



PPGCA
Programa de
Pós-graduação
em Ciências da
Administração

ISSN: 1983-6635



RGO
Revista Gestão
Organizacional



fapesc
Fundação de Amparo à
Pesquisa e Inovação do
Estado de Santa Catarina



OPEN ACCESS

Este é um artigo publicado em acesso aberto (Open Access) sob a licença Creative Commons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

CAPACIDADES DINÂMICAS NA HIPERPERSONALIZAÇÃO: UMA ANÁLISE VIA MODELAGEM DE EQUAÇÕES ESTRUTURAIS COM CLICKSTREAM

DYNAMIC CAPABILITIES IN HYPERPERSONALIZATION: AN ANALYSIS THROUGH STRUCTURAL EQUATION MODELING WITH CLICKSTREAM DATA

CAROLLINE CANDEIAS DA SILVA

Universidade Federal do Rio Grande do Norte (UFRN)

Doutoranda em Administração

ORCID: <https://orcid.org/0000-0001-8846-0180>

E-mail: carollinecs@gmail.com

MARIA GABRIELLE SOARES GOMES

Universidade Federal do Rio Grande do Norte (UFRN)

Doutoranda em Administração

ORCID: <https://orcid.org/0009-0002-5112-7573>

E-mail: gabriellesoaresuf@gmail.com

GLENDA MICHELLE MARQUES FONSECA FERREIRA DANTAS

Universidade Federal do Rio Grande do Norte (UFRN)

Doutoranda em Administração

ORCID: <https://orcid.org/0009-0001-3541-6538>

E-mail: glenda.marques@ifrn.edu.br

AFRANIO GALDINO DE ARAUJO

Universidade Federal do Rio Grande do Norte (UFRN)

Doutor em Engenharia de Produção

ORCID: <https://orcid.org/0000-0002-7294-2609>

E-mail: afranioga@gmail.com

ADRIANNE PAULA VIEIRA DE ANDRADE

Universidade Federal do Rio Grande do Norte (UFRN)

Doutora em Administração

ORCID: <https://orcid.org/0000-0003-3304-8812>

E-mail: adriannepaula@gmail.com

Editor científico: Sady Mazzioni

Submissão: 09/11/2025. Revisão: 12/03/2025. Aceite: 04/05/2026. Publicação: 05/08/2026.

Como citar: Silva, C. C. da., Gomes, M. G. S., Dantas, G. M. M. F. F., Araujo, A. G. de., & Andrade, A. P. V. de., (2026). Capacidades dinâmicas da hiperpersonalização: uma análise via modelagem de equações estruturais com clickstream. *RGO - Revista Gestão Organizacional*, 19(1), 158-181. <http://dx.doi.org/10.22277/rgo.v19i1.8724>.

RESUMO

Objetivo: Propor e validar um modelo empírico de mensuração do Potencial de Hiperpersonalização em ambientes de *e-commerce*, operacionalizado a partir de padrões de navegação registrados em dados de *clickstream*.

Método/abordagem: Trata-se de uma pesquisa quantitativa, observacional e confirmatória baseada em dados secundários de *clickstream* em ambiente de *e-commerce*. A base empírica reúne 74.817 registros de navegação de 1.000 usuários, agregados em 10.000 sessões entre janeiro e julho de 2024. A unidade analítica foi a sessão de navegação. Os dados passaram por pré-processamento, incluindo exclusão de sessões com evento único e tratamento de *outliers*. O construto Potencial de Hiperpersonalização foi estimado por Modelagem de Equações Estruturais em um modelo reflexivo de fator único com quatro indicadores comportamentais: intensidade de visualizações, diversidade de produtos explorados, proporção de visualizações e taxa de conversão. A qualidade da mensuração foi avaliada por testes de fatorabilidade, confiabilidade composta, variância média extraída e índices de ajuste do modelo.

Principais Resultados: Os resultados indicam que padrões de navegação derivados de dados de *clickstream* constituem indicadores empíricos do potencial de hiperpersonalização em ambientes digitais. O modelo apresentou validade e confiabilidade satisfatórias.

Contribuições teóricas/práticas/sociais: O estudo aproxima a literatura de dados comportamentais digitais da teoria das capacidades dinâmicas ao propor uma forma empírica de mensurar fundamentos comportamentais associados à personalização digital.

Originalidade/relevância: O estudo propõe um modelo empírico para mensurar as bases comportamentais da hiperpersonalização em ecossistemas digitais, conectando padrões observáveis de interação *online* aos microfundamentos das capacidades dinâmicas.

Palavras-chave: Hiperpersonalização. Personalização digital. Capacidades dinâmicas. Visão Baseada em Recursos. *Clickstream*.

ABSTRACT

Purpose: Propose and validate an empirical model for measuring Hyperpersonalization Potential in e-commerce environments, operationalized based on browsing patterns recorded in clickstream data.

Method/approach: This is a quantitative, observational, and confirmatory study based on secondary clickstream data in an e-commerce environment. The empirical basis comprises 74,817 browsing records from 1,000 users, aggregated in 10,000 sessions between January and July 2024. The analytical unit was the browsing session. The data underwent preprocessing, including the exclusion of single-event sessions and the treatment of outliers. The Hyperpersonalization Potential construct was estimated by Structural Equation Modeling in a single-factor reflexive model with four behavioral indicators: viewing intensity, diversity of products explored, proportion of views, and conversion rate. The quality of the measurement was assessed by factorability tests, composite reliability, extracted mean variance, and model fit indices.

Main Findings: The results indicate that browsing patterns derived from clickstream data are empirical indicators of the potential for hyperpersonalization in digital environments. The model showed satisfactory *validity* and reliability.

Theoretical/practical/social contributions: The study brings together the literature on digital behavioral data and dynamic capabilities theory by proposing an empirical way to measure behavioral fundamentals associated with digital personalization.

Originality/relevance: The study proposes an empirical model to measure the behavioral bases of hyperpersonalization in digital ecosystems, connecting observable patterns of online interaction to the microfoundations of dynamic capabilities.

Keywords: Hyper-personalization. Digital personalization. Dynamic capabilities. Resource-Based View. Clickstream.

1 INTRODUÇÃO

O comércio eletrônico (*e-commerce*) transformou-se nas últimas décadas, evoluindo de um canal de vendas suplementar para um ecossistema digital baseado no uso intensivo de dados para orientar decisões estratégicas (Kannan & Li, 2017).

A compreensão do comportamento do consumidor deixou de depender exclusivamente de análises retrospectivas baseadas em pesquisas de mercado, do histórico de vendas e do retorno dos clientes (Davenport, 2023). Com a expansão de mercados digitais, dinâmicos e saturados de informação, consumidores passaram a demandar experiências mais relevantes e individualizadas, deslocando a lógica competitiva das organizações para a capacidade de interpretar sinais comportamentais e responder às necessidades individuais em tempo real (Laudon & Traver, 2024).

Nesse cenário, a personalização digital tornou-se um mecanismo de diferenciação competitiva em ambientes *online* (Rochefort & Ndlovu, 2024). De modo geral, a personalização digital refere-se ao processo de adaptação de conteúdos, recomendações ou ofertas com base em dados históricos ou padrões de comportamento dos usuários, permitindo ajustar experiências de consumo a preferências identificadas ao longo das interações digitais (Bleier et al., 2017; Vesanen & Raulas, 2006).

Ao reduzir a incerteza na jornada de compra e oferecer interações mais relevantes, estratégias de personalização digital têm sido associadas a maiores níveis de engajamento, satisfação e conversão em ambientes digitais (Lemon & Verhoef, 2016).

No entanto, avanços no uso de dados e de capacidades analíticas têm ampliado as possibilidades da personalização digital, permitindo adaptações mais precisas e dinâmicas nas interações com os consumidores (Chandra et al., 2022). Na literatura recente, esse desenvolvimento tem sido caracterizado como hiperpersonalização (Srivastav, 2025; Narayana & Koralla, 2025; Rane, Choudhary, & Rane, 2023; Guendouz, 2024; Sipos, 2024; Davenport, 2023).

Em contraste com a personalização digital tradicional, baseada principalmente em segmentação ou em padrões históricos agregados, a hiperpersonalização envolve a adaptação contínua das interações entre empresas e consumidores. Essa adaptação ocorre por meio da integração de diferentes fontes de dados comportamentais, emocionais, contextuais e históricos, permitindo ajustes contínuos, em tempo real, ao longo das interações digitais (Jain et al., 2021; Valdez Mendia & Flores-Cuautle, 2022; Davenport, 2023; Rane, Choudhary, & Rane, 2023; Sipos, 2024; Srivastav, 2025; Narayana & Koralla, 2025).

