

Modelo analítico de gestão para empresas Data-Driven



<https://doi.org/10.56238/sevened2023.006-013>

José Jerônimo de Menezes Lima

Doutorado em Administração de Empresas
Universidade do Vale do Rio dos Sinos

Emir José Redaelli

Doutorado em Administração de Empresas
Universidade do Vale do Rio dos Sinos

RESUMO

Esta pesquisa, de natureza qualitativa, propõe um framework de modelo analítico de gestão para empresas data-driven. O framework foi desenvolvido a partir da revisão narrativa da literatura especializada sobre modelos de gestão focados em análise de dados para alavancar a competitividade de empresas data-driven. Um modelo analítico de gestão é um conjunto de fundamentos de administração logicamente inter-relacionados, integrados de forma sistêmica e coerentes com uma filosofia organizacional baseada em análise de dados para a tomada de decisão

estratégica, visando gerar vantagem analítica e, por consequência, vantagem competitiva sustentável nos negócios. A estrutura do framework proposto tem os seguintes componentes: Competição Analítica e Vantagem Analítica; Posicionamento Estratégico e Foco Analítico; Liderança Transformadora e Jornada Data-Driven; Orientação para o Mercado e Análise de Tendências; Domínio de Data Science e Business Analytics; Tomada de Decisão Baseada em Dados; e Gestão de Projetos Analíticos. A principal contribuição desta pesquisa é de natureza teórico-gerencial e visa identificar fatores determinantes para a ideação de um modelo de gestão com foco em análise de dados. Como estudos futuros, sugere-se a operacionalização dos componentes do framework, possibilitando sua implementação em empresas intensivas em conhecimento para validar sua adequação ao contexto da competição analítica.

Palavras-chave: Analytics Economy, Competição Analítica, Modelo Analítico de Negócio, Modelo Analítico de Gestão.

1 INTRODUÇÃO

Encontrar o modelo de gestão ideal para uma empresa requer um processo de identificação de informações-chave, análise e avaliação dessas informações, e tomada de decisão sobre as opções disponíveis, visando ao sucesso nos negócios (FNQ,2017). Essas informações-chave são analisadas para se chegar a um modelo de gestão ideal que aborde características próprias da empresa, como seu modelo de negócio, interação com o ambiente externo, compreensão do ambiente interno e pontos em comum entre os métodos de gestão em uso na empresa com modelos de referência (LIMA; REDAELLI, 2023). Ainda, é importante considerar os objetivos estratégicos do negócio, isto é, aquilo que a empresa deseja alcançar a longo prazo, e conhecer referenciais comparativos pertinentes que deem o direcionamento para a construção de um modelo de gestão próprio eficaz (PAGLIUSO; CARDOSO; SPIEGEL, 2012).

Um modelo de gestão é uma representação da realidade que descreve as relações entre diferentes elementos da gestão de uma empresa. É a maneira como uma empresa se organiza em



relação aos processos que utiliza para realizar seu modelo de negócio (FNQ, 2017). Nesse sentido, Amitt e Zott (2020) afirmam que não existe um modelo de gestão ideal pré-estabelecido que as empresas devem considerar aspectos específicos, como o setor de atuação, o tipo de atividade econômica desenvolvida, a filosofia e a cultura organizacional, as estratégias e os objetivos do negócio. Dessa forma, definir o modelo de gestão mais eficiente e eficaz à realidade de uma empresa conduz ao aprimoramento dos pontos essenciais do negócio, viabilizando a criação de valor para todas as partes interessadas.

Na visão de Bock e George (2018), Grover et al. (2018), Gao (2020) e Kotorov (2020), dentre os principais benefícios de um modelo de gestão pode-se citar:

- (i) Busca de diferencial competitivo no mercado: diferenciação é o ato de desenvolver um conjunto de aspectos distintivos das ofertas da empresa em relação às ofertas da concorrência, e ter o controle das competências centrais, as quais são fontes de vantagens comparativas, e manter a excelência operacional são requisitos para que uma empresa que deseja se sobressair à concorrência.
- (ii) Padronização dos processos: a sistematização das práticas de gestão visa ao melhor método para se executar um trabalho. Por esse motivo, os processos devem ser acompanhados para garantir a qualidade das operações, buscando um padrão de excelência operacional a ser seguido para a execução das atividades. Padronizar processos também é importante para garantir um modelo de trabalho, estipular um caminho bem-definido para a execução das atividades e conferir previsibilidade ao processo. Assim, a empresa melhora sua qualidade, diminui riscos e aumenta a produtividade.
- (iii) Comunicação entre setores: o acesso às informações é a base do bom relacionamento interpessoal. Um modelo de gestão eficaz uniformiza a linguagem e melhora o diálogo entre os diversos setores. A comunicação gerencial inclui processos necessários para assegurar que os dados dos processos sejam gerados, coletados, distribuídos, armazenados, recuperados e organizados de maneira oportuna e apropriada.
- (iv) Mapeamento e monitoramento de processos: mapeamento de processos é uma técnica utilizada para entender como o negócio está operando, identificando cada atividade dos processos. Mensurar e monitorar os resultados que uma empresa está conseguindo alcançar se consegue com a utilização de Key Performance Indicators (KPIs) para que uma empresa identificar se seus objetivos e metas estão sendo alcançados.
- (v) Gerenciamento dos riscos: é possível planejar, organizar, dirigir e controlar recursos humanos e materiais de uma empresa, no sentido de mitigar riscos de operação de uma empresa. Com essas informações, pode-se obter dados importantes para as decisões tomadas serem as mais assertivas. Ainda, é necessário estabelecer estratégias para alcançar o equilíbrio



ideal entre as metas de crescimento e de retorno de investimentos, bem como mitigar os riscos associados.

Nessa direção, este artigo propõe um framework de modelo analítico de gestão, aqui conceituado como um conjunto de fundamentos de gestão logicamente inter-relacionados, integrados de forma sistêmica e coerentes com uma filosofia organizacional baseada em análise de dados para a tomada de decisão estratégica, visando gerar vantagem analítica para as empresas alcançarem vantagem competitiva sustentável.

Neste artigo, adota-se a definição de ‘vantagem analítica’ como a capacidade dinâmica obtida pelo gerenciamento baseado em fatos e dados e o uso estratégico de análise quantitativa de dados, métodos matemáticos e algoritmos de modelagem estatística descritiva, preditiva e prescritiva para orientar decisões e ações que permitam às empresas buscar vantagem competitiva sustentável (REDAELLI; LIMA, 2023). Nesse contexto, ‘vantagem competitiva’ diz respeito à abordagem da Economia que avalia o resultado da gestão de uma empresa que a posiciona, em termos de rentabilidade do patrimônio líquido, acima da média de seu setor de atuação (PORTER, 1989).

2 DESENVOLVIMENTO

Esta pesquisa, de natureza qualitativa, utiliza o método de revisão narrativa da literatura especializada sobre o tema ‘modelos de gestão’ para construir o framework proposto, conforme sugere Rother (2007).

Entende-se por framework um conjunto estruturado de atividades necessárias para se atingir os objetivos esperados nas definições essenciais de um constructo de estudo, bem como as relações existentes entre essas atividades, apresentado de maneira conceitual. A literatura sobre modelagem organizacional considera ‘framework’ diferentemente de ‘modelo’: ‘framework’ é uma construção teórica envolvendo conceitos obtidos de um referencial teórico de referência e de estudos empíricos analisados criticamente; a noção de ‘modelo’ pressupõe o detalhamento de um framework em passos operacionalizáveis para ser colocado em prática, com a sugestão de métodos, técnicas, ferramentas, capacitações e políticas específicas para cada caso no qual será aplicado (RAVITCH; RIGGAN, 2016). Dessa forma, a análise de um framework oferece uma oportunidade de teorização para a construção de um quadro de referência baseado em teorias já consolidadas na prática no campo de estudo em questão. Assim, a utilização de um framework permite flexibilidade de modificação e ênfase na compreensão do objeto de estudo.

As principais características de um framework são: (i) não é apenas um conjunto de conceitos, mas uma construção em que cada conceito desempenha um papel que ilustra os fatores-chave inter-relacionados; (ii) não fornece um cenário causal/analítico da empresa diagnosticada, mas uma abordagem interpretativa da realidade da empresa; (iii) não oferece uma explicação teórica, como



ocorre em modelos quantitativos; proporciona a compreensão da realidade estudada; (iv) não fornece conhecimentos sobre a realidade empresarial, mas de interpretação e percepções dos envolvidos nesses fatos; (v) tem natureza indeterminista e, portanto, não permite prever um resultado; (vi) pode ser desenvolvido por meio de um processo de análise qualitativa; e (vii) as fontes de dados consistem em muitas teorias orientadas para a disciplina objeto do framework, que se tornam dados empíricos da análise proposta, a partir do estudo de teorias multidisciplinares de conhecimento, metassíntese, ou uma síntese sistemática dos resultados obtida por estudos qualitativos, procurando gerar novas interpretações em um determinado campo de estudo.

