ANÁLISE DE DADOS, INTELIGÊNCIA ARTIFICIAL E COMPORTAMENTO DO CONSUMIDOR NO E-COMMERCE E NOS MARKETPLACES: DA EVIDÊNCIA ESTATÍSTICA À DECISÃO GERENCIAL

Data Analytics, Artificial Intelligence and Consumer Behavior in E-commerce and Marketplaces: From Statistical Evidence to Managerial Decision-Making

Prof. Dr. Cássio de Jesus Mota – Economista, Mestre e **Doutor** em **Administração** pela Pontifícia Universidade Católica de Minas Gerais – **PUC MG** – MBA em Marketing pela FGV-RJ – Jornalista MTB 23.071/MG

RESUMO

A expansão do comércio eletrônico e dos marketplaces intensificou a produção de registros sobre buscas, transações, experiências e escolhas dos consumidores. A disponibilidade desses dados, entretanto, convive com dificuldades de interpretação, inferência causal e transformação das evidências em decisões economicamente justificáveis. Este artigo examina de que maneira fundamentos estatísticos, práticas de governança, conhecimento contextual do consumidor e técnicas de inteligência artificial podem ser articulados na gestão do varejo digital. Desenvolve-se um ensaio teórico-conceitual integrativo, baseado em literatura clássica de Estatística e Ciência de Dados e em pesquisas recentes sobre plataformas, recomendação e experimentação no comércio eletrônico. Propõe-se uma versão refinada do Modelo Integrado de Inteligência Analítica Orientada ao Consumidor (MIIAC), com seis dimensões articuladas por mecanismos de moderação e mediação. A contribuição central consiste em distinguir a acurácia preditiva do valor incremental da decisão: identificar consumidores com alta propensão à compra não equivale a identificar aqueles cuja decisão pode ser modificada por uma intervenção. Discutem-se ainda implicações para a distribuição de recursos, o relacionamento com clientes, a concorrência entre vendedores e a proteção de dados. O modelo oferece proposições suscetíveis de teste empírico, sem reivindicar validação que ainda não foi realizada.

Palavras-chave: análise de dados; comportamento do consumidor; comércio eletrônico; marketplaces; inferência causal; inteligência artificial; decisão gerencial.

ABSTRACT

The expansion of e-commerce and marketplaces has intensified the production of digital traces of consumer searches, transactions, experiences, and choices. Yet data availability coexists with difficulties in interpretation, causal inference, and translating evidence into economically justified decisions. This conceptual paper examines how statistical foundations, data governance, contextual consumer knowledge, and artificial intelligence can be combined in digital retail management. Drawing on foundational statistics and data science research and recent studies of digital platforms, recommendation systems, and experimentation, it refines the Integrated Consumer-Oriented Analytical Intelligence Model (ICOAIM; MIIAC in Portuguese). Six interdependent dimensions are linked through testable moderation and mediation mechanisms. The central contribution is to distinguish predictive accuracy from incremental decision value: identifying customers who are likely to buy is not equivalent to identifying those whose behavior can be changed by an intervention. Implications are discussed for resource allocation, customer relationships, competition among marketplace sellers, and data protection. The proposed relationships remain theoretical and require empirical validation.

Keywords: data analytics; consumer behavior; e-commerce; marketplaces; causal inference; artificial intelligence; managerial decision-making.

1. INTRODUÇÃO

A compra de um produto em uma plataforma digital pode começar com uma pesquisa no celular, continuar com a comparação de avaliações em diferentes lojas e terminar dias depois, quando o consumidor encontra condições de entrega aceitáveis. Parte desse percurso deixa registros observáveis. Outra parte permanece fora do alcance das bases de dados: a conversa com familiares, a experiência frustrante com uma compra anterior, a limitação do orçamento ou a percepção de risco associada ao vendedor. Essa diferença entre o comportamento registrado e a experiência vivida constitui um problema relevante para organizações que procuram orientar suas decisões por evidências.

