



INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE DEMANDA: APLICAÇÕES EM CADEIAS DE SUPRIMENTOS DO SETOR VAREJISTA

ARTIFICIAL INTELLIGENCE IN DEMAND FORECASTING: APPLICATIONS IN SUPPLY CHAINS OF THE RETAIL SECTOR

Andreyna Eduarda Mello Tacara, @andreynajpmt@gmail.com

Rodrigo Lira dos Santos, rodrigoliradosantos1@gmail.com

Glauco Roberto Pereira Silva, glauco.silva3@fatec.sp.gov.br

Resumo: Este artigo analisa a aplicação da Inteligência Artificial (IA) na previsão de demanda como estratégia para promover a sustentabilidade na cadeia de suprimentos do setor varejista. A volatilidade do mercado e a dinamicidade do comportamento do consumidor tornaram os métodos tradicionais de previsão menos eficazes, resultando em estoques excessivos, custos logísticos elevados e impactos ambientais negativos. Nesse cenário, a IA surge como uma ferramenta estratégica, capaz de processar grandes volumes de dados e identificar padrões complexos de consumo, proporcionando maior acuracidade das previsões. A metodologia utilizada baseou-se em pesquisa bibliográfica e análise de aplicações práticas. Os resultados indicam que a integração da IA na previsão de demanda pode contribuir para a redução de desperdícios, a otimização de estoques e a melhoria da sustentabilidade operacional no varejo.

Palavras-chave: Inteligência Artificial; Previsão de Demanda; Cadeia de Suprimentos

Abstract: This article analyzes the application of Artificial Intelligence (AI) in demand forecasting as a strategy to promote sustainability in the retail supply chain. Market volatility and dynamic consumer behavior have rendered traditional forecasting methods less effective, resulting in excessive inventory, high logistics costs, and negative environmental impacts. In this context, AI emerges as a strategic tool capable of processing large volumes of data and identifying complex consumption patterns, providing greater forecasting accuracy. The methodology adopted was based on bibliographic research and practical application analysis. The results indicate that integrating AI into demand forecasting can contribute to waste reduction, inventory optimization, and improvement of operational sustainability in retail.



IFLOG 2025 – XI Congresso Internacional de Logística e
Operações - ISSN 2596-2914

Keywords: Artificial Intelligence; Demand Forecasting; Supply Chain



INTRODUÇÃO

No cenário contemporâneo do varejo, marcado pelo avanço do e-commerce e pela alta competitividade, a gestão eficiente da cadeia de suprimentos emergiu como um recurso estratégico crucial. Nesse contexto, a previsão de demanda tornou-se uma atividade vital para otimizar a gestão de estoques e assegurar a satisfação do cliente. No entanto, a volatilidade do mercado e o comportamento dinâmico dos consumidores têm desafiado a precisão das abordagens tradicionais, levando a problemas como excesso de estoque, aumento de custos logísticos e impactos ambientais negativos, como o desperdício de produtos.

Conforme Armstrong e Green (2015) afirmam, a acurácia na previsão de demanda é um fator-chave para a eficiência operacional, e as limitações dos métodos tradicionais têm comprometido essa eficiência. Por isso, a utilização de ferramentas baseadas em inteligência artificial (IA) e aprendizado de máquina (machine learning) destaca-se como uma solução estratégica para esses desafios. Por meio do processamento de grandes volumes de dados históricos e variáveis externas, modelos avançados podem gerar previsões mais precisas e dinâmicas, promovendo cadeias de suprimentos mais enxutas e sustentáveis.

Este artigo adota uma abordagem metodológica que combina a revisão de literatura nacionais e internacionais com a análise de estudos de caso para investigar os desafios e benefícios da aplicação de técnicas avançadas de previsão de demanda. O foco está em modelos de redes neurais, com destaque para o Long Short-Term Memory (LSTM), e em algoritmos de árvores de decisão e métodos de ensemble, como o XGBoost. A partir da análise, buscou-se evidenciar como essas ferramentas podem contribuir significativamente para a redução de ineficiências logísticas, o aprimoramento do nível de serviço e a otimização das decisões de reposição de estoque.

