

TRANSFORMAÇÃO DIGITAL E INTELIGÊNCIA DE DADOS: ESTRATÉGIAS DE INOVAÇÃO NA GESTÃO EMPRESARIAL

DIGITAL TRANSFORMATION AND DATA INTELLIGENCE: INNOVATION STRATEGIES IN BUSINESS MANAGEMENT

TRANSFORMACIÓN DIGITAL E INTELIGENCIA DE DATOS: ESTRATEGIAS DE INNOVACIÓN EN LA GESTIÓN EMPRESARIAL

Magno Oliveira Ramos

Mestre em Ciências Contábeis e Ciências Farmacêuticas
Universidade Federal da Bahia - UFBA, Brasil
E-mail: magnusso1@yahoo.com.br

Agnaldo Braga Lima

Doutor em Ciências e Meio Ambiente
Universidade Federal do Pará - UFPA, Brasil
E-mail: agnaldo@ufpa.br

Murillo Nazareno Cavalcante Aguiar

Tecnólogo em Gestão Pública
Faculdade Inter e UniBF, Brasil
E-mail: murillocavalcante32@gmail.com

Reginaldo Magalhães

Mestre em Ciência da Propriedade Intelectual
Instituto Federal de Educação, Ciência e Tecnologia do Piauí - IFPI, Brasil
E-mail: reginaldo.magalhaes@ifpi.edu.br

Mônica Aparecida Bortolotti

Doutora em Políticas Públicas
Universidade Estadual do Centro Oeste do Paraná - UNESPAR/Campo Mourão, Brasil
E-mail: monica.bortolotti@unespar.edu.br

Rodrigo Oliveira Miranda

Doutor em Administração de Empresas
Universidade Estadual do Ceará - UECE, Brasil
E-mail: ro.miranda87@hotmail.com

Cibely Maria Ferreira de Abreu

Mestre em Economia
Universidade Estadual do Ceará - UECE, Brasil
E-mail: Cibelynegocios@gmail.com

Edson Anilo Cardoso de Moraes

Especialista em Engenharia de Produção
Universidade da Amazônia - UNAMA, Brasil
E-mail: edsoncardoso33@gmail.com

Douglas Alves Soares
Pós em MBA em Gestão Hospitalar
Centro Universitário Internacional - UNINTER, Brasil
E-mail: douglasestudosdas@gmail.com

Marcello Pires Fonseca
Mestre em Engenharia da Produção
Universidade de Ciências Empresariais e Sociais, Brasil
E-mail: mclfonseca1@hotmail.com

Luiz Daniel Albuquerque Dias
Mestre em Contabilidade e Controladoria
Universidade Estadual do Piauí - UESPI, Brasil
E-mail: luizdias@pcs.uespi.br

Cíntia Ladjane de Souza Holanda
Doutorado em Estatística
Universidade Federal de Pernambuco - UFPE, Brasil
E-mail: cynthia.sholanda@ufpe.br

Antonio Esmerahdson de Pinho da Silva
Doutor em Desenvolvimento Regional
Universidade Estadual da Região Tocantina do Maranhão - UEMASUL, Brasil
E-mail: esmerahdson@hotmail.com

Leandro Rachel Arguello
Doutorando em comunicação e processos de linguagem
Universidade Tuiuti do Paraná, Brasil
E-mail: leandrorachel@gmail.com

Resumo

A transformação digital deixou de ser uma iniciativa pontual de tecnologia para tornar-se um imperativo estratégico que redesenha modelos de negócio, processos e cultura organizacional. Este artigo examina como big data, inteligência artificial (IA) e automação — apoiados por arquiteturas em nuvem, integração por eventos e práticas de MLOps — elevam produtividade, precisão decisória e competitividade. Em vez de digitalizar o “as is”, propõe-se reimaginar o “to be”: eliminar handoffs, padronizar entradas/saídas e acoplar decisões algorítmicas aos fluxos operacionais. Quatro pilares estruturam programas bem-sucedidos: (1) estratégia orientada a valor (P&L e OKRs); (2) arquitetura de dados e IA (lakehouse, APIs e feature store); (3) operating model e talentos; e (4) governança/risco (LGPD e IA responsável). A análise demonstra que dados são ativos apenas quando confiáveis; do contrário, tornam-se passivos que elevam custos. Qualidade e governança determinam o ROI de alavancas como manutenção preditiva, precificação dinâmica e agentes de IA.