Embora a literatura recente tenha avançado na descrição das tecnologias e aplicações associadas à hiperpersonalização, muitos estudos ainda se concentram principalmente em aspectos tecnológicos ou em métricas operacionais de desempenho, como a acurácia de algoritmos, taxas de conversão ou níveis de engajamento (Jain et al., 2021; Valdez Mendia &

Flores-Cuautle, 2022; Davenport, 2023; Rane, Choudhary, & Rane, 2023; Sipos, 2024; Srivastav, 2025; Narayana & Koralla, 2025). Nesse sentido, ainda são limitadas as investigações que procuram compreender e mensurar empiricamente os fundamentos comportamentais e analíticos que antecedem e sustentam esse fenômeno em ambientes digitais.

Antes do surgimento das práticas atuais de hiperpersonalização, dados de *clickstream* já eram amplamente utilizados na pesquisa de marketing para mapear padrões de navegação, medir o engajamento em *sites* e prever comportamentos de compra *online* (Bucklin et al., 2002; Olbrich & Holsing, 2011; Su & Chen, 2015; Raphaelli et al., 2017; Kagan & Bekkerman, 2018; Pal et al., 2021).

A investigação dessas sequências de cliques, do tempo de permanência e dos caminhos de navegação permitiu compreender padrões de interesse e diferentes estágios da jornada de compra em níveis agregados ou em níveis de sessão (Bucklin & Sismeiro, 2009; Montgomery et al., 2004), estabelecendo bases analíticas que posteriormente contribuíram para o desenvolvimento de estratégias mais avançadas de personalização.

Dessa forma, os dados de *clickstream* permitem analisar como consumidores interagem com ambientes digitais e como essas interações podem ser traduzidas em decisões estratégicas orientadas por dados.

Sob a perspectiva da estratégia empresarial, tais dados podem ser interpretados como recursos estratégicos capazes de sustentar vantagem competitiva. A Visão Baseada em Recursos (*Resource-Based View* — RBV) sustenta que recursos valiosos, raros e difíceis de imitar podem constituir a base da vantagem competitiva sustentável (Barney & Hesterly, 2007; Wernerfelt, 1984).

No contexto digital, dados comportamentais, infraestrutura analítica e capacidades de interpretação de dados tornam-se ativos estratégicos importantes para a criação de valor. Entretanto, a literatura de estratégia enfatiza que, em ambientes dinâmicos, a criação de valor depende da capacidade das organizações de interpretar, integrar e mobilizar recursos por meio de capacidades organizacionais que permitam sua adaptação contínua às mudanças do ambiente competitivo (Teece, Pisano & Shuen, 1997; Sun, Chen, & Mei, 2024).

Por sua vez, a Teoria das Capacidades Dinâmicas (*Dynamic Capabilities Theory* — DCT) propõe que a vantagem competitiva em contextos de rápida transformação tecnológica depende da habilidade das organizações de detectar oportunidades emergentes (*sensing*), mobilizar recursos para explorá-las (*seizing*) e reconfigurar continuamente processos e rotinas organizacionais (*reconfiguring*) (Teece, 2007; Eisenhardt & Martin, 2000).

Embora sistemas de recomendação e modelos analíticos baseados em dados de interação digital tenham avançado, grande parte da literatura concentra-se na eficácia de algoritmos ou em métricas operacionais de marketing, como taxas de conversão ou engajamento (Jain et al., 2021; Davenport, 2023). Ainda são limitadas as investigações que procuram relacionar padrões comportamentais observáveis em ambientes digitais a processos estratégicos mais amplos associados às capacidades organizacionais.

Com base nisso, propõe-se que padrões observáveis de interação digital registrados em dados de *clickstream* fornecem sinais comportamentais relevantes sobre as interações entre consumidores e plataformas digitais. Esses sinais constituem insumos informacionais que podem alimentar rotinas analíticas utilizadas pelas organizações para detectar e explorar oportunidades em ambientes digitais. Assim, a capacidade de interpretar e mobilizar tais dados torna-se parte das capacidades organizacionais necessárias para a implementação de práticas de hiperpersonalização.

A partir dessa perspectiva, argumenta-se que práticas atuais de hiperpersonalização representam a evolução de rotinas analíticas desenvolvidas a partir da interpretação de sinais comportamentais gerados nas interações digitais. Para investigar essa proposição, este estudo utiliza um banco de dados de *e-commerce* com registros de navegação e transações ocorridas entre janeiro e julho de 2024, permitindo analisar padrões comportamentais associados à personalização em ambientes digitais.

Com base neste enquadramento, o objetivo deste estudo é propor e validar um modelo empírico para mensurar os fundamentos comportamentais da hiperpersonalização em ambientes de *e-commerce*, operacionalizados a partir de padrões de navegação registrados em dados de *clickstream*. Especificamente, busca-se explorar como esses padrões podem servir como indicadores empíricos associados aos processos de detecção (*sensing*) e exploração (*seizing*) de oportunidades.

No campo teórico, o estudo contribui ao estabelecer uma ponte entre dados comportamentais e a literatura de estratégia, demonstrando como métricas observáveis de interação digital podem ser utilizadas para mensurar processos estratégicos associados às capacidades dinâmicas. No campo prático, o modelo proposto oferece um instrumento analítico capaz de apoiar gestores na avaliação da maturidade das capacidades analíticas e de personalização em ambientes digitais. Adicionalmente, ao utilizar dados observacionais de navegação, o estudo contribui para o desenvolvimento de abordagens metodológicas replicáveis para investigar fenômenos estratégicos em ecossistemas digitais orientados por dados.

O artigo está organizado em cinco seções. A seção 2 apresenta a revisão da literatura sobre personalização digital, hiperpersonalização, *e-commerce* e capacidades dinâmicas. A seção 3 descreve os procedimentos metodológicos adotados, com destaque para o uso da Modelagem de Equações Estruturais (MEE) aplicada a dados de *clickstream*. A seção 4 apresenta os resultados empíricos do modelo proposto. Por fim, a seção 5 discute as implicações teóricas e gerenciais do estudo, bem como suas limitações e sugestões para pesquisas futuras.

2 REVISÃO DA LITERATURA

2.1 A PERSONALIZAÇÃO E SUA EVOLUÇÃO ATÉ A HIPERPERSONALIZAÇÃO

A trajetória da personalização no marketing tem origem nas primeiras abordagens de segmentação de mercado. Smith (1956) propôs que os mercados poderiam ser divididos em subgrupos relativamente homogêneos, permitindo que as organizações direcionassem suas ofertas e comunicações de forma mais eficiente. Esses segmentos podem ser definidos a partir de diferentes tipos de variáveis, como critérios demográficos (idade, gênero e renda), geográficos (localização e clima), psicográficos (estilo de vida, valores e personalidade) ou comportamentais (frequência de uso, lealdade à marca e benefícios buscados).

Posteriormente, essa lógica foi consolidada no *framework* conhecido como *Segmentation, Targeting and Positioning* (STP), amplamente difundido na literatura de marketing estratégico como ferramenta para identificar segmentos prioritários e desenvolver propostas de valor direcionadas (Kotler & Keller, 2016).

Nas décadas seguintes, o marketing passou a incorporar de forma mais intensa o uso de dados nas estratégias de relacionamento com clientes. O marketing direto, formalizado por Wunderman (1973), integrou a segmentação com o uso de bases de dados estruturadas,

porém limitadas em capacidade analítica, para estabelecer comunicação direta com consumidores (Peelen, Ekelmans & Vijn, 1989; Sheth & Parvatiyar, 1995).

Em seguida, o Marketing de Relacionamento, introduzido por Berry (1983), destacou a importância da construção de relações duradouras com os clientes. Essa evolução culminou no conceito de Marketing *One-to-One*, popularizado por Peppers e Rogers (1993), que defendia a ideia de tratar cada cliente individualmente a partir das informações coletadas ao longo das interações.

Paralelamente, avanços na gestão de operações possibilitaram o surgimento da customização em massa, conceito introduzido por Davis (1987) e posteriormente consolidado por Pine (1993). Essa abordagem tornou possível oferecer produtos adaptados às preferências individuais, mantendo, ao mesmo tempo, ganhos de escala na produção.

Com a expansão dos ambientes digitais e da coleta de dados de interação, novas formas de personalização passaram a ser desenvolvidas a partir do registro de comportamentos de usuários em plataformas digitais. Nesse contexto, a hiperpersonalização é definida como uma forma de personalização baseada na integração de diversas fontes de dados comportamentais, contextuais e históricos, permitindo adaptar conteúdos, ofertas e interações de acordo com padrões observados de comportamento do consumidor em tempo real (Valdez Mendia & Flores-Cuautle, 2022; Jain et al., 2021; Micu et al., 2022; Pukas, 2022; Davenport, 2023; Srivastav, 2025).

Entre os ambientes digitais em que essas práticas se desenvolvem, o comércio eletrônico constitui um contexto relevante para a análise de estratégias de personalização. Plataformas de *e-commerce* registram interações dos usuários ao longo da navegação, permitindo observar padrões de comportamento e adaptar ofertas e recomendações com base nesses registros (Raji et al., 2024; Nguyen et al., 2024).

