenvolver *champions* voluntários dentro de cada área. Ademais, ele diz:

“Vamos setar uma expectativa de formação mínima e testá-las através de certificações, provando os capabilities e direcionando uma jornada de desenvolvimento. Essa pessoa será responsável por fomentar iniciativas e direcionar as ações de inovação”.

O Chief of Staff argumenta que a formação do profissional da empresa ainda é técnica, observando as necessidades do cliente médico, mas menos focados nas necessidades do cliente final ou do negócio:

“ainda existe um gap analítico em boa parte das equipes. Isso se reflete na base da pirâmide, onde profissionais recém-formados, boa parte deles farmacêuticos, tem uma visão sólida em relação a informações técnicas, dos produtos que comercializamos, mas não tem uma visão clara do negócio e das skills financeiras necessárias para ocupar um cargo de gestão. Já entre profissionais mais sênior sinto um viés de seguir olhando os dados que sempre existiram, como visitação dia ou cobertura de médicos visitados. Acredito que a confiança no conhecimento

empírico e em um formato que já deu certo impede que esses profissionais tomem decisões baseadas em toda a base de dados disponíveis atualmente”.

Em contrapartida o **Analista de Comex** expõe que nas áreas de operações a combinação entre perfis técnicos e de negócios é menos incomum:

“dentro de supply a maior parte dos funcionários são engenheiros que tem maior treinamento em análise de dados e novas tecnologias durante sua formação profissional, logo cada time tem um profissional que conhece a operação e tem conhecimento para estruturar um dashboard nesse formato”.

Dessa forma, de acordo com a percepção dos respondentes, existe uma variação grande entre a maturidade dos diferentes times para essa dimensão. A empresa em geral tem uma boa ideia das expectativas que podem ser atendidas com a construção e automatização dos dados, porém existe um *gap* quanto ao profissional com capacidade técnica de executar essa ação. Isso gera uma dependência dos times de *Tech* e *Commercial Operation* gerando filas de iniciativas a serem implementadas.

4.1.5 Governança: FASE – Corporate Adoption

Uma empresa no estágio de *Corporate Adoption* na dimensão Governança, entende que o *analytics*, com todos os seus benefícios, pode ser um risco, especialmente se dados de fontes externas fizerem parte da equação. Uma empresa nesta fase deve se preocupar em responder perguntas como: “De quem eram os dados? De quem são os dados? Aonde vai? Quanto tempo vai durar?”. Para governança de dados, um esforço semelhante será realizado com uma estratégia de dados bem definida e comitê de gestão e direção supervisionando o progresso dos dados. O gerente geral (*sponsor* do projeto) está envolvido em atualizações mensais. O programa é executado de acordo com o orçamento e tratado em pé de igualdade com outros programas de integração de dados. A empresa nesse estágio equilibra as necessidades de política e privacidade de dados com os requisitos dos usuários para ter os dados apropriados de que precisam para análises relevantes, oportunas e consistente.

A figura abaixo representa a média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Análises:

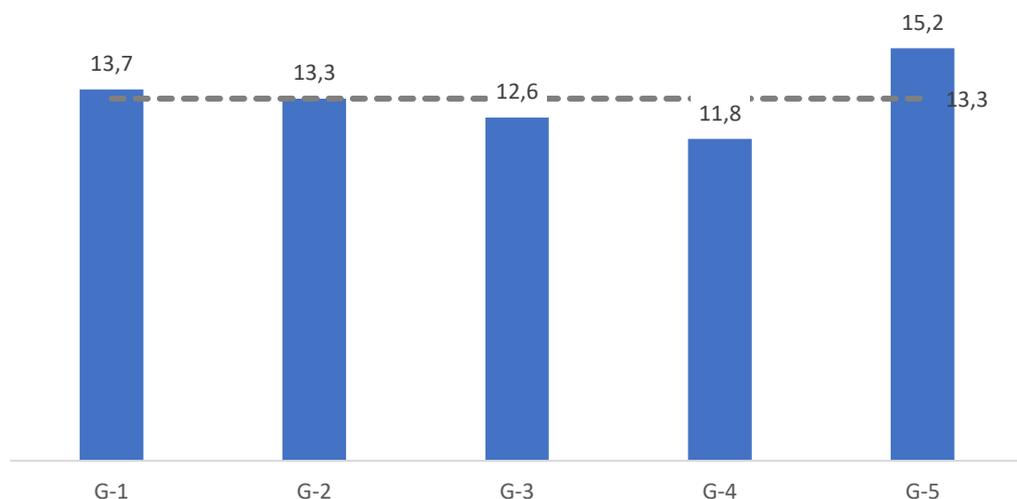


Figura 19. média entre a pontuação das respostas obtidas na *survey* para as perguntas relacionadas a dimensão de Análises

Pode-se observar que nessa dimensão a empresa obteve pontuação acima da média e ficou com status de Corporate adoption. Entendo que nessa dimensão o status mais avançado dentro do modelo de maturidade se deve ao fato da empresa ter um histórico bem-sucedido de negócios com governos federal e estaduais, onde a necessidade de cuidado com dados é maior, logo os times de Legal e Compliance estão envolvidos nos Comitês Comerciais e lideram reuniões mensais de mapeamento de riscos. Cerca de 47% dos participantes entrevistados acreditam que a afirmativa “as políticas de gerenciamento e propriedade de dados estão em vigor e documentadas em minha empresa” é válida por toda a organização. Além disso, por ser tratar de um setor regulado, parte relevante dos dados capturados são demandados por agências como ANVISA ou CMED.

Contudo, apesar do bom resultado nessa dimensão o comentário do **Chief Tech Office** demonstra que parte dessa percepção se deve ao fato do perfil de governança da empresa:

“apesar dos avanços na cultura de governança, a empresa ainda tem um perfil risk avoidance e isso acaba limitando o avanço na maneira como os dados são analisados”.

O fato da empresa não estar em uma indústria pioneira na parte de inovação, salvo quando se trata de produtos inovadores, contribui para que no momento que uma iniciativa é implementada os *benchmarkings* de governança já são conhecidos, conforme comento o *Chief of Staff* da empresa:

“a empresa tem perfil conservador para iniciativas inovadoras. Além disso estamos em um mercado aonde a inovação chega 3 anos depois de implementado em varejo ou consumo. Sendo assim, é de se esperar que, uma vez implementado uma inovação no setor farmacêutico já existe benchmarkings de mercado para acompanhamento e aprovação dos temas”.

Nessa dimensão os resultados da pesquisa apontam para uma maior maturidade na empresa em comparação com as outras dimensões principalmente puxadas pela crença de que os processos e políticas de governança estão bem estabelecidos entre as diferentes áreas da empresa. Por outro lado, as entrevistas em profundidade apontam que esse resultado possivelmente tem por trás o perfil *risk avoidance* da empresa e da indústria farmacêutica em geral e um atraso estrutural na implementação de iniciativas inovadoras, o que acaba levando a um melhor conhecimento das boas práticas de mercado no momento da implementação.

4.2 A Relação entre a percepção de Maturidade em BI e a percepção de criação de Vantagem Competitiva e melhoria em Performance

A fim de complementar o trabalho previamente realizado através da análise dos dados coletados via *survey*, realizada via *google forms*, e das entrevistas em profundidade realizadas com 4 respondentes da *survey* que possuem papel fundamental na operação da empresa objeto de estudo, optou-se por complementar a análise do resultado com: (i) uma análise de fator, com o objetivo de reduzir o número de variáveis de vantagem competitiva e desempenho. Além disso, os resultados da análise de fator foram usados para construir índices para análise posterior de regressão; (i) Regressão múltipla, que teve como objetivo explorar a relação entre uma variável dependente (fator de desempenho e VC) e outras variáveis independentes (dimensões de maturidade), a fim de através da análise de relações construir propostas de soluções para problemas, ou nesse caso, proposta

de melhorias para a empresa. Por fim, com essa sessão pretende-se atingir o objetivo secundário 4, que é de avaliar quantitativamente a relação entre percepção **da maturidade** em BI e a percepção do potencial de criação de vantagem competitiva e desempenho por meio da adoção de BI. No presente capítulo traremos somente os resultados das análises, a discussão desses resultados foram incluídas no capítulo 4.2.3.

4.2.1 Tratamento dos Dados

Uma vez iniciado o tratamento dos dados, através de análise de valores ausentes no SPSS foram identificados em 3 cases um total de 5 Dados Faltantes entre as respostas da pesquisa *via survey*. Conforme refletidos nas tabelas abaixo:

1.- Análise de Valores Ausentes

Estatísticas univariadas						
	N	Média	Desvio Padrão	Ausente		N de ...
				Contagem	Porcentagem	Baixo
A1	32	10,844	3,4235	0	,0	0
A2	32	8,209	3,6310	0	,0	0
A3	32	14,041	5,0007	0	,0	0
A4	31	12,448	2,8652	1	3,1	0
A5	31	14,523	2,5269	1	3,1	0
A6	32	13,134	2,9174	0	,0	1
A7	32	14,253	3,1630	0	,0	1
A8	32	13,638	2,8284	0	,0	0
A9	31	13,471	2,3320	1	3,1	0
GD1	31	9,939	3,8145	1	3,1	0
GD2	32	13,2453	5,34146	0	,0	0
GD3	32	12,866	4,8807	0	,0	0
GD4	32	11,753	2,8997	0	,0	0
GD5	32	14,375	3,6326	0	,0	0
GD6	32	8,525	3,6374	0	,0	0
GD7	32	11,450	3,5380	0	,0	0
GD8	32	15,106	4,5522	0	,0	5
GD9	32	12,347	3,2397	0	,0	0
GD10	32	12,538	2,9971	0	,0	1
GD11	32	10,963	3,2301	0	,0	0
GD12	32	13,737	2,7211	0	,0	0
GD13	32	13,216	2,2850	0	,0	0
G1	32	13,863	3,4697	0	,0	1
G2	32	13,328	2,7053	0	,0	1
G3	32	12,631	3,0061	0	,0	2
G4	32	11,847	3,2234	0	,0	0
G5	32	15,178	2,9488	0	,0	0
I1	32	11,422	4,8192	0	,0	0
I2	32	12,931	2,7647	0	,0	0

Tabela 2. Análise de valores ausentes

Estatísticas univariadas

	N	Média	Desvio Padrão	Ausente		N de ...
				Contagem	Porcentagem	Baixo
I3	32	12,031	2,5441	0	,0	0
O1	32	16,050	4,0292	0	,0	3
O2	32	12,994	4,8719	0	,0	0
O3	32	12,944	3,4571	0	,0	0
O4	32	16,569	2,5072	0	,0	2
O5	32	12,244	3,2016	0	,0	0
O6	32	12,134	2,9365	0	,0	2
O7	32	14,778	3,4192	0	,0	0
O8	32	14,044	2,9957	0	,0	1
O9	32	12,259	3,4271	0	,0	0
O10	32	13,628	2,9029	0	,0	2
Organização	32	13,664	2,1934	0	,0	1
Infraestrutura	32	12,128	2,1838	0	,0	0
Gestão de Dados	32	12,318	1,5870	0	,0	0
Análises	32	12,716	1,8371	0	,0	0
Governança de dados	32	13,329	2,1034	0	,0	0
VC1	32	4,125	1,0395	0	,0	0
VC2	32	4,500	,7620	0	,0	1
VC3	31	4,581	,6720	1	3,1	0
VC4	32	4,406	,7976	0	,0	0
P1	32	4,438	,7156	0	,0	0
P2	32	4,500	,7184	0	,0	0
P3	32	4,500	,6720	0	,0	0
P4	32	4,500	,7620	0	,0	0
P5	32	4,188	,8590	0	,0	0
P6	32	4,438	,7156	0	,0	0
P7	32	4,500	,7620	0	,0	1
P8	32	3,563	,9136	0	,0	0

Tabela 3. Estatísticas Univariadas

Identificou-se que 4 dentre esses estão entre as perguntas do modelo de maturidade *em Business Intelligence*. Observando as perguntas onde não obteve-se respostas de um dos respondentes identificamos que: (i) em nenhum dos casos se tratava de uma pergunta técnica, todas buscavam entender apenas a percepção do respondentes; (ii) entre elas 3 (A-4, A-5, A-9) tinham a opção de resposta Neutral que seria a opção válida se o respondente não tivesse uma percepção a compartilhar sobre a pergunta; (iii) no caso da outra pergunta com dado faltando (GD-1) observamos que se tratava de uma pergunta com opção de resposta Yes ou No quanto ao uso de celulares para análise de dados. Sendo assim, entende-se que em todos os casos os respondentes estariam aptos a responder ou optar por uma resposta neutra caso não houvesse certeza quanto a percepção. Por isso, concluímos que nesses casos se trata de Faltas Completamente Aleatórias (MCAR) pois as faltas não apresentam padrão ou relação com o sujeito, logo não se observa nenhuma razão a não ser o acaso (sujeito esquece de responder ou pula a pergunta sem querer) para os dados faltantes. Vale mencionar que sendo os dados faltantes são aleatórios o impacto tende a ser pequeno, uma vez que, não existe padrão entres esses dados

e a falta não tem relação com a pesquisa. Além disso, eles representam um baixo percentual do total das respostas do banco de dados coletado.

Para esses casos, uma vez que, o modelo de maturidade calcula os índices das respostas e das dimensões através da média optamos por tratar os dados faltantes mantendo-os e calculando os índices com base nas outras perguntas da dimensão, pois dessa forma não traríamos impacto para a análise. Além disso, entendeu-se que o impacto de tratar dessa forma seria menor que eliminar os respondentes que geraram dados faltantes pois dessa forma o n de respondentes ficaria menor que os 30 preconizados por Hair et al (2010).

O outro dado faltante aconteceu na pergunta VC-3, que relaciona o estágio de maturidade da empresa objeto de estudo com sua capacidade de gerar novos negócios. Nesse caso não existia a opção Neutro caso o respondente não tivesse certeza sobre a sua percepção. Além disso, atualmente o termo *Spawning New Business* não é o mais comum para o desenvolvimento de novos negócios em empresas, tendo sido substituído tanto na literatura quanto no mundo corporativo pela expressão *Business Development*, sendo assim pode ter havido dúvida do respondente sobre o questionamento. Pelos motivos supracitados, optou-se por eliminar todas as respostas do respondente da pesquisa, pois ainda assim ficaríamos com 31 respondentes.

4.2.2 Análise de Fator

Existem basicamente quatro passos para a condução da análise fatorial: (i) entrada de dados; (ii) cálculo das correlações entre as variáveis; (iii) extração inicial dos fatores; (iv) rotação da matriz.

Teste de KMO e Bartlett

Medida Kaiser-Meyer-Olkin de adequação de amostragem.		,757
Teste de esfericidade de Bartlett	Aprox. Qui-quadrado	197,436
	df	55
	Sig.	,000

Tabela 4. Teste de KMO e Bartlett

A tabela acima demonstra os resultados de 2 testes que indicam a adequação de seus dados para detecção de estrutura. O Teste de KMO é uma estatística que indica a proporção de variância em suas variáveis que pode ser causada por fatores subjacentes. Valores próximos a 1,0 em geral indicam que uma análise de fator pode ser útil com esses dados. O resultado 0,757 indica que existe uma boa correlação entre as variáveis e que a qualidade da análise será satisfatória. Além disso, temos o teste de Bartlett, que testa a hipótese de que sua matriz de correlação é uma matriz de identidade, o que indicaria que suas variáveis não estão relacionadas e, portanto, inadequadas para a detecção de estrutura. Valores abaixo do nível de significância indicam que uma análise de fator pode ser útil com seus dados. Uma vez que a significância ficou em 0,000 podemos considerar que existem benefício na aplicação de uma análise de fator.