A metodologia utilizada para elaboração do framework proposto é mostrada no Quadro 1, seguindo todas as ações recomendadas, a partir de um quadro multidisciplinar da literatura acadêmica e comercial especializada para descrever um diagnóstico sistêmico fundamentado em modelos de excelência da gestão consagrados em empresas data-driven.

Quadro 1 - Metodologia de construção do framework.

Fases	Ações Realizadas
Fase 1	Mapear referências no estado da arte da literatura acadêmica e comercial especializada sobre modelos de gestão baseados em dados, incluindo a utilização de artigos científicos e livros acadêmicos e de negócios.
Fase 2	Realizar a leitura extensiva e a categorização dos dados selecionados visando agrupá-los tanto por disciplina como por uma escala de importância e poder representativo dentro de cada disciplina, de modo a se conseguir maximizar a eficácia da pesquisa e assegurar a representação eficaz de cada disciplina.
Fase 3	Identificar e nomear conceitos com o intuito de analisar os dados selecionados e descobrir novos conceitos que surjam da revisão da literatura.
Fase 4	Desconstruir e categorizar os conceitos encontrados para identificar os seus principais atributos, características, pressupostos e papel, e, subsequentemente, organizar e categorizar os conceitos conforme as suas características e papel ontológico, epistemológico e metodológico. O resultado dessa fase inclui os nomes dos conceitos, uma descrição de cada um deles, a categorização conforme o seu papel ontológico, epistemológico ou metodológico, e a apresentação das referências para cada conceito.
Fase 5	Integrar conceitos para agrupar aqueles que tenham semelhanças, reduzindo o número de conceitos e permitindo a sua manipulação.
Fase 6	Sintetizar os conceitos num quadro teórico que faça sentido aos pesquisadores e aos futuros usuários do <i>framework</i> .
Fase 7	Validar o <i>framework</i> proposto e seus conceitos para verificar se faz sentido não só para os pesquisadores, mas também para outros estudiosos e praticantes do assunto. A validação de um <i>framework</i> é um processo que começa com os pesquisadores, que procuram outros especialistas para obter deles feedback.

Fonte: Adaptado de Cecin et al. (2022).

Os componentes do framework de modelo analítico de gestão proposto, bem como o modelo analítico de negócio que o embasa, são apresentados no Quadro 2.

Quadro 2 - Referencial teórico para elaboração do framework proposto.

Referências Teóricas	Questões-Chave e/ou Perspectivas
Amit e Zott (2020)	O estudo é baseado em mais de 20 anos de pesquisa teórica colaborativa e empírica rigorosa, tendo uma orientação pragmática. É orientado para ação e fornece a empresários e executivos um guia detalhado para o design e implementação de modelos de negócios inovadores e modelos de gestão escaláveis para as empresas.
Bock e George (2018)	Mostram que modelos de negócios impulsionam o crescimento rápido e como criar, testar, adaptar e inovar modelos de negócios e de gestão bem-sucedidos para qualquer tipo de empresa.



Davenport e Harris (2018)	Fornecem o mapa para uma empresa se tornar um competidor analítico, mostrando como criar novas estratégias com base em analytics. O modelo de cinco etapas da competição analítica descreve os comportamentos típicos, as capacidades e os desafios de cada etapa. Explicam como utilizar as capacidades de uma empresa e como guiá-la em direção aos mais altos níveis de competição no mundo dos negócios governado pelos dados, enfatizando recursos-chave: humano e tecnológico.
Evans (2019)	Apresenta os conceitos fundamentais da análise de negócios moderna e fornece ferramentas para se entender como a análise de dados funciona nas empresas. Examina a análise de negócios nas perspectivas descritiva e preditiva.
Ghandi, Bathia e Dev (2021)	Explicam a análise de dados voltada para a tomada de decisão com modelos e algoritmos, conceitos teóricos, aplicações, experimentos em domínios relevantes ou focados em questões específicas. Exploram os conceitos de tecnologia de banco de dados, aprendizado de máquina, sistemas baseados em conhecimento, computação de alto desempenho, recuperação de informações, descoberta de padrões ocultos em grandes volumes de dados e visualização de dados. Apresentam recursos de mineração de padrões, agrupamento, classificação e análise de dados.
Gordon (2023)	Adota uma abordagem prática e cobre os principais casos de uso para análises em diferentes áreas de negócios, incluindo análise de marketing, RH, operacional e financeira. Fundamenta a discussão nos dados, análises e visualização, e na compreensão das responsabilidades legais e éticas decorrentes.
Krantz (2023)	Apresenta um <i>framework</i> para garantir que haja alinhamento entre o que o negócio precisa, o que as equipes de dados podem entregar e as competências que os líderes devem se envolver. Descreve um processo para abordar os vieses mais comuns e a resistência psicológica à mudança, tanto ao nível individual quanto cultural organizacional, e examina a importância das habilidades interpessoais, bem como das capacidades técnicas. Aconselha como as empresas podem focar melhor seus recursos de dados para garantir que eles apoiem as atividades de negócios mais críticas e de valor agregado.
Lima e Redaelli (2023)	As análises oriundas da tomada de decisão baseada em dados permitem, pela interpretação de conjuntos de pequenos e grandes volumes de dados, a geração de insights para os executivos poderem definir estratégias para resolver problemas, melhorar processos, gerar inovação e buscar mais competitividade. Empresas chamadas de negócios de dados adotam essa postura como parte de uma estratégia defendida pela liderança e empurrada para baixo para os decisores em todos os níveis, capacitando seus executivos para reconhecer a importância estratégica dos dados e a utilizar melhores ferramentas qualitativas e quantitativas para tomar as melhores decisões. Apresentam o conceito de Competição Analítica e Jornada <i>Data-Driven</i> , que descrevem as características e práticas de gestão das empresas que evoluíram para um degrau mais elevado em maturidade analítica. A evolução de uma empresa desde a utilização de <i>Business Intelligence</i> até a Competição Analítica requer formular estratégias para gerir os dados, um investimento significativo em tecnologia, capacitação dos executivos na <i>expertise</i> na gestão de dados e criação de uma cultura organizacional <i>data-driven</i> para a tomada de decisão.
Lisinski (2013)	Apresenta uma estrutura de metodologia da ciência de gestão, sintetizada na determinação e descrição dos seus componentes básicos, cobrindo três níveis de análise e efetuando uma descrição detalhada desses níveis: filosofia; métodos; e práticas de gestão. Utiliza uma análise estrutural para identificação e das características de componentes particulares da metodologia da ciência de gestão.
Magretta (2015)	Explora a lógica de atuação das empresas bem-sucedidas e como se baseiam em modelos de negócio, modelos de gestão, estratégia e práticas, visando explicar a gestão como a capacidade de transformar a complexidade em desempenho.
Porter e Tanner (2015)	Apresentam um <i>framework</i> para a excelência organizacional como forma de diagnóstico sistemático comparativo de modelos de excelência organizacional. Introduce o processo de autoavaliação, explora as principais abordagens à autoavaliação e ilustra os benefícios práticos da autoavaliação com exemplos de estudos de casos.



Provost e Fawcett (2016)	Apresentam princípios de <i>Data Science</i> e pensamento analítico necessários para extrair conhecimento útil e valor de negócios a partir dos dados. Esses princípios sustentam os processos e as estratégias necessárias para resolver problemas de negócios por meio das técnicas de mineração de dados.
Sahay (2018)	Discute as principais categorias de análise de dados: descritiva, preditiva e prescritiva, com suas ferramentas e aplicações nos negócios. Concentra-se na análise descritiva que envolve o uso de métodos descritivos e visualização de dados, bem como ferramentas de análise de dados, aplicações de <i>big data</i> e o uso de dashboards para entender o desempenho dos negócios.
Seebacher e Garritz (2021)	Conforme os autores, apenas 5% de todas as empresas podem ser consideradas orientadas por dados, o que significa que 95% de todas elas não utilizam dados nas tomadas de decisão. Isso representa um enorme risco para todas as partes interessadas. Nesse contexto, muitos executivos acreditam que simplesmente comprar uma solução de IA-TI resolverá o problema. Os executivos devem desenvolver os conceitos e competências da gestão orientada por dados para aplicar essas novas tecnologias. Descreve o caminho para a gestão orientada por dados, o descreve as etapas necessárias para implementar uma gestão orientada por dados.
Sharda, Delen e Turban (2019)	O ambiente de negócios em constante evolução e cada vez mais complexo faz o tempo para a tomada de decisões encolher, ao passo que a natureza global das decisões está se expandindo, exigindo o desenvolvimento e uso de sistemas computadorizados de apoio à decisão. Apresentam as bases teóricas e conceituais do apoio a decisões e as ferramentas e técnicas disponíveis.