Dessa forma, as práticas atuais de hiperpersonalização podem ser compreendidas como a evolução de rotinas analíticas e comportamentais desenvolvidas em ambientes digitais, especialmente em plataformas de *e-commerce* que registram interações dos usuários. Sob uma perspectiva estratégica, essas rotinas podem ser interpretadas como processos organizacionais de identificação e exploração de padrões de comportamento em contextos orientados por dados.

2.2 O E-COMMERCE COMO CONTEXTO DE APLICAÇÃO DA HIPERPERSONALIZAÇÃO

A ascensão do *e-commerce* transformou as dinâmicas de consumo e de relacionamento entre empresas e clientes (Raji et al., 2024). Inicialmente associado à conveniência e à ampliação do acesso ao consumo, o comércio eletrônico evoluiu para um ecossistema baseado em dados, no qual a experiência do usuário e a análise comportamental passaram a orientar processos de diferenciação competitiva (Nandy & Kirit, 2025). Cada clique, visualização ou transação geram rastros digitais que, quando analisados, permitem identificar padrões de navegação e comportamento do consumidor em ambientes de *e-commerce*, além de possibilitar a inferência de intenções de compra a partir das interações registradas (Raphaeli et al., 2017; Sakar et al., 2018).

Nesse contexto, o *e-commerce* funciona como um espaço de observação de práticas de personalização, permitindo testar e mensurar o impacto de diferentes estímulos em tempo real (Lemon & Verhoef, 2016; Wang, 2024). A lógica da jornada do cliente organiza-se a partir de diversos pontos de contato como buscas, anúncios, recomendações e interações em redes sociais (Lemon & Verhoef, 2016), que capturam informações sobre o comportamento do consumidor e podem influenciá-lo (Pappas, 2018). Diferentemente das interações físicas, as

jornadas digitais podem ser registradas e modeladas com alto nível de detalhamento (Schweidel et al., 2022), possibilitando análises preditivas e intervenções automatizadas (Wang, 2024).

Entre as fontes de dados comportamentais geradas nesse ambiente, o *clickstream* registra sequências de cliques e interações realizadas pelos usuários (Wang et al., 2017). Esse registro reflete as decisões tomadas pelos consumidores ao longo da jornada *online*, incluindo visualizações de produtos, adições ao carrinho e conclusões de compra, compondo uma representação detalhada do comportamento digital (Aylin Tokuç & Dag, 2025; Liu et al., 2024; Thirumagal et al., 2024). A análise desses dados permite identificar padrões de navegação, inferir intenções de compra e desenvolver modelos de recomendação (Montgomery et al., 2004), alcançando níveis de precisão entre 72% e 75% em estudos recentes (Liu et al., 2024; Zhou & Hudin, 2024).

Do ponto de vista gerencial, os dados de *clickstream* fornecem informações sobre o comportamento de navegação dos consumidores, permitindo às organizações extrair insumos comportamentais e apoiar decisões estratégicas baseadas em dados em ambientes digitais (Montgomery et al., 2004; Wedel & Kannan, 2016). Esses registros também possibilitam acompanhar o ciclo de vida do cliente e ajustar conteúdos, comunicações e estímulos de marketing ao longo da jornada digital (Patnaik & Bhowmick, 2022; Gomes & Meisen, 2023).

2.3 MODELAGEM PREDITIVA E *CLICKSTREAM* COMO BASE DA MENSURAÇÃO

A digitalização das interações entre consumidores e plataformas ampliou o uso de dados comportamentais na análise de padrões de consumo. Esses dados permitem o desenvolvimento de modelos preditivos utilizados para identificar padrões de navegação e apoiar processos de decisão organizacional (Wedel & Kannan, 2016; Davenport, 2023).

No contexto do *e-commerce*, a modelagem preditiva baseia-se em dados de *clickstream*, que registram a sequência de ações realizadas por um usuário durante a navegação em um site, desde o acesso inicial até a conversão ou abandono da compra (Montgomery et al., 2004; Bucklin & Sismeiro, 2009). Esses registros incluem informações como tempo de permanência em páginas, sequência de cliques, produtos visualizados e transações realizadas, permitindo observar o processo de decisão do consumidor em ambientes digitais (Liu et al., 2024; Mahajan et al., 2024).

A análise desses registros permite identificar padrões comportamentais associados à exploração de produtos, à avaliação de alternativas e às decisões de compra em ambientes digitais. A partir desses padrões, modelos estatísticos e algoritmos preditivos podem ser empregados para estimar probabilidades de compra, abandono de navegação ou conversão ao longo da jornada digital (Liu et al., 2024; Zhou & Hudin, 2024).

Nesse sentido, os dados de *clickstream* constituem uma base empírica para investigar como interações digitais podem ser traduzidas em informações analíticas capazes de apoiar estratégias de personalização em plataformas *online*. Ao registrar comportamentos observáveis dos usuários, esses dados permitem operacionalizar indicadores comportamentais associados às interações entre consumidores e ambientes digitais.

Neste estudo, os registros de *clickstream* são utilizados como fonte empírica para a construção de indicadores comportamentais empregados na mensuração do construto analisado. A partir desses dados, busca-se identificar padrões de navegação que possam fornecer evidências empíricas sobre processos associados à personalização em ambientes digitais orientados por dados.

2.4 DA TEORIA DA VISÃO BASEADA EM RECURSOS À TEORIA DAS CAPACIDADES DINÂMICAS

A Teoria da Visão Baseada em Recursos (RBV) com seus fundamentos em Penrose (1959) e sua consolidação seminal por Wernerfelt (1984), postula que a vantagem competitiva deriva da posse de recursos valiosos, raros, inimitáveis e organizados (*VRIO*) (Barney & Hesterly, 2007).

No contexto da hiperpersonalização, estes recursos assumem uma natureza intangível e tecnológica, englobando infraestrutura de dados, algoritmos, bases de dados proprietárias e competências analíticas (Hitt, Ireland & Hoskisson, 2017; Buiak et al., 2024; Dahake, Mohare & Somani, 2023).

Contudo, a RBV, com seu pressuposto de ambientes relativamente estáveis, mostrou-se limitada para explicar a sustentação da vantagem competitiva em contextos de mudança tecnológica acelerada e globalização (Eisenhardt & Martin, 2000). Foi nesse cenário de crescente turbulência que Teece, Pisano e Shuen (1997) introduziram a Teoria das Capacidades Dinâmicas (DCT), propondo uma visão processual e evolutiva. Se a RBV explica o que gera a vantagem (a posse de recursos), a DCT explica como essa vantagem é renovada (Teece, Pisano & Shuen, 1997).

Esta teoria foi posteriormente refinada por Teece (2007), que operacionalizou o conceito em três capacidades inter-relacionadas: o *sensing*, que envolve a detecção de oportunidades e ameaças a partir do monitoramento sistemático de tendências, dados e padrões comportamentais; o *seizing*, que compreende a mobilização de recursos e a conversão de *insights* analíticos em decisões estratégicas, inovações ou experiências personalizadas; e o *reconfiguring*, que se refere ao redesenho e à recombinação de ativos, sistemas e rotinas organizacionais com o propósito de garantir o alinhamento contínuo à dinâmica do ambiente competitivo e fortalecer a capacidade adaptativa da organização. O cerne dessas capacidades, conforme o autor, é "manter a aptidão evolutiva à medida que os mercados e as oportunidades tecnológicas mudam" (Teece, 2007).


Sob esta ótica, a hiperpersonalização emerge não simplesmente da posse de dados e algoritmos (perspectiva RBV), mas da capacidade dinâmica da organização de aprender com os dados comportamentais (*sensing*), transformar esses *insights* em experiências customizadas (*seizing*) e atualizar continuamente seus modelos e estruturas (*reconfiguring*).

A literatura evoluiu ainda mais para o conceito de Capacidades Dinâmicas Digitais (CDD), que detalha os microfundamentos necessários para a adaptação em ambientes digitais (Warner & Wäger, 2019; Ellström et al., 2022; Albannai et al., 2024). As CDD englobam três dimensões: detecção digital (monitoramento e interpretação de dados e tecnologias emergentes), apreensão digital (mobilização de recursos e prototipagem ágil) e transformação digital (reconfiguração contínua de processos, modelos de negócio e estruturas organizacionais).

Portanto, a hiperpersonalização pode ser interpretada como um fenômeno organizacional que depende do desenvolvimento de capacidades dinâmicas digitais voltadas à interpretação e mobilização de dados comportamentais.

O *framework* proposto (Figura 1) sintetiza a integração teórica, posicionando a infraestrutura analítica e comportamental da hiperpersonalização como a expressão empírica de um sistema estratégico.

Figura 1
Framework da Hiperpersonalização como Capacidade Dinâmica



A base estrutural, ancorada na Visão Baseada em Recursos (RBV), fornece os recursos estratégicos necessários, como algoritmos e dados, que podem apresentar características de valor, raridade, dificuldade de imitação e insubstituibilidade. Esses recursos são mobilizados por meio das capacidades dinâmicas, pelas quais a organização identifica oportunidades a partir dos dados (*sensing*), aproveita essas oportunidades ao desenvolver ofertas personalizadas (*seizing*) e reconfigura continuamente seus recursos e processos para manter o alinhamento com as mudanças do mercado (*reconfiguring*).

