ÁREA TEMÁTICA: Tecnologia, Inteligência Artificial e Transformação Digital em Administração

DESIGN SCIENCE E IA GENERATIVA NO VAREJO *OMNICHANNEL*

Categoria: ENANGRAD Pleno

Modalidade: Ensaio teórico

Resumo

Este ensaio teórico discute como a *Design Science Research* pode orientar o desenvolvimento de artefatos de Inteligência Artificial Generativa aplicados à personalização da estratégia *Omnichannel* no varejo. O estudo parte do problema de que pequenas e médias empresas varejistas enfrentam restrições de dados, tecnologia e competências analíticas para integrar canais físicos e digitais, interpretar a jornada do cliente e priorizar ações gerenciais. A pesquisa adota abordagem qualitativa, de natureza teórico-conceitual, fundamentada em revisão narrativa da literatura sobre *Omnichannel*, experiência do cliente, modelos de linguagem, IA Generativa e Design Science Research. Como resultado teórico, propõe-se um modelo composto por seis movimentos: explicitação do problema gerencial, delimitação das capacidades *Omnichannel*, tradução do conhecimento em regras de design, configuração contextual do artefato, avaliação sociotécnica e refinamento orientado por aprendizagem. Conclui-se que a IA Generativa produz maior valor quando tratada como artefato sociotécnico, avaliável e governado, e não como ferramenta autônoma. O artigo contribui ao articular rigor teórico, utilidade prática, explicabilidade e validação humana no desenvolvimento de soluções generativas para o varejo.

Palavras-chave: *Design Science Research*. Inteligência Artificial Generativa. Artefato. *Omnichannel*. Varejo.

Abstract

This theoretical essay discusses how *Design Science Research* can guide the development of Generative Artificial Intelligence artifacts applied to *Omnichannel* strategy personalization in retail. The study addresses the problem that small and medium-sized retailers face constraints regarding data, technology, and analytical capabilities to integrate physical and digital channels, interpret the customer journey, and prioritize managerial actions. The research adopts a qualitative, theoretical-conceptual approach based on a narrative review of the literature on *Omnichannel* retailing, customer experience, language models, Generative AI, and Design Science Research. As a theoretical result, the article proposes a model composed of six movements: problem explication, delimitation of *Omnichannel* capabilities, translation of knowledge into design rules, contextual configuration of the artifact, sociotechnical evaluation, and learning-oriented refinement. The study concludes that Generative AI creates greater value when treated as a sociotechnical, evaluable, and governed artifact rather than as an autonomous tool. The article contributes by articulating theoretical rigor, practical utility, explainability, and human validation in the development of generative solutions for retail.

Keywords: Design Science Research. Generative Artificial Intelligence. Artifact. *Omnichannel*. Retail.

1. Introdução

A transformação digital modificou a forma como empresas varejistas estruturam canais, relacionamentos e processos de atendimento ao consumidor. O avanço do comércio eletrônico, das redes sociais, dos aplicativos móveis e dos sistemas automatizados de atendimento ampliou a exigência por jornadas integradas, nas quais o cliente transita entre canais físicos e digitais sem perceber rupturas operacionais, informacionais ou comunicacionais (Lemon & Verhoef, 2016; Verhoef *et al.*, 2015). Nesse ambiente, a estratégia *Omnichannel* deixou de representar apenas presença em múltiplos canais e passou a exigir integração sistêmica, coordenação de dados, consistência de experiência e capacidade de personalização.

A literatura diferencia multicanalidade, *cross-channel* e *Omnichannel* para indicar graus distintos de integração entre canais. Na multicanalidade, os canais coexistem, mas podem operar de modo isolado; no cross-channel, há algum nível de articulação; no *Omnichannel*, a experiência é concebida como uma jornada integrada, contínua e orientada pelo cliente (Beck & Rygl, 2015; Verhoef *et al.*, 2015). Essa mudança aumenta a complexidade gerencial, pois exige que dados de consumo, estoques, atendimento, campanhas, logística e precificação sejam interpretados de forma coordenada.

