



**INSTITUTO
FEDERAL**
Piauí

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS TERESINA CENTRAL
CURSO BACHARELADO EM ENGENHARIA MECÂNICA**

WESLEY RESENDE DOS SANTOS

**APLICAÇÃO DE APRENDIZADO DE MÁQUINA NA OTIMIZAÇÃO DA CADEIA DE
SUPRIMENTOS DA INDÚSTRIA 4.0: UMA REVISÃO SISTEMÁTICA DA
LITERATURA**

TERESINA-PI

2023

WESLEY RESENDE DOS SANTOS

APLICAÇÃO DE APRENDIZADO DE MÁQUINA NA OTIMIZAÇÃO DA CADEIA DE
SUPRIMENTOS DA INDÚSTRIA 4.0: UMA REVISÃO SISTEMÁTICA DA
LITERATURA

Trabalho de Conclusão de Curso apresentado
como exigência parcial para obtenção do diploma
do Curso de Bacharelado em Engenharia Mecânica
do Instituto Federal de Educação, Ciência e
Tecnologia do Piauí, Campus Teresina Central.

Orientador: Prof. Me. Francisco Marcelino Almeida
de Araújo.

TERESINA

2023

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Santos, Wesley Resende dos

S237a Aplicação de aprendizado de máquina na otimização da cadeia de
suprimentos da indústria 4.0 : uma revisão sistemática da literatura / Wesley
Resende dos Santos. - 2023.
89 f.: il. color.

Trabalho de Conclusão de Curso (Bacharelado em Engenharia Mecânica)
- Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus
Teresina Central, 2023.

Orientador : Prof Me. Francisco Marcelino Almeida de Araújo.

1. Aprendizado de máquina . 2. Gerenciamento da cadeia de suprimentos.
3. Indústria 4.0.. I.Título.

CDD - 620

Elaborado por Maria Rosismar Farias CRB 3/631

WESLEY RESENDE DOS SANTOS

APLICAÇÃO DE APRENDIZADO DE MÁQUINA NA OTIMIZAÇÃO DA CADEIA DE
SUPRIMENTOS DA INDÚSTRIA 4.0: UMA REVISÃO SISTEMÁTICA DA
LITERATURA

Trabalho de Conclusão de Curso apresentado
como exigência parcial para obtenção do diploma
do Curso de Bacharelado em Engenharia Mecânica
do Instituto Federal de Educação, Ciência e
Tecnologia do Piauí, Campus Teresina Central.

Aprovada em: ____/____/____.

BANCA EXAMINADORA

Prof. Me. Francisco Marcelino Almeida de Araújo (Orientador)
Instituto Federal do Piauí (IFPI)

Prof. Dr. Petteson Linniker Carvalho Serra
Instituto Federal do Piauí (IFPI)

Prof. Dr. Eduilson Lívio Neves da Costa Carneiro
Instituto Federal do Piauí (IFPI)

A Deus, por ser extremamente paciente e piedoso comigo...
Aos meus pais que foram companheiros em todas as horas...

AGRADECIMENTOS

Agradeço imensamente às pessoas que contribuíram de maneira significativa para a conclusão deste trabalho, tornando possível a realização deste TCC. À minha querida mãe, Francisca, e à minha irmã, Eslania, expresso minha profunda gratidão. Seu amor incondicional, encorajamento constante e compreensão foram o alicerce que me permitiu dedicar-me a este projeto com determinação.

Ao Professor Petteson, coordenador do curso, agradeço pela sua disposição em ajudar em todas as etapas deste percurso acadêmico. Sua orientação e suporte foram fundamentais, e sou grato por sua gigante contribuição para a conclusão do curso.

Expresso minha gratidão ao Professor Marcelino, meu orientador, pela sua orientação perspicaz, paciência e dedicação ao longo deste processo. Suas sugestões valiosas e seu comprometimento foram fundamentais para a qualidade deste trabalho. À Professora Evânia, minha sincera apreciação por compartilhar seu conhecimento na disciplina de TCC. Suas aulas e feedbacks foram cruciais para o desenvolvimento das habilidades necessárias para a elaboração deste trabalho.

À banca por ter aceitado o convite para a avaliação desse trabalho.

Aos amigos universitários que trilharam essa jornada ao meu lado e fizeram parte de forma muito importante para que eu tenha chegado neste momento, em especial para a minha grande amiga Iara Leal que mesmo com algumas turbulências na nossa amizade, não deixou de ser a pessoa mais especial que conheci dentro do curso. E também a todos os amigos que esperaram ansiosos por este momento do fechamento do meu ciclo dentro da IFPI.

“O poder não é determinado pelo seu tamanho,
mas pelo tamanho do seu coração e dos seus sonhos.”

Monkey D. Luffy

RESUMO

Este trabalho de conclusão de curso conduz uma revisão sistemática da literatura centrada na aplicação do aprendizado de máquina para otimizar a gestão da cadeia de suprimentos na indústria 4.0. O objetivo primordial é identificar as principais tendências, desafios e oportunidades relacionadas à implementação de técnicas de aprendizado de máquina nesse contexto. A revisão sistemática envolveu uma análise crítica de 74 documentos selecionados após extensa pesquisa em bases de dados científicas. Os resultados destacam a viabilidade e a eficácia do aprendizado de máquina em várias etapas da cadeia de suprimentos, abrangendo desde a previsão de demanda até a otimização de rotas de transporte. Suas aplicações essenciais incluem aprimoramento da previsão de demanda, otimização do planejamento de produção, eficiente gestão de estoques, aperfeiçoamento das rotas de transporte e detecção de irregularidades e fraudes. No entanto, o estudo reconhece a existência de desafios significativos, como a garantia da qualidade dos dados e a integração complexa de sistemas. Com suas descobertas valiosas, este trabalho contribui para a identificação de oportunidades estratégicas e a discussão dos obstáculos a serem superados na implementação bem-sucedida de técnicas de aprendizado de máquina na gestão da cadeia de suprimentos, fornecendo orientação relevante para a indústria na era da Indústria 4.0.

***Palavras-chave:** aprendizado de máquina; gerenciamento da cadeia de suprimentos; indústria 4.0.

ABSTRACT

This undergraduate thesis conducts a systematic literature review focused on the application of machine learning to optimize supply chain management in Industry 4.0. The primary objective is to identify key trends, challenges, and opportunities related to the implementation of machine learning techniques in this context. The systematic review involved a critical analysis of 74 selected documents after extensive research in scientific databases. The results highlight the feasibility and effectiveness of machine learning at various stages of the supply chain, ranging from demand forecasting to transport route optimization. Essential applications include improving demand forecasting, optimizing production planning, efficient inventory management, enhancing transport routes, and detecting irregularities and fraud. However, the study acknowledges the existence of significant challenges, such as ensuring data quality and the complex integration of systems. With its valuable findings, this work contributes to identifying strategic opportunities and discussing obstacles to be overcome in the successful implementation of machine learning techniques in supply chain management, providing relevant guidance for the industry in the era of Industry 4.0.

Keywords: machine learning; supply chain management; industry 4.0.

LISTA DE ILUSTRAÇÕES

Figura 1 - Arranjo básico do sistema ML	22
Figura 2 - Aprendizado de máquina supervisionado.	23
Figura 3 - Aprendizado de máquina não supervisionado.	24
Figura 4 - Aprendizado de máquina semi-supervisionado.....	24
Figura 5 - Aprendizagem por reforço.....	25
Figura 6 - Inteligência artificial, aprendizado de máquina e aprendizado profundo...26	
Figura 7 - Comparação entre o neurônio da rede neural e uma célula nervosa.	28
Figura 8 - Características da Manufatura 4.0	34
Figura 9 - Pilares da Industria 4.0	35
Figura 10 - As três dimensões do Supply Chain Management.....	38
Figura 11 - Perspectivas da Logística versus Supply Chain Management.....	39
Figura 12 - Indústria 5.0: personalização de produtos e serviços e co-trabalho entre colaboradores e robôs.....	43
Figura 13 - Etapa de pesquisa de acordo com a metodologia PRISMA.....	49
Figura 14 - Tipo de artigo de pesquisa.....	53
Figura 15 - Artigos de revista por país de origem.....	54
Figura 16 - Artigos de periódicos por ano.....	55
Figura 17 - Categorização estruturada de aprendizado de máquina na manufatura.....	60

LISTA DE TABELAS

Tabela 1 - Critérios de inclusão e exclusão	50
Tabela 2 - Artigos de revista com base no número de publicações.....	57
Tabela 3 - Breve análise de artigos sobre estudos teóricos	61
Tabela 4 - Análise breve de artigos sobre modelagem matemática e simulação	64
Tabela 5 - Análise breve de artigos sobre implementação	66

LISTA DE ABREVIATURAS E SIGLAS

ANN/RNN	Redes Neurais Artificiais
BCG	Boston Consulting Group
CNN	Redes Neurais Convolucionais
IA	Inteligência Artificial
IIoT	Internet Industrial das Coisas
IoT	Internet das Coisas
ML/AM	Aprendizado De Maquina
MPMEs	Micro, pequenas e médias empresas
PRISMA	Principais Itens para relatar Revisões Sistemáticas e MetaAnálises
PRV	Problema de Roteamento de Veículos
RNR	Redes Neurais Recorrentes
RSL	Revisão Sistemática da Literatura
SCM	Supply Chain Management
SCR	Resiliência da Cadeia de Suprimentos

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS DO TRABALHO	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	18
2	REFERENCIAL TEÓRICO.....	19
2.1	INTELIGENCIA ARTIFICIAL	19
2.2	APRENDIZADO DE MAQUINA	20
2.2.1	Configuração Fundamental de um Sistema de Aprendizado de Máquina	21
2.2.2	Tipos de Aprendizagem de Máquina.....	22
2.2.2.1	Aprendizagem Supervisionada.....	22
2.2.2.2	Aprendizado Não Supervisionado	23
2.2.2.3	Aprendizado Semi-supervisionado	24
2.2.2.4	Aprendizado por Reforço.....	25
2.3	APRENDIZADO PROFUNDO	25
2.3.1	Redes Neurais Artificiais	27
2.4	EVOLUÇÃO INDUSTRIAL	29
2.5	INDUSTRIA 4.0	32
2.6	SUPPLY CHAIN MAGANEMENT	37
2.7	APLICAÇÃO DE INTELIGENCIA ARTIFICIAL NO SUPPLY CHAIN MAGANEMENT.....	40
2.8	INDUSTRIA 5.0	41
3	METODOLOGIA	44
3.1	LACUNAS DE PESQUISA.....	44
3.2	QUESTÕES DE PESQUISA.....	45
3.3	MODALIDADE DE PESQUISA.....	46
3.4	METODOLOGIA ADOTADA PARA RSL	49
4	RESULTADOS E DISCUSSÕES	52
4.1	CONTRIBUIÇÕES DE DIVERSAS FONTES PARA A APRENDIZAGEM DE MÁQUINA NA CADEIA DE SUPRIMENTOS DE MANUFATURA	52
4.1.1	Análise com base no tipo de artigos de pesquisa.....	52
4.1.2	Análise por país dos artigos de periódicos	53
4.1.3	Análise de Artigos de Revista por Ano	54
4.1.4	Análise de Artigos de Revista com Base no Número de Publicações.....	57
4.2	ESTUDOS REALIZADOS SOBRE ML NA CADEIA DE SUPRIMENTOS DE MANUFATURA E SUAS CATEGORIAS	60
4.2.1	Estudo Teórico.....	60
4.2.2	Modelagem Matemática e Simulação	64
4.2.3	Implementação	66
4.2.4	Análise concisa do conteúdo	69
4.3	TENDÊNCIAS FUTURAS DO ML NA CADEIA DE SUPRIMENTOS DE MANUFATURA.....	70
4.4	DESAFIOS DA IMPLATAÇÃO DE APRENDIZADO DE MÁQUINA NO SCM DA INDUSTRIA MANUFACTUREIRA.....	71

5	CONCLUSÃO	73
	REFERENCIAS.....	77

1 INTRODUÇÃO

A evolução das técnicas de inteligência artificial (IA) tem causado um impacto substancial nas esferas pessoais e nos procedimentos de engenharia. Diversos setores, como fabricação, design industrial, inspeção, monitoramento e controle, têm experimentado consequências significativas decorrentes desse fenômeno (VARSHNEY, 2016). No contexto atual, engenheiros têm adquirido a habilidade de conceber, fornecer e manter equipamentos e ferramentas de ponta em diversas indústrias, que abrangem áreas como saúde, seguros, energia, petróleo e gás, educação, aeroespacial, manufatura e transporte (WANG et al., 2018). No entanto, (AGGOUR et al., 2019) enfatizam que apesar da ampla aplicação da IA na resolução de vários desafios nas áreas de engenharia e manufatura, o mundo ainda está nos estágios iniciais de uma revolução industrial impulsionada pela IA.

Conforme afirma (HEGDE; ROKSETH, 2020), os algoritmos de inteligência artificial têm desempenhado um papel crucial na resolução de problemas específicos em diversas áreas da engenharia. Observa-se que a IA contribui para a diminuição do ciclo de produção e do desperdício, resultando em uma notável melhoria na utilização de recursos em situações complexas de fabricação (BEDBROOK et al., 2019). Além disso, o Aprendizado de Máquina (*Machine Learning* - ML) proporciona ferramentas simples, porém altamente eficazes, para a constante melhoria da qualidade em processos de manufatura de extrema complexidade e desafio (WUEST et al., 2016).

O termo "Aprendizado de Máquina" é essencialmente uma subárea da inteligência artificial, na qual as máquinas têm a capacidade de se comportar como um ser humano. O aprendizado de máquina tem recebido atenção significativa e adoção em diversos setores. Dados e programas são utilizados para capacitar as máquinas a tomar decisões como um ser humano. Na indústria manufatureira, a cadeia de suprimentos emerge como uma ferramenta eficaz para aprimorar a eficiência, impulsionar as operações e melhorar os processos de tomada de decisão. Algoritmos de ML permitem que as máquinas analisem grandes volumes de dados e identifiquem padrões e relacionamentos a partir desses dados sem programação explícita. Com o avanço das tecnologias, grandes quantidades de dados não estruturados são geradas. Existe a necessidade de técnicas inteligentes para analisar esses dados não estruturados e interpretar dados estruturados significativos para

aprendizado, raciocínio e tomada de decisão, assim como seres humanos (BELHADI et al., 2021).