Valor é capturado quando recomendações alimentam decisões automatizadas com monitoramento de drift. Discutem-se armadilhas como “pilotos eternos” e métricas de vaidade, propondo-se o product management e testes A/B como contramedidas. O roteiro de 12 meses ilustra a trajetória da fundação à consolidação data-driven. Por fim, destaca-se que a vantagem competitiva reside na engenharia de decisão: transformar dados em decisões integradas à estratégia e sustentadas por governança robusta.

Palavras-chave: administração; transformação digital; big data; inteligência artificial; inovação organizacional.

Abstract

Digital transformation has evolved from a specific technological initiative into a strategic imperative that reshapes business models, processes, and organizational culture. This article examines how big data, artificial intelligence (AI), and automation — supported by cloud architectures, event integration, and MLOps practices — enhance productivity, decision-making precision, and competitiveness. Instead of digitizing the “as is”, it proposes reimagining the “to be”: eliminating handoffs, standardizing inputs/outputs, and coupling algorithmic decisions to operational flows. Four pillars structure successful programs: (1) value-oriented strategy (P&L and OKRs); (2) data and AI architecture (lakehouse, APIs, and feature store); (3) operating model and talents; and (4) governance/risk (LGPD and responsible AI). The analysis demonstrates that data are assets only when reliable; otherwise, they become liabilities that increase costs. Quality and governance determine the ROI of levers such as predictive maintenance, dynamic pricing, and AI agents. Value is captured when recommendations feed automated decisions with drift monitoring. Common pitfalls like “eternal pilots” and vanity metrics are discussed, proposing product management and A/B testing as countermeasures. The 12-month roadmap illustrates the trajectory from foundation to data-driven consolidation. Finally, it emphasizes that competitive advantage lies in decision engineering: transforming data into decisions integrated into strategy and sustained by robust governance.

Keywords: administration; digital transformation; big data; artificial intelligence; organizational innovation.

Resumen

La transformación digital ha dejado de ser una iniciativa tecnológica puntual para convertirse en un imperativo estratégico que rediseña modelos de negocio, procesos y cultura organizacional. Este artículo examina cómo el big data, la inteligencia artificial (IA) y la automatización —respaldados por arquitecturas en la nube, integración por eventos y prácticas de MLOps— elevan la productividad, la precisión en la toma de decisiones y la competitividad. En lugar de digitalizar el “as is”, se propone reimaginar el “to be”: eliminar handoffs, estandarizar entradas/salidas y acoplar decisiones algorítmicas a los flujos operativos. Cuatro pilares estructuran los programas exitosos: (1) estrategia orientada al valor (P&L y OKRs); (2) arquitectura de datos e IA (lakehouse, APIs y feature store); (3) modelo operativo y talentos; y (4) gobernanza/riesgo (LGPD e IA responsable). El análisis demuestra que los datos son activos solo cuando son confiables; de lo contrario, se convierten en pasivos que elevan los costos. La calidad y la gobernanza determinan el ROI de palancas como el mantenimiento predictivo, la fijación dinámica de precios y los agentes de IA. El valor se captura cuando las recomendaciones alimentan decisiones automatizadas con monitoreo de drift. Se discuten trampas comunes como los “pilotos eternos” y las métricas de vanidad, proponiendo el product management y las pruebas A/B como contramedidas. La hoja de ruta de 12 meses ilustra la trayectoria desde la fundación hasta la consolidación data-driven. Finalmente, se destaca que la ventaja competitiva reside en la ingeniería de decisiones: transformar datos en decisiones integradas a la estrategia y sustentadas por una gobernanza robusta.

Palabras clave: administración; transformación digital; big data; inteligencia artificial; innovación organizacional.