A Inteligência Artificial passou a ocupar posição relevante nesse debate ao permitir análise de dados, automação de interações, previsão de comportamentos e personalização em escala (Davenport *et al.*, 2020; Huang & Rust, 2021). Com os modelos de linguagem de grande escala e a IA Generativa, essa discussão torna-se mais ampla, pois sistemas baseados em linguagem natural podem apoiar diagnósticos, recomendações, sínteses e orientações gerenciais ajustadas ao contexto de cada empresa (Bommasani *et al.*, 2021; Brown *et al.*, 2020). No varejo, essa capacidade abre possibilidades para apoiar gestores na interpretação da maturidade *Omnichannel* e na priorização de ações.

Entretanto, a adoção de IA no varejo não pode ser reduzida à escolha de uma ferramenta tecnológica. A geração de respostas plausíveis por modelos generativos não assegura, por si só, validade gerencial, adequação ao contexto, controle de viés, rastreabilidade das recomendações ou alinhamento estratégico. Esse ponto é sensível em pequenas e médias empresas varejistas, que frequentemente enfrentam limitações de infraestrutura, bases de dados pouco estruturadas e menor disponibilidade de equipes especializadas. Assim, o problema de pesquisa que orienta este ensaio pode ser formulado da seguinte forma: como a *Design Science Research* pode orientar o desenvolvimento de artefatos de IA Generativa úteis, avaliáveis, transparentes e coerentes com problemas reais de personalização *Omnichannel* no varejo?

Este artigo tem como objetivo discutir como a *Design Science Research* pode orientar o desenvolvimento de artefatos de Inteligência Artificial Generativa destinados à personalização da estratégia *Omnichannel* no varejo. A investigação limita-se ao plano teórico-conceitual, sem coleta empírica primária, articulando literatura sobre DSR, *Omnichannel*, experiência do cliente, transformação digital, IA Generativa, explicabilidade e governança. Este artigo está organizado da seguinte forma: após esta introdução, a segunda seção apresenta a fundamentação teórica; a terceira descreve a metodologia; a quarta desenvolve a análise e discussão dos resultados teóricos; e a quinta seção apresenta as conclusões, contribuições, limitações e sugestões para pesquisas futuras.

2. Fundamentação Teórica

2.1 Estratégia *Omnichannel* e Personalização da Experiência Do Cliente

A estratégia *Omnichannel* está associada à integração de canais e pontos de contato em uma jornada de consumo fluida, consistente e centrada no cliente (Verhoef *et al.*, 2015). Diferentemente da presença simultânea em múltiplos canais, sua lógica depende da coordenação entre sistemas, processos e práticas comerciais. A experiência do cliente passa a ser moldada por interações que ocorrem antes, durante e após a compra, envolvendo busca de informações, comparação de alternativas, aquisição, entrega, atendimento, devolução e relacionamento pós-venda (Lemon & Verhoef, 2016).

A literatura sobre experiência do cliente indica que a jornada não é linear, pois consumidores podem iniciar a busca em redes sociais, consultar avaliações online, visitar lojas físicas, concluir a compra por aplicativo e solicitar suporte por canais digitais. Essa mobilidade impõe às empresas a necessidade de manter coerência de informações, preços, disponibilidade, histórico de atendimento e comunicação (Lemon & Verhoef, 2016; Piotrowicz & Cuthbertson, 2014). Assim, a personalização *Omnichannel* depende de uma arquitetura gerencial capaz de reconhecer o cliente ao longo dos canais e adaptar ofertas, mensagens e serviços às suas necessidades.

A personalização, nesse contexto, não deve ser compreendida apenas como recomendação automatizada de produtos. Ela envolve a adaptação da estratégia de canais ao contexto da empresa, ao perfil do cliente, às capacidades operacionais e à maturidade digital disponível. Em empresas de menor porte, essa adaptação é ainda mais relevante, pois a adoção de soluções tecnológicas amplas tende a ser limitada por orçamento, dados incompletos e rotinas pouco formalizadas. Por isso, modelos que orientem diagnósticos e recomendações devem considerar capacidades organizacionais, e não apenas funcionalidades digitais isoladas.

A avaliação da estratégia *Omnichannel* pode ser organizada em dimensões como experiência online, loja física, fulfillment, site ou aplicativo móvel, integração de marketing e precificação, atendimento e mídias sociais. Essas dimensões permitem compreender que o *Omnichannel* não se limita à venda, mas envolve comunicação, operação, logística, dados e relacionamento. Nesse ponto, artefatos de IA Generativa podem apoiar gestores ao interpretar informações dispersas e transformá-las em recomendações ordenadas por prioridade, viabilidade e impacto esperado.