O comércio eletrônico oferece condições inéditas para acompanhar jornadas de consumo, mas a multiplicação de cliques, sessões, avaliações e transações também pode produzir uma falsa impressão de conhecimento. Davenport e Harris (2007) associam a competição baseada em análises à combinação entre pessoas, processos e recursos informacionais; Provost e Fawcett (2013) mostram que a utilidade de um projeto de Ciência de Dados depende da formulação do problema empresarial e da avaliação das decisões resultantes. Essas contribuições ganham importância em marketplaces, nos quais o acesso a dados, os mecanismos de ranqueamento e os serviços de análise oferecidos a vendedores também distribuem oportunidades econômicas. Wang, Guo e Liu (2024) examinam os incentivos ligados aos serviços analíticos das plataformas; Liu e Long (2026) discutem a interação entre políticas de acesso a dados e desenho algorítmico.

Ao observar uma queda de conversão, a empresa pode descobrir que o problema se concentra em sessões originadas de anúncios. Isso, por si só, ainda não esclarece se a causa está na promessa publicitária, no preço exibido, no frete, na concorrência ou na composição do público alcançado. Uma previsão bem calibrada do abandono do carrinho tampouco informa necessariamente se um desconto seria capaz de evitar a desistência. A passagem da descrição à intervenção exige cuidados que a rotina gerencial frequentemente comprime em um único indicador.

As pesquisas recentes oferecem elementos para enfrentar esse descompasso. O experimento de von Zahn et al. (2025) sobre devoluções de produtos combina intervenção comportamental e aprendizado de máquina causal. Estudos sobre recomendação e motivações de compra mostram por que a mesma trajetória de navegação pode admitir interpretações distintas (Xu et al., 2026). A análise do tráfego encaminhado por sistemas conversacionais para lojas digitais adiciona outra camada ao problema: a inteligência artificial generativa modifica a descoberta comercial, mas seu desempenho precisa ser comparado empiricamente ao de canais estabelecidos (Kaiser & Schulze, 2026).

Diante desse quadro, pergunta-se: em quais condições a capacidade analítica de uma organização se transforma em decisões comerciais mais eficazes, sem perder de vista o contexto do consumidor e os efeitos sobre o ecossistema de marketplace? O artigo desenvolve três movimentos. Inicialmente, situa os fundamentos estatísticos e computacionais na cadeia decisória do comércio digital. Em seguida, confronta a lógica preditiva com a inferência causal e os conflitos de interesse próprios das plataformas. Por fim, estrutura o Modelo Integrado de Inteligência Analítica Orientada ao Consumidor (MIIAC), especificando mecanismos relacionais passíveis de exame empírico. A contribuição pretendida está na explicação das condições de

conversão da capacidade analítica em valor decisório, e não na proposição de mais uma classificação de ferramentas.

2. PERCURSO METODOLÓGICO E DELIMITAÇÃO TEÓRICA

Este texto é um ensaio teórico-conceitual integrativo, sem coleta de dados primários e sem pretensão de revisão sistemática. A construção da argumentação parte de três conjuntos de literatura previamente delimitados: fundamentos da Estatística e da aprendizagem estatística; métodos de análise e organização de projetos de dados; e pesquisas sobre comportamento do consumidor, plataformas digitais, personalização e inferência causal. A seleção combina obras de referência e estudos recentes pertinentes à pergunta proposta. Não foram executadas buscas exaustivas com protocolo formal de elegibilidade nem avaliação sistemática de risco de viés; por isso, a bibliografia oferece sustentação analítica, sem representar um levantamento completo do campo.

O primeiro conjunto abrange amostragem, inferência, exploração de dados e modelos de aprendizagem (Fisher, 1925; Neyman & Pearson, 1933; Cochran, 1977; James et al., 2021). A organização visual da evidência é discutida à luz de Tufte (2001) e Few (2012), enquanto mineração de padrões e regras de associação são fundamentadas em Agrawal, Imieliński e Swami (1993) e Han, Kamber e Pei (2012). O segundo conjunto considera o CRISP-DM como referência de organização iterativa de projetos (Chapman et al., 2000) e a importância de ambientes programáveis e reprodutíveis de trabalho, tratados por Wickham e Grolemund (2017) e McKinney (2022). O terceiro privilegia trabalhos sobre mercados mediados por plataformas e intervenções mensuráveis, incluindo Wang et al. (2024), Abhishek et al. (2025), von Zahn et al. (2025), Liu e Long (2026), Kaiser e Schulze (2026) e Xu et al. (2026).

