



ConBRepro

XIV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

I CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

04 a 06 de dezembro de 2024

Energias Limpas nas Engenharias

Transformação na gestão de inventário: aplicações, desafios e benefícios do Machine Learning

Luccas André Madrigrano

Estudante – Strong Business School

Rodrigo Taboranski de Paula Matos

Estudante – Strong Business School

Renato Marcio dos Santos

Professor orientador – Strong Business School

Resumo: Este artigo tem como objetivo analisar a implementação de automação de processos de gerenciamento de inventário por meio do uso de ferramentas de *Machine Learning* (ML), destacando as contribuições positivas nos resultados e os desafios de implementação e adequação dos sistemas. Visa destacar como processos de previsão de demanda e reposição de estoque podem tornar-se mais eficientes, com redução de custos, minimização de desperdícios, mitigando assim os erros humanos e reconhecendo padrões mais complexos em análises da utilização e necessidade de recompra. Destacam-se também as contribuições dos modelos ML para a geração de resultados que podem ser utilizados para tomadas de decisões mais estratégicas pelos gestores.

Palavras-chave: Gestão de inventário, Tecnologia e Inovação, Machine Learning, Inteligência Artificial.

Transformation in Inventory Management: Applications, Challenges, and Benefits of Machine Learning

Abstract: This article aims to analyze the automation of inventory management processes using Machine Learning (ML) tools, highlighting the positive contributions to the results and the challenges of implementing and adapting to the systems. It aims to highlight how demand forecasting and inventory replenishment processes can become more efficient, reducing costs, and minimizing waste, thus mitigating human errors and recognizing more complex patterns in analyses of utilization and the need for reordering. Also, highlighting the contributions of ML models to generating results that can be used for more strategic decision-making by managers.

Keywords: Inventory Management; Technology and Innovation; Machine Learning; Artificial Intelligence.

1. Introdução

A gestão de inventário é um tema muito importante para o sucesso e planejamento de empresas, e em setores que demandam alta eficiência na cadeia de suprimentos, a boa gestão dos ativos se torna ainda mais necessária. Historicamente, a gestão de inventário utilizava métodos totalmente manuais. Com o avanço tecnológico, os registros nos séculos

XIX e XX começaram a seguir rumos mais sistemáticos, aprimorando as técnicas, como por exemplo com o uso de cartões de controle de estoque e, depois, sistemas baseados em códigos de barras.

Na segunda metade do século XX, com o avanço da TI (Tecnologia da Informação), surgiram os primeiros Sistemas de Planejamento de Recursos Empresariais (ERP), que integravam os diferentes departamentos e processos em uma única plataforma. À medida que a globalização aumentou a demanda e, como resultado, a complexidade das cadeias de suprimentos e o volume de dados, ficou claro que os métodos existentes e comumente utilizados não eram suficientes para lidar com as novas condições e as exigências do mercado. Foi nesse contexto que as abordagens automatizadas começaram a ganhar terreno.

A evolução dos sistemas de armazenamento, sendo desde os cartões perfurados de Charles Babbage (sistemática de controle de estoque criada pela empresa norte-americana *Tabulating Machine Company* que consistia em perfurar um cartão de acordo com a saída e entrada de itens do estoque, quais eram lidos por uma máquina desenvolvida para tal feito e integrados ao sistema) até as modernas soluções de armazenamento em nuvem, ilustram que a necessidade para que as tecnologias avancem para o gerenciamento de grandes volumes de dados sejam prioridade na gestão do estoque. A inteligência artificial (IA) e seu formato o qual retratamos no texto, o *Machine Learning* (ML), surge como uma solução promissora para otimizar a gestão de inventário, oferecendo capacidades de previsão de demanda, automação de processos e análise de grandes volumes de dados em tempo real (GODA; KITSUREGAWA, 2012).

A questão central que permeia a narrativa desse artigo está em compreender quais são os desafios para a implementação de sistemas que usam ou integram o ML para o gerenciamento de inventário, seus benefícios e os maiores desafios retratados na literatura. Com esse estudo, esperamos contribuir facilitando para que empresas lidem com os desafios futuros, assim como na referência de estudos em cada um dos tópicos mapeados.