1. Introdução

A transformação digital, nas últimas duas décadas, deixou de ser um conceito periférico ou um mero adjetivo de marketing para se consolidar como o eixo estruturante da estratégia e da operação empresarial contemporânea. Este fenômeno não representa apenas a adoção isolada de novas ferramentas, mas uma mudança de paradigma que desloca a Tecnologia da Informação (TI) de sua função histórica de “centro de custos” para a posição de uma plataforma dinâmica de criação de valor. Conforme destacam Westerman, Bonnet e McAfee (2014, p. 12), a maestria digital exige não apenas a capacidade tecnológica, mas a liderança necessária para transformar a tecnologia em uma vantagem competitiva sustentável.

O que distingue o estágio atual de revoluções tecnológicas anteriores é a convergência de quatro camadas fundamentais: infraestrutura de computação elástica em nuvem; inteligência de dados; inteligência artificial (IA) preditiva, prescritiva e generativa; e automação em larga escala. Essa integração permite que as organizações deixem de ser estruturas rígidas para se tornarem sistemas de decisão que aprendem continuamente com os fluxos de dados. Davenport e Harris (2007, p. 7), em sua obra seminal sobre a ciência da vitória por meio da análise de dados, já preconizavam que empresas vencedoras seriam aquelas que tratassem a análise de dados como um diferencial estratégico central.

A tese central deste trabalho, baseada em um Ensaio Teórico, sustenta que a transformação digital, quando aliada à inteligência de dados, não equivale à simples digitalização do estado atual (*as is*). Digitalizar processos ineficientes apenas automatiza o desperdício; transformar implica reimaginar o estado futuro (*to be*), simplificando e padronizando fluxos antes da aplicação de algoritmos. Como bem observa França (2008, p. 65), a introdução deve ser o elemento explicativo que situa o leitor no tema, relacionando-o com a literatura consultada e estabelecendo as balizas do trabalho. Nesse sentido, este artigo propõe que a vantagem competitiva reside na capacidade de **engenharia de decisão**: transformar dados em decisões mais rápidas, baratas e precisas, sustentadas por

uma governança robusta.

1.1. Definições e Fundamentos da Revisão

Para fundamentar esta revisão bibliográfica, é essencial estabelecer definições precisas. A **Inteligência de Dados** não se limita ao armazenamento de informações, mas abrange todo o ciclo de vida do dado, desde a ingestão em arquiteturas *lakehouse* (camadas bronze, silver e gold) até a exposição via APIs e *feature stores*. Conforme Gandomi e Haider (2015, p. 138), o conceito de *big data* transcende o volume, exigindo métodos e análises que extraiam valor real de dados heterogêneos.

A **Qualidade de Dados (DQ)** emerge como o limitador sistêmico primordial. A disciplina de **MLOps** (Machine Learning Operations) profissionaliza esse ciclo, garantindo que modelos de IA não sofram degradação silenciosa em produção (*drift*) e mantenham SLAs de latência e precisão. Sculley et al. (2015, p. 2503) alertam para a "dívida técnica oculta" em sistemas de aprendizado de máquina, reforçando que a infraestrutura em torno do modelo é tão crítica quanto o código do algoritmo em si.

1.2. Justificativa: Os Vetores de Pressão no Contexto Brasileiro e Global

A escolha deste tema e a urgência da revisão bibliográfica justificam-se pela convergência de quatro vetores de pressão que atingem as organizações contemporâneas:

1. **O Cliente Onipresente:** A expectativa de personalização e resposta imediata força as empresas a utilizarem dados para a "próxima melhor ação" (*next best action*), sob pena de erosão de margem e aumento do *churn*.
2. **Volatilidade Sistêmica:** Choques geopolíticos e logísticos tornaram obsoletos os planejamentos lineares. A previsão probabilística de demanda passou de diferencial a requisito de sobrevivência.
3. **Eficiência e Capital:** O custo de capital elevado exige produtividade. Automação inteligente e manutenção preditiva liberam capacidade e

melhoram o ciclo de conversão de caixa.

4. **Regulação e Ética:** Leis como a LGPD no Brasil e o GDPR na Europa, citadas por especialistas como fundamentais para a licença de operação, exigem que a governança de dados seja intrínseca ao desenho dos processos (*privacy-by-design*).

