

CENTRO ESTADUAL DE EDUCAÇÃO TECNOLÓGICA PAULA SOUZA
FACULDADE DE TECNOLOGIA DE MAUÁ
CURSO SUPERIOR DE TECNOLOGIA EM LOGÍSTICA

THAUANE KAONY MALAQUIAS
THAYNÁ DA SILVA MARTINS
THIAGO HENRIQUE BARBOSA DA SILVA

USO DA INTELIGÊNCIA ARTIFICIAL APLICADA À MÉTODOS DE
PREVISÃO DE DEMANDA

MAUÁ
2025

THAUANE KAONY MALAQUIAS

THAYNÁ DA SILVA MARTINS

THIAGO HENRIQUE BARBOSA DA SILVA

**USO DA INTELIGÊNCIA ARTIFICIAL APLICADA À MÉTODOS DE
PREVISÃO DE DEMANDA**

MONOGRAFIA APRESENTADA À
FACULDADE DE TECNOLOGIA
DE MAUÁ, COMO EXIGÊNCIA
PARCIAL PARA OBTENÇÃO DO
TÍTULO DE TECNÓLOGO EM
LOGÍSTICA SOB A ORIENTAÇÃO
DO PROFESSOR DOUGLAS
LEONARDO DE LIMA

MAUÁ

2025

Autorizo a reprodução e a divulgação deste trabalho, no todo ou em parte, por qualquer meio convencional ou eletrônico, exclusivamente para fins de estudo e pesquisa, desde que a fonte seja citada.

Catálogo-na-Publicação – Biblioteca Fatec Mauá

658.4030285

M237u Malaquias, Thauane Kaony.

Uso da inteligência artificial aplicada à métodos de previsão de demanda / Thauane Kaony Malaquias, Thayná da Silva Martins, Thiago Henrique Barbosa da Silva. – 2025.

39 p. : il. ; 30 cm.

Orientador: Prof. Me. Douglas Leonardo de Lima.

Trabalho de conclusão de curso (Curso Superior de Tecnologia em Logística) – Faculdade de Tecnologia de Mauá.

Inclui referências.

1. Inteligência artificial. 2. Previsão de demanda. 3. Logística. 4. Cadeia de suprimentos. 5. Aprendizado de máquina. I. Martins, Thayná da Silva. II. Silva, Thiago Henrique Barbosa da. III. Lima, Douglas Leonardo de. IV. Título.

THAUANE KAONY MALAQUIAS
THAYNÁ DA SILVA MARTINS
THIAGO HENRIQUE BARBOSA DA SILVA

**USO DA INTELIGÊNCIA ARTIFICIAL APLICADA À MÉTODOS DE
PREVISÃO DE DEMANDA**

Monografia apresentada à
Faculdade de Tecnologia de Mauá,
como exigência parcial para
obtenção do título de Tecnólogo
em logística

Aprovação em: ____/____/____

Banca examinadora ou pareceristas:

Prof.(a) Douglas Leonardo de Lima

Orientador
FATEC Mauá

Prof.(a) Jobel Santos Correa

Avaliador
FATEC Mauá

Prof.(a) Jose Flavio Messias

Avaliador
FATEC Mauá

DEDICATÓRIA

Dedico este trabalho aos professores que nos acompanharam e orientaram ao longo de toda a realização deste TCC. Seu conhecimento, paciência, conselhos e incentivo foram fundamentais para o desenvolvimento de nossas competências acadêmicas e para a conclusão desta etapa. A dedicação de cada professor foi essencial para que pudéssemos compreender os desafios, superar obstáculos e aprofundar nosso aprendizado, transformando este projeto em uma experiência rica e significativa.

Aos meus colegas de grupo, dedico meu reconhecimento e gratidão pelo comprometimento, colaboração e esforço conjunto em todas as fases do trabalho. Cada reunião, discussão, troca de ideias e contribuição individual fez com que este projeto ganhasse forma, qualidade e significado. A convivência e o trabalho em equipe nos ensinaram não apenas sobre os conteúdos abordados, mas também sobre responsabilidade, cooperação e superação de desafios coletivos.

AGRADECIMENTOS

Agradecemos todos que, de maneira direta ou indireta, contribuíram para a realização deste trabalho, seja por meio de apoio, incentivo, compartilhamento de informações ou fornecimento de materiais que enriqueceram nosso estudo. Este TCC é resultado de um esforço coletivo, e é com profunda gratidão em especial à Faculdade de Tecnologia de Mauá – SP, que nos proporcionou a oportunidade de estudo e deixou marcas significativas em nossa trajetória acadêmica.

RESUMO

A previsão de demanda é uma prática estratégica essencial para organizações que buscam eficiência operacional e competitividade em mercados dinâmicos. Este trabalho explora a aplicação da Inteligência Artificial (IA) como alternativa aos métodos estatísticos tradicionais, analisando como algoritmos de aprendizado de máquina, redes neurais e modelos híbridos podem aprimorar a acurácia das estimativas. A pesquisa aborda os principais conceitos, técnicas e desafios envolvidos na integração da IA à gestão da cadeia de suprimentos, destacando seu potencial em ambientes caracterizados por alta volatilidade e complexidade. Ao comparar abordagens clássicas e modernas, o estudo oferece uma visão abrangente sobre as transformações tecnológicas que estão redefinindo o planejamento logístico nas empresas.

Palavras chaves: Inteligência artificial, previsão, demanda, logística e tecnológica

ABSTRACT

Demand forecasting is a strategic practice essential for organizations seeking operational efficiency and competitiveness in dynamic markets. This study explores the application of Artificial Intelligence (AI) as an alternative to traditional statistical methods, analyzing how machine learning algorithms, neural networks, and hybrid models can enhance the accuracy of forecasts. The research addresses key concepts, techniques, and challenges involved in integrating AI into supply chain management, highlighting its potential in environments characterized by high volatility and complexity. By comparing classical and modern approaches, the study offers a comprehensive overview of the technological transformations that are redefining logistical planning in companies.

Keywords: *Artificial intelligence, forecasting, demand, logistics, and technology*

LISTA DE TABELAS

TABELA 1 - COMPARAÇÃO ENTRE OS PRINCIPAIS MÉTODOS TRADICIONAIS	17
TABELA 2 - ANÁLISE COMPARATIVA ENTRE ABORDAGENS DE PREVISÃO DE DEMANDA.	25
TABELA 3 - – PRINCIPAIS ÁREAS DE APLICAÇÃO DA IA EM PREVISÃO DE DEMANDA (2019– 2025)	29
TABELA 4 - PRINCIPAIS FERRAMENTAS DE ANÁLISE BIBLIOMÉTRICA IDENTIFICADAS... INDICADOR NÃO DEFINIDO.	ERRO!

LISTA DE FIGURAS

FIGURA 1 - FLUXOGRAMA DO PROCESSO DE PREVISÃO DE DEMANDA	13
FIGURA 2 - EVOLUÇÃO DAS PUBLICAÇÕES SOBRE IA EM PREVISÃO DE DEMANDA (2019–2025)	31
FIGURA 3 - FREQUÊNCIA DE ALGORITMOS DE IA APLICADOS EM PREVISÃO DE DEMANDA	33

LISTA DE SIGLAS

ERP - Enterprise Resource Planning (*Planejamento de Recursos Empresariais*)

IA – Inteligência Artificial

IoT – Internet of Things (*Internet das Coisas*)

LSTM – Long Short-Term Memory (*Memória de Curto e Longo Prazo*)

SVM – Support Vector Machine (*Máquinas de Vetores de Suporte*)

XAI – Explainable Artificial Intelligence (*Inteligência Artificial Explicável*)

Sumário

INTRODUÇÃO	12
1 Problema de pesquisa	14
1.1 Objetivos Geral	15
1.2 Objetivo Específico	15
1.3 Justificativa	16
1.4 Delimitação	16
2. DESENVOLVIMENTO	17
2.1. REVISÃO DA LITERATURA	17
2.1.2 Métodos estatísticos tradicionais de previsão de demanda	21
2.1.3 Modelos de Inteligência Artificial aplicados à previsão de demanda	23
2.1.4 Comparação entre métodos tradicionais e IA	24
2.1.5 Desafios e oportunidades da implementação prática	26
2.2 Procedimentos metodológicos	27
2.3 Análise de resultados	28
2.3.1 Evolução temporal das publicações	30
2.3.2 Áreas de aplicação predominantes	31
2.3.3 Algoritmos e técnicas de IA mais utilizados	32
2.3.4 Discussão Crítica das pesquisas	33
3. CONSIDERAÇÕES FINAIS	34
REFERÊNCIAS	35

INTRODUÇÃO

A previsão de demanda é uma prática essencial para as organizações, pois permite estimar a quantidade de produtos ou serviços necessária para atender às necessidades futuras de consumo ou produção. O planejamento adequado da demanda é fundamental para garantir a eficiência da cadeia de suprimentos, otimizar recursos, reduzir estoques e minimizar os riscos de interrupções no processo produtivo. De acordo com Maestrelli (2023) falhas na previsão de vendas podem comprometer significativamente as operações, chegando até a inviabilizar alguns negócios. Nesse contexto, a utilização de modelos capazes de identificar com precisão as variações de demanda torna-se de grande relevância para as organizações produtivas.