Este estudo foi conduzido por meio de uma revisão bibliográfica sistemática que abrange as principais pesquisas sobre a aplicação de *Machine Learning* (ML) na gestão de inventários. A metodologia envolveu a definição de termos-chave como "Machine Learning", "gestão de inventário", "previsão de demanda" e "otimização de estoque", seguidos da busca em bases de dados acadêmicas de publicações preferencialmente a partir de 2017, garantindo a atualidade das informações. Após a filtragem inicial, os estudos foram selecionados com base na relevância do tema e na qualidade metodológica. Em seguida, os artigos foram analisados, sintetizando os principais padrões, benefícios e desafios do uso de ML e IA na gestão de inventários, incluindo sua integração com sistemas ERP e WMS. Essa abordagem nos permitiu ter uma visão atual e fundamentada sobre as oportunidades e limitações dessa tecnologia no contexto de gestão de inventários.

Este artigo é organizado em duas seções principais. A primeira, de referencial teórico, está dividida em cinco subseções. Inicia-se com uma revisão geral dos estudos publicados sobre o tema, passando, em seguida, para considerações sobre a gestão de inventário e o uso de *Machine Learning* (ML). São exploradas as maneiras pelas quais o ML pode ser aplicado à gestão de inventário, destacando, por fim, os principais desafios dessa aplicação e as soluções propostas na literatura. A segunda seção apresenta os resultados e discussões, introduzindo uma tabela que resume os principais desafios e benefícios da aplicação de ML, com referências específicas para cada tema. Em seguida, é realizada uma análise e discussão dos pontos evidenciados.

2. Metodologia

Para conduzir nosso estudo, optamos por uma revisão bibliográfica detalhada, abrangendo as principais pesquisas sobre a aplicação de técnicas de ML na gestão de inventários. Nossa abordagem seguiu os seguintes passos:

Definimos primeiramente os termos e palavras-chave mais relevantes para nossa pesquisa, como "*Machine Learning*", "gestão de inventário", "Inteligência Artificial", "previsão de demanda", "otimização de estoque", "ERP" e "WMS". Assim, pesquisamos em bases de dados acadêmicas.

Nós buscamos por artigos científicos, dissertações e revisões literárias, dando prioridade para publicações com datas de publicação a partir de 2017. Sendo um tema muito atual e em constante mudança, precisávamos garantir que as informações fossem atuais e tratassem das tecnologias mais recentes. Utilizamos referências anteriores a essa data excepcionalmente para evidenciar dados históricos, que não são passíveis de variação.

Filtramos os resultados com base na relevância dos títulos e se nos resumos o assunto era contemplado. Incluímos estudos que abordavam diretamente a aplicação de ML na gestão de inventários, assim como aqueles que examinavam a integração com sistemas de ERP e WMS.

Fizemos a leitura dos artigos selecionados, avaliando a qualidade da metodologia, compilando os resultados obtidos e as conclusões apresentadas.

Durante a etapa de análise crítica, identificamos os principais padrões, benefícios e desafios associados ao uso de IA e ML na gestão de inventários. Essa análise nos ajudou a sintetizar as informações de maneira clara e estruturada.

Além disso, realizamos uma pesquisa complementar sobre a evolução histórica da gestão de inventários e a relação entre ML e sistemas de ERP/WMS. Consultamos fontes que detalhavam o desenvolvimento histórico e as tendências atuais na área.

Com base nas informações reunidas, formulamos nossa hipótese central, levando em consideração as lacunas identificadas na literatura existente e as novas oportunidades para a aplicação de ML na gestão de inventários.

Por fim, organizamos e redigimos todo o material de forma coesa e lógica. Revisamos o conteúdo para garantir clareza, resultando no artigo apresentado.

Esse método sistemático de revisão bibliográfica nos proporcionou uma visão abrangente e bem fundamentada sobre as aplicações de *Machine Learning* na gestão de inventários, destacando os benefícios, desafios e oportunidades que essas tecnologias oferecem.