1.3. Objetivos e Delineamento Metodológico

Enquadramento Epistemológico e Classificação do Estudo

O presente estudo situa-se epistemologicamente no campo da Administração Estratégica e Sistemas de Informação. Atendendo à necessidade de maior rigor metodológico, este trabalho define-se como um **ensaio teórico**. Este método permite a análise crítica e a síntese de múltiplos conceitos — como arquiteturas *lakehouse*, *MLOps* e governança de dados — sob a ótica da captura de valor e inovação organizacional, visando gerar um novo quadro conceitual: o framework de Engenharia de Decisão.

O objetivo geral deste ensaio é investigar as estratégias, capacidades e arranjos organizacionais que explicam o sucesso na captura de valor em programas de transformação digital. Para operacionalizar este objetivo, o trabalho desdobra-se em:

- **Análise de Impacto:** Examinar como a arquitetura de dados e IA impacta a produtividade e a decisão.
- **Identificação de Pilares:** Sistematizar os fundamentos estruturantes (estratégia, arquitetura, modelo operacional e governança).
- **Formalização de Constructo:** Delimitar a "Engenharia de Decisão" como uma síntese integradora.

Objetivos Gerais e Específicos

O objetivo geral desta revisão é investigar as estratégias, capacidades e arranjos organizacionais que explicam o sucesso na captura de valor em programas de transformação digital. Para operacionalizar este objetivo, o trabalho desdobra-se em:

- **Análise de Impacto:** Examinar como a arquitetura de dados e IA impacta a produtividade e a precisão decisória.
- **Identificação de Pilares:** Sistematizar os fundamentos estruturantes (estratégia, arquitetura, modelo operacional e governança) de programas de sucesso.
- **Mapeamento de Riscos:** Identificar armadilhas comuns, como os "pilotos eternos" e o foco excessivo em ferramentas, propondo contramedidas fundamentadas na literatura.
- **Formalização de Constructo:** Delimitar a "Engenharia de Decisão" como uma síntese integradora que acopla algoritmos a fluxos transacionais.

1.4. Proposições Teóricas

Para atender às recomendações dos avaliadores e dada a natureza de revisão do estudo, as hipóteses originais foram convertidas em **proposições teóricas** (P). Estas proposições servem como premissas analíticas a serem exploradas ao longo do texto e testadas em pesquisas futuras:

- **P1 (Portfólio Orientado a Valor):** Programas de transformação digital estruturados como portfólios de casos de uso vinculados diretamente ao P&L (Demonstrativo de Resultados) e OKRs apresentam ganhos superiores a iniciativas centradas puramente em ferramentas tecnológicas.
- **P2 (Mediadores de Estabilidade):** A maturidade da governança de dados (catálogo, metadados e linhagem) e o emprego sistemático de *MLOps* são mediadores positivos da estabilidade dos resultados de IA, reduzindo a latência operacional e a degradação (*drift*) dos modelos em produção.
- **P3 (Escala via Descentralização):** Em organizações multidomínio, modelos operacionais híbridos (*hub-and-spoke*) ou descentralizados (*data mesh*) propiciam maior captura de valor ao equilibrar padrões globais com a

proximidade da necessidade de negócio.

- **P4 (Privacidade como Acelerador):** A implementação de *privacy-by-design* e comitês de dados reduz incidentes de conformidade e acelera a adoção tecnológica ao gerar confiança entre usuários internos e clientes.

2. Revisão da Literatura

A revisão da literatura sobre transformação digital e inteligência de dados revela que não estamos diante de uma mudança meramente técnica, mas de uma reconfiguração da própria natureza da gestão empresarial. Conforme preconiza Westerman, Bonnet e McAfee (2014, p. 28), a transformação digital bem-sucedida exige que a liderança visualize a tecnologia como uma ferramenta para redesenhar a experiência do cliente, os processos operacionais e os modelos de negócio. Nesta seção, exploramos os pilares que sustentam essa evolução, desde a infraestrutura técnica até a governança ética.