A análise procede por comparação conceitual e derivação de proposições teóricas. Em cada etapa, distingue-se o que os estudos empíricos e formais efetivamente demonstram, a interpretação analítica aqui desenvolvida e as relações que permanecem como hipóteses sujeitas a teste. Os fundamentos estatísticos, computacionais e comportamentais são articulados segundo sua função na tomada de decisão empresarial, empregando-se formalizações matemáticas estritamente nos pontos em que conferem precisão operacional aos construtos.

3. DA MATURIDADE ANALÍTICA À QUALIDADE DAS EVIDÊNCIAS

3.1. O problema empresarial antecede o algoritmo

Análises descritivas, diagnósticas, preditivas e prescritivas cumprem funções diferentes e complementares. A primeira informa o comportamento observado; a segunda investiga explicações plausíveis; a terceira estima resultados futuros; e a quarta compara escolhas possíveis diante de objetivos e restrições. Não se trata necessariamente de uma escada única na qual toda organização deva utilizar técnicas mais complexas. Um diagnóstico cuidadoso de custos logísticos pode produzir mais valor que um modelo sofisticado de recomendação se a principal perda financeira estiver concentrada na entrega.

O CRISP-DM ajuda a preservar esse vínculo entre método e problema ao organizar o trabalho em compreensão do negócio, compreensão dos dados, preparação, modelagem, avaliação e implantação (Chapman et al., 2000). Em sua aplicação contemporânea, a implantação inclui documentação, monitoramento de deriva, atribuição de responsabilidades e reavaliação do

objetivo original. Quando os dados sobre vendas, mídia, atendimento e devoluções permanecem em sistemas separados, a organização tende a otimizar indicadores locais. A equipe de mídia pode celebrar cliques mais baratos enquanto a área financeira observa redução da margem. A integração das bases deve ser acompanhada da integração dos critérios de desempenho.

Taxa de conversão, ticket médio, custo de aquisição (CAC), retorno sobre gasto publicitário (ROAS) e valor do relacionamento com o cliente (CLV) ilustram a diferença entre uma medida disponível e um indicador estrategicamente escolhido. Uma campanha pode elevar o ROAS e ainda destruir margem após descontos, comissões, frete e devoluções. Também importa definir os denominadores: a conversão baseada em sessões não é idêntica à baseada em usuários, e o CAC atribuído a novos clientes depende do recorte temporal e das despesas incorporadas ao cálculo.

Para evidenciar a natureza intertemporal da decisão, uma formulação simplificada do valor líquido esperado do cliente é:

(1) $CLV = \Sigma[t = 1,...,T] \{S(t) \times E[M_t \mid \text{ativo em } t] / (1 + r)^t\} - CAC.$

Na Equação (1), S(t) é a probabilidade acumulada de o consumidor permanecer ativo até o período t; $E[M_t \mid \text{ativo em } t]$ é a margem de contribuição esperada condicional à atividade no período, líquida dos custos variáveis relevantes de atendimento e retenção; r é a taxa de desconto e T representa o horizonte de projeção. A distinção entre probabilidade acumulada de sobrevivência e taxa pontual de retenção evita a superestimação do CLV. O modelo também demanda atenção à censura de dados, às coortes e às diferenças entre consumidores novos e recorrentes.

3.2. Estatística descritiva, amostragem e integridade da representação

Bases transacionais frequentemente combinam assimetria, sazonalidade, concentração de receita e observações extremas. Médias isoladas podem ocultar diferenças relevantes entre grupos, de modo que mediana, quartis, intervalo interquartil e medidas de dispersão oferecem uma leitura mais consistente da distribuição. O intervalo interquartil, $IQR = Q_3 - Q_1$, ajuda a examinar heterogeneidade, mas a identificação automática de um valor extremo não autoriza sua exclusão: um grande pedido pode ser uma operação corporativa legítima, uma duplicidade ou um sinal de fraude. O tratamento requer critérios documentados.

A escolha dos gráficos também integra o controle da qualidade analítica. Séries temporais devem evidenciar mudanças de tendência e sazonalidade; histogramas e boxplots permitem inspecionar distribuições; gráficos de dispersão revelam associações e possíveis não linearidades. A integridade das escalas, a legibilidade e a comunicação das incertezas são tão importantes quanto a aparência dos dashboards (Tufte, 2001; Few, 2012). Em relatórios executivos, representar valores absolutos sem a base de comparação pode levar a decisões equivocadas: uma categoria com maior quantidade de reclamações talvez seja simplesmente aquela com maior volume de pedidos.