2.2 Inteligência Artificial Generativa e Modelos de Linguagem

A Inteligência Artificial pode ser compreendida como o campo dedicado ao desenvolvimento de sistemas capazes de perceber, aprender, raciocinar e agir diante de dados e objetivos definidos (Russell & Norvig, 2020). Nas últimas décadas, o avanço do aprendizado de máquina e do aprendizado profundo ampliou a capacidade de reconhecimento de padrões, previsão e automação. A partir da arquitetura transformer, proposta por Vaswani *et al.* (2017), os modelos de linguagem passaram a operar com atenção contextualizada em larga escala, favorecendo avanços em compreensão e geração de linguagem natural.

Os modelos de linguagem de grande escala são treinados em amplas bases textuais e capazes de gerar respostas coerentes a partir de prompts e contextos fornecidos pelo usuário (Bommasani *et al.*, 2021; Brown *et al.*, 2020). No uso organizacional, tais modelos podem apoiar redação, síntese, classificação, atendimento, ideação, análise qualitativa e suporte à decisão. Contudo, sua capacidade generativa deve ser tratada com cautela, pois fluência linguística não

equivale, necessariamente, à veracidade, adequação normativa ou qualidade decisória (Bender *et al.*, 2021).

No varejo, a IA Generativa pode ser utilizada para interpretar diagnósticos de canais, elaborar recomendações de marketing, simular jornadas, apoiar a criação de conteúdos, estruturar planos de ação e orientar a priorização de melhorias. Ainda assim, a utilidade do artefato depende de sua configuração contextual. Um modelo genérico pode produzir respostas amplas, mas não necessariamente ajustadas às capacidades, restrições e objetivos de uma empresa específica. A configuração de instruções, bases de conhecimento, parâmetros de análise e critérios de validação torna-se, portanto, componente do próprio artefato.

Essa compreensão desloca a discussão da IA Generativa do campo da adoção instrumental para o campo do projeto sociotécnico. O artefato não é apenas o modelo de linguagem, mas o conjunto formado por problema, base conceitual, regras de design, prompts, dados de entrada, fluxo decisório, critérios de explicação e mecanismos de avaliação. Essa perspectiva aproxima a IA Generativa da Design Science Research, uma vez que a tecnologia passa a ser desenvolvida como resposta projetada para uma classe de problemas organizacionais.

2.3 *Design Science Research* e Desenvolvimento de Artefatos

A *Design Science Research* tem origem na compreensão de que determinadas pesquisas em Administração e Sistemas de Informação buscam não apenas explicar fenômenos, mas criar artefatos capazes de intervir em problemas relevantes (March & Smith, 1995; Simon, 1996). Na abordagem de Hevner *et al.* (2004), a pesquisa em ciência do design deve equilibrar rigor e relevância, articulando conhecimento científico acumulado e necessidades do ambiente organizacional. Peffers *et al.* (2007) sistematizam essa lógica em uma metodologia que envolve identificação do problema, definição de objetivos, design e desenvolvimento, demonstração, avaliação e comunicação.

Gregor e Hevner (2013) avançam nessa discussão ao enfatizar que artefatos podem gerar contribuição científica quando incorporam conhecimento de design, permitem avaliação e oferecem prescrições úteis para uma classe de problemas. Dessa forma, a DSR não se restringe à criação de soluções técnicas. Seu valor reside na produção de conhecimento sobre como e por que determinado artefato pode funcionar em determinado contexto.

Quando aplicada à IA Generativa, a DSR ajuda a evitar dois riscos recorrentes. O primeiro é o tecnocentrismo, no qual a solução é definida pela novidade tecnológica e não pelo problema gerencial. O segundo é a ausência de avaliação, quando a utilidade do artefato é presumida em razão da sofisticação do modelo. A DSR exige que a solução seja construída a partir de uma lacuna real, explicite objetivos de desempenho, seja demonstrada em contexto de uso e passe por avaliação quanto à utilidade, qualidade e adequação (Hevner *et al.*, 2004; Peffers *et al.*, 2007).

No desenvolvimento de artefatos generativos, essa lógica orienta a passagem entre três níveis. O primeiro é o nível conceitual, no qual se definem construtos, dimensões e relações teóricas. O segundo é o nível operacional, no qual esses elementos são traduzidos em instruções, formulários, bases de conhecimento, árvores de decisão e parâmetros de resposta. O terceiro é o nível avaliativo, no qual se verificam coerência, aderência ao contexto, clareza das recomendações, transparência e potencial de implementação.