Matrizes anti-imagem

		VC-1	VC-2	VC-3	VC-4	P-1	P-2
Covariância anti-imagem	VC-1	,471	-,099	,025	,009	,015	,103
	VC-2	-,099	,334	,011	-,010	,051	,055
	VC-3	,025	,011	,201	-,145	,003	,003
	VC-4	,009	-,010	-,145	,223	,008	-,063
	P-1	,015	,051	,003	,008	,294	,047
	P-2	,103	,055	,003	-,063	,047	,455
	P-3	-,033	-,037	-,041	,006	-,177	-,124
	P-4	-,006	-,134	-,069	,069	-,080	-,110
	P-5	-,036	,030	,073	-,141	,003	,058
	P-7	-,129	-,151	-,108	,037	-,063	-,097
P-8	-,147	-,054	-,074	,067	-,027	-,032	
Correlação anti-imagem	VC-1	,819 ^a	-,248	,080	,028	,041	,223
	VC-2	-,248	,801 ^a	,041	-,036	,162	,141
	VC-3	,080	,041	,768 ^a	-,687	,011	,010
	VC-4	,028	-,036	-,687	,707 ^a	,031	-,199
	P-1	,041	,162	,011	,031	,787 ^a	,129
	P-2	,223	,141	,010	-,199	,129	,799 ^a
	P-3	-,100	-,132	-,186	,026	-,666	-,374
	P-4	-,018	-,479	-,318	,303	-,306	-,339
	P-5	-,101	,102	,319	-,581	,011	,167
	P-7	-,302	-,421	-,387	,126	-,185	-,231
P-8	-,303	-,131	-,233	,202	-,071	-,067	

Tabela 5. Matrizes Anti-imagem

Analisando a matriz anti-imagem, os valores da diagonal principal também representam uma medida de adequação dos dados à análise de fator, para cada uma

das variáveis analisadas. Avaliando os resultados da análise de fator rodada antes da versão final identificou-se que o P-6 deveria ser eliminado da análise, uma vez que, de acordo com a literatura valores abaixo de 0,5 indicam que a variável pode não se ajustar à estrutura definida pelas outras variáveis, sendo assim, poderá ser eliminada.

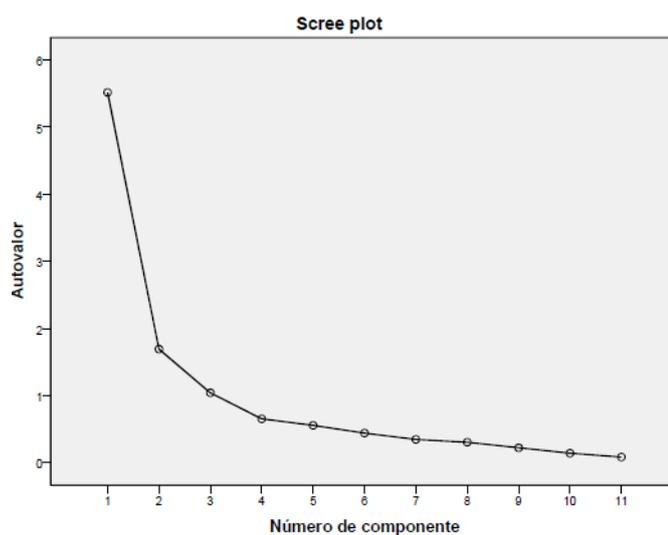


Figura 20. determinação do número ideal de fatores

A figura acima (*scree plot*) ajuda na determinação do número ideal de fatores. Sendo a última grande queda entre o quarto e o quinto componentes, optou-se por extrair 4 fatores para rotação.

Componente	Valores próprios iniciais			Somadas de extração de carregamentos ao quadrado	
	Total	% de variância	% cumulativa	Total	% de variância
1	5,516	50,149	50,149	5,516	50,149
2	1,692	15,385	65,533	1,692	15,385
3	1,041	9,468	74,999	1,041	9,468
4	,654	5,946	80,946	,654	5,946
5	,556	5,051	85,997		
6	,441	4,010	90,006		
7	,347	3,151	93,158		
8	,305	2,775	95,933		
9	,222	2,022	97,955		
10	,141	1,282	99,238		
11	,084	,762	100,000		

Tabela 6. quantidade de variância nas variáveis originais contabilizadas por cada componente

Variância total explicada

Componente	Somas de extração de ...	Somas rotativas de carregamentos ao quadrado		
	% cumulativa	Total	% de variância	% cumulativa
1	50,149	2,467	22,424	22,424
2	65,533	2,377	21,605	44,029
3	74,999	2,269	20,629	64,659
4	80,946	1,792	16,287	80,946
5				
6				
7				
8				
9				
10				
11				

Método de Extração: Análise de Componente Principal.

Tabela 7. Variância total explica

Na tabela 8, a coluna total nos mostra a quantidade de variância nas variáveis originais contabilizadas por cada componente, na coluna % de Variância observamos a proporção, expressa em porcentagem, da variância contabilizadas por cada componente e na coluna % cumulativa dá a porcentagem de variância contabilizadas pelos componentes somadas.

A segunda seção da tabela, podemos observar os componentes extraídos da análise. Com eles, podemos explicar aproximadamente 81% da variabilidade nas 11 variáveis originais, dessa forma se pode reduzir consideravelmente a complexidade do conjunto com apenas uma perda de 19% de informações.

Matriz de componente^a

	Componente			
	1	2	3	4
VC-1		,615		
VC-2	,706			
VC-3	,837			
VC-4	,743			
P-1	,715			
P-2	,647			
P-3	,697			
P-4	,815			
P-5	,801			
P-7		,630		
P-8	,688			

Método de Extração: Análise de Componente Principal.

a. 4 componentes extraídos.

Tabela 8. Matriz de componentes

Matriz de componente rotativa^a

	Componente			
	1	2	3	4
VC-1		,851		
VC-2		,712		
VC-3			,775	
VC-4			,817	
P-1	,812			
P-2			,643	
P-3	,879			
P-4				,789
P-5				,759
P-7		,772		
P-8	,643			

Método de Extração: Análise de Componente Principal.
Método de Rotação: Varimax com Normalização de Kaiser.

a. Rotação convergida em 8 iterações.

Tabela 9. Matriz de Componentes Rotativa

A matriz de componentes rotativa foi usada para determinar o que os componentes representam. Através do método de rotação foi possível reduzir o tamanho e a complexidade dos dados de 11 variáveis para 4 fatores com uma extração de componentes principais. Essa redução gera uma perda para análise, porém nesse caso, acredita-se que os benefícios em reduzir os dados superam esse custo.

Matriz de transformação de componente

Componente	1	2	3	4
1	,527	,457	,529	,483
2	-,558	,810	-,176	,034
3	,596	,247	-,762	-,051
4	,235	,270	,330	-,873

Método de Extração: Análise de Componente Principal.
Método de Rotação: Varimax com Normalização de Kaiser.

Tabela 10. Matriz de transformação de componentes

Em resumo, os passos anteriormente descritos permitiram a redução dos dados de forma a criar 4 novos fatores cujas correlações serão analisadas através de regressão:

F1 = *Net Sales* (P-1) + *Operating Margin* (P-3) + *Organizational Climate* (P-8)

F2 = *Lowering Cost* (VC-1) + *Enhancing Differentiation* (VC-2) + *New Products Introduction* (P-7)

F3 = *Changing Competitive Scope* (VC-3) + *Spawning new businesses* (VC-4) + *Profit* (P-2)

F4 = *Market Share Evolution* (P-4) + *Customer Recurrence* (P-5)

4.2.3 Resultados das Regressões

As regressões abaixo foram feitas com o objetivo de determinar se existe uma relação estatisticamente significativa entre as variáveis dependentes e independentes e entre elas quais tem uma correlação mais forte.

4.2.3.1 Regressão F1

A primeira regressão foi realizada considerando o primeiro fator agrupado, gerado considerando as variáveis *Net Sales*, *Operating Margin* e *Organizational Climate* (apêndice 1). Esse novo fator chamamos de F1.

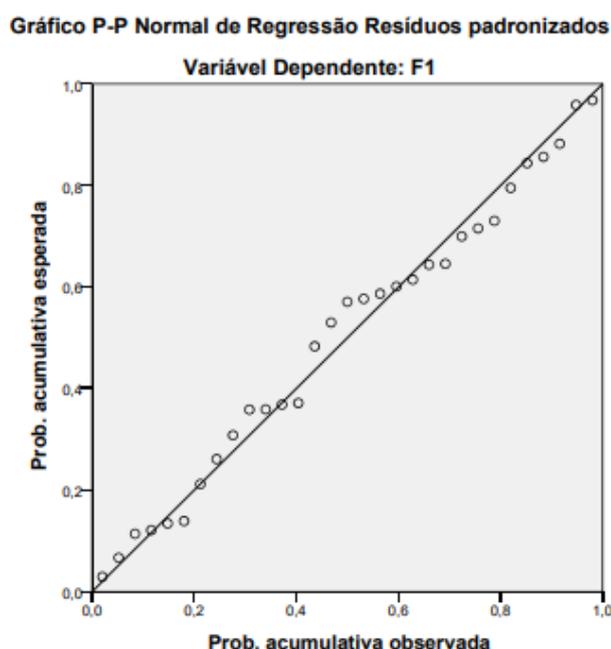


Figura 21. Gráfico P-P Normal F1

O primeiro teste de premissas a ser realizado será o de normalidade, uma vez que, para fazer inferências válidas de sua regressão, os resíduos da regressão devem seguir uma distribuição normal. Conforme demonstrado no gráfico de probabilidade predita (P-P) acima, observamos que os resíduos estão em conformidade com a linha de normalidade diagonal indicada no gráfico.

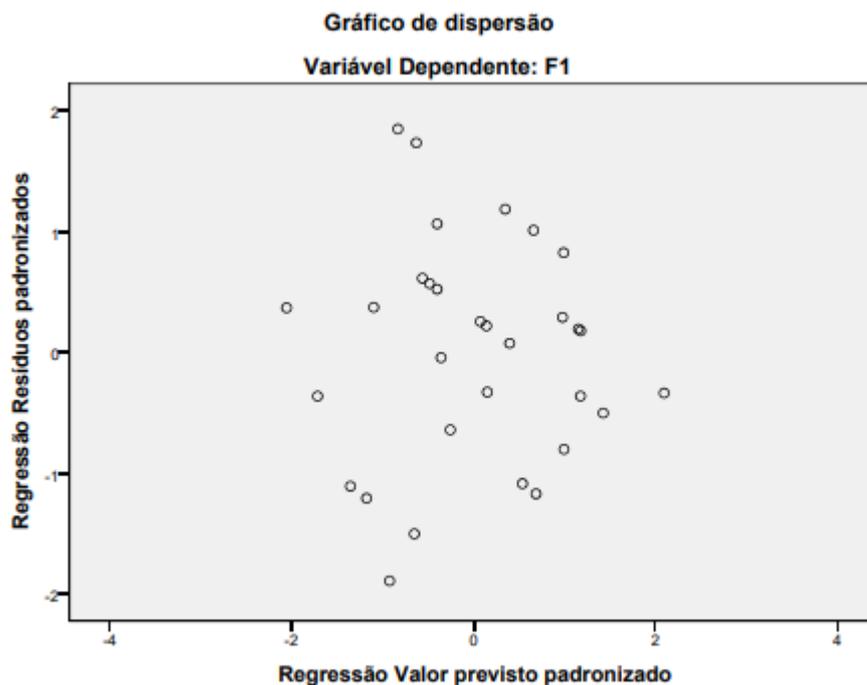


Figura 22. Gráfico Homocedasticidade F1

A homoscedasticidade refere-se a propriedade de um conjunto de dados em que a variância dos resíduos de um modelo de regressão é constante em todos os níveis da variável independente. Na figura acima vemos que existe homocedasticidade.

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização ^b		Inserir

a. Variável Dependente: F1

b. Todas as variáveis solicitadas inseridas.

Quadro 3. Variáveis Inseridas/Removidas F1**Resumo do modelo^b**

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,523 ^a	,274	,129	,61621	1,700

a. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

b. Variável Dependente: F1

Tabela 11. Resumo do Modelo F1

Interpretando os resultados da regressão refletidos no quadro de Resumo do modelo vemos que o R quadrado 0,274 indica que 27,4% da variância na percepção dos respondentes em relação a variável dependente F1 pode ser explicada pelos preditores. Como o interesse desse trabalho é simplesmente entender a relação entre as variáveis não gera um ponto de preocupação específico o baixo valor de R quadrado. Sendo o resultado 1,7, entre o range de 0 e 2, indica que existe uma autocorrelação positiva a amostra.

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	3,582	5	,716	1,887	,133 ^b
	Resíduo	9,493	25	,380		
	Total	13,075	30			

a. Variável Dependente: F1

b. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

Tabela 12. Teste Anova F1

Em relação ao teste ANOVA, o resultado de valor-p igual a 0,133. Uma vez que, consideramos o nível de significância (alfa) como 0,05, não é possível afirmar que existe uma diferença significativa entre as médias estatísticas das variáveis. Logo, não há provas suficientes para rejeitar a hipótese nula de que as médias são todos iguais. Nesses casos, uma vez que a tabela já demonstra uma ausência de relação, os resultados da regressão serão mantidos abaixo, mas não serão feitos comentários em relação a eles.

Coeficientes^a

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.
	B	Erro Padrão	Beta		
1 (Constante)	6,610	1,055		6,265	,000
Organização	,097	,100	,322	,970	,341
Infraestrutura	-,077	,064	-,261	-1,209	,238
Gestão de Dados	,044	,111	,107	,398	,694
Análises	-,094	,101	-,255	-,930	,361
Governança de dados	-,163	,069	-,505	-2,370	,026

a. Variável Dependente: F1

Tabela 13. Coeficientes F1

4.2.3.2 Regressão F2

A segunda regressão foi realizada considerando o segundo fator agrupado, gerado considerando as variáveis *Lowering Cost*, *Enhancing Differentiation* e *New Products Introduction* (apêndice1). A esse novo fator demos o nome de F2.

Gráfico P-P Normal de Regressão Resíduos padronizados

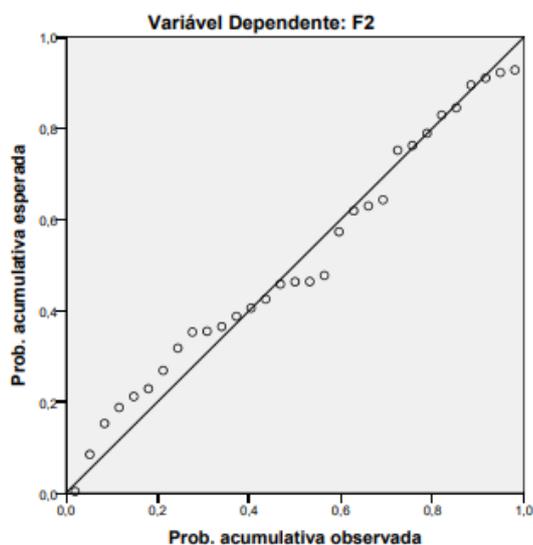


Figura 23. Gráfico P-P Normal F2

Podemos observar no gráfico de probabilidade predita (P-P) acima que existe normalidade, uma vez que, os resíduos estão em conformidade com a linha de normalidade diagonal indicada no gráfico.

Gráfico de dispersão

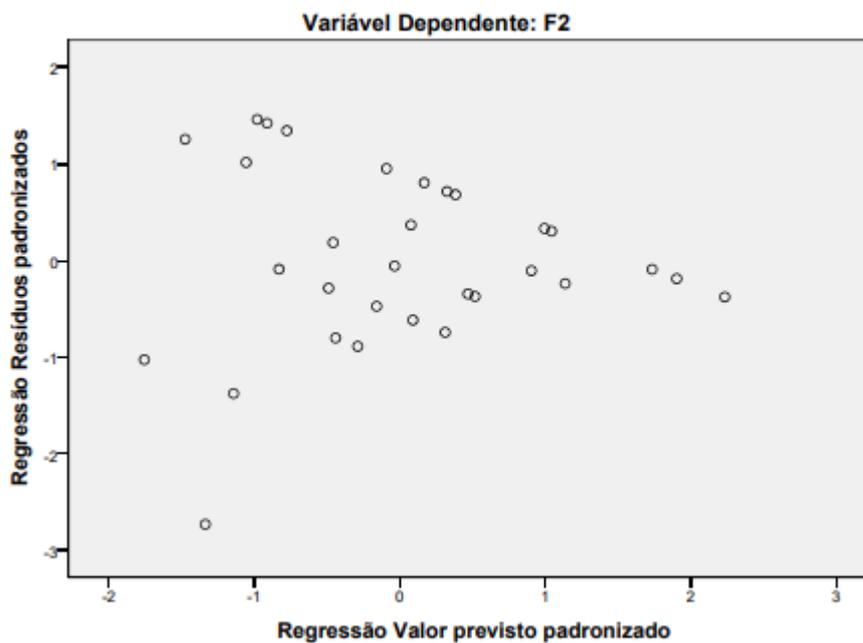


Figura 24. Gráfico Homocedasticidade F2

Ao analisar a figura acima, é possível observar que existe um padrão de dispersão em todo o eixo X, descrevendo no gráfico um formato cônico, o que indica heterocedasticidade.

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização ^b		Inserir

a. Variável Dependente: F2

b. Todas as variáveis solicitadas inseridas.