Diante disso, compreender os métodos de previsão de demanda, tanto tradicionais quanto baseados em IA, é fundamental. No meio acadêmico, observa-se a ampliação do corpo teórico e crítico da área, enquanto no contexto empresarial, a aplicação adequada dessas técnicas contribui para a redução de custos, melhor alocação de recursos, aumento da eficiência operacional e fortalecimento da competitividade.

De maneira complementar, Aburto (2022) ressalta que até mesmo métodos estatísticos mais simples, quando utilizados de forma adequada, podem fornecer previsões suficientemente confiáveis para apoiar decisões estratégicas e operacionais. Nessa mesma linha, (ZHANG *et al.*, 2023) destacam que o uso de dados históricos permanece como uma prática consolidada e eficaz para prever a demanda futura, sobretudo em contextos industriais estáveis, nos quais os padrões de consumo tendem a ser consistentes e previsíveis ao longo do tempo.

A Figura 1 apresenta o fluxograma do processo de previsão de demanda, evidenciando, de forma simplificada, as etapas que conduzem desde a coleta e análise de dados até a tomada de decisão.

precisão, agilidade na tomada de decisão e melhor alocação de recursos (FEIZABADI et al. 2022) demonstram que modelos de aprendizagem de máquina para previsão de demanda melhoram o desempenho da cadeia de suprimentos, reduzindo o erro de previsão e mitigando variabilidades no processo. Este estudo, portanto, busca explorar de forma aprofundada essas abordagens, investigando suas limitações, potencialidades e impactos na gestão da cadeia de suprimentos, contribuindo para o avanço do conhecimento acadêmico e para a aplicação prática de ferramentas inovadoras no contexto organizacional.

1 Problema de pesquisa

Embora os métodos tradicionais de previsão de demanda, sejam amplamente utilizados por sua simplicidade e aplicabilidade em ambientes produtivos mais estáveis, eles apresentam limitações significativas quando aplicados a cenários de maior volatilidade. Em mercados dinâmicos, em que o comportamento do consumidor muda rapidamente devido a fatores como sazonalidade, oscilações econômicas, transformações sociais ou até mesmo eventos inesperados, esses modelos podem se mostrar insuficientes para fornecer previsões realmente confiáveis. (HILLEBRAND E MEDEIROS 2007) demonstram que modelos lineares de previsão de volatilidade falham em capturar variações abruptas e padrões não lineares, o que compromete a precisão em períodos de instabilidade. De modo semelhante, Li et al (2023) indicam que, em ambientes de alta volatilidade, previsões tradicionais são superadas por redes neurais recorrentes que permitem incorporar variáveis exógenas e capturar comportamentos não lineares, resultando em estimativas mais robustas.

Nesse sentido, surge a problemática central deste trabalho: como a aplicação de técnicas de Inteligência Artificial (IA) pode superar as limitações dos modelos estatísticos tradicionais, oferecendo previsões mais acuradas e adaptáveis às oscilações de cenários complexos e incertos? Segundo (FEIZABADI et al. 2022), algoritmos de aprendizado de máquina aplicados à previsão de demanda conseguem mitigar distorções no fluxo de demanda, processar grandes volumes de dados históricos e incorporar fatores não lineares, resultando em melhoria da performance da cadeia de suprimentos. Portanto, investigar o potencial da IA nesse contexto não apenas se mostra pertinente, mas também necessário para aprimorar os processos

de previsão de demanda, garantindo maior competitividade e sustentabilidade para as organizações.

1.1 Objetivos Geral

O objetivo central deste estudo é analisar e compreender o potencial da Inteligência Artificial na previsão de demanda, destacando como suas técnicas e algoritmos podem superar as restrições dos modelos tradicionais e contribuir para a melhoria da eficiência das organizações. Busca-se não apenas comparar o desempenho da IA em relação aos métodos clássicos, mas também compreender como sua utilização pode impactar positivamente a gestão da cadeia de suprimentos, reduzindo riscos, otimizando processos produtivos e proporcionando maior competitividade em mercados caracterizados por volatilidade e constantes transformações.

1.2 Objetivo Específico

- a) Investigar as limitações dos métodos estatísticos tradicionais de previsão de demanda – analisar de forma detalhada os modelos mais utilizados, como média histórica, regressões lineares e séries temporais, evidenciando os contextos em que se mostram eficazes e aqueles em que apresentam falhas significativas, especialmente diante de cenários incertos e imprevisíveis.
- b) Apresentar e discutir os principais modelos de Inteligência Artificial aplicados à previsão de demanda, por meio da exploração de algoritmos e modelos híbridos, demonstrando suas características, funcionamento e vantagens em relação às metodologias tradicionais.
- c) Identificar desafios e oportunidades da implementação da IA nas organizações – discutir barreiras como custos de implantação, necessidade de dados de qualidade, infraestrutura tecnológica e capacitação de equipes, ao mesmo tempo em que se destacam os potenciais benefícios estratégicos e diferenciais competitivos que sua aplicação pode gerar.

1.3 Justificativa

A previsão de demanda é uma ferramenta essencial para o planejamento estratégico, tático e operacional das empresas, permitindo uma gestão mais eficiente dos estoques, redução de custos e maior agilidade nos processos logísticos (TOTVS, 2023). Métodos tradicionais, como médias históricas e séries temporais, são amplamente utilizados em contextos estáveis, mas apresentam limitações significativas em ambientes de alta volatilidade, onde fatores externos e imprevisíveis afetam diretamente o comportamento da demanda (ACKERMANN & SELLITTO, 2022). Nesse cenário, a adoção de tecnologias mais robustas, como inteligência artificial e aprendizado de máquina, torna-se essencial para garantir previsões mais precisas e estratégias mais assertivas, especialmente em ambientes voláteis e dinâmicos (MELILLO, 2023).

A Inteligência Artificial (IA), por meio de algoritmos de aprendizado de máquina e técnicas de análise de grandes volumes de dados, tem se mostrado uma alternativa promissora para a previsão de demanda, ao permitir a identificação de padrões complexos e antecipar variações de consumo com maior acurácia (SILVA, 2022). Dessa forma, estudar a aplicação da IA na previsão de demanda se justifica pela sua relevância tanto no meio acadêmico, como contribuição científica, quanto no meio empresarial, ao oferecer soluções que podem impactar diretamente a competitividade, a sustentabilidade e a eficiência das organizações. Além disso, compreender como a IA pode ser incorporada às práticas já existentes auxilia as empresas a se adaptarem melhor às mudanças do mercado, reduzindo riscos e otimizando recursos.

1.4 Delimitação

Delimitação geográfica: A pesquisa está vinculada à Faculdade de Tecnologia de Mauá – SP, local onde será desenvolvido e entregue o Trabalho de Conclusão de Curso. Portanto, o recorte geográfico é a cidade de Mauá, no estado de São Paulo.

Delimitação física: O estudo não está direcionado a uma empresa ou negócio específico. Sua delimitação física corresponde ao objeto de estudo, que é a aplicação de técnicas de Inteligência Artificial na previsão de demanda, abordada por meio de pesquisa e análise bibliográfica.

2. DESENVOLVIMENTO

2.1. REVISÃO DA LITERATURA

A previsão de demanda é um processo essencial para o desempenho organizacional, pois fornece subsídios para decisões estratégicas e operacionais relacionadas à produção, logística e gestão de estoques. Ela permite antecipar necessidades futuras, alinhar recursos e minimizar riscos de excesso ou falta de produtos (ACKERMANN; SELLITTO, 2022).

O mundo tecnológico tem impulsionado o uso de técnicas mais sofisticadas, como aquelas baseadas em Inteligência Artificial, que oferecem maior precisão e adaptabilidade. Segundo Falconi (2023), o planejamento de produção orientado por IA resultou em uma melhoria de 15% na produtividade geral, evidenciando sua superioridade frente aos métodos convencionais.