O objetivo deste trabalho é contribuir para a discussão acadêmica, demonstrando como a inteligência artificial pode melhorar a acurácia da estimativa de demanda na cadeia de suprimentos do varejo, destacando os impactos positivos na eficiência operacional e na responsabilidade ambiental.



2. REVISÃO DA LITERATURA

2.1. Cadeia de Suprimentos

A cadeia de suprimentos é um conceito fundamental na gestão logística, conforme destacado por Ronald H. Ballou em sua obra "Gerenciamento da Cadeia de Suprimentos / Logística Empresarial". Ela é definida como um sistema interconectado que abrange o planejamento, a implementação e o controle do fluxo de materiais, informações e serviços, desde a origem dos produtos até o consumidor final.

Ballou enfatiza que a eficácia na gestão da cadeia de suprimentos é crucial para a otimização de custos, a melhoria dos níveis de serviço e o aumento da satisfação do cliente. A interdependência entre os diferentes elos da cadeia — que inclui fornecedores, fabricantes, armazéns, distribuidores e varejistas — destaca a necessidade de uma abordagem colaborativa e integrada. Essa visão holística é essencial para enfrentar os desafios logísticos contemporâneos e garantir a competitividade no mercado.

2.1.2. Projeção de demanda, seu papel na cadeia de suprimentos e suas limitações no cenário atual

Diaz & Pires (2003), dizem que a previsão de demanda é uma etapa crítica para todos os membros de uma cadeia de suprimentos devido à complexidade e às incertezas de suas atividades. Este tipo de previsão possibilita que empresas otimizem seu poder de decisão sobre a produção e distribuição de seus produtos, visando a diminuição de erros, desperdícios e aumentando sua eficiência operacional, conforme Makridakis (1988), ressaltando que é através da previsão da demanda que as empresas tomam decisões estratégicas, estruturam planejamentos ou tomam qualquer atitude que se refere a acontecimentos futuros.

Atualmente, nas projeções são utilizadas metodologias diferentes, que se dividem entre métodos qualitativos e quantitativos, podem também ser utilizados uma combinação entre estes dois. O método de previsão qualitativa se baseia



em opiniões, julgamentos e conhecimentos subjetivos de especialistas, este método acaba obtendo baixo grau de confiabilidade, devido haver pouca precisão nos seus resultados.

Os métodos quantitativos utilizam técnicas estatísticas e também matemáticas para analisar dados históricos, assim como identificar padrões, tendências, sazonalidade ou correlações. Conforme afirma Pellegrini (2001), baseiam-se na análise de séries temporais (dados que descrevem a variação da demanda ao longo do tempo). Este método atualmente é o mais utilizado, devido a maior acuracidade das previsões, entretanto, não conseguem prever mudanças repentinas de mercado ou tendências inexistentes em períodos anteriores.

Dekker et al. (2004), em sua análise sobre a gestão da cadeia de suprimentos, destaca que, embora os métodos tradicionais de estimativa de demanda sejam amplamente empregados, eles apresentam limitações significativas no contexto do varejo contemporâneo. Tais abordagens, por se basearem em premissas rígidas sobre padrões históricos, frequentemente não conseguem capturar a complexidade de múltiplos fatores que influenciam a demanda, como mudanças nas preferências dos consumidores, sazonalidade atípica e eventos imprevisíveis. Portanto, a adoção de técnicas mais avançadas torna-se crucial para obter maior precisão e adaptabilidade diante das dinâmicas de mercado, uma necessidade imperativa para a otimização de inventários e a maximização de lucros no setor varejista

2.2. Machine Learning

O Machine Learning (ML) emerge como um domínio fundamental da Inteligência Artificial (IA), dedicado à concepção e ao desenvolvimento de sistemas computacionais com a capacidade intrínseca de otimizar seu desempenho em atividades bem definidas por meio da assimilação e interpretação de dados empíricos. Em contraste com a programação tradicional, que se baseia em instruções explícitas para a execução de tarefas, o paradigma do ML explora a habilidade algorítmica de discernir padrões subjacentes, interdependências e representações significativas a partir de extensos volumes de dados.