2.4 Governança, Explicabilidade e Validação Humana

O desenvolvimento de artefatos de IA Generativa para o varejo exige atenção à governança, à explicabilidade e à validação humana. Sistemas generativos podem produzir recomendações sobre comunicação, atendimento, precificação, segmentação, integração de canais e uso de dados de clientes. Tais recomendações podem afetar decisões comerciais e relações de consumo, razão pela qual não devem ser tratadas como decisões autônomas ou neutras.

A explicabilidade atua como mecanismo de controle e confiança. Em modelos generativos, respostas textuais podem parecer coerentes mesmo quando apresentam fragilidades, vieses ou inadequações ao contexto. A literatura sobre *Explainable* AI destaca que transparência, interpretabilidade e auditabilidade favorecem a confiança em sistemas inteligentes (Arrieta *et al.*, 2020; Ribeiro *et al.*, 2016). No varejo, essa explicabilidade permite que recomendações sejam analisadas à luz de restrições operacionais, capacidades internas e expectativas dos consumidores.

A supervisão humana é indispensável porque a IA não possui responsabilidade moral, julgamento ético nem conhecimento tácito pleno sobre a organização. Modelos generativos podem organizar informações e sugerir ações, mas não compreendem integralmente cultura empresarial, relações locais, restrições financeiras e impactos sociais das decisões. Bender *et al.* (2021) alertam que a fluência linguística dos modelos de linguagem não deve ser confundida com compreensão factual ou julgamento normativo. Assim, decisões sobre preços, dados pessoais, automação de atendimento e segmentação devem permanecer sob responsabilidade gerencial.

No contexto de pequenas e médias empresas varejistas, recomenda-se uma governança incremental, iniciando por regras simples de uso, revisão das recomendações, registro das decisões e acompanhamento dos resultados. Em estágios posteriores, a empresa pode avançar para critérios mais formais de auditoria, indicadores de desempenho, protocolos de privacidade e análise dos efeitos das recomendações sobre a experiência do cliente.

3. Metodologia

Este estudo caracteriza-se como ensaio teórico de abordagem qualitativa, natureza exploratória e finalidade conceitual. A escolha pelo ensaio teórico justifica-se pela necessidade de articular campos ainda em desenvolvimento, especialmente a integração entre estratégia *Omnichannel*, Inteligência Artificial Generativa e Design Science Research. Diferentemente de pesquisas empíricas voltadas à mensuração de relações causais, o ensaio teórico busca organizar argumentos, propor relações conceituais e indicar possibilidades de desenvolvimento para pesquisas futuras.

Os procedimentos de construção do estudo envolveram revisão narrativa da literatura e articulação conceitual. A seleção das fontes priorizou autores reconhecidos nos campos de *Omnichannel*, experiência do cliente, IA Generativa, modelos de linguagem, governança algorítmica, explicabilidade e DSR. Foram considerados artigos científicos, livros acadêmicos e trabalhos de referência que oferecem sustentação à discussão sobre artefatos, personalização da jornada, suporte à decisão e avaliação sociotécnica.

A análise foi conduzida por síntese teórica, buscando identificar convergências entre os desafios gerenciais do varejo *Omnichannel* e as possibilidades de uso da IA Generativa como artefato de apoio ao diagnóstico e à recomendação. O procedimento analítico foi organizado em três movimentos: identificação de lacunas conceituais, integração dos referenciais teóricos e formulação de proposições. A investigação não

realizou coleta primária de dados, entrevistas ou aplicação empírica de instrumento. Portanto, os resultados apresentados possuem natureza teórico-propositiva.

4. Análise e Discussão dos Resultados Teóricos

4.1 *Design Science Research* no Desenvolvimento de Artefatos Generativos

A aplicação da DSR ao desenvolvimento de um artefato de IA Generativa para personalização *Omnichannel* requer compreender que o problema gerencial é anterior à ferramenta. No varejo, o problema não se resume à falta de IA, mas à dificuldade de traduzir dados, canais e recursos organizacionais em recomendações práticas para melhorar a experiência do cliente. Essa dificuldade inclui fragmentação informacional, baixa maturidade digital, ausência de indicadores, falta de integração entre canais e limitação de competências analíticas.