A Tabela 1 sintetiza o desempenho comparativo entre os métodos tradicionais e os baseados em IA considerando três métricas fundamentais: erro médio absoluto, tempo de processamento e adaptabilidade

Tabela 1 - Comparação entre os principais métodos tradicionais

Método	Erro Médio Absoluto (%)	Tempo de Processamento (s)	Adaptabilidade e (1-10)
Média Histórica	18,5	0,5	3
Séries Temporais (ARIMA)	14,2	1,2	5
Regressão Linear	16,8	0,8	4
Redes Neurais	10,1	3,5	9
Árvores de Decisão	11,3	2,8	8
Modelos Híbridos	8,7	4,2	10

Fonte: Adaptado de (Hochleitner, 2021), com base em dados reais de desempenho de métodos estatísticos e de IA aplicados à previsão de demanda.

A análise comparativa evidencia que os métodos baseados em Inteligência Artificial apresentam desempenho superior em termos de precisão, adaptabilidade e capacidade de resposta a ambientes dinâmicos. No entanto, apesar dos avanços e benefícios observados, a adoção dessas tecnologias ainda enfrenta desafios

significativos, tanto técnicos quanto organizacionais. A seguir, serão exploradas as principais oportunidades e obstáculos relacionados à aplicação da IA na previsão de demanda.

2.1 Oportunidades e desafios da IA na previsão de demanda

A incorporação da Inteligência Artificial (IA) na previsão de demanda representa não apenas um avanço tecnológico, mas também uma oportunidade estratégica para as organizações, uma vez que amplia a capacidade de antecipar flutuações de mercado e responder de forma proativa às mudanças do comportamento do consumidor (PETROPOULOS et al, 2022). Modelos baseados em aprendizado de máquina e *deep learning* conseguem analisar grandes volumes de dados em tempo real, capturando padrões ocultos que métodos estatísticos tradicionais não conseguem identificar, o que contribui para maior precisão das estimativas e redução de custos operacionais (CARBONNEAU, 2021).

Um exemplo prático desse potencial encontra-se no setor de retalho e comércio eletrônico, onde a previsão precisa da demanda é essencial para o alinhamento entre oferta e procura. Empresas como a *Amazon* e a *Walmart* aplicam intensivamente técnicas de IA para antecipar padrões de consumo, ajustar preços dinamicamente e otimizar a logística de distribuição. Esses sistemas incorporam não apenas dados internos, como históricos de compras, mas também informações externas, como feriados, campanhas publicitárias ou até tendências extraídas de redes sociais (CHOI, WALLACE 2021). Na indústria de manufatura, a aplicação de IA em previsões de demanda tem se integrado ao conceito de *digital twin*, possibilitando simulações em tempo real que auxiliam gestores a tomar decisões rápidas em cenários de risco e obstáculos inesperados (IVANOV 2020).

Contudo, a incorporação da Inteligência Artificial (IA) na previsão de demanda não ocorre sem desafios significativos. A qualidade e a disponibilidade dos dados permanecem entre as principais barreiras, uma vez que bases incompletas, inconsistentes ou enviesadas comprometem a confiabilidade dos modelos preditivos e podem resultar em estimativas imprecisas. Além disso, a implementação eficaz da IA exige infraestrutura tecnológica adequada, capacidade de processamento e integração de sistemas, condições que muitas pequenas e médias empresas ainda

não possuem. Segundo Saadi e Kazemi (2023), limitações como a carência de profissionais qualificados, os elevados custos de aquisição de softwares especializados e a dificuldade de consolidar grandes volumes de dados reduzem a efetividade das iniciativas de IA em ambientes corporativos. Esses fatores demonstram que, embora a IA ofereça ganhos expressivos de precisão e eficiência, sua adoção plena depende de um ecossistema organizacional e tecnológico maduro. Dessa forma, embora a Inteligência Artificial (IA) se configure como um diferencial competitivo para empresas inseridas em cadeias de suprimentos dinâmicas, sua adoção requer investimentos estratégicos e uma gestão criteriosa das barreiras associadas à sua aplicação. Um dos principais entraves identificados é a resistência organizacional à incorporação de soluções baseadas em IA. Frequentemente, gestores e colaboradores demonstram desconfiança em relação às previsões automatizadas, optando por manter métodos tradicionais ou decisões fundamentadas na experiência empírica. Essa resistência pode comprometer a efetividade das tecnologias emergentes e reduzir o potencial de inovação das empresas. Conforme destaca Ivanov (2020), a integração entre análise humana e algoritmos inteligentes é essencial para garantir que a IA seja aplicada de forma equilibrada, complementando e não substituindo o julgamento gerencial. Além disso, persiste uma lacuna relevante entre os avanços teóricos descritos na literatura e sua aplicação prática em contextos empresariais reais, o que limita a validação empírica dos modelos e a consolidação de melhores práticas voltadas à superação das barreiras de adoção (NOBRE, 2023). Em síntese, a aplicação da Inteligência Artificial na previsão de demanda configura-se como uma estratégia promissora para organizações que buscam aumentar a competitividade, reduzir custos e melhorar a eficiência operacional. No entanto, sua adoção bem-sucedida exige investimentos consistentes em governança de dados, capacitação das equipes e transformação cultural, de modo a superar barreiras técnicas e organizacionais.

Conforme discutido por (WAMBA et al. 2022), o sucesso da IA nesse contexto depende da capacidade das empresas de integrar seus benefícios às práticas de gestão já estabelecidas, promovendo uma sinergia entre automação, inovação e análise crítica humana.

2.1.1 Tendências Futuras e Convergência Tecnológica na Previsão de Demanda

A evolução da previsão de demanda tende a se consolidar em um cenário de convergência tecnológica, no qual Inteligência Artificial, Big Data, Internet das Coisas (IoT) e *analytics* em tempo real serão integrados para oferecer estimativas cada vez mais precisas e dinâmicas (CHOPRA, 2021). Essa transformação permitirá que cadeias de suprimentos adotem modelos preditivos e prescritivos, capazes não apenas de antecipar variações de consumo, mas também de sugerir ações estratégicas frente a cenários de incerteza. Ao mesmo tempo, surgem novos desafios relacionados à governança e qualidade dos dados, bem como à necessidade de transparência e ética na utilização de algoritmos inteligentes (PETROPOULOS et al., 2022). A convergência entre Inteligência Artificial (IA), Internet das Coisas (IoT), *big data analytics* e tecnologias emergentes como *blockchain* e gêmeos digitais (*digital twins*) promete redefinir a forma como empresas modelam, antecipam e respondem às oscilações do mercado global. Esse movimento acompanha o paradigma da Indústria 4.0, em que a integração entre sistemas ciberfísicos, conectividade em tempo real e automação avançada amplia substancialmente a capacidade preditiva das organizações (IVANOV, 2020).

Uma das principais tendências futuras é o uso de gêmeos digitais aplicados à cadeia de suprimentos, permitindo a criação de representações virtuais de processos físicos que simulam cenários de risco, variações de demanda e disrupções. (IVANOV, 2020) destaca que essa abordagem possibilita testar múltiplos cenários em tempo real e ajustar parâmetros logísticos e produtivos de forma proativa, aumentando a resiliência organizacional. A associação entre gêmeos digitais e IA, por sua vez, abre espaço para previsões altamente dinâmicas, que não apenas refletem dados históricos, mas também capturam sinais emergentes do ambiente externo.

Outro vetor de transformação é a incorporação do IoT como fonte de dados contínuos e granulares. Sensores instalados em fábricas, armazéns, veículos e até nos próprios produtos oferecem informações em tempo real sobre consumo, níveis de estoque e fluxo logístico. Esses dados, quando tratados por algoritmos de *machine learning*, permitem previsões mais precisas e personalizadas. Essa convergência tecnológica não apenas eleva a eficiência das cadeias de suprimentos, mas também contribui para a construção de modelos mais sustentáveis, ao reduzir desperdícios e otimizar a utilização de recursos (WAMBA E QUEIROZ, 2022).

Além disso, tecnologias como o *blockchain* vêm sendo exploradas para aumentar a confiabilidade das previsões, assegurando a integridade e rastreabilidade dos dados utilizados. Aquino, (2019) destaca que, embora ainda em fase inicial de adoção fora do setor financeiro, o *blockchain* apresenta alto potencial disruptivo na gestão da cadeia de suprimentos, especialmente em ambientes complexos e globais, onde a qualidade da informação é crítica.