3. Referencial teórico

3.1 Visão geral do tema na literatura

Em estudo bibliométrico sobre a utilização de tecnologias na gestão de inventário realizado entre 2012 e 2022, os países que mais publicaram artigos sobre o tema de aplicações de inteligência artificial na gestão de inventários são: China, Canadá, Bélgica, EUA e Turquia (ALBAYRAK ÜNAL *et al.*, 2023) e os métodos mais aplicados incluem algoritmos de aprendizado supervisionado como Regressão Linear, Regressão Ridge e Regressão Lasso, além de técnicas de *clustering* como *K-means* e *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN). Também são destacados os modelos de redes neurais e métodos avançados como *Long Short-Term Memory* (LSTM) e árvores de decisão em conjunto. Esses métodos têm mostrado resultados promissores na prática.

A aplicação de algoritmos de aprendizado supervisionado, como Regressão Linear, Regressão Ridge e Regressão Lasso, tem melhorado significativamente a precisão das previsões de demanda, reduzindo o excesso de estoque e as faltas de produtos. Técnicas

de clustering, como *K-means* e DBSCAN, têm sido eficazes na segmentação de dados e na identificação de padrões atípicos, o que é crucial para a gestão de riscos e a otimização de operações logísticas. Modelos de redes neurais, especialmente LSTM, têm se destacado na previsão de séries temporais, proporcionando uma visão mais precisa das tendências de demanda e ajudando na alocação eficiente de recursos. No entanto, a implementação dessas tecnologias também apresenta desafios, como a necessidade de grandes volumes de dados de alta qualidade e a complexidade na integração com sistemas existentes. Além disso, questões de privacidade e segurança de dados são preocupações importantes que precisam ser abordadas para garantir a eficácia e a aceitação dessas soluções tecnológicas. (PASUPULETI, *et al.*, 2024).

3.2 Gestão de inventário

A gestão de inventário é um processo crucial na cadeia de suprimentos (THAKUR, 2023). Trata-se da atividade que garante a disponibilidade de itens para os clientes, coordenando as funções de compras, fabricação e de distribuição. Garantindo, então, que a produção ou que os varejos tenham o nível correto de estoque por meio da continuidade de fornecimento. Resumindo, a gestão de inventário existe para equilibrar oferta e demanda, diminuindo falhas no fornecimento, como a não disponibilidade de bens no momento em que são necessários e também para a minimização de custos na cadeia de suprimentos. Sendo assim, um gestor de inventário deve ter total controle sobre os requisitos de cada um de seus clientes, sejam eles internos ou externos (WILD, 2017).

A relação entre a gestão de inventário e a cadeia de suprimentos é complexa. As sincronizações entre essas áreas mantêm a fluidez e a eficiência operacional. A gestão de inventário assegura que os produtos certos estejam disponíveis nas quantidades certas, evitando tanto a falta quanto o excesso de materiais através do planejamento de necessidade de materiais (MRP). Para que isso seja possível são utilizados sistemas avançados de planejamento de recursos empresariais (ERP), que proporcionam maior visibilidade da necessidade e do estoque entre as diferentes funções da cadeia de suprimentos (GUPTA; GEORGE, 2016).

O risco que a gestão de inventário está exposta é relacionado aos erros humanos, que podem ter um *efeito cascata*, impactando toda a logística de uma empresa. Por exemplo, a ausência de produtos por causa de uma previsão falha de demanda pode gerar faltas de estoque, levando à perda de vendas e a insatisfação dos clientes. Também, um excesso de estoque pode aumentar os custos de armazenamento e resultar em produtos obsoletos, especialmente em indústrias com produtos de alta rotatividade e constante inovação. Além disso, a necessidade de fazer pedidos urgentes para cobrir deficiências pode elevar os custos e prejudicar a eficiência operacional (MURPHY; KNEMEYER, 2018).

3.3 Machine Learning

O sistema de *Machine Learning* é um subconjunto da Inteligência Artificial, que resolve os problemas cognitivos e ajuda a otimizar a velocidade e a qualidade das informações (LINGAM, 2018). O ML se destaca por permitir que ferramentas de IA dispensem a necessidade de um conhecimento programado, já que as permite extrair padrões de dados brutos para construir sua própria base de conhecimento (GOODFELLOW *et al.*, 2016).