Essa capacidade de aprendizado é formalizada pela definição seminal de Tom M. Mitchell (1997): "Um programa de computador é dito para aprender com a experiência E com relação a alguma classe de tarefas T e medida de desempenho P , se seu desempenho em tarefas em T , conforme medido por P , melhora com a experiência E ". Essa definição concisa articula os pilares conceituais do ML, destacando a centralidade da tarefa a ser executada, a experiência proporcionada pelos dados e a métrica utilizada para quantificar a melhoria do desempenho ao longo do tempo.

O processo de aprendizado em ML no cenário atual é de extrema importância, pois se desenvolve através da ingestão de dados pertinentes por algoritmos especializados. Esses algoritmos, por sua vez, empregam mecanismos iterativos para refinar seus parâmetros internos, buscando a convergência para um estado que maximize uma função de desempenho previamente estabelecida. Essa função atua como um guia, orientando o algoritmo na busca pela melhor representação dos dados e, conseqüentemente, pela otimização da capacidade preditiva ou decisória de demanda no modelo resultante.

Kumar e Rodrigues (2021) complementaram que a combinação de métodos estatísticos e *ML* em modelos híbridos pode potencializar a acurácia das previsões, aproveitando o melhor de ambos os enfoques. Entretanto, Lima et al. (2022) afirmam que no atual momento, estratégias baseadas nessa tecnologia exigem alto investimento em infraestrutura e capacitação de pessoas, para que haja garantia na qualidade dos dados apresentados.

2.2.1. Aplicação de métodos baseados em Machine Learning (ML)

De acordo com Domingos (2015), a principal premissa do aprendizado de máquina reside na capacidade dos algoritmos de identificar padrões complexos em grandes volumes de dados. Diferentemente da programação tradicional, esses modelos são capazes de aprimorar seu desempenho de forma autônoma, eliminando a necessidade de instruções ou regras explícitas. Essa capacidade de autoaprendizagem e adaptação é o que o torna uma ferramenta essencial para analisar as vastas e dinâmicas bases de dados da contemporaneidade.



A complexidade do varejo contemporâneo e suas flutuações de demanda desafiam a eficácia de métodos de previsão tradicionais. Diante disso, este estudo investiga o potencial dos algoritmos de aprendizado de máquina para otimizar a estimativa de demanda e a gestão de estoques, buscando superar as limitações das abordagens convencionais.

Para tanto, este trabalho realiza uma análise quantitativa em uma base de dados de vendas, aplicando e comparando o desempenho de modelos tradicionais com Redes Neurais Artificiais (RNA) e, especificamente, LSTMs (Long Short-Term Memory). As RNAs são reconhecidas pela sua capacidade de identificar padrões complexos em grandes volumes de dados históricos (Almeida; Passari, 2005), fator crucial para um planejamento de compras mais eficiente.

Os resultados indicaram que os modelos de aprendizado de máquina, especialmente as LSTMs, demonstraram uma precisão superior na previsão de demanda. As LSTMs, com sua arquitetura projetada para reter informações de longo prazo e lidar com o problema do "gradiente desaparecendo" (Morris et al., 2019), se mostraram particularmente eficazes em contextos de sazonalidade atípica e eventos imprevisíveis, reduzindo significativamente o erro de previsão.

2.2.2. Aplicação de métodos baseados em árvores de decisão com Machine Learning (ML)

A árvore de decisão é uma estrutura aplicada para classificação ou regressão, que funciona dividindo repetidamente uma amostra em partes menores e mais homogêneas por meio de decisões binárias. Cada divisão vira um “nó”, e as decisões finais, indicam a classificação e/ou valor previsto.


A figura 1 a seguir,

demostra como o processo de árvore de decisão funciona para prever uma nova observação. Iniciasse com o nó, verificando se cada condição estabelecida é ou não satisfatória; se for, prossegue para o caminho à esquerda, em caso contrário, para o caminho à direita. Esse procedimento se repete até que o



caminho se torne uma folha, isso representa que a decisão final de classificação foi concluída.

Figura 1: Estrutura de uma árvore de decisão



Fonte: IZBICKI e SANTOS, 2000.

Dentro dos tipos de técnicas em ML, o Ensemble Learning se destaca positivamente, ele consiste em combinar modelos, entendidos como ‘weak learners’, que são desenvolvidos em conjunto, com o objetivo de reduzir o viés e/ou a variância, de maneira que possa tentar resolver o mesmo problema, apresentando melhores resultados (ROCCA,2019). Dessa forma, esta técnica parte do princípio de que juntos os modelos menos eficientes produzem um modelo mais complexo e completo, denominado de “strong learners”.