Fonte: Elaborado pelos autores.

Com base nessas referências, o framework do Modelo Analítico de Gestão (MAG) proposto representa uma diretriz que permite conexão de processos gerenciais, explorando as sinergias das condições de organização em ambientes de negócio dinâmicos. Essa lógica de ideação oferece uma abordagem prática e integrativa que ajuda a gerenciar a frustração da incerteza e aumenta o nível de prontidão para a tomada de decisão estratégica baseada em análise de dados.

O MAG está no contexto da Analytics Economy, que, segundo Berndtsson (2018), Cao (2019) e Tang (2022), é o ambiente econômico que utiliza análise de dados como ação norteadora de novas estruturas e lógicas empresariais para a geração de valor a partir da utilização estratégica dos dados. Concebido especialmente para empresas dos setores econômicos intensivos em conhecimento, auxilia a expandir as capacidades dinâmicas requeridas pelos negócios contemporâneos e apoia a criação de um fluxo de valor nos negócios a partir dos dados. Isso é possível pela integração dos contextos externos e internos, não se tratando apenas de adaptabilidade nem do comprometimento, resultando em um negócio futuro sustentável. A trilha do modelo é adaptativa, integrando desafios de curto prazo, médio e longo prazos, e o norte estratégico cria um senso de urgência e dedicação para uma posição de vantagem competitiva no mercado. Conecta o passado e o presente, pela análise descritiva de dados, com o futuro, pela análise preditiva e prescritiva de dados. No entanto, não prevê as realidades do amanhã, pois essas dependem das decisões que empresários e executivos tomarem com bases nas análises realizadas, mas sua lógica facilita lidar com o desconhecido de forma pragmática, harmonizando o desejado e o possível, o presente e o futuro. Dessa forma, representa uma oportunidade para o desenvolvimento de um caminho sobre como executar uma estratégia que atenda ao presente e ao futuro da empresa simultaneamente.



Incorporado ao contexto da Analytics Economy, o MAG é flexível, integrativo e evita prescrições, combinando conceitos de Matemática, Estatística, Ciência da Computação e Administração para permitir que as empresas busquem crescimento pela integração que se beneficia das opções de valor criado pela inovação, a exploração de tendências e novas lógicas plausíveis do futuro e a formulação e operacionalização de estratégias competitivas deliberadas. Para adequar-se a tal variedade de contextos, a lógica de ideação do MAG é integrativa e modular, conectando a estratégia com a inovação, tornando o futuro mais plausível e amentando a adaptabilidade e a agilidade da execução das estratégias.

Nesse sentido, os componentes do MAG são:

- (i) **Competição Analítica e Vantagem Analítica:** arcabouço teórico no qual se assentam os direcionadores do modelo analítico de gestão.
- (ii) **Posicionamento Estratégico e Foco Analítico:** Auxilia na definição do foco estratégico de premissas empresariais baseadas em ganhos operacionais com gestão da eficiência ou ganhos de mercado com a inovação, facilitando a realização de ações de mercado embasadas na Competição Analítica.
- (iii) **Liderança Transformadora e Jornada Data-Driven:** Estabelece os compromissos da alta direção com a evolução do uso de dados para a tomada de decisão estratégica e avalia o nível de maturidade analítica no qual a empresa está e como ela planeja evoluir para patamares mais elevados.
- (iv) **Orientação para o Mercado e Análise de Tendências:** filosofia de gestão do negócio que coloca as necessidades e expectativas dos clientes no centro das decisões de negócio. Especificamente, em setores intensivos em conhecimento, significa entender profundamente necessidades dos clientes, mudanças nas preferências deles, e o ambiente competitivo. A análise de tendências está relacionada à orientação para o mercado, envolvendo o monitoramento e a interpretação das mudanças de longo prazo no setor, na tecnologia, na economia e nos padrões sociais.
- (v) **Domínio de Data Science e Business Analytics:** permite transformar grandes volumes de dados em informações úteis. Isso é vital para identificação de oportunidades, otimização de processos, e previsão de tendências. Business Analytics refere-se ao processo de coleta, processamento e análise de dados para auxiliar os executivos a tomar decisões informadas, utilizando métodos e técnicas de análise estatística. O domínio de Business Analytics permite entender e interpretar o desempenho do negócio para identificar áreas para melhorias, com base em análises quantitativas.



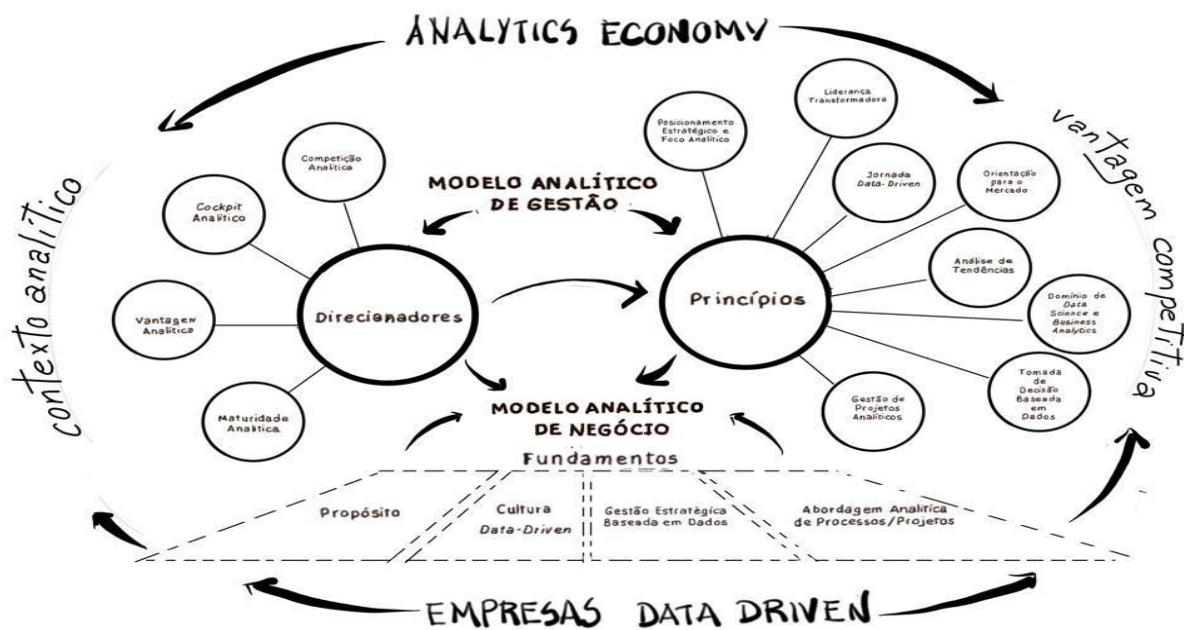
(vi) Tomada de Decisão Baseada em Dados: refere-se ao processo de fazer escolhas estratégicas com base na análise e interpretação de dados reais, em vez de utilização de intuição ou observação casual.

(vii) Gestão de Projetos Analíticos: envolve o planejamento, execução, monitoramento e conclusão de projetos que se concentram em análise de dados para gerar insights.

Nessa direção, a Figura 1 ilustra a visão integrativa do Modelo Analítico de Negócio e do Modelo Analítico de Gestão proposto. A Figura 2 mostra a estrutura específica do MAG. Essas figuras sintetizam a visão do posicionamento estratégico e foco analítico.

Um modelo analítico de negócio é um conjunto de fundamentos de gestão logicamente inter-relacionados, integrados de forma sistêmica e coerentes com uma filosofia organizacional baseada em análise de dados para a tomada de decisão estratégica, para gerar vantagem analítica para as empresas alcançarem vantagem competitiva nos negócios. O modelo analítico de negócio que embasa o MAG sugere uma abordagem de gestão empresarial baseada em análise de dados para a tomada de decisão estratégica. O modelo é composto pelos seguintes componentes: (i) Propósito Analítico; (ii) Cultura Data-Driven; (iii) Gestão Estratégica Baseada em Dados; (iv) e Abordagem Analítica de Processos e Projetos. O modelo visa gerar vantagem analítica para as empresas alcançarem vantagem competitiva nos negócios. Sugere também a importância de um modelo de negócio e um modelo de gestão integrados para alcançar vantagem analítica (REDAELLI; LIMA, 2023).