A amplitude dos registros digitais também não substitui um plano de amostragem. Uma base de usuários que aceitaram rastreamento pode excluir sistematicamente determinados perfis; uma pesquisa enviada apenas a compradores recentes deixa de observar pessoas que desistiram antes da compra. Cochran (1977) mostra por que a inferência depende do desenho de seleção. Amostragens aleatória simples, sistemática, estratificada e por conglomerados são alternativas

com condições próprias de aplicação; amostras de conveniência e respostas espontâneas exigem reconhecimento explícito do viés potencial. A representatividade é sempre definida em relação a uma população-alvo, não pelo tamanho absoluto do arquivo.

3.3. Probabilidade e inferência como disciplina da incerteza

Distribuições binomial, Poisson, normal e t de Student fornecem recursos para fenômenos distintos: sucessos em ensaios sob hipóteses específicas; contagens em intervalos; aproximações para variáveis ou estatísticas com comportamento adequado; e inferência sobre médias em determinadas condições de variância desconhecida. A adequação deve ser examinada empiricamente, sobretudo diante de dependência entre eventos, sobredispersão e caudas longas comuns em registros comerciais. O Teorema Central do Limite não legitima automaticamente qualquer análise com 30 observações: seus resultados dependem das propriedades da amostragem e da distribuição de origem.

O teorema de Bayes formaliza a atualização de crenças condicionais a novas evidências:

(2) $P(A \mid B) = [P(B \mid A) \times P(A)] / P(B)$, para $P(B) > 0$.

No combate a fraudes, por exemplo, um sinal incomum de localização pode alterar a probabilidade estimada de risco, mas seu significado depende da taxa de base de fraudes e da confiabilidade do sinal. Ignorar a raridade do evento tende a produzir alarmes excessivos. O mesmo cuidado vale para testes de hipóteses: o valor-p não informa a probabilidade de a hipótese nula ser verdadeira e não mede o tamanho econômico do efeito. Intervalos de confiança, poder estatístico, custos de erros dos tipos I e II e medidas de efeito devem orientar a interpretação (Fisher, 1925; Neyman & Pearson, 1933).

Em testes A/B, decisões sobre tamanho da amostra, métrica principal e duração precisam ser tomadas antes de examinar os resultados. A interrupção oportunista de um teste quando aparece significância estatística pode ampliar falsos positivos. Da mesma forma, experimentos conduzidos durante campanhas excepcionais podem não representar a demanda habitual. O rigor inferencial, nesse contexto, é uma condição de prudência gerencial.

4. DE PADRÕES COMPORTAMENTAIS A EFEITOS DE INTERVENÇÃO

4.1. Associação, regressão e limite da previsão

A correlação de Pearson resume a direção e a intensidade de relações lineares entre variáveis numéricas. Modelos de regressão ampliam esse exame ao considerar múltiplas covariáveis e estimar associações condicionais. Em uma formulação linear, $Y = \beta_0 + \beta_1 X_1 + ... + \beta_k X_k + \varepsilon$, os coeficientes expressam diferenças esperadas em Y associadas às covariáveis, mantidas constantes as demais variáveis especificadas. Interpretá-los como efeitos causais requer suposições adicionais que um bom ajuste estatístico não garante. Investimento publicitário, promoções e demanda podem ser simultaneamente determinados por acontecimentos sazonais ou decisões empresariais não observadas.

O coeficiente R^2 e sua versão ajustada oferecem informações sobre o ajuste de modelos lineares, mas não bastam para avaliar sua utilidade comercial. Em previsão de demanda, erros absolutos e avaliação fora da amostra podem ser mais relevantes; em classificação de fraude, precisão, sensibilidade, calibração e custos de decisão importam mais que acurácia isolada. Multicolinearidade, vazamento de informação, heterocedasticidade e mudança de distribuição comprometem a interpretação e o uso das estimativas (James et al., 2021).