Quadro 4. Variáveis Inseridas/Removidas F2

Resumo do modelo^b

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,530 ^a	,281	,137	,68341	2,298

a. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

b. Variável Dependente: F2

Tabela 14. Resumo do modelo F2

Com os resultados refletidos no resumo do modelo observamos que R quadrado 0,281, ou seja, 28,1% da variância na percepção dos respondentes em relação a variável dependente F2 pode ser explicada pelos preditores. Como o interesse desse trabalho é não estar relacionado a predição a relação entre as variáveis não gera um ponto de preocupação específico o baixo valor de R quadrado. Em relação ao teste de Durbin-Watson, o resultado 2,298, que fica dentro do range de 2 e 4, indicando que existe autocorrelação negativa.

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	4,568	5	,914	1,956	,121 ^b
	Residuo	11,676	25	,467		
	Total	16,244	30			

a. Variável Dependente: F2

b. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

Tabela 15. Teste anova F2

Em relação ao teste ANOVA, o resultado de valor-p igual a 0,121. Uma vez que, alfa é igual a 0,05, não podemos afirmar se existe diferença significativa entre as médias estatísticas das variáveis. Logo, não há provas suficientes para rejeitar a hipótese nula de que as médias são todos iguais. Da mesma forma feita na regressão acima, não serão feitos comentários em relação a tabela dos Coeficientes.

Coeficientes^a

Modelo		Coeficientes não padronizados		Coeficientes padronizados	t	Sig.
		B	Erro Padrão	Beta		
1	(Constante)	6,586	1,170		5,628	,000
	Organização	-,129	,111	-,385	-1,164	,256
	Infraestrutura	-,066	,071	-,200	-,933	,360
	Gestão de Dados	,087	,124	,190	,708	,486
	Análises	,071	,112	,171	,629	,535
	Governança de dados	-,120	,076	-,333	-1,568	,129

a. Variável Dependente: F2

Tabela 16. Coeficientes F2

4.2.3.3 Regressão F3

A segunda regressão foi realizada considerando o segundo fator agrupado, gerado considerando as variáveis *Changing Competitive Scope*, *Spawning new businesses* e *Profit* (apêndice1). Esse chamamos de F3.

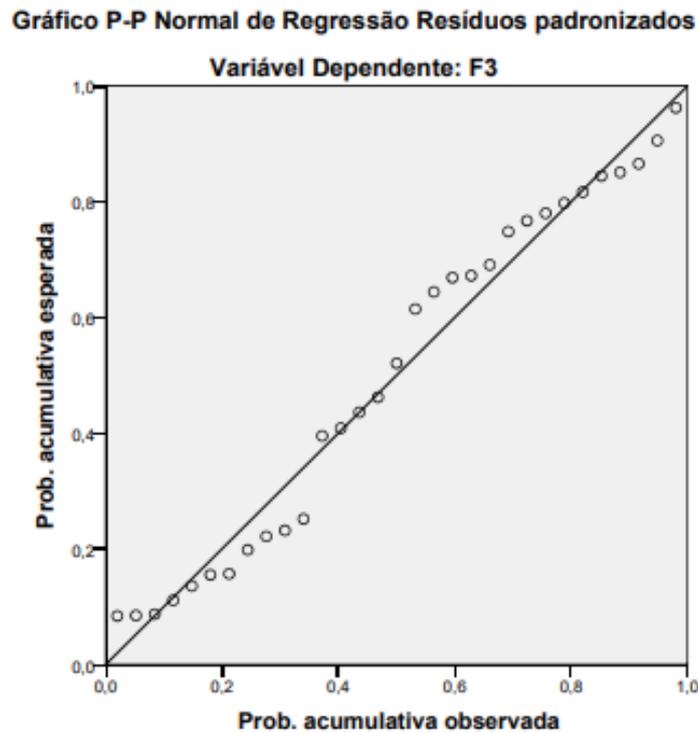


Figura 25. Gráfico P-P Normal F3

A figura de probabilidade predita (P-P) acima que existe normalidade indica que existe normalidade pois os resíduos se encontram em conformidade com a linha de normalidade diagonal indicada.

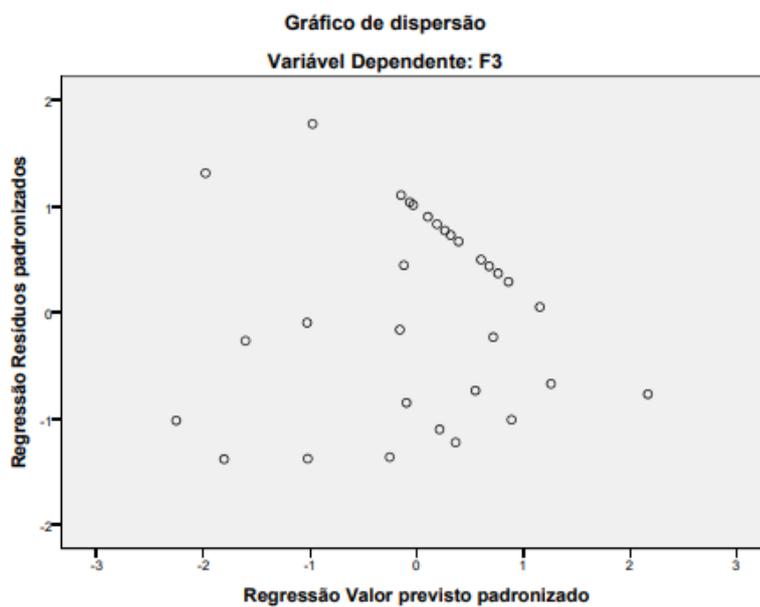


Figura 26. Gráfico Homocedasticidade F3

Ao analisar o gráfico acima, é possível perceber que os resíduos são menos homogêneos em uma pequena parte do gráfico, porém optou-se por seguir com a análise da regressão apesar desse ponto de atenção.

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização ^b		Inserir

a. Variável Dependente: F3

b. Todas as variáveis solicitadas inseridas.

Quadro 5. Variáveis Inseridas/Removidas F3

Resumo do modelo^b

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,663 ^a	,440	,328	,52265	1,867

a. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

b. Variável Dependente: F3

Tabela 17. Resumo do modelo F3

Podemos observar no quadro de resumo do modelo que R quadrado 0,440, ou seja, 44,0% da variância na percepção dos respondentes em relação a variável dependente F3 pode ser explicada pelos preditores. Nessa regressão o valor de R fica mais próximo de 1, sendo assim sugere que existe uma maior relação linear entre as variáveis das observadas no estudo. Em relação ao teste de Durbin-Watson, o resultado 1,867, indica uma autocorrelação positiva entre as variáveis.

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	5,357	5	1,071	3,922	,009 ^b
	Resíduo	6,829	25	,273		
	Total	12,186	30			

a. Variável Dependente: F3

b. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

Tabela 18. Teste anova F3

Em relação ao teste ANOVA, o resultado de valor-p igual a 0,009. Uma vez que, consideramos o nível de significância (alfa) como 0,05, podemos dizer que o valor-p é menor que o nível de significância definido. Sendo assim, podemos rejeitar a hipótese nula e concluir que nem todas as médias são iguais, ou seja, existe uma relação entre as variáveis.

Coeficientes^a

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.
	B	Erro Padrão	Beta		
1 (Constante)	6,653	,895		7,434	,000
Organização	-,005	,085	-,016	-,056	,956
Infraestrutura	-,165	,054	-,573	-3,028	,006
Gestão de Dados	,126	,094	,316	1,333	,194
Análises	,030	,086	,085	,355	,726
Governança de dados	-,153	,058	-,490	-2,616	,015

a. Variável Dependente: F3

Tabela 19. Coeficientes F3

Sobre a tabela de Coeficientes, podemos observar que os valor-p dos preditores: Organização, Gestão de Dados e Análises são maiores que o nível de significância que definimos previamente (Insignificante). Sendo assim, os resultados sugerem que as mudanças nessas preditoras não estão associadas a mudança na resposta. Sendo Governança de dados e Infraestrutura os preditores que possuem valor-p abaixo de alfa, 0,006 e 0,015 respectivamente, o resultado sugere que alterações nos valores desses preditores estão relacionadas as alterações na variável resposta.

Interpretando os resultados dos preditores observamos que seus coeficientes de inclinação, tiveram como resultado -0,165 e -0,153 respectivamente. Os resultados negativos na coluna de coeficientes indicam uma relação inversa entre a variável dependente e os preditores, sendo assim, uma vez que avançamos nos eixos sobre a percepção de Infraestrutura e Governança de Dados podemos observar uma leve queda na percepção de que o uso adequado de *business intelligence* tem influência sobre os resultados da variável **F3**.

4.2.3.4 Regressão F4

A quarta regressão foi realizada considerando o primeiro fator agrupado, gerado considerando as variáveis *Market Share Evolution* e *Customer Recurrence* (apêndice 1). A esse novo fator chamamos **F4**.

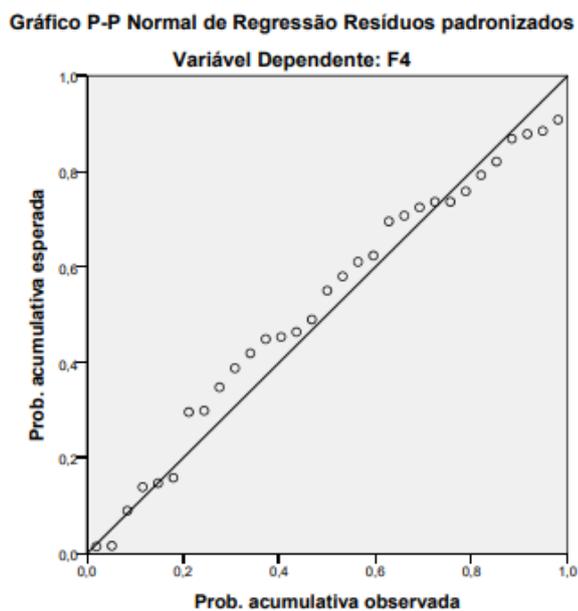


Figura 27. Gráfico P-P Normal F4

O gráfico de probabilidade predita (P-P) acima demonstra que existe normalidade pois podemos observar que os resíduos estão em conformidade com a linha de normalidade diagonal no gráfico.

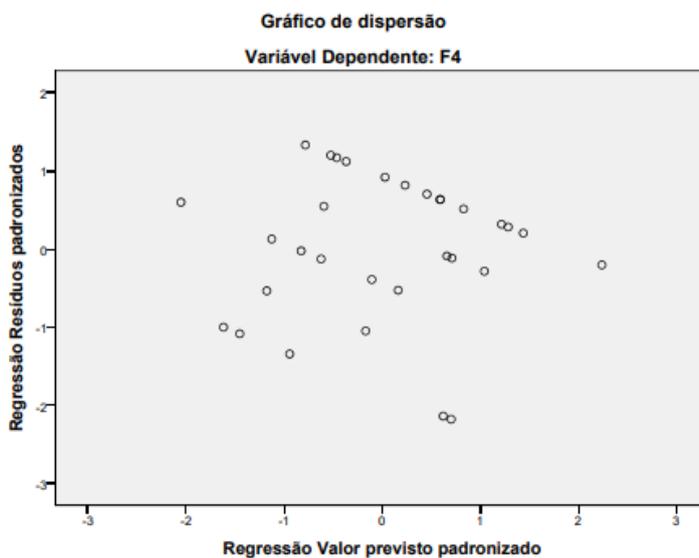


Figura 28. Gráfico Homocedasticidade F4

Ao analisar o gráfico acima, observamos um padrão de dispersão em todo o eixo X, descrevendo no gráfico um formato cônico, o que indica heterogeneidade.

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização ^b	.	Inserir

a. Variável Dependente: F4

b. Todas as variáveis solicitadas inseridas.

Quadro 6. Variáveis Inseridas/Removidas F4

Resumo do modelo^b

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Durbin-Watson
1	,485 ^a	,236	,083	,72672	1,847

a. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

b. Variável Dependente: F4

Tabela 20. Resumo do modelo F4

Considerando os resultados no quadro de Resumo do modelo vemos que o R quadrado 0,236 indica que 23,6% da variância na percepção dos respondentes em relação a variável dependente **F4** pode ser explicada pelos preditores. Como o interesse desse trabalho é simplesmente entender a relação entre as variáveis não gera um ponto de preocupação específico o baixo valor de R quadrado. Em relação ao teste de Durbin-Watson o resultado de 1,847 está dentro da normalidade para análise e uma vez estando entre 0 e 2 sugere que existe uma autocorrelação positiva entre as variáveis.

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	4,071	5	,814	1,542	,213 ^b
	Resíduo	13,203	25	,528		
	Total	17,274	30			

a. Variável Dependente: F4

b. Preditores: (Constante), Governança de dados, Infraestrutura, Análises, Gestão de Dados, Organização

Tabela 21. Teste anova F4

Sobre o teste ANOVA, o resultado aferido do valor-p foi igual a 0,213. Uma vez que, alfa é igual a 0,05, sendo o valor-p maior que alfa, não podemos afirmar se existe diferença significativa entre as médias estatísticas das variáveis. Logo, não há provas suficientes para rejeitar a hipótese nula de que as médias são todos iguais.

Coeficientes^a

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.
	B	Erro Padrão	Beta		
1 (Constante)	7,166	1,244		5,759	,000
Organização	,027	,118	,078	,228	,821
Infraestrutura	-,103	,076	-,300	-1,356	,187
Gestão de Dados	,068	,131	,143	,515	,611
Análises	-,086	,119	-,201	-,718	,480
Governança de dados	-,127	,081	-,342	-1,565	,130

a. Variável Dependente: F4

Tabela 22. Coeficientes F4

4.3 Discussão de Resultados

4.3.1 Discussão dos resultados do Modelo de Maturidade em Business

Intelligence

Considerando as médias entre estas 5 dimensões: Organização, Infraestrutura, Gestão de Dados, Análises e Governança, a empresa obtém o score de 12,8 no modelo de maturidade, sendo assim classificada como *Early Adoption*, conforme podemos observar na tabela abaixo:

Categoria	Resumo Resultado	Estágio de Maturidade
Organização	13,7	Corporate Adoption
Infraestrutura	12,1	Early Adoption
Gestão de Dados	12,3	Early Adoption
Análises	12,7	Early Adoption
Governança de dados	13,3	Corporate Adoption

	Resumo Resultado	Estágio de Maturidade
Empresa Objeto de Estudo	12,8	Early Adoption

Tabela 23. médias entre 5 dimensões

Empresas em estágio de *Early Adoption* em um modelo de maturidade analítica geralmente estão começando a se familiarizar com a análise de dados e sua importância para a tomada de decisões estratégicas. Elas podem estar começando a coletar e armazenar dados, mas ainda não tem uma estrutura ou equipe dedicada para analisá-los. Neste estágio, as empresas podem estar utilizando ferramentas básicas de análise, como planilhas e gráficos estatísticos, e ainda estão aprendendo sobre as diferentes técnicas e ferramentas avançadas disponíveis. O resultado do estágio de *Early Adoption* (descrição dos estágios e do modelo de maturidade no capítulo 2.4.1) próximo ao Abismo, reflete bem o momento corporativo da empresa que teve a chegada de um novo gerente geral no Brasil em julho de 2021, um entusiasta do uso de inovação para incrementar performance. Os primeiros movimentos realizados pela nova liderança foram a reorganização da equipe de Inovação, que foi 100% trocada por profissionais vindos de seguimentos como mercado de Luxo, Consumo e Varejo, vistos como *benchmarking* na aplicação de *Business Intelligence* nos negócios. Além disso, foi implementado o modelo de *Business Partnering* para os profissionais desse setor. Esse modelo faz com que cada profissional seja responsável por suportar uma área de negócios nos seus projetos, isso faz com que cada projeto da empresa tenha em seu grupo de trabalho um profissional de tecnologia, fazendo com que as resoluções dos problemas tenham um olhar mais focado em inovação e um aumento do uso de soluções de prateleira, uma vez que é prática comum entre esses profissionais a adoção de sistemas e processos disponíveis no mercado. O resultado da pesquisa apontando que cerca de 80% dos funcionários acreditam que profissionais especializados estão disponíveis para suportar projetos e tirar dúvidas operacionais pode validar esse *assumption*.

Além da criação desse novo departamento, nesse mesmo período, foi criado um grupo multidisciplinar, liderado pela equipe de negócios, que trabalhou na construção de uma base para integração de todos os dados capturados pelas diferentes áreas da empresa em um único repositório. Essa integração em uma base única irá permitir, em um primeiro momento, a criação de *dashboards* em tempo real que poderão ser usados para tomada de decisão e na sequência, com a evolução no uso de *IA e Machine Learnig*, irá automatizar e escalar a criação de jornadas personalizadas para cada tipo de cliente. Projetos *cross-functional* como esse vem disseminando a cultura de dados através da companhia, conforme aponta o

resultado de que 31% dos respondentes acreditam fortemente que as pessoas já vêm tomando decisões suportadas por ferramentas analíticas.