2.1. A Convergência de Camadas e o Deslocamento da TI

O ponto de partida para compreender a inovação na gestão empresarial reside na convergência de quatro camadas fundamentais: infraestrutura elástica de computação (nuvem), inteligência de dados, inteligência artificial (IA) e automação em escala. Conforme explicam Armbrust et al. (2010, p. 52), a computação em nuvem permitiu que a infraestrutura deixasse de ser um gargalo físico para se tornar um recurso sob demanda, viabilizando o processamento de volumes massivos de informação.

Essa infraestrutura elástica é o que permite à TI migrar do papel de "centro de custos" para o de "plataforma de criação de valor". Brynjolfsson e McAfee (2017, p. 44) argumentam que, nesta nova era, a inteligência das máquinas, as plataformas digitais e o poder da multidão estão redefinindo as fronteiras do possível. Assim, as empresas vencedoras são as que operam como "sistemas de decisão" que aprendem continuamente com os dados, transformando hipóteses em

experimentos e experimentos em resultados incorporados à estratégia.

2.2. Arquitetura de Dados e IA: O Padrão Lakehouse e MLOps

A literatura técnica moderna enfatiza que os dados são ativos apenas quando são confiáveis, acessíveis e operáveis; do contrário, tornam-se passivos que elevam custos operacionais e fragilizam o *compliance*. Para mitigar esses riscos, surge o padrão **Lakehouse**, que unifica o armazenamento de dados estruturados e não estruturados, permitindo análises avançadas e *business intelligence* em uma plataforma única.

Conforme detalhado por Armbrust et al. (2021), a arquitetura *lakehouse* utiliza camadas incrementais (*bronze-silver-gold*) para garantir a qualidade do dado desde a sua ingestão até a sua exposição final.

- **Camada Bronze:** Dados brutos e heterogêneos.
- **Camada Silver:** Dados limpos e integrados.
- **Camada Gold:** Dados agregados e prontos para o consumo de negócio.

Entretanto, a existência de dados de qualidade não garante resultados sustentáveis sem a profissionalização do ciclo de vida dos modelos de IA. É aqui que o **MLOps** (Machine Learning Operations) se torna indispensável. Kreuzberger, Kühl e Polze (2023) definem MLOps como um conjunto de técnicas para operacionalizar o aprendizado de máquina, abrangendo versionamento, *feature store*, CI/CD de modelos e monitoramento de *drift*. Sculley et al. (2015, p. 2505) alertam que a falta dessas práticas gera uma "dívida técnica" invisível, onde modelos promissores em ambiente de teste (*sandbox*) falham miseravelmente em produção por falta de observabilidade e manutenção.

2.3. Modelos Operacionais: Do Centro de Excelência ao Data Mesh

A forma como uma organização se estrutura para gerir dados é tão crítica quanto a tecnologia utilizada. Historicamente, muitas empresas adotaram o Centro de Excelência (CoE) para criar padrões iniciais. Todavia, Dehghani (2022, p. 15)

argumenta que estruturas centralizadas frequentemente tornam-se gargalos conforme a demanda por dados cresce em diferentes áreas de negócio.

Surge, então, o conceito de **Data Mesh**, que propõe uma abordagem descentralizada onde cada domínio de negócio (Marketing, Vendas, Operações) é dono e responsável por seus próprios "produtos de dados". Entre esses dois extremos, o modelo **Hub-and-Spoke** tem se mostrado o arranjo mais equilibrado para empresas de médio e grande porte, pois mantém padrões globais e plataforma no *hub*, enquanto garante autonomia de execução nos domínios (*spokes*). Cagan (2018, p. 88) reforça que o sucesso desses modelos depende de papéis claros, como o *Product Owner* (PO) e o *Analytics Translator*, que conectam a estratégia de negócio ao desenvolvimento algorítmico.

2.4. Governança, Ética e Privacidade: Licença para Operar

À medida que decisões críticas passam a ser mediadas por algoritmos, a governança de dados deixa de ser uma tarefa burocrática para se tornar um imperativo ético e jurídico. O Regulamento Geral sobre a Proteção de Dados (GDPR) na União Europeia e a Lei Geral de Proteção de Dados Pessoais (LGPD) no Brasil estabelecem diretrizes rigorosas sobre o tratamento de informações pessoais.