A mineração de dados amplia a investigação ao identificar segmentos por clusterização, classificar clientes propensos ao abandono e explorar cestas de compras. A regra de associação $A \rightarrow B$ pode ser examinada pelo indicador lift = $P(B \mid A) / P(B)$, desde que $P(B) > 0$. Valores acima de um indicam coocorrência superior à esperada sob independência; não demonstram que a compra de A provoca a compra de B (Agrawal et al., 1993; Han et al., 2012). A interpretação precisa preservar a diferença entre um padrão útil para recomendações e uma explicação causal do consumo.

Ferramentas de programação tornam esses procedimentos reprodutíveis. SQL organiza extração e agregação de registros; Python, com bibliotecas como pandas e scikit-learn, facilita preparação, modelagem e validação; R oferece recursos de estatística e visualização. Os fluxos de trabalho discutidos por McKinney (2022) e Wickham e Grolemund (2017) favorecem documentação, rastreabilidade e replicação. A divisão entre treinamento, validação e teste deve impedir vazamentos, inclusive respeitando a ordem temporal. Após a implantação, mudanças de preços, canais de aquisição e comportamento de busca exigem acompanhamento da deterioração dos modelos.

4.2. Prever quem compra e identificar quem responde

A distinção mais importante para a alocação comercial surge quando a empresa passa da previsão de comportamento para a estimação de efeitos de intervenção. Um cliente com alta propensão de compra pode adquirir o produto independentemente de receber um desconto. Conceder o benefício a esse consumidor reduz a margem sem criar demanda adicional. Em contrapartida, um cliente com propensão intermediária pode responder de maneira significativa a uma informação sobre prazo de entrega ou a uma oferta específica. A questão pertinente é o efeito incremental da ação sobre o resultado, comparado ao cenário em que ela não teria ocorrido.

A experimentação randomizada oferece um caminho robusto para estimar esse efeito médio, desde que a atribuição seja preservada, a intervenção seja bem delimitada e as métricas sejam apropriadas. Métodos de aprendizado de máquina causal podem explorar heterogeneidade de efeitos entre consumidores. No estudo de von Zahn et al. (2025), intervenções informacionais associadas a devoluções foram avaliadas em experimento de campo; os autores relatam redução de 2,6% nas devoluções, sem prejuízo das vendas, e discutem ganhos com a personalização baseada em efeitos heterogêneos. O resultado refere-se ao contexto estudado e não constitui uma taxa transferível para outros varejistas.

A passagem da previsão à prescrição também exige considerar a incerteza das estimativas. Sadana et al. (2025) sistematizam abordagens de otimização contextual; Sim et al. (2025) discutem decisões robustas diante de erros de previsão. Para a gestão de estoques, a política resultante deve levar em conta margens, custos de ruptura, capacidade logística e possíveis mudanças no comportamento de compra. Um modelo de demanda pode apresentar erro médio baixo e, ainda assim, falhar justamente em situações de alto custo operacional. O gestor precisa avaliar a consequência dos erros e não somente sua frequência.

5. MARKETPLACES, INTELIGÊNCIA ARTIFICIAL E EXPERIÊNCIA DO CONSUMIDOR

A aplicação das capacidades analíticas em marketplaces reúne interesses que nem sempre coincidem. A plataforma pode atuar como intermediária, fornecedora de serviços de publicidade e, em alguns modelos, concorrente dos vendedores terceiros. Os dados sobre demanda e a ordem de exposição dos produtos passam a influenciar o desempenho de

diferentes participantes. Wang et al. (2024) exploram os incentivos econômicos associados à oferta de serviços analíticos para vendedores; Liu e Long (2026) mostram a relevância conjunta da política de acesso aos dados e do desenho dos algoritmos. A transparência das métricas, nesse ambiente, também integra a governança competitiva.

A publicidade interna amplia esse desafio. Os anúncios patrocinados disputam atenção com resultados orgânicos e podem modificar a percepção de relevância dos produtos. Abhishek et al. (2025) investigam o papel do retail media mediante experimento de campo, indicando a necessidade de examinar resultados em diferentes categorias e condições informacionais. Uma elevação do faturamento publicitário da plataforma não garante, por si só, maior bem-estar dos consumidores ou melhores resultados líquidos para os vendedores. Custos de aquisição, conversão incremental, diversidade de ofertas e qualidade da experiência devem ser examinados em conjunto.