Existem três modelos básicos de ML, sendo: aprendizado supervisionado, não supervisionado e por reforço. No aprendizado supervisionado, a máquina é ensinada a associar entradas e saídas, usando exemplos já conhecidos como treinamento, o processo é feito por meio de assistência externa. No aprendizado não supervisionado, os algoritmos agem por conta própria para analisar os dados, ao contrário do supervisionado,

encontrando características padrões neles. No aprendizado por reforço, a máquina aprende a realizar determinadas ações baseando-se no acúmulo de recompensas (MAHESH, 2020).

3.4 Aplicação de Machine Learning na gestão de inventário

O uso de ML tem impactado diversas áreas, incluindo a gestão de inventário. O ML pode ajudar em tomadas de decisões relacionadas à gestão de estoque em indústrias de comércio eletrônico, por exemplo, melhorando a precisão nas previsões de demanda (LINGAM, 2018).

A eficiência da cadeia de suprimentos é um fator que auxilia na competitividade dos negócios pois a gestão de inventário está intimamente ligada ao custo (ISLAM et al., 2024). Com o advento da Indústria 4.0, que enfatiza o uso inteligente de informações em vez de ativos físicos, a tomada de decisões pelos gestores é aprimorada significativamente com as estruturas de ML (GONÇALVES, 2022).

A implementação de ferramentas de IA representa uma nova oportunidade para processar grandes volumes de informações complexas em tempo real, o que não era possível anteriormente. Ferramentas de ML podem ser utilizadas para análise e categorização do estoque (GARCÍA-BARRIOS, 2021), e nos próximos anos podem se destacar como uma das tecnologias mais eficazes para previsão de inventário devido ao seu poder de análises complexas de dados. Combinando computação em nuvem, *big data* e algoritmos de aprendizado, é possível avaliar grandes volumes de dados considerando diversos fatores de demanda com alta precisão e mínima incidência de erros. Além disso, essas ferramentas possuem capacidade de autocorreção, o que também traz mais eficiência em comparação às técnicas tradicionais de previsão, pois é possível rodar análises repetidamente e comparar resultados (LINGAM, 2018).

Podemos também explorar de forma ampla a aplicação de ML em técnicas de previsão de demanda e controle de inventário como forma de aprimorar parâmetros de reabastecimento ou compreender sazonalidade de demandas (THAKUR et al., 2023). Financeiramente, foi observado que sistemas inteligentes são capazes de reduzir custos operacionais e melhorar a alocação de recursos, elevando a agilidade e a eficiência da cadeia logística (ISLAM et al., 2024). Além disso, o uso de *Machine Learning* pode elevar a sustentabilidade nas operações de inventário diminuindo desperdícios (PASUPULETI et al., 2024).

Um ponto muito interessante é a aplicação das redes neurais convolucionais (CNNs) na logística e gestão de inventário e como as CNNs estão sendo adaptadas para otimizar processos de logística e logística reversa, para ajustar automaticamente os níveis de estoque em armazéns inteligentes (XU et al., 2023). Essas redes ajudam a identificar padrões complexos em dados de inventário, trazendo a possibilidade de criar correlações mais complexas entre os padrões de entradas e saídas de itens e permitindo ajustes em tempo real (TANG et al., 2023).

CNNs são extremamente eficazes na monitorização do fluxo de entrada e saída de produtos, facilitando a categorização automatizada e a organização do inventário com base em dados históricos e projeções futuras (SPIRITO, 2024). Quanto à aplicação olhando para a logística reversa, aumentamos a capacidade de prever quando e quais produtos podem ser devolvidos, e quando devolvidos, otimizar o processo de recolhimento e reintegração ao estoque. Isso não só reduz os custos associados à devolução de mercadorias, como também melhora a disponibilidade de produtos reciclados para venda, fazendo um uso mais sustentável dos recursos (JOKELA, 2024).

Armazéns inteligentes podem juntar as capacidades do ML para trabalhar em sinergia com sensores IoT (*Internet of Things*, Internet das Coisas) e sistemas de gestão de inventário (tipo WMS) para ajustar dinamicamente os níveis de estoque. Eles analisam dados em tempo real de diversas fontes e traqueiam a localização de itens das bases logísticas. Ajustam o nível de estoque imediatamente quando o item sai da localização somado a informação de utilização do sistema, criam pedidos de reabastecimento para evitar falta de estoque e criam movimentações necessárias para maximizar a utilização do estoque (LIU *et al.*, 2022).