Este ciclo é realimentado pelos resultados gerados por práticas de personalização orientadas por dados, configurando um *loop* de aprendizado contínuo. Dessa forma, a hiperpersonalização não é tratada, neste estudo, como um fenômeno diretamente observado, mas como um desdobramento analítico sustentado por capacidades dinâmicas digitais em funcionamento.

Portanto, a infraestrutura comportamental e analítica associada à hiperpersonalização pode ser compreendida como manifestação empírica de capacidades dinâmicas digitais, refletindo a habilidade das organizações de interpretar e mobilizar dados e algoritmos para criar valor, o que demanda integração entre infraestrutura tecnológica, aprendizado organizacional e processos contínuos de reconfiguração estratégica.

2.5 HIPÓTESES E ENQUADRAMENTO CONCEITUAL DO CONSTRUTO HIPER

Com base na literatura, dados gerados em interações digitais podem ser interpretados como sinais comportamentais do comportamento do consumidor em ambientes *online*. Em plataformas de *e-commerce*, registros de *clickstream* permitem observar como consumidores exploram produtos, avaliam alternativas e tomam decisões ao longo da jornada digital (Montgomery et al., 2004; Bucklin & Sismeiro, 2009).

Sob a perspectiva das capacidades dinâmicas, esses sinais podem fornecer informações para processos organizacionais de detecção (*sensing*) e exploração (*seizing*) de oportunidades em ambientes digitais (Teece, 2007). Nesse contexto, padrões de navegação podem ser tratados como insumos informacionais utilizados em práticas de personalização baseadas em dados.

Neste estudo, o construto HIPER representa o potencial informacional presente nos padrões de navegação observados em dados de *clickstream*. Assim, HIPER não corresponde diretamente à hiperpersonalização organizacional, mas aos sinais comportamentais que podem ser explorados por sistemas analíticos em processos de personalização digital.

Com base nisso, propõem-se as seguintes hipóteses.

A intensidade de visualizações de produtos reflete o volume de interação com estímulos de produto durante a sessão (Montgomery et al., 2004; Bucklin & Sismeiro, 2009).

H1. Maior intensidade de visualizações de produtos por sessão está positivamente associada ao Potencial de Hiperpersonalização (HIPER).

A diversidade de produtos visualizados indica a amplitude de interesses explorados durante a navegação (Moe, 2003; Bucklin & Sismeiro, 2009).

H2. Maior diversidade de produtos visualizados por sessão está positivamente associada ao Potencial de Hiperpersonalização (HIPER).

A proporção de visualizações de produtos no total de eventos da sessão indica o foco da navegação em atividades de avaliação de produtos.

H3. Maior proporção de visualizações de produtos no total de eventos da sessão está positivamente associada ao Potencial de Hiperpersonalização (HIPER).

A conversão representa a transformação da atenção em ação, fornecendo evidências de preferência revelada (Lemon & Verhoef, 2016).

H4. Maior taxa de conversão por sessão está positivamente associada ao Potencial de Hiperpersonalização (HIPER).

3 ASPECTOS METODOLÓGICOS

Este estudo adota abordagem quantitativa, observacional e aplicada, com base em dados secundários de eventos de navegação e transação em ambiente de *e-commerce*. O objetivo metodológico consiste em operacionalizar empiricamente o Potencial de Hiperpersonalização (HIPER) a partir de padrões comportamentais observáveis, convertendo um fenômeno estratégico, abstrato e não diretamente mensurável em um construto latente passível de estimação empírica. Para tanto, empregou-se a Modelagem de Equações Estruturais, dada sua adequação à mensuração de variáveis latentes e à avaliação simultânea das relações entre o construto teórico e seus indicadores observáveis.

A escolha da MEE decorre do fato de que a hiperpersonalização, enquanto capacidade analítica e comportamental do sistema, não é diretamente observável em uma única variável. Sua identificação exige a combinação de manifestações empíricas associadas à navegação do usuário, à exploração de produtos e à transformação da atenção em ações de maior valor, o que torna apropriada a estimação de um modelo de mensuração reflexivo.

A base empírica utilizada é composta por registros de eventos de navegação e transação em *e-commerce*, estruturados em nível de evento e contendo as variáveis: *UserID*, *SessionID*, *Timestamp*, *EventType*, *ProductID*, *Amount* e *Outcome*. O arquivo analisado reúne 74.817 registros, correspondentes a 1.000 usuários e 10.000 pares distintos *UserID-SessionID*, cobrindo interações ocorridas entre 01/01/2024 e 24/07/2024. Os eventos observados incluem, entre outros, *page_view*, *click*, *product_view*, *add_to_cart*, *purchase*, *login* e *logout*.

A unidade analítica do estudo foi a sessão de navegação. Como o identificador *SessionID* não é globalmente único no arquivo, a sessão foi operacionalizada pela combinação entre *UserID* e *SessionID*. Essa decisão metodológica evita agregações indevidas entre usuários distintos e assegura maior consistência ao rastreamento comportamental em nível de sessão.

A escolha dessa base decorre de sua aderência ao problema de pesquisa. Por conter eventos explícitos de navegação, visualização de produtos, adição ao carrinho e compra, o banco permite derivar indicadores comportamentais diretamente compatíveis com a proposta de mensurar fundamentos empíricos da hiperpersonalização em ambiente digital. Nesse sentido, o ambiente empírico é tratado como uma prova de conceito de mensuração, voltada à operacionalização dos microfundamentos comportamentais associados à personalização avançada.

3.2 CONSTRUTO CENTRAL E DEFINIÇÃO DAS VARIÁVEIS

O construto central do estudo é o HIPER, entendido como o grau em que padrões de navegação e resposta do usuário revelam condições comportamentais compatíveis com personalização avançada. No plano teórico, o construto está ancorado nos microfundamentos das capacidades dinâmicas, especialmente nos processos de *sensing* e *seizing*. O primeiro remete à capacidade de captar, identificar e interpretar sinais do ambiente; o segundo, à capacidade de transformar tais sinais em ações de maior valor.

No entanto, esses fundamentos não foram modelados como fatores latentes distintos. Empiricamente, o modelo foi especificado como unidimensional e reflexivo, partindo da premissa de que diferentes manifestações comportamentais da navegação digital funcionam como indicadores de um único fator latente associado ao potencial de hiperpersonalização. Assim, *sensing* e *seizing* operam, neste estudo, como fundamentos conceituais para a escolha dos indicadores, e não como dimensões latentes estimadas separadamente.

A construção das variáveis foi realizada em nível de sessão, a partir da agregação dos eventos por *UserID* e *SessionID*. O construto HIPER foi operacionalizado por quatro indicadores observados. O primeiro indicador, *n_product_view_session*, corresponde ao número de eventos *product_view* em cada sessão e representa a intensidade da exploração comportamental. O segundo, *n_unique_products_session*, corresponde ao número de produtos distintos visualizados em eventos *product_view*, refletindo a amplitude dessa exploração. O terceiro, *ratio_product_view*, foi calculado como a razão entre o número de eventos *product_view* e o total de eventos da sessão, funcionando como medida do foco da navegação em estímulos de produto. O quarto, *conversion_rate_session*, foi calculado como a razão entre a quantidade de produtos distintos adicionados ao carrinho e o número de visualizações de produto na sessão, sendo interpretado como evidência da efetividade da transformação da atenção em ação de maior valor.

No *script*, a identificação do evento de adição ao carrinho foi realizada por busca textual do termo “*cart*” nos rótulos da variável *EventType*, o que permite localizar o evento *add_to_cart*. Para evitar problemas de divisão por zero, as sessões sem qualquer visualização de produto receberam *conversion_rate_session* = 0. De modo análogo, nas sessões sem *product_view*, o indicador *n_unique_products_session* assumiu valor zero. Formalmente, o modelo de mensuração foi especificado da seguinte forma:

$$HIPER = \sim n_product_view_session + n_unique_products_session + ratio_product_view + conversion_rate_session$$

Em termos substantivos, *n_product_view_session* e *n_unique_products_session* aproximam o componente de *sensing*, por refletirem intensidade e diversidade da exploração. Por sua vez, *ratio_product_view* e *conversion_rate_session* aproximam, respectivamente, o foco comportamental da sessão e a capacidade de converter interesse em ação, fornecendo base empírica para o componente de *seizing*.