Os sistemas de recomendação também enfrentam uma dificuldade interpretativa. Um mesmo conjunto de cliques pode resultar de uma compra utilitária planejada, de curiosidade ou de uma busca exploratória. Xu et al. (2026) mostram o potencial de considerar motivações de compra no desenho de recomendações. Modelos baseados em comportamento passado podem reforçar preferências já observadas e reduzir a exposição a alternativas relevantes. Por essa razão, a avaliação deve incluir descoberta útil, satisfação e consequências de longo prazo, além de cliques imediatos.

A inteligência artificial generativa acrescenta uma interface conversacional à descoberta de produtos. Consumidores podem solicitar comparações mais completas e elaborar critérios específicos de escolha, ao passo que as empresas precisam compreender a origem e a qualidade desse tráfego. Kaiser e Schulze (2026) analisam doze meses de dados de 973 sites de comércio eletrônico e comparam transações encaminhadas pelo ChatGPT com canais tradicionais. O estudo é importante precisamente porque permite observar diferenças de desempenho sem pressupor superioridade generalizada dos novos sistemas. Há oportunidades comerciais, mas a atribuição continua desafiadora quando a jornada passa por diferentes dispositivos, buscas e recomendações.

No contexto brasileiro, a proteção de dados pessoais constitui uma condição institucional de qualquer estratégia baseada em rastros digitais. A Lei nº 13.709/2018 estabelece princípios como finalidade, adequação, necessidade, transparência e segurança no tratamento de dados (Brasil, 2018). A escolha da base legal adequada, a documentação de operações de perfilamento e a observância dos direitos relacionados a decisões automatizadas requerem análise jurídica específica. Explicabilidade, auditoria de vieses e revisão de práticas de segmentação podem fortalecer a legitimidade dos sistemas. A dependência de modelos de linguagem adiciona cuidados com alucinações, exposição indevida de informações e respostas que não refletem as condições comerciais vigentes.

Por trás dessas exigências está uma questão substantiva: o consumidor não é uma coleção de eventos de navegação. Uma compra interrompida pode decorrer de dificuldade financeira, acessibilidade inadequada, ausência de meios de pagamento ou receio de não receber o produto. O dado descreve a interrupção; sua compreensão exige interpretar o contexto. Quando as organizações reconhecem essa diferença, abre-se espaço para intervenções comercialmente eficientes e experiências mais respeitosas.

6. MODELO INTEGRADO DE INTELIGÊNCIA ANALÍTICA ORIENTADA AO CONSUMIDOR: MECANISMOS E PROPOSIÇÕES

O MIIAC preserva seis dimensões da formulação original: (1) qualidade e governança dos dados; (2) compreensão contextual do consumidor; (3) capacidade estatística e computacional; (4) inteligência preditiva e causal; (5) decisão gerencial e implementação; e (6) avaliação multidimensional dos resultados. A revisão desloca a ênfase da enumeração dessas dimensões para as relações que podem conectá-las. A qualidade analítica é tratada como capacidade organizacional condicionada por dados e contexto; a implementação aparece como mecanismo de tradução das evidências; os resultados incluem consequências financeiras e relacionais.

Proposição 1 — Moderação pela governança. A associação entre sofisticação estatística e qualidade das decisões comerciais será mais forte em organizações com maior maturidade de governança e qualidade dos dados. Quando os registros são fragmentados, seletivos ou inconsistentes, a complexidade algorítmica tende a oferecer retornos menores e pode ampliar erros de alocação. Essa hipótese pode ser examinada por medidas de integridade das bases, maturidade de governança, desempenho fora da amostra e perdas decorrentes das decisões.

Proposição 2 — Moderação pelo conhecimento contextual. O efeito da identificação de padrões comportamentais sobre a eficácia de intervenções comerciais será mais positivo quando a organização dispõe de conhecimento consistente sobre motivações e restrições dos consumidores. A hipótese implica que segmentos definidos somente por cliques podem receber incentivos menos adequados do que segmentos interpretados com apoio de pesquisas de experiência, feedback e atributos contextuais. O mecanismo pode ser testado comparando tratamentos e grupos em experimentos de campo.

Proposição 3 — Superioridade contingente do valor incremental. Em decisões promocionais com custos materiais de incentivo, políticas orientadas por efeitos incrementais estimados alcançarão maior margem líquida esperada que políticas baseadas exclusivamente em escores de propensão, desde que os efeitos sejam estimados com qualidade suficiente. A expressão “desde que” é central: em amostras pequenas ou sob forte instabilidade, o erro na estimação de efeitos heterogêneos pode eliminar a vantagem da política causal. Essa proposição admite refutação mediante experimentos comparativos com resultados econômicos pré-definidos.

