



XVI FATECLOG
FATEC CARAPICUÍBA
CARAPICUÍBA/SP - BRASIL
13 E 14 DE JUNHO DE 2025



MACHINE LEARNING E ECR: TRANSFORMANDO A PREVISÃO DE DEMANDA NO VAREJO

HENRIQUE PASSOS DA CONCEIÇÃO (FATEC ZONA SUL)
henrique.ferreira22@fatec.sp.gov.br

VITORIA CRISTINA SANTOS DA SILVA (FATEC ZONA SUL)
vitoria.silva83@fatec.sp.gov.br

YURI PASSOS DA CONCEIÇÃO (FATEC ZONA SUL)
yuri.ferreira01@fatec.sp.gov.br

Orientador
PROF.DR. MOACIR DE FREITAS JUNIOR (FATEC ZONA SUL)
moacir.junior@fatec.sp.gov.br

RESUMO

O presente artigo explora a previsão de demanda no varejo, destacando sua importância estratégica para a gestão eficiente de estoques e a satisfação do consumidor. A pesquisa classifica-se como de natureza exploratória e descritiva, com abordagem qualitativa, fundamentada em revisão bibliográfica e análise de estudos de caso. O estudo investigou o potencial do *Machine Learning* na melhoria da precisão preditiva juntamente ao modelo *Efficient Consumer Response* (ECR), que promove a colaboração entre fabricantes, distribuidores e varejistas para otimizar a cadeia de suprimentos. A integração entre ambas as abordagens possibilita respostas mais ágeis às variações da procura, reduzindo estoques excessivos e minimizando rupturas. Foram analisadas abordagens como Redes Neurais Artificiais, especialmente as *LSTM* (Long Short-Term Memory), além de técnicas como árvores de decisão, *random forests* e *gradient boosting*, reconhecidas por sua eficiência na previsão de consumo. Os resultados indicam que a adoção dessas tecnologias aumenta a capacidade das empresas de antecipar tendências, reduzindo desperdícios e melhorando a eficiência operacional. Contudo, sua implementação requer investimentos em tecnologia, qualificação profissional e processos robustos de coleta e tratamento de dados. Assim, a combinação de *Machine Learning* com ECR representa um avanço significativo na gestão da cadeia de suprimentos, tornando as empresas mais competitivas no setor varejista.

PALAVRAS-CHAVE: Previsão de demanda; *Machine Learning*; Cadeia de suprimentos.

ABSTRACT

This article explores demand forecasting in retail, highlighting its strategic importance for efficient inventory management and customer satisfaction. The research is classified as exploratory and descriptive in nature, with a qualitative approach, based on bibliographic review and case study analysis. The study is classified as exploratory and descriptive research, with a qualitative approach based on a literature review. The research investigates the potential of Machine Learning (ML) to improve predictive accuracy in conjunction with the Efficient Consumer Response (ECR) model, which promotes collaboration between manufacturers, distributors, and retailers to optimize the supply chain. The integration of both allows for faster responses to demand fluctuations, reducing excess inventory and minimizing stockouts. Approaches such as Artificial Neural Networks (ANN), particularly Long Short-Term Memory (LSTM) networks, along with techniques like decision trees, random forests, and gradient boosting, recognized for their efficiency in consumption forecasting, were analyzed. The results indicate that the adoption of these technologies enhances companies' ability to anticipate trends, reduce waste, and improve operational efficiency. However, their implementation requires investments in technology, professional training, and robust data collection and processing systems. Thus, the combination of ML with ECR represents a significant advancement in supply chain management, making companies more competitive in the retail sector.

KEYWORDS: Demand Forecasting; Machine Learning, Supply Chain.

XVI FATECLOG – O papel da Inteligência Artificial nas Operações Logísticas
FATEC CARAPICUÍBA
CARAPICUÍBA/SP - BRASIL

1. INTRODUÇÃO

Armstrong e Green (2015) afirmam que o cenário atual do varejo, caracterizado por um ambiente altamente dinâmico e competitivo, faz com que o prognóstico de demanda torne-se uma atividade estratégica essencial para a gestão eficiente dos estoques e para a satisfação dos clientes. O comportamento dos consumidores é influenciado por uma série de fatores, como sazonalidade, tendências de mercado, variações econômicas e mudanças no perfil de consumo. Diante dessas variáveis, prever a necessidade com precisão se torna um desafio significativo para as empresas do setor, exigindo o uso de abordagens mais avançadas para reduzir incertezas e melhorar a tomada de decisões.