3.3 PRÉ-PROCESSAMENTO E PROCEDIMENTOS DE ANÁLISE

O tratamento dos dados foi executado em *Python*. O arquivo *ecommerce_clickstream_transactions.csv* foi importado mediante *pandas.read_csv()*, e os indicadores foram construídos por agregação dos registros em nível de sessão. Quanto à filtragem e à normalização, sessões compostas por um único evento foram excluídas para eliminar ruído comportamental (Bucklin & Sismeiro, 2009). As variáveis foram normalizadas

por *z-score*, mitigando o efeito de *outliers* e facilitando a comparação das cargas fatoriais, em conformidade com Hair et al., (2019). *Outliers* extremos, detectados pelo método do intervalo interquartil (IQR), foram avaliados e removidos quando atribuídos a erros sistêmicos de *logging* (Tukey, 1977).

As variáveis *Amount* e *Outcome*, embora presentes no arquivo, não foram empregadas diretamente na mensuração do construto HIPER nesta especificação. Do mesmo modo, a variável *Timestamp* foi mantida como metadado do evento, sem entrada direta no modelo reflexivo final, uma vez que a unidade de análise adotada foi a sessão identificada pelo par *UserID-SessionID*.

A análise estatística foi conduzida por meio de MEE reflexiva de fator único, estimada em *Python* com a biblioteca *semopy*. No *script*, a especificação do modelo foi definida em sintaxe de mensuração, seguida do ajuste por *Model.fit(panel)* e da inspeção dos parâmetros por *model.inspect()*. A biblioteca utilizada adota, por padrão, a função objetivo MLW e o *solver SLSQP*, além de permitir o cálculo de estatísticas globais de ajuste por meio da rotina *calc_stats()*.

A avaliação da qualidade da mensuração foi estruturada em quatro frentes. A primeira correspondeu à fatorabilidade da matriz de correlações, examinada por meio do índice *Kaiser-Meyer-Olkin (KMO)* e do teste de esfericidade de Bartlett. O KMO foi utilizado como diagnóstico preliminar de adequação amostral, enquanto o teste de Bartlett foi empregado para verificar se a matriz de correlações difere significativamente de uma matriz identidade. Consideraram-se, como referências operacionais, valores globais de KMO superiores a 0,60 e significância estatística no teste de Bartlett.

A segunda frente correspondeu à avaliação do modelo de mensuração. As cargas fatoriais foram examinadas quanto ao sinal, magnitude e significância estatística, adotando-se como referências valores superiores a 0,50, com preferência por cargas acima de 0,70. A consistência interna do construto foi avaliada pela confiabilidade composta, tomando-se 0,70 como referência mínima. A variância média extraída, quando reportada, foi interpretada à luz do patamar de 0,50 como evidência de validade convergente.

A terceira frente refere-se ao ajuste global do modelo, por meio de estatísticas como: qui-quadrado, CFI, TLI, RMSEA e SRMR. Para fins de interpretação, adotaram-se como referências operacionais CFI e TLI iguais ou superiores a 0,90, bem como RMSEA e SRMR inferiores a 0,08. Tais pontos de corte foram tratados como guias de avaliação, e não como regras mecânicas de aceitação.

A quarta frente concentrou-se na interpretação substantiva dos parâmetros estimados. Nesse ponto, a significância estatística das cargas não foi tomada isoladamente como evidência de robustez substantiva. Considerando que parte dos indicadores deriva de uma base operacional próxima, especialmente dos eventos *product_view*, a análise interpretativa passou a considerar também a heterogeneidade das magnitudes, a possibilidade de redundância informacional entre medidas e a coerência teórica entre indicador e construto.

4 ANÁLISE DOS RESULTADOS

4.1 CARACTERIZAÇÃO DA AMOSTRA ANALÍTICA

A base analisada reúne 74.817 registros de eventos, agregados em 10.000 sessões de navegação, correspondentes a 1.000 usuários. Em consonância com a estratégia metodológica adotada, a unidade analítica do estudo foi a sessão, operacionalizada pela combinação entre *UserID* e *SessionID*. A partir dessa agregação, foram construídos os quatro indicadores observados do construto HIPER, isto é, *n_product_view_session*, *n_unique_products_session*, *ratio_product_view* e *conversion_rate_session*.

Essa estrutura permite apreender diferentes manifestações comportamentais da navegação digital. Enquanto *n_product_view_session* e *n_unique_products_session* expressam, respectivamente, a intensidade e a amplitude da exploração de produtos ao longo da sessão, *ratio_product_view* capta o foco relativo da navegação em estímulos de produto, e *conversion_rate_session* procura refletir a efetividade da transformação da atenção em ação de maior valor, operacionalizada neste estudo pela adição de itens ao carrinho. Nessa configuração, o modelo estimado buscou verificar se esses indicadores convergem empiricamente para um único fator latente, interpretado como Potencial de Hiperpersonalização.

4.2 RESULTADOS DO MODELO DE MENSURAÇÃO

A estimação do modelo reflexivo de fator único indicou que todos os indicadores apresentaram associação positiva e estatisticamente significativa com o construto latente *HIPER*, conforme consta na Tabela 1.

Tabela 1
Parâmetros Estimados do Modelo de Mensuração do Construto HIPER

lval	op	rval	Estimate	Std. Err	z-value	p-value
<i>n_product_view_session</i>	~	HIPER	1	-	-	-
<i>n_unique_products_session</i>	~	HIPER	1,0150	0,0007	1.523,25	0
<i>ratio_product_view</i>	~	HIPER	0,1334	0,0009	141,57	0
<i>conversion_rate_session</i>	~	HIPER	0,1205	0,0077	15,61	0
HIPER	~~	HIPER	1,0382	0,0147	70,57	0
<i>conversion_rate_session</i>	~~	<i>conversion_rate_session</i>	0,6184	0,0087	70,71	0
<i>n_product_view_session</i>	~~	<i>n_product_view_session</i>	0,0017	0,0004	4,2674	1,98E-05
<i>n_unique_products_session</i>	~~	<i>n_unique_products_session</i>	0,0014	0,0004	3,3907	6,97E-04
<i>ratio_product_view</i>	~~	<i>ratio_product_view</i>	0,0092	0,0001	70,61	0

O indicador *n_product_view_session* foi adotado como referência para a escala do fator, com carga fixada em 1. Entre os indicadores estimados, *n_unique_products_session* apresentou a maior carga fatorial, de 1,01, erro-padrão de 0,00, estatística z de 1.523,25 e valor-p inferior a 0,001. A magnitude elevada de cargas reforça que a intensidade e a diversidade da exploração (*sensing*) constituem o núcleo central do Potencial de Hiperpersonalização, indicando que usuários com maior exposição a um leque amplo de produtos são os que mais engajam com os fundamentos mensurados pelo construto, alinhando-se com a literatura de personalização algorítmica (Micu et al., 2022).

Em seguida, *ratio_product_view* apresentou carga de 0,13, erro-padrão de 0,00, estatística z de 141,57 e valor-p inferior a 0,001. *Conversion_rate_session* apresentou carga de 0,12, erro-padrão de 0,00, estatística z de 15,60 e valor-p inferior a 0,001.


Este padrão é teoricamente coerente e demonstra sua atribuição complementar e distinta na mensuração do construto HIPER. O primeiro atua como refinamento da qualidade do *sensing*, enquanto o segundo aproxima empiricamente aspectos comportamentais relacionados ao *seizing*, entendido como a transformação do interesse em ações de maior valor ao longo da jornada digital.

A significância e a direção positiva de todas as cargas fatoriais validam a convergência ao construto HIPER, conforme os critérios estabelecidos por Hair et al. (2019), todavia, a magnitude das cargas não é homogênea, o que exige interpretação cautelosa e orientada.

4.3 HETEROGENEIDADE DAS CARGAS E INTERPRETAÇÃO SUBSTANTIVA

Para complementar a interpretação estatística dos resultados, a Figura 2 apresenta o Diagrama de Caminhos do modelo ajustado. Esse diagrama sintetiza, de modo visual, a estrutura relacional entre *HIPER* e os seus indicadores comportamentais, organizados conforme sua vinculação teórica aos processos de *sensing* e *seizing*.

Figura 2
Diagrama de Caminhos do Modelo de Mensuração do Construto HIPER



No diagrama, observa-se que as setas partem do fator latente HIPER e convergem para cada um dos indicadores, expondo a natureza reflexiva do modelo. Os coeficientes apresentados nas setas representam as cargas fatoriais padronizadas, confirmando estatisticamente a força da associação entre o fator e cada indicador. Todas as cargas são positivas e significativas (p-valor = 0,00), consistente com os resultados tabulares.

A distribuição das cargas fatoriais sugere que o construto HIPER, tal como operacionalizado neste estudo, é mais fortemente capturado pelos indicadores associados à exploração de produtos do que pelos indicadores relacionados ao foco da sessão e à conversão. Isso se evidencia no contraste entre carga de *n_unique_products_session* e cargas substancialmente menores de *ratio_product_view* e *conversion_rate_session*.

Em termos analíticos, esse padrão sugere que a dimensão empírica dominante do construto está concentrada no comportamento exploratório do usuário, sobretudo na variedade de produtos visualizados ao longo da sessão. Assim, a medida latente proposta parece refletir, com maior intensidade, o componente de *sensing* associado à exploração, ao monitoramento e à ampliação do contato com estímulos de produto. Já os indicadores mais próximos do componente de *seizing*, especialmente *conversion_rate_session*, embora significativos, exibiram menor intensidade de associação com o fator comum.