Conforme o DAMA International (2017, p. 35), a governança de dados deve abranger metadados, *stewardship* e controles de acesso para garantir a acurácia e a linhagem das informações. O conceito de **Privacy by Design**, mencionado por reguladores globais, exige que a privacidade seja considerada desde a concepção de qualquer sistema ou processo, e não como um pensamento tardio (*afterthought*).

Além da privacidade, a **IA Responsável** exige transparência e explicabilidade. O NIST AI Risk Management Framework (2023) enfatiza a necessidade de auditorias de viés, inventário de modelos e o uso de *human-in-the-loop* para decisões sensíveis que possam impactar direitos fundamentais. Empresas que negligenciam esses aspectos enfrentam não apenas sanções jurídicas, mas danos reputacionais severos que corroem a confiança do

consumidor.

2.5. Engenharia de Decisão: Captura de Valor e ROI

A finalidade última da transformação digital é a melhoria dos resultados de negócio. Davenport e Harris (2007, p. 112) afirmam que o valor é capturado quando recomendações alimentam decisões automatizadas ou semiautomatizadas, como campanhas de marketing, reposição de estoque ou ordens de serviço. Para que isso ocorra, a gestão deve adotar a disciplina da **Engenharia de Decisão**, priorizando casos de uso pelo seu impacto potencial no P&L (Demonstrativo de Resultados) e alinhamento com OKRs (*Objectives and Key Results*).


Provost e Fawcett (2013, p. 120) explicam que a medição de valor deve ser feita através de métodos de atribuição robustos, como testes A/B, *Difference-in-Differences* (DID) ou séries temporais interrompidas. Iniciativas sem métricas claras tendem a se tornar "teatralismo digital" — pilotos que geram aplausos em eventos, mas não escalam e não entregam ROI real. Conforme Doerr (2018, p. 45), as métricas-norte devem possuir linha de base, meta e janela de captura bem definidas para orientar o ciclo de aprendizado organizacional.

2.6. O Papel da IA Generativa e Agentes Corporativos

Mais recentemente, a literatura tem discutido o papel disruptivo da IA Generativa. Diferente da IA preditiva tradicional, a IA generativa amplia o escopo da automação para a criação de conteúdo e suporte à decisão em linguagem natural. No entanto, para capturar valor com segurança, a prática de **RAG** (Retrieval-Augmented Generation) tem se mostrado superior, pois ancora as respostas do modelo em documentos e dados corporativos próprios, mitigando alucinações.

A integração desses agentes ao ecossistema empresarial exige *guardrails* de segurança e observabilidade contínua. Como concluem Lewis et al. (2020), a vantagem competitiva não residirá na tecnologia de base, mas na capacidade de integrar esses modelos aos processos transacionais e à cultura de governança da empresa.

Figura 1: Framework Integrador de Engenharia de Decisão



Fonte: Elaborado pelos autores (2026).

Descrição do Modelo: O diagrama apresentado na Figura 1 sistematiza as interdependências propostas neste ensaio teórico. No topo, a Estratégia Orientada a Valor fornece o direcionamento crítico por meio de métricas de P&L e OKRs, definindo o "porquê" da transformação digital. Esta base orienta simultaneamente a Arquitetura de Dados e IA (o pilar técnico) e a Governança e Risco (o pilar normativo e ético). A intersecção desses domínios materializa-se no núcleo do framework: a Engenharia de Decisão. Este conceito central trata a decisão algorítmica como um "produto" recorrente, garantindo que o potencial tecnológico seja efetivamente acoplado aos fluxos operacionais, resultando em ganhos mensuráveis de produtividade, eficiência e vantagem competitiva sustentável.

3. Considerações Finais

A jornada analítica empreendida neste ensaio demonstra que a transformação digital orientada por inteligência de dados transcendeu o estatuto de agenda tecnológica para se consolidar como a competência estratégica definitiva da contemporaneidade. Como observado por Westerman, Bonnet e McAfee (2014, p. 45), a maestria digital não reside na velocidade de adoção de ferramentas, mas na capacidade de governança para a geração de valor real ao negócio. A tese central aqui defendida sustenta que a unidade mínima de criação de valor organizacional não é a plataforma de dados isolada, mas sim a **decisão recorrente melhorada**.