Este estudo foi desenvolvido com uma abordagem qualitativa e quantitativa, utilizando pesquisa bibliográfica e análise de dados para avaliar a eficácia da aplicação do *Machine Learning* na previsão de consumo dentro do modelo de *Efficient Consumer Response*. De acordo com pensamento de Gil (2006) as pesquisas quantitativas consideram que tudo possa ser contável, ou seja, que seja gerado informações a partir de números para assim classificá-los e analisá-los, já as qualitativas consistem em coletas de dados por meio de observação, relato, entrevista e outros, por meio de uma dinâmica entre o mundo e o sujeito, não traduzida por números. Foram utilizadas referências acadêmicas, estudos de caso e dados de empresas que implementaram essas tecnologias, com o objetivo de compreender as melhores práticas e os desafios enfrentados.

A pesquisa exploratória visa proporcionar maior familiaridade com o tema, permitindo aprofundar o conhecimento. Conforme Gil (2002), esse tipo de pesquisa busca identificar, analisar e sistematizar as contribuições teóricas já publicadas sobre determinado fenômeno, utilizando-se de materiais previamente elaborados, como livros, artigos científicos e relatórios técnicos.

Para a elaboração do artigo foi desenvolvida a partir da análise de fontes primárias e secundárias, considerando literatura acadêmica nacional e internacional, com foco nos desafios e benefícios da adoção de técnicas avançadas de vaticínio, como redes neurais com ênfase em *LSTM*, árvores de decisão e métodos de conjunto (ex.: *Random Forest* e *XGBoost*.) A revisão teórica foi complementada por estudos de caso documentados, que evidenciam a aplicação prática dessas ferramentas no contexto varejista, sobretudo no que tange à redução de ineficiências logísticas, aprimoramento do nível de serviço e aumento da assertividade nas decisões de reposição de estoque. A escolha por essa abordagem justifica-se pela necessidade de aprofundamento teórico sobre as transformações na logística varejista frente ao *digital supply chain*.

Conforme Dekker, Et al. (2004), um cálculo impreciso pode resultar em dois problemas críticos para o comércio varejista: o excesso de estoque ou a falta de produtos disponíveis. O excesso de estoque acarreta custos elevados de armazenagem, deterioração de produtos e riscos de obsolescência, além de comprometer o capital de giro da empresa. Por outro lado, a escassez de produtos pode levar à perda de vendas, insatisfação dos consumidores e até mesmo à migração de clientes para concorrentes. Encontrar um equilíbrio eficiente na predição no volume de compra é fundamental para garantir a competitividade e a sustentabilidade do mercado varejista.

Finlay (2014) afirma que os avanços tecnológicos permitiram o desenvolvimento de abordagens inovadoras, como o uso de algoritmos de aprendizado de máquina para a estimativa de comercialização. Essa ferramenta possibilita a análise de grandes volumes de dados históricos, identificando padrões e tendências de maneira mais eficaz do que métodos tradicionais de antecipação. Diferentemente das abordagens estatísticas convencionais, que frequentemente assumem relações lineares entre variáveis, os algoritmos de aprendizado de máquina são capazes de capturar padrões não lineares e adaptar-se a mudanças no

comportamento do consumidor ao longo do tempo. Brownlee (2016) corrobora ao dizer que permite que as empresas façam previsões mais precisas, reduzindo erros e melhorando a eficiência operacional.

Segundo Eaves e Kingsman (2004) o *Efficient Consumer Response* fomenta que o objetivo da ferramenta é garantir que os produtos certos estejam disponíveis nos locais corretos e no momento adequado, eliminando ineficiências e melhorando o fluxo de mercadorias na cadeia de suprimentos. Junto ao uso da aprendizagem da máquina, a implementação do conceito de resposta eficiente ao consumidor tem se mostrado uma estratégia de fato eficiente na otimização da cadeia de suprimentos. Sendo então um sistema colaborativo que visa integrar fabricantes, distribuidores e varejistas para melhorar a resposta às necessidades dos consumidores, reduzindo custos operacionais e aumentando a eficiência logística.

Aastrup, J. Et al. (2008) afirmam que a combinação dessas duas abordagens, aprendizado de máquina e *ECR* representa um avanço significativo na forma como a cadeia de suprimentos do varejo pode ser gerida. Enquanto o aprendizado de máquina aprimora a precisão das previsões de consumo, permitindo ajustes estratégicos e operacionais mais assertivos, enquanto o outro assegura que toda a cadeia esteja alinhada para responder de forma eficiente a essas previsões. Essa integração proporciona benefícios como a redução de custos com estoques, a diminuição de rupturas e sobras de produtos, além da melhoria na experiência do consumidor final.