3.5 Desafios da implementação e soluções retratadas

Qualidade dos dados: A precisão do ML está ligada à qualidade dos dados disponíveis. Dados de baixa qualidade resultam em previsões inconsistentes e não confiáveis, o que compromete a utilidade do ML para a gestão de estoque (JEYARAMAN *et al.*, 2024). A ausência de qualidade nos dados pode se manifestar de diversas formas, incluindo dados ausentes, incompletos, duplicados e desatualizados, o que pode impactar negativamente a performance dos modelos (GUDIVADA *et al.*, 2017).

Os conjuntos de dados podem frequentemente ser considerados não acurados, uma vez que podem conter imperfeições que necessitam de tratamento prévio. Muitos usuários e pesquisadores de ML veem o processo de limpeza e manipulação dos dados como uma tarefa impeditiva para o funcionamento dos modelos, uma vez que as previsões só podem ser confiáveis se comprovadamente corresponderem à realidade do estoque (AROYO *et al.*, 2022). A limpeza dos dados envolve práticas como a remoção de duplicatas, preenchimento de lacunas, atualização de informações e normalização das variáveis, e, apesar de ser possível tratar dados referentes ao estoque utilizando sistemas de deduplicação e ‘*Tiring*’ (KROTHAPALLI, *et al.*, 2023), para garantir a acurácia deles em relação ao sistema, no contexto dos estoques físicos, ainda é preciso realizar a conferência através de uma atividade prática.

Custos de implementação e capacidade computacional: Os sistemas de administração de estoques baseados em *enterprise resource planning* (ERP) são amplamente utilizados e conhecidos por sua eficácia na gestão de recursos empresariais. Exemplos notáveis incluem SAP, *Oracle ERP Cloud* e *Microsoft Dynamics 360*. Esses sistemas tendem a apresentar um custo relativamente uniforme tanto para a implementação quanto para a manutenção, refletindo em uma previsibilidade orçamentária que é benéfica para muitas organizações (MARTINS; BELFO, 2023). A introdução de modelos de ML em sistemas de estoques traz uma série de desafios adicionais.

Um desses desafios evidentes é a necessidade de equilibrar o desempenho dos modelos ML com a carga computacional necessária para que eles funcionem. O treinamento de ML demanda um alto processamento computacional e uma disponibilidade significativa de memória e essa capacidade demandada aumenta de acordo com a complexidade das tarefas exigidas. Isso pode resultar no aumento dos custos operacionais, muitas vezes superando os associados a ERPs tradicionais (KROTHAPALLI, *et al.*, 2023).

Entende-se a necessidade de desenvolver modelos de ML com processamento mais leve, capaz de operar com recursos limitados. Esses modelos devem minimizar os requisitos de processamento e necessidade de memória de acesso aleatório, facilitando a aplicação em diferentes contextos e reduzindo custos. (KROTHAPALLI, *et al.*, 2023).

O desenvolvimento de soluções híbridas pode ser a solução para juntar ERPs tradicionais e técnicas de ML, o que pode representar uma área promissora para futuras pesquisas e implementações. A importância de integrar o ML com sistemas de planejamento de

recursos empresariais (ERP) pode estar em aproveitar as capacidades computacionais para usar algoritmos de ML em dados em tempo real computados no ERP, para antecipar cenários e apoiar a avaliação dos gestores a qualquer momento (ZAKARIA, *et al.*, 2024) como maneira de aprimoramento dos sistemas atuais.

Integração: algumas empresas utilizam sistemas antigos que geram incompatibilidade com modelos de IA por não ter a infraestrutura necessária, carecendo de determinadas ferramentas que permitiriam a integração adequada, o que é muito comum em indústrias tradicionais. O uso de IA e ML exige o processamento de grandes volumes de dados, sendo que esses sistemas não estão planejados para acompanhar a demanda crescente exigida por tais modelos, causando sobrecargas que se tornam um desafio para o uso eficaz desses modelos.

Desafios organizacionais também devem ser considerados, uma vez que os trabalhadores podem não estar capacitados para uso dessas ferramentas, causando uma adaptação morosa. Restrições políticas da organização também podem afetar a integração caso procedimentos de implementação de inovações tecnológicas sejam muito burocráticos.