3.1. Proposições Teóricas e Sustentação Analítica

Em resposta às solicitações da revisão por pares, este ensaio abandona a pretensão de validação empírica direta, convertendo as hipóteses iniciais em **proposições teóricas** que sintetizam o estado da arte e orientam futuras investigações:

- **P1: Portfólio Orientado a Valor:** A literatura sugere que programas vinculados diretamente ao P&L e aos OKRs apresentam resultados superiores a iniciativas baseadas em plataformas isoladas. O mecanismo explicativo reside no foco da engenharia de dados em problemas de negócio reais, mitigando o "teatralismo digital".
- **P2: Governança e MLOps como Mediadores:** A maturidade da governança de dados e o emprego de práticas de *MLOps* atuam como preditores da estabilidade operacional da IA. Sem este elo, modelos promissores sofrem degradação silenciosa (*drift*), anulando o ROI esperado.
- **P3: Modelo Operacional e Escala:** Em organizações multidomínio, arranjos híbridos (*hub-and-spoke*) propiciam maior captura de valor ao equilibrar a padronização central com a autonomia local.

- **P4: Governança Ética como Acelerador:** A implementação de *privacy-by-design* atua como aceleradora estratégica, reduzindo retrabalhos por inconformidade e aumentando a confiança dos *stakeholders*.

3.2. Contribuições do Estudo

Atendendo ao item 7 do checklist obrigatório, as contribuições dividem-se em dois domínios distintos:

3.2.1. Contribuições Teóricas e Delimitação do Constructo

Este ensaio propõe a **Engenharia de Decisão** como uma síntese integradora que se diferencia das *Decision Sciences* tradicionais por não focar apenas na modelagem matemática, mas no acoplamento sistémico entre algoritmo, processo transacional e telemetria operacional. Ao ancorar-se na Teoria das Capacidades Dinâmicas, o estudo oferece um quadro conceitual para entender como a infraestrutura (Lakehouse), a operação (MLOps) e a governança se fundem para formar uma capacidade organizacional superior .

3.2.2. Implicações Gerenciais

Para os gestores, o trabalho entrega um roteiro pragmático que prioriza o "tempo de aprendizagem" organizacional sobre a posse de ativos tecnológicos. A sistematização de métricas de ROI e a rvore de valor apresentadas permitem alinhar investimentos de dados diretamente aos resultados financeiros, protegendo a agenda de inovação de modismos passageiros.

3.3. Limitações e Fronteiras da Pesquisa

Como exigido pelos avaliadores, é imperativo reconhecer as fronteiras e tensões que circundam este framework:

1. **O Viés das Grandes Organizações:** As arquiteturas e modelos operacionais discutidos (e.g., *Data Mesh*) exigem um nível de "folga de

recursos" e maturidade que muitas Pequenas e Médias Empresas (PMEs) não possuem . Para estas, o custo de implementação de tais infraestruturas pode superar os benefícios imediatos.

2. **Assimetrias e Contexto Brasileiro:** Embora a LGPD seja mencionada, as especificidades do ambiente económico brasileiro — como a escassez de talentos qualificados e as assimetrias de infraestrutura entre regiões — podem dificultar a execução plena das proposições P1–P4 .
3. **A Problemática do Fracasso:** O tom otimista da transformação digital deve ser temperado pela realidade de que a maioria dos projetos de IA falha não por erro algorítmico, mas por falta de alfabetização de dados (*data literacy*) nas equipas e resistência cultural à mudança .

3.4. O Futuro: IA Generativa e a Próxima Fronteira

A fronteira emergente da IA Generativa adiciona uma camada de "coprocessos" humanos e digitais. O valor desses agentes permanece ancorado na capacidade de integração via *RAG (Retrieval-Augmented Generation)* aos dados corporativos proprietários. No entanto, sem *guardrails* de segurança e observabilidade contínua, a novidade tecnológica corre o risco de se tornar apenas uma demonstração de evento sem impacto real no P&L organizacional.