2. EMBASAMENTO TEÓRICO

2.1 PROJEÇÃO DE DEMANDA E SUA IMPORTÂNCIA NO VAREJO

De acordo com Armstrong e Green (2015), a estimativa de demanda refere-se ao processo de estimar a quantidade de bens ou serviços que serão consumidos dentro de um determinado período. No varejo, essa prática é essencial para a administração eficiente dos estoques, definição estratégica de preços, planejamento de compras e distribuição de recursos. Uma premonição assertiva possibilita a redução de custos operacionais, minimiza desperdícios e melhora a satisfação do cliente, garantindo que os itens certos estejam disponíveis no momento e local adequados.

Dekker. Et al. (2004) afirmam que embora o comércio de retalho moderno enfrente desafios constantes devido à volatilidade do mercado, como às mudanças nos padrões de consumo e à influência de fatores externos, como sazonalidade e variações econômicas. Além disso, o crescimento do e-commerce e a digitalização dos processos comerciais aumentaram a complexidade da gestão de demanda, exigindo previsões mais precisas e dinâmicas. Nesse cenário, o uso de técnicas adequadas para prever a procura se torna essencial para manter a competitividade e evitar prejuízos decorrentes de estoques excessivos ou insuficientes.

2.1.2 Métodos tradicionais de projeção de demanda e suas limitações

Finlay (2014), discute que ao longo dos anos, diversas abordagens estatísticas foram desenvolvidas para prever a necessidade de consumo varejista, sendo uma das mais utilizadas o método de Médias Móveis. Esse método consiste em calcular a média das vendas em um determinado período e projetar esse valor para previsões futuras. Apesar de sua simplicidade e facilidade de aplicação, essa abordagem apresenta limitações significativas, especialmente na identificação de variações sazonais e tendências de longo prazo, o que pode comprometer sua eficácia em cenários dinâmicos.

Brownlee (2016) destaca a regressão estatística como outra técnica amplamente adotada para previsão de requisições de mercado. Essa metodologia emprega equações matemáticas

para estabelecer relações entre variáveis independentes, como preços, promoções e sazonalidade, e a necessidade observada. Um dos principais desafios desse método é a suposição de que essas relações permanecem estáveis ao longo do tempo. No contexto do varejo, onde as preferências dos consumidores e as condições de mercado podem mudar rapidamente, essa limitação pode reduzir a precisão das previsões.

Eaves e Kingsman (2004) afirmam que os modelos *ARIMA* (*Autoregressive Integrated Moving Average*) se destacam no campo da análise de séries temporais. Esses modelos combinam componentes autorregressivos de médias móveis para identificar padrões históricos e utilizá-los na projeção de consumo futuro. Apesar de serem métodos matematicamente sofisticados e eficazes na análise de padrões lineares, apresentam dificuldades na detecção de padrões não lineares e na adaptação a mudanças abruptas no comportamento dos consumidores, tornando-se menos eficazes em mercados altamente voláteis.

Dekker et al. (2004) reitera que, embora amplamente utilizados, os métodos tradicionais de estimativa de demanda possuem limitações consideráveis no contexto do varejo contemporâneo. Essas abordagens baseiam-se em premissas rígidas sobre padrões históricos e, muitas vezes, não são capazes de capturar a complexidade dos múltiplos fatores que afetam a demanda, como mudanças nas preferências dos consumidores, sazonalidade atípica e eventos inesperados. Diante dessas limitações, torna-se essencial adotar técnicas mais avançadas, capazes de proporcionar maior precisão e adaptabilidade às dinâmicas do mercado.

2.1.3 A necessidade de abordagens mais sofisticadas: o papel do *Machine Learning*

Gomes et al. (2020) ressaltam que os métodos estatísticos tradicionais enfrentam limitações diante da volatilidade e complexidade do mercado varejista, falhando em captar padrões não lineares e interações complexas. Nesse contexto, Zhang et al. (2023) apontam o *Machine Learning*, especialmente com o uso de redes neurais e técnicas de *Deep Learning*, como alternativa promissora, capaz de identificar padrões ocultos e adaptar-se melhor às mudanças do comportamento do consumidor.

Kumar e Rodrigues (2021) complementam que a combinação de métodos estatísticos e *ML* em modelos híbridos pode potencializar a acurácia das previsões, aproveitando o melhor de ambos os enfoques. No entanto, Lima et al. (2022) alertam que a implementação de *ML* exige investimentos robustos em infraestrutura e capacitação, além da garantia de qualidade dos dados.