4.3.2 A maturidade da empresa em *Business Analysis* e a criação de vantagem competitiva sustentada

O uso de dados é fundamental para a obtenção de vantagem competitiva sustentada por uma empresa. A coleta, análise e utilização adequada de dados possibilitam a identificação de oportunidades, tomada de decisões informadas e aprimoramento de processos internos. Além disso, a incorporação de tecnologias de análise de dados, como *machine learning* e inteligência artificial, permite a automação e aceleração de tarefas rotineiras, liberando tempo para ações estratégicas. Em suma, o uso de dados é uma forma de diferenciar a empresa de seus concorrentes e aumentar sua eficiência, agilidade e efetividade.

Os resultados da pesquisa mostram que em geral os respondentes acreditam que o uso adequado dos dados pode gerar impacto em todas as dimensões de vantagem competitiva elencadas por Porter em seu artigo *How information gives you competitive advantage*. São elas:

<i>Lowering Cost</i>	O uso de tecnologia pode alterar os custos de uma empresa em qualquer parte da cadeia de valor. O impacto histórico da tecnologia no custo se limitou a atividades nas quais o processamento repetitivo de informações desempenhou um papel importante. Esses limites não existem mais, no entanto. Mesmo atividades como montagem, que envolvem principalmente processamento físico, agora têm um grande componente de processamento de informações.
<i>Enhancing Differentiation</i>	O impacto da tecnologia da informação nas estratégias de diferenciação é igualmente dramático. A nova tecnologia da informação possibilita a personalização de produtos. Ao agrupar mais informações com o pacote de produto físico vendido ao comprador, a nova tecnologia afeta a capacidade de uma empresa se diferenciar.

<p><i>Changing Competitive Scope</i></p>	<p>A tecnologia aumenta a capacidade da empresa de coordenar suas atividades regional, nacional e globalmente. Ele pode desbloquear o poder de um escopo geográfico mais amplo para criar vantagem competitiva. A revolução da informação está criando inter-relações entre setores que antes eram separados. A fusão de tecnologias de computador e telecomunicações é um exemplo importante. Essa convergência tem efeitos profundos na estrutura de ambas as indústrias.</p>
<p><i>Spawning New Business</i></p>	<p>A revolução da informação está dando origem a indústrias completamente novas de três maneiras distintas. Primeiro, torna os novos negócios tecnologicamente viáveis. Em segundo lugar, a tecnologia da informação também pode gerar novos negócios, criando demanda derivada por novos produtos. Em terceiro lugar, a tecnologia da informação cria novos negócios dentro dos antigos.</p>

Quadro 7. Todas as dimensões de vantagem competitiva podem gerar impacto no uso adequado dos dados

A figura abaixo representa o percentual de respondentes em cada uma das opções mencionadas na legenda abaixo. Lembrando que conforme mencionado no apêndice 1 os números na legenda representam uma escala de um a cinco (um igual a imaterial e cinco igual a muito importante) quanto a percepção de quão relevante é o uso adequado em *business intelligence* para cada dimensão de vantagem competitiva proposta por Porter:

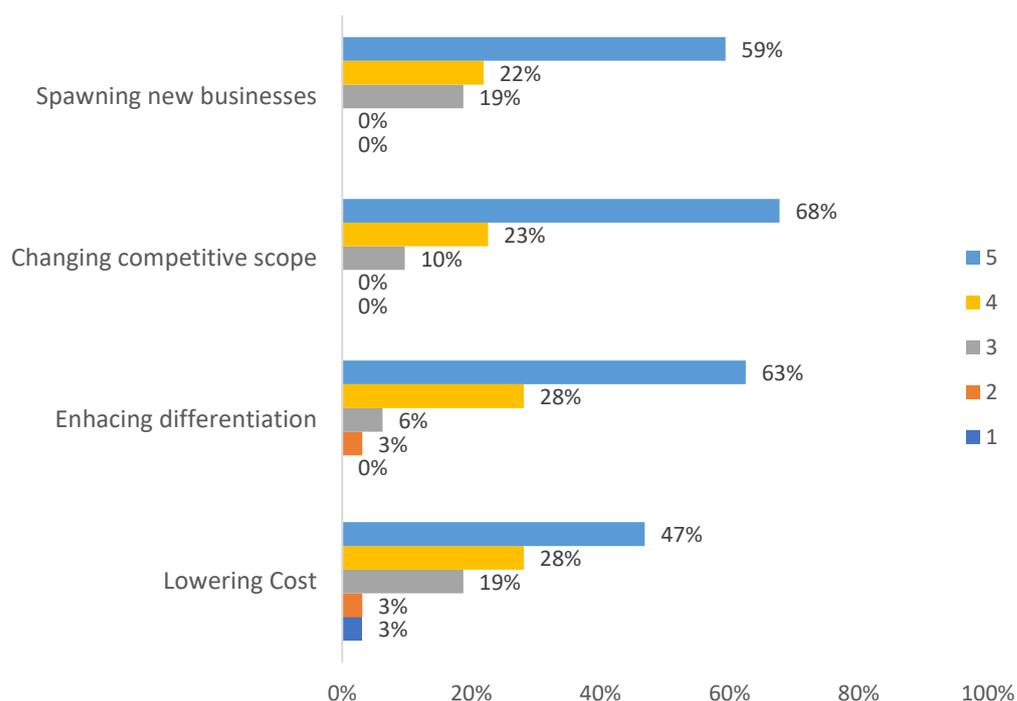


Figura 29. Opção dos respondentes nas opções citadas

Conforme mostra a figura acima, a dimensão que o uso adequado de dados pode gerar maior impacto, de acordo com a percepção dos respondentes, é a *Changing Competitive Scope*. Esse resultado está alinhado com o perfil da empresa uma vez que sua estratégia de crescimento no passado passou por crescer em número de países onde a empresa opera diretamente. Além disso, vem alinhado com o setor de saúde que já passou por diferentes ciclos de consolidação, através de *M&A* e verticalização de operadoras de saúde. Por fim as *BigPharmas* viram a popularização de sistemas de *ERP* e implementação de *BIs* nas indústrias nacionais de genéricos aumentarem de forma significativa a competitividade no setor.

Na sequência *Enhacing Differentiation* aparece como a segunda dimensão mais impactada de acordo com a percepção dos respondentes. O resultado faz sentido para a indústria, uma vez que, parte relevante do faturamento do negócio vem através de produtos patenteados, onde a competição acontece efetivamente na frente do médico, entre diferentes moléculas usadas para tratar uma mesma doença. Nesse caso, o uso adequado dos dados está em demonstrar através de estudos clínicos a diferenciação do seu produto versus a molécula competidora, capturar o comportamento de estudo do médico para garantir que ele será impactado pela

mensagem de diferenciação em seu canal de preferência e monitorar a frequência de visitas de representante necessária para mudar o comportamento prescritivo desse médico. Sendo assim, essa crença ou foco da empresa em buscar a vantagem competitiva através dessa dimensão funciona muito bem para seu portfólio de inovação, protegido por patentes.

Outro ponto relevante para a indústria farmacêutica, representado pela dimensão *Spawning New Business*, é o desenvolvimento de novos mercados através do lançamento de novos produtos e categorias. Nesse ponto, a indústria evoluiu muito nos últimos anos através da implementação de ferramentas estatísticas, analíticas e sistemas automatizados para estudos clínicos que reduzem as fases entre estudos clínicos e otimizam as análises de órgãos reguladores como Anvisa ou FDA.

Um ponto de atenção foi que o uso de dados para redução de custos foi o que teve pior performance entre os respondentes. Esse ponto chama a atenção especialmente pelo contexto macro vivido no país, com inflação e juros (custo do dinheiro) reduzindo as margens dos negócios, aumentando a fricção entre fabricantes, atacadistas e varejo farmacêutico. Esse cenário faz com que empresas que conseguem manter seus custos em ordem, mesmo em indústrias onde a margem cobre parcialmente as ineficiências, possam oferecer melhores condições comerciais, sejam elas através de descontos, prazos ou acordos de estoques. Além dos fatores supracitados, o negócio de produtos sem patentes ainda representa quase metade do negócio da empresa no Brasil, sendo assim, mudar o foco do uso de dados para redução de custos (de promoção e administrativo) é importante para manter a competitividade da empresa frente a fabricantes nacionais de produtos genéricos.

Em resumo, se reconhece a importância de evoluir na maturidade do uso de dados na empresa e fica claro pela pesquisa que essa visão independe do cargo ou tempo em indústria farmacêutica do respondente. Outro ponto que vale ser mencionado é sequência de resultados mais altos: *Changing Competitive Scope*; *Enhancing Differentiation*; *Spawning New Business*, *Lowering Cost* estão de acordo com a visão de futuro da empresa em ser tornar uma biofarmacêutica focada em produtos de inovação. Porém essa é uma jornada mais lenta, uma vez que, depende de resultados de estudos clínicos e aprovação de agências regulatórias. Dessa forma, o negócio de produtos que competem com genéricos ainda será

relevante para a empresa por um bom tempo e nesse seguimento a sensibilidade a preço dos consumidores é maior.

4.3.3 A maturidade da empresa em *Business Intelligence* e o incremento na performance

A maturidade em *Business Intelligence* e a performance dos negócios estão diretamente correlacionados, uma vez que, a primeira fornece as organizações a capacidade de tomar decisões baseadas em dados que podem levar a um melhor desempenho. Ao usar dados para balizar as decisões, as organizações podem entender melhor suas operações, clientes e tendências de mercado, permitindo que tomem decisões conscientes e com clareza do como poderiam melhorar seus resultados. Uma organização pode, por exemplo, identificar áreas de negócios com baixo desempenho e fazer alterações para melhorar a eficiência, reduzir custos ou aumentar a receita. Além de ajudar a identificar áreas de melhoria, *business intelligence* também pode ser usada para medir o sucesso de várias iniciativas, além de identificar oportunidades de crescimento. Ao acompanhar indicadores de desempenho ao longo do tempo, as organizações podem avaliar o impacto de suas estratégias e ajustar o curso, se necessário. Monitorando de perto os indicadores de performance a empresa pode ajustar continuamente suas operações, dessa forma as organizações podem se manter competitivas e melhorar o desempenho dos negócios.

A figura abaixo representa o percentual de respondentes em cada uma das opções mencionadas na legenda. Conforme mencionado no apêndice 1 os números na legenda representam uma escala de um a cinco (um igual a imaterial e cinco igual a muito importante) quanto a percepção de quão relevante é o uso adequado em *business intelligence* para cada um dos principais *KPIs* Financeiros acompanhados pela empresa:

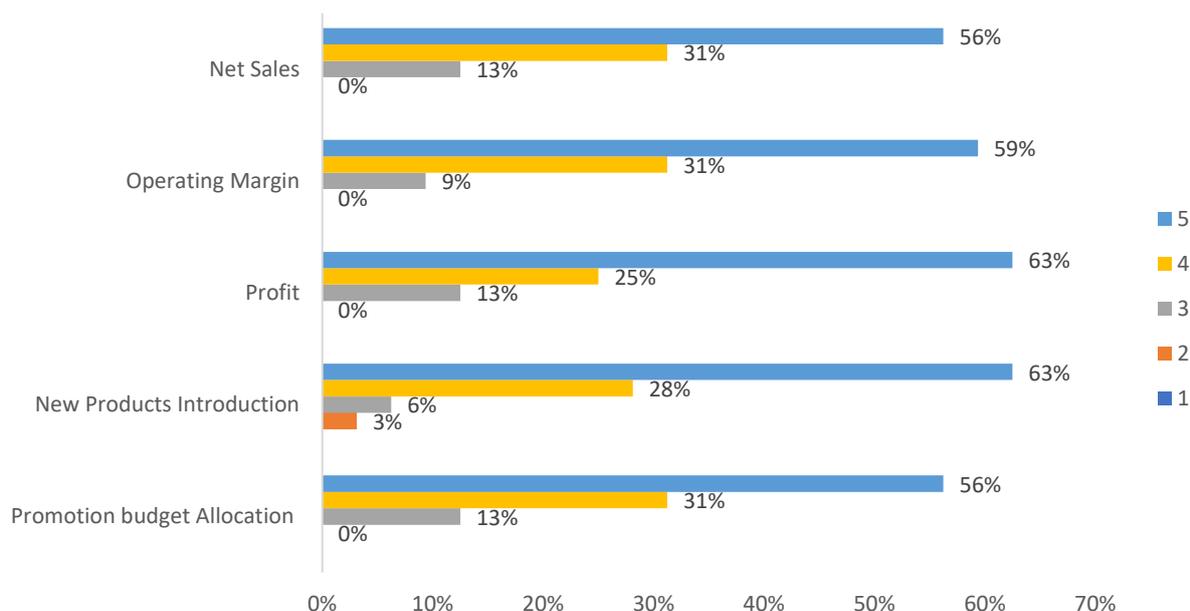


Figura 30. Opção dos respondentes nas opções citadas

Alguns pontos a serem destacados, na figura acima, como *outputs* da pesquisa é a crença que a maturidade de dados tem maior impacto no resultado de lucro que em vendas. Essa percepção dos respondentes está alinhada a pesquisas da *Singularity University* que mostram que o uso adequado das novas tecnologias traz mudanças no modelo neoclássico de crescimento, demonstrando que se pode gerar um mesmo resultado de produção com o emprego de menos capital sendo compensado pelo ganho em produtividade. Trazendo para o contexto desse negócio, pode-se atingir um *P&L leverage*, ou seja, crescer mais em lucro que em vendas, usando a maior capacidade de captura e análise de dados para aumentar o conhecimento do cliente e aumentar o ROI das iniciativas Comerciais e de Marketing. Além disso, um outro ponto a ser mencionado é a crença de que a maior

maturidade em *BI* tem a capacidade de melhorar o *Go-to-market* de novos produtos, crença essa alinhada com a percepção da criação de vantagem competitiva na dimensão *Spawning New Business*.

Dando seguimento a análise, agora avaliando o mercado, na figura abaixo representa o percentual de respondentes em cada uma das opções mencionadas na legenda, quanto a percepção de quão relevante é o uso adequado em *business intelligence* para cada um dos principais *KPIs* de performance externa acompanhados pela empresa:

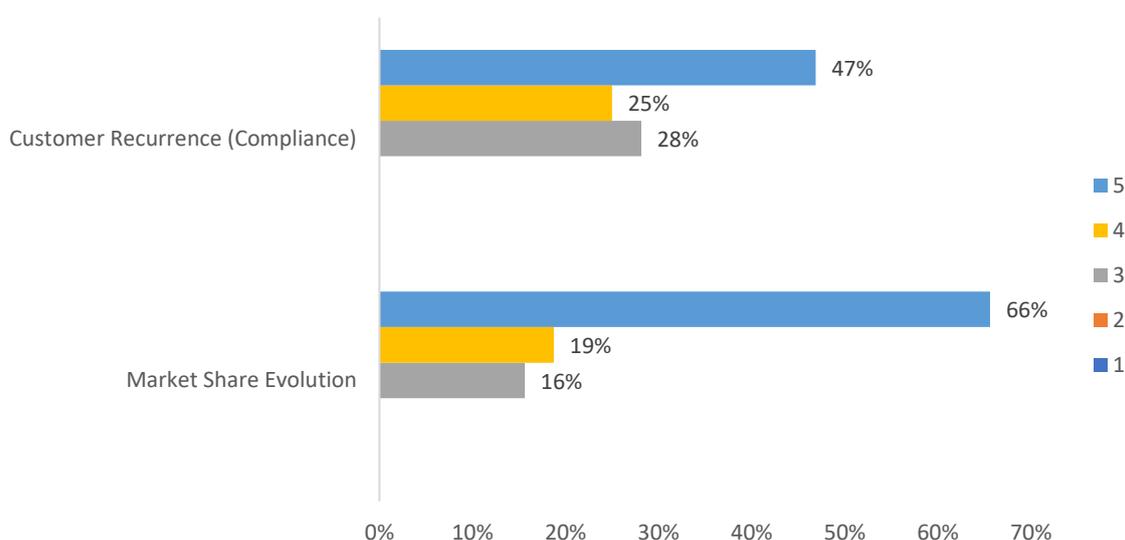


Figura 31. Opção dos respondentes nas opções de Customer Recurrence e Market Share Evolution

Na figura acima observamos a forte percepção que os respondentes têm em relação a capacidade do estágio de maturidade da empresa influenciar na evolução do market share dos seis produtos. Considerando o mercado farmacêutico podemos associar o ganho de market share a capacidade de diferenciar suas moléculas de seus competidores para o prescritor e dessa forma capturar a maior fatia de mercado. Sendo assim, existe uma correlação entre a melhoria de performance externa através do ganho de market share e a criação de vantagem competitiva através da dimensão *Enhancing Differentiation*. Por outro lado, os respondentes têm uma percepção menor em relação a capacidade de se gerar recorrência de compra para a

empresa. Esse é um *KPI* muito importante, uma vez que, as maiores oportunidades de captura de valor dentro de um portfólio de Vacinas ou Respiratório de uso contínuo é o aumento de *compliance* que pode dobrar a receita gerada por um paciente no caso das vacinas, caso o mesmo complete o esquema vacinal, e aumentar significativamente o ciclo de vida de um produto respiratório devido a base de clientes. Um fator que pode influenciar a percepção dos respondentes é que para ambos os produtos o *call-to-action* é do cliente paciente e a indústria ainda não descobriu a melhor forma, dentro das regulamentações da Anvisa e da LGPD de se comunicar diretamente com esse cliente.