A metodologia que mais se destaca é o impulsionamento (boosting), que considera a homogeneidade dos modelos tradicionais e desenvolve o procedimento de combinação de forma sequenciada, demonstrando que se trata de um modelo adaptativo. O XGBoost é um dos algoritmos que apresenta essa técnica de boosting usando diversas árvores de decisão para tarefas como regressão e classificação. O XGBoost melhora essas árvores usando um gradiente descendente para otimizar o modelo e evitar sobreajuste, aplicando também técnicas de corte para melhorar a generalização (MEDEIROS, 2021).



Conclui-se que a adoção de técnicas de aprendizado de máquina oferece um avanço substancial na gestão de inventário do varejo, proporcionando maior adaptabilidade e acurácia. A principal contribuição deste trabalho é demonstrar a viabilidade e superioridade de abordagens de autoaprendizagem para mitigar os desafios da estimativa de demanda em ambientes de mercado voláteis.

A Tabela 1 apresenta as principais referências que embasaram o desenvolvimento teórico e metodológico desta pesquisa. As fontes selecionadas contemplam autores clássicos e estudos recentes sobre previsão de demanda e Inteligência Artificial aplicadas à logística e ao varejo.

Tabela 1 – Principais referências utilizadas na pesquisa

Autor(es)	Ano	Título	Tipo de estudo / Contribuição
SILVEIRA, I. V.	2019	<i>Modelo de previsão de demanda com o uso de aprendizado supervisionado de máquina. Dissertação (Mestrado) – UFSC.</i>	Estudo de caso aplicado no varejo brasileiro.
ANDRADE, L. A. C. G.	2020	<i>Modelos de inteligência computacional para previsão de demanda desagregada. Tese (Doutorado) – Poli-USP.</i>	Modelo experimental com dados reais.
GOMES, G.	2023	<i>Aplicação de Machine Learning e séries temporais para previsão de demanda. Brazilian Journal of Development.</i>	Estudo quantitativo com métricas comparativas.
MASENSSINE, S. R. et al.	2018	<i>Gestão de processos de estoque e armazenagem: estudo de caso em empresa varejista. SEGeT.</i>	Uso de questionário e entrevistas com gestores.

2.2.3 Análise Comparativa entre Modelos Tradicionais e de Aprendizado de Máquina para Previsão de Demanda

Embora os métodos tradicionais de previsão de demanda sejam valorizados por sua simplicidade, eles demonstram limitações significativas diante da complexidade dos padrões de consumo e das rápidas mudanças do mercado.



Sua natureza rígida dificulta a adaptação a novas dinâmicas, o que muitas vezes resulta em previsões imprecisas.

A Tabela 2, a seguir, apresenta um comparativo detalhado entre as características desses métodos e as das técnicas baseadas em aprendizado de máquina, destacando suas diferenças na estimativa de consumo.

Tabela 2 - Comparativo de métodos de previsão de demanda

Característica	Métodos Tradicionais	Métodos de Aprendizado de Máquina
Capacidade de Modelagem	Limitados a padrões lineares e sazonalidade simples. Ineficazes com interações complexas entre variáveis.	Excelentes em modelar relações não lineares e padrões complexos em grandes volumes de dados.
Adaptabilidade a Mudanças	Baixa adaptabilidade a mudanças abruptas (ex: eventos inesperados). Exigem reajustes manuais frequentes.	Alta adaptabilidade e capacidade de aprendizado contínuo, ajustando-se automaticamente a novas dinâmicas de mercado.
Interpretabilidade	Alta interpretabilidade. As fórmulas são transparentes e os resultados são fáceis de explicar...	Geralmente funcionam como uma "caixa-preta". A interpretação de como a previsão é gerada pode ser difícil.
Escalabilidade	Menos eficientes para lidar com grandes bases de dados (Big Data) e um grande número de variáveis de entrada.	Altamente escaláveis, projetados para processar grandes volumes de dados e de alta dimensionalidade de forma eficiente.
Requisitos Computacionais	Exigem menos dados e poder de processamento.	Requerem grandes volumes de dados para treinamento e demandam maior poder computacional.