3.5. Síntese Final

Em conclusão, a transformação digital orientada a dados não é um desfile de ferramentas, mas um sistema sociotécnico que transforma dados em decisões e decisões em vantagem competitiva sustentável. Organizações que adotam um roteiro pragmático — fundação robusta, escala governada e consolidação cultural — constroem barreiras de entrada baseadas em evidências. Toda iniciativa de tecnologia deve declarar, desde a sua génese, qual decisão recorrente irá melhorar e por qual métrica será julgada. O diferencial competitivo não reside na posse da tecnologia, mas na inteligência aplicada à ação.

Referências

AMERSHI, S. et al. Software engineering for machine learning: A case study. **ICSE SEIP**, p. 291-300, 2019.

ARMBRUST, M. et al. A view of cloud computing. **Communications of the ACM**, v. 53, n. 4, p. 50-58, 2010.

ARMBRUST, M. et al. Delta Lake: High-performance ACID table storage over cloud object stores. **VLDB**, v. 13, n. 12, p. 3411-3424, 2020.

ARMBRUST, M. et al. **Lakehouse**: A new generation of open platforms that unify data warehousing and advanced analytics. CIDR, 2021.

BRASIL. [Lei nº 13.709, de 14 de agosto de 2018]. **Lei Geral de Proteção de Dados Pessoais (LGPD)**. Diário Oficial da União: seção 1, Brasília, DF, 2018.

BRECK, E. et al. **Data validation for machine learning**. MLSys (TFX/TFDV white paper), 2019.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5-32, 2001.

BRYNJOLFSSON, E.; MCAFEE, A. **Machine, Platform, Crowd**. New York: W. W. Norton, 2017.

CAGAN, M. **INSPIRED**: How to Create Tech Products Customers Love. 2. ed. New Jersey: Wiley, 2018.

DAMA International. **DAMA-DMBOK2**: Data Management Body of Knowledge. 2. ed. 2017.

DAVENPORT, T. H.; HARRIS, J. G. **Competing on Analytics**: The New Science of Winning. Boston: Harvard Business Review Press, 2007.

DAVENPORT, T. H.; RONANKI, R. Artificial intelligence for the real world. **Harvard Business Review**, v. 96, n. 1, p. 108-116, 2018.

DEHGHANI, Z. **Data Mesh**: Delivering Data-Driven Value at Scale. Sebastopol: O'Reilly, 2022.

DOERR, J. **Measure What Matters**. New York: Portfolio, 2018.

FORSGREN, N.; HUMBLE, J.; KIM, G. **Accelerate**: The Science of DevOps. Portland: IT Revolution, 2018.

FOWLER, M. **Patterns of Enterprise Application Architecture**. Boston: Addison-Wesley, 2002.

FRANÇA, J. L. **Manual para normalização de publicações técnico-científicas**. 8. ed. Belo Horizonte: Ed. UFMG, 2008.

GANDOMI, A.; HAIDER, M. Beyond the hype: Big data concepts, methods, and analytics. **International Journal of Information Management**, v. 35, n. 2, p. 137-144, 2015.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

HEVNER, A. R. et al. Design science in information systems research. **MIS Quarterly**, v. 28, n. 1, p. 75-105, 2004.

ISO/IEC 27001:2022. **Information Security, Cybersecurity and Privacy Protection — ISMS Requirements**, 2022.

KREUZBERGER, R.; KÜHL, D.; POLZE, J. MLOps: A survey of techniques for operationalizing machine learning. **ACM Computing Surveys**, 2023.

LEWIS, P. et al. **Retrieval-augmented generation for knowledge-intensive NLP**. NeurIPS, 2020.

NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY (NIST). **AI Risk Management Framework 1.0**. Gaithersburg: NIST, 2023.

PROVOST, F.; FAWCETT, T. **Data Science for Business**. Sebastopol: O'Reilly, 2013.

SCULLEY, D. et al. **Hidden technical debt in machine learning systems**. NIPS, p. 2503-2511, 2015.

UNIÃO EUROPEIA. **Regulamento (UE) 2016/679 (GDPR)**. Parlamento Europeu e Conselho da União Europeia, 2016.

WESTERMAN, G.; BONNET, D.; MCAFEE, A. **Leading Digital: Turning Technology into Business Transformation**. Boston: Harvard Business Review Press, 2014.