Um aspecto do negócio que, de acordo com a percepção dos respondentes, pode ser pouco impactado pela maturidade no uso dos dados está relacionado ao clima organizacional. Um fator que pode impactar essa percepção é o fato do desconforto entre os colaboradores que uma *AI* ou *Machine Learning* pode definir quem deve ser promovido ou demitido. Apesar de existir confiança no uso de dados para tomada de decisão, como nesses casos qualquer um pode estar sujeito a análise fria dos dados, existe um desconforto e uma crença de que uma área de pessoas ou RH deve ponderar as variáveis antes de tomar uma decisão com base em dados. Conforme refletido na figura abaixo:

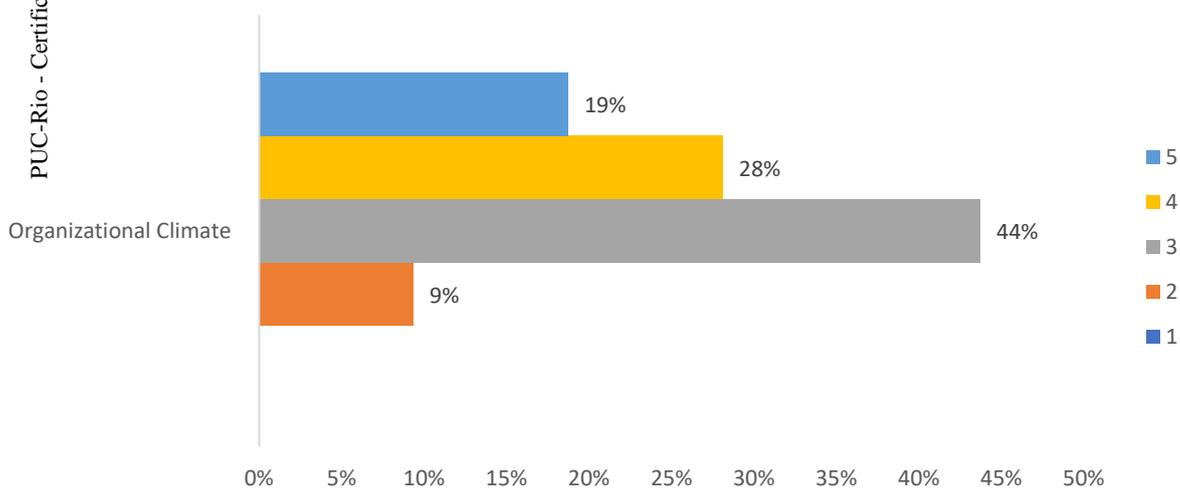


Figura 32. percepção dos respondentes ligada ao impacto pela maturidade no uso dos dados está relacionado ao clima organizacional.

Em resumo, fica claro que os respondentes da pesquisa em geral reconhecem na maturidade de *BI* um potencializador para impulsionar ganhos

financeiros para os acionistas, gerando de incremento no *profit* através de melhor alocação de recurso e lançamento bem-sucedido de produtos inovadores, que em geral garantem uma melhor margem para a indústria. Em relação a performance externa, é alta a crença de que se pode ganhar *market share* com o melhor uso de dados pois em geral a disputa por *market share* acontece com o cliente prescriptor, logo existe um ganho através de diferenciação do produto, porém ainda se observa ceticismo em relação a capacidade de se melhorar a comunicação direta com o cliente paciente. Por fim, é neutra-positiva a percepção que a maturidade em *BI* pode ter um impacto positivo no clima organizacional, uma vez que, existe a tendência de se associar facilmente *Organizational Climate* com a relação entre pessoas, porém correlacionar aumento do uso de *BI* com melhores decisões ou automatização de rotinas repetitivas que podem levar a uma melhor satisfação individual do funcionário, que no limite afeta a organização como um todo, pode ser uma relação menos direta e mais complexa de se fazer.

4.3.4 Discussão sobre os resultados das regressões

Conforme supracitado uma etapa anterior a rodar a regressão no SPSS foi realizar uma análise de fator com o objetivo de reduzir os dados, pois objetivo geral das técnicas de análise de fator é encontrar uma maneira de condensar a informação contida em um número de variáveis originais em um conjunto menor de novas dimensões compostas ou variáveis com uma perda mínima de informação. Sendo assim, através dessa análise foram reduzidos a 4 fatores conforme relacionados abaixo:

F1 = *Net Sales* (P-1) + *Operating Margin* (P-3) + *Organizational Climate* (P-8)

F2 = *Lowering Cost* (VC-1) + *Enhancing Differentiation* (VC-2) + *New Products Introduction* (P-7)

F3 = *Changing Competitive Scope* (VC-3) + *Spawning new businesses* (VC-4) + *Profit* (P-2)

F4 = *Market Share Evolution* (P-4) + *Customer Recurrence* (P-5)

Para cada um dos fatores gerados através da análise de fator rodamos uma regressão tendo como variável dependente os fatores gerados e preditores

(constante) as dimensões do modelo de maturidade em *Business Intelligence*: Organização, Infraestrutura, Gestão de Dados, Análises e Governança de Dados. As regressões consideram os fatores como variáveis dependentes conforme ordenado abaixo:

Regressão 1 – Variável dependente **F1**

Regressão 2 – Variável dependente **F2**

Regressão 3 – Variável dependente **F3**

Regressão 4 – Variável dependente **F4**

Conforme supracitado em relação as regressões 1, 2 e 4, observamos através do teste ANOVA que o valor-p na tabela foi maior que o nível de significância pré definido e por isso consideramos o resultado Insignificante. Dessa forma, os resultados sugerem que as mudanças nas preditoras não estarão relacionadas a qualquer mudança na variável resposta. Por isso, constatou-se que não há nenhuma relação significativa entre as variáveis.

Pode-se observar no resultado da regressão 3 que o teste ANOVA mostra um valor-p abaixo do nível de significância, por isso é possível rejeitar a hipótese nula e concluir que nem todas as médias são iguais. Além disso, analisando o quadro dos coeficientes pode-se observar que a regressão obteve valor-p abaixo do nível de significância alfa em dois dos preditores: Infraestrutura e Governança de Dados. Para os dois, dado que o valor-p é menor que alfa, descartou-se a hipótese nula de que beta é igual a zero, sendo o beta significativo pode-se interpretar o sinal negativo, de modo a concluir que existe uma correlação negativa entre os preditores e a variável dependente **F3**.

Uma hipótese apontada pela análise das regressões é de que os profissionais que avaliaram a empresa em estágios menos maduros dentro do modelo são aqueles que possuem maior grau de especialização em temas relacionados a *business intelligence*, *artificial intelligence* e *machine learning*. Esse profissional é um *early adopter* em novas tecnologias e conhece o impacto que elas têm na produtividade tanto do profissional quanto do capital investido. Dessa forma, ele conhece o potencial que a implementação de uma Infraestrutura, com um ecossistema de

ferramentas de dados suportando o negócio, e uma governança robusta cascadeada por toda a organização pode ter nos resultados financeiros, impactando vendas e lucratividade, na sua habilidade de se manter competitivo através do conhecimento da necessidade do cliente e na sua capacidade de fazer um gerenciamento adequado do seu portfólio, através do lançamento de novos produtos e com a entrada em mercados e categorias que antes não atuava. Por outro lado, esse profissional pode ter uma régua mais alta para avaliar o estágio de maturidade que a empresa se encontra. Por ter maior conhecimento das novas tecnologias tem maior expectativa em relação a maneira como a empresa vai se posicionar quanto as novas ferramentas de *benchmarking* do mercado e um critério mais alto para avaliar seus pares quanto a sua capacidade de gerar insights a partir do ecossistema de dados implementado. Outra hipótese em relação a correlação negativa entre governança de dados e a maturidade em *business intelligence* pode estar na crecha de que um modelo robusto de governança pode atrasar a implementação de novas ferramentas e processos, trazendo certa lentidão pra empresa e fazendo com que seus funcionários tenham a percepção de que não conseguem avançar com a agenda de inovação pois as equipes de jurídico e *compliance* atuam *gate keepers* do *status quo*.

4.3.5 Plano de melhorias por dimensão

Com esse capítulo pretende-se atingir o objetivo secundário 5, que é apresentar um plano de melhorias em cada dimensão a fim de atingir o estágio de *Corporate Adoption*. Uma vez classificada como uma empresa *Early Adoption* pelo modelo de maturidade a empresa já iniciou sua jornada para a maturidade em *Business Intelligence*, porém ainda existe um caminho com várias etapas de melhorarias do uso de recursos, que se implementadas, podem melhorar a capacidade da empresa em *analytics* e assim levar a um cenário onde ela tem mais vantagem competitiva versus seus concorrentes e assim melhorar sua performance interna.

No entanto, passar de uma empresa *Early Adoption* para uma *Corporate Adoption* pode ser um desafio, não à toa existe um Abismo (*Chasm*) entre as duas dimensões, por isso é importante desenvolver um plano de melhoria sólido para garantir que seus esforços analíticos estejam alinhados com seus objetivos do negócio e forneçam resultados mensuráveis para que a evolução possa ser acompanhada pelos *sponsors* dos projetos.

De acordo com os autores do modelo de maturidade (Halper & Stodder 2015), o momento de transição entre **Early Adoption** e **Corporate Adoption** é a principal fase de transformação na jornada analítica do negócio. Isso porque no estágio de **Corporate Adoption** a expectativa é que os usuários finais já estejam diretamente envolvidos na criação dos relatórios e análises, e que a maneira como tomam decisões de negócios já tenha sido transformada com a implementação de uma cultura *data-driven*. Nesse estágio também se espera que os usuários estejam usando diferentes tipos de dados e que existam *big datas* que capturem e gerem *insights* baseados em dados estruturados, semiestruturados e não estruturados. Para atingir tais estágios existe uma série de obstáculos que a empresa precisa superar para atravessar o **Abismo**, tais obstáculos podem ser classificados, de acordo com o autor do modelo, em quatro diferentes dimensões: (i) Financiamento, para isso é importante, conforme supracitado, que sejam bem definidas as métricas que serão acompanhadas e os *milestones* intermediários que precisarão ser atingidos, uma vez que, naturalmente isso facilita o *buy-in* e confiança na iniciativa; (ii) Gestão de dados e gestão de governança, para avançar nessa dimensão é preciso que toda a organização tenham acesso aos dados necessários para operar e tomar decisões, para isso é necessário que existam processos e *checkpoints* para que o dado certo esteja disponível. Nesse estágio é necessário também que a empresa fortaleça sua arquitetura de dados, melhorando a integração entre eles ou no mínimo reduzindo os silos, para executar esses movimentos é preciso que a gestão de governança e qualidade dos dados avance a fim de evitar que um dado equivocado ou uma informação confidencial seja disponibilizada e impacte o processo; (iii) habilidades, para passar pelo **Abismo** e se tornar uma empresa **Corporate Adoption**, a empresa precisa reduzir sua dependência de uma área para criação de *dashboards* e geração de *insights*. O negócio precisa utilizar as ferramentas existentes e criar novas de maneira *self-service*. Se a empresa tem orçamento para acelerar esse avanço pode fazê-lo através da contratação de profissionais com tais *capabilities* e colocá-los como *focal point* da transformação por área. Dessa forma, pode desenvolver, através de *mentoring* ou *shadowing* os profissionais que já estavam na área e não possuíam essa habilidade; (iv) Cultura e Política Empresarial, para que toda a estratégia de desenvolvimento e implementação de sistemas funcione é preciso que toda a organização esteja alinhada nesse processo. Sendo assim, é necessário que os patrocinadores da iniciativa comuniquem de maneira clara na organização os

benefícios da implementação de uma cultura *data-driven*, uma vez que, durante o processo de transformação a operação e carga de trabalho dos funcionários pode ser impactado.

Conforme os critérios informados no capítulo 2.4.1, a empresa objeto de estudo já está em um estágio de Corporate Adoption nas dimensões Governança e Organização, logo o trabalho se limitará a propor pontos de melhorias para as dimensões Análises, Infraestrutura e Gestão de dados. Correlacionando as dimensões de maturidade com as dimensões dos obstáculos de evolução, ambas propostas pelo autor do estudo, podemos estruturar as propostas de melhorias da seguinte forma:

Dimensão de Maturidade	Dimensão dos obstáculos
Análises	<ul style="list-style-type: none"> ▪ Financiamento ▪ Habilidades
Infraestrutura	<ul style="list-style-type: none"> ▪ Financiamento ▪ Gestão de dados e gestão de governança
Gestão de dados	<ul style="list-style-type: none"> ▪ Cultura e Política Empresarial ▪ Gestão de dados e gestão de governança

Quadro 8. Estruturação das propostas de melhoria

4.4.1 Proposta de melhoria para dimensão de análises

De acordo com a literatura, os desafios para a evolução dessa dimensão estão na capacidade de garantir investimentos de maneira sustentável e as habilidades necessárias aos times de cada unidade de negócio. A fim de cobrir os *gaps* citados, a proposta seria a criação de um *project chart* onde seria definido um gerente de projetos responsável por definir um escopo para o projeto, por exemplo quais áreas seriam impactadas, quais seriam os objetivos finais e intermediários que deveriam ser atingidos e os recursos que seriam consumidos. Além disso, esse ficaria responsável por atualizar periodicamente a alta gestão, patrocinador do projeto quanto aos pontos que vem evoluindo e os frutos que os movimentos estão gerando para a empresa. Dessa forma, traria clareza aos patrocinadores de como o

dinheiro do projeto está sendo investido, por quando tempo ainda precisaríamos investir, além de expor as conquistas e eventualmente os *ROIs* positivos que o projeto vem gerando, como por exemplo com uma decisão de reduzir um desconto para um cliente que não é estratégico ou a decisão de não participar de um congresso para médicos que não são target para a empresa.

Além disso, para cobrir o gap de habilidades daria um *upgrade* de vaga em pelo menos um recurso por área. Desse recurso, seria alinhado o desempenho esperado quanto a capacidade analítica e que ele seria como um *champion* responsável por apoiar seus pares no processo de tomada de decisão quando alguma dúvida surgisse, circular artigos ou cursos sobre a temática e facilitar a comunicação entre a área e o time Data Science, hoje alocado dentro da estrutura de *Commercial Excellence*.

Por fim, uma das diferenças mencionadas pelo criador do modelo entre uma empresa *Early Adoption* e *Corporate Adoption* no que tange a dimensão de análises é a velocidade que um dado é capturado até se tornar um *insight*. Para melhorar esse tempo médio, adicionaria duas posições para a equipe de Data Science, esses ficariam responsáveis por identificar possíveis correlações de dados e automatizar os *insights* gerados pelos cruzamentos desses dados. Por exemplo, hoje a empresa tem uma ferramenta que monitora aprovação de genéricos na ANVISA, porém esses dados não é automaticamente cruzado com o *sell-out* dos produtos de referência.

4.4.2 Proposta de melhoria para dimensão de Infraestrutura

Em relação a dimensão de Infraestrutura a literatura, mostra que os desafios para a evolução dessa dimensão estão nos investimentos e a gestão dos dados e governança. Para essa dimensão a proposta que seria feita pelo pesquisador vai ao encontro dos movimentos que a empresa vem fazendo nos últimos anos, ou seja, consolidar seus sistemas com fornecedores globais, como Oracle, SAP e Veeva, além de negociar com esses provedores treinamento que são disponibilizados no *hub* de capacitação da empresa e da contratação de novos módulos desses sistemas com o objetivo de substituir o uso de planilhas, que ainda são amplamente usadas por parte dos funcionários.