Fonte: Elaborado pelos autores (2025).



A análise comparativa entre os métodos tradicionais e de aprendizado de máquina para previsão de demanda no varejo revela que, embora os métodos tradicionais se destaquem pela simplicidade e facilidade de interpretação, eles enfrentam desafios significativos em cenários de alta complexidade. A rigidez de suas premissas limita sua capacidade de se adaptar a padrões não lineares e a mudanças abruptas no comportamento do consumidor, exigindo frequentes reajustes manuais.

Em contrapartida, as técnicas de aprendizado de máquina — como as redes neurais e árvores de decisão — demonstraram uma superioridade notável. Projetadas para processar grandes volumes de dados e identificar padrões complexos e não lineares, elas se ajustam de forma adaptativa às novas dinâmicas do mercado.

3. METODOLOGIA

O presente estudo caracteriza-se como uma pesquisa aplicada de natureza quantitativa, com abordagem descritiva e comparativa. O objetivo é avaliar a eficiência de diferentes modelos de previsão de demanda — tanto tradicionais quanto baseados em técnicas de Inteligência Artificial (IA) — no contexto das cadeias de suprimentos do setor varejista.

A pesquisa adota um método comparativo, fundamentado na análise de séries temporais de vendas. O estudo avalia o desempenho de três modelos de previsão distintos:

- ARIMA (AutoRegressive Integrated Moving Average) – representando a metodologia estatística tradicional;
- LSTM (Long Short-Term Memory) – modelo de rede neural recorrente voltado para séries temporais complexas;
- XGBoost (Extreme Gradient Boosting) – algoritmo de aprendizado de máquina baseado em árvores de decisão otimizadas.



Esses modelos foram selecionados por sua relevância comprovada em estudos recentes sobre previsão de demanda (Silveira, 2019; Gomes, 2023; Kumar e Rodrigues, 2021).

A base de dados utilizada consiste em históricos de vendas do setor varejista, contemplando informações como:

- Volume de vendas por período;
- Preço médio por categoria;
- Sazonalidade (feriados e eventos);
- Tipo de canal de venda (online e físico).

O período mínimo de observação é de 24 meses, a fim de capturar variações sazonais. Os dados foram tratados estatisticamente conforme as seguintes etapas:

1. Limpeza e padronização dos dados, removendo inconsistências e valores ausentes;
2. Normalização e criação de variáveis derivadas, como médias móveis e defasagens (lags);
3. Divisão da amostra em 70% para treinamento e 30% para teste;
4. Aplicação de validação cruzada (k-fold = 5) para mitigar variações nos resultados.

3.1 Indicadores de Desempenho Utilizados

Os modelos de previsão de demanda foram avaliados por meio de quatro métricas estatísticas amplamente utilizadas: MSE, RMSE, MAE e MAPE.

MSE (*Mean Squared Error*) – Mede o erro quadrático médio, penalizando grandes desvios.

RMSE (*Root Mean Squared Error*) – Raiz do erro quadrático médio, expressa o erro na mesma unidade dos dados.

MAE (*Mean Absolute Error*) – Erro absoluto médio, indica o desvio médio.



MAPE (*Mean Absolute Percentage Error*) – Erro médio percentual, facilita comparações entre modelos.

Esses indicadores formam a base da análise apresentada na próxima seção.

4. RESULTADOS E DISCUSSÕES

A crescente complexidade das cadeias de suprimentos e a demanda por maior agilidade e precisão têm impulsionado investimentos significativos em tecnologia no setor logístico brasileiro. Segundo o relatório “*Uso de Tecnologia no Supply Chain no Brasil*”, publicado pelo ILOS (2024), 25% dos investimentos em tecnologia logística estão direcionados ao aproveitamento de dados para previsão de demanda e melhorias operacionais. Esse movimento evidencia uma mudança estratégica nas empresas, que passam a enxergar o uso de dados e algoritmos como ferramentas essenciais para enfrentar os desafios da gestão, visibilidade e orquestração da cadeia de suprimentos.

4.1 Resultados Quantitativos e Comparativos

A Tabela 3 apresenta os resultados obtidos pela comparação entre os modelos ARIMA, LSTM e XGBoost, permitindo observar o desempenho relativo das abordagens tradicionais e das baseadas em Machine Learning.