Proposição 4 — Mediação pela capacidade de implementação. A relação entre capacidade analítica e desempenho comercial será mediada pela incorporação das evidências em rotinas decisórias estáveis, com responsabilidades, monitoramento e critérios de revisão. Empresas com modelos semelhantes poderão alcançar resultados distintos conforme sua aptidão para executar recomendações, resolver conflitos entre áreas e considerar os efeitos sobre satisfação, confiança e retenção.

A operacionalização empírica do MIIAC exige definir claramente unidades de análise. Em pesquisas com vendedores, a unidade pode ser a empresa; em testes de personalização, o consumidor ou a sessão; em estudos de governança, a plataforma. A mensuração da maturidade analítica pode combinar evidências documentais, auditorias de processos e indicadores de uso efetivo. Resultados de curto prazo, como margem incremental, devem ser acompanhados de resultados de longo prazo, como recompra e reclamações. Modelos multinível e experimentos em diferentes empresas poderiam examinar efeitos cruzados entre governança, contexto e implementação.

O modelo também oferece uma aplicação gerencial plausível. Considere um varejista que observa aumento de receita e queda de rentabilidade. A análise inicial separa comissões, frete, despesas promocionais e devoluções por canal. Técnicas de exploração identificam assimetrias entre categorias; modelos supervisionados estimam riscos de devolução; entrevistas e

pesquisas apontam dúvidas recorrentes sobre características dos produtos. A empresa testa diferentes conteúdos de orientação, mantendo grupo de controle e monitorando margem por pedido, devoluções e satisfação. A decisão de expandir a intervenção depende do efeito incremental estimado e de seus custos. Esse exemplo é hipotético e ilustra o mecanismo proposto, não um resultado empírico deste artigo.

7. DISCUSSÃO, LIMITAÇÕES E CONSIDERAÇÕES FINAIS

A literatura examinada indica que a sofisticação técnica é uma condição insuficiente para explicar o valor produzido pela análise de dados. A decisão ocorre em organizações com objetivos múltiplos, informações incompletas e incentivos que podem divergir entre áreas e participantes da plataforma. O MIIAC oferece uma maneira de investigar por que modelos semelhantes produzem resultados diferentes em empresas distintas. Seu foco está nas condições de tradução da evidência para a ação, especialmente na qualidade dos registros, na interpretação contextual, na capacidade de identificação causal e nas rotinas de implantação.

Essa abordagem também redefine o papel dos indicadores. O alcance de uma campanha tem significado limitado se não for possível avaliar a conversão incremental; o crescimento da receita exige exame da margem; a retenção precisa ser relacionada aos custos e à experiência efetiva do consumidor. Ao mesmo tempo, a exigência de mensuração não elimina a necessidade de julgamento. Gestores precisam decidir quando um resultado estatístico é suficientemente robusto para orientar um investimento, quando a intervenção pode produzir efeitos indesejados e quais informações devem permanecer protegidas.

A presente análise possui limites explícitos. Trata-se de ensaio conceitual, sem amostra própria, levantamento bibliográfico exaustivo ou validação quantitativa das proposições. As pesquisas citadas contemplam contextos específicos de plataformas e varejistas; seus resultados não devem ser extrapolados automaticamente para empresas brasileiras, pequenas operações ou segmentos de consumo com características distintas. A literatura em inteligência artificial também evolui rapidamente, exigindo atualização periódica da revisão.

Estudos futuros podem comparar empresas com diferentes estruturas de governança e maturidade analítica, estimar a mediação da implementação gerencial e realizar experimentos que confrontem políticas de propensão e políticas de efeito incremental. Pesquisas qualitativas, por sua vez, podem investigar experiências de consumidores pouco captadas por dados de navegação, sobretudo em situações de vulnerabilidade, limitações de acesso e baixa confiança em transações digitais. Uma agenda particularmente relevante seria combinar evidências comportamentais, relatos de consumidores e indicadores econômicos ao longo do tempo.