Acredito que no momento o Brasil surfa alguns ventos favoráveis que vem ajudando no avanço dessa dimensão, como por exemplo: (i) a mudança de posicionamento global da empresa, tentando como uma Pharma-Tech através da implementação de processos e parcerias com empresas do vale do silício; (ii) o aumento da relevância do Brasil para a empresa globalmente, gerada por anos de constante crescimento duplo dígito, o que coloca o Brasil como mercado prioritário na negociação para implementação de um sistema global; (iii) a maior integração entre as agências reguladoras Brasileiras e estrangeiras, simplificando assim os requerimentos de sistemas antes demandados especificamente para o mercado Brasileiro.

Sendo assim, o trabalho se limita a recomendar que a empresa siga nessa estratégia de consolidação em sistemas globais, disponibilização de treinamentos *self-service* para profissionais que queiram se aprofundar na ferramenta e contratação de cada vez mais módulos para substituir o uso de planilhas, que claramente não são a melhor maneira de armazenar e analisar dados.

4.4.3 Proposta de melhoria para dimensão de Gestão de Dados

Sobre a dimensão de Gestão de Dados a literatura preconiza que os desafios para a evolução nessa dimensão estão na Gestão dos Dados e Governança e Cultura e Política Empresarial. De uma empresa **Corporate Adoption** em Gestão de Dados espera-se que o uso de *Business Intelligence* seja aplicado não somente na criação de *PowerBIs* ou *Dashboards* mas também para gerar *insights* e automatização de decisões. Além disso, é esperado que a empresa seja pioneira no setor ao desenvolver novas fontes para coleta e compartilhamento de dados, dentro de uma forte política de governança, com clientes e fornecedores.

Com o objetivo de atingir os níveis citados acima, reforçaria a equipe de Data Science, conforme citado no capítulo 4.4.1, a fim de garantir que uma modelagem e parametrização adequada apoiaria o processo de cruzamento de dados e identificação de correlações entre dados de diferentes fontes. Além disso, iria propor ao time de trade marketing a inclusão de acordos de troca de informação dentro dos *join business plans* que essa equipe negocia anualmente com os principais clientes. Dessa forma, condicionaria o pagamento de *rebates* e outros

tipos de ressarcimentos, comum na indústria, a disponibilização de informações consideradas chave para o processo interno de tomada de decisão da empresa.

Além disso, um desafio para o tomador de decisão na indústria farmacêutica é o grande número de farmácias conhecidas como independentes, ou seja, aquelas que não pertencem a nenhuma rede e assim não compram os produtos diretamente da indústria, mas usam um distribuidor para facilitar a operação logística. Dessas, que representam mais de 50% do total de farmácias no Brasil a indústria conhece muito pouco sobre o comportamento de venda, a última informação disponibilizada sobre elas vem através da informação reportada pelo atacadista do que ele vendeu para a farmácia. Para cobrir esses *gaps* minha sugestão seria liderar uma agenda de *benchmarking* com o setor de bebidas, outro setor que opera B2B2B2C a fim de verificar quais tecnologias estão usando para garantir o melhor atendimento a um cliente que ele não tem contato direto. Ademais, buscaria parcerias com provedores de sistemas de gestão para pequenos PDVs, a fim de viabilizar, ainda que preservando a informação a nível CNPJ, dados de vendas de produtos em uma determinada região, buscando encontrar correlações com dados demográficos, trabalhos de promoção médica ou outros indicadores microeconômicos que poderiam apoiar no direcionamento de esforços e tomada de decisões comerciais.

5. Conclusão

Esse trabalho teve como objetivo avaliar dentro de um modelo de maturidade o estágio de desenvolvimento de uma empresa do setor farmacêutico utilizando dados coletados via survey e analisados conforme preconizado pelo modelo. Buscou-se atingir ao objetivo primário, de analisar a percepção de uma amostra de funcionários, de diferentes departamentos e cargos, sobre o estágio de maturidade em *Business Intelligence* de uma empresa do setor farmacêutico e os objetivos secundários: (i) identificar, por meio de uma revisão da literatura, um framework adequado para avaliar a maturidade em *Business Intelligence*; (ii) criar, por meio dessa revisão da literatura, um questionário para avaliar quanto a maturidade, o potencial de criação de vantagem competitiva e melhoria de performance da empresa; (iii) aplicar o modelo na empresa objeto de estudo por meio do questionário para a identificação do nível de maturidade, vantagem competitiva e performance da etapa anterior, com funcionários que atuam em áreas que lidam com tais temas; complementarmente, avaliar esses resultados à luz de entrevistas em profundidade com funcionários chave; (iv) avaliar quantitativamente a relação entre percepção do maturidade em BI e a percepção do potencial de criação de vantagem competitiva e desempenho por meio da adoção de BI; (v) com base nos resultados aferidos apresentar um plano de melhorias em cada dimensão a fim de atingir o estágio de Corporate Adoption.

A fim de atingir aos objetivos supracitados, a pesquisa foi realizada percorrendo as seguintes etapas:

1. Coleta de dados via survey aberta entre as 5 dimensões de análise de maturidade;
2. Entrevistas com respondentes chave para testar os resultados e cruzar com o momento vivido pela empresa;
3. Correlação de dados coletados via *survey* com referencial teórico para comparar e identificar se o real valor do uso de dados para geração de vantagem competitiva e melhoria de performance é percebido por uma amostra de funcionários da empresa objeto de estudo.

A relevância teórica do estudo se encontra no de que poucos estudos associaram o modelo de maturidade em *Business Intelligence* com a melhoria de performance coletando informações de profissionais de diferentes áreas da organização e em geral limitaram a análise a resultados ligados à área de marketing somente, como aumento nas vendas e impactos nas propagandas.

O estudo demonstrou através de análise do modelo e posterior entrevista com respondentes-chave que o modelo de maturidade pode ser aplicado ao setor farmacêutico e que colaboradores em diferentes níveis e departamentos tem clareza sobre o potencial da aplicação da *Business Intelligence* para melhoria de performance e diferenciação da empresa frente aos seus competidores.

A aplicação do modelo de maturidade enquadrando a empresa objeto de estudo como um *Early Adoption* (descrição nos capítulos 4.1.6 & 2.4.1). Dentre as 5 diferentes dimensões avaliadas pelo modelo o resultado da empresa foi próximo em todas elas sendo a dimensão de Governança a que recebeu a pontuação mais alta, tendo como principal motivo para tal pontuação a percepção de que os processos de governança são maduros e cascadeados por toda a organização e a dimensão de infraestrutura a que teve a menor pontuação, essa motivada pela percepção de que o uso de planilhas como principal ferramenta para armazenagem e análise de dados é alta entre a maioria dos participantes da pesquisa.

Além disso, o estudo demonstrou que existe uma correlação negativa entre a percepção que a empresa objeto de estudo tem um processo maduro em *business intelligence* e a percepção da capacidade de uma empresa madura gerar vantagem competitiva sustentada e a incremento na performance.

A maneira como o modelo foi aplicado permitiu que as fraquezas e fortalezas da empresa objeto de estudo fossem identificadas em cada uma das dimensões do modelo. Além disso, a variedade de perguntas propostas no questionário apontou os pontos de melhoria da empresa no que tange capacitação do material humano e implementação de sistemas. Dessa forma, os resultados analisados a luz da literatura permitiram a construção de uma proposta de plano de melhorias que se implementadas poderiam ajudar a empresa a cobrir seus *gaps* atuais e avançar para o próximo estágio do modelo maturidade em *Business Intelligence*.

5.1 Limitações do Estudo

O estudo se limita a estudar somente uma empresa do setor farmacêutico, sendo assim não temos base de comparação versus outros competidores dentro do mesmo mercado. Também é válido informar que a amostra coletada na pesquisa não necessariamente reflete a opinião corporativa da empresa objeto de estudo, sendo apenas a opinião dos 32 respondentes do questionário.

Na seleção dos sujeitos foi feita a opção de incluir um grupo heterogêneo de respondentes. Sendo assim, dentre os respondentes existem pessoas com *backgrounds* diversos dessa forma, quando se tratava de perguntas técnicas ou conceituais existe a possibilidade de o respondente não ter conhecimento adequado para inferir uma percepção ou já possuir um viés uma vez que, as respostas correspondem somente a impressões particulares de cada um deles quando a situação proposta.

Ainda que tenha sido informado que não haveria necessidade do respondente se identificar no início do questionário e de que a ferramenta não permite que seja feito um rastreio após as respostas serem enviadas, o fato do pesquisador ser um funcionário da empresa objeto de estudo pode ter reduzido o número de participantes da pesquisa, limitando assim as observações a serem analisadas, e impactado a qualidade das respostas incluídas na pesquisa.

5.2 Oportunidades para futuras pesquisas

Esse estudo apresenta oportunidades para pesquisas futuras através da aplicação do mesmo modelo de maturidade para funcionários de outros competidores do setor farmacêutico, para se criar uma base de comparação entre os diferentes agentes de mercado, assim como cria a possibilidade de comparação entre empresas nacionais e internacionais a fim de investigar se o setor farmacêutico no Brasil está competitivo em comparação com mercados mais maduros. Uma outra oportunidade para pesquisas futuras é a aplicação de modelo similar para diferentes indústrias, como Consumo, Bebidas e Varejo por exemplo. Dessa forma se poderia identificar os *bechmarkings* entre os setores assim como investigar o grau de evolução entre cada um dos setores, a fim de validar as melhores práticas que poderiam ser adotadas por um setor menos maduro ou indicar quais setores

poderiam ser *pipeline* de talentos para um *player* que opte por acelerar sua maturidade em análise de dados através de contratação de talentos no mercado.

6. Referências

FILLIETAZ, A.; CRISPIM, S.F. Migração de valor na indústria farmacêutica. *Revista de Negócios*, Blumenau, v.15, n.2, p. 10-31, 2010.

DENVER, Richard Miller. *Cyclopedia of commercial and business anecdotes*. Londres:

150 years of Business Intelligence: A brief history. Documento Eletrônico. Disponível em < <https://www.cio.com/>>. Acesso em Outubro de 2022

M Tannoury; A. Zouhair. *The Influence of Emerging Markets on the Pharmaceutical Industry*

Building Better Global Economic BRICs *Global Economics* [Internet] 2001;66:1–15. <http://www.goldmansachs.com/our-thinking/archive/archive-pdfs/build-better-brics.pdf>

IPSOS 5º Panôrama Farmacêutico - Respostas médicos sobre interações com a indústria

Kyere, M., & Ausloos, M. (2021). Corporate governance and firms financial performance in the United Kingdom. *International Journal of Finance & Economics*, 26(2) 1871–1885.

Haseeb, M., Hussain, H. I., Kot, S., Androniceanu, A., & Jermittiparsert, K. (2019). Role of social and technological challenges in achieving a sustainable competitive advantage and sustainable business performance. *Sustainability*, 11(14), 3811.

Howson, C., Sallam, R.L., Richardson, J.L., Tapadinhas, J., Idoine, C.J. and Woodward, A., 2018. Magic quadrant for analytics and business intelligence platforms. Retrieved Aug, 16, p. 2018.

I.N. Lings, G.E. Greenley The impact of internal and external market orientations on firm performance *Journal of Strategic Marketing*, 17 (2009), pp. 41-53

Menon, A., & Varadarajan, P. R. (1992). A model of marketing knowledge use within firms. *Journal of Marketing*, 56(4), 53–71.

Harvard Business Review – Bad Data Costs the U.S. \$3 Trillion Per Year 2013 – Thomas Redman

5 Data Analytics Trends in 2022 That Will Continue Into 2023 – Rui Pereira

Corman, A., Canaway, R., Culnane, C., Teague, V., Public comprehension of privacy protections applied to health data shared for research: An Australian cross-sectional study (2021)

Harvard Business Review – Create KPIs That Reflect Your Strategic Priorities – Graham Kenny

Elbashir, M. Z., Sutton, S. G., Mahama, H., & Arnold, V. (2021). Unravelling the integrated information systems and management control paradox: Enhancing dynamic capability through business intelligence. *Accounting & Finance*, 6, 1775–1814.

Peng, J., Viator, R., Buchheit, S., 2007. An experimental study of multidimensional hierarchical accounting data: drill-down paths can influence economic decisions. *J. Inf. Syst.* 21 (2), 69–86.

Card, S., MacKinlay, J. & Schneiderman, B., 1999 Information visualization Using vision to think

Hair, J., Black, W. Babin, Barry, Anderson, R., 2010 *Multivariate Data Analysis: A Global Perspective Edition: Seventh Edition* Publisher: Pearson

Townsend, C., Kahn, B., 2014. The “Visual Preference Heuristic”: The Influence of Visual versus Verbal Depiction on Assortment Processing, Perceived Variety, and Choice Overload. *Journal of Consumer Research*, Volume 40, Issue 5, 1 February 2014, Pages 993–1015,

H. Chen, R.H.L. Chiang, V.C. Storey, Business intelligence and analytics: from big data to big impact, *MIS Q.* 36 (2012) 1165–1188.

Vidgen, R., Shaw, S., & Grant, D. B. (2017). Management challenges in creating value from business analytics. *European Journal of Operational Research*, 261(2), 626–639.

Mikalef, P., Pappas, I. O., Krogstie, J., & Giannakos, M. (2018). Big data analytics capabilities: A systematic literature review and research agenda. *Information Systems and e-Business Management*, 16(3), 547–578.

Mayhew, M., Saleh, T., and Williams, S., 2016 Making data analytics work for you – instead of the other way around

Mikalef, P., & Pateli, A. (2017). Information technology-enabled dynamic capabilities and their indirect effect on competitive performance: Findings from PLS-SEM and fsQCA. *Journal of Business Research*, 70, 1–16.

Brown, B., Court, D., and Willmott, P., 2013. Mobilizing your C-suite for big-data analytics

Ransbotham, S., Kiron, D., Gerbert, P., et al. (2017). Reshaping business with artificial intelligence. *MIT Sloan Management Review*, 59(1), 1–17.

Grover, V., Chiang, R. H. L., Liang, T.-P., & Zhang, D. (2018). Creating Strategic Business Value from Big Data Analytics: A Research Framework. *Journal of Management Information Systems*, 35(2), 388–423.

Chen, H., Chiang, R., & Storey, V. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *Management Information Systems Quarterly*, 36(4), 1165–1188.

Davenport, T., & Harris, J. (2017). *Competing on Analytics: Updated, with a New Introduction: The New Science of Winning*. Harvard Business Press.

Roth, G., 2015. Convergent evolution of complex brains and high intelligence. *Philos. Trans. R. Soc. Lond. Ser. B Biol. Sci.* 370, 20150049.

Filho, W.J., Lent, R., Herculano-Houzel, S., 2009. Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. *J. Comp. Neurol.* 513, 532–541.

Cochrane, P., Winter, C.S., Hardwick, A., 1995. *Biological Limits to Information Processing in the Human Brain*. British Telecommunications Publications.

John Sweller, J., van Merriënboer J., Paas F., 1998 *Cognitive Architecture and Instructional Design*

Paas, F., Tuovinen, J. E., Tabbers, H., & Van Gerven, P. W. M. (2003). Cognitive load measurement as a means to advance cognitive load theory. *Educational Psychologist*, 38(1), 63–71

Russell, S., Gangopadhyay, A., Yoon, V., 2008 *Assisting decision making in the event-driven enterprise using wavelets*.

Pajares, F., & Graham, L. (1999). Self-efficacy, motivation constructs, and mathematics performance of entering middle school students. *Contemporary Educational Psychology*, 24

O'Connor, T. G., Bredenkamp, D., Rutter, M., et al. (1999). Attachment disturbances and disorders in children exposed to early severe deprivation. *Infant Mental Health Journal*, 20, 10e29.

James, G., 2018. Statistics within business in the era of big data. Department of Data Sciences and Operations, University of Southern California, United States

Hand, D. J. (1999). Statistics and data mining: Intersecting disciplines. *SIGKDD Explorations*, 1, 16-19.

Hand, D. J., Blunt, G., Kelly, M. G., & Adams, N. M. (2000). Data mining for fun and profit. *Statistical Science*, 15, 111-126

Dash, S., Shakyawar, S., Sharma, M., Kaushik, M., 2019. Big data in healthcare: management, analysis and future prospects *Journal of Big Data* volume 6, Article number: 54 (2019)

Fournier, D. M. (2005). Evaluation and program planning. In S. Mathison (Ed.), *Encyclopaedia of Evaluation* (p. 140). Sage.

Scriven, M. (2003). Michael Scriven on the differences between evaluation and social science research. *The Evaluation Exchange*. 9(4).

Alkin, M. C., & Christie, C. (2004). An Evaluation Theory Tree, in Alkin M.C. *Evaluation roots*. SAGE Publications.

Calaprice, A. (Ed.), 2000. *The Expanded Quotable Einstein*. Princeton University Press, Princeton, NJ, p. 314.