O conceito de big data está se tornando prevalente em praticamente todas as áreas de negócios, contribuindo para a economia global. Métodos tradicionais são incapazes de lidar com esse grande volume de dados, portanto, há a necessidade de decisões baseadas em dados que auxiliem as empresas a obter vantagem competitiva (RAZA, 2022). O avanço no aprendizado de máquina beneficia setores como manufatura, varejo, serviços financeiros, *supply chain management* (SCM), controle de estoque e logística, saúde e ciências da vida, viagens, hospitalidade e energia. Inovações no aprendizado de máquina ajudam a melhorar a tomada de decisão, reduzir o tempo, aumentar a precisão e, em última análise, contribuir para a redução de custos. A disponibilidade de dados aumenta com o tempo, portanto, a necessidade de gerenciar essa grande quantidade de dados é necessária. Técnicas de ML podem extrair eficientemente dados estruturados e significativos da grande quantidade de dados não estruturados. A implementação de técnicas de aprendizado de máquina está aumentando devido à sua precisão e eficiência em relação às práticas convencionais (BORODAVKO; ILLÉS; BÁNYAI, 2021).

O ML é adotado em diversos campos, como assistência do Google Maps, em voos comerciais para uso do piloto automático, inteligência de e-mail, filtros de spam, respostas inteligentes em e-mails, classificação de e-mails, em bancos e finanças pessoais, em redes sociais como Facebook, Pinterest, Snapchat, Instagram, etc., também em diagnóstico médico e assistência médica e na tomada de decisões preditivas na fabricação e na cadeia de suprimentos, logística e transporte (AMERISIANAKI et al., 2019). Entre todos esses, a adoção do ML no setor de manufatura está crescendo rapidamente, e o big data está sendo estruturado adequadamente com técnicas de ML. A geração de uma grande quantidade de dados deve ser coletada adequadamente e convertida em dados estruturados e significativos. Estratégias tradicionais eram incapazes de processar eficientemente esses big data. Técnicas de ML desempenham um papel significativo na gestão da cadeia de suprimentos e no controle de estoque. A evolução do ML oferece benefícios na cadeia de suprimentos de manufatura para oportunidades e desafios de negócios reais. A adoção de técnicas de ML na cadeia de suprimentos de manufatura está em estágio revolucionário e seu uso juntamente com a Indústria 4.0 revoluciona o mundo digital (AL-SAHAF et al., 2019)

A principal tarefa para fabricantes e engenheiros é gerenciar a quantidade ideal de estoque ao longo da cadeia de suprimentos. Se os inventários não forem manipulados adequadamente, pode haver chances do chamado efeito chicote. Para controlar o inventário, é utilizada a estratégia de pedido até reposição, que avalia periodicamente o estoque e faz pedidos em intervalos fixos. O inventário é um ativo valioso em uma empresa e deve ser gerenciado com cuidado para evitar complicações como o fenômeno de pedidos em atraso ou o efeito chicote. Portanto, há a necessidade de desenvolver um framework dinâmico que preveja a demanda flutuante do cliente e gerencie o nível de estoques ao longo da cadeia de suprimentos (ISLAM; AMIN, 2020; PRIORE et al., 2019).

As indústrias estão atualmente passando pela “Quarta Revolução Industrial”, como os profissionais a chamam, termo também conhecido como “Indústria 4.0”. (I4.0) A integração entre sistemas físicos e digitais dos contextos de produção é o que preocupa principalmente a Indústria 4.0 (CARVALHO et al., 2019). A emergência das tecnologias da Indústria 4.0 é um fator chave para a transformação digital na gestão da cadeia de suprimentos e do inventário. Essas tecnologias emergentes são responsáveis pela revolução digital nessas áreas (IVANOV et al., 2021; QI; MAK; SHEN, 2020). A aplicação de aprendizado de máquina em diversos campos está crescendo rapidamente devido à sua ampla gama de técnicas emergentes (BODENDORF; MERKL; FRANKE, 2021). No mundo em constante mudança de hoje, a coleta de grandes quantidades de dados é uma preocupação importante. As abordagens clássicas têm se mostrado inadequados para gerenciar a imensa quantidade de dados gerados na cadeia de suprimentos. O uso de técnicas de ML aprimora a eficiência e a eficácia da cadeia de suprimentos, extraíndo padrões específicos dos dados coletados (TIRKOLAEI et al., 2021). As técnicas de ML desempenham um papel crucial na análise e interpretação dessa grande quantidade de dados. O principal objetivo da automação de sistemas tradicionais é minimizar erros humanos na tomada de decisões e treinar máquinas para prever a demanda dos clientes na gestão da cadeia de suprimentos e do inventário (BENHAMIDA et al., 2021; ZHANG et al., 2020). Prever a demanda dos clientes é um desafio significativo na gestão da cadeia de suprimentos para evitar pedidos em atraso e excesso de estoque de produtos (ISLAM; AMIN, 2020; SEO et al., 2021). Em cadeias de suprimentos de circuito fechado, a tomada de decisões e as operações de produção se tornam complexas. Algoritmos avançados baseados em lógica fuzzy e ML auxiliam no

monitoramento e gerenciamento das operações de produção para alcançar os objetivos do processo (GONZÁLEZ RODRÍGUEZ; GONZALEZ-CAVA; MÉNDEZ PÉREZ, 2020).

Contudo, apesar dos benefícios das técnicas de inteligência artificial nas áreas de engenharia e fabricação, como discutido por Wuest et al. (2016), a diversidade dessas técnicas apresenta um desafio significativo para muitos profissionais e engenheiros da indústria, quando se trata de escolher a técnica apropriada dentre as múltiplas opções disponíveis. Isso, por conseguinte, pode dificultar a adoção dessas técnicas por uma parcela considerável de especialistas no campo, criando uma lacuna de pesquisa na aplicação da tecnologia para a digitalização e otimização da cadeia de suprimentos.

Dessa forma, o progresso e a evolução das técnicas de IA em diversos sistemas e ambientes de engenharia e manufatura ainda não foram devidamente abordados na literatura. Este artigo de pesquisa tem como objetivo fornecer uma análise sistemática e uma revisão da literatura sobre o uso de aprendizado de máquina em cadeias de suprimentos de manufatura. Com isso, este artigo oferece uma visão abrangente e atualizada sobre o uso de aprendizado de máquina na cadeia de suprimentos de manufatura, fornecendo insights valiosos para pesquisadores, profissionais e tomadores de decisão.

1.1 OBJETIVOS DO TRABALHO

O objetivo representa a ideia central do trabalho científico. Neste capítulo, será descrito de forma breve e factual o propósito para o qual será conduzido o estudo e o objetivo a ser alcançado com ele.

1.1.1 Objetivo Geral

Realização de uma revisão sistemática e abrangente da literatura, de acordo com o protocolo PRISMA (Principais Itens para relatar Revisões Sistemáticas e MetaAnálises) para estudos e relatórios sobre o uso de técnicas de aprendizado de máquina na cadeia de suprimentos da indústria de manufatura.

1.1.2 Objetivos Específicos

- Apresentar uma síntese concisa dos conceitos fundamentais de inteligência artificial, aprendizado de máquina, aprendizado profundo, Indústria 4.0 e SCM e identificar tendências no uso ou na pesquisa de técnicas de IA na Indústria 4.0, a fim de oferecer uma visão geral aos leitores e auxiliar os novos pesquisadores.
- Identificar os diversos estudos realizados sobre ML para a cadeia de suprimentos de manufatura e suas categorias
- Analisar a eficácia das técnicas de aprendizado de máquina na previsão de demanda e na otimização de processos na cadeia de suprimentos da Indústria de manufatura.
- Avaliar as limitações e desafios enfrentados na implementação de técnicas de aprendizado de máquina na cadeia de suprimentos da Indústria de manufatura
- Quais as tendências futuras do ML para a cadeia de suprimentos da Indústria de manufatura

2 REFERENCIAL TEÓRICO

2.1 INTELIGENCIA ARTIFICIAL

A definição precisa da Inteligência Artificial é um desafio devido à sua intrincada complexidade. No entanto, é imperativo esclarecer conceitos essenciais como ponto de partida para a discussão proposta neste estudo. Conforme enfatizado por Pozzebon, Frigo e Bittencourt (2004), a Inteligência Artificial constitui-se, por um lado, como um campo científico que se dedica à análise e compreensão do fenômeno da inteligência, e, por outro lado, como um domínio da engenharia que busca conceber instrumentos destinados a ampliar as capacidades intelectuais humanas. O cerne de nossa análise concentra-se na segunda concepção, isto é, a IA enquanto um domínio da engenharia computacional que tem desempenhado um papel transformador na vida da humanidade.

O estudo da IA remonta às décadas de 1940 e 1950, com raízes em pesquisas interdisciplinares. O pioneiro John McCarthy descreve a IA como "o projeto de fazer com que máquinas usem linguagem, formem abstrações e conceitos, resolvam tipos de problemas que agora são reservados para o homem, e melhorem a si mesmas" (MCCARTHY et al., 2006). Essa definição ampla continua a ser relevante, mas a IA evoluiu muito além de suas origens.

A IA busca replicar funções cognitivas humanas em sistemas computacionais. Conforme destacado por Nilsson (1979), um dos principais objetivos da IA é desenvolver máquinas capazes de raciocinar, aprender, resolver problemas e tomar decisões de forma autônoma, simulando a inteligência humana.

A IA está intrinsecamente ligada ao aprendizado de máquina, que se destaca por permitir que sistemas aprimorem seu desempenho com base em experiência e dados. Desde os primeiros modelos de aprendizado, como o Perceptron de Rosenblatt, até abordagens modernas, como as redes neurais profundas, a IA testemunhou avanços significativos (MITCHELL, 2013). As palavras de Arthur Samuel, que em 1959 descreveu o aprendizado de máquina como a habilidade de um computador "aprender sem ser explicitamente programado", ainda ressoam no cenário atual.

As vantagens da IA são diversas. Uma das maiores vantagens é a capacidade de processamento e análise de grandes volumes de dados em tempo real, proporcionando insights valiosos. Isso é ilustrado pelo uso de IA na medicina para diagnóstico precoce e tratamento personalizado (ESTEVA et al., 2017). Além disso, Goldental e Kanter (2020) afirma que a IA oferece automação de tarefas complexas, o que melhora a eficiência operacional e reduz o erro humano. Em setores como a indústria automobilística, a IA possibilitou o desenvolvimento de veículos autônomos, reduzindo significativamente o risco de acidentes.

No entanto, a IA também apresenta desvantagens. A dependência excessiva de sistemas de IA pode levar à perda de empregos em determinados setores. Autoridades devem considerar questões éticas e regulatórias, incluindo a privacidade de dados e o viés algorítmico, conforme discutido por Barocas, Hardt e Narayanan (2023). Além disso, a IA está sujeita a limitações em termos de compreensão contextual e empatia. Em cenários complexos que exigem interpretação subjetiva ou empatia, a IA pode ser inadequada, o que pode afetar a qualidade dos serviços (KERASIDOU, 2020).

Em síntese, a Inteligência Artificial desempenha um papel cada vez mais proeminente em nossa sociedade, transformando a maneira como abordamos problemas e desafios complexos. Seus objetivos fundamentais buscam replicar funções cognitivas humanas em sistemas computacionais, visando aprimorar a automação e a eficiência em uma variedade de setores.

2.2 APRENDIZADO DE MAQUINA

O aprendizado de máquina é um campo da inteligência artificial e da ciência da computação que se concentra na utilização de dados e algoritmos para imitar como os humanos aprendem e melhorar continuamente a precisão. Segundo Amruthnath e Gupta (2018), ML é uma subcategoria de IA e é definido como qualquer algoritmo ou programa que tenha a capacidade de aprender com o menor ou nenhum suporte adicional.


Na sua forma mais fundamental, COPELAND (2016) destaca que o aprendizado de máquina é basicamente a prática de usar algoritmos para analisar dados, aprender com eles e então decidir ou prever. Ao contrário das rotinas de software de codificação manual com um conjunto específico de instruções para realizar uma tarefa específica, a máquina é “treinada” usando grandes quantidades de dados e algoritmos que lhe dão a capacidade de aprender a correlação entre a entrada e a saída desejada e, portanto, como para executar a tarefa.

De acordo com STANISAVLJEVIC e SPITZER (2016), o aprendizado de máquina oferece abordagens que têm a capacidade de gerar soluções para problemas complexos. ML possibilita que sistemas e máquinas adquiram conhecimento de forma automática e melhorem com base em suas próprias experiências, sem a necessidade de programação explícita.

2.2.1 Configuração Fundamental de um Sistema de Aprendizado de Máquina

A Figura 1 ilustra a estrutura essencial de um sistema de aprendizado de máquina. Um objetivo de aprendizado é estabelecido, e a partir dele, um conjunto de dados, seja rotulado ou não rotulado, é coletado de diversas fontes de dados e posteriormente dividido em dois conjuntos distintos: o conjunto de dados de treinamento e o conjunto de dados de teste. Com base nas metas organizacionais, a base de conhecimento determina o algoritmo de aprendizado de máquina mais adequado para atender ao objetivo atual da organização. O conhecimento obtido pelo algoritmo de aprendizado de máquina a partir dos padrões ocultos nos dados de treinamento é então aplicado aos dados de teste, que representam exemplos desconhecidos, com a finalidade de realizar previsões. A saída prevista pelo modelo é subsequentemente comparada com os valores desejados, a fim de avaliar o desempenho do modelo.

Figura 1 - Arranjo básico do sistema ML



Fonte: Elaborado pelo Autor (2023).