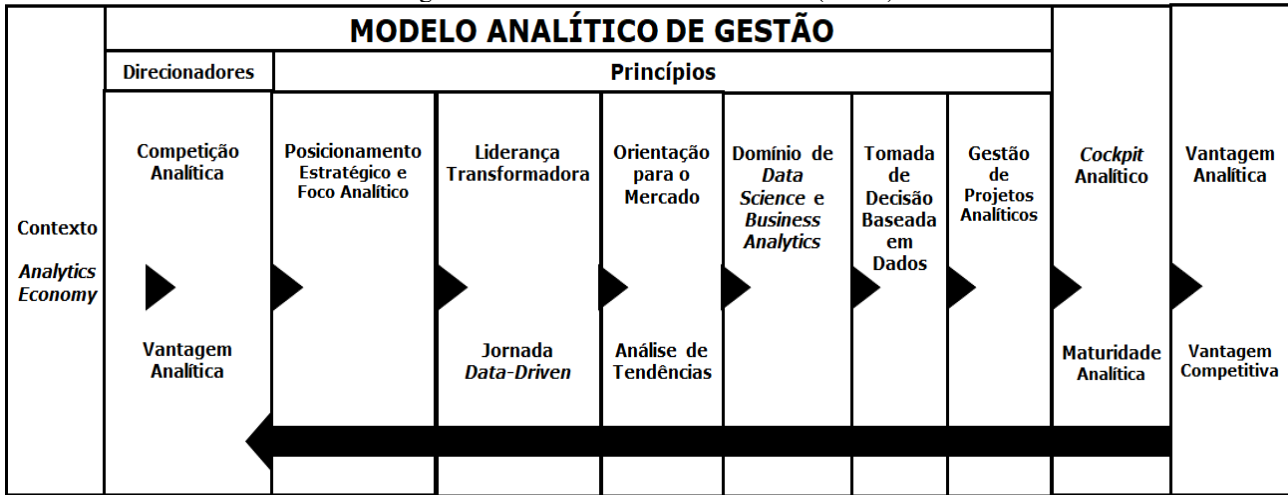
Figura 1 - Modelo Analítico de Negócio e Modelo Analítico de Gestão.



Fonte: Elaborada pelos autores.



Figura 2 - Modelo Analítico de Gestão (MAG).



Fonte: Elaborada pelos autores.

Tendo por base as definições de Saulles (2020), Pentland, Lipton e Hardjono (2021), Yaseen (2022), Lima e Redaelli (2023) e Redaelli e Lima (2023), os componentes do MAG são:

2.1 POSICIONAMENTO ESTRATÉGICO E FOCO ANALÍTICO

Segundo Seddon et al. (2017), Vidgen, Shaw e Grantt (2017), Marr (2021), Asplen-Taylor (2022) e Lima e Redaelli (2023), a definição do posicionamento estratégico das empresas é quase sempre efetuada sobre o conhecimento prático do que empresários e executivos acreditam que realmente funciona, do que não funciona, e por quê. O conhecimento prático geralmente disponível é essencial, mas por estar disponível a todos, raramente consegue ser decisivo.

O pressuposto que afirma que todo o conhecimento sobre negócio importante é disponibilizado por sistemas de Enterprise Resource Planning (ERP) ou por especialistas no assunto frequentemente mata a inovação, reprime mudanças e bloqueia o aperfeiçoamento em empresas que passaram a acreditar que sua maneira de fazer as coisas é a melhor. Assim, mesmo que clientes e mercados mudem rápida e frequentemente, a sobrevivência e o crescimento das empresas exigem foco nas principais ofertas atuais e nas receitas que elas geram. Se as empresas tiverem insuficiência de produtos e serviços já consolidados, mas ainda viáveis, perderão lucros adicionais que poderão gerar investimentos. Alertar para que empresários e executivos apliquem novas tecnologias a ofertas antigas, reiniciando seu ciclo de crescimento, pode orientar a uma direção futura, sendo esse o objetivo principal da análise de dados.

Conforme Abbosh, Nunes e Downes (2021), ‘pivotar’ é um termo que traduz a necessidade de uma empresa mudar de rumos diante de novos desafios ou crises. Significa mudar completamente a direção ou o propósito de uma empresa para que sua sustentabilidade seja alcançada pela melhoria de sua competitividade.



2.3 LIDERANÇA TRANSFORMADORA E JORNADA DATA-DRIVEN

A Jornada Data-Driven de uma empresa começa com a sensibilização dos executivos para a utilização de relatórios extraídos de sistemas de ERP, os quais são os sistemas integrados de gestão empresarial usados pelas empresas para subsidiar sua tomada de decisão. Numa fase inicial, esses sistemas utilizam somente dados internos e análise focada em estatística descritiva, que analisa o passado, avançando na jornada até a obtenção de ganhos com a utilização de modelagem estatística preditiva e prescritiva.

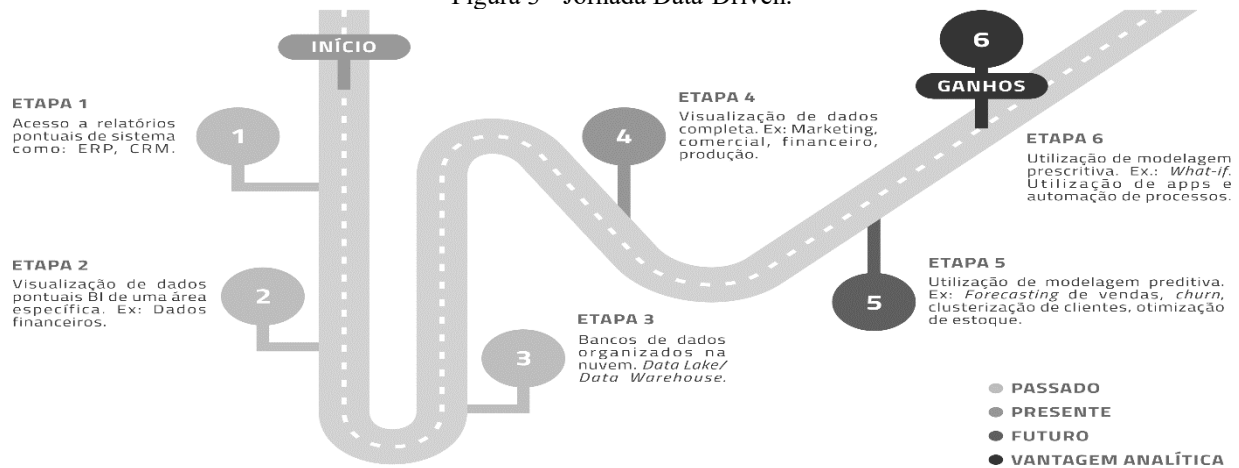
Abraçar a ciência por detrás dos dados significa aprofundar a análise das questões internas confrontando-as com questões de interação com o ambiente externo do negócio. Destina-se a inspirar e a lembrar que uma empresa bem-sucedida não se acomoda, está sempre aprendendo, adaptando-se e crescendo, alimentada por análise de dados. É preciso considerar também que uma mesma empresa pode estar em diferentes estágios de maturidade analítica e assim, no caso de uma empresa que não nasceu digital, é provável que áreas distintas estejam em etapas diferentes da Jornada Data-Driven.

É um engano acreditar que a Jornada Data-Driven tem um fim. Na verdade, a vantagem analítica nasce justamente quando uma empresa aprende a aplicar a inteligência de dados para testar e validar produtos, ajustar erros, experimentar protótipos e mensurar ações, de forma prática, rápida e em tempo real. Portanto, ser Data-Driven é um processo baseado na interação e experimentação analítica, com o uso de métricas para mensurar o desempenho de novas soluções, entender problemas e melhorar a competitividade. Em especial, no contexto da Competição Analítica, é considerar a experiência e a perspectiva do cliente, monitorar o seu nível de satisfação e pivotar sempre que necessário. Dessa forma, a condução eficaz da Jornada Data-Driven cria o ambiente propício para a tomada de decisão baseada em dados, em vez de em intuição ou experiências contaminadas por ruídos e vieses. Assim, a Jornada Data-Driven cria o contexto capacitante que permite às empresas atuar na Competição Analítica com um modelo de analítico de negócio e um modelo analítico de gestão que utilizam ferramentas de Business Analytics para a definição de estratégias competitivas deliberadas para a inovação, a criação de valor e a busca de vantagem competitiva.

A Figura 3 ilustra a Jornada Data-Driven de uma empresa.



Figura 3 - Jornada Data-Driven.



Fonte: Elaborada pelos autores.