Considerando esses pontos, a gestão da mudança está completamente atrelada ao tema, já que a transição deve ser feita com planejamento cuidadoso, investimento adequado e disposição para acolher as inovações. Além disso, é importante que haja comunicação e treinamento adequados à força de trabalho, além de uma revisão da política da empresa (SINGH; ADHIKARI, 2023).

4. Análise de resultados e discussão

As tabelas abaixo possuem a finalidade de sintetizar os principais desafios e benefícios encontrados nos estudos analisados, para nortear a discussão dos resultados.

Tabela 1 – Desafios de implementação de ML em processos de gestão de inventário

Desafios de implementação	Referências
Qualidade dos dados	JEYARAMAN <i>et al.</i> , 2024 GUDIVADA <i>et al.</i> , 2017
Acurácia do estoque físico	AROYO <i>et al.</i> , 2022
Custos de implementação	MARTINS; BELFO, 2023
Capacidade computacional	KROTHAPALLI, <i>et al.</i> , 2023
Incompatibilidade de sistemas pré-existent	SINGH; ADHIKARI, 2023
Capacitação dos trabalhadores	SINGH; ADHIKARI, 2023
Restrições burocráticas da implementação	SINGH; ADHIKARI, 2023

Tabela 2 – Benefícios de implementação de ML em processos de gestão de inventário

Benefícios	Referências
Variabilidade técnica de integração	PASUPULETI, <i>et al.</i> , 2024
Refinamento na análise de dados para tomada de decisões	LINGAM, 2018 GONÇALVES, 2022 TANG, <i>et al.</i> , 2023 SPIRITO, 2024 KROTHAPALLI, <i>et al.</i> , 2023
Otimização de big data	GOODFELLOW, <i>et al.</i> , 2016 LINGAM, 2018
Processamento de dados real-time	GARCÍA-BARRIOS, 2021

	TANG, <i>et al.</i> , 2023 LIU, <i>et al.</i> , 2022 ZAKARIA, <i>et al.</i> , 2024
Previsão de movimentação de inventário	XU, <i>et al.</i> , 2023 JOKELA, 2024 SPIRITO, 2024

Os estudos evidenciam que a aplicação de algoritmos de ML na gestão de inventários pode trazer diversos benefícios, mas não está isenta de desafios. Tais dificuldades devem ser mitigadas para garantir o sucesso da adoção desses sistemas. Se a qualidade dos dados não for garantida, a análise pode ser comprometida, como é evidenciado por Jeyaraman *et al.* (2024) e Gudivada *et al.* (2017). A acurácia do estoque físico, caracterizada pela fidelidade dos dados em sistema ao estado físico dos estoques, também é uma questão importante de ser levada em conta, como apontam Aroyo *et al.* (2022).

Outro ponto de atenção é o custo de implementação, que eleva conforme o nível de adaptação da infraestrutura necessária em cada organização para suportar os modelos de ML, que envolvem desde a aquisição de hardware à integração com plataformas já utilizadas (MARTINS; BELFO, 2023), tal desafio é reforçado por Krothapalli *et al.* (2023), ao citar a capacidade computacional e por Singh & Adhikari (2023), que destacam sobre incompatibilidade de sistemas pré-existentes, que não foram projetados para integração com tais modelos, necessitando modificações pontuais ou substituição completa de sistemas.

Singh & Adhikari (2023) também pontuam as restrições burocráticas e a capacitação dos trabalhadores, evidenciando como a organização pode impactar a implementação de novas tecnologias, atrasando assim o processo de adoção e gerando resistência a mudanças.

Diversos dos benefícios apontados pelos autores têm como resultado o apoio à tomada de decisões. Traçando um paralelo entre as utilidades apontadas, podemos observar tais efeitos em continuidade, nessa ordem, de Processamento de dados *real-time*, Otimização de *big data* e refinamento na análise de dados para tomada de decisões. O refinamento na análise de dados, evidenciado por Lingam (2018) e Gonçalves (2022), é caracterizado pela identificação de padrões complexos que ajuda as empresas nas tomadas de decisões, sendo que Goodfellow *et al.* (2016) ainda reforçam a possibilidade de lidar com uma vasta quantidade de dados em tempo real, o que permite rápida reação a mudanças mercadológicas e readequação dos níveis de estoque (GARCÍA-BARRIOS, 2021; ZAKARIA *et al.*, 2024).