Gigerenzer, G. (2014). *Risk savvy: How to make good decisions*. New York, USA: Penguin.

G. G., 2016 – *Harvard Business Review* – Ruído: Como superar o alto custo oculto da tomada de decisões inconsistente

Freeman, D., 2017. Preferred personal equilibrium and simple choices. Department of Economics, Simon Fraser University, 8888 University Dr., Burnaby, BC, Canada V5A 1S6a

Ariely, D., Loewenstein, G., & Prelec, D. (2003). Coherent arbitrariness: stable demand curves without stable preferences. In Brocas, II & J. Carrillo (Eds.), *The psychology of economic decisions*. Oxford, UK: Oxford University Press.

Hoeffler, S., & Ariely, D. (1999). Constructing stable preferences: a look into dimensions of experience and their impact on preference stability. *Journal of Consumer Psychology*, 8(2), 113–139.

Chapman, G. B., & Johnson, E. J. (1999). Anchoring, activation, and the construction of values. *Organizational Behavior and Human Decision Processes*, 79(2), 115–153.

Ariely, D., Lynch, J. G., & Aparicio, M. IV, (2004). Learning by collaborative and individual-based recommendation agents. *Journal of Consumer Psychology*, 14(1–2), 81–95.

Moorthy, K. S., Ratchford, B. T., & Talukdar, D. (1997). Consumer information search revisited: theory and empirical analysis. *Journal of Consumer Research*, 23, 263–277.

Laibson, D. (1997). Golden eggs and hyperbolic discounting. *The Quarterly Journal of Economics*, 112(2), 443–477.

Benartzi, S., & Thaler, R. H. (1999). Risk aversion or myopia? Choices in repeated gambles and retirement investments. *Management Science*, 45(3), 364–381.

Blue, A. D. (2002). *The Essential Wine Guide*

Moorthy, K. S., Ratchford, B. T., & Talukdar, D. (1997). Consumer information search revisited: theory and empirical analysis. *Journal of Consumer Research*, 23, 263–277.

Laibson, D. (1997). Golden eggs and hyperbolic discounting. *The Quarterly Journal of Economics*, 112(2), 443–477.

Barberis, N., Thaler, R., 2003. A survey of behavioral finance. In: Constantinides, H.M., Stulz, R. (Eds.), *Handbook of the Economics of Finance*. Elsevier, Amsterdam, pp. 1051–1121

P.J.H. Schoemaker, Multiple scenario development: its conceptual and behavioral foundation, *Strateg. Manag. J.* 14 (1993) 193–213.

R.M. Bradfield, Cognitive barriers in the scenario development process, *Adv. Dev. Hum. Resour.* 10 (2) (2008) 198–215

Messier, P., Wulf, T (2011). Cognitive benefits of scenario planning: Its impact on biases and decision quality

K.L. Milkman, D. Chugh, M.H. Bazerman, How can decision making be improved? *Perspect. Psychol. Sci.* 4 (2009) 378–383.

R.P. Larrick, Debiasing, in: D.J. Koehler, N. Harvey (Eds.), *Blackwell Handbook of Judgment and Decision Making*, Blackwell, Oxford, 2004, pp. 316–337.

K. van der Heijden, *Scenarios: The Art of Strategic Conversation*, John Wiley and Sons, Chichester, 2005.

J.B. Soll, J. Klayman, Overconfidence in interval estimates, *J. Exp. Psychol. Learn. Mem. Cogn.* 30 (2) (2004) 299–314.

A.D. Galinsky, L.J. Kray, From thinking about what might have been to sharing what we know: the effects of counterfactual mind-sets on information sharing in groups, *J. Exp. Soc. Psychol.* 40 (5) (2004) 606–618.

P. Wack, Scenarios: shooting the rapids, *Harv. Bus. Rev.* 63 (6) (1985) 139–150.

The rise of Intelligent Automation – Turning Complexity into Profit – Harvard Business Review

Turning Complexity into Profit Ma, L., & Sun, B. (2020). *Machine Learning and AI in Marketing – Connecting Computer Power to Human Insights. International Journal of Research in Marketing*, 37(3), 481–504.

Russell, S. J., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. Upper Saddle River, NJ: Prentice-Hall.

Loureiro, S. M. C., Guerreiro, J., & Tussyadiah, I. (2021). Artificial Intelligence in Business: State of the Art and Future Research Agenda. *Journal of Business Research* 129(5), 911–926

Wright, L. T., Robin, R., Stone, M., & Aravopoulou, D. E. (2019). Adoption of Big Data Technology for Innovation in B2B Marketing. *Journal of Business-to-Business Marketing*, 26(3–4), 281–293.

Huang, M. H., & Rust, R. T. (2021). A Strategic Framework for Artificial Intelligence in Marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50.

Martínez-López, F. J., & Casillas, J. (2013). Artificial Intelligence-Based Systems Applied in Industrial Marketing: A Historical Overview, Current and Future Insights. *Industrial Marketing Management*, 42(4), 489–495.

Wamba-Taguimdje, S.-L., Wamba, S. F., Kamdjoug, J. R. K., & Wanko, C. E. T. (2020). Influence of artificial intelligence (AI) on firm performance: The business value of Aibased transformation projects. *Business Process Management Journal*, 26(7), 1893–1924.

Spanjol, J., Xiao, Y., & Welzenbach, L. (2018). Successive innovation in digital and physical products: Synthesis, conceptual framework, and research directions. *Innovation and Strategy (Review of Marketing Research)*, 15, 31–62.

Verganti, R., Vendraminelli, L., & Iansiti, M. (2020). Innovation and design in the age of artificial intelligence. *Journal of Product Innovation Management*, 37(3), 212–227.

Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, 61(4), 135–155.

Chen, H., Chiang, R. H. L., Storey, V. C., & Robinson, J. M. (2012). Business Intelligence and Analytics: From Big Data To Big Impact. *MIS Quarterly*, 36(4), 1165–1188.

Alidrisi, H. (2021). Measuring the environmental maturity of the supply chain finance: A big data-based multi-criteria perspective. *Logistics*, 5(2), 22–24

Manuylenko, V. V., Borlakova, A. I., Milenkov, A. V., Bigday, O. B., Drannikova, E. A., & Lisitskaya, T. S. (2021). Development and validation of a model for assessing potential strategic innovation risk in banks based on data mining-Monte-Carlo in the “Open Innovation” system. *Risks*, 9(6).

Chatterjee, S., Chaudhuri, R., & Vrontis, D. (2021). Does data-driven culture impact innovation and performance of a firm? An empirical examination. *Annals of Operations Research*. Chatterjee, S., Chaudhuri,

Makowski, P. T., & Kajikawa, Y. (2021). Automation-driven innovation management? Toward innovation-automation-strategy cycle. *Technological Forecasting and Social Change*, 168, 9.

Burstrom, T., Parida, V., Lahti, T., & Wincent, J. (2021). AI-enabled business-model innovation and transformation in industrial ecosystems: A framework, model and outline for further research. *Journal of Business Research*, 127, 85–95

Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897–904.

Cheah, S., & Wang, S. (2017). Big data-driven business model innovation by traditional industries in the Chinese economy. *Journal of Chinese Economic and Foreign Trade Studies*, 10(3), 229–251.

Jazdauskaite, J., Privarova, M., Baranskaite, E., Juscius, V., & Kelemen-Henyel, N. (2021). Evaluation of the impact of science and technology on the labour market. *Marketing and Management of Innovations*, 4, 153–167.

Arias-Perez, J., & Velez-Jaramillo, J. (2022). Ignoring the three-way interaction of digital orientation, not-invented-here syndrome, and employee's artificial intelligence awareness in digital innovation performance: A recipe for failure. *Technological Forecasting and Social Change*, 174(2).

Prem, E. (2019). Artificial intelligence for innovation in Austria. *Technology Innovation Management Review*, 9(12), 5–15.

Battisti, S., Agarwal, N., & Brem, A. (2022). Creating new tech entrepreneurs with digital platforms: Meta-organizations for shared value in data-driven retail ecosystems. *Technological Forecasting and Social Change*, 175, 12.

Yu, X., Nguyen, B., & Chen, Y.i. (2016). Internet of things capability and alliance entrepreneurial orientation, market orientation and product and process innovation. *Internet Research*, 26(2), 402–434.

Cetindamar, D., Lammers, T., & Zhang, Y.i. (2020). Exploring the knowledge spillovers of a technology in an entrepreneurial ecosystem-the case of artificial intelligence in Sydney. *Thunderbird International Business Review*, 62(5), 457–474.

Sun, X., & Zhang, Q. (2021). Building digital incentives for digital customer orientation in platform ecosystems. *Journal of Business Research*, 137, 555–566.

Kakatkar, C., Bilgram, V., & Füller, J. (2020). Innovation analytics: Leveraging artificial intelligence in the innovation process. *Business Horizons*, 63(2), 171–181.

Mariani, M., & Nambisan, S. (2021). Innovation analytics and digital innovation experimentation: The rise of research-driven online review platforms. *Technological Forecasting and Social Change*, 172.

Acar, M., & Toker, A. (2019). Predicting consumer personality traits in the sharing economy: The case of 135irbnb. *Applied Marketing Analytics*, 5(1), 83–96

Masih, J., & Joshi, A. (2021). Understanding health-foods consumer perception using big data analytics. *Journal of Management Information and Decision Sciences*, 24(3), 1–15

Johnson, D. S., Muzellec, L., Sihi, D., & Zahay, D. (2019). The marketing organization's journey to become data-driven. *Journal of Research in Interactive Marketing*, 13(2), 162–178.

Varsha, P. S., Akter, S., Kumar, A., Gochhait, S., & Patagundi, B. (2021). The impact of artificial intelligence on branding: A bibliometric analysis (1982–2019). *Journal of Global Information Management*, 29(4), 221–246

Fagella, D. (2018). Artificial intelligence in marketing and advertising – 5 examples of real traction

Syam, N., & Sharma, A. (2018). Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. *Industrial Marketing Management*, 69, 135–146

Loureiro, S. M. C., Guerreiro, J., & Tussyadiah, I. (2020). Artificial intelligence in business: State of the art and future research agenda. *Journal of Business Research*

Huang, M. H., & Rust, R. T. (2021). A Strategic Framework for Artificial Intelligence in Marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50.

Martínez-Lopez, F. J., & Casillas, J. (2013). Artificial Intelligence-Based Systems Applied in Industrial Marketing: A Historical Overview, Current and Future Insights.

Bozidar, V., Corbo, L., Silva, S., Dabi., M., 2022 The evolving role of artificial intelligence in marketing: A review and research agenda

Tractica (2020). Artificial Intelligence Software Market to Reach \$126.0 Billion in Annual Worldwide Revenue by 2025.

MIT Technology Review Insights (2020). The global AI agenda: North America. MIT Technology Review

Overgoor, G., Chica, M., Rand, W., & Weishampel, A. (2019). Letting the Computers Take Over: Using AI to Solve Marketing Problems. *California Management Review*, 61(4), 156–185.

Rangaswamy, A., Moch, N., Felten, C., van Bruggen, G., Wieringa, J. E., & Wirtz, J. (2020). The role of marketing in digital business platforms. *Journal of Interactive Marketing*, 51(August), 72–90.

Haenlein, M., & Kaplan, A. (2019). A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, 61(4), 5–14.

PriceWaterhouseCoopers (2017): How artificial intelligence is pushing man and machine closer together

Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48 (1), 24–42

Marinova, D., de Ruyter, K., Huang, M.-H., Meuter, M. L., & Challagalla, G. (2017).

Getting Smart: Learning From Technology-Empowered Frontline Interactions. *Journal of Service Research*, 20(1), 29–42.

Rust, R. T., & Huang, M.-H. (2012). Optimizing service productivity. *Journal of Marketing*, 76(2), 47–66

Lu, V. N., Wirtz, J., Kunz, W., Paluch, S., Gruber, T., Martins, A., & Patterson, P. (2020).

Service robots, customers, and service employees: What can we learn from the academic literature and where are the gaps? *Journal of Service Theory and Practice*, 30 (3), 361–391

Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48 (1), 24–42

Wirtz, J., Patterson, P. G., Kunz, W. H., Gruber, T., Lu, V. N., Paluch, S., & Martins, A. (2018). Brave new world: Service robots in the frontline. *Journal of Service Management*, 29(5), 907–931

Wirtz, J. (2020). Organizational ambidexterity: Cost-effective service excellence, service robots, and artificial intelligence. *Organizational Dynamics*, 49(3), 1–9

Wirtz, J., So, K. K. F., Mody, M., Liu, S., & Chun, H. E. H. (2019). Platforms in the peer-to-peer sharing economy. *Journal of Service Management*, 30(4), 452–483.

Luo, X., Tong, S., Fang, Z., & Qu, Z. (2019). Frontiers: machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases. *Marketing Science*, 38(6), 937–947.

Davenport, T. H., & Kirby, J. (2015). Beyond automation. *Harvard Business Review*, 93(6), 58–65.

Chui, M., Manyika, J., & Miremadi, M. (2015). Four fundamentals of workplace automation. *McKinsey Quarterly*, 29(3), 1–9.

McAfee, A., & Brynjolfsson, E. (2016). Human work in the robotic future: Policy for the age of automation. *Foreign Affairs*, 95(4), 139–150

Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, 61(4), 135–155

Salminen, J., Yoganathan, V., Corporan, J., Jansen, B. J., & Jung, S.-G. (2019). Machine learning approach to auto-tagging online content for content marketing efficiency: A comparative analysis between methods and content type. *Journal of Business Research*, 101, 203–217.

Smart Insights (2018). How AI is changing the role of the marketer in 2018. <https://www.smartinsights.com/managing-digital-marketing/managing-marketing-technology/how-ai-is-changing-the-role-of-the-marketer-in-2018/>.

Zhao, D. (2013). Frontiers of big data business analytics: Patterns and cases in online marketing. In *Big data and business analytics* (pp. 43–68). CRC Press.

Mayhew, H., Saleh, T., Williams, S., (2016). Making data analytics work for you—instead of the other way around. McKinsey Insight

HBR ANALYTIC SERVICES SURVEY, NOVEMBER 2018

Moon, Y. (2003). Don't Blame the Computer: When Self-Disclosure Moderates the Self-Serving Bias. *Journal of Consumer Psychology*, 13(1–2), 125–137

Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm Aversion: People Erroneously Avoid Algorithms After Seeing Them Err. *Journal of Experimental Psychology: General*, 144(1), 114–126.

Promberger, M., & Baron, J. (2006). Do Patients Trust Computers? *Journal of Behavioral Decision Making*, 19(5), 455–468

Castelo, N., Bos, M. W., & Lehmann, D. R. (2019). Task-Dependent Algorithm Aversion. *Journal of Marketing Research*, 56(5), 809–825

Kutner, et al. (2004) *Applied Linear Statistical Models*. 4th Edition

Davenport, T. H., & Kirby, J. (2016). Just How Smart are Smart Machines? *MIT Sloan Management Review*, 57(3), 21–25.

Wortmann, Ch., Fischer, P. M., & Reinecke S. (2018). The Holy Grail in Decision- Making? How Big Data Changes Decision Processes of Marketing Managers. European Marketing Academy Conference, Glasgow, UK

Granulo, A., Fuchs, C., & Puntoni, S. (2019). Psychological Reactions to Human versus Robotic Replacement. *Nature Human Behavior*, 3(5), 1062–1069.

Fuchs, C., Schreier, M., & Van Osselaer, S. M. (2015). The Handmade Effect: What's Love Got to Do With It? *Journal of Marketing*, 79(2), 98–110

Gray, K. (2012). The Power of Good Intentions: Perceived Benevolence Soothes Pain, Increases Pleasure, and Improves Taste. *Social Psychological and Personality Science*, 3 (5), 639–645.

Gujarati, D.N. and Porter, D.C. (2009) *Basic Econometrics*. 5th Edition, McGraw Hill Inc., New York.

Leung, E., Paolacci, G., & Puntoni, S. (2018). Man versus Machine: Resisting Automation in Identity-Based Consumer Behavior. *Journal of Marketing Research*, 55(6), 818–831.

Leslie, K. J., Kim, T., & Barasz, K. (2018). Ads That Don't Overstep. *Harvard Business Review*, 96(1), 62–69.

Trends in Customer Trust CRM - Salesforce Research 2018

Hagiu, A., Wright, J., (2020) When Data Creates Competitive Advantage And when it doesn't. *Harvard Business Review*

How Your CRM Platform Can Make Your Customers Happier (2021) *Harvard Business Review*

P Mikalef, IO Pappas, J Krogstie, PA Pavlou, Big data and business analytics: a research agenda for realizing business value, *Inf. Manage.* 57 (2020), <https://doi.org/10.1016/j.im.2019.103237>. N.PAG-N.PAG.