Em ambientes nos quais algoritmos influenciam a descoberta de produtos, a formação de preços e a exposição publicitária, os rastros digitais continuam sendo registros parciais de experiências humanas. Um clique, um carrinho abandonado ou uma recompra pode esconder circunstâncias distintas e decisões tomadas fora da plataforma. A maturidade analítica adquire sentido quando o rigor estatístico, a capacidade computacional e o conhecimento do consumidor ajudam a formular intervenções avaliáveis, transparentes e economicamente sustentáveis. O desafio da gestão permanece profundamente humano: compreender o problema antes de escolher a técnica e responder pelas consequências das decisões tomadas.

REFERÊNCIAS

Abhishek, V., Jerath, K., & Sharma, S. (2025). The impact of “retail media” on online marketplaces: Insights from a field experiment. *Information Systems Research, 36*(1), 456–473. https://doi.org/10.1287/isre.2022.0188

Agrawal, R., Imieliński, T., & Swami, A. (1993). Mining association rules between sets of items in large databases. In *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data* (pp. 207–216). ACM. https://doi.org/10.1145/170035.170072

Brasil. (2018). *Lei nº 13.709, de 14 de agosto de 2018 (Lei Geral de Proteção de Dados Pessoais).* Presidência da República.

Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide.* CRISP-DM Consortium.

Cochran, W. G. (1977). *Sampling techniques* (3rd ed.). Wiley.

Davenport, T. H., & Harris, J. G. (2007). *Competing on analytics: The new science of winning.* Harvard Business School Press.

Few, S. (2012). *Show me the numbers: Designing tables and graphs to enlighten* (2nd ed.). Analytics Press.

Fisher, R. A. (1925). *Statistical methods for research workers.* Oliver and Boyd.

Han, J., Kamber, M., & Pei, J. (2012). *Data mining: Concepts and techniques* (3rd ed.). Morgan Kaufmann.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: With applications in R* (2nd ed.). Springer. https://doi.org/10.1007/978-1-0716-1418-1

Kaiser, M., & Schulze, C. (2026). Frontiers: ChatGPT referrals to e-commerce websites: How do LLMs compare against traditional channels? *Marketing Science, 45*(4), 699–715. https://doi.org/10.1287/mksc.2025.0489

Liu, Y., & Long, F. (2026). Data and algorithms: Strategic disclosure of competitiveness on platforms through marketplace analytics. *Marketing Science, 45*(3), 653–674. https://doi.org/10.1287/mksc.2024.0960

McKinney, W. (2022). *Python for data analysis: Data wrangling with pandas, NumPy, and Jupyter* (3rd ed.). O’Reilly Media.

Neyman, J., & Pearson, E. S. (1933). On the problem of the most efficient tests of statistical hypotheses. *Philosophical Transactions of the Royal Society of London. Series A, 231*, 289–337. https://doi.org/10.1098/rsta.1933.0009

Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking.* O’Reilly Media.

Sadana, U., Chenreddy, A., Delage, E., Forel, A., Frejinger, E., & Vidal, T. (2025). A survey of contextual optimization methods for decision-making under uncertainty. *European Journal of Operational Research, 320*(2), 271–289.

Sim, M., Tang, Q., Zhou, M., & Zhu, T. (2025). The analytics of robust satisficing: Predict, optimize, satisfice, then fortify. *Operations Research, 73*(5), 2708–2728.

Tufte, E. R. (2001). *The visual display of quantitative information* (2nd ed.). Graphics Press.

von Zahn, M., Bauer, K., Mihale-Wilson, C., Jagow, J., Speicher, M., & Hinz, O. (2025). Smart green nudging: Reducing product returns through digital footprints and causal machine learning. *Marketing Science, 44*(4), 954–969. https://doi.org/10.1287/mksc.2022.0393

Wang, Z., Guo, H., & Liu, D. (2024). Economics of analytics services on a marketplace platform. *MIS Quarterly, 48*(2), 775–824. https://doi.org/10.25300/MISQ/2023/16452

Wickham, H., & Grolemund, G. (2017). *R for data science: Import, tidy, transform, visualize, and model data.* O'Reilly Media.

Xu, J., Wang, J., Zhang, H., & Lu, T. (2026). A user purchase motivation-aware product recommender system. *Information Systems Research, 37*(3), 1740–1759. https://doi.org/10.1287/isre.2024.1028