2.2.2 Tipos de Aprendizagem de Máquina


De acordo com Raschka e Mirjalili (2019), os tipos de aprendizagem de máquina são classificados em três categorias principais: aprendizado supervisionado (Supervised learning), aprendizado não supervisionado (Unsupervised learning) e aprendizado por reforço (Reinforcement learning). Essas mesmas categorias de aprendizado são também apontadas por Russell e Norvig (2021) como os principais, no entanto, eles também introduzem o conceito de aprendizado semi-supervisionado (Semi-supervised learning), que se caracteriza por ser uma combinação de elementos dos aprendizados supervisionado e não supervisionado.

2.2.2.1 Aprendizagem Supervisionada

Este método é caracterizado pelo uso de conjuntos de dados rotulados (Figura 2) para treinar algoritmos com o objetivo de classificar dados com precisão ou prever resultados. À medida que os dados de entrada são introduzidos no modelo, os pesos são ajustados até que o modelo se ajuste adequadamente. Esse ajuste faz parte do processo de validação cruzada, que visa garantir que o modelo evite o sobreajuste ou subajuste. O aprendizado supervisionado desempenha um papel fundamental na

capacidade das organizações de abordar uma variedade de desafios do mundo real, tais como a classificação de mensagens de spam em caixas de entrada distintas. Os métodos empregados nesse tipo de aprendizado englobam redes neurais, o algoritmo Naive Bayes, regressão linear, regressão logística, árvores de decisão, entre outros (RASCHKA; MIRJALILI, 2019).

Figura 2 - Aprendizado de máquina supervisionado.




Fonte: Elaborado pelo Autor (2023).

2.2.2.2 Aprendizado Não Supervisionado

Este método envolve a análise e a agregação de conjuntos de dados não rotulados por meio do uso de métodos de aprendizado de máquina (conforme ilustrado na Figura 3). Esses algoritmos têm a capacidade de descobrir padrões ocultos ou agrupamentos de dados sem a necessidade de intervenção humana. O aprendizado não supervisionado é particularmente adequado para análise exploratória de dados, técnicas de venda cruzada, segmentação de consumidores e identificação de imagens e padrões, pois é capaz de identificar semelhanças e contrastes nos dados. Dentre os algoritmos usados no aprendizado não supervisionado, podemos citar redes neurais, o método de agrupamento k-means, abordagens de agrupamento probabilístico, entre outros. Por exemplo, a análise de componentes principais e a decomposição de valores singulares são dois métodos comumente empregados no aprendizado não supervisionado. Eles são utilizados para redução da dimensionalidade e extração de características (RASCHKA; MIRJALILI, 2019).

Figura 3 - Aprendizado de máquina não supervisionado.




Fonte: Elaborado pelo Autor (2023).

2.2.2.3 Aprendizado Semi-supervisionado

Este conceito representa uma abordagem intermediária entre o aprendizado com e sem orientação de um "professor". Durante o treinamento, ele faz uso de um conjunto de dados menor e rotulado para direcionar o processo de classificação e extração de informações em um conjunto de dados maior e não rotulado. O aprendizado semi-supervisionado, ilustrado na Figura 4, surge como uma solução para o desafio da escassez de dados rotulados (ou da impossibilidade de etiquetar dados em quantidade suficiente) para treinar algoritmos de aprendizado supervisionado (RUSSELL; NORVIG, 2021).

Figura 4 - Aprendizado de máquina semi-supervisionado.



Fonte: Elaborado pelo Autor (2023).

2.2.2.4 Aprendizado por Reforço

Esse conceito implica em adotar medidas adequadas para maximizar a compensação em uma dada circunstância. É empregado por software e robôs para determinar o comportamento ou curso de ação ótimo em uma situação específica. No aprendizado supervisionado, os dados de treinamento contêm a chave de solução, de modo que o modelo é treinado com a resposta correta como referência. No entanto, no aprendizado por reforço (conforme apresentado na Figura 5), não há uma resposta pré-definida e nenhum aprendizado anterior; o sistema determina como concluir a tarefa. Na ausência de um conjunto de treinamento, o sistema é compelido a adquirir conhecimento por meio da experiência (RASCHKA; MIRJALILI, 2019).

Figura 5 - Aprendizagem por reforço.




Fonte: Elaborado pelo Autor (2023).

2.3 APRENDIZADO PROFUNDO

O aprendizado de máquina é uma subseção, ou subdisciplina, da Inteligência Artificial, e o Aprendizado Profundo é uma subseção do Aprendizado de Máquina. De acordo com Copeland (2016), a forma mais simplificada de conceber a relação entre esses conceitos é representá-los como círculos concêntricos, em que a IA - a ideia pioneira - é o círculo mais amplo, seguida pelo aprendizado de máquina - que se

desenvolveu posteriormente - e, por fim, o aprendizado profundo - que impulsiona a atual explosão da IA - se encaixa dentro de ambos (Figura 6).

Figura 6 - Inteligência artificial, aprendizado de máquina e aprendizado profundo.



Fonte: Elaborado pelo Autor (2023).

O aprendizado profundo, é uma forma de aprendizado de máquina que se inspira na estrutura do cérebro humano. Os algoritmos de aprendizado profundo buscam extrair conclusões de maneira análoga à mente humana, continuamente analisando dados por meio de uma estrutura lógica específica. Para alcançar esse objetivo, o aprendizado profundo utiliza uma arquitetura composta por várias camadas de algoritmos conhecidas como Redes Neurais Artificiais (ANN - Artificial Neural Network). Essas redes neurais artificiais são construídas com base em dados históricos e podem estimar valores futuros (OPPERMANN, 2022).

O Aprendizado Profundo pode ser considerado uma forma mais avançada de aprendizado de máquina, baseando-se em uma abordagem algorítmica denominada Redes Neurais Artificiais. Essas redes neurais são inspiradas na nossa compreensão

da biologia do cérebro humano e são estruturadas em camadas, com conexões, neurônios e direções de propagação de dados.


2.3.1 Redes Neurais Artificiais

De acordo com Géron e Ravaglia (2021), os primeiros indícios de redes neurais surgiram em 1943, quando o neurofisiologista Warren McCulloch e o matemático Walter Pitts descreveram o funcionamento de neurônios e propuseram um modelo pioneiro de rede neural, marcando um marco significativo nesse campo.

O desenvolvimento de RNN tem sido significativamente influenciado pelo estudo das redes neurais biológicas. Os neurônios, os blocos de construção das redes neurais biológicas, consistem em um corpo celular, dendritos e um axônio, por meio dos quais eles recebem e transmitem sinais. A transmissão de sinais ocorre através de sinapses, onde os impulsos se propagam do axônio de um neurônio para o dendrito de outro. A geração de um pulso eletroquímico, conhecido como potencial de ação, é um mecanismo chave por meio do qual os neurônios se comunicam. Desenvolvimentos recentes na neurociência reavivaram o interesse em compreender a aprendizagem no córtex, especialmente em relação às redes neurais artificiais (LILLICRAP et al., 2020).

Como o nome implica, a estrutura da rede neural é fundamentada na semelhança com os neurônios encontrados no sistema nervoso humano, como é evidenciado na comparação entre um neurônio de rede (representado no lado esquerdo da Figura 7) e um neurônio humano (ilustrado no lado direito da Figura 7).

Figura 7 - Comparação entre o neurônio da rede neural e uma célula nervosa.



Fonte: Adaptado de (GÉRON, 2019).

O cérebro humano opera em redes funcionais em larga escala que sustentam a cognição e o comportamento, e essas redes compartilham propriedades com redes neurais artificiais usadas em aprendizado de máquina. O desenvolvimento de RNN tem sido inspirado pela organização estrutural e funcional do cérebro humano, com o objetivo de alcançar conectividade adaptativa e flexível, bem como comunicação dependente de espaço e tempo, semelhante às redes neurais biológicas (KROHN et al., 2023; YANG et al., 2022).

A inspiração na biologia não se limita apenas à estrutura, mas também ao funcionamento. As RNN são projetadas de modo a aprender e reconhecer padrões, de maneira análoga ao funcionamento do cérebro humano (SUGIURA, 2021). Elas têm a capacidade de executar diversas operações, incluindo agrupamento, classificação e regressão, permitindo a categorização de dados não rotulados com base em semelhanças entre as amostras (SZEGEDY et al., 2015). Modelos de aprendizado profundo, como redes neurais convolucionais (RNC) e redes neurais recorrentes (RNR), aplicam esses princípios para superar desafios de otimização e processar dados (HRAMOV et al., 2018).

Redes neurais têm sido aplicadas em diversos campos, incluindo imagens médicas, previsão de crimes e diagnóstico de falhas (HAN et al., 2018; SHAHROUDNEJAD, 2021; TESHNIZI; AYATOLLAHI, 2015).

Além disso, a capacidade do neurônio artificial de aprender e se adaptar é crucial para o seu funcionamento na rede neural. Semelhante à sua inspiração

biológica, as redes neurais artificiais envolvem ajustes nas conexões sinápticas entre neurônios, permitindo a aprendizagem e o aprimoramento das capacidades de processamento de informações. Esse processo de aprendizado permite que a rede melhore seu desempenho ao longo do tempo e se adapte a mudanças nos dados de entrada (LIU et al., 2023).

Em princípio, uma estrutura cerebral artificial deveria ser mais rápida do que a biológica. No entanto, na realidade, isso não ocorre. A diferença na velocidade de processamento entre os neurônios biológicos e os circuitos neurais artificiais é um tópico de interesse no campo da neurociência e da engenharia neuromórfica. Enquanto os circuitos digitais operam em escalas de nanossegundos, os neurônios biológicos funcionam em escalas de milissegundos (WOOD, 1996). Para compensar essa diferença, o cérebro humano utiliza uma rede maciça de aproximadamente 86 bilhões de neurônios e cerca de 100 trilhões de sinapses e conexões estimadas, o que contribui para sua notável eficiência (WOOD, 1996). A eficiência energética do cérebro é notável, com um consumo de energia estimado de apenas 10^{-17} a 10^{-15} Joules por operação por segundo, em contraste com computadores tradicionais que têm uma eficiência de aproximadamente 10^{-9} Joules (WOOD, 1996). Isso destaca a incrível eficiência e capacidades de processamento paralelo do cérebro humano, que ainda são desafiadoras de replicar em redes neurais artificiais.

2.4 EVOLUÇÃO INDUSTRIAL

A primeira revolução industrial, que teve início na Inglaterra no final do século XVIII, marcou uma mudança significativa na produção mecânica. A introdução de máquinas a vapor tornou os métodos tradicionais de manufatura artesanal obsoletos (AIRES; MOREIRA; FREIRE, 2018).

Hartwell (1990) comenta que esse período transformador trouxe inúmeras melhorias para o cenário industrial. A fabricação de novos produtos químicos, a otimização dos processos fabris, a maior eficiência no uso da energia a vapor e a substituição da madeira e outros biocombustíveis revolucionaram o ambiente industrial, resultando em mudanças profundas na economia e na sociedade. O surgimento de novas profissões, produtos e fábricas impulsionou a migração da

população rural para os centros urbanos, em busca de oportunidades nesse cenário industrial em rápida evolução.

Durante essa era, o trabalho passou de indústrias descentralizadas em pequenas oficinas para fábricas centralizadas. O ritmo de produção não era mais determinado pelos trabalhadores individuais, mas sim por máquinas incansáveis, supervisionadas por encarregados que impunham disciplina rigorosa, muitas vezes recorrendo a medidas coercitivas. Esse novo sistema fabril pode ser comparado a uma forma de detenção, em que as horas de trabalho dos operários eram ditadas pelo relógio, com pouca consideração pelo seu bem-estar (LANDES, 2005).

A segunda revolução industrial, que teve início no final do século XIX, trouxe mudanças ainda mais transformadoras. Essa fase foi caracterizada pelo foco na eletricidade, no uso do petróleo como fonte de energia e na implementação da linha de montagem. Além disso, ocorreram avanços significativos no campo das telecomunicações (SCHWAB, 2019).

O surgimento da eletricidade impulsionou avanços e inovações em diversas indústrias. A invenção da lâmpada incandescente comercial em 1879 revolucionou os sistemas de iluminação urbana e industrial. Linhas de transmissão de energia em longa distância se tornaram uma alternativa mais viável em comparação com as máquinas térmicas movidas a vapor. O uso do petróleo se intensificou na produção de combustíveis, como diesel e gasolina para motores de combustão interna, tendo um impacto profundo nos setores industrial e de transporte. Além disso, houve avanços significativos nas telecomunicações, com a introdução do telefone, rádio e telégrafo, que encurtaram distâncias e aceleraram a comunicação global (DATHEIN, 2003).

Essas mudanças revolucionárias no cenário industrial resultaram na criação de novas oportunidades de emprego, exigindo a aquisição de habilidades novas e especializadas. A transição para a produção em larga escala aumentou a competitividade e exigiu mudanças dinâmicas nos processos fabris.

Segundo Wren e Bedeian (2009), nesse período, os princípios da administração científica, defendidos pelo engenheiro Frederick Winslow Taylor, desempenharam um papel fundamental na melhoria das condições de trabalho nas fábricas e no aumento da produtividade dos trabalhadores. A abordagem de Taylor

abordou diversos desafios, como a falta de incentivos para melhorar o desempenho dos trabalhadores, a necessidade de uma melhor integração entre os diferentes departamentos das empresas e os conflitos entre supervisores e trabalhadores em relação às metas de produção.

Na primeira fase, Taylor identificou a remuneração dos funcionários como uma questão importante que privilegiava o empregador, seja por meio de salários por hora ou por produtividade. "A máxima prosperidade de cada funcionário significa não apenas salários mais altos, mas também, e mais importante, o desenvolvimento de cada indivíduo em sua condição de máxima eficiência" (TAYLOR, 2006). Na segunda fase, o foco passou a ser a melhoria dos métodos de trabalho utilizados, conhecida como administração de operações fabris. Na terceira fase, Taylor resumiu os princípios da administração científica, incluindo o desenvolvimento de um método que representasse a melhor maneira de executar uma tarefa, a seleção e o treinamento/desenvolvimento dos trabalhadores, a busca por mão de obra não resistente aos métodos devido ao sistema de pagamento e a divisão do trabalho entre supervisores e trabalhadores (KWASNICKA, 2004).