Mendes e Castro (2023) afirmam que a evolução contínua das técnicas de *ML* e sua aplicação na previsão de necessidade de consumo representam uma oportunidade estratégica para o varejo. Empresas que adotam essas tecnologias estão mais bem posicionadas para antecipar tendências, responder às necessidades dos consumidores e manter uma vantagem competitiva no mercado dinâmico atual.

2.2. Introdução ao *Machine Learning* e *Redes Neurais* para previsão de demanda

De acordo com Domingos (2015), o aprendizado de máquina consiste na capacidade dos algoritmos de identificar padrões em grandes volumes de dados e aprimorar seu desempenho automaticamente sem a necessidade de programação explícita. Esse processo permite que sistemas computacionais sejam planejados e tomem decisões com base na experiência adquirida, sendo um dos pilares fundamentais da inteligência artificial.

As Redes Neurais Artificiais (RNA) têm sido amplamente utilizadas na previsão de vendas de varejo devido à sua capacidade de analisar grandes volumes de dados históricos e identificar padrões complexos. Essas referências selecionadas para um planejamento de

compras mais eficientes e auxiliam na otimização da gestão de estoques, fatores essenciais para a competitividade no setor varejista (Almeida; Passari, 2005)

De acordo com Morris et al. (2019), as redes LSTM (*Long Short-Term Memory*) são um tipo especial de rede neural que consegue guardar informações importantes por períodos mais longos de tempo. Diferente de modelos antigos, que tinham dificuldade em lembrar dados de etapas anteriores a um problema conhecido como "gradiente desaparecendo", as *LSTMs* foram projetadas para armazenar e usar essas informações de maneira eficiente. Elas fazem isso por meio de "portas" de controle chamadas de entrada (*Input gate*), esquecimento (*Forget gate*) e saída (*Output gate*), que funcionam como filtros para decidir o que lembrar e o que esquecer. Isso torna as *LSTMs* muito úteis para trabalhar com informações em sequência, como no reconhecimento de voz, no entendimento de textos e na antecipação de padrões em séries temporais.

2.2.3 Métodos baseados em árvores de decisão para aprimorar previsões de consumo

Conforme Carvalho 2014, às árvores de decisão são modelos preditivos estruturados em uma hierarquia de regras, permitindo a segmentação dos dados com base em características relevantes. Os mesmos são amplamente utilizados devido à sua interpretabilidade e facilidade de implementação. No entanto, essas árvores podem cometer erros se os dados forem muito complexos e variados, levando a um problema chamado *overfitting*, em que o modelo que decora os dados ao invés de aprender padrões reais.

Congruente Carvalho 2014, para resolver essa limitação, surgiram os chamados métodos de conjunto. Esses métodos, como o *Random Forest* e o *XGBoost*, juntam várias árvores de decisão para criar um modelo mais forte e confiável. Em vez de depender de apenas uma árvore, eles combinam os resultados de muitas árvores diferentes, o que reduz erros e melhora a precisão das previsões. Essa estratégia é semelhante a pedir a opinião de vários especialistas ao invés de confiar em apenas uma pessoa: o resultado final tende a ser mais equilibrado e certo. No contexto da previsão de fluxo de pedidos no varejo, esses métodos permitem analisar grandes volumes de dados de forma mais precisa, ajudando as empresas a tomar decisões mais seguras sobre estoques, promoções e lançamentos de produtos.

2.2.5 Comparativos entre os modelos antigos vs atuais na previsão de demanda

Os métodos tradicionais de previsão de demanda são conhecidos por sua simplicidade e fácil interpretação, mas apresentam limitações quando aplicados a padrões mais complexos ou a cenários de mudanças abruptas no comportamento do consumidor. Em muitos casos, os usuários desses métodos enfrentam dificuldades para ajustar os modelos de maneira eficaz às novas dinâmicas do mercado.

A seguir, a tabela 1 apresenta uma comparação detalhada entre as principais características dos métodos tradicionais e das técnicas baseadas em aprendizado de máquina na estimativa de consumo.