Esse achado é teoricamente coerente com a formulação do estudo, na medida em que a hiperpersonalização depende, primeiramente, da capacidade de captar e organizar sinais comportamentais do usuário. Ao mesmo tempo, ele indica que a operacionalização empírica

do construto privilegia mais fortemente a faceta exploratória da navegação do que a faceta decisória ou de conversão.

4.4 PRECISÃO ESTATÍSTICA E CAUTELAS INTERPRETATIVAS

Os valores de z observados, especialmente para *n_unique_products_session* e *ratio_product_view*, são extremamente elevados. Embora isso reforce a significância estatística dos parâmetros, tais magnitudes não devem ser interpretadas automaticamente como evidência de robustez substantiva superior. Como parte dos indicadores deriva de uma base operacional próxima, notadamente dos eventos *product_view*, é plausível que exista elevada regularidade estatística entre algumas medidas, com consequente redução dos erros-padrão e ampliação das estatísticas z .

Nesse sentido, o resultado empírico deve ser interpretado com sobriedade. O modelo oferece evidência de associação estatística consistente entre os indicadores e o construto HIPER, mas isso não elimina a possibilidade de sobreposição informacional entre variáveis oriundas do mesmo núcleo comportamental. Em vez de sugerir validade plena e definitiva da estrutura proposta, os resultados devem ser lidos como evidência inicial favorável à mensuração do construto, ainda sujeita a refinamentos.

4.5 VARIÂNCIAS ESTIMADAS E QUALIDADE DA MENSURAÇÃO

No que se refere às variâncias estimadas, a variância do fator latente HIPER foi positiva e estatisticamente significativa, indicando variabilidade suficiente do construto no conjunto das sessões analisadas. As variâncias residuais dos indicadores também foram positivas e significativas, o que sugere que, embora o fator comum explique parcela relevante da covariação entre as medidas, persiste componente residual não desprezível em cada indicador.

Em particular, *conversion_rate_session* apresentou variância residual de 0,61, indicando que parcela importante de sua variabilidade não é absorvida pelo fator latente comum. Isso é coerente com a própria natureza do indicador, mais sensível a aspectos contextuais e comportamentais de cada sessão. *Ratio_product_view* apresentou variância residual de 0,00, ao passo que *n_product_view_session* e *n_unique_products_session* exibiram variâncias residuais menores, ainda que estatisticamente significativas. Em conjunto, tais resultados reforçam a interpretação de que o modelo capta um fator comum plausível, mas não esgota a complexidade dos comportamentos observados.

4.6 SÍNTESE DOS ACHADOS

De forma agregada, os resultados firmam a proposição de que padrões observáveis de navegação e interação em ambiente de *e-commerce* podem ser adotados para mensurar empiricamente o Potencial de Hiperpersonalização. A convergência estatística entre os quatro indicadores e o fator latente HIPER sugere que o construto tem aderência empírica inicial, especialmente quando operacionalizado por medidas de exploração de produtos em nível de sessão.

Ao mesmo tempo, a heterogeneidade das cargas fatoriais indica que os indicadores não contribuem de maneira uniforme para a composição empírica do fator comum. O modelo, portanto, deve ser interpretado como uma prova de conceito de mensuração, e não como estrutura definitiva e exaustiva do fenômeno. Essa conclusão é relevante porque preserva a contribuição central do estudo, a transformação de um conceito estratégico abstrato em

construto empiricamente observável, sem extrapolar o alcance dos resultados efetivamente obtidos.

5 DISCUSSÃO DOS RESULTADOS

Os resultados indicam que padrões de navegação registrados em dados de *clickstream* podem ser utilizados para operacionalizar empiricamente dimensões comportamentais associadas à personalização orientada por dados em ambientes digitais.

A convergência estatística entre os indicadores observados e o construto latente HIPER sugere que métricas derivadas de interações digitais capturam sinais comportamentais sobre a forma como usuários exploram informações e respondem a estímulos de produto ao longo da jornada de compra. Esses achados dialogam com estudos que apontam o potencial dos registros de *clickstream* para compreender processos de decisão do consumidor em contextos *online* (Kaptein & Eckles, 2012; Micu et al., 2022).

Os indicadores relacionados à intensidade e à diversidade de visualizações de produtos apresentaram as maiores associações com o construto latente. Esses resultados indicam que a exploração de produtos constitui uma dimensão predominante dos padrões comportamentais capturados pelo modelo

Em termos analíticos, esse comportamento pode ser interpretado como um sinal da ampliação do contato do usuário com diferentes estímulos de produto ao longo da navegação. Na literatura de marketing digital, esse tipo de comportamento tem sido associado à fase exploratória da jornada do consumidor, na qual diferentes alternativas são avaliadas antes da tomada de decisão (Bucklin & Sismeiro, 2009; Moe, 2003).

A predominância desses indicadores também dialoga com a perspectiva das capacidades dinâmicas. Na formulação proposta por Teece (2007), o processo de *sensing* envolve a identificação e interpretação de sinais do ambiente. No contexto digital, esses sinais podem emergir das interações registradas em plataformas *online*, nas quais padrões de navegação revelam preferências, interesses e trajetórias de busca dos consumidores.

Nesse sentido, a intensidade e a diversidade de visualizações de produtos podem ser interpretadas como manifestações comportamentais associadas à geração de informações para processos analíticos.

Os indicadores associados ao foco da navegação e à conversão também apresentaram associação positiva com o construto, embora com magnitudes inferiores às observadas para as métricas de exploração. Esse padrão sugere que, embora o comportamento exploratório represente a dimensão com maior carga fatorial no modelo, a transformação da atenção em ação também integra os padrões comportamentais capturados pelo modelo.

A literatura sobre jornada do cliente destaca que a conversão representa um estágio posterior do processo decisório, no qual interações acumuladas ao longo da navegação podem se traduzir em comportamentos associados à decisão de compra, como a adição de produtos ao carrinho ou a realização de compras (Lemon & Verhoef, 2016).

A heterogeneidade das cargas fatoriais indica que diferentes manifestações comportamentais contribuem de forma distinta para a mensuração do construto HIPER. Os indicadores de exploração capturam com maior intensidade a dimensão informacional da navegação, enquanto os indicadores de foco e conversão refletem etapas posteriores do processo decisório. Esse padrão sugere que o construto está mais fortemente associado à fase exploratória da interação do usuário, sem deixar de incorporar elementos relacionados à efetividade da navegação.

Do ponto de vista metodológico, os resultados reforçam a utilidade da Modelagem de Equações Estruturais para operacionalizar construtos latentes derivados de dados comportamentais digitais. O modelo reflexivo de fator único permitiu integrar diferentes manifestações observáveis da navegação em uma estrutura analítica comum, consistente com abordagens que utilizam indicadores observáveis para mensurar fenômenos latentes em pesquisas organizacionais e de marketing (Fornell & Larcker, 1981; Diamantopoulos & Siguaw, 2006).

Em termos teóricos, os achados aproximam a literatura sobre personalização digital da perspectiva das capacidades dinâmicas ao sugerir que padrões de interação registrados em ambientes digitais podem ser interpretados como fontes de informação relevantes para compreender processos organizacionais baseados em dados.

6 CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo propor e testar um modelo empírico para mensurar o Potencial de Hiperpersonalização (HIPER) em ambientes de *e-commerce*. Para isso, foi estimado um modelo de equações estruturais reflexivo de fator único aplicado a indicadores comportamentais derivados de dados de *clickstream*, incluindo intensidade de visualizações, diversidade de produtos explorados, proporção de visualizações e taxa de conversão.

Os resultados indicam que padrões de navegação registrados em dados de *clickstream* podem funcionar como indicadores empíricos do potencial informacional associado à hiperpersonalização em ambientes digitais. Indicadores relacionados à intensidade e à diversidade da exploração de produtos apresentaram maior associação com o construto latente, enquanto métricas relacionadas ao foco da navegação e à conversão contribuíram de forma complementar para sua mensuração.

Sob a perspectiva da estratégia organizacional, os resultados sugerem que padrões comportamentais observados em ambientes digitais podem funcionar como sinais associados aos processos de detecção (*sensing*) e exploração (*seizing*) de oportunidades descritos na literatura de capacidades dinâmicas (Teece, 2007; Eisenhardt & Martin, 2000). Nesse sentido, o estudo aproxima dados comportamentais derivados de interações digitais da literatura de capacidades dinâmicas e da personalização baseada em dados.

Do ponto de vista teórico, a pesquisa contribui ao aproximar dados comportamentais e teoria das capacidades dinâmicas. Do ponto de vista metodológico, demonstra o uso de dados de *clickstream* como base empírica para a construção de indicadores de um construto latente derivado de padrões comportamentais observados em ambientes digitais.