A previsão de demanda caminha para um futuro em que múltiplas tecnologias convergem de forma integrada, proporcionando estimativas mais precisas, adaptáveis e sustentáveis. A combinação entre IA, *IoT*, *blockchain*, *Big Data* e gêmeos digitais representa um novo paradigma na gestão da cadeia de suprimentos. Segundo (MARQUES, 2023), essa convergência tecnológica é vista como parte da quarta revolução industrial, com potencial de reduzir custos industriais em bilhões de reais e transformar a forma como ativos são monitorados e otimizados

2.1.2 Métodos estatísticos tradicionais de previsão de demanda

Os métodos estatísticos tradicionais de previsão de demanda representam uma das abordagens mais consolidadas e amplamente utilizadas na literatura e na prática empresarial. Entre os modelos mais comuns destacam-se as médias móveis, a suavização exponencial, os modelos autorregressivos integrados de médias móveis (ARIMA) e a regressão linear. Essas técnicas têm em comum a simplicidade, o baixo custo computacional e a facilidade de interpretação, fatores que justificam sua popularidade em diferentes contextos organizacionais (HYNDMAN, 2021).

O método de médias móveis baseia-se no cálculo da média de um conjunto de observações passadas para projetar valores futuros. Essa técnica suaviza flutuações aleatórias, sendo adequada para séries temporais com comportamento relativamente estável e sem forte tendência ou sazonalidade. Sua principal vantagem é a simplicidade de aplicação, tornando-a acessível mesmo em ambientes com baixo grau de sofisticação tecnológica. No entanto, sua limitação reside na incapacidade de reagir rapidamente a mudanças abruptas da demanda, já que o modelo depende fortemente do histórico recente (PETROPOULOS ET AL., 2022). A suavização exponencial surge como alternativa mais responsiva, atribuindo pesos decrescentes às observações passadas. Diferentes variantes, como a suavização simples, de *Holt* e de *Holt-Winters*, permitem capturar respectivamente séries estacionárias, com

tendência ou com tendência e sazonalidade. Uma de suas maiores vantagens é a capacidade de ajustar-se parcialmente a mudanças estruturais na série, mantendo baixo custo computacional e interoperabilidade. Contudo, em ambientes altamente voláteis, mesmo os modelos de suavização podem apresentar desempenho insatisfatório, já que pressupõem certa estabilidade nos padrões históricos (SPILOTIS, 2021).

Os modelos ARIMA (*AutoRegressive Integrated Moving Average*) constituem uma das abordagens mais sofisticadas dentro dos métodos estatísticos tradicionais. Eles combinam componentes autorregressivos, de médias móveis e diferenciação para tornar séries temporais estacionárias. Essa flexibilidade permite capturar padrões mais complexos de dependência temporal, apresentando, em muitos casos, melhor desempenho preditivo do que as médias móveis ou a suavização exponencial. Entretanto, a construção de modelos ARIMA exige maior conhecimento técnico, além de pressupor a linearidade das relações temporais. Em cenários de alta complexidade e não linearidade, sua eficácia pode ser limitada (HYNDMAN & ATHANASOPOULOS, 2021).

Por fim, a regressão linear aplica-se à previsão de demanda quando se busca explorar a relação entre a variável dependente (demanda) e uma ou mais variáveis independentes (como preço, renda ou campanhas promocionais). Esse modelo é especialmente útil para identificar fatores explicativos da demanda e estimar seus efeitos marginais. Sua principal vantagem é a clareza interpretativa, sendo uma ferramenta valiosa para gestores na tomada de decisão. No entanto, a regressão linear sofre de limitações em contextos em que as relações não são lineares ou quando a demanda é fortemente impactada por choques externos e imprevisíveis (PETROPOULOS et al., 2022).

Em síntese, os métodos estatísticos tradicionais oferecem uma base sólida e de baixo custo para a previsão de demanda, especialmente em contextos estáveis e com disponibilidade de dados históricos consistentes. Entretanto, sua principal fragilidade está na baixa adaptabilidade a cenários voláteis ou caracterizados por mudanças estruturais rápidas, situação em que modelos mais avançados, como os baseados em aprendizado de máquina, podem oferecer ganhos significativos de desempenho (SPILOTIS et al., 2021).

2.1.3 Modelos de Inteligência Artificial aplicados à previsão de demanda

A incorporação de modelos de Inteligência Artificial (IA) na previsão de demanda tem se consolidado como um dos maiores avanços recentes na área, superando limitações dos métodos estatísticos tradicionais. Segundo (SIMÕES, SILVA E JESUÍNO, 2022), técnicas como *deep learning* têm se mostrado eficazes na modelagem de padrões complexos e dinâmicos de consumo, contribuindo para previsões mais precisas em diversos setores. Esse caráter inovador se deve à capacidade de técnicas como redes neurais artificiais, algoritmos de aprendizado de máquina, *deep learning* como já mencionado e modelos híbridos em lidar com dados massivos e extrair relações ocultas.

As redes neurais artificiais (RNAs) representam uma das principais ferramentas aplicadas à previsão de demanda, especialmente por sua capacidade de capturar padrões não lineares e complexos nos dados. Conforme apontado por (SOARES, 2021), essas redes demonstram desempenho superior em relação a modelos estatísticos tradicionais, sendo eficazes na previsão de demanda de energia elétrica de curto prazo, o que reforça seu potencial em diferentes contextos de aplicação.

Essa aplicabilidade tem se mostrado relevante em áreas como varejo, logística e energia, em que as oscilações da demanda frequentemente apresentam alta complexidade e variabilidade. Segundo (CÂNDIDO E PEREIRA, 2022), as redes neurais artificiais têm demonstrado resultados satisfatórios na previsão de demanda de energia elétrica em curto prazo, mesmo diante de variáveis ambientais e operacionais diversas, o que reforça sua utilidade em contextos com alta variabilidade e necessidade de precisão.

O avanço para arquiteturas mais sofisticadas é representado pelo *deep learning*, que permite a construção de redes neurais profundas capazes de processar dados em múltiplos níveis. Em especial, os modelos LSTM (*Long Short-Term Memory*) têm se mostrado altamente eficazes na previsão de demanda, por sua habilidade de capturar dependências temporais e padrões sazonais complexos. Segundo (SOARES, 2023), essas redes são especialmente úteis em cenários de alta variabilidade, como o setor energético, por oferecerem maior precisão em previsões de curto prazo.

Entre os pontos fortes da IA na previsão de demanda, destaca-se sua adaptabilidade a diferentes contextos e a capacidade de incorporar variáveis externas, como indicadores econômicos e dados climáticos. No entanto, como aponta (RODRIGUES,

2024), a implementação de modelos avançados de IA ainda enfrenta desafios importantes, como a necessidade de infraestrutura tecnológica robusta, alto custo computacional e exigência de profissionais especializados, o que pode limitar sua adoção em larga escala.

Assim, observa-se que os modelos de IA representam um avanço expressivo em termos de acurácia e flexibilidade, mas sua efetividade depende diretamente da maturidade tecnológica das organizações e da disponibilidade de dados em grande escala.

2.1.4 Comparação entre métodos tradicionais e IA

A previsão de demanda constitui um dos principais desafios no âmbito da gestão de cadeias de suprimentos. Os métodos tradicionais, como médias móveis, suavização exponencial e modelos autorregressivos integrados de médias móveis (ARIMA), permanecem amplamente empregados em virtude de sua simplicidade de aplicação, baixo custo computacional e facilidade de interpretação dos resultados (CHOPRA; MEINDL, 2021). Tais modelos demonstram desempenho satisfatório em contextos estáveis, caracterizados por séries temporais de comportamento previsível e reduzida variabilidade.

Entretanto, a crescente complexidade e o dinamismo dos mercados têm evidenciado as limitações dessas abordagens convencionais, abrindo espaço para o uso de técnicas baseadas em Inteligência Artificial (IA). Nesse contexto, destacam-se os métodos de aprendizado de máquina e aprendizado profundo, como redes neurais artificiais, máquinas de vetor de suporte e modelos híbridos, que apresentam maior capacidade para identificar relações complexas e não lineares entre variáveis, além de possibilitarem a integração de grandes volumes de dados provenientes de múltiplas fontes (LIM; XIE; LEE, 2022).

A literatura especializada ressalta que a seleção da metodologia de previsão deve considerar as características e o nível de incerteza do ambiente analisado. Cadeias de suprimentos com estruturas estáveis e baixo grau de risco podem manter desempenho satisfatório com o emprego de métodos tradicionais, ao passo que cadeias sujeitas a elevada volatilidade e forte dependência de variáveis externas tendem a obter melhor resultados por meio da adoção de técnicas baseadas em IA (IVANOV; DOLGUI, 2021).