Tabela 1 -Comparação entre métodos tradicionais e *Machine Learning* na estimativa de demanda

Critério	Métodos Tradicionais (Médias Móveis, Regressão, ARIMA)	<i>Machine Learning</i> (Redes Neurais, XGBoost, etc.)
----------	--	--

Capacidade de Captar Padrões	Funciona bem para dados lineares e estacionários, mas tem dificuldades com padrões complexos.	Captura relações não lineares e padrões complexos automaticamente.
Sazonalidade e Tendências	Sistemas como ARIMA precisam de ajustes manuais para lidar com a sazonalidade.	Modelos como LSTM identificam tendências e sazonalidades automaticamente.
Adaptação a Novos Dados	Pode precisar de reconfiguração manual quando há mudanças abruptas.	Aprende continuamente e se adapta melhor a novas tendências.
Requisitos de Dados	Funciona bem com menos dados, mas requer pré-processamento significativo.	Necessita grandes volumes de dados para melhor desempenho.
Complexidade Computacional	Modelos estatísticos são mais simples e exigem menos poder computacional.	Algoritmos avançados podem ser computacionalmente intensivos.
Interpretação dos Resultados	Fácil de interpretar e entender a relação entre variáveis.	Protótipos como redes neurais são mais difíceis de interpretar (caixa-preta).
Precisão da Previsão	Boa para dados com padrões simples e estáveis.	Melhor precisão em cenários complexos com múltiplas variáveis.

Fonte: Elaborada pelos autores (2025).

A análise comparativa reforça que a inteligência preventiva não apenas supera métodos tradicionais em precisão, mas também proporciona vantagens estratégicas ao varejo, como maior capacidade de personalização de estoques, identificação de novas oportunidades de mercado e resposta mais rápida às flutuações de procura. Dessa forma, a adoção dessas tecnologias deixa de ser apenas uma opção de inovação e se torna um diferencial competitivo essencial para empresas que desejam se destacar no cenário atual.

2.3 O modelo ECR e sua relação com a previsão de demanda

Para Christopher (2016), *ECR (Efficient Consumer Response)* é uma estratégia de gestão da cadeia de suprimentos que visa aumentar a eficiência e a resposta ao consumidor final, por meio do compartilhamento de informações entre varejista e o fornecedor, reduzindo estoques e melhorando a disponibilidade de produto.

Enfatizar esta ferramenta está diretamente ligado ao planejamento colaborativo, em que:


XVI FATECLOG – O papel da Inteligência Artificial nas Operações Logísticas
FATEC CARAPICUÍBA
CARAPICUÍBA/SP - BRASIL

"Acordos exclusivos entre fornecedores e varejistas têm se tornado o alicerce para especialistas que buscam uma vantagem competitiva em um mundo de negócios cada vez mais guiado pelo preço. Quando a lendária grife italiana Gucci descobriu que sua imagem estava severamente desgastada pelo excesso de exposição em licenciamentos e lojas de desconto, ela decidiu encerrar seus contratos de fornecimento com terceiros, controlar sua distribuição e abrir lojas próprias para recuperar parte do brilho." (KOTLER, 2012, p.457).

A resposta eficiente ao consumidor aumenta o valor agregado ao cliente final e exige uma reavaliação de toda a cadeia de suprimentos. Isso torna as empresas mais ágeis e adaptáveis às mudanças do mercado. Com a finalidade de superar os *GAPs* e diminuir o efeito chicote, onde pequenas variações na demanda podem gerar grandes oscilações nos pedidos da cadeia de suprimento, afetando a reposição de produtos e custos logísticos.

Para alcançar esses objetivos, são aplicados quatros pilares fundamentais do sistema colaborativo. Conforme a figura 1 abaixo mostra como os processos logísticos podem ser otimizados entres os *Upstream* e *downstream*.

Figura 1- Pilares fundamentais do ECR



Fonte: Elaborado pelos autores (2025).

O modelo *ECR* propõe pilares fundamentais para otimizar a cadeia de suprimentos e atender melhor ao consumidor final. Entre eles, destacam-se: a reposição eficiente, que, conforme Ballou (2006), consiste na sincronização entre fornecedor e varejista, guiada pela necessidade real do consumidor, evitando excessos de estoque e rupturas que possam comprometer o serviço; a introdução de novos produtos, que, segundo Kotler (2012), deve ser baseada na identificação de necessidades de mercado e na capacidade da empresa de oferecer soluções diferenciadas; o sortimento eficiente da loja, que, de acordo com Christopher (2016), depende da escolha estratégica do mix de produtos, assegurando que os itens certos estejam disponíveis no local e momento adequados para o consumidor; e a promoção de produtos, que, no ponto de vista de Kotler (2012), pode ser facilitada ao convencer os lojistas a estocar e promover extensões de marca a partir de um aumento previsível do volume de compra, focando a comunicação diretamente no novo produto, sem necessidade de criar uma nova conscientização de marca.