A primeira contribuição da DSR consiste em explicitar o problema como uma situação de *design*. O varejista precisa decidir quais ações *Omnichannel* priorizar, mas nem sempre dispõe de dados estruturados ou de conhecimento técnico para avaliar sua própria maturidade. O artefato generativo deve funcionar como mediador entre conhecimento teórico e decisão gerencial, transformando conceitos como integração de canais, personalização, experiência do cliente, fulfillment e consistência de comunicação em perguntas diagnósticas, critérios interpretativos e recomendações acionáveis.

A segunda contribuição reside na tradução do referencial teórico em regras de design. Uma regra de design define uma relação entre contexto, mecanismo e resultado esperado. Por exemplo, se a empresa possui canais digitais ativos, mas não integra histórico de atendimento, o artefato deve recomendar a organização de dados de clientes antes de sugerir automações avançadas. Se a empresa apresenta baixa maturidade de fulfillment, recomendações sobre campanhas de conversão devem ser condicionadas à capacidade de entrega. Assim, o artefato não apenas responde, mas hierarquiza recomendações conforme o nível de maturidade da organização.

A terceira contribuição refere-se à configuração contextual do modelo generativo. Em vez de desenvolver uma nova infraestrutura de IA, a solução pode utilizar um modelo pré-existente e configurá-lo por meio de instruções, arquivos de referência, engenharia de prompts, critérios de análise e fluxos de interação. Essa estratégia é aderente a contextos de pequenas e médias empresas, pois reduz barreiras técnicas e financeiras. Contudo, a configuração deve estabelecer limites de resposta, alertas de incerteza, critérios de explicação e recomendação de validação humana.

A quarta contribuição envolve a avaliação sociotécnica. Em artefatos de IA Generativa, avaliar apenas o funcionamento técnico é insuficiente. É necessário examinar se as recomendações são compreensíveis para gestores, se respeitam as restrições do negócio, se são coerentes com o referencial teórico e se favorecem decisões implementáveis. Essa avaliação deve considerar utilidade percebida, clareza, aplicabilidade, transparência, aderência à maturidade digital e risco de respostas genéricas ou inadequadas.

A quinta contribuição está no refinamento do artefato. A DSR pressupõe ciclos de aprendizagem. Assim, as interações com usuários, os resultados das recomendações e as limitações identificadas devem alimentar ajustes nas perguntas diagnósticas, nas regras de design e nas instruções do modelo. O artefato torna-se mais robusto quando incorpora aprendizagem a partir do uso, sem abandonar mecanismos de governança e validação humana.

Quadro 1

Articulação entre etapas da DSR e desenvolvimento de artefato generativo

Etapa da DSR	**Pergunta orientadora**	**Aplicação ao artefato de IA Generativa**	**Resultado esperado**
Identificação do problema	Qual problema de decisão *Omnichannel* precisa ser apoiado?	Mapeamento de rupturas de canais, baixa maturidade digital e limitações de dados.	Problema delimitado e classe de usuários definida.
Objetivos da solução	Que desempenho o artefato deve alcançar?	Definição de capacidade diagnóstica, recomendação personalizada e explicação das sugestões.	Critérios de utilidade e qualidade do artefato.
Design e desenvolvimento	Como o conhecimento teórico será traduzido em solução?	Conversão de dimensões *Omnichannel* em prompts, regras de decisão, campos de entrada e base conceitual.	Artefato configurado para análise contextual.
Demonstração	Como o artefato será usado em situação realista?	Aplicação em situações simuladas ou casos exemplares de varejo com diferentes níveis de maturidade.	Evidências iniciais de funcionamento e interação usuário-sistema.
Avaliação	O artefato é útil, claro e aderente ao contexto?	Análise de coerência teórica, aplicabilidade, explicabilidade e necessidade de validação humana.	Subsídios para melhoria e refinamento.
Comunicação	Como o conhecimento de design será compartilhado?	Descrição do modelo, regras de design, proposições e implicações gerenciais.	Contribuição teórica e prática comunicável.

Fonte: Elaborado para este ensaio com base em Hevner *et al.* (2004), Peffers *et al.* (2007) e Gregor e Hevner (2013).