O nome de Henry Ford também se destaca na segunda revolução industrial por sua capacidade de aumentar significativamente os níveis de produção em massa. A produção em massa é caracterizada pela fabricação de peças padronizadas e pela necessidade de trabalhadores especializados em tarefas específicas, realizando um número menor de atividades e ocupando uma posição mais fixa dentro da fábrica.

A terceira revolução industrial, que teve início na década de 1960, é lembrada como a revolução digital ou da computação, impulsionada pelo desenvolvimento de várias tecnologias, como semicondutores, computação em mainframe, computação pessoal, entre as décadas de 1970 e 1980, e a internet na década de 1990 (SCHWAB, 2019).

A automação e a robótica são aplicadas nas linhas de produção, e as informações são armazenadas e processadas de forma digital. O setor de comunicação passa por mais uma transformação total com o surgimento e o uso da telefonia móvel.

Neste período, observa-se que as empresas que conseguiram se adaptar mais rapidamente a essas mudanças se destacaram, como a indústria siderúrgica,

metalúrgica e automobilística, que fizeram investimentos significativos durante os períodos das grandes guerras mundiais e aprimoraram suas invenções posteriormente.

O uso de instrumentos mais precisos e eficientes permitiu otimizar o tempo de fabricação e os custos com mão de obra, e o aumento dos lucros foi uma consequência de todos esses fatores associados. Nesse período, o mundo foi apresentado a uma palavra que mudaria drasticamente a realidade: globalização. Agora, as informações podiam circular mais rapidamente, sem barreiras físicas ou temporais (SILVA; DA SILVA; GOMES, 2002).

2.5 INDÚSTRIA 4.0

O termo "INDÚSTRIA 4.0" foi introduzido pela primeira vez em 2011 como parte de um projeto estratégico voltado para o aumento da produtividade na indústria alemã, por meio da incorporação de inovações de alta tecnologia. Em 2012, o grupo encarregado desse projeto, liderado por Siegfried Dais e Kagermann, apresentou um relatório ao governo alemão delineando estratégias para a implementação da INDÚSTRIA 4.0. Posteriormente, em 2013, o trabalho desse grupo foi exposto na Feira de Hannover sob o título "Recomendações Estratégicas para a Implementação da INDÚSTRIA 4.0", no qual foram elencados os passos necessários para a efetiva implantação de uma indústria no contexto 4.0, conforme documentado por (BERTULUCCI, 2016).

Indústria 4.0, também conhecida como Quarta Revolução Industrial, é caracterizada pela integração de tecnologias digitais nos processos industriais, resultando em maior automação, conectividade e troca de dados (KICIŃSKI; CHAJA, 2021). É um conceito transformador que está remodelando a indústria manufatureira. A Indústria 4.0 utiliza tecnologias como big data, sensores inteligentes, robótica, computação em nuvem, aprendizado de máquina, realidade aumentada, inteligência artificial e Internet das Coisas (ERSOY, 2022). Essas tecnologias permitem o desenvolvimento de fábricas inteligentes e a otimização dos processos de produção (TALEB; AFOLABI; BAGAA, 2019).

Ainda de acordo com Taleb, Afolabi e Bagaa (2019), uma das principais características da Indústria 4.0 é a maior conectividade e comunicação entre máquinas, sistemas e seres humanos. Essa conectividade permite a coleta e análise de dados em tempo real, possibilitando a manutenção preditiva, aprimorando a tomada de decisões e aumentando a eficiência (LEITAO et al., 2020). Outra característica é o uso de robótica avançada e automação, capazes de realizar tarefas complexas com precisão e rapidez. Isso leva a um aumento da produtividade e à redução de erros humanos (KICIŃSKI; CHAJA, 2021).

Filho e Goi (2021) argumentam que fábricas que operam em um nível avançado de integração e automação precisarão ter máquinas, processos, sistemas e edifícios projetados especificamente para alcançar esse objetivo. No entanto, não se trata apenas de investimentos físicos, pois também requer ações planejadas significativas nas áreas organizacionais.

O termo Indústria 4.0 pode englobar diversas definições que abarcam diferentes perspectivas conceituais. De acordo com Shafiq et al. (2015), refere-se à integração de máquinas e dispositivos físicos equipados com sensores e softwares, os quais são empregados para antever, controlar e planejar resultados de maneira mais eficiente.

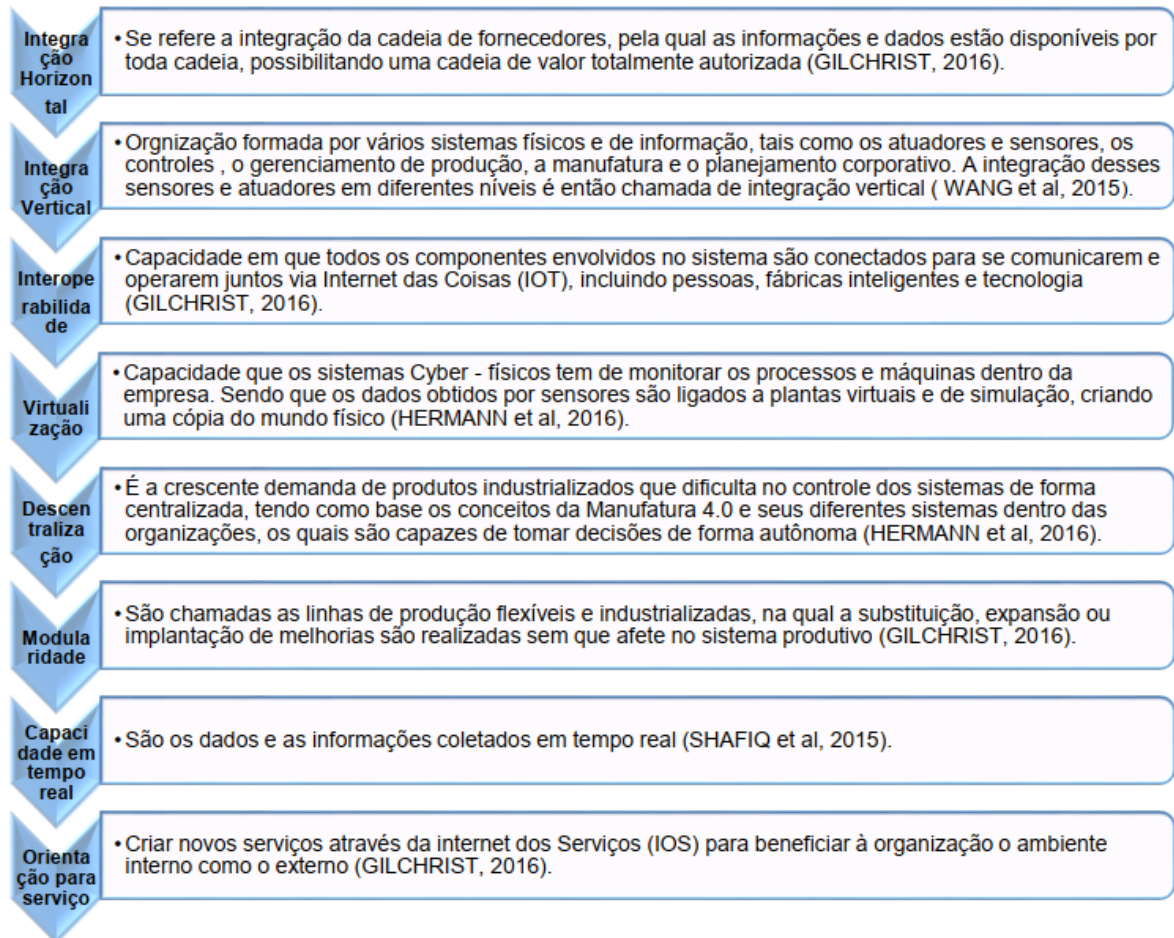
Por outro prisma, na concepção de Khan e Turowski (2016), Indústria 4.0 representa a revolução da aplicação de tecnologias avançadas em um sistema de produção que incorpora novos valores e serviços para seus clientes, resultando em benefícios significativos para a organização em si. Esse enfoque pode, por conseguinte, aprimorar a flexibilidade e a qualidade dos sistemas produtivos, atendendo às demandas dos novos e inovadores modelos de negócios e fazendo uso de serviços ágeis.

Dentre as principais características da Indústria 4.0, destacam-se aquelas que se revelam mais distintivas, a saber: Integração Horizontal, Integração Vertical, Interoperabilidade, Virtualização, Descentralização, Modularidade, Capacidade em Tempo Real e Orientação para Serviços. Estas características conferem benefícios significativos tanto para as empresas como para os clientes. No que concerne às empresas, possibilitam tomadas de decisão mais ágeis, evitando a ocorrência de atrasos e perdas na produção. Quanto aos clientes, a Indústria 4.0 proporciona uma

gama mais ampla de produtos, entregues com maior celeridade, atendendo, assim, às suas exigências de forma satisfatória (SCHULES, 2019).

A seguir, na Figura 8, é possível identificar tais características à profundamente:


Figura 8 - Características da Manufatura 4.0



Fonte: Adaptado de Schules (2019)

Dentro do contexto da Indústria 4.0, os chamados "pilares tecnológicos" representam as tecnologias fundamentais que sustentam e impulsionam essa nova revolução industrial. O Boston Consulting Group (BCG) identificou nove desses pilares tecnológicos que desempenham um papel central no avanço da Indústria 4.0 (RÜßMANN et al., 2015). Na Figura 9, podemos observar os nove pilares tecnológicos com base no estudo de caso realizado pelo Boston BCG em empresas alemãs.

Figura 9 - Pilares da Industria 4.0



Fonte – BCG Industry 4.0: The Future of Productivity and Growth in Manufacturing Industries (https://www.bcg.com/publications/2015/engineered_products_project_business_industry_4_future_productivity_growth_manufacturing_industries, acessado em outubro de 2023)

Faz-se necessário uma breve explicação de cada um desses pilares para uma compreensão mais aprofundada das tecnologias envolvidas (RÜßMANN et al., 2015):

- a) Cloud (Nuvem): Representa o espaço de armazenamento de dados, permitindo que organizações aloquem informações provenientes de sensores de forma acessível e disponível em qualquer local, eliminando a necessidade de buscar dados em discos rígidos físicos.
- b) Impressão 3D ou Manufatura Aditiva: Usada para a prototipagem e produção de componentes individuais, possibilitando a produção de peças específicas ou protótipos funcionais de maneira eficiente, reduzindo o tempo de entrega e minimizando os estoques de reposição.
- c) Realidade Aumentada: Envolvendo diversos serviços, a realidade aumentada inclui, por exemplo, o uso de óculos de realidade aumentada, permitindo que operadores recebam orientações para reparar ou substituir componentes específicos.

d) Big Data: Refere-se à análise baseada em grandes volumes de dados, possibilitando a coleta e a avaliação abrangente de informações provenientes de diversas fontes, incluindo equipamentos de produção, sistemas de gerenciamento empresarial e sistemas de clientes. Essa análise é essencial para tomadas de decisão em tempo real.

e) Robôs Autônomos: São utilizados para realizar tarefas independentes dos seres humanos, interagindo com eles de forma coordenada. Isso permite a automatização de tarefas repetitivas e de menor valor agregado, liberando os humanos para atividades mais complexas.

f) Simuladores: Consistem na geração de cenários diversos para apoiar a tomada de decisões, permitindo a compreensão do que ocorrerá em determinados ambientes. Isso é exemplificado pelo uso de drones que monitoram parques industriais, identificando movimentos de produtos e pessoas, auxiliando na otimização de recursos e processos.

g) Integração Horizontal e Vertical: Permite a criação de uma cadeia de valor integrada, possibilitando a colaboração entre diversos parceiros, como fornecedores, empresas e clientes. Isso resulta em uma troca eficiente de dados de produtos e produção.

h) Internet Industrial das Coisas (IIoT): Envolve a interconexão de dispositivos de campo enriquecidos com computação, permitindo que comuniquem e interajam entre si, proporcionando análise e tomada de decisões em tempo real.

i) Segurança de Dados: Torna-se crucial com o aumento do uso da tecnologia, visto que a segurança dos ativos, que incluem o fluxo de informações e a proteção de dados, torna-se essencial para prevenir ataques virtuais e o roubo de informações.

Além desses pilares, alguns autores afirmam que a Inteligência Artificial também é considerada fundamental na Indústria 4.0, uma vez que envolve a criação de máquinas inteligentes que podem perceber, entender, agir e aprender de forma autônoma ou em conjunto com atividades humanas (SACOMANO et al., 2018). A IA

desempenha um papel central na automação e na melhoria da eficiência em vários aspectos da Indústria 4.0.

2.6 SUPPLY CHAIN MAGANEMENT

O conceito de gerenciamento da cadeia de suprimentos (Supply Chain Management - SCM) teve sua origem no início da década de 80, quando Oliver e Webber (1982), consultores especializados em logística, propuseram o uso desse termo para descrever um novo campo da ciência que estava em desenvolvimento. Conforme definido por Oliver e Webber (1982), o gerenciamento da cadeia de suprimentos é um processo que envolve o planejamento, implementação e controle das operações da cadeia, com o objetivo de satisfazer as demandas dos clientes da forma mais eficiente possível. A abordagem da SCM abrange todos os aspectos relacionados à movimentação e ao armazenamento de matérias-primas, estoques em processo e produtos acabados, desde o ponto de origem até o ponto de consumo.

É importante notar que as pesquisas relacionadas à integração e coordenação de diferentes unidades funcionais que são fundamentais para o SCM datam de antes do surgimento do próprio termo. Várias áreas, incluindo logística, marketing, gestão e pesquisa organizacional, demonstraram interesse nesse tópico conforme mencionado por Green e Whitten e Inman (2008). Temas relacionados, como desenvolvimento de canais (ALDERSON, 1957), o "efeito chicote" em sistemas de produção e distribuição (FORRESTER, 1958), localização de estoques (HANSSMANN, 1959), análise de colaboração e cooperação (BOWERSOX; CLOSS, 1996) e planejamento de produção hierárquica (HAX; MEAL, 1975) foram investigados e discutidos na literatura ao longo do tempo.