A utilização da ferramenta descrita no tópico atua nas gestões da cadeia de suprimento ajudando a reduzir erros na reposição de estoques e na movimentação interna da empresa, elevando o nível de serviço logístico e a qualidade dos bens gerenciados, para que isso ocorra

com efetividade o varejista e o fornecedores precisam trabalhar juntos, caso ao contrário se um varejista superestimar a saída, faz pedidos maiores ao fornecedor, que por sua vez aumenta a produção. Se a demanda real não se confirmar, há excesso de estoque e custos elevados.

Dentro disso, os algoritmos preventivos surgem como grande aliado, permitindo leituras de dados de grande volume e identificando padrões ocultos, garantido maiores taxas de assertividade em comparação com os atuais sistemas usados, a previsibilidade do fluxo de pedidos é essencial para o sucesso do *ECR*, pois reduz desperdícios e melhora a eficiência operacional.

3. DESENVOLVIMENTO DA TEMÁTICA

Com o avanço das tecnologias de análise de dados e inteligência artificial, empresas líderes como Amazon, Coca-Cola e P&G têm revolucionado suas operações de previsão de demanda. A Amazon, por exemplo, utiliza algoritmos de *Machine Learning* para prever padrões de compra em tempo real, ajustando estoques de forma dinâmica e antecipando necessidades de reabastecimento antes mesmo que o consumidor finalize suas compras. Essa abordagem permite uma logística mais eficiente e reduz atrasos nas entregas.

Na indústria de bens de consumo, a Coca-Cola e a P&G aplicam técnicas de *Machine Learning* para analisar os impactos de campanhas promocionais e mudanças de comportamento dos consumidores. A partir da análise de grandes volumes de dados internos e externos como sazonalidade, tendências de consumo e dados de concorrência, essas empresas conseguem direcionar suas ações de marketing com maior precisão, otimizando investimentos e ampliando as vendas.

Além disso, o *Machine Learning* possibilita uma resposta rápida às oscilações do mercado. Em vez de depender apenas de históricos de vendas, como faziam os modelos tradicionais, as empresas agora combinam dados em tempo real de fornecedores, clientes e ambiente competitivo. Esse novo modelo de detecção de demanda promove uma gestão mais proativa da cadeia de suprimentos e transforma relações comerciais, antes rígidas, em parcerias colaborativas, orientadas pela troca contínua de informações e pela busca conjunta de eficiência.

Dessa forma, o uso estratégico do *Machine Learning* não apenas melhora a precisão do fluxo de pedidos, mas também eleva a resiliência e a agilidade das cadeias logísticas, tornando-se um diferencial competitivo indispensável no varejo global.

4. RESULTADOS E DISCUSSÕES

A pesquisa demonstrou que a otimização da cadeia de suprimentos com a utilização combinada de tecnologias de *Machine Learning* (ML) e do modelo *Efficient Consumer Response* (ECR) proporciona reposições de produtos mais inteligentes e dinâmicas. Diferentemente dos métodos tradicionais, que exigem ajustes manuais constantes, os algoritmos de ML se adaptam automaticamente a cada novo dado inserido no sistema, aumentando a eficiência operacional e contribuindo para a satisfação do consumidor final, fator essencial em cadeias ágeis e competitivas.

Diante da complexidade de interpretar o comportamento dos clientes no varejo, influenciado por fatores como sazonalidade, perfil de consumo e diferenças entre canais online e físicos, a aplicação de algoritmos de ML torna-se uma ferramenta estratégica. Esses algoritmos auxiliam na identificação de padrões ocultos, contribuindo para a definição de um mix de produtos mais assertivo e para a realização de promoções baseadas em dados, resultando em uma resposta mais eficiente às necessidades do consumidor.

A pesquisa também evidenciou que a implementação de modelos preditivos avançados reduz significativamente o impacto do efeito chicote na cadeia de suprimentos, diminuindo erros de previsão e equilibrando a produção e o gerenciamento de estoques ao longo do tempo. Com isso, torna-se possível evitar tanto pedidos excessivos quanto insuficientes, melhorando o fluxo logístico.

Outro resultado relevante é o fortalecimento das conexões digitais na cadeia de suprimentos, promovido pela integração entre sistema colaborativo e modelagem algorítmica no contexto da Indústria 4.0. Essa transformação possibilita uma comunicação mais eficaz entre fornecedores e atacadistas, automatizando o compartilhamento de informações e aumentando a agilidade no atendimento às demandas.