Porter, M., Millar, V. (1985), How Information Gives You Competitive Advantage - *Harvard Business Review*

YIN, Robert K. Case study research design and methods third edition. *Applied Social Research Methods Series*, v. 5, 2003.

Halper, F., & Stodder, D. (2014). TDWI analytics maturity model guide. Retrieved from <https://tdwi.org/whitepapers/2014/10/tdwi-analytics-maturity-model-guide/> asset.aspx.

Niño H., Niño, J., Ortega R., (2018) Business intelligence governance framework in a university: Universidad de la costa case study

V Grover, RHL Chiang, T-P Liang, D Zhang, Creating strategic business value from big data analytics: a research framework, *J. Manag. Inf. Syst.* 35 (2018) 388–423, <https://doi.org/10.1080/07421222.2018.1451951>.

E Brynjolfsson, K McElheran, *Data in Action: Data-Driven Decision Making in U. S. Manufacturing*, Social Science Research Network, Rochester, NY, 2016

J Manyika, M Chui, B Brown, et al., *Big data: The next Frontier For innovation, Competition*, McKinsey Global Institute, 2011.

] G Schryen, Revisiting IS business value research: what we already know, what we still need to know, and how we can get there, *Eur. J. Inf. Syst.* 22 (2013) 139–169, <https://doi.org/10.1057/ejis.2012.45>.

T Liang, J You, C Liu, A resource-based perspective on information technology and firm performance: a meta analysis, *Ind. Manag. Data Syst.* 110 (2010) 1138–1158, <https://doi.org/10.1108/02635571011077807>.

J-H Lim, B Dehning, VJ Richardson, RE Smith, A meta-analysis of the effects of IT investment on firm financial performance, *J. Inf. Syst.* 25 (2011) 145–169, <https://doi.org/10.2308/isys-10125>.

Wernerfelt, B. (1984). A resource-based view of the firm. *Strategic Management Journal*, 5 (2), 171–180

Michael E. Porter, *Estratégia competitiva* (Nova York: Free Press, 1980), Capítulo 2

Halper, F, Stodder, D., (2015) *TDWI Analytics Maturity Model Guide*

Creswell, J. W. (2010). *Projeto de pesquisa, Métodos qualitativo, quantitativo e misto.*

M. Wood, J. Daly, J. Miller, Marc. Roper (1999) *Multi-method research: An empirical investigation of object-oriented technology - The Journal of Systems and Software* 48 (1999) 13-26

Apêndice 1 – Questionário

Dimension	#	Questions	Options of Answer
Organization	O-1	Do you have both business and IT sponsorship across the company for analytics initiatives?	We don't have sponsorship across the company for analytics; We have IT sponsorship only; We have business sponsorship only; We have both business and IT sponsorship AND we work together; Don't know;
Organization	O-4	We are able to express the potential benefits of an analytics project in business language for executives to understand?	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Organization	O-5	We have a well-established funding process in place for analytics. It is driven by both business and IT.	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Organization	O-6	We have an analytics road map in place that has been agreed to across the company AND the discipline to change the road map if needed	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Organization	O-7	We take action using analytics (i.e., analytics as part of a business process, as part of a model) in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Organization	O-8	Data and analytics drive our business in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Organization	O-9	We train users to perform more advanced analytics	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;

Organization	O-2	There are people in my organization with skills in advanced analytics to support the needs of the business (i.e., data scientists, business analysts, computer scientists, etc.)	No; Yes, at the department or business unit level; Yes, company-wide;
Organization	O-10	We have users across the spectrum of analytic skill making use of analytics in my organization	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Organization	O-3	Analytics projects are driven by business leadership and deliver value incrementally instead of at the end of the entire development process	No; We are moving that way; Yes, for some projects; Definitely;
Infrastructure	I-1	We have the right skills in place to address infrastructure technologies for our analytics efforts	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Infrastructure	I-3	Our data scientists and analysts work closely with our data warehouse and data management teams to ensure that analytics workloads have the data infrastructure our employees need/use	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Infrastructure	I-2	What infrastructure technologies do you currently utilize for your analytics efforts?	We use flat files or spreadsheets; We have a data warehouse or a data mart; We use an analytic platform or appliance; We use a range of technologies, including our data warehouse, Hadoop, and others, but they are siloed; We use a range of approaches that form an analytics ecosystem; None;
Data Management	GD-1	Do you make use of mobile technologies for analytics?	No, and we have no plans to do so; No, but we are thinking about it; Yes, but only for a select few; Yes, for all those who need it;
Data Management	GD-9	We have a company-wide information architecture in place for analytics	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;

Data Management	GD -10	We have designed our architecture to take advantage of legacy systems already in place	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Data Management	GD -2	We use the public cloud for analytics	No, we would never use the public cloud; We have a private cloud that we use for analytics; We have a hybrid model where we use some public cloud, some data center, and some private cloud; We don't use the cloud yet for analytics, but we are moving in that direction;
Data Management	GD -3	What kinds of data do you currently collect and manage as part of your analytics efforts?	None; Structured data only from our internal systems; Structured data and demographic data; Multi-structured data along with our structured data; We collect and manage data from multiple sources, both internal and external to the company. This includes unstructured data, geospatial data, and much more;
Data Management	GD -4	How much data are you analyzing currently?	Megabytes; Terabytes; Petabytes; Don't know;
Data Management	GD -5	We make use of multiple sources of data in a single analysis	No; Yes, with structured data; Yes, with structured data and 1 or 2 outside sources such as demographic data; Yes, with different kinds of data including unstructured data and other non-traditional data, but it is a hassle trying to integrate it; Yes, with different kinds of data and we do a good job of integrating it;
Data Management	GD -11	Employees at my company can easily find the data they need when they need it	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;

Data Management	GD -6	How do you integrate your data?	<p>We don't have a good way of integrating it yet;</p> <p>We have metadata that we use to help in data integration;</p> <p>We use a vendor's product for data integration such as data blending, unified information access, data virtualization in a data layer, or a logical data warehouse;</p> <p>We employ ETL routines to centralize as much data as possible in a data warehouse;</p>
Data Management	GD -12	Our data is stored in silos	<p>Strongly disagree;</p> <p>Disagree;</p> <p>Neutral;</p> <p>Agree;</p> <p>Strongly agree;</p> <p>Don't Know;</p>
Data Management	GD -7	If users want self-service access to shared data resources they can generally get it	<p>No; users are limited to their own data silos and do not have access to shared data resources;</p> <p>Yes; we apply techniques such as data blending to enable self-service access to integrated data from multiple sources;</p> <p>Users, if they meet access criteria, have self-service access only to a centralized data warehouse;</p> <p>No self-service access, but through IT users can access some shared data resources;</p>
Data Management	GD -13	We have a process in place for dealing with data quality that is dependent on the kind of data we are dealing with	<p>Strongly disagree;</p> <p>Disagree;</p> <p>Neutral;</p> <p>Agree;</p> <p>Strongly agree;</p> <p>Don't Know;</p>
Data Management	GD -8	What kinds of analytics techniques does your company use to analyze data?	<p>None yet;</p> <p>BI/OLAP tools, dashboards, reporting, and even real-time reporting;</p> <p>Those above as well as visual discovery;</p> <p>Those above as well as predictive analytic;</p> <p>Those above as well as other data mining or statistical techniques;</p> <p>We utilize all of the techniques described above as well as techniques such as social media</p>

			analytics, geospatial analytics, text analytics, network analytics, or stream mining;
Analytics	A-4	Analytics are often automated as part of the business processes in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Analytics	A-5	We have a good idea of what business questions we are trying to solve with data in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Analytics	A-6	We have tolerance for early failure with new analytics technologies in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Analytics	A-7	Analytics is seen as a competitive differentiator in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Analytics	A-8	We are able to deploy analytics to support performance management metrics so that users can more deeply analyze data associated with the metrics for which they are accountable	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Analytics	A-9	Business users who develop useful data visualizations or advanced analytics are able to work with IT to secure funding and focus resources on deploying analytics to other internal departments	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;

Analytics	A-1	How are analytics delivered in your company?	<p>We don't deliver them yet;</p> <p>The statistician or data scientist prepares and delivers them;</p> <p>IT or statisticians build a dashboard or other interactive delivery method;</p> <p>Business analysts or others create and distribute them;</p> <p>They are operationalized as part of a business process;</p> <p>We use a variety of distribution methods, including operationalizing and embedding analytics into a business process;</p>
Analytics	A-2	What percentage of your organization's business analysts, data analysts, data scientists, and business users have the tools and know-how to analyze data in a self-service environment, without close IT involvement?	<p>None;</p> <p>1-20%;</p> <p>21-50%;</p> <p>51-75%;</p> <p>76-100%;</p>
Analytics	A-3	Data management and ownership policies are in place and documented in my company	<p>No;</p> <p>We haven't had time for that but we know we need to do that;</p> <p>We are putting this in place now at the business unit level;</p> <p>Yes, at the business unit level;</p> <p>Yes, at the enterprise level;</p>
Governance	G-1	We have an analytics governance team in place with representatives from across the company, including key business stakeholders. Roles and responsibilities are clearly defined	<p>Strongly disagree;</p> <p>Disagree;</p> <p>Neutral;</p> <p>Agree;</p> <p>Strongly agree;</p> <p>Don't Know;</p>
Governance	G-2	We are monitoring adherence to our analytics policies	<p>Strongly disagree;</p> <p>Disagree;</p> <p>Neutral;</p> <p>Agree;</p> <p>Strongly agree;</p> <p>Don't Know;</p>
Governance	G-3	The formalized role of the analytics steward is in place with roles and responsibilities are clearly identified	<p>Strongly disagree;</p> <p>Disagree;</p> <p>Neutral;</p> <p>Agree;</p> <p>Strongly agree;</p> <p>Don't Know;</p>
Governance	G-4	Data definitions and metadata are clearly established	<p>Strongly disagree;</p> <p>Disagree;</p> <p>Neutral;</p> <p>Agree;</p> <p>Strongly agree;</p> <p>Don't Know;</p>

Governance	G-5	Security policies are in place and enforced for all forms of data in my company	Strongly disagree; Disagree; Neutral; Agree; Strongly agree; Don't Know;
Creating Competitive Advantage	VC -1	Lowering Cost	1 para Imaterial e 5 para Muito Importante
Creating Competitive Advantage	VC -2	Enhacing differentiation	1 para Imaterial e 5 para Muito Importante
Creating Competitive Advantage	VC -3	Changing competitive scope	1 para Imaterial e 5 para Muito Importante
Creating Competitive Advantage	VC -4	Spawning new businesses	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-1	Net Sales	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-2	Profit	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-3	Operating Margin	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-4	Market Share Evolution	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-5	Customer Recurrence (Compliance)	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-6	Promotion budget Allocation	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-7	New Products Introduction	1 para Imaterial e 5 para Muito Importante
Improving Performance	P-8	Organizational Climate	1 para Imaterial e 5 para Muito Importante

Apêndice 2 – Pontuação por resposta

Perguntas	Pontuação	Possível Respostas
Do you have both business and IT sponsorship across the company for analytics initiatives?	18,4	We have both business and IT sponsorship AND we work together
	5,6	We don't have sponsorship across the company for analytics
	11,8	Neutral / Don't Know
	15,0	We have business sponsorship only
There are people in my organization with skills in advanced analytics to support the needs of the business (i.e., data scientists, business analysts, computer scientists, etc.)	18,4	Yes, company-wide
	5,6	No
	15,0	Yes, at the department or business unit level
Analytics projects are driven by business leadership and deliver value incrementally instead of at the end of the entire development process	15,0	Yes, for some projects
	8,7	We are moving that way
	5,6	No
	18,4	Definitely
What infrastructure technologies do you currently utilize for your analytics efforts?	18,4	We use a range of approaches that form an analytics ecosystem
	5,6	We use flat files or spreadsheets
	8,7	We use an analytic platform or appliance
	15,0	We use a range of technologies, including our data warehouse, Hadoop, and others, but they are siloed
	11,8	We have a data warehouse or a data mart
Do you make use of mobile technologies for analytics?	11,8	Yes, but only for a select few
	18,4	Yes, for all those who need it
	8,7	No, but we are thinking about it
	5,6	No, and we have no plans to do so
We use the public cloud for analytics	18,4	We have a private cloud that we use for analytics
	8,7	We don't use the cloud yet for analytics, but we are moving in that direction
	5,6	No, we would never use the public cloud
	11,8	We have a hybrid model where we use some public cloud, some data center, and some private cloud
What kinds of data do you currently collect and manage as part of your analytics efforts?	18,4	We collect and manage data from multiple sources, both internal and external to the company. This includes unstructured data, geospatial data, and much more
	8,7	Structured data only from our internal systems
	11,8	Structured data and demographic data
	15,0	Multi-structured data along with our structured data
	5,6	None
How much data are you analyzing currently?	8,7	Megabytes
	11,8	Neutral / Don't Know
	8,7	Megabytes
	18,4	Terabytes
We make use of multiple sources of data in a single analysis	15,0	Yes, with structured data
	18,4	Yes, with different kinds of data including unstructured data and other non-traditional data, but it is a hassle trying to integrate it
	11,8	Yes, with structured data and 1 or 2 outside sources such as demographic data
	8,7	Yes, with different kinds of data and we do a good job of integrating it
	5,6	No
How do you integrate your data?	8,7	We use a vendor's product for data integration such as data blending, unified information access, data virtualization in a data layer, or a logical data warehouse
	5,6	We don't have a good way of integrating it yet
	11,8	We employ ETL routines to centralize as much data as possible in a data warehouse
	15,0	We have metadata that we use to help in data integration
If users want self-service access to shared data resources they can generally get it	8,7	No self-service access, but through IT users can access some shared data resources
	5,6	No; users are limited to their own data silos and do not have access to shared data resources
	15,0	Yes; we apply techniques such as data blending to enable self-service access to integrated data from multiple sources
	11,8	Users, if they meet access criteria, have self-service access only to a centralized data warehouse
What kinds of analytics techniques does your company use to analyze data?	18,4	BI/OLAP tools, dashboards, reporting, and even real-time reporting
	16,6	Those above as well as visual discovery

	15,0	We utilize all of the techniques described above as well as techniques such as social media analytics, geospatial analytics, text analytics, network analytics, or stream mining
	13,4	Those above as well as predictive analytic
	5,6	None yet
	15,0	Those above as well as other data mining or statistical techniques
How are analytics delivered in your company?	8,7	They are operationalized as part of a business process
	7,2	Business analysts or others create and distribute them
	15,0	IT or statisticians build a dashboard or other interactive delivery method
	16,6	We use a variety of distribution methods, including operationalizing and embedding analytics into a business process
	5,6	We don't deliver them yet
	15,0	The statistician or data scientist prepares and delivers them
What percentage of your organization's business analysts, data analysts, data scientists, and business users have the tools and know-how to analyze data in a self-service environment, without close IT involvement?	15,0	51-75%
	5,6	1-20%
	8,7	21-50%
Data management and ownership policies are in place and documented in my company	18,4	Yes, at the enterprise level
	8,7	We are putting this in place now at the business unit level
	15,0	Yes, at the business unit level
	5,6	No
	7,1	We haven't had time for that but we know we need to do that
All Other questions	5,6	Strongly Disagree
	8,7	Disagree
	11,8	Neutral / Don't Know
	15,0	Agree
	18,4	Strongly Agree

Apêndice 3 – Roteiro Entrevista em profundidade

Roteiro Entrevista
Como você avalia a relevância desse trabalho de pesquisa?
Como você avalia capacidade do uso de BI para criação de vantagem competitiva e incremento de resultados no setor farmacêutico?
Como avaliar o enquadramento da empresa como uma Early Adption no geral?
Como avaliar o enquadramento da empresa como uma Corporate Adption quanto a dimensão Organização? Quais fatores atribui esse resultado?
Como avaliar o enquadramento da empresa como uma Early Adption quanto a dimensão Infraestrutura? Quais fatores atribui esse resultado? O que precisa evoluir para empresa atingir o estágio de Corporate Adoption?
Como avaliar o enquadramento da empresa como uma Early Adption quanto a dimensão Gestão de Dados? Quais fatores atribui esse resultado? O que precisa evoluir para empresa atingir o estágio de Corporate Adoption?
Como avaliar o enquadramento da empresa como uma Early Adption quanto a dimensão Análises? Quais fatores atribui esse resultado? O que precisa evoluir para empresa atingir o estágio de Corporate Adoption?
Como avaliar o enquadramento da empresa como uma Corporate Adption quanto a dimensão Governança? Quais fatores atribui esse resultado?