2.4 ORIENTAÇÃO PARA O MERCADO E ANÁLISE DE TENDÊNCIAS

Orientação para o mercado trata da filosofia de negócios que coloca as necessidades e expectativas dos clientes no centro de todas as decisões de negócios. Em setores intensivos em conhecimento, isso significa entender profundamente as necessidades dos clientes, as mudanças nas suas preferências, e o ambiente competitivo. As empresas com essa filosofia utilizam técnicas e ferramentas de análise para entender o que seus clientes realmente precisam e querem. Isso envolve realizar pesquisas com os clientes, análises de dados e trabalho colaborativo com as áreas de marketing e desenvolvimento de produtos. A capacidade de responder rapidamente às mudanças nas necessidades do mercado é fundamental e requer o desenvolvimento ágil de novos produtos e serviços, ou a adaptação dos existentes para atender às novas demandas identificadas. Entender o mercado também significa conhecer a fundo a concorrência, analisar como os produtos e serviços se comparam aos dos concorrentes e garantir que a empresa esteja posicionada de maneira eficaz em seu mercado de atuação. Isso diz respeito à orientação para o mercado e envolve o monitoramento e a interpretação das mudanças de longo prazo no setor, na tecnologia, na economia e nos comportamentos sociais. As empresas competidores analíticos utilizam métodos, técnicas e ferramentas para identificar tendências emergentes por análise de dados de mercado, observação de competidores e mesmo pesquisa acadêmica integrada ao negócio. Segundo Redaelli e Lima (2023), identificar tendências é o primeiro passo para aumentar a habilidade de interpretar o que as tendências significam para o negócio e como se pode responder adequadamente a elas. Isso pode significar necessidade de investimentos em novas tecnologias, mudança de estratégias de marketing, redefinir produtos e serviços. Em setores intensivos em conhecimento, a inovação é a chave e analisar tendências ajuda a ficar à frente da concorrência, adaptando as empresas às mudanças do mercado e explorando novas oportunidades.



2.5 DOMÍNIO DE DATA SCIENCE E BUSINESS ANALYTICS

Para Carillo et al. (2019), a grande contribuição do domínio de técnicas e ferramentas analíticas diz respeito aos avanços em termos de pensamento crítico, ou seja, na melhoria dos processos mentais de discernimento, análise e avaliação, que inclui todos os possíveis processos de reflexão sobre itens intangíveis ou não para formar um sólido julgamento que concilia evidência científica com bom senso.

Data Science (Ciência de Dados), é o campo de estudo que envolve o uso de métodos científicos, conhecimento do negócio, algoritmos e sistemas para extrair insights dos dados. O domínio de Data Science permite transformar grandes volumes de dados brutos em informações acionáveis, o que é vital para identificação de oportunidades, otimização de processos, e previsão de tendências. A utilização de Data Science em áreas, como marketing (para segmentação de clientes), operações (para otimização da cadeia de suprimentos) e desenvolvimento de produtos (para criação de produtos orientados por dados) requer utilizartecnologias avançadas e ferramentas, como aprendizado de máquina e Inteligência Artificial (IA), permitindo a análise mais aprofundada e a geração de insights.

Nessa direção, Business Analytics refere-se ao processo de coleta, processamento, e análise de dados para auxiliar executivos na tomada de decisões informadas. Inclui métodos e técnicas de análise estatística e computacional. O domínio de Business Analytics permite entender e interpretar o desempenho do negócio, pela identificação de áreas para melhorias, busca de eficiências e crescimento, com base em análises quantitativas. Utilizar Business Analytics em toda a empresa pode melhorar a tomada de decisão e a otimização de estratégias de marketing, além do gerenciamento eficiente de recursos humanos e financeiros. Assim, Data Science e Business Analytics trabalham frequentemente juntos. Enquanto Data Science pode ser mais voltada à previsão e modelagem avançada, Business Analytics foca na interpretação e aplicação dos insights ao contexto de negócios (DAVENPORT; HARRIS, 2018; LIMA; REDAELLI, 2023).

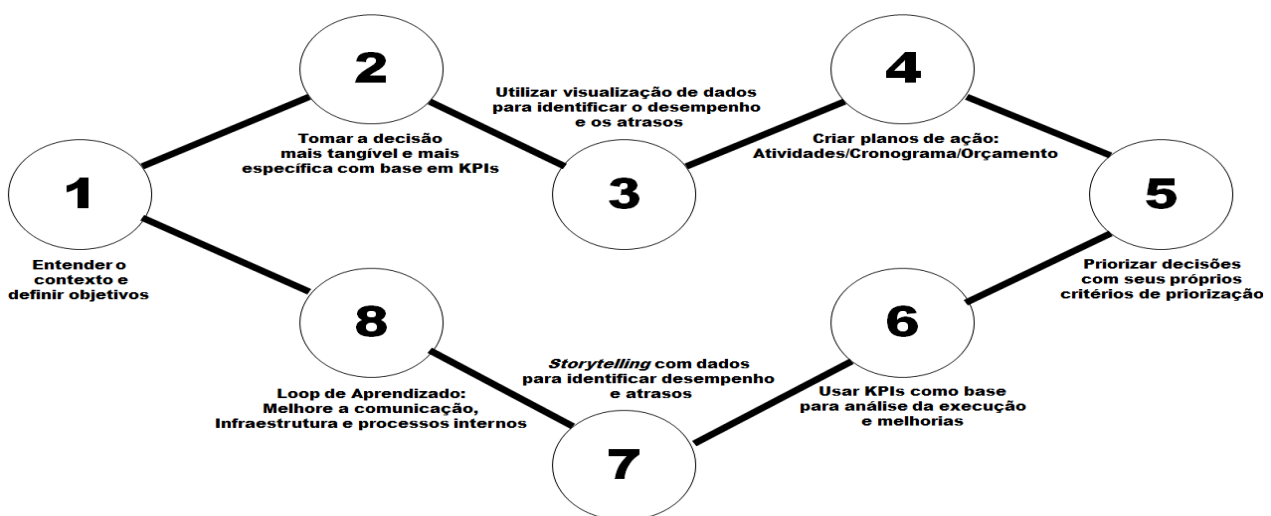
2.6 TOMADA DE DECISÃO BASEADA EM DADOS

A tomada de decisões baseada em dados, também conhecida como Data-Driven Decision Making (DDDM) é uma prática de coleta e análise de dados para apoiar as decisões. Não há um consenso sobre um processo específico a seguir para isso. Embora muitos autores abordem a DDDM sob a ótica dos dados, entende-se que ela diz respeito ao contexto da gestão estratégica das empresas. Por exemplo, para Berndtsson (2018), Ghandi, Bathia e Dev (2021) e Kumar (2021), as principais características de uma abordagem disciplinada e orientada por dados para a tomada de decisão pressupõe a utilização de KPIs alinhados às estratégias, orientando a lógica das tomadas de decisão, permitindo assim às empresas aprender com os erros, analisar os resultados de más e boas decisões, gerando melhoria dos loops de aprendizagem organizacional.



A DDDM é baseada em provas empíricas, permitindo aos executivos propor ações informadas que resultem em resultados comerciais positivos. O oposto de um processo orientado por dados é a tomada de decisões baseadas unicamente na intuição. Para os empresários e executivos orientados por dados, ouvir o seu instinto pode fazer parte do seu processo de tomada de decisão, mas só adotam ações específicas com base no que os dados revelam. Ao contrário, em empresas orientadas por dados, empresários e executivos compreendem os benefícios do conhecimento proveniente dos dados para fazer movimentos empresariais sensatos. Dessa forma, tomar decisões baseadas em dados requer um processo com várias etapas, que vão desde a análise da situação atual até a formulação de um plano de ação. A Figura 4 ilustra o passo a passo da DDDM.

Figura 4 - Tomada de decisão baseada em dados.



Fonte: Elaborada pelos autores.

Passo 1: É preciso entender o contexto da decisão e identificar quais objetivos a empresa espera alcançar pela DDDM, e depois construir uma estratégia em torno deles. Nessa etapa não há problema se a estratégia não estiver completamente definida, mas a empresa precisa entender que grandes volumes de dados irão ajudá-la a alcançar seus objetivos. Assim, articular esses objetivos irá moldar as estratégias de coleta e análise de dados desde o início. Também nessa etapa, é preciso comunicar a todos os envolvidos a necessidade de empenho na continuidade das ações definidas a partir da tomada de decisões baseada em dados. Esse é um valor do que se chama ‘cultura data-driven’, e que é tão importante quanto ter uma infraestrutura e as ferramentas analíticas necessárias. Ao comprometer-se a utilizar dados na tomada de decisão, a empresa reconhece a eficácia dessa abordagem e precisa fazer isso de forma que gere confiança em todos. É preciso determinar se os seus objetivos requerem utilizar dados reais para análise ou dados experimentais para simulações ou modelagem. Dados reais são os que estão sendo coletados e analisados para tentar descobrir o que já está acontecendo no negócio.



Dados experimentais, por sua vez, são aqueles coletados a partir de um ambiente de experimentação controlado para descobrir quais práticas empresariais funcionam melhor.

Passo 2: A empresa deve se concentrar em poucas áreas de negócio e definir perguntas para determinar quais são as áreas que necessitam de maior atenção. Normalmente, a resposta é relacionada a marketing e vendas, finanças ou operações, ou uma mistura das três. Naquelas áreas nas quais a empresa acredita que terá mais benefícios em termos de crescimento do negócio com a DDDM, deve-se priorizar as de maior impacto. Isso necessita de identificação das questões comerciais específicas que planeja responder, em especial as questões relacionadas com os objetivos empresariais definidos na primeira etapa. Formular esse pensamento sob a forma de hipóteses que possam ser provadas ou refutadas e que possam ser utilizadas como ponto de partida da investigação. Também é preciso identificar as fontes de dados que precisa e quais os dados podem coletar delas. Quando identifica antecipadamente os dados específicos que precisa coletar e como fará isso, a empresa gasta muito menos recursos financeiros e tempo do que se simplesmente coletasse tudo e tentasse descobrir o que fazer com os dados mais tarde. A definição e utilização de KPIs é fundamental para que os dados coletados apoiem factualmente a decisão a ser tomada, justificando-a.