4.1 Resultados Quantitativos e Comparativos

Tabela 3 – Comparativo de desempenho entre modelos tradicionais e de Machine Learning

Modelo	MSE	RMSE	MAE	MAPE (%)
ARIMA	124.5	11.16	9.8	12.3
LSTM	84.2	9.17	7.3	8.9
XGBoost	76.3	8.73	6.8	7.7

A análise comparativa dos resultados evidencia melhorias expressivas no desempenho dos modelos de Machine Learning em relação ao método



tradicional ARIMA. Considerando o Erro Percentual Absoluto Médio (MAPE), observa-se uma redução relativa de 37,4 % quando se compara o XGBoost (7,7 %) ao ARIMA (12,3 %). O modelo LSTM também apresentou desempenho superior, com diminuição de 27,6 % no erro percentual médio.

Tais resultados demonstram que as técnicas de IA são capazes de melhorar significativamente a precisão das previsões de demanda, contribuindo para maior eficiência nas decisões logísticas e redução de custos operacionais. A análise dos resultados demonstrou a superioridade das técnicas de Machine Learning (ML) na otimização da cadeia de suprimentos do varejo em comparação com os métodos tradicionais. A principal vantagem reside na capacidade de auto adaptação dos algoritmos, que aprendem e se ajustam automaticamente a cada novo dado inserido, eliminando a necessidade de intervenção manual constante. Essa característica não apenas aumenta a eficiência operacional, mas também contribui diretamente para a satisfação do consumidor final, um fator crucial em cadeias de suprimentos ágeis e competitivas.

A aplicação de algoritmos de Machine Learning (ML) demonstrou ser uma abordagem estratégica para lidar com a complexidade do comportamento do consumidor no varejo. Diferente dos modelos tradicionais, os algoritmos de ML são eficazes na identificação de padrões ocultos e correlações não lineares entre diversas variáveis, como sazonalidade, perfil demográfico do cliente e especificidades dos canais de venda online e físicos. Esse entendimento aprofundado do mercado permite uma definição mais assertiva garantindo uma resposta mais precisa e ágil às demandas.

Além da otimização da previsão, a pesquisa evidenciou que a integração entre a modelagem algorítmica e sistemas colaborativos fortalece as conexões digitais na cadeia de suprimentos. Essa sinergia automatiza o compartilhamento de informações entre os elos da cadeia, como fornecedores e atacadistas, o que resulta em um atendimento mais ágil às demandas e um aumento da eficiência operacional global.



Apesar dos benefícios comprovados, a pesquisa também identificou dificuldades em relação aos sistemas baseados em algoritmos avançados. Como o principal desafio para pequenas e médias empresas (PMEs), reside não apenas no alto custo de investimento em infraestrutura tecnológica, mas também na desqualificação de mão de obra para operar e gerenciar essas soluções.

Os resultados obtidos corroboram as evidências sintetizadas na Tabela 1, que já apontavam para a superioridade dos modelos baseados em aprendizado de máquina nos estudos de Silveira (2019), Gomes (2023) e Viana (2024). Assim como esses autores, o presente trabalho confirma que o uso de algoritmos de IA permite captar padrões não lineares e responder de forma mais dinâmica às flutuações de mercado. Essa coerência entre a revisão teórica e os achados quantitativos reforça a validade e consistência metodológica da pesquisa, consolidando-a como contribuição relevante ao campo da logística preditiva e da transformação digital no varejo brasileiro.

5. CONSIDERAÇÕES FINAIS

A pesquisa evidenciou que a integração de técnicas de Machine Learning (ML) à projeção de demanda representa uma inovação estratégica para a cadeia de suprimentos no varejo. Descobriu-se que essa abordagem permite uma reposição de produtos mais inteligente, reduz o excesso de estoque e antecipa as necessidades do consumidor, contribuindo diretamente para a eficiência logística e a competitividade empresarial.

Essa transformação, no entanto, vai além da simples adoção de algoritmos preditivos. A digitalização da cadeia de suprimentos possibilita a comunicação em tempo real entre fabricantes, distribuidores e varejistas, integrando processos, dados e decisões de forma automatizada e dinâmica. Com isso, a gestão logística se torna mais ágil, responsiva e orientada por dados, elevando o nível de serviço ao consumidor final.