O estudo apresenta limitações relacionadas à disponibilidade e nível de detalhamento dos dados de *clickstream* utilizados, bem como ao fato de a análise ter sido realizada em um único ambiente de *e-commerce*, o que delimita a generalização dos achados. Pesquisas futuras podem ampliar a análise incluindo variáveis contextuais, métricas de engajamento após a conversão e indicadores de fidelização, além de testar o modelo em diferentes plataformas e segmentos.

Outro ponto refere-se aos efeitos da curadoria algorítmica sobre os padrões de interação observados nas plataformas digitais. Embora não mensurados neste estudo, sistemas de recomendação podem influenciar a exposição a conteúdos e produtos, levantando questões relacionadas à autonomia e à diversidade de escolhas do consumidor (Shin, Rasul & Fotiadis, 2022). Pesquisas futuras também podem explorar aspectos éticos e regulatórios da personalização baseada em dados, incluindo governança de dados, transparência algorítmica e privacidade.

Por fim, os dados de *clickstream* permitem observar padrões de interação que funcionam como sinais para processos de *sensing* e *seizing*, contribuindo para compreender o potencial de hiperpersonalização em ambientes digitais orientados por dados.

REFERÊNCIAS

- Albannai, N. A., Raziq, M. M., Malik, M., Scott-Kennel, J., & Igoè, J. (2024). Unraveling the role of digital leadership in developing digital dynamic capabilities for the digital transformation of firms. *Benchmarking: An International Journal*, 32(6), 2250-2275. <https://doi.org/10.1108/BIJ-10-2023-0756>
- Barney, J. B., & Hesterly, W. S. (2007). *Administração estratégica e vantagem competitiva*. Pearson Prentice Hall.
- Berry, L. L. (1983). Relationship marketing. In L. L. Berry, G. L. Shostack, & G. D. Upah (Eds.), *Emerging perspectives on services marketing* (pp. 25–28). American Marketing Association.
- Bleier, A., de Keyser, A., & Verleye, K. (2017). Customer engagement through personalization and customization. In R. J. Brodie, L. D. Hollebeek, & J. Conduit (Eds.), *Customer engagement marketing* (pp. 75-94). Springer International Publishing. https://doi.org/10.1007/978-3-319-61985-9_4
- Bucklin, R. E., & Sismeiro, C. (2009). Click here for internet insight: advances in clickstream data analysis in marketing. *Journal of Interactive Marketing*, 23(1), 35–48. <https://doi.org/10.1016/j.intmar.2008.10.004>
- Bucklin, R., Lattin, J., Ansari, A., Gupta, S., Bell, D., Coupey, E., Little, J., Mela, C., Montgomery, A., & Steckel, J. (2002). Choice and the Internet: From Clickstream to Research Stream. *Marketing Letters*, 13, 245-258. <https://doi.org/10.1023/a:1020231107662>
- Buiak, L., Shynkaryk, M., Semenenko, Y., & Pryshliak, K. (2024, September). *Optimization of marketing department activities using machine learning technologies*. In 2024 14th International Conference on Advanced Computer Information Technologies (ACIT) (pp. 293-298). IEEE. <https://doi.org/10.1109/ACIT62333.2024.10712551>
- Chandra, S., Verma, S., Lim, W. M., Kumar, S., & Donthu, N. (2022). Personalization in personalized marketing: Trends and ways forward. *Psychology & marketing*, 39(8), 1529-1562. <https://doi.org/10.1002/mar.21670>
- Dahake, P. S., Mohare, R. V., & Somani, N. (2023, August). *Exploring machine learning's potential in predicting consumer behavior for captivating marketing*. In 2023 Second International Conference on Smart Technologies for Smart Nation (SmartTechCon) (pp. 1347-1352). IEEE. <https://doi.org/10.1109/SmartTechCon57526.2023.10391558>

- Davenport, T. H. (2023). Hyper-personalization for customer engagement with Artificial Intelligence. *Management and Business Review*, 3(1-2), 29-36. <https://ssrn.com/abstract=4585804>
- Davis, S. M. (1987). *Future perfect*. Addison-Wesley.
- Diamantopoulos, A., & Siguaw, J. A. (2006). Formative versus reflective indicators in organizational measure development: A comparison and empirical illustration. *British Journal of Management*, 17(4), 263–282. <https://doi.org/10.1111/j.1467-8551.2006.00500.x>
- Ellström, D., Holtström, J., Berg, E., & Josefsson, C. (2022). Dynamic capabilities for digital transformation. *Journal of Strategy and Management*, 15(2), 272–286. <https://doi.org/10.1108/JSMA-04-2021-0089>
- Eisenhardt, K. M., & Martin, J. A. (2000). Dynamic capabilities: What are they? *Strategic Management Journal*, 21(10–11), 1105–1121. [https://doi.org/10.1002/1097-0266\(200010/11\)21:10/11<1105::AID-SMJ133>3.0.CO;2-E](https://doi.org/10.1002/1097-0266(200010/11)21:10/11<1105::AID-SMJ133>3.0.CO;2-E)
- Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), 39–50. <https://doi.org/10.2307/3151312>
- Gomes, M. A., & Meisen, T. (2023). A review on customer segmentation methods for personalized customer targeting in e-commerce use cases. *Information Systems and e-Business Management*, 21(3), 527–570. <https://doi.org/10.1007/s10257-023-00640-4>
- Guendouz, T. (2024). Artificial intelligence-powered customer experience management (moving from mass to hyper-personalization in light of relationship marketing). *International Journal for Scientific Research*, 3(6), 247–306. <https://doi.org/10.59992/IJSR.2024.v3n6p9>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage Learning EMEA.
- Hitt, M. A. Ireland, & Hoskisson.(2017). *Strategic Management Competitiveness & Globalization: Concept and cases*. Cengage Learning.
- Jain, G., Paul, J., & Shrivastava, A. (2021). Hyper-personalization, co-creation, digital clienteling and transformation. *Journal of Business Research*, 124, 12–23. <https://doi.org/10.1016/j.jbusres.2020.11.034>
- Kagan, S., & Bekkerman, R. (2018). Predicting Purchase Behavior of Website Audiences. *International Journal of Electronic Commerce*, 22, 510 - 539. <https://doi.org/10.1080/10864415.2018.1485084>

- Kannan, P. K., & Li, H. (2017). Digital marketing: A framework, review and research agenda. *International Journal of Research in Marketing*, 34(1), 22–45.
<https://doi.org/10.1016/j.ijresmar.2016.11.006>
- Kaptein, M., & Eckles, D. (2012). Heterogeneity in the effects of online persuasion. *Journal of Interactive Marketing*, 26(3), 176–188.
<https://doi.org/10.1016/j.intmar.2012.02.002>
- Kotler, P., & Keller, K. L. (2016). *Marketing management* (15th ed.). Pearson.
- Laudon, K. C., & Traver, C. G. (2024). *E-commerce 2023–2024: Business, Technology, Society* (18th ed.). Global Edition.
- 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>
- Liu, D., Huang, H., Zhang, H., Luo, X., & Fan, Z. (2024). Enhancing customer behavior prediction in e-commerce: A comparative analysis of machine learning and deep Learning models. *Applied and Computational Engineering*, 55(1), 181–195.
<https://doi.org/10.54254/2755-2721/55/20241475>
- Mahajan, R., Kumar, S., Lim, W. M., & Sareen, M. (2024). The role of business and management in driving the sustainable development goals (SDGs): Current insights and future directions from a systematic review. *Business Strategy and the Environment*, 33(5), 4493–4529. <https://doi.org/10.1002/bse.3712>
- Micu, A., Capatina, A., Cristea, D. S., Munteanu, D., Micu, A. E., & Sarpe, D. A. (2022). Assessing an on-site customer profiling and hyper-personalization system prototype based on a deep learning approach. *Technological Forecasting and Social Change*, 174, 121289. <https://doi.org/10.1016/j.techfore.2021.121289>
- Mikalef, P., & Krogstie, J. (2020). Examining the interplay between big data analytics and contextual factors in driving process innovation capabilities. *European Journal of Information Systems*, 20(3), 260–287.
<https://doi.org/10.1080/0960085X.2020.1740618>
- Moe, W. W. (2003). Buying, searching, or browsing: Differentiating between online shoppers using in-store navigational clickstream. *Journal of consumer psychology*, 13(1-2), 29–39. https://doi.org/10.1207/S15327663JCP13-1&2_03
- Montgomery, A. L., Li, S., Srinivasan, K., & Liechty, J. C. (2004). Modeling online browsing and path analysis using clickstream data. *Marketing Science*, 23(4), 579–595.
<https://doi.org/10.1287/mksc.1040.0073>
- Nandy, M., & Kirit, D. D. (2025). *Big data-driven customer experience in e-commerce: Personalizing user journeys with advanced analytics*. In 2025 International