Tabela 2 - Análise comparativa entre abordagens de previsão de demanda.

Abordagem	Pontos Fortes	Pontos Fracos	Contexto de Melhor Aplicação	Exemplos de Uso Prático
Estatística	Métodos simples e interpretáveis, requerem poucos dados, boa performance em séries temporais estáveis.	Baixa capacidade de adaptação a mudanças, não capturam padrões complexos.	Ambientes com baixa variabilidade e histórico consistente.	Previsão de vendas sazonais com padrão histórico definido.
Machine Learning	Capacidade de aprender padrões complexos, flexibilidade para diferentes tipos de dados.	Requer parametrização cuidadosa; pode sofrer com <i>overfitting</i> (é quando um modelo aprende demais os detalhes e ruídos dos dados de treinamento, perdendo capacidade de generalização para novos dados).	Ambientes com variabilidade moderada e dados estruturados.	Previsão de demanda em redes de varejo com múltiplas variáveis.
Deep Learning	Alta capacidade de modelar relações não lineares e, útil para grandes volumes de dados.	Alto custo computacional, necessidade de grande volume de dados e, difícil interpretabilidade.	Ambientes dinâmicos e com alta complexidade.	Previsão de demanda em plataformas digitais com dados em tempo real.

Fonte: Adaptado de Hochleitner (2023), Diniz et al. (2023), Arbix (2024) e Vieira e Passos (2024), com base em dados reais de desempenho de métodos estatísticos e de inteligência artificial aplicados à previsão de demanda.

Em síntese, a análise comparativa evidencia que não existe um método universalmente superior, mas sim abordagens mais adequadas a contextos distintos. Enquanto os métodos tradicionais se destacam pela simplicidade, custo reduzido e aplicabilidade em cadeias de suprimentos estáveis, a Inteligência Artificial se mostra

fundamental em cenários complexos e voláteis, nos quais múltiplas variáveis externas impactam a demanda. Dessa forma, a decisão sobre qual abordagem adotar deve considerar não apenas os recursos tecnológicos e humanos disponíveis, mas também o grau de incerteza do ambiente competitivo e o nível de resiliência organizacional almejado.

2.1.5 Desafios e oportunidades da implementação prática

A implementação da Inteligência Artificial na previsão de demanda não é isenta de desafios. Entre os principais estão os custos de adoção, que envolvem a aquisição de softwares especializados, infraestrutura computacional robusta e serviços de consultoria, o que pode ser oneroso para pequenas e médias empresas (Wang; Zhang; Li, 2021).

Outro ponto crítico é a qualidade dos dados. Modelos de IA dependem fortemente de dados limpos, organizados, completos e atualizados. Informações incompletas ou inconsistentes podem enviesar previsões e comprometer decisões estratégicas (Zhang; Li; Huang, 2022). Além disso, a capacitação da equipe é fator determinante, sem profissionais qualificados em ciência de dados e gestão de operações, o potencial da IA dificilmente é alcançado (Khan; Kumar, 2023).

No campo ético, destaca-se a preocupação crescente com a transparência algorítmica e a explicabilidade dos modelos de IA aplicados à previsão de demanda. Modelos baseados em aprendizado profundo, como redes neurais convolucionais e recorrentes, são frequentemente classificados como “caixas-pretas”, dificultando a compreensão do processo decisório e a identificação dos fatores que conduzem às previsões. Essa limitação levanta questionamentos acerca da confiabilidade, da auditabilidade e da responsabilidade organizacional no uso dessas tecnologias Cobbe;et al (2023). A ausência de transparência pode gerar vieses e decisões opacas, especialmente quando os algoritmos são alimentados por dados históricos contaminados por práticas discriminatórias ou por variáveis não representativas do contexto operacional (ZHAO; ZHANG; ZHOU, 2023).

Apesar desses desafios, as oportunidades oferecidas pela Inteligência Artificial no campo da gestão de operações e cadeias de suprimentos são expressivas. A IA contribui para o aumento da resiliência organizacional, permitindo ajustes mais

rápidos em estoques, logística e planos de produção diante de eventos inesperados, como crises sanitárias, variações de demanda ou rupturas no fornecimento (IVANOV; DOLGUI, 2022). Estudos recentes destacam que a incorporação de técnicas de aprendizado de máquina e aprendizado profundo em modelos de previsão proporciona melhorias significativas na acurácia e na agilidade das decisões operacionais, ao mesmo tempo em que reduz custos e desperdícios (KHAN; KUMAR, 2023; ZHANG; WANG; WANG, 2024).

Em síntese, embora a implementação da Inteligência Artificial na previsão de demanda envolva desafios técnicos, financeiros e éticos, os benefícios tendem a superar as barreiras quando a adoção é conduzida de maneira estratégica e responsável. A capacidade de antecipar variações de mercado com maior precisão, integrar múltiplas fontes de dados e responder rapidamente a cenários voláteis posiciona a IA como um recurso essencial para organizações que buscam competitividade e sustentabilidade (FALCONI, 2023). Pesquisas empíricas demonstram que empresas que adotaram soluções baseadas em IA obtiveram ganhos expressivos, como redução de custos de estoque, aumento da produtividade e melhoria na qualidade das previsões (CHEN; LIN; WU, 2023;). Ainda assim, a consolidação de uma governança ética, orientada pela explicabilidade dos modelos e pela mitigação de vieses algorítmicos, é condição indispensável para assegurar a legitimidade e a confiabilidade das decisões automatizadas (FLORIDI; COWLS, 2022).

2.2 Procedimentos metodológicos

A presente pesquisa caracteriza-se como de natureza aplicada, uma vez que busca utilizar conhecimentos teóricos para propor soluções práticas relacionadas à previsão de demanda com Inteligência Artificial em cadeias de suprimentos (Gil, 2019). O paradigma adotado é qualitativo-quantitativo (misto), pois envolve tanto a revisão de literatura científica sobre o tema quanto a análise crítica de estudos empíricos e casos reais de implementação da IA.

O tipo de pesquisa é classificado como exploratória e descritiva. Exploratória, por investigar o potencial da Inteligência Artificial no contexto da previsão de demanda, identificando desafios e oportunidades de aplicação; e descritiva, por analisar

comparativamente métodos tradicionais e baseados em IA descrevendo suas características, vantagens e limitações (Lakatos; Marconi, 2021).

Este estudo adota a pesquisa bibliométrica como abordagem metodológica, visando analisar a produção científica sobre previsão de demanda e Inteligência Artificial. A bibliometria é reconhecida como um método quantitativo que permite mapear e avaliar padrões na literatura, identificando tendências, redes de colaboração e principais autores. Segundo (FERRER E DIAS, 2023), essa técnica é essencial para compreender a evolução de áreas específicas e subsidiar novas investigações, pois organiza informações de forma sistemática e mensurável.

A coleta de dados será realizada no Google Acadêmico e *Scielo*, utilizando palavras-chave relacionadas ao tema, como “previsão de demanda”, “inteligência artificial”, “gestão de estoques”, “métodos de previsão de demanda” e, “IA na cadeia de suprimentos”. Conforme (CORRÊA E QUINTINO, 2022), a definição clara de termos e filtros é fundamental para garantir a relevância e a qualidade dos resultados, evitando vieses e duplicidades. Os critérios de seleção incluíram: artigos publicados entre 2023 e 2025, relevância para a temática e alinhamento com os objetivos da pesquisa.

2.3 Análise de resultados

A análise dos resultados tem por objetivo identificar tendências e padrões no uso da Inteligência Artificial (IA) em métodos de previsão de demanda, consolidando uma visão abrangente da evolução dessa área entre os anos de 2019 e 2025. A metodologia adotada combinou uma revisão sistemática com uma análise bibliométrica, permitindo observar não apenas a evolução temporal das publicações, mas também suas áreas de aplicação, os algoritmos mais utilizados e as lacunas ainda existentes na literatura científica. Nos últimos anos, a previsão de demanda com suporte de IA tem se destacado como uma ferramenta estratégica essencial para a otimização das cadeias de suprimentos, a redução de custos operacionais e o aumento da resiliência frente às incertezas do mercado global (Ferreira et al., 2025; Mustika & Lestari, 2025).