Passo 3: A visualização dos KPIs é relevante para que se possa examinar o andamento dos projetos oriundos das decisões tomadas, e se realmente foram relevantes para a questão comercial abordada. Existem duas grandes categorias de dados, e uma vez que cada uma delas pode auxiliar na tomada de decisões, ambas são normalmente necessárias. Dados qualitativos tem caráter não-numérico e são subjetivos. São observados, em vez de medidos. Dados quantitativos, por sua vez, são numéricos, objetivos e medidos, não apenas observados. Nem todos os dados são adequados para utilização. Os dados devem medir algo significativo, devem ser precisos, formatados corretamente, e não conter duplicações e falhas. Por esses motivos, os métodos de coleta de dados são frequentemente submetidos a um teste em uma área-piloto antes de serem implantados. Se a empresa estiver trabalhando a partir de dados existentes, poderá ter de ‘limpar’ os dados antes de realizar as análises, o que implica verificar informações, corrigir erros e remover redundâncias e outliers. Para se ter qualidade dos dados, algumas perguntas-chave devem ser respondidas pela sua visualização. Quem coletou os dados, e se esses são confiáveis? A confiabilidade exige que se verifique se todos os dados foram coletados utilizando os mesmos parâmetros, e que não contenham respostas falsas. Como foram coletadas as amostras dos dados? Os dados são representativos da realidade? Os dados incluem outliers (medições excepcionalmente altas ou baixas)? Como isso afeta a distribuição global dos dados? As relações causais são verdadeiramente causais ou incidentais? Ou será que os dados das variáveis coletas dão uma impressão imprecisa de causalidade? Quais são as suposições subjacentes aos dados, e se são válidas para a análise? E, o mais crucial, por que se decidiu analisar os dados de uma forma e não de outra? Mesmo que opte por excluir alguns dados, é provável que a empresa descubra que tem várias



fontes de dados internas. Ter múltiplas fontes de dados significa que se pode escolher a melhor opção para coletar dados, com base no que for mais rápido, barato e confiável.

Passo 4: A partir da decisão tomada, é preciso criar planos de ação para implementá-la. Planos de ação mais completos têm sempre um cronograma com todas as atividades necessárias à implementação da decisão, além de um orçamento que aloca os recursos necessários à sua operacionalização.

Passo 5: Criar critérios de análise do andamento dos planos de ação evita o comportamento HiPPO e conduz as análises de monitoramento de volta para o ciclo da DDDM. Isso justifica que sejam alocadas pessoas para a coleta e análise de dados sobre a execução dos planos de ação, e essas pessoas serão as primeiras, e por vezes as únicas, a verificar a veracidade dos dados. O erro mais comum observado na implementação de decisões orientadas por dados é negligenciar a validação dos dados antes de se tirar conclusões. Especialmente em empresas que anteriormente não confiavam muito nos dados para impulsionar a ação podem negligenciar submeter as decisões a um controle de qualidade ou a processo de governança, e é provável serem incorretos em muitos casos.

Passo 6: Analisar os dados disponíveis sob a forma de KPIs permite a descoberta de insights. Mesmo que não se tenha toda a capacidade de fazer essa análise, ainda é fundamental saber que tipo de análises são necessárias (como diagnóstico ou previsão), porque a análise de diferentes tipos de dados exige diferentes competências analíticas. Lidar com dados quantitativos é relativamente simples, mas dados qualitativos, como imagens, vídeos, discursos e textos, exigem diferentes conhecimentos conceituais e aptidões técnicas.

Passo 7: Apresentar os resultados das análises efetuadas e contar histórias significativas a partir delas é também uma parte surpreendentemente difícil da análise de dados. Depois de alguém ter analisado os dados para chegar a conclusões, deve entregar essas conclusões às pessoas certas, no momento certo, e da forma certa, com histórias que façam sentido. Não faltam formas interessantes de apresentar essas histórias baseadas em dados e sua visualização. Mesmo ideias complexas podem ser mais facilmente comunicadas com uma boa apresentação que contenha gráficos ou dashboards. O objetivo disso é ligar os conhecimentos adquiridos a ações que beneficiarão o negócio. É preciso que storytellings com dados retratem claramente tanto as recompensas como os riscos de grandes decisões orientadas por dados.

Passo 8: O loop de conhecimento criado pela DDDM permitirá que o grupo envolvido nela realize momentos de aprendizagem, com lições aprendidas que são decorrentes do ciclo realizado, as quais indicarão necessidades de melhorar a comunicação, atualizar a infraestrutura e a melhoria do processo de governança de dados.

Dessa forma conduzida, a DDDM é a prática de coletar dados, analisá-los e basear as decisões em conhecimentos derivados das informações geradas pelas análises desses dados. Esse processo



contrasta fortemente com a tomada de decisões baseadas no sentimento intuitivo, tradição ou teorias abstratas demais. As decisões orientadas pelos dados são normalmente mais objetivas e podem ser facilmente avaliadas conforme o seu impacto na métrica.

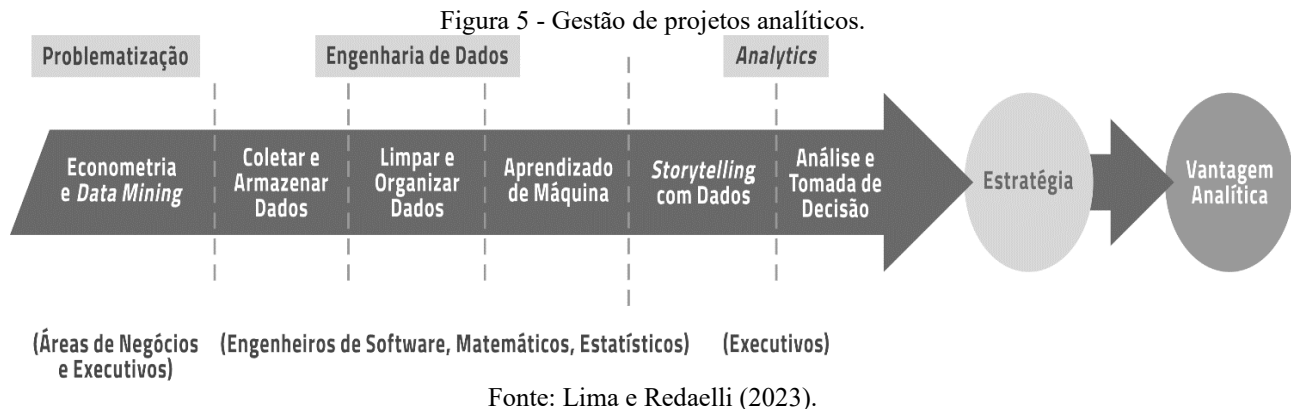
Subjacente à DDDM está a crença de que melhores dados geram melhores decisões, que por sua vez geram melhores resultados. De fato, sem dados, as pessoas correm um risco muito maior de serem influenciadas por vieses ou de agirem com base em falsas suposições. O sucesso da DDDM depende da qualidade dos dados coletados e dos métodos utilizados para a sua análise. A DDDM é fortemente quantitativa, historicamente, sua utilização tem sido limitada devido à necessidade de coleta permanente de dados estatísticos, mas a disseminação de sistemas de informação para analisar grandes conjuntos de dados tornou a DDDM muito mais acessível. Assim, ela não se limita às grandes empresas com vastos recursos computacionais. Empresas de qualquer porte podem utilizar a DDDM para transformar os seus processos, tornando-se mais ágeis pela detecção de novas oportunidades de negócio e respondendo mais rapidamente às mudanças do mercado. Com a coleta de dados em tempo real, os executivos podem medir rapidamente os resultados obtidos e criar um ciclo de feedback ágil. Essas capacidades tornam as empresas orientadas a dados excepcionalmente focadas no cliente e mais competitivas. Também levam a uma maior transparência e responsabilidade, o que pode melhorar o trabalho em equipe e o envolvimento das pessoas.