Felea e Albăstroiu (2013) destacam que o interesse e a importância do gerenciamento da cadeia de suprimentos aumentaram significativamente desde a década de 80, quando as empresas perceberam a necessidade de colaborar com fornecedores e outras partes da cadeia de suprimentos para se manterem competitivas. A aplicação prática do SCM tem sido amplamente pesquisada, e várias definições foram propostas na literatura para descrever a gestão eficaz da cadeia de suprimentos.

Além disso, alguns autores enfatizam que a SCM tem raízes na evolução histórica da logística, e muitos consideram as duas como sinônimos. Ballou e Gilbert e Mukherjee (2000) propõem que existem três abordagens conceituais principais para o SCM: coordenação intrafuncional, que se refere à gestão das atividades logísticas dentro de uma empresa; coordenação interfuncional, que envolve a coordenação entre diferentes funções e áreas funcionais dentro da empresa; e coordenação interorganizacional, que diz respeito à coordenação das atividades que ocorrem entre empresas distintas na cadeia de suprimentos, envolvendo o fluxo de produtos (Figura 10).

Figura 10 - As três dimensões do Supply Chain Management




Fonte: adaptada de Ballou, Gilbert e Mukherjee (2000).

Consequentemente, de acordo com Ballou e Gilbert e Mukherjee (2000), as atividades tanto intrafuncionais quanto interfuncionais, normalmente associadas à gestão da logística empresarial, estão inseridas no escopo do gerenciamento da cadeia de suprimentos. Isso implica que a logística pode ser considerada uma subárea do SCM.

No entanto, Larson e Halldorsson (2004) identificaram quatro perspectivas conceituais distintas que abordam a amplitude dos conceitos de gerenciamento da cadeia de suprimentos e logística: i) abordagem tradicional; ii) re-rotulagem; iii) perspectiva sindicalista; e iv) perspectiva interseccionada (conforme ilustrado na Figura 11).

Figura 11 - Perspectivas da Logística versus Supply Chain Management



Fonte: Adaptada de Larson e Halldorsson (2004).

A abordagem tradicional concebe o SCM como uma parte limitada da logística, tratando-o como uma forma especializada de logística que se concentra nas operações externas ou interorganizacionais. Por outro lado, a perspectiva de re-rotulagem simplesmente renomeia a logística como gerenciamento da cadeia de suprimentos, mantendo, em grande parte, a essência das atividades semelhante à logística, o que se assemelha às dimensões de logística definidas por Ballou e Gilbert e Mukherjee (2000), como apresentado na Figura 10. Na visão sindicalista, a logística é considerada uma parte integrante do SCM, fazendo parte dos muitos processos ou áreas de negócios que compõem o gerenciamento da cadeia de suprimentos. Por fim, na perspectiva interseccionada, o SCM é compreendido como uma estratégia abrangente que engloba diversas, se não todas, as áreas de negócios da organização, enquanto a logística lida com decisões operacionais. Nessa ótica, o SCM está associado às decisões estratégicas, enquanto as decisões táticas são compartilhadas na interseção entre o SCM e a logística, que também desempenha um papel nas decisões organizacionais.

2.7 APLICAÇÃO DE INTELIGENCIA ARTIFICIAL NO *SUPPLY CHAIN* MANAGEMENT

No âmbito do SCM, o gerenciamento da qualidade desempenha um papel fundamental. A gestão da qualidade orientada por dados tem um impacto profundo na melhoria dos processos da cadeia de suprimentos, no planejamento e nas operações. A utilização de técnicas de gerenciamento da qualidade orientadas por dados é fundamental para capacitar a cadeia de suprimentos a permanecer competitiva no mercado global (AGRAWAL et al., 2023). A Aprendizagem de Máquina tem recebido atenção significativa por sua substancial contribuição para a digitalização das operações de fabricação. As aplicações de ML abrangem diversos domínios na fabricação, abordando tarefas de diferentes níveis de complexidade e aprimorando o desempenho (CHEN et al., 2023).

Com o advento da era da Indústria 4.0, torna-se evidente a necessidade de digitalização e desmaterialização da cadeia de suprimentos. As técnicas de ML e a inteligência artificial facilitam a aquisição de dados extensivos da Internet das Coisas e da tecnologia de proximidade, auxiliando na mitigação dos riscos da cadeia de suprimentos (PERANO et al., 2023). Algoritmos de ML se mostram inestimáveis no gerenciamento das complexidades e incertezas inerentes a problemas do mundo real, como o problema de roteamento de veículos (PRV). A combinação de algoritmos de ML e metodologias analíticas aprimora cenários de resolução de problemas, abrangendo formulações de problemas e desempenho de algoritmos (BAI et al., 2023).

A paisagem pós-COVID introduziu desafios adicionais para a SCM. Há uma crescente necessidade de aprimorar a resiliência da cadeia de suprimentos (SCR), com foco em fatores vitais como interconexão e transformabilidade. Modgil e Singh e Hannibal (2022) discutem como a IA pode aprimorar a SCR desenvolvendo capacidades de continuidade dos negócios. Ao aproveitar tecnologias de IA, como ciência de dados e métodos supervisionados de aprendizado de máquina, as organizações podem prever e mitigar melhor as interrupções, otimizar a gestão de estoques e melhorar a previsão de demanda.

A IA também pode ser usada para otimizar as operações da cadeia de suprimentos e os processos de tomada de decisão. Tsolakis et al. (2023) destacam a implementação conjunta da IA e da tecnologia blockchain nas cadeias de suprimentos para ampliar os limites de desempenho operacional e promover o desenvolvimento sustentável. Um esforço intensificado é necessário para promover a adoção de técnicas de IA/AM entre micro, pequenas e médias empresas (MPMEs), concedendo-lhes uma vantagem competitiva para a sustentabilidade nesse ambiente (YOUNIS; SUNDARAKANI; ALSHARAI, 2022).

Na paisagem tecnológica em rápida evolução, a tomada de decisões na gestão da cadeia de suprimentos enfrenta desafios devido à complexidade da combinação de processos contínuos e discretos. A geração rápida de dados requer algoritmos inteligentes e alto poder de processamento. A aprendizagem por reforço oferece um ambiente sustentável, adaptativo e dinâmico para a gestão da cadeia de suprimentos (ROLF et al., 2023). Avanços nos campos da Internet das Coisas, big data, computação em nuvem e ML estão impulsionando o surgimento da era da Indústria 5.0. A Indústria 5.0 gira em torno de três componentes essenciais: seres humanos, organizações e tecnologia. Ela se baseia em princípios fundamentais de colaboração, comunicação, coordenação e automação (ZIZIC et al., 2022).


2.8 INDÚSTRIA 5.0

O termo "Indústria 5.0," também conhecido como a Quinta Revolução Industrial, foi cunhado pela primeira vez em 2015. Ele se destaca pela ênfase na personalização de produtos e pela integração da relação entre seres humanos e sistemas inteligentes. Isso envolve a combinação da criatividade humana com a agilidade e precisão de robôs, incluindo a capacidade de operar em ambientes adversos (MAESTRI et al., 2021). A Indústria 5.0 surge como uma alternativa para enfrentar diversos desafios contemporâneos, que se tornaram ainda mais complexos e dinâmicos devido a eventos como a pandemia da COVID-19 e o conflito entre Rússia e Ucrânia. Esses acontecimentos elevaram o nível de complexidade desse cenário a um patamar anteriormente inimaginável (PEREIRA; SANTOS, 2022).

A Indústria 5.0 é a fusão de tecnologia avançada com princípios organizacionais, visando aprimorar as operações e tornar a cadeia de suprimentos mais resiliente e sustentável em um mundo altamente competitivo (IVANOV, 2023). Em um mundo em constante crescimento e avançado, surgem desafios cruciais, como ciclos de vida de produtos curtos e a produção de produtos personalizados. Para superar esses desafios, técnicas de aprendizado profundo por reforço podem ser empregadas para otimizar o processo de produção (PANZER; BENDER, 2022). A evolução e exploração de técnicas de ML estão crescendo rapidamente em novos domínios. As capacidades da cadeia de suprimentos estão se aprimorando rapidamente com o uso de ferramentas e técnicas de IA e ML. As ferramentas de ML proporcionam uma vantagem competitiva e sustentável para a Gestão da Cadeia de Suprimentos (RAZA; GOVINDALURI; BHUTTA, 2023).

Conforme destacado por (ASLAM et al., 2020), a Indústria 5.0 se baseia em um sistema que prioriza a personalização de produtos, operando com pequenos lotes de produção individualizados e, como resultado, gerando maior valor agregado. Esse conceito se diferencia significativamente da abordagem da Indústria 4.0, que se baseia em um modelo de produção em massa por meio de linhas de produção autônomas, com foco em grandes lotes de produção para atender à demanda. A Indústria 5.0 incorpora diversas tecnologias, tais como manufatura aditiva, robôs colaborativos e uma proporção significativa de dispositivos conectados a redes de internet, além de um ecossistema digital e o desenvolvimento da inteligência artificial (ASLAM et al., 2020). A Figura 12 oferece uma representação visual das principais características dessa era, destacando os elementos de "personalização", "criatividade" e a simulação da colaboração entre seres humanos e robôs. Além disso, as tecnologias habilitadoras da Indústria 4.0 continuam presentes, uma vez que essa transição é considerada.

Figura 12 - Indústria 5.0: personalização de produtos e serviços e co-trabalho entre colaboradores e robôs.



Fonte: Maestri et al., 2021

A Indústria 5.0 é fundamentada na sinergia entre seres humanos e máquinas autônomas. Em comparação com a Indústria 4.0, essa abordagem coloca um foco maior no ser humano, visando a combinação do potencial do cérebro humano e da criatividade, mantendo ao mesmo tempo a sustentabilidade e a ambidestria (ASLAM et al., 2020). Esse conceito enfatiza a importância da pesquisa e da inovação como meios de sustentar a indústria a longo prazo, atendendo às necessidades humanas (PEREIRA; SANTOS, 2022).

As revoluções industriais têm proporcionado benefícios significativos para os setores produtivos, permitindo níveis mais elevados de produção, melhor controle de qualidade, redução de desperdícios e a capacidade de produzir itens diferenciados e competitivos. Portanto, é essencial desenvolver estratégias cada vez mais competitivas, alinhadas com os avanços digitais e tecnológicos.

3 METODOLOGIA

Esta seção resume a abordagem e o método de pesquisa, que serão detalhados nos tópicos a seguir.

3.1 LACUNAS DE PESQUISA

As tendências atuais, oportunidades e desafios do Aprendizado de Máquina na gestão de logística e cadeia de suprimentos são brevemente destacados por Akbari e Do (2021), que consideraram um total de 115 artigos de 1994 a 2019. Este artigo de pesquisa fornece uma metodologia de pesquisa detalhada adaptada para a aplicação do ML na SCM. Aamer, Eka Yani e Alan Priyatna (2020) concentram-se na aplicação de técnicas de ML para previsão de demanda. O autor selecionou sistematicamente 79 artigos de um total de 1.870 para uma análise detalhada. Este artigo categoriza os trabalhos de pesquisa em três setores: agricultura, indústria e setor de serviços. Agrawal et al. (2023) revisaram artigos de pesquisa relacionados à gestão da qualidade orientada por dados na cadeia de suprimentos. O autor analisou e revisou 595 artigos da base de dados SCOPUS, com foco na melhoria da qualidade das empresas da cadeia de suprimentos por meio de tecnologias digitais. Borodavko, Illés e Bányai (2021) elaboraram o impacto da Indústria 4.0 na cadeia de suprimentos e logística, explicando sucintamente os desafios e benefícios da adoção da inteligência artificial na gestão da cadeia de suprimentos e logística. Boute et al. (2022) descreveram o algoritmo de aprendizado profundo de reforço para o desenvolvimento da tomada de decisões na gestão de estoques. Ni, Xiao e Lim (2020) revisaram brevemente artigos de periódicos publicados entre 1998 e 2018, com um total de 123 artigos selecionados para análise quantitativa. O foco do artigo de pesquisa é contribuir para uma visão abrangente da aplicação de ML na gestão da cadeia de suprimentos. Qi, Mak e Shen (2020) realizaram um levantamento dos artigos de pesquisa relacionados à pesquisa operacional e ciência da gestão que se concentraram na abordagem orientada por dados nas operações de varejo.

Embora várias aplicações de ML sejam destacadas na revisão da literatura, há uma carência de uma revisão completa sob um único domínio. Existe a necessidade de estudar a revisão da literatura e categorizá-la em subdomínios para que seja útil para engenheiros, autoridades empresariais e pesquisadores. Isso é fundamental para compreender completamente a necessidade e o escopo do assunto e é útil para pesquisadores que podem precisar de pesquisas futuras. Portanto, este artigo contribui fornecendo uma análise sistemática da revisão da literatura e uma análise estatística da literatura disponível sobre a adoção de técnicas de ML no setor de manufatura.

A lacuna na pesquisa pode ser identificada a partir das pesquisas mais recentes na área de aprendizado de máquina citadas acima. A maioria das pesquisas está focada na implementação de ML para melhorar o desempenho e eficiência da cadeia de suprimentos. Esta pesquisa visa analisar mais a fundo as pesquisas existentes e estender a pesquisa para a adoção de ML na cadeia de suprimentos de manufatura. Existe uma carência de pesquisas sobre ML na cadeia de suprimentos de manufatura. Portanto, há uma necessidade de concentração na área de adoção de ML na "Manufatura" e "Cadeia de Suprimentos".

Este artigo de pesquisa aborda a lacuna na pesquisa por meio de uma revisão sistemática da literatura (RSL) sobre a implementação de ML na cadeia de suprimentos de manufatura. A academia e os profissionais da área certamente se beneficiarão com este estudo. O mundo foi fortemente impactado após o cenário da pandemia de COVID-19, o que causou dinâmicas na demanda do cliente. Para prever com precisão a demanda do cliente flutuante na cadeia de suprimentos no setor da Indústria de manufatura, há a necessidade de implementação de técnicas de ML. Portanto, este estudo visa abordar essa necessidade de pesquisa.