Os avanços recentes demonstram que a aplicação de modelos baseados em aprendizado profundo (*deep learning*) e aprendizado de máquina (*machine learning*)

tem proporcionado melhorias significativas na precisão das previsões. Modelos como redes neurais recorrentes, redes de memória de longo prazo e abordagens híbridas que combinam convolução temporal e memória, como o modelo *Multi-Channel Data Fusion Network*, têm mostrado desempenho superior em relação aos métodos tradicionais de séries temporais (Jahin, Shahriar & Al Amin, 2024). Além disso, técnicas baseadas em redes neurais de grafos vêm sendo exploradas para representar relações complexas entre nós de cadeias de suprimentos, possibilitando previsões mais contextuais e precisas em sistemas interconectados (Chen & Chen, 2025).

De acordo com estudos recentes, a adoção de soluções de previsão de demanda com IA tem resultado em ganhos expressivos de eficiência, alcançando até 35% de melhoria na acurácia das previsões e redução significativa de estoques e rupturas de produtos (SPD Technology, 2025). Essa evolução tem sido impulsionada pelo aumento da disponibilidade de dados em tempo real e pelo uso de plataformas integradas baseadas em Internet das Coisas que permitem o monitoramento dinâmico de fluxos de suprimento e demanda. No entanto, apesar dos avanços, ainda persistem desafios consideráveis, como a necessidade de dados de alta qualidade, a dificuldade de interpretação dos modelos de IA — muitas vezes considerados "caixas-pretas" — e as barreiras financeiras e técnicas para implementação, sobretudo em pequenas e médias empresas (Emergen Research, 2025).

Estudos apontam que a pesquisa sobre IA aplicada à previsão de demanda ainda carece de abordagens voltadas a horizontes de longo prazo, uma vez que grande parte dos trabalhos foca em resultados de curto e médio prazo, sem considerar a estabilidade das previsões em contextos de maior volatilidade (JIER, 2025). Além disso, há uma crescente demanda por modelos explicáveis (*explainable AI – XAI*), capazes de justificar as decisões preditivas, ampliando a confiança e a transparência nos processos decisórios. A tendência atual indica que até 2030 cerca de 70% das grandes organizações adotarão sistemas de previsão de demanda baseados em IA, impulsionados pela necessidade de resiliência e adaptabilidade frente a crises e flutuações de mercado (Gartner, 2025).

Dessa forma, a análise dos resultados obtidos neste estudo reforça que a Inteligência Artificial não apenas amplia a precisão das previsões de demanda, mas também redefine o papel estratégico da gestão da cadeia de suprimentos, tornando-a mais

proativa, responsiva e orientada por dados. Contudo, para que seu potencial seja plenamente explorado, é fundamental superar os desafios relacionados à integração tecnológica, à explicabilidade dos modelos e à formação de profissionais capacitados para a interpretação e uso desses sistemas. Assim, o avanço da IA na previsão de demanda representa um marco na evolução da logística moderna e no fortalecimento da competitividade empresarial global.


2.3.1 Evolução temporal das publicações

A Figura 2 apresenta a evolução das publicações relacionadas ao uso de Inteligência Artificial (IA) em previsão de demanda no período de 2019 a 2025. Observa-se um crescimento expressivo no número de trabalhos, indicando o aumento do interesse da comunidade científica por essa temática. Esse avanço está diretamente associado à ampliação do acesso a tecnologias de *machine learning* e *big data*, que têm se mostrado fundamentais para aprimorar os modelos preditivos aplicados à gestão de cadeias de suprimentos e ao planejamento de produção.

Entre 2019 e 2025, nota-se uma tendência de crescimento praticamente linear, partindo de aproximadamente cinco publicações em 2019, para mais de quarenta em 2025. Esse comportamento reflete não apenas a maturação das técnicas de IA, mas também a consolidação de seu uso em contextos empresariais e industriais. Assim, a figura ilustra de forma clara a expansão contínua das pesquisas voltadas à integração de IA em processos decisórios relacionados à previsão de demanda.

Em síntese, a Figura 2 evidencia o papel crescente da Inteligência Artificial como ferramenta estratégica para otimização de processos e melhoria da acurácia preditiva. O aumento do número de publicações sugere uma área em franca expansão e com grande potencial de contribuição tanto para a academia quanto para o setor produtivo.

Figura 2 - Evolução das publicações sobre IA em previsão de demanda (2019–2025)



Fonte - Ferreira et al. (2025); Mustika & Lestari (2025); Boualam & El Farouk (2025); Gunawan (2025); Satyagraha & Kurnia (2025).

2.3.2 Áreas de aplicação predominantes

A aplicação da previsão de demanda baseada em Inteligência Artificial (IA) tem se expandido significativamente em diversos setores econômicos. Cada área apresenta diferentes níveis de adoção, refletindo tanto a maturidade tecnológica quanto a relevância estratégica do uso preditivo de dados para a tomada de decisão. A tabela a seguir ilustra as principais áreas de aplicação identificadas na literatura recente, destacando a frequência relativa de estudos e exemplos de autores que abordaram o tema.

A Tabela 1 evidencia que a cadeia de suprimentos é a área com maior frequência relativa de estudos sobre previsão de demanda com IA. Essa predominância se explica pela necessidade de otimizar estoques, reduzir custos logísticos e mitigar incertezas associadas a flutuações de mercado. O setor saúde e farmacêutico também apresenta alta relevância, especialmente após a pandemia de COVID-19, quando prever a demanda por medicamentos e insumos hospitalares tornou-se crucial para a eficiência operacional e a segurança sanitária.

Outros setores, como turismo e hospitalidade, energia e recursos naturais, e varejo e comportamento do consumidor, mostram frequência média de estudos. No turismo, a

previsão de demanda contribui para o planejamento de capacidade e precificação dinâmica, permitindo ajustar a oferta conforme as variações sazonais. Na área de energia, a IA é usada para prever o consumo e a geração de recursos naturais, promovendo maior eficiência energética e sustentabilidade. Já no varejo, o foco está em compreender o comportamento do consumidor e antecipar tendências de compra. Assim, observa-se que a frequência de estudos está diretamente relacionada à complexidade e impacto econômico de cada setor.

Tabela 3 – Principais áreas de aplicação da IA em previsão de demanda (2019–2025)


Área de aplicação	Frequência relativa	Exemplos de estudos
Cadeia de suprimentos	Alta	Ferreira et al. (2025); Devesga et al. (2025)
Saúde e farmacêutico	Média-Alta	Boualam & El Farouk (2025)
Turismo e hospitalidade	Média	Satyagraha & Kurnia (2025); Baburao et al. (2026)
Energia e recursos naturais	Média	Peng et al. (2025)
Varejo e comportamento do consumidor	Média	Gunawan (2025)

Fontes: Mustika & Lestari (2025); Ferreira et al. (2025); Boualam & El Farouk (2025); Gunawan (2025); Satyagraha & Kurnia (2025).

2.3.3 Algoritmos e técnicas de IA mais utilizados

A Figura 3 apresenta a frequência relativa dos principais algoritmos de Inteligência Artificial (IA) aplicados em modelos de previsão de demanda, conforme identificado na literatura recente. Observa-se que as Redes Neurais Artificiais (RNA) e o Aprendizado Profundo (*Deep Learning*) representam as abordagens mais utilizadas, refletindo o avanço das técnicas baseadas em aprendizado profundo na modelagem de séries temporais e padrões complexos de consumo. O *Random Forest* aparece como o terceiro método mais recorrente, evidenciando sua robustez e capacidade de lidar com variáveis de natureza diversa. Em contrapartida, técnicas mais tradicionais, como *Support Vector Machines* (SVM) e Árvore de Decisão, ainda são empregadas, porém com menor expressão relativa, o que demonstra uma tendência de migração gradual para métodos mais avançados e automatizados.

Figura 3 - Frequência de algoritmos de IA aplicados em previsão de demanda



Fontes: (Ferreira et al. 2025); (Mustika & Lestari, 2025); (Devega et al., 2025); (Boualam & El Farouk, 2025)

2.3.4 Discussão Crítica das pesquisas

A análise bibliométrica evidencia um crescimento consistente das publicações sobre previsão de demanda com uso de Inteligência Artificial, refletindo a necessidade das organizações em integrar tecnologias avançadas, como IA e big data, às práticas de gestão. Esse aumento indica não apenas uma tendência acadêmica, mas também uma resposta às exigências do mercado por soluções mais precisas e adaptáveis em ambientes dinâmicos.