Outro benefício significativo é a previsão de movimentação de inventário, essencial para a eficiência da cadeia de suprimentos, caracterizada pela previsão de variações de demanda com maior precisão que modelos tradicionais, permitindo uma melhor alocação de recursos e otimização de custos de armazenamento e logística.

Já a variabilidade técnica de integração, apontada por Pasupuleti *et al.* (2024), destaca-se pela flexibilidade de adaptação dos sistemas de ML com ambientes tecnológicos e infraestruturas já existentes, permitindo ajustes conforme a necessidade sem comprometer a eficiência operacional.

Nota-se, portanto, que a implementação de ML na gestão de inventário, apesar de estar cerceada por desafios, oferece ganhos substanciais a longo prazo em termos de eficiência operacional, precisão nas previsões de demanda e otimização de recursos. A adoção de ML pode transformar de maneira significativa o gerenciamento de inventário das empresas, permitindo respostas mais rápidas às flutuações de mercado, controle mais rigoroso sobre os processos logísticos e análise de dados mais precisa.

5. Conclusão

Conclui-se que a aplicação de *Machine Learning* na gestão de inventário é uma evolução significativa na forma como as empresas gerenciam seus estoques. A sinergia entre ML, *big data* e computação em nuvem redefine os parâmetros de operação logística, oferecendo uma visão holística e integrada dos processos operacionais. Em contrapartida, há notáveis desafios de implementação, como a qualidade dos dados, a capacidade computacional e a integração com sistemas legados. No entanto, à medida que novas soluções de ML surgem, espera-se que esses desafios sejam mitigados.

Tendo olhar para o futuro, a tendência é que a Indústria 4.0 continue a transformar a gestão de inventário, exigindo cada vez mais o uso de ferramentas tecnológicas como IoT, sensores inteligentes e sistemas de ML, o que pode ser abordado em novos estudos. A antecipação da adoção dessas tecnologias permite uma maior capacidade de lidar com as novas demandas de mercado.

Resumindo, a combinação de *Machine Learning* e outras tecnologias avançadas traz maior eficiência e inovação à gestão de inventário. Ao adotarem essas soluções, as empresas podem melhorar seus resultados operacionais e aumentar sua capacidade de adaptação e crescimento em mercados globalizados e em constante transformação, o que as leva a um patamar mais elevado em eficiência logística.

Referências

ALBAYRAK ÜNAL, Özge; ERKAYMAN, Burak; USANMAZ, Bilal. Applications of artificial intelligence in inventory management: A systematic review of the literature. **Archives of Computational Methods in Engineering**, v. 30, n. 4, p. 2605-2625, 2023.

KROTHAPALLI, Bhavani; SHANMUGAM, Lavanya; MOHAMMED, Subhan Baba. Machine Learning Algorithms for Efficient Storage Management in Resource-Limited Systems: Techniques and Applications. **Journal of Artificial Intelligence Research and Applications**, v. 3, n. 1, p. 406-442, 2023.

GARCÍA-BARRIOS, David. A machine learning based method for managing multiple impulse purchase products: an inventory management approach. **Journal of Engineering Science and Technology Review**, 2021.

GODA, Kazuo; KITSUREGAWA, Masaru. The history of storage systems. **Proceedings of the IEEE**, v. 100, n. Special Centennial Issue, p. 1433-1440, 2012.

GONÇALVES, Mafalda Correia Piçarra. **The possibility of implementing intelligent systems and the respective impact of artificial intelligence on inventory management and warehousing**. 2022. Dissertação de Mestrado. ISCTE-Instituto Universitario de Lisboa (Portugal).

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. MIT Press, 2016.

GUDIVADA, Venkat; APON, Amy; DING, Junhua. Data quality considerations for big data and machine learning: Going beyond data cleaning and transformations. **International Journal on Advances in Software**, v. 10, n. 1, p. 1-20, 2017.

GUPTA, Manjul; GEORGE, Joey F. Toward the development of a big data analytics capability. **Information & Management**, v. 53, n. 8, p. 1049-1064, 2016.