Entretanto, destaca-se que a implementação de sistemas baseados em algoritmos avançados ainda representa um desafio para pequenas e médias empresas, devido aos altos custos de investimento em infraestrutura tecnológica e à escassez de mão de obra qualificada. Enquanto grandes corporações conseguem absorver esses investimentos, muitas companhias de menor porte ainda enfrentam barreiras para integrar plenamente essas tecnologias em seus processos.

Assim, conclui-se que a aplicação das técnicas de inteligência preventiva e ECR contribui significativamente para a melhoria da gestão logística e para a elevação da satisfação dos clientes, consolidando-se como um diferencial competitivo essencial no varejo contemporâneo.

5. CONSIDERAÇÕES FINAIS

A integração de *Machine Learning* e resposta eficiente ao cliente final na projeção de demanda se consolidou como uma inovação estratégica para a otimização da cadeia de suprimentos no varejo. Ao permitir uma reposição de produtos mais inteligente, a redução de estoques excessivos e a antecipação das necessidades dos consumidores, essas tecnologias impactam positivamente a eficiência logística e a competitividade das empresas.

Contudo, a transformação digital não se limita apenas à adoção de algoritmos preditivos. A convergência entre *Machine Learning*, ECR e o conceito de *Digital Supply Chain* representa a próxima fronteira para a evolução do setor. A digitalização da cadeia de suprimentos permite a comunicação em tempo real entre fabricantes, distribuidores e varejistas, integrando processos, dados e decisões de maneira automatizada e dinâmica. Dessa forma, a gestão logística torna-se mais ágil, responsiva e orientada por dados, elevando o nível de serviço ao consumidor final.

Superar os desafios de infraestrutura tecnológica, integração de sistemas legados e qualificação de mão de obra será fundamental para a consolidação dessa transformação. Pesquisas futuras poderão investigar o papel de novas tecnologias emergentes, como *blockchain* e inteligência artificial integrada na construção de cadeias de suprimentos digitais ainda mais resilientes e preditivas.

Assim, conclui-se que o investimento em *Digital Supply Chain*, aliado às práticas de modelagem algorítmica e ECR, é essencial para empresas que buscam não apenas acompanhar as mudanças do mercado, mas liderar a inovação e garantir sua sustentabilidade a longo prazo.

REFERÊNCIAS

ALMEIDA, FERNANDO CARVALHO DE; PASSARI, ANTONIO FABRÍCIO. **Aplicação de redes neurais na previsão de vendas no varejo**. São Paulo: USP, 2005

XVI FATECLOG – O papel da Inteligência Artificial nas Operações Logísticas
FATEC CARAPICUÍBA
CARAPICUÍBA/SP - BRASIL

AASTRUP, J.; GRANT, D. B.; BJERRE, M. **Value creation and category management through Efficient Consumer Response (ECR) partnerships.** *International Journal of Retail & Distribution Management*, 2008.

ARMSTRONG, J. S.; GREEN, K. C. **Demand Forecasting: Evidence-based Methods.** [S. l.: s. n.], 2015.

AMAZON WEB SERVICES (AWS). *AI-powered demand sensing: The future of accurate forecasting.* Disponível em: <https://aws.amazon.com/pt/executive-insights/content/ai-powered-demand-sensing/>. Acesso em: 27 abr. 2025.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/logística empresarial.** 5ª ed. Porto Alegre/SC: Bookman, 2006.

BROWNEE, J. **Machine Learning Mastery With Python: Understand Your Data, Create Accurate Models, and Work Projects End-to-End.** [S. l.: s. n.], 2016.

CARVALHO, Hialo Muniz. **Aprendizado de máquina voltado para mineração de dados: árvores de decisão.** 2014. Monografia (Graduação) – Universidade de Brasília, Brasília, 2014.

CHRISTOPHER, Martin. **Logistics & Supply Chain Management: Creating Value-Adding Networks.** 5ª edição, Pearson, 2016.

DEKKER, R.; VAN DONSSelaar, H.; OUWEHAND, P. **How to use aggregation and combined forecasting to improve seasonal demand forecasts.** [S. l.: s. n.], 2004.

DOMINGOS, Pedro. **The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World.** New York: Basic Books, 2015.

EAVES, A. H. C.; KINGSMAN, B. G. **Forecasting for the ordering and stock-holding of spare parts.** [S. l.: s. n.], 2004.

FINLAY, S. **Predictive Analytics, Data Mining and Big Data: Myths, Misconceptions and Methods.** [S. l.: s. n.], 2014.

GIL, A. C. **Como elaborar projetos de pesquisa.** 4. Ed. São Paulo: Atlas, 2002.