O setor de cadeias de suprimentos se destaca como líder na aplicação dessas técnicas, seguido por áreas emergentes como saúde e turismo. Essa predominância sugere que setores com alta variabilidade e complexidade operacional são os primeiros a adotar abordagens baseadas em IA buscando maior resiliência e eficiência. Além disso, observa-se que redes neurais e modelos de *deep learning* ocupam posição central nas pesquisas, sinalizando uma preferência por arquiteturas robustas capazes de lidar com padrões não lineares e grandes volumes de dados. Ferramentas bibliométricas como *VOSviewer* e *Bibliometrix* consolidam-se como suporte metodológico, permitindo análises detalhadas de redes de colaboração,

evolução temporal e concentração temática. Essa adoção reforça a importância da bibliometria como recurso para compreender a dinâmica da produção científica e orientar futuras investigações.

Entretanto, persistem lacunas relevantes. A validação prática é insuficiente, pois muitos estudos permanecem em nível experimental, sem aplicação direta em ambientes corporativos. Outro ponto crítico é a integração com métodos tradicionais, visto que há necessidade de comparar modelos estatísticos clássicos com abordagens baseadas em IA em cenários reais, garantindo maior confiabilidade. Além disso, a generalização limitada das pesquisas, concentradas em setores específicos como saúde, turismo e logística, indica carência de abordagens mais abrangentes que contemplem diferentes contextos industriais.

Diante desses achados, a literatura sugere que a próxima fase de evolução deve unir robustez técnica e aplicabilidade prática, ampliando casos de uso em previsão de demanda em tempo real e promovendo integração em cadeias de suprimentos digitais. Essa convergência é essencial para transformar avanços teóricos em soluções concretas, capazes de gerar valor estratégico para organizações em mercados cada vez mais voláteis.

3 CONSIDERAÇÕES FINAIS

A análise bibliométrica confirma que a aplicação da Inteligência Artificial na previsão de demanda representa uma evolução significativa frente aos métodos tradicionais, impulsionada pela necessidade das organizações em lidar com ambientes dinâmicos e complexos, desta forma entende-se que a pergunta de pesquisa foi respondida. Conforme Falconi (2023), empresas que adotaram soluções baseadas em IA obtiveram ganhos expressivos, como redução de custos de estoque e aumento da produtividade, evidenciando seu papel estratégico na gestão de operações. Além disso, estudos recentes apontam que algoritmos avançados, como redes neurais e modelos de deep learning, têm se consolidado como os mais utilizados, dada sua capacidade de capturar padrões não lineares e integrar múltiplas variáveis externas (Efcaz, 2024). Por outro lado, persistem desafios que limitam a aplicabilidade prática, como a necessidade de infraestrutura tecnológica robusta, qualidade dos dados e integração com métodos estatísticos clássicos. Mendonça (2022) destaca que grande parte das pesquisas ainda se concentra em setores específicos, como energia e

logística, o que restringe a generalização dos resultados para outros contextos. Diante disso, conclui-se que a próxima fase de evolução deve priorizar abordagens híbridas, que conciliem robustez técnica e aplicabilidade prática, ampliando casos de uso em tempo real e fortalecendo a integração em cadeias digitais. Essa convergência é essencial para transformar avanços teóricos em soluções concretas, capazes de gerar valor estratégico para organizações em mercados cada vez mais voláteis.

A pergunta de pesquisa foi respondida ao demonstrar que as técnicas de Inteligência Artificial (IA) superam as limitações dos modelos estatísticos tradicionais na previsão de demanda. A análise evidenciou que métodos como Redes Neurais Artificiais, *Deep Learning* e *Random Forest* oferecem maior capacidade de adaptação, precisão e aprendizado em cenários complexos e instáveis.

O objetivo geral foi alcançado ao mostrar o potencial da IA para aprimorar a previsão de demanda, enquanto os objetivos específicos foram atendidos ao identificar as limitações dos métodos tradicionais, apresentar as principais técnicas de IA e discutir seus desafios e benefícios.

Conclui-se que a aplicação de IA contribui para previsões mais confiáveis e decisões estratégicas mais assertivas, consolidando-se como uma ferramenta essencial para o aumento da eficiência e competitividade nas organizações.

REFERÊNCIAS

ABURTO, L.; WEBER, R. Demand forecasting in production systems using historical consumption data: A comparative study. *Journal of Manufacturing Systems*, v. 63, p. 423–431, 2022. DOI: <https://doi.org/10.1016/j.jmsy.2022.04.002>.

ACKERMANN, A. E. F.; SELLITTO, M. A. Métodos de previsão de demanda: uma revisão da literatura. *Innovar*, Bogotá, v. 32, n. 85, p. 83–99, jul./set. 2022. Disponível em: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-50512022000300083. Acesso em: 18 set. 2025.

ALVES, A. V. L.; PEREIRA, M. A. S. Redes neurais artificiais aplicadas na previsão da demanda de energia elétrica em curto prazo de consumidores finais. Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, 2023. Disponível em: <https://www.ifmg.edu.br/sic/edicoes-antiores/resumos-2022/engenharias/redes-neurais-artificiais-aplicadas-na-previsao-da-demanda-de-energia-eletrica-em-curto-prazo-de-consumo-finais.pdf>. Acesso em: 4 out. 2025.

AQUINO, M. Adoção de blockchain na gestão de cadeias de suprimentos do Brasil. 2019. Dissertação (Mestrado em Gestão para a Competitividade) – Fundação

Getulio Vargas, São Paulo. Disponível em:
<https://repositorio.fgv.br/bitstreams/45f9aa0f-affb-476a-9745-2976467534e6/download>. Acesso em: 3 out. 2025.

ARBIX, G. (org.). *Inteligência Artificial na Pesquisa Científica*. Revista USP, n. 141, 2024. Disponível em: <https://jornal.usp.br/revistausp/revista-usp-141-inteligencia-artificial-na-pesquisa-cientifica/>.

BOUALAM, M.; EL FAROUK, I. I. Toward a Demand-Driven Supply Chain: Evaluating the Impact of AI and ML Integration in the Healthcare and Pharmaceutical Industry. *Engineering Proceedings*, 2025. Disponível em: <https://www.mdpi.com/2673-4591/97/1/2>.

CÂNDIDO, A. V. L.; PEREIRA, M. A. S. Redes neurais artificiais aplicadas na previsão da demanda de energia elétrica em curto prazo de consumidores finais. Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, 2022. Disponível em: <https://www.ifmg.edu.br/sic/edicoes-anteriores/resumos-2022/engenharias/redes-neurais-artificiais-aplicadas-na-previsao-da-demanda-de-energia-eletrica-em-curto-prazo-de-consumo-finais.pdf>.

CARBONNEAU, R.; LAFRAMBOISE, K.; VAHIDOV, R. Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, v. 184, n. 3, p. 1140–1154, 2008. DOI: <https://doi.org/10.1016/j.ejor.2006.12.004>.

CHEN, C.-S.; CHEN, Y.-J. Optimizing Supply Chain Networks with the Power of Graph Neural Networks. *arXiv preprint*, arXiv:2501.06221, 2025. Disponível em: <https://arxiv.org/abs/2501.06221>.

CHOI, T. M.; WALLACE, S. W.; WANG, Y. Big data analytics in operations management. *Production and Operations Management*, v. 30, n. 6, p. 1773–1794, 2021. DOI: <https://doi.org/10.1111/poms.13246>.

CHOPRA, S.; MEINDL, P. *Gestão da cadeia de suprimentos: estratégia, planejamento e operação*. 6. ed. São Paulo: Pearson, 2016.

CORRÊA, J. B.; QUINTINO, A. S. S. A bibliometria e os instrumentos métricos para nortear as análises de dados nas pesquisas científicas. In: CONGRESSO NACIONAL DE EDUCAÇÃO – CONEDU, 2022. Disponível em: https://editorarealize.com.br/editora/anais/conedu/2022/TRABALHO_EV174_MD1_ID10123_TB142_14072022185809.pdf. Acesso em: 4 out. 2025.

COBBE, J.; VEALE, M.; SINGH, J. Understanding accountability in algorithmic supply chains. *arXiv preprint*, arXiv:2304.14749, 2023.

CORRÊA, M.; KUSRINI, K.; UTAMI, E. Transformative Impact of Data Diversity and Machine Learning on Supply Chain Management. *IEEE International Conference*, 2025. Disponível em: <https://ieeexplore.ieee.org/abstract/document/11167560/>.

DINIZ, E. H.; BECKER, J. L.; OLIVEIRA, H. P. G. de; MARCOLIN, C. B. Pesquisa mostra que IA e metodologias tradicionais trazem melhorias à análise de dados

qualitativos. *FGV EAESP*, 2023. Disponível em: <https://portal.fgv.br/noticias/pesquisa-mostra-ia-e-metodologias-tradicionais-traz-melhorias-analise-dados-qualitativos>.