- Conference on Automation and Computation (AUTOCOM) (pp. 1363–1367). IEEE. <https://doi.org/10.1109/AUTOCOM60220.2025.10957405>
- Narayana, L., & Koralla, G. (2025). Hyper-personalization: Transforming digital experiences through advanced data analytics and AI. *World Journal of Advanced Engineering Technology and Sciences*, 15(01), 333-345. <https://doi.org/10.30574/wjaets.2025.15.1.0219>
- Nguyen, D. N., Nguyen, V. H., Trinh, T., Ho, T., & Le, H. S. (2024). A personalized product recommendation model in e-commerce based on retrieval strategy. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(2), 100303. <https://doi.org/10.1016/j.joitmc.2024.100303>
- Olbrich, R., & Holsing, C. (2011). Modeling Consumer Purchasing Behavior in Social Shopping Communities with Clickstream Data. *International Journal of Electronic Commerce*, 16, 15 - 40. <https://doi.org/10.2753/jec1086-4415160202>
- Pal, G., Atkinson, K., & Li, G. (2021). Real-time user clickstream behavior analysis based on apache storm streaming. *Electronic Commerce Research*, 23, 1829-1859. <https://doi.org/10.1007/s10660-021-09518-4>
- Pappas, I. O. (2018). User experience in personalized online shopping: A fuzzy-set analysis. *European Journal of Marketing*, 52(7/8), 1679–1703. <https://doi.org/10.1108/EJM-10-2017-0707>
- Patnaik, J., & Bhowmick, B. (2022). Determining appropriateness for management of appropriate technology: An empirical study using factor analysis. *Technology Analysis and Strategic Management*, 34(2), 125–137. <https://doi.org/10.1080/09537325.2021.1890013>
- Peelen, E., Ekelmans, C. F. W., & Vijn, P. (1989). Direct marketing for establishing the relationships between buyers and sellers. *Journal of Direct Marketing*, 3(1), 7–14. <https://doi.org/10.1002/dir.4000030104>
- Peppers, D., & Rogers, M. (1993). *The one to one future: Building relationships one customer at a time*. Currency Doubleday.
- Penrose, E. T. (1959). *The theory of the growth of the firm*. Basil Blackwell.
- Pine, B. J. (1993). *Mass customization: The new frontier in business competition*. Harvard Business School Press.
- Pukas, A. (2022). Hyper-personalization as a customer relationship management tool in a SMART organization. *Problemy Zarządzania - Management Issues*, 20(3), 95–108. <https://doi.org/10.7172/1644-9584.97.5>
- Raji, M., Olodo, H., Oke, T., Addy, W., Ofodile, O., & Oyewole, A. (2024). E-commerce and consumer behavior: A review of AI-powered personalization and market trends. *GSC*

Advanced Research and Reviews, 18(03), 066–077.

<https://doi.org/10.30574/gscarr.2024.18.3.0090>

- Rane, N., Choudhary, S., & Rane, J. (2023). Hyper-personalization for enhancing customer loyalty and satisfaction in Customer Relationship Management (CRM) systems. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4641044>
- Raphaeli, O., Goldstein, A., & Fink, L. (2017). Analyzing online consumer behavior in mobile and PC devices: A novel web usage mining approach. *Electron. Commer. Res. Appl.*, 26, 1-12. <https://doi.org/10.1016/j.elerap.2017.09.003>
- Rocheftort, T., & Ndlovu, Z. (2024). Digital marketing strategies in building brand awareness and loyalty in the online era. *Startupreneur Business Digital (Sabda Journal)*, 3(2), 107-114. <https://doi.org/10.33050/sabda.v3i2.539>
- Sakar, C., Polat, S., Katircioglu, M., & Kastro, Y. (2018). Real-time prediction of online shoppers' purchasing intention using multilayer perceptron and LSTM recurrent neural networks. *Neural Computing and Applications*, 31, 6893 - 6908. <https://doi.org/10.1007/s00521-018-3523-0>
- Sheth, J. N., & Parvatiyar, A. (1995). The evolution of relationship marketing. *International Business Review*, 4(4), 397–418. [https://doi.org/10.1016/0969-5931\(95\)00018-6](https://doi.org/10.1016/0969-5931(95)00018-6)
- Shin, D., Rasul, A., & Fotiadis, A. (2022). Why am I seeing this? Deconstructing algorithm literacy through the lens of users. *Internet Research*, 32(4), 1214–1234. <https://doi.org/10.1108/INTR-02-2021-0087>
- Sipos, D. (2024). Harnessing artificial intelligence for hyper-personalization in digital marketing: A comparative analysis of predictive models and consumer behavior. *Technium Business and Management*, 9, 47–55. <https://doi.org/10.47577/business.v9i.11724>
- Smith, W. R. (1956). Product differentiation and market segmentation as alternative marketing strategies. *Journal of Marketing*, 21(1), 3–8. <https://doi.org/10.1177/002224295602100102>
- Srivastav, M. (2025). Hyper-Personalization in Marketing Campaigns: Is It Going Too Far?. *International Journal For Multidisciplinary Research*. <https://doi.org/10.36948/ijfmr.2025.v07i05.54845>
- Schweidel, D., Bart, Y., Inman, J., Stephen, A., Libai, B., Andrews, M., Rosario, A., Chae, I., Chen, Z., Kupor, D., Longoni, C., & Thomaz, F. (2022). How consumer digital signals are reshaping the customer journey. *Journal of the Academy of Marketing Science*, 50, 1257 - 1276. <https://doi.org/10.1007/s11747-022-00839-w>

- Su, Q., & Chen, L. (2015). A method for discovering clusters of e-commerce interest patterns using click-stream data. *Electron. Commer. Res. Appl.*, 14, 1-13. <https://doi.org/10.1016/j.elerap.2014.10.002>
- Sun, W., Chen, K., & Mei, J. (2024). Integrating the resource-based view and dynamic capabilities: a comprehensive framework for sustaining competitive advantage in dynamic markets. *EPRA International Journal of Economic and Business Review*. <https://doi.org/10.36713/epra18157>
- Teece, D. J. (2007). Explicating dynamic capabilities: The nature and microfoundations of (sustainable) enterprise performance. *Strategic Management Journal*, 28(13), 1319–1350. <https://doi.org/10.1002/smj.640>
- Teece, D. J., Pisano, G., & Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic Management Journal*, 18(7), 509–533. [https://doi.org/10.1002/\(SICI\)1097-0266\(199708\)18:7<509::AID-SMJ882>3.0.CO;2-Z](https://doi.org/10.1002/(SICI)1097-0266(199708)18:7<509::AID-SMJ882>3.0.CO;2-Z)
- Thirumagal, P. G., Bhattacharjee, K., Dorbala, R., Palav, M. R., S, V., & Mahajan, V. (2024). *Application of machine learning algorithms in personalized marketing*. In 2024 5th International Conference on Recent Trends in Computer Science and Technology (ICRTCST) (pp. 165–170). IEEE. <https://doi.org/10.1109/ICRTCST61793.2024.10578463>
- Tokuç, A. A., & Dag, T. (2025). Predicting user purchases from clickstream data: A comparative analysis of clickstream data representations and machine learning models. *IEEE Access*, 13, 43796–43817. <https://doi.org/10.1109/ACCESS.2025.3548267>
- Tukey, J. W. (1977). *Exploratory data analysis*. Addison-Wesley.
- Valdez Mendia, J. M., & Flores-Cuautle, J. J. A. (2022). Toward customer hyper-personalization experience - A data-driven approach. *Cogent Business & Management*, 9(1), 2041384. <https://doi.org/10.1080/23311975.2022.2041384>
- Vesonen, J., & Raulas, M. (2006). Building bridges for personalization: A process model for marketing. *Journal of Interactive Marketing*, 20(1), 5–20. <https://doi.org/10.1002/dir.20052>

- Wang, G., Zhang, X., Tang, S., Wilson, C., Zheng, H., & Zhao, B. (2017). Clickstream User Behavior Models. *ACM Transactions on the Web (TWEB)*, 11 (4), 1 - 37. <https://doi.org/10.1145/3068332>
- Wang, T.-C. (2024). Deep learning-based prediction and revenue optimization for online platform user journeys. *Quantitative Finance and Economics*, 8(1), 1–28. <https://doi.org/10.3934/QFE.2024001>
- Warner, K. S., & Wäger, M. (2019). Building dynamic capabilities for digital transformation: An ongoing process of strategic renewal. *Long Range Planning*, 52(3), 326–349. <https://doi.org/10.1016/j.lrp.2018.12.001>
- Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97–121. <https://doi.org/10.1509/jm.15.0413>
- Wernerfelt, B. (1984). A resource-based view of the firm. *Strategic Management Journal*, 5(2), 171–180. <https://doi.org/10.1002/smj.4250050207>
- Zhou, S., & Hudin, N. S. (2024). Advancing e-commerce user purchase prediction: Integration of time-series attention with event-based timestamp encoding and Graph Neural Network-Enhanced user profiling. *PLOS ONE*, 19(4), e0299087. <https://doi.org/10.1371/journal.pone.0299087>