3.2 QUESTÕES DE PESQUISA

Para abordar as lacunas de pesquisa mencionadas, este estudo aborda as seguintes questões de pesquisa:

QP1. Quais são as contribuições de diversas fontes para a aprendizagem de máquina na cadeia de suprimentos de manufatura?

QP2. Quais são os diversos estudos realizados sobre ML na cadeia de suprimentos de manufatura e suas categorias?

QP3. Quais são as tendências futuras do ML na cadeia de suprimentos de manufatura?

Além das perguntas norteadoras, o presente trabalho de conclusão de curso buscará identificar os desafios e barreiras que a implantação de ML no SMC da indústria manufatureira enfrenta.

Uma RSL foi realizada para responder às QPs acima, com foco na aplicação de ML na SCM.

3.3 MODALIDADE DE PESQUISA

Conforme delineado nos objetivos, o presente estudo visa a realizar uma revisão sistemática para aprofundar a temática em questão. Dessa forma, o trabalho oferece uma base teórica sólida, e a pesquisa é caracterizada como fundamental em sua natureza, embora também possa servir como referência para estudos de caso futuros ou a abordagem de problemas práticos.

A pesquisa tem como objetivo compreender um conteúdo/assunto específico para poder solucionar um determinado problema. A classificação da pesquisa pode variar dependendo dos autores adotados. No contexto das pesquisas, Prodanov e Freitas (2013) identificam três perspectivas de classificação: a natureza da pesquisa, a abordagem utilizada, os objetivos da pesquisa.

Em relação à natureza, uma pesquisa pode ser categorizada como básica ou aplicada. A pesquisa básica busca a geração de conhecimento sem necessariamente visar uma aplicação prática, enquanto a pesquisa aplicada tem como objetivo gerar conhecimento com o propósito direto de solucionar problemas específicos (DA SILVA; MENEZES, 2005). Nesse contexto, este estudo pode ser caracterizado como

aplicado, uma vez que busca produzir resultados que possam servir como solução, ou parte dela, para problemas reais.

No que diz respeito à abordagem, uma pesquisa pode ser classificada como quantitativa, qualitativa ou uma combinação de ambas (MIGUEL et al., 2010). Uma pesquisa é considerada quantitativa quando utiliza análises estatísticas para alcançar seus resultados. Por outro lado, uma pesquisa qualitativa se baseia em discussões, reflexões e conhecimento existente para aprofundar a compreensão de um determinado tema. A abordagem combinada visa empregar tanto a análise quantitativa quanto a qualitativa (MIGUEL et al., 2010). Portanto, esta pesquisa é categorizada como qualitativa.

No que se refere aos objetivos, a pesquisa pode ser classificada como exploratória, descritiva ou explicativa, de acordo com a taxonomia proposta por Gil (2022). A pesquisa exploratória visa proporcionar uma compreensão mais profunda do problema em estudo. Por outro lado, a pesquisa descritiva busca detalhar as características de um fenômeno (ou população) e/ou estabelecer relações entre variáveis (GIL, 2022). Enquanto isso, a pesquisa explicativa tem como objetivo elucidar as razões subjacentes à ocorrência dos fenômenos (GIL, 2022)

Portanto, com base no exposto, pode-se categorizar esta pesquisa, em relação aos seus objetivos, como exploratória e descritiva. Isso porque busca familiarizar-se com o tema do uso da inteligência artificial na SCM da Indústria 4.0.

Será adotada a abordagem de RSL. Galvão e Pereira (2014) diz que se trata de um tipo de investigação focada em questão bem definida, que visa identificar, selecionar, avaliar e sintetizar as evidências relevantes disponíveis.

Ainda sobre a RSL, Galvão e Pereira (2014) afirma que:

As revisões sistemáticas devem ser abrangentes e não tendenciosas na sua preparação. Os critérios adotados são divulgados de modo que outros pesquisadores possam repetir o procedimento. Revisões sistemáticas de boa qualidade são consideradas o melhor nível de evidência para tomadas de decisão. Por seguir um método científico explícito e apresentar resultado novo, a revisão sistemática é classificada como contribuição original na maioria das revistas de pesquisa.

A revisão sistemática da literatura envolve a coleta de uma ampla gama de materiais relevantes em um campo específico, uma especialidade ou um aspecto de um tópico de pesquisa, e busca sintetizar os avanços acadêmicos mais recentes relacionados ao tema em questão. Esse método utiliza análise, leitura, classificação e resumo para alcançar esse objetivo (GONÇALVES, 2019). Além disso, a revisão sistemática tem como propósito resumir o estado atual da pesquisa em um determinado campo e auxiliar na identificação de questões de pesquisa específicas (ROWLEY; SLACK, 2004). Para atingir seus objetivos, a revisão sistemática emprega diversas técnicas destinadas a minimizar vieses e erros, resultando na produção de evidências de alta qualidade (TRANFIELD; DENYER; SMART, 2003). O processo de revisão sistemática segue etapas cuidadosamente planejadas para coletar informações relevantes sobre o tópico de pesquisa proposto (GOUGH, 2007) e para justificar e delimitar a questão de pesquisa (TRANFIELD; DENYER; SMART, 2003).

A revisão sistemática da literatura é um método que visa promover a reprodutibilidade da pesquisa e é caracterizado por sua natureza científica e transparência (TRANFIELD; DENYER; SMART, 2003). Para conduzir uma revisão sistemática, é essencial seguir um protocolo rigoroso. Esses protocolos estabelecem diretrizes relacionadas à sequência da pesquisa, seleção de palavras-chave, bancos de dados a serem consultados, e critérios de inclusão e exclusão, que são fundamentais para a seleção dos trabalhos a serem analisados (TRANFIELD; DENYER; SMART, 2003). É crucial que o protocolo seja explicitamente documentado antes do início do processo de revisão para garantir que a pesquisa seja realizada com cuidado e de maneira consistente (MOHER et al., 2015).


Neste estudo, foi conduzida uma revisão sistemática da literatura seguindo as etapas delineadas no fluxograma Preferred Reporting Items for Systematic Review and Meta-Analysis (PRISMA) (MOHER et al., 2015). Esse enfoque fornece uma estrutura metodológica clara e reconhecida para conduzir revisões sistemáticas, promovendo a integridade e a transparência no processo de pesquisa.

3.4 METODOLOGIA ADOTADA PARA RSL

A pesquisa bibliográfica realizada neste estudo seguiu um processo em etapas de acordo com a Metodologia PRISMA conforme mostrado na Figura 13.

A revisão da literatura foi conduzida de forma abrangente em periódicos revisados por pares disponíveis em fontes de pesquisa abertas. A Tabela 1 apresenta a abordagem de seleção dos estudos para o trabalho de pesquisa, considerando critérios como o período de 2015 a 2023 e a língua inglesa.

Figura 13 - Etapa de pesquisa de acordo com a metodologia PRISMA.



Fonte: Elaborado pelo Autor (2023)

Tabela 1 - Critérios de inclusão e exclusão

Tópico	Critérios de Inclusão	Critérios de exclusão	Observação
Base de dados	SCOPUS	Outros bancos de dados	A pesquisa literária foi baseada apenas em artigos em inglês. Para investigar novos avanços no campo da aplicação da abordagem de aprendizado de máquina na Gestão da Cadeia de Suprimentos, uma revisão breve da literatura foi realizada em artigos a partir de 2015. Todos os artigos necessários para a pesquisa literária foram coletados na base de dados SCOPUS, com o objetivo de desenvolver o uso de técnicas de aprendizado de máquina na área de manufatura.
Período de tempo	2015 a 2023	Antes de 2015	
Tipo de Documento	Artigos e Revisões publicados em Revistas científicas, congressos, livros, capítulos de livros.	Artigos não publicados, trabalho de conclusão de cursos, dissertações, teses e documentos não científicos (por exemplo, editorial, carta).	
Linguagem	Inglês	Outros Idiomas	
Acesso	Ter acesso ao documento completo.	Não ter acesso ao documento completo.	

Fonte: Elaborado pelo Autor (2023).

Durante a fase de identificação dos arquivos para a pesquisa em questão, foi utilizada a base de dados SCOPUS, com o intuito de encontrar artigos relevantes sobre o tema proposto. Para responder às perguntas desta revisão, no processo a *string* de busca utilizada na pesquisa foi “*Supply Chain Management*” e “*Machine Learning*”, pois assim foi possível obter o maior número de pesquisas relacionadas ao

uso de aprendizado de máquina com a expressão “aprendizado de máquina” em inglês, e o termo “*Supply Chain Management*” delimitou o campo em que o termo “*Machine Learning*” se aplicaria. As palavras-chave determinadas devem ser encontradas no título, resumo ou palavras-chave das publicações. Portanto, a seguinte consulta de pesquisa foi usada nesta revisão sistemática resultando em 600 trabalhos: (*TITLE-ABS-KEY ("Machine Learning") AND TITLE-ABS-KEY ("Supply Chain Management")*)

A próxima etapa é eliminar quaisquer artigos que não sejam relevantes. Isso é feito determinando quais publicações devem ser incluídas na revisão (critérios de inclusão) e quais devem ser descartadas sem uma análise mais aprofundada (critérios de exclusão). O resultado da pesquisa de acordo com período de 2015 a 2023 foi um total de 560 entradas de publicações. Em seguida, o material selecionado foi limitado a artigos e revisões publicados em revistas revisadas por pares, totalizando 281 artigos. Incluindo publicações escritas em inglês, restaram 277 artigos. Foram selecionados somente os trabalhos já finalizados, resultando 257. Finalmente foram filtrados e excluídos os trabalhos que não apresentavam acesso completo e que não se relacionavam diretamente com as palavras chaves. Ao final desse processo, foram obtidos um total de 127 artigos que atenderam aos critérios estabelecidos

Posteriormente, uma primeira leitura criteriosa foi realizada nos títulos, resumos e palavras-chave dos documentos, com o objetivo de identificar aqueles que estavam alinhados com o tema proposto da pesquisa. Em seguida, uma segunda leitura foi conduzida, dessa vez abrangendo as introduções e conclusões dos documentos selecionados, proporcionando uma compreensão mais aprofundada do contexto geral da pesquisa. Por fim, uma leitura completa de cada documento foi realizada, focando na identificação das ferramentas de qualidade mais frequentemente aplicadas e no entendimento de como essas ferramentas impactam o desempenho operacional das organizações. Após a conclusão dessas etapas, um total de 74 documentos foi cuidadosamente escolhido para compor a amostra final, representando uma base sólida para a análise e investigação em questão.

4 RESULTADOS E DISCUSSÕES

Nessa seção serão apresentados os resultados obtidos durante o desenvolvimento do trabalho, na qual será realizada a discussão dos resultados da revisão sistemática. Os resultados serão apresentados de acordo com as “Questões de Pesquisa”, presentes na seção 3.2.


4.1 CONTRIBUIÇÕES DE DIVERSAS FONTES PARA A APRENDIZAGEM DE MÁQUINA NA CADEIA DE SUPRIMENTOS DE MANUFATURA

O estudo estatístico é conduzido por meio da distribuição dos artigos de periódicos em diferentes categorias. Os artigos são diferenciados em quatro categorias: (1) Tipo de artigo de pesquisa, (2) Diferentes países contribuindo nesta área de pesquisa, (3) Publicação de artigos ano a ano e (4) Diferentes periódicos que contribuíram para a publicação de trabalhos de pesquisa relacionados à adoção de técnicas de aprendizagem de máquina na cadeia de suprimentos de manufatura.

4.1.1 Análise com base no tipo de artigos de pesquisa

A área de pesquisa completa é distinguida pela ênfase no tipo de artigos de periódicos. Os artigos de pesquisa que realizaram levantamento de literatura, desenvolveram algum trabalho teórico e elaboraram estruturas conceituais são categorizados como estudos teóricos. Os artigos que descreveram algum levantamento gerencial, modelagem matemática e simulação são agrupados na categoria de modelagem matemática e simulação. Os artigos que criaram protótipos e descreveram algum estudo de caso implementando-os na indústria são categorizados na categoria de implementação. A Figura 14 - Tipo de artigo de pesquisa, mostra a classificação dos artigos de acordo com as diferentes categorias.

Figura 14 - Tipo de artigo de pesquisa.




Fonte: Elaborado pelo Autor (2023).

4.1.2 Análise por país dos artigos de periódicos

Observa-se que o número máximo de artigos de periódicos é publicado pela China (12 artigos). Em seguida, Alemanha e Índia ocupam o segundo lugar na publicação de artigos de pesquisa (7 artigos), seguidos por Itália, Canadá e Estados Unidos (4 artigos), e Países Baixos e Espanha (3 artigos). Alguns outros países também contribuíram para o trabalho de pesquisa, como Austrália, Bélgica, Dinamarca, Marrocos, Omã, Taiwan e Reino Unido (2 artigos), e Áustria, Colômbia, Egito, Hong Kong, Hungria, Indonésia, Malásia, Nova Zelândia, Portugal, Eslovênia, Suécia, Turquia e Vietnã (1 artigo cada). A Figura 15 - Artigos de revista por país de origem ilustra os países e o número de artigos publicados pelos respectivos países.

Figura 15 - Artigos de revista por país de origem.




Fonte: Elaborado pelo Autor (2023).

4.1.3 Análise de Artigos de Revista por Ano

A abordagem de Aprendizado de Máquina é um conceito relativamente novo no setor de cadeia de suprimentos. A adoção de técnicas de ML oferece vantagens adicionais no campo da manufatura. O conceito de manufatura inteligente usando conceitos de aprendizado de máquina começou a avançar a partir de 2015. Houve um aumento na área de interesse a partir de 2015 (2 artigos), seguido por uma ligeira queda em 2016 (1 artigo) e, em seguida, um aumento novamente nos artigos de pesquisa a partir de 2017 e 2018 (3 artigos). O interesse e o avanço na área de aprendizado de máquina impulsionam a pesquisa nessa área, o que se reflete em um

aumento nas publicações a partir de 2019 (11 artigos), 2020 (14 artigos) e 2021 (29 artigos). A Figura 16 - Artigos de periódicos por ano mostra o ano e o número de artigos de revista publicados nos respectivos anos.