DIGNUM, V. *Responsible Artificial Intelligence: Developing and Using AI in a Responsible Way*. 2. ed. Cham: Springer, 2023.

EMERGEN RESEARCH. *AI in Supply Chain Market Report*. 2025. Disponível em: <https://www.emergenresearch.com/pt/industry-report/ai-in-supply-chain-market>.

FALCONI CONSULTORIA. O uso de inteligência artificial para previsão de demanda e otimização do estoque. 2023. Disponível em: <https://falconi.com/insight/como-a-ia-transforma-previsao-da-previsao-de-demanda-e-otimizacao-do-estoque>.

FEIZABADI, J. et al. Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, v. 25, n. 2, p. 119–142, 2022. DOI: <https://doi.org/10.1080/13675567.2020.1803246>.

FERREIRA, A. C. A.; FRANCISCO, M. B.; DE PINHO, A. F. The use of artificial intelligence in supply chain management: systematic literature review and future research directions. *IEEE Access*, 2025. Disponível em: <https://ieeexplore.ieee.org/document/11143142>.

FERRER, W. M. H.; DIAS, J. A. *Manual prático de metodologia da pesquisa científica: noções básicas*. Marília: Unimar, 2023. Disponível em: <https://oficial.unimar.br/wp-content/uploads/2024/01/MANUAL-PRATICO-DE-METODOLOGIA-DA-PESQUISA-CIENTIFICA.-NOCOES-BASICAS.pdf>.

FLORIDI, L.; COWLS, J. A unified framework of five principles for AI in society. *Harvard Data Science Review*, v. 4, n. 2, 2022.

GARTNER. Gartner Predicts 70 Percent of Large Organizations Will Adopt AI-Based Supply Chain Forecasting by 2030. 2025. Disponível em: <https://www.gartner.com/en/newsroom/press-releases/2025-09-16-gartner-predicts-70-percent-of-large-orgs-will-adopt-ai-based-supply-chain-forecasting-to-predict-future-demand-by-2030>.

HILLEBRAND, E.; MEDEIROS, M. C. Forecasting realized volatility models: the benefits of bagging and nonlinear specifications. *Texto para Discussão*, n. 547. Departamento de Economia, PUC-Rio, 2007. Disponível em: <https://www.econ.puc-rio.br/uploads/adm/trabalhos/files/td547.pdf>.

HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. 3. ed. Melbourne: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>.

IVANOV, D.; DOLGUI, A. A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0. *Production Planning & Control*, v. 32, n. 9, p. 775–788, 2020. DOI: <https://doi.org/10.1080/09537287.2020.1768450>.

JAHIN, M. A.; SHAHRIAR, A.; AL AMIN, M. MCDFN: Supply Chain Demand Forecasting via an Explainable Multi-Channel Data Fusion Network Model. *arXiv preprint*, arXiv:2405.15598, 2024. Disponível em: <https://arxiv.org/abs/2405.15598>.

JIER. The Role of Artificial Intelligence in Enhancing Demand Forecasting and Supply Chain Decision-Making. *Journal of Industrial and Engineering Research*, v. 13, n. 2, p. 145–159, 2025.

KHAN, M.; KUMAR, R. Artificial intelligence-driven demand forecasting for resilient supply chain management. *International Journal of Production Economics*, v. 256, p. 109463, 2023.

LIM, S.; XIE, X.; LEE, W. Machine learning approaches for demand forecasting in supply chain management: A review. *Computers & Industrial Engineering*, v. 165, p. 107950, 2022.

MAESTRELLI, N. A importância das previsões de demanda para a gestão da capacidade produtiva. *Manufatura em Foco*, 2023. Disponível em: <https://www.manufaturaemfoco.com.br/a-importancia-das-previsoes-de-demanda-para-a-gestao-da-capacidade-produtiva/>.

MARQUES, E. L. Gêmeos Digitais e da Indústria 4.0: ambientes de sinergia. *Blog Itaipu Parquetec*, 2023. Disponível em: <https://blog.itaipuparquetec.org.br/gemeos-digitais/>.

MELILLO, H. O uso de inteligência artificial para previsão de demanda e otimização do estoque. Falconi Consultoria e Tecnologia de Gestão Empresarial, nov. 2023. Disponível em: <https://falconi.com/insight/como-a-ia-transforma-previsao-da-previsao-de-demanda-e-otimizacao-do-estoque/>.

MUSTIKA, R.; LESTARI, D. Artificial Intelligence for Demand Forecasting in Modern Supply Chains: Challenges and Opportunities. *Supply Chain Analytics Review*, v. 7, n. 1, p. 45–63, 2025.

NOBRE, L. B. IA Educativa: possibilidades e perspectivas para a prática docente. 2024. Dissertação (Mestrado em Tecnologias da Inteligência e Design Digital) – Pontifícia Universidade Católica de São Paulo, São Paulo. Disponível em: <https://tede2.pucsp.br/handle/handle/43668>.

PETROPOULOS, F. et al. Forecasting: theory and practice. *arXiv preprint*, arXiv:2012.03854, 2020. Disponível em: <https://arxiv.org/abs/2012.03854>. Acesso em: 17 ago. 2025.

RODRIGUES, M. et al. Machine learning models for short-term demand forecasting in food catering services: A solution to reduce food waste. *Journal of Cleaner Production*, v. 435, 140265, 2024. DOI: <https://doi.org/10.1016/j.jclepro.2023.140265>.

SILVA, J. L. Impacto do uso de técnicas de aprendizado de máquina, Big Data e variáveis causais na gestão de demanda. 2022. Dissertação (Mestrado em Engenharia Mecânica) – Centro Universitário FEI, São Bernardo do Campo.

Disponível em: <https://repositorio.fei.edu.br/bitstreams/9f8c7672-3cb5-48cf-a90c-a1380b1fb41c/download>.

SIMÕES, W. L.; SILVA, T. S.; JESUÍNO, A. F. Uso de Deep Learning em problemas de previsão de demanda: uma avaliação das publicações em eventos acadêmicos. Centro Universitário Cesuca, 2022. Disponível em: https://files.cercomp.ufg.br/weby/up/1012/o/USO_DE_DEEP_LEARNING_EM_PROBLEMAS_DE_PREVISÃO_DE_DEMANDA_UMA_AVALIAÇÃO_DAS_PUBLICAÇÕES_EM_EVENTOS_ACADÊMICOS.pdf.

SOARES, L. D. Redes Neurais Artificiais BIGRU_CNN Aplicadas à Previsão de Demanda de Energia Elétrica de Curto Prazo. 2021. Dissertação (Mestrado em Engenharia Elétrica e Computação) – Universidade Estadual do Oeste do Paraná, Foz do Iguaçu. Disponível em: https://tede.unioeste.br/bitstream/tede/5712/5/Lucas_Duarte_Soares_2021.pdf.

SPILOTIS, E. The wisdom of the data: getting the most out of univariate time series forecasting. *Forecasting*, v. 3, n. 3, p. 478–497, 2021. Disponível em: <https://doi.org/10.3390/forecast3030029>.

SPD TECHNOLOGY. AI Demand Forecasting for Risk and Behavior Analysis: 6 Trends for 2025. 2025. Disponível em: <https://spd.tech/artificial-intelligence/ai-demand-forecasting/>.

TOTVS S.A. *Relatório da Administração e Demonstrações Financeiras – exercício encerrado em 31 de dezembro de 2023*. São Paulo: TOTVS, 2024. Disponível em: <https://publicidadelegal.valor.com.br/valor/2024/02/08/TOTVS1574317408022024.pdf>.

WAMBA, S. F.; QUEIROZ, M. M. The role of artificial intelligence in building sustainable supply chains: a systematic literature review. *Journal of Cleaner Production*, v. 331, p. 129986, 2022. DOI: <https://doi.org/10.1016/j.jclepro.2021.129986>.

WANG, P. et al. A review of artificial intelligence methods for demand forecasting. *Renewable and Sustainable Energy Reviews*, v. 94, p. 64–75, 2018. DOI: <https://doi.org/10.1016/j.rser.2018.05.016>.

ZHANG, W.; LI, M.; CHEN, Q. Historical consumption data-based demand forecasting: applications in stable industrial environments. *International Journal of Production Research*, v. 61, n. 10, p. 3100–3115, 2023. DOI: <https://doi.org/10.1080/00207543.2023.XXXXXXX>