As políticas da DDDM tornam claro que as inferências e os modismos não estão conduzindo a empresa, e o clima interno melhora porque as pessoas veem que dados objetivos apoiam as decisões de gestão. Nas empresas que dão prioridade à tomada de decisão orientada por dados, os objetivos são concretos e os resultados são medidos. Os membros da equipe gestora sentem frequentemente uma maior sensação de controle porque conseguem ver claramente os resultados que estão sendo alcançados para os objetivos definidos. O teor das interações pode tornar-se mais positivo porque as discussões são baseadas em fatos, em vez de serem conduzidas pelo ego e pela personalidade individuais. A criação de uma cultura orientada a dados requer, assim, um compromisso de longo prazo de educar toda a empresa e de defender esse esforço desde a alta direção. Mesmo assim, é quase certo que a evolução para essa nova forma de fazer negócios leve tempo para se firmar. A evolução para uma cultura orientada pelos dados segue geralmente cinco fases que mostram os patamares de evolução da maturidade analítica: (i) Negação de dados: a empresa começa com uma desconfiança em relação aos dados e não os utiliza; (ii) Indiferença de dados: a empresa não tem interesse que os dados sejam coletados ou utilizados; (iii) Consciência de dados: a empresa coleta dados e os utiliza para monitorar processos, mas não baseia as suas decisões nesses dados; (iv) Dados Informados: os executivos utilizam dados seletivamente para apoiar a tomada de decisões; e (v) Dados Orientados: os dados desempenham um papel central no maior número possível de decisões em toda a empresa.



2.6 GESTÃO DE PROJETOS ANALÍTICOS

Um projeto é um esforço temporário empreendido para criar um produto, serviço ou resultado exclusivo. Um projeto analítico é semelhante a um projeto de desenvolvimento de software: em ambos os casos, o objetivo é ganhar benefícios econômicos ou criar valor para as partes interessadas. A Figura 5 sintetiza a lógica de utilização de Data Science nos negócios e a gestão de projetos analíticos.



Para Singh (2015), uma questão inicial importante a ser considerada na gestão de projetos analíticos diz respeito à característica básica do projeto que se planeja realizar, tendo em vista certas proposições sobre a fase de problematização. Às vezes as empresas têm um problema específico que emerge das análises gerenciais que realiza, mas elas não têm dados suficientes sobre esse problema específico. Nesse caso, recomenda-se que a empresa crie um portfólio de projetos com a realização de atividades de data mining para explorar grandes quantidades de dados, os quais são validados aplicando-se os padrões neles detectados a novos conjuntos de dados. Nesse sentido, data mining é o processo analítico projetado para explorar grandes quantidades de dados para encontrar padrões consistentes e relevantes, ou relações sistemáticas entre variáveis, os quais são validados aplicando os padrões detectados a novos conjuntos de dados, com o trabalho de cientistas de dados. O pressuposto básico da mineração de dados é a argumentação ativa, isto é, em vez do usuário definir o problema, selecionar os dados e escolher as ferramentas para analisar tais dados, as técnicas de data mining pesquisam automaticamente os mesmos à procura de anomalias e possíveis relacionamentos, identificando assim problemas que não tenham sido ainda identificados. Por outro lado, às vezes as empresas não têm um problema específico, mas elas identificam que têm a sua disposição muitos dados disponibilizados por seus sistemas de ERP, e podem então usar técnicas de econometria para testar hipóteses e prever fenômenos econômicos que levem à descoberta de problemas ou à criação de vantagens comparativas significativas. Segundo Gujarati (2019), a Econometria é a parte da Matemática aplicada à Economia para correlacionar dados, sendo frequentemente usada na definição de políticas econômicas. É um conjunto de ferramentas estatísticas usado para entender a relação entre



variáveis econômicas pela aplicação de modelos matemáticos, e geralmente utiliza como modelo econométrico básico a regressão linear.

A fase seguinte do desenvolvimento de um projeto analítico é chamada de Engenharia de Dados, considerada a fase *hard* de projetos de Data Science em negócios. Nessa fase, equipes de cientistas de dados com competências em ciência da computação e engenharia de software, matemática aplicada e estatística, valem-se de mineração de dados para organizar aqueles que serão utilizados por administradores e executivos para visualização, análise, tomada de decisão e proposição de estratégias deliberadas.

Uma das abordagens mais comuns nessa fase é o uso de data mining, que formula hipóteses sobre a qualidade dos dados, as quais devem ser aceitas ou rejeitadas, a partir de avaliação dessas hipóteses, que passa por etapas típicas: (i) avaliação do conjunto de dados necessários; (ii) determinação de critérios de sucesso e métricas de qualidade; (iii) e preparação de dados, modelagem e avaliação de resultados. Na maioria das vezes, o trabalho pode ser cíclico, pois algumas etapas podem ser repetidas várias vezes. Quando se encerra a avaliação das hipóteses, um modelo de dados é criado e colocado em operação. Quando a equipe de cientistas de dados termina essas etapas do processo de Engenharia de Dados, a base de dados gerada, chamada de data lake (lago de dados), um tipo de repositório que armazena conjuntos grandes e variados de dados brutos em formato nativo, é então disponibilizada às consultas pelos administradores e executivos. Com os data lakes, tem-se uma visão não refinada dos dados. Essa estratégia de gerenciamento é cada vez mais usada por empresas que querem um grande repositório holístico para armazenar dados.

A primeira etapa, de coleta e armazenamento de dados, é precedida pela definição, por parte dos envolvidos no problema a ser resolvido, sobre as quais serão os tipos e as categorias de dados e quais serão as fontes dos dados a serem coletados. Então segue-se a busca, seleção, coleta e armazenamento de dados brutos. Diz-se que os dados são brutos porque eles ainda não foram processados para uma finalidade específica. Os dados em um data lake são definidos somente após serem consultados. Os cientistas de dados podem acessar as informações brutas quando necessário por meio de modelagem preditiva ou ferramentas analíticas mais avançadas. Todos os dados são mantidos quando se usa um data lake: nada é removido ou filtrado antes do armazenamento. Os dados podem ser analisados em breve, no futuro ou nunca. Eles também podem ser usados várias vezes para diferentes finalidades, ao contrário de quando os dados são refinados para um fim específico e o seu reaproveitamento é mais difícil. O termo data lake é apropriado para descrever esse tipo de repositório como um lago, porque ele armazena um conjunto de dados em seu estado natural, como água que não foi filtrada. Os dados fluem de diversas fontes para o data lake sendo armazenados no formato original. Em um data lake, os dados são transformados apenas quando são necessários para análises, por meio da aplicação de esquemas de análise comparativa. Esse processo é chamado de “esquema para leitura



por os dados serem mantidos em estado bruto até que estejam prontos para uso. Com os data lakes, os usuários acessam e exploram dados da forma que quiserem, sem precisar movê-los para outro sistema. Geralmente, a geração de insights e a elaboração de relatórios, a partir de um data lake, é ad hoc: os usuários não precisam extrair com frequência relatórios analíticos de outra plataforma ou tipo de repositório; no entanto, podem aplicar um esquema e automatizar a cópia de um relatório, se necessário.

A segunda etapa, de limpeza e organização dos dados, é realizada por matemáticos e estatísticos, que tratam anomalias encontradas, como dados do tipo missing (parcialmente perdidos) ou outliers (fora dos padrões do grupo de dados). Aqui também são necessárias definições, por parte dos envolvidos no problema a ser resolvido, sobre quais serão os tratamentos a serem aplicados a esses tipos de dados. Então segue-se a limpeza e organização para gerar um data lake com dados minerados. Em outras palavras, as ferramentas de data mining analisam os dados, descobrem problemas ou oportunidades escondidas nos relacionamentos desses dados e então diagnosticam o comportamento do negócio, requerendo a mínima intervenção dos usuários, que assim podem se dedicar somente a buscar o conhecimento para gerar maior vantagem competitiva. Acontece, na prática, que quando um data lake com dados minerados é finalmente disponibilizado, passando às vezes por complexas e demoradas etapas de coletar, armazenar, limpar e organizar os dados, eles já estão defasados e desatualizados, uma vez que as bases de dados pesquisadas continuaram a ser alimentadas de dados o tempo todo. Nesse momento entram em ação os algoritmos de machine learning (aprendizado de máquina) para automatizar todo o trabalho conduzido até agora pela equipe de cientistas de dados, melhorando cada vez mais os próprios algoritmos e conferindo celeridade ao processo, de modo que os data lakes a serem utilizados estejam sempre os mais completos, minerados e atualizados possíveis. O aprendizado de máquina é um método de analytics que automatiza a construção de modelos analíticos derivado da inteligência artificial e baseado na ideia de que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. Em resumo, o uso da inteligência artificial é o primeiro passo que analisa os dados e fornece resultados analíticos rapidamente aos usuários. Machine learning baseia-se na aplicação de inteligência artificial em uma segunda etapa, que não apenas analisa dados brutos, mas também procura padrões nos dados que podem gerar mais insights.

A partir do término da fase de Engenharia de Dados, começa a fase de Analytics, que contempla as etapas de elaboração de storytelling com dados e a análise e tomada de decisão empresarial (DYKES, 2023). Começa então a parte soft de Data Science voltada para negócios, com a aplicação dos conceitos, métodos, técnicas e ferramentas de Business Intelligence. Em síntese, Data Science trata da coleta de dados de diversas fontes, decorrentes da mineração de dados, para analisar e subsidiar a tomada de decisões, preditivamente, em grandes quantidades de dados e gerando insights. A utilização



estratégica de Data Science e a interpretação eficaz dos dados pode melhorar a eficiência operacional de uma empresa e o crescimento das receitas de várias maneiras, criando vantagem analítica que leva ao aumento da competitividade.