Figura 16 - Artigos de periódicos por ano



Fonte: Elaborado pelo Autor (2023).

No ano de 2021, observamos um pico significativo nas publicações relacionadas ao aprendizado de máquina no gerenciamento da cadeia de suprimentos. O reconhecimento crescente do potencial do aprendizado de máquina em aprimorar as operações e a tomada de decisões na cadeia de suprimentos foi um dos principais impulsionadores desse crescimento. Os algoritmos de aprendizado de máquina, ao analisar e prever grandes volumes de dados, demonstraram eficiência na otimização da cadeia de suprimentos.

Diversas aplicações bem-sucedidas do aprendizado de máquina na gestão da cadeia de suprimentos foram evidenciadas, abrangendo desde a previsão de demanda até a gestão de riscos financeiros e a resiliência da cadeia de suprimentos. Essas aplicações ressaltaram a eficácia do aprendizado de máquina em lidar com os desafios complexos inerentes à cadeia de suprimentos.

A pandemia de COVID-19 em 2020 intensificou a necessidade de cadeias de suprimentos resilientes e ágeis, promovendo uma mudança de foco significativa para a pesquisa em aprendizado de máquina na gestão da cadeia de suprimentos. Os algoritmos de aprendizado de máquina mostraram-se valiosos na detecção de riscos

emergentes, na manutenção de relatórios relevantes e na implementação de ações adequadas para a reformulação da cadeia de suprimentos.

Além disso, a disponibilidade de grandes volumes de dados e os avanços na capacidade computacional facilitaram a aplicação do aprendizado de máquina na gestão da cadeia de suprimentos, proporcionando uma base sólida para o aumento das pesquisas nessa área. Contudo, em contraste, observou-se uma súbita diminuição no número de publicações sobre aprendizado aplicado em gerenciamento de cadeia de suprimentos em 2022.

Diversos fatores contribuíram para essa queda. O impacto da pandemia de COVID-19 interrompeu atividades de pesquisa e acadêmicas, como coleta de dados e colaboração, desviando o foco da pesquisa para enfrentar desafios imediatos apresentados pela situação de emergência. Além disso, a evolução contínua do campo de gerenciamento de cadeia de suprimentos redirecionou os interesses de pesquisa para tópicos emergentes ou áreas de foco, resultando em uma diminuição nas publicações sobre aprendizado aplicado.

A disponibilidade de financiamento e recursos também desempenhou um papel crucial na diminuição do número de publicações em 2022. Mudanças nas prioridades de financiamento podem ter levado a uma diminuição nos projetos de pesquisa e publicações em determinados domínios, incluindo aprendizado aplicado em gerenciamento de cadeia de suprimentos. Portanto, essas flutuações observadas em 2022 podem ser atribuídas a uma combinação de fatores externos, incluindo a pandemia, mudanças nos interesses de pesquisa e disponibilidade de recursos, que afetaram a trajetória das publicações nessa área específica.

É importante observar que a diminuição de publicações em um ano específico não necessariamente indica uma diminuição na importância ou relevância do aprendizado aplicado em gerenciamento de cadeia de suprimentos. As tendências de pesquisa podem flutuar ao longo do tempo, e é possível que o número de publicações aumente novamente nos anos subsequentes à medida que surgirem novas oportunidades de pesquisa e avanços.

4.1.4 Análise de Artigos de Revista com Base no Número de Publicações

Esta seção contribui para a distribuição de 74 artigos de revista de acordo com a revista e o número de artigos publicados por essas revistas. A Tabela 2 - Artigos de revista com base no número de publicações. mostra os diferentes nomes de revistas, juntamente com suas abreviações e o número de publicações de cada revista. Um total de 52 revistas diferentes contribuíram para a publicação dos 74 artigos de pesquisa. A revista "International Journal of Production Research" publicou a maioria, com 10 artigos. As contribuições também vêm das áreas de ciências aplicadas (4 artigos), computação, engenharia industrial e problemas matemáticos em engenharia (3 artigos).

Tabela 2 - Artigos de revista com base no número de publicações.

Nome do Periódico	Abreviatura	N.º de publicações
European Journal of Operational Research	EJOR	1
Academic Journal of Manufacturing Engineering	AJME	1
Applied Mathematics and Information Sciences	AMIS	1
Applied Sciences	AS	4
Arabian Journal of Geosciences	AJG	1
Automation in Construction	AC	1
Benchmarking: An International Journal	BAIJ	2
Computers and Industrial Engineering	CIE	3
Data Technologies and Applications	DTA	1
Decision Sciences	DS	1
Decision Support Systems	DSS	2
Energies	Energies	1

Engineering Applications of Artificial Intelligence	EAAI	1
European Journal of Operational Research	EJOR	2
Future Generation Computer Systems	FGCS	1
Institute of Industrial and Systems Engineers Transactions	IISE	1
IEEE Access	IEEE	2
Industrial Management and Data Systems	IMDS	1
INFORMS Journal on Applied Analytics	IJAA	1
International Journal of Electrical and Computer Engineering	IJECE	1
International Journal of Industrial Engineering	IJIE	1
International Journal of Physical Distribution and Logistics Management	IJPDLM	1
International Journal of Information Management	IJME	1
International Journal of Integrated Engineering	IJIE	1
International Journal of Machine Learning and Cybernetics	IJMLC	1
International Journal of Production Economics	IJPE	1
International Journal of Production Research	IJPR	10
International Journal of Recent Technology and Engineering	IJRTE	1
International Journal of Simulation: Systems, Science and Technology	IJSSST	1
Inventions	INVENTIONS	1
Journal of Big Data	JBD	1
Journal of Cleaner Production	JCP	1
Journal of Communications Software and Systems	JCSS	1


Journal of Computing and Information Science in Engineering	JCISE	1
Journal of Engineering Science and Technology Review	JESTR	1
Journal of Enterprise Information Management	JEIM	1
Journal of Intelligent and Fuzzy Systems	JIFS	2
Journal of Intelligent Manufacturing	JIM	1
Journal of Organizational and End User Computing	JOEUC	1
Journal of the Royal Society of New Zealand	JRSNZ	1
Mathematical Problems in Engineering	MPE	3
Mechanical Systems and Signal Processing	MSSP	1
Naval Research Logistics	NRL	1
Neural Computing and Applications	NCA	1
Operations and Supply Chain Management: An International Journal	OSCM	1
Procedia Manufacturing	PM	1
Proceedings of the Institution of Civil Engineers: Municipal Engineer	PICE	1
Processes	PROCESSES	1
Procedia Computer Science	PCS	1
Production Planning and Control	PPC	1
Recent Patents on Computer Science	RPCS	1
TQM Journal	TQM	1
Total de artigos:		74

Fonte: Elaborado pelo Autor (2023).

4.2 ESTUDOS REALIZADOS SOBRE ML NA CADEIA DE SUPRIMENTOS DE MANUFATURA E SUAS CATEGORIAS

A presente pesquisa de revisão da literatura se concentra nas aplicações de técnicas de Aprendizado de Máquina na área de Cadeia de Suprimentos (CS) de manufatura. Esta abordagem visa proporcionar uma compreensão abrangente do papel do AM no setor da indústria manufatureira, bem como identificar as tendências atuais e o crescente interesse por essa tecnologia no contexto da manufatura. Após uma análise cuidadosa, foram selecionados 74 artigos para análise mais detalhada. Esses artigos foram posteriormente distribuídos em três categorias principais, a saber: (1) Estudo Teórico (31 artigos), (2) Modelagem Matemática e Estudo de Simulação (16 artigos) e (3) Implementação (29 artigos). Uma análise completa dessa categorização pode ser observada na Figura 17 - Categorização estruturada de aprendizado de máquina na manufatura

Figura 17 - Categorização estruturada de aprendizado de máquina na manufatura



Fonte: Elaborado pelo Autor (2023).

4.2.1 Estudo Teórico

A seção destinada ao Estudo Teórico na revisão de literatura dos 74 artigos selecionados foi subdividida em três subcategorias, nomeadamente a Revisão de

Literatura, a Estrutura Teórica e o Quadro Conceitual. A Tabela 3 apresenta os artigos de revistas que tratam do Estudo Teórico.

Aamer et al. (2020) concentrou-se na aplicação de técnicas de ML para previsão precisa de demanda e sua contribuição para o aprimoramento da eficiência na cadeia de suprimentos. A cadeia de suprimentos baseada em dados desempenha um papel crucial na otimização dos processos tradicionais da cadeia de suprimentos. Outros estudos, como Akbari e Do (2021), Al-Sahaf et al. (2019) e Ameri Sianaki et al. (2019), se dedicaram a investigar o estado atual do uso de técnicas de AM na logística e cadeia de suprimentos, com foco em possíveis pesquisas futuras nessa área. A automação, digitalização, Internet das Coisas e big data têm se mostrado elementos-chave para ajudar as organizações a enfrentar os desafios da nova era da manufatura. A digitalização na cadeia de suprimentos auxilia no atendimento às flutuações na demanda dos clientes, fornecendo produtos no momento adequado e na quantidade correta (BORODAVKO; ILLÉS; BÁNYAI, 2021).

Tabela 3 - Breve análise de artigos sobre estudos teóricos

Autor	Ano	País	Tipo de artigo	Áreas de Aplicação (Domínio de Manufatura)
Chen et al.	2023	Dinamarca	Revisão de literatura	Manufatura
Agrawal et al.	2023	Índia	Revisão de literatura	Agricultura, transportes e indústria automóvel
Perano et al.	2023	Itália	Revisão de literatura	Supply Chain Management
Bai et al.	2023	China	Revisão de literatura	Indústria Automobilística
LI et al.	2023	China	Revisão de literatura	Operações de Supply Chain Management
Ivanov et al.	2023	Alemanha	Revisão de literatura	Supply Chain Management
De Simone et al.	2023	Itália	Revisão de literatura	Manufatura
Panzer e Bender.	2022	Alemanha	Revisão de literatura	Manufatura
Raza et al.	2023	Omã	Revisão de literatura	Supply Chain Management
Rolf et al.	2022	Alemanha	Revisão de literatura	Supply Chain Management

Zizic et al.	2022	Reino Unido	Revisão de literatura	Supply Chain Management
Aamer et al.	2021	Indonésia	Revisão de literatura	Setor Industrial e Setor Agropecuário
Akbari e Do.	2021	Vietnã	Revisão de literatura	Logística do Supply Chain Management
Borodavko et al.	2021	Hungria	Revisão de literatura	Indústria Automobilística
Boute et al.	2021	Bélgica	Revisão de literatura	Controle de Estoque
Ni et al.	2020	China	Revisão de literatura	Manufatura
Qi et al.	2020	Estados Unidos	Revisão de literatura	Pesquisa Operacional
Al-Sahaf et al.	2019	New Zealand	Revisão de literatura	Manufatura
Gupta e Saxena.	2019	Índia	Revisão de literatura	Gestão Operacional e Financeira
Rai et al.	2021	Índia	Revisão de literatura	Manufatura
Ameri Sianaki et al.	2019	Austrália	Revisão de literatura	Cidades inteligentes, saúde e transporte

Fonte: Elaborado pelo Autor (2023).

Adicionalmente, técnicas de aprendizado de máquina têm se destacado na resolução de problemas complexos de tomada de decisão sequencial, superando métodos analíticos e numéricos convencionais (BOUTE et al., 2022). Ni, Xiao e Lim (2020) conduziram uma revisão sistemática da adoção de técnicas de AM na cadeia de suprimentos, demonstrando que essa adoção está em desenvolvimento para aprimorar a cadeia de suprimentos tradicional. A utilização de abordagens orientadas por dados representa um marco significativo para o campo da pesquisa operacional, que historicamente focava apenas no desenvolvimento de propriedades estruturadas e na minimização do espaço de busca na otimização (QI; MAK; SHEN, 2020). Gupta e Saxena (2019) exploraram o impacto do chamado "efeito chicote" por meio de simulação e modelos matemáticos, utilizando abordagens de aprendizado de máquina.

Bodendorf, Merkl e Franke (2021) investigaram o papel do ML na CS, concentrando-se na estimativa de custos inovadores. O autor conduziu uma revisão minuciosa das técnicas de estimativa de custos inteligentes na indústria

manufatureira. Ivanov et al. (2021) analisaram as pesquisas mais recentes em relação à Indústria 4.0, sobretudo do ponto de vista dos pesquisadores. Nesse contexto, o autor desenvolveu um quadro conceitual que descreve o estágio atual e as futuras oportunidades da Indústria 4.0 para pesquisadores em gestão de operações. Ma, Li, Thorstenson (2021) propuseram um quadro conceitual para análise de causas raiz orientada por big data, empregando técnicas de AM, com o objetivo de aprimorar a qualidade do produto. A crescente geração de grandes volumes de dados tem impactado negativamente a eficiência e eficácia da cadeia de suprimentos. A inovação promovida pela Indústria 4.0 tem inspirado a implementação de tecnologias inteligentes no setor de manufatura, visando aprimorar a eficiência do sistema de produção. Técnicas de AM têm se destacado por sua capacidade de lidar com grandes volumes de dados gerados e identificar padrões nos dados coletados (RAI et al., 2021). A aplicação de técnicas de AM tem sido eficaz na identificação de riscos na cadeia de suprimentos e na estimativa das flutuações na demanda por parte dos clientes (TIRKOLAEI et al., 2021). Wang et al. (2021) desenvolveram uma ferramenta de mineração de dados para informações de construção em escala regional, com o intuito de gerenciar riscos relacionados a desastres naturais, fazendo uso de técnicas de ML. A seleção de fornecedores resilientes é um critério fundamental na manufatura digital para o gerenciamento da demanda dinâmica dos clientes e a previsão de probabilidades de interrupção (CAVALCANTE et al., 2019). Fu e Chien (2019) desenvolveram um quadro de análise orientado por dados, combinando técnicas de ML e mecanismos de agregação temporal, com o propósito de prever as flutuações na demanda por componentes eletrônicos.