4.2 Modelo Conceitual Proposto

Com base na articulação teórica apresentada, propõe-se que o desenvolvimento de artefatos de IA Generativa para personalização *Omnichannel* seja compreendido por meio de seis movimentos integrados: explicitação do problema gerencial, delimitação das capacidades *Omnichannel*, tradução do conhecimento teórico em regras de design, configuração contextual do artefato generativo, avaliação sociotécnica e refinamento orientado por aprendizagem.

O primeiro movimento, explicitação do problema gerencial, consiste em identificar a classe de problemas que o artefato pretende resolver. No caso do varejo *Omnichannel*, essa classe envolve decisões sobre integração de canais, comunicação, atendimento, logística, precificação e experiência do cliente. A explicitação do problema impede que a IA seja adotada como solução genérica e permite que o artefato seja direcionado a necessidades concretas.

O segundo movimento, delimitação das capacidades *Omnichannel*, estabelece quais dimensões serão avaliadas. Capacidades podem incluir presença digital,

experiência de loja, integração de dados, fulfillment, responsividade móvel, marketing integrado, atendimento e uso de mídias sociais. A delimitação evita dispersão analítica e permite que o artefato gere diagnósticos comparáveis.

O terceiro movimento, tradução teórica em regras de design, converte literatura científica em orientações operacionais. Essa etapa é relevante porque modelos generativos tendem a responder conforme o contexto fornecido. Se o contexto é vago, as recomendações podem ser genéricas. Se o contexto é estruturado por regras de design, as recomendações tendem a ser mais aderentes ao problema.

O quarto movimento, configuração contextual do artefato, envolve engenharia de prompts, instruções, documentos de base, linguagem de resposta, critérios de prioridade e formas de interação. Essa configuração deve definir o que o artefato pode afirmar, como deve justificar recomendações e quando deve solicitar dados adicionais. Em artefatos generativos, a qualidade do design está associada à qualidade do contexto fornecido ao modelo.

O quinto movimento, avaliação sociotécnica, examina a utilidade do artefato para usuários reais ou para situações de uso teoricamente plausíveis. Essa avaliação deve incluir critérios técnicos, como consistência das respostas, e critérios organizacionais, como clareza, viabilidade e aderência à realidade do negócio. A avaliação sociotécnica reconhece que o valor do artefato emerge da interação entre modelo, usuário, dados, rotinas e decisões.

O sexto movimento, refinamento orientado por aprendizagem, incorpora os resultados da avaliação ao aprimoramento do artefato. O processo de design torna-se cumulativo, permitindo ajustar perguntas, regras, exemplos, limites e recomendações. Esse movimento aproxima o desenvolvimento de artefatos generativos de uma lógica iterativa de aprendizagem organizacional.

4.3 Proposições Teóricas do Estudo

As proposições teóricas sintetizam as relações conceituais discutidas neste ensaio. Elas não devem ser interpretadas como resultados empíricos confirmados, mas como formulações que podem orientar estudos futuros sobre o uso da DSR no desenvolvimento de artefatos de IA Generativa para personalização *Omnichannel*.

Quadro 2
Proposições teóricas para o desenvolvimento de artefatos generativos pela DSR

Proposição	**Formulação teórica**
P1	Quanto maior a explicitação do problema gerencial antes da configuração do modelo generativo, maior tende a ser a aderência das recomendações ao contexto organizacional.
P2	Artefatos generativos orientados por regras de design derivadas da literatura tendem a produzir recomendações mais consistentes do que artefatos configurados apenas por instruções genéricas.
P3	A personalização *Omnichannel* mediada por IA Generativa depende da compatibilidade entre capacidades digitais da empresa, dados disponíveis e nível de maturidade gerencial.
P4	A explicabilidade das recomendações aumenta a confiança gerencial no artefato e favorece a validação humana das decisões propostas.
P5	A avaliação sociotécnica amplia a utilidade do artefato ao considerar clareza, viabilidade, ética,

	governança de dados e aplicabilidade operacional.
P6	Ciclos de refinamento orientados pela DSR fortalecem o artefato ao transformar limitações de uso em aprendizagem de design.

Fonte: Elaborado para este ensaio.

4.4 Implicações para Pesquisa e Gestão

O modelo proposto contribui para a literatura ao posicionar a IA Generativa como componente de um artefato de design, e não como solução autônoma. Essa distinção é relevante porque parte dos debates sobre IA enfatiza capacidades técnicas dos modelos, enquanto a DSR exige analisar o artefato em relação a um problema, a um contexto, a critérios de utilidade e a uma base teórica. Assim, o valor da IA Generativa no varejo emerge da relação entre modelo, regras de design, dados, usuário e decisão gerencial.