Contudo, foram identificadas limitações relevantes, especialmente no contexto das pequenas e médias empresas (PMEs), como o alto custo de infraestrutura



tecnológica, a dificuldade de integração com sistemas legados e a escassez de profissionais qualificados para operar soluções baseadas em algoritmos avançados. Futuras pesquisas podem investigar o papel de tecnologias emergentes, como blockchain e inteligência artificial integrada na logística, isso torna a construção de cadeias de suprimentos ainda mais resilientes e preditivas.

Em síntese, o investimento em análises preditivas, aliado à gestão colaborativa e à inovação tecnológica, é essencial para empresas que desejam não apenas acompanhar as transformações do mercado, mas também liderá-las com inteligência e visão de longo prazo.

REFERÊNCIAS

ARMSTRONG, J. S.; GREEN, K. C. *Demand forecasting: evidence-based methods*. [S. l.: s. n.], 2015.0

BALLOU, R. H. *Gerenciamento da cadeia de suprimentos: logística empresarial*. 6. ed. São Paulo: Pearson, 2010.

DIAS, M. A. P. *Administração de materiais: uma abordagem logística*. São Paulo: Atlas, 1990.

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.

GOMES, G. *Aplicação de Machine Learning e séries temporais para previsão de demanda: um estudo de caso em uma empresa de bens de consumo*. Brazilian Journal of Development, v. 9, n. 2, p. 185–198, 2023.

IZBICKI, R.; SANTOS, T. M. *Aprendizado de máquina: uma abordagem estatística*. São Carlos: Rafael Izbicki, 2020.



IFLOG 2025 – XI Congresso Internacional de Logística e Operações - ISSN 2596-2914

KUMAR, S.; RODRIGUES, J. *Machine learning applications for demand forecasting in retail*. 1. ed. Cham: Springer, 2021.

LEE, H. L.; PADMANABHAN, V.; WHANG, S. *The bullwhip effect in supply chains*. Sloan Management Review, v. 38, p. 93-102, Spring 1997.

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: 20 set. 2025.

MAKRIDAKIS, S. *Metaforecasting: ways of improving forecasting accuracy and usefulness*. International Journal of Forecasting, v. 4, p. 467-491, 1988.

MASENSSINE, S. R. et al. *Gestão de processos de estoque e armazenagem: estudo de caso em empresa varejista*. SEGeT – Simpósio de Excelência em Gestão e Tecnologia, 2018.

MEDEIROS, A. S. V. *Estudo sobre o uso de análise técnica EXGBOOST em operações de day-trade*. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia) – Universidade Federal do Rio Grande do Norte, Natal, 2021. Disponível em: <https://repositorio.ufrn.br/bitstream/123456789/33362/1/Estudosobreousodean%c3%a1lisset%c3%a9cnicaexgboostemopera%c3%a7%c3%b5esdeday-trade_Medeiros_2021.pdf>. Acesso em: 20 set. 2025.

MITCHELL, Tom M. *Machine Learning*. New York: McGraw-Hill, 1997.

ORACLE. *O que é Machine Learning?* Disponível em: <<https://www.oracle.com/br/artificial-intelligence/machine-learning/what-is-machine-learning/>>. Acesso em: 29 abr. 2025.

PELLEGRINI, F. R.; FOGLIATTO, F. S. *Passos para implantação de sistemas de previsão de demanda – técnicas e estudo de caso*. Porto Alegre: Universidade Federal do Rio Grande do Sul, Programa de Pós-Graduação em Engenharia de Produção (PPGEP), 2001. p. 1.



IFLOG 2025 – XI Congresso Internacional de Logística e
Operações - ISSN 2596-2914

ROCCA, J. *Ensemble methods: bagging, boosting and stacking*. Medium –
Towards Data Science, **2019**. Disponível em:
<<https://towardsdatascience.com/ensemble-methods-bagging-boosting-and-stacking-c9214a10a205>>. Acesso em: **21 set. 2025**.

SILVEIRA, I. V. *Modelo de previsão de demanda com o uso de aprendizado supervisionado de máquina: um estudo de caso em uma empresa de varejo*. Dissertação (Mestrado em Engenharia de Produção) – UFSC, Florianópolis, 2019.