3 CONCLUSÃO

A partir do mapeamento da literatura acadêmica e comercial especializada sobre modelos de negócio e modelos de gestão baseados em análise de dados para a tomada de decisão estratégica, foi realizada a categorização dos aspectos relevantes para a estruturação de um framework de modelo analítico de gestão.

Utilizando um quadro operacional obtido de modelos de gestão de sucesso na Analytics Economy, foram selecionadas informações que sugerem as ações apropriadas para a execução bem-sucedida de um negócio data-driven: (i) selecionar um modelo de gestão adequado ao atual cenário econômico da Analytics Economy, baseando em dados o modelo de negócio para empresas data-driven; (ii) coletar dados que minimizam o enviesamento de análise; (iii) analisar os dados para reduzir a probabilidade de erro; e (iv) derivar um arcabouço de modelo analítico de gestão específico para empresas data-driven. O framework proposto sugere uma abordagem de gestão empresarial baseada em análise de dados para a tomada de decisão estratégica.

O modelo é composto por fundamentos de gestão inter-relacionados, integrados de forma sistêmica e coerentes com uma filosofia organizacional, sendo formado pelos seguintes componentes: (i) Competição Analítica e Vantagem Analítica; (ii) Posicionamento Estratégico e Foco Analítico; (iii) Liderança Transformadora e Jornada Data-Driven; (iv) Orientação para o Mercado e Análise de Tendências; (v) Domínio de Data Science e Business Analytics; (vi) Tomada de Decisão Baseada em Dados; e (vii) Gestão de Projetos Analíticos.

Nesse sentido, a principal contribuição desta pesquisa é de natureza teórico-gerencial e diz respeito à busca de mais rigor científico no processo de estruturação de um modelo analítico de gestão.

Como sugestões de estudos futuros, sugere-se operacionalizar os componentes do framework do modelo analítico de gestão, possibilitando sua implementação em empresas intensivas em conhecimento para validar sua adequação ao contexto da Competição Analítica.



REFERÊNCIAS

- ABBOSH, O.; NUNES, P.; DOWNES, L. Pivotar para o futuro: Descubra valor e gere crescimento em um mundo disruptivo. Rio de Janeiro: Alta Books, 2021.
- AMIT, R.; ZOTT, C. Business model innovation strategy: Transformational concepts and tools for entrepreneurial leaders. Hoboken: John Wiley & Sons, 2020.
- ASPLEN-TAYLOR, S. Data and analytics strategy for business: Unlock data assets and increase innovation with a results-driven data Strategy. London: Kogan-Page, 2022.
- BERNDTSSON, M. Becoming a data-driven organisation (2018). Disponível em: <Twenty-Sixth European Conference on Information Systems>. Acesso em: 11 set. 2023.
- BOCK, A. J.; GEORGE. G. The business model book: Design, build and adapt business ideas that drive business growth. Harlow: Pearson Education, 2018.
- CAO, L. Data science thinking: The next scientific, technological and economic revolution. Berlin: Springer, 2019.
- CARILLO, K. D. A.; GALY, N.; GUTHRIE, C.; VANHEMS, A. How to turn managers into data-driven decision makers: Measuring attitudes towards business analytics. Business Process Management Journal, v. 25, n. 3, p. 553-578, 2019.
- CECIN, S.; LIMA, J. J. M.; MEIRA, R. C.; REDAELLI, E. J. Framework integrativo de diagnóstico organizacional para projetos de consultoria de gestão da mudança. Revista Desenvolve, v. 11, n. 2, p. 01-21, 2022.
- DAVENPORT, T. H.; HARRIS, J. G. Competição analítica: Vencendo através da nova ciência. Rio de Janeiro: Alta Books, 2018.
- DYKES, B. Dados e storytelling de impacto: Como usar números, imagens e histórias para gerar mudanças efetivas nos negócios. São Paulo: Benvirá, 2023.
- EVANS, V. Business analytics: Methods, models, and decisions. 3rd. ed. Harlow: Pearson, 2019.
- FNQ - FUNDAÇÃO NACIONAL DA QUALIDADE. Modelo de excelência da gestão (MEG): Guia de referência da gestão para a excelência. 21. ed. São Paulo: FNQ, 2017.
- GANDHI, P.; BATHIA, S.; DEV, K. Data driven decision making using analytics. Boca Raton: CRC, 2021.
- GAO, J.; SAEWAR, Z. How do firms create business value and dynamic capabilities by leveraging big data analytics management capability? (2020). Disponível em: <<https://link.springer.com/article/10.1007/s10799-022-00380-w>>. Acesso em: 20 jul. 2023.
- GORDON, M. E. Business analytics: Combining data, analysis and judgement to inform decisions. Thousand Oaks: Sage, 2023.
- GROVER, V.; CHIANG, R. H.; LIANG, T. P.; ZHANG, D. Creating strategic business value from big data analytics: A research framework. Journal of Management Information Systems, v. 35, n. 2, p. 388-423, 2018.
- GUJARATI, D. Econometria: Princípios, teoria e aplicações práticas. São Paulo: Saraiva Educação, 2019.



- KOTOROV, R. Data-driven business models for the digital economy. New York: Business Expert, 2020.
- KRANTZ, J. Data-informed decision making: Bridge the divide between data and business. London: Kogan Page, 2023.
- KUMAR, U. D. Business analytics: The science of data-driven decision making. 2nd. ed. Hoboken: John Wiley & Sons, 2021.
- LIMA, J.; REDAELLI, E. Competição analítica: Um modelo de gestão de negócios para a inovação e a criação de valor para as empresas. 2. ed. Curitiba: Appris, 2023.
- LISINSKI, M. Structural analysis of the management science methodology. Business, Management and Education, v. 11, n. 1, p. 109-136, 2013.
- MAGRETTA, J. O que é a gestão: Como funciona e porque interessa a todos. Lisboa: Actual, 2015.
- MARR, B. Data strategy: How to profit from a world of big data, analytics and artificial intelligence. 2nd. ed. London: Kogan Page, 2021.
- PAGLIUSO, A. T.; CARDOSO, R.; SPIEGEL, T. Gestão organizacional: O desafio da construção do modelo de gestão. São Paulo: Saraiva Uni, 2012.
- PENTLAND, A.; LIPTON, A.; HARDJONO, T. Building the new economy: Data as capital. Boston: MIT, 2021.
- PORTER, M. Vantagem competitiva: Criando e sustentando um desempenho superior. Rio de Janeiro: Campus, 1989.
- PORTER, L. J.; TANNER, S. J. Assessing business excellence. 2nd. ed. London: Routledge, 2015.
- PROVOST, F.; FAWCETT, T. Data science para negócios: O que você precisa saber sobre mineração de dados e pensamento analítico de dados. Rio de Janeiro: Alta books, 2016.
- RAVITCH, S. M.; RIGGAN, M. Reason & rigor: How conceptual frameworks guide research. 2nd. ed. Thousand Oaks: Sage, 2016.
- REDAELLI, E.; LIMA, J. Vantagem analítica: Como mapear tendências e utilizar análise de dados para obter vantagem competitiva nos negócios. Curitiba: Appris, 2023.
- ROTHER, E. T. Revisão sistemática x revisão narrativa. Acta Paulista de Enfermagem, v. 20, n. 2, p. v-vi, 2007.
- SAHAY, A. Business analytics: A data-driven decision-making approach for business. New York: Business Experts, 2018.
- SAULLES, M. The business of data: Commercial opportunities and social challenges in a world fuelled by data. Abingdon; Routledge, 2020.
- SEDDON, P. B.; CONSTANTINIDIS, D.; TAMM, T.; DOD, H. How does business analytics contribute to business value? Info Systems Journal, n. 27, p. 237–269, 2017.
- SEEBACHER, U.; GARRITZ, J. Data-driven management: A primer for modern corporate decision making. Estocolmo: AQPS, 2021.



SHARDA, R.; DELEN, D.; TURBAN, E. Business intelligence e análise de dados para gestão do negócio. 4. ed. Porto Alegre: Bookman, 2019.

SINGH, H. Project management analytics: A data-driven approach to making rational and effective Project decisions. Old Tappan: Pearson FT, 2015.

TANG, C. Data capital: How data is reinventing capital for globalization. Berlin: Springer, 2022.

VIDGEN, R.; SHAW, S.; GRANT, D. B. Management challenges in creating value from business analytics. European Journal of Operational Research, n. 261, p. 626-639, 2017.

YASEEN, S. G. Digital economy, business analytics, and big data analytics applications. Cham: Springer, 2022.