Para a literatura de *Omnichannel*, o ensaio reforça que a integração de canais exige mais do que implantação tecnológica. A personalização depende de capacidades organizacionais e de maturidade digital. Um artefato generativo pode auxiliar esse processo ao transformar dimensões de análise em diagnósticos e recomendações. Todavia, sua efetividade depende da qualidade dos dados e da capacidade de o gestor interpretar e validar as sugestões recebidas.

Para a literatura de DSR, o texto indica que artefatos baseados em modelos de linguagem apresentam desafios próprios. Diferentemente de sistemas determinísticos, modelos generativos podem produzir respostas variáveis, dependentes do prompt, do contexto e das instruções. Por isso, a avaliação deve contemplar não apenas eficiência funcional, mas também estabilidade argumentativa, clareza, explicabilidade e adequação ao uso. Esse ponto amplia a agenda de avaliação em DSR para contextos de IA Generativa.

No plano gerencial, o ensaio sugere que pequenas e médias empresas podem utilizar artefatos generativos como instrumentos de apoio diagnóstico e planejamento, desde que os limites da tecnologia sejam reconhecidos. O artefato pode apoiar perguntas como: quais canais precisam ser integrados primeiro, quais dados devem ser organizados antes de automatizar campanhas, que ações têm maior aderência ao estágio atual da empresa e quais recomendações devem ser validadas por gestores antes da implementação.

A DSR também orienta uma postura prudente diante da IA. Recomendações geradas por modelos devem ser acompanhadas de justificativas, critérios de prioridade, premissas e indicação de incertezas. Em ambientes regulados pela proteção de dados, o desenho do artefato deve considerar governança, minimização de dados, consentimento, segurança e revisão humana. Portanto, o desenvolvimento de artefatos generativos para o varejo requer equilíbrio entre inovação, aplicabilidade e responsabilidade.

5. Conclusão e Contribuições

Este ensaio teórico teve como objetivo discutir como a *Design Science Research* pode orientar o desenvolvimento de artefatos de Inteligência Artificial Generativa aplicados à personalização da estratégia *Omnichannel* no varejo. O argumento central sustentou que a DSR oferece um caminho metodológico adequado para transformar problemas organizacionais complexos em artefatos úteis, avaliáveis e fundamentados teoricamente.

Conclui-se que artefatos generativos produzem maior valor quando são projetados a partir de problemas gerenciais claramente delimitados, regras de design derivadas da literatura, configuração contextual, avaliação sociotécnica e ciclos de refinamento. Nessa perspectiva, a IA Generativa não deve ser tratada como resposta universal ou ferramenta autônoma, mas como componente de um sistema sociotécnico que articula dados, linguagem, julgamento gerencial e aprendizagem organizacional.

A principal contribuição teórica do artigo reside na proposição de um modelo conceitual composto por seis movimentos: explicitação do problema gerencial, delimitação das capacidades *Omnichannel*, tradução do conhecimento teórico em regras de design, configuração contextual do artefato generativo, avaliação sociotécnica e refinamento orientado por aprendizagem. Essa estrutura pode orientar pesquisadores interessados em desenvolver artefatos baseados em modelos de linguagem sem reduzir a pesquisa à simples adoção de uma ferramenta tecnológica.

O artigo também contribui ao aproximar os campos de Design Science Research, *Omnichannel*, experiência do cliente e IA Generativa. A literatura de DSR fornece a lógica de construção e avaliação do artefato; a literatura *Omnichannel* delimita a classe de problemas ligados à integração de canais; a literatura de experiência do cliente orienta a análise da jornada; e a literatura sobre IA Generativa permite compreender o potencial e os riscos dos modelos de linguagem em decisões organizacionais.

A contribuição prática está em demonstrar que a IA Generativa pode apoiar pequenas e médias empresas varejistas na interpretação de sua maturidade *Omnichannel*, na priorização de ações e na geração de recomendações contextualizadas. Entretanto, tal uso deve ser acompanhado por validação humana, governança de dados, explicabilidade e adequação ao contexto. O artefato deve apoiar a decisão, não a substituir integralmente.