Priore et al. (2019) desenvolveram um framework dinâmico baseado em algoritmo de aprendizado indutivo para propor a política de reposição mais apropriada em resposta às mudanças ambientais. Bandaru et al. (2015) propuseram um framework de inovização¹ automatizada usando programação genética no contexto de inovização em níveis superiores.

¹ O termo "inovização" é uma combinação das palavras "innovation" (inovação) e "optimization" (otimização). Refere-se a um processo no qual se busca otimizar ou aprimorar a inovação em um determinado contexto, geralmente usando métodos ou técnicas avançadas. O objetivo do processo de inovização é encontrar soluções inovadoras e eficazes para problemas ou desafios específicos, frequentemente envolvendo a aplicação de abordagens criativas e tecnológicas para atingir resultados melhores.

4.2.2 Modelagem Matemática e Simulação

A seção de Modelagem Matemática e Simulação é subdividida em três partes: pesquisa gerencial (4 artigos), modelagem matemática (2 artigos) e simulação (10 artigos). A Tabela 4 fornece uma breve análise dos artigos relacionados à modelagem matemática e simulação.

Tabela 4 - Análise breve de artigos sobre modelagem matemática e simulação

Autor	Ano	País	Tipo de artigo	Áreas de Aplicação (Domínio de Manufatura)
Belhadi et al.	2021	Marrocos	Levantamento Gerencial	Estoque e Ware house
Gonçalves et al.	2021	Portugal	Simulação	Indústria Automobilística
Han e Zhang.	2021	China	Simulação	Empresa de Produção de Alimentos
Li, Z.	2021	China	Simulação	Busca na Web para o Consumidor
Raza S.	2022	Omã	Levantamento Gerencial	Logística e Gerenciamento de Estoque
Sardar et al.	2021	Coreia do Sul	Modelagem Matemática	Indústria Automobilística
Wang e Yang.	2021	China	Simulação	Lojas Online
Xuan, F.	2021	China	Levantamento Gerencial	Gerenciamento de Risco Financeiro para PMEs
Delgoshaei et al.	2020	Canadá	Simulação	Manufatura
Islam e Amin.	2020	Canadá	Simulação	Manufatura
Rahim et al.	2020	Malásia	Simulação	Indústria Automobilística (Aeronaves)
Wu et al.	2020	China	Simulação	Processo de Seleção de Parceiros
Yadav et al.	2020	Índia	Levantamento Gerencial	Manufatura
Ji et al.	2019	China	Simulação	Gerenciamento da Cadeia de Suprimentos e Logística
Simchi-Levi e Wu.	2018	Estados Unidos	Modelagem Matemática	Otimização de Processos de Negócios"
Hogenboom et al.	2015	Países Baixos	Simulação	Gerenciamento Econômico

Fonte: Elaborado pelo Autor (2023).

Belhadi et al. (2021) propuseram uma técnica com base em tomada de decisão multicritério (MCDM) e algoritmos baseados em inteligência artificial para avaliar os padrões desenvolvidos pela Cadeia de Suprimentos de Reação. Raza (2022) discutiu

técnicas de gestão da qualidade orientadas por dados para aprimorar o desempenho da cadeia de suprimentos. Xuan (2021) construiu um modelo de avaliação do índice de risco usando uma abordagem de aprendizado de máquina para melhorar os serviços financeiros da cadeia de suprimentos. Yadav, Shankar, Singh e (2020) estudaram o impacto da Indústria 4.0/Tecnologias de Informação e Comunicação (TICs), Lean Six Sigma e sistemas de gestão da qualidade no desempenho organizacional. A cadeia de suprimentos depende de dois principais fatores: o fabricante e o fornecedor. O fornecedor pode não fornecer informações precisas sobre a demanda ao fabricante. A técnica de Identificação por Radiofrequência (RFID) ajuda a reduzir as situações de excesso de estoque e falta de estoque, rastreando o movimento dos produtos (SARDAR; SARKAR; KIM, 2021). Simchi-Levi e Wu (2018) estudaram o papel da digitalização por meio de análise e automação para melhorar a gestão no varejo.

Atualmente, as lojas online estão crescendo rapidamente, pois proporcionam grande conveniência aos clientes. Wang e Yang (2021), Ji et al. (2019) e LI (2021) determinaram e desenvolveram um modelo de previsão de vendas e marketing de precisão em lojas online de produtos. Gonçalves et al. (2021) propuseram uma abordagem multivariada para previsão superior e desempenho de estoque em comparação com referências tradicionais univariadas. Han e Zhang (2021) desenvolveram um modelo de gestão de riscos com base em abordagens de ML e redes neurais para melhorar a eficiência da cadeia de suprimentos. Delgoshaei et al. (2021) desenvolveram um método de programação inteira multi-período para o agendamento de uma cadeia de suprimentos ao longo de um horizonte de tempo. A previsão da demanda do cliente é afetada devido a dados incorretos. Islam e Amin (2020) propuseram um modelo para prever o provável backlog na cadeia de suprimentos usando técnicas de ML. Abdol Rahim et al. (2020) determinaram um modelo para minimização de custos de componentes críticos de aeronaves para planejamento e requisitos de manutenção. Wu et al. (2020) propuseram um modelo de classificação multi-parceiro para selecionar os parceiros potenciais para lidar eficazmente com o processo de avaliação de parceiros. Ji et al. (2019) propuseram um modelo de previsão para melhorar a experiência de serviço logístico dos clientes e otimizar o modelo de estoque. Hogenboom et al. (2015) determinaram uma abordagem por meio de algoritmos de ML para a fixação de preços táticos adaptativos

em mercados de cadeia de suprimentos de vários agentes usando regimes econômicos.

4.2.3 Implementação

A seção de Implementação é subdividida em duas partes: estudo de caso e protótipo. Essa parte abrange artigos de revistas que estudaram estudos de caso e implementaram técnicas de Aprendizado de Máquina para criar protótipos. A Tabela 5 apresenta uma análise breve dos artigos sobre implementação.

Tabela 5 - Análise breve de artigos sobre implementação

Autor	Ano	País	Tipo de Artigo	Áreas de Aplicação (domínio de manufatura)
Benhamida et al.	2021	Espanha	Estudo de Caso	Compra de Estoque e Produtos em Lojas Online
Bousqaoui et al.	2021	Marrocos	Estudo de Caso	Estudo de Caso de um Supermercado em Marrocos
García-Barrios et al.	2021	Colômbia	Protótipo	Compra de Produtos por Impulso
Liu et al.	2021	China	Estudo de Caso	Indústria Automobilística
Luo, Y.	2021	China	Estudo de Caso	Indústria do Carvão
Melançon et al.	2021	Canadá	Estudo de Caso	Indústria Automobilística (Indústria de Pneus)
Ramakurthi et al.	2021	Índia	Protótipo	Indústria Automobilística (Indústria de Engrenagens)
Rožanec et al.	2021	Eslovênia	Protótipo	Indústria Automobilística
Schneckenreither et al.	2021	Áustria	Protótipo	Manufatura
Seo et al.	2021	Coreia do Sul	Estudo de Caso	Indústria Automobilística
Van Belle et al.	2021	Bélgica	Estudo de Caso	Manufatura
Abolghasemi et al.	2020	Austrália	Estudo de Caso	Manufatura
González et al.	2020	Espanha	Estudo de Caso	Setor Industrial (Lavanderia)
Leung et al.	2020	Hong Kong	Estudo de Caso	Logística e Gerenciamento da Cadeia de Suprimentos
Liu et al.	2020	Estados Unidos	Protótipo	Indústria Automobilística
Van Steenberghe e Mes.	2020	Países Baixos	Estudo de Caso	Manufatura

Yan et al.	2020	Canadá	Protótipo	Setor Logístico
Zhang et al.	2020	China	Protótipo	Indústria Automobilística
Alfian et al.	2019	Coreia do Sul	Protótipo	Gerenciamento de Estoque em Armazéns
Banjanagari e Vijay Kumar	2019	Índia	Protótipo	Manufatura
Baryannis et al.	2019	Alemanha	Estudo de Caso	Logística e Gerenciamento da Cadeia de Suprimentos
Lolli et al.	2019	Itália	Protótipo	Indústria Automobilística (Peças de Reposição)
Parada et al.	2018	Espanha	Protótipo	Gerenciamento Logístico
Sam Sekhar e Chalapathl.	2018	Índia	Protótipo	Planejamento de Recursos Empresariais
Aleem et al.	2017	Egito	Estudo de Caso	Gerenciamento de Inventário
Lolli et al.	2017	Itália s	Estudo de Caso	Gerenciamento de Inventário
Demey e Wolff.	2016	Países Baixo	Estudo de Caso	Gerenciamento de Inventário
Lu e Kao.	2016	Taiwan	Estudo de Caso	Setor Eletrônico

Fonte: Elaborado pelo Autor (2023).

García-Barrios et al. (2021) propuseram um método para agrupar e clusterizar produtos de compra por impulso a fim de aplicar políticas de estoque eficientes. Os sistemas tradicionais de manufatura têm passado por mudanças devido às inovações tecnológicas. Ramakurthl et al. (2021) se concentraram em um estudo de caso na indústria automobilística com o objetivo de otimizar o planejamento de processos e funções de agendamento usando técnicas de ML. Rožanec et al. (2021) avaliaram critérios de desempenho de modelos de previsão de demanda com base em dados de demanda passada. Schneckenreither, Haeussler e Gerhold (2021) implementou um modelo preditivo para planejamento de liberação de pedidos usando abordagens de ML. O gerenciamento de energia de veículos híbridos melhora a economia de combustível. Liu et al. (2021) derivaram um modelo de previsão de curto prazo, adotando previsões estocásticas e ML. Alfian et al. (2019) propuseram um algoritmo de ML para detectar dados falsos capturados por Identificação por Radiofrequência. Lolli et al. (2019) desenvolveram um modelo de classificação de estoque multicritério aplicado à demanda intermitente por meio de algoritmo de ML. Parada, Melià-Seguí, Pous (2018) determinaram um método para detecção de anomalias usando gerenciamento de informações baseado em RFID, utilizando técnicas de IoT. Sam Sekhar e Chalapathl (2019) projetaram um modelo de previsão baseado em pré-processamento para melhorar a precisão da previsão em conjuntos de dados de cadeia de suprimentos. No setor automobilístico, a gestão de peças sobressalentes

tem um impacto significativo nos negócios como um todo. Zhang et al. (2020) projetaram um modelo para a avaliação precisa de peças sobressalentes com base em algoritmos de agrupamento e redes neurais de retropropagação. Banjanagari e Vijay Kumar (2019) demonstraram um modelo de previsão de vendas para uma grande rede de varejo usando técnicas de ML.

Benhamida et al. (2021) e Van Steenberghe e Mes (2020) propuseram um modelo com base em métodos híbridos, CombTSB para demanda intermitente e abordagem baseada em agrupamento para previsão de demanda de novos produtos. Bousqaoui, Slimani e Achchab (2021) descreveram uma análise comparativa para a previsão de demanda de produtos de período limitado usando a média móvel autorregressiva integrada (ARIMA) e aprendizado profundo. Luo (2021) desenvolveu modelos de controle de custos ambientais e testes práticos usando computação em nuvem e técnicas de ML. Nas cadeias de suprimentos avançadas, às vezes não é possível atingir as metas estabelecidas. Técnicas de ML preveem falhas no nível de serviço com antecedência de algumas semanas e alertam os planejadores, como demonstrado por Melançon et al. (2021). Seo et al. (2021) estabeleceram estratégias apropriadas de reposicionamento com base em previsões precisas de demanda por bicicletas. Van Belle, Gun e Verbeke (2021) investigaram diferentes abordagens de ML e métodos de previsão para prever a demanda de atacadistas usando dados de venda. Abolghasemi et al. (2020) implementaram um modelo que lida com eventos sistemáticos usando técnicas de previsão estatística e de ML. Leung et al. (2020) descreveram uma metodologia preditiva para prever a chegada de pedidos de comércio eletrônico em tempo quase real usando técnicas de ML. Baryannis, Dani e Antoniou (2019) propuseram um framework de previsão de riscos na cadeia de suprimentos, usando técnicas de IA baseadas em dados para antecipar atrasos nas entregas em cadeias de suprimentos de manufatura de vários níveis do mundo real. Aleem et al. (2017) implementaram sistemas fuzzy e adaptativos de redes neurais fuzzy na otimização do problema de estoque de produção. Demey e Wolff (2016) determinaram uma estratégia de busca baseada em modelos para o sistema de gerenciamento de estoque. Algoritmos de ML fornecem bons resultados na classificação multicritério de estoque em classes baseadas em classificadores supervisionados, conforme demonstrado por Lolli et al. (2017). Lu e Kao (2016) determinaram um esquema de previsão de vendas baseado em agrupamento usando

máquina de aprendizado extremo e métodos de agrupamento de ligação. Yan, Choudhury e Wei (2020) desenvolveram um algoritmo de prevenção de colisões centralizado usando técnicas de ML para aumentar a eficiência da carga computacional do servidor central.

4.2.4 Análise concisa do conteúdo

Foram selecionados 74 artigos para este estudo. Nesta pesquisa, uma análise detalhada desses 74 artigos é realizada. A análise detalhada dos 74 artigos é feita classificando-os em estudo teórico, estudo de modelagem matemática e simulação e implementação. A pesquisa mostra que a maior parte do trabalho é realizada no estudo teórico e na implementação, contribuindo com 42% e 39%, respectivamente. Comparado a esses dois, o trabalho realizado na modelagem matemática e simulação é de 22%. Os artigos são novamente subdivididos em categorias para uma melhor clareza e compreensão.

A categoria de estudo teórico é subdividida em revisão de literatura, papel teórico e estrutura conceitual. A contribuição dos artigos de revisão de literatura é de 28