GIL, Antônio C. **Métodos e técnicas de pesquisa social.** 5. ed. São Paulo: Atlas, 2006.

GHISI, F. A.; FERNANDES, A. C. **O surgimento e a difusão do Efficient Consumer Response (ECR) na cadeia de suprimentos.** [S. l.: s. n.], 2001.

GHISI, F. A.; SILVA, A. L. da. **Implantação do Efficient Consumer Response (ECR): um estudo multicaso com indústrias, atacadistas e varejistas.** [S. l.: s. n.], 2006.

GOMES, R. et al. **The impact of Machine Learning on demand forecasting: A systematic review.** *Journal of Retailing and Consumer Services*, v. 65, p. 102529, 2020. Disponível em: <https://link.springer.com/article/10.1057/s41270-022-00162-x>. Acesso em: 19 mar. 2025.

IONOS. **Long Short-Term Memory (LSTM).** Disponível em: <https://www.ionos.com/pt-br/digitalguide/sites-de-internet/desenvolvimento-web/long-short-term-memory/>. Acesso em: 20 mar. 2025.

KUMAR, S.; RODRIGUES, J. *Machine Learning Applications for Demand Forecasting in Retail*. 1. ed. Cham: Springer, 2021.

KURNIA, S.; JOHNSTON, R. B. *Adoption of Efficient Consumer Response: the issue of mutuality*. *Supply Chain Management: An International Journal*, 2003.

KOTLER, P.; KELLER, K. L. *Administração de Marketing*. 14ª ed. São Paulo: Pearson Prentice Hall, 2012.

LAVRATTI, F. B.; MARTINELLI, D. P. *Considerações conceituais sobre Efficient Consumer Response (ECR) no contexto supermercadista*. [S. l.: s. n.], 2002.

LIMA, C.; ALMEIDA, J.; NASCIMENTO, L. *Implementation Challenges of Machine Learning for Retail Demand Forecasting*. *Computers in Industry*, v. 145, p. 103643, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2212827122004036>. Acesso em: 19 mar. 2025.

MENDES, F.; CASTRO, B. *Competitive Advantage through AI-Based Demand Forecasting in Retail*. *Applied Sciences*, v. 13, n. 19, p. 11112, 2023. Disponível em: <https://www.mdpi.com/2076-3417/13/19/11112>. Acesso em: 19 mar. 2025.

OLIVEIRA, P.; SILVA, R.; COSTA, M. *Advances in Demand Forecasting using Machine Learning and Deep Learning Approaches*. *Expert Systems with Applications*, v. 198, p. 116839, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0950705122010498>. Acesso em: 19 mar. 2025.

PRICEMET. *Machine Learning e Previsão de Demanda: Como Coca-Cola e P&G utilizam IA para estratégias mais eficazes*. Disponível em: <https://pricemet.com.br/machine-learning-previsao-de-demanda/#:~:text=Coca%2DCola%20e%20P%26G%20utilizam,recursos%20para%20a%C3%A7%C3%B5es%20mais%20eficazes>. Acesso em: 27 abr. 2025.

SILVA, T.; PEREIRA, A. *Data-Driven Demand Forecasting in Retail: A Machine Learning Approach*. *Journal of Retail Analytics*, v. 7, n. 5, p. 93, 2023. Disponível em: <https://www.mdpi.com/2571-5577/7/5/93>. Acesso em: 19 mar. 2025.

ZHANG, Y. et al. *Deep Learning Models for Retail Demand Forecasting: A Comprehensive Study*. *Processes*, v. 13, n. 2, p. 594, 2023. Disponível em: <https://www.mdpi.com/2227-9717/13/2/594>. Acesso em: 19 mar. 2025.

"Os conteúdos expressos no trabalho, bem como sua revisão ortográfica e adequação às normas ABNT são de inteira responsabilidade dos autores."

«Declaração de IA generativa e tecnologias assistidas por IA no processo de redação»

“Declara-se pelos autores que durante a preparação deste trabalho foi utilizado CHAT GPT para tradução de artigo em inglês, revisão na parte de escrita aplicando o círculo de melhoria contínua pontuando pontos de feedbacks, criação de tabela e pesquisa de



XVI FATECLOG
FATEC CARAPICUÍBA
CARAPICUÍBA/SP - BRASIL
13 E 14 DE JUNHO DE 2025



assuntos. Após utilizar esta ferramenta/serviço, os autores editaram e revisaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo da publicação.”

Comentado [1]: Manter o texto do template do artigo nesse ponto

Comentado [2]: Henrique verificar.