ISLAM, Md Khyrul; AHMED, Hasib; AL BASHAR, Mahboob; TAHER, Md Abu. Role of artificial intelligence and machine learning in optimizing inventory management across global industrial manufacturing & supply chain: a multi-country review. **International Journal of Management Information Systems and Data Science**, v. 1, n. 2, p. 1-14, 2024.

JEYARAMAN, Jawaharbabu; KRISHNAMOORTHY, Gowrisankar; KONIDENA, Bhargav Kumar; SISTLA, Sai Mani Krishna. Machine learning for demand forecasting in manufacturing. **International Journal for Multidisciplinary Research**, v. 6, n. 1, p. 1-115, 2024.

JOKELA, Joni. **Optimizing Inventory Management: Leveraging CNNs and Conventional Grouping Methods: A Strategy for Excess Inventory Reduction and Dynamic Grouping**. Vaasa, 100 p., 2024. Dissertação de Mestrado – University of Vaasa.

LINGAM, Yashoda Kiran. The role of Artificial Intelligence (AI) in making accurate stock decisions in E-commerce industry. **Int. J. Adv. Res. Ideas Innov. Technol**, v. 4, n. 3, p. 2281-2286, 2018.

LIU, Mingzhou; XU, Xin; WANG, Xiaoqiao; JIANG, Qiannan; LIU, Conghu. Intelligent monitoring method of tridimensional storage system based on deep learning. **Environmental Science and Pollution Research**, v. 29, n. 46, p. 70464-70478, 2022.

MAHESH, Batta. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR)**. [Internet], v. 9, n. 1, p. 381-386, 2020.

MARTINS, Emanuel João; BELFO, Fernando Paulo. Major concerns about Enterprise Resource Planning (ERP) systems: A systematic review of a decade of research (2011-2021). **Procedia Computer Science**, v. 219, p. 378-387, 2023.

MURPHY, Paul R.; KNEMEYER, A. Michael. **Contemporary logistics**. Pearson, 2018.

PASUPULETI, Vikram; THURAKA, Bharadwaj; KODETE, Chandra Shikhi; MALISETTY, Saiteja. Enhancing supply chain agility and sustainability through machine learning: optimization techniques for logistics and inventory management. **Logistics**, v. 8, n. 3, p. 73, 2024.

SINGH, Navdeep; ADHIKARI, Daisy. Challenges and Solutions in Integrating AI with Legacy Inventory Systems. **International Journal for Research in Applied Science and Engineering Technology**, v. 11, n. 12, p. 609-613, 2023.

SPIRITO, Chiara. **Artificial Intelligence applications in Reverse Logistics, how technology could improve return and waste management creating value**. Torino, 111 p., 2024. Tese de Doutorado – Politecnico di Torino.

TANG, Yuk Ming; CHAU, Ka Yin; LAU, Yui-yip; ZHENG, Zehang. Data-intensive inventory forecasting with artificial intelligence models for cross-border e-commerce service automation. **Applied Sciences**, v. 13, n. 5, p. 3051, 2023.

TANG, Yuk Ming; CHAU, Ka Yin; LAU, Yui-yip; ZHENG, Zehang; THAKUR, Mamta; PATEL, Prabhat; GUPTA, Lalit Kumar; KUMAR, Mukund; SATHISH KUMAR, A. S. Data-intensive inventory forecasting with artificial intelligence models for cross-border e-commerce service automation. **Applied Sciences**, v. 13, n. 5, p. 3051, 2023.

WILD, T. **Best practice in inventory management. 3. ed.** Routledge, 2017.

XU, Zhiming; NI, Weichuan; LIU, Shaojiang; WANG, Feng; LI, Jing. Logistics Supply Chain Network Risk Prediction Model Based on Intelligent Random Forest Model. **IEEE Transactions on Engineering Management**, 2023.

ZAKARIA, Ahmed Youssri; ABDELBDEA, Elsayed; RASLAN, Atef; ALI, Tarek; GHEITH, Mervat; KHATER, Al-Sayed; AMIN, Essam A. An Improved Enterprise Resource Planning System Using Machine Learning Techniques. **Journal of Software Engineering and Applications**, v. 17, n. 5, p. 203-213, 2024.