No plano social, o artigo contribui ao discutir possibilidades de acesso de empresas menores a recursos analíticos antes concentrados em organizações com maior capacidade tecnológica. Ao operar em linguagem natural, artefatos generativos podem reduzir barreiras cognitivas de uso, ampliar a capacidade diagnóstica de gestores e favorecer melhorias na experiência do consumidor, desde que sejam aplicados com responsabilidade, transparência e proteção de dados.

Como limitação, destaca-se que este ensaio apresenta contribuição conceitual e proposicional, sem desenvolver testagem empírica no próprio texto. As proposições apresentadas devem ser compreendidas como agenda de pesquisa, e não como resultados confirmados. Pesquisas futuras podem avaliar o modelo em diferentes segmentos varejistas, comparar artefatos generativos configurados por diferentes regras de design, analisar métricas de qualidade das recomendações e investigar os efeitos da explicabilidade na confiança dos gestores.

Também se recomenda explorar a relação entre maturidade digital, capacidade de dados e valor percebido no uso de artefatos generativos. Estudos qualitativos com gestores, estudos de caso em pequenas empresas, experimentos com diferentes formas de prompts e análises longitudinais de refinamento do artefato podem aprofundar a compreensão sobre como a DSR contribui para o desenvolvimento responsável de soluções generativas no varejo.

Conclui-se que a aplicação da DSR ao desenvolvimento de artefatos de IA Generativa favorece uma abordagem mais rigorosa, prática e responsável da transformação digital no varejo. Em vez de tratar a IA como resposta universal, a DSR recoloca o problema organizacional no centro do processo de inovação e orienta a

construção de soluções alinhadas à experiência do cliente, às capacidades da empresa e à produção de conhecimento em Administração.

Referências

Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion, 58*, 82-115. https://doi.org/10.1016/j.inffus.2019.12.012

Beck, N., & Rygl, D. (2015). Categorization of multiple channel retailing in multi-, cross-, and omni-channel retailing for retailers and retailing. *Journal of Retailing and Consumer Services, 27*, 170-178. https://doi.org/10.1016/j.jretconser.2015.08.001

Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency* (pp. 610-623). Association for Computing Machinery. https://doi.org/10.1145/3442188.3445922

Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., Bernstein, M. S., Bohg, J., Bosselut, A., Brunskill, E., Brynjolfsson, E., Buch, S., Card, D., Castellon, R., Chatterji, N., Chen, A., Creel, K., Davis, J. Q., Demszky, D., ... Liang, P. (2021). *On the opportunities and risks of foundation models*. arXiv. https://doi.org/10.48550/arXiv.2108.07258

Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems, 33*, 1877-1901.

Davenport, T. H., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science, 48*, 24-42. https://doi.org/10.1007/s11747-019-00696-0

Gregor, S., & Hevner, A. R. (2013). Positioning and presenting *Design Science Research* for maximum impact. *MIS Quarterly, 37*(2), 337-355. https://doi.org/10.25300/MISQ/2013/37.2.01

Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design science in information systems research. *MIS Quarterly, 28*(1), 75-105. https://doi.org/10.2307/25148625

Huang, M. H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science, 49*, 30-50. https://doi.org/10.1007/s11747-020-00749-9

Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing, 80*(6), 69-96. https://doi.org/10.1509/jm.15.0420

March, S. T., & Smith, G. F. (1995). Design and natural science research on information technology. *Decision Support Systems, 15*(4), 251-266. https://doi.org/10.1016/0167-9236(94)00041-2

Peffers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A *Design Science Research* methodology for information systems research. *Journal of Management Information Systems, 24*(3), 45-77. https://doi.org/10.2753/MIS0742-1222240302

Piotrowicz, W., & Cuthbertson, R. (2014). Introduction to the special issue: Information technology in retail: Toward *Omnichannel* retailing. *International Journal of Electronic Commerce, 18*(4), 5-16. https://doi.org/10.2753/JEC1086-4415180400

Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?" Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135-1144). Association for Computing Machinery. https://doi.org/10.1145/2939672.2939778

Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Simon, H. A. (1996). *The sciences of the artificial* (3rd ed.). MIT Press.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems, 30*.

Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). From multi-channel retailing to omni-channel retailing: Introduction to the special issue on multi-channel retailing. *Journal of Retailing, 91*(2), 174-181. https://doi.org/10.1016/j.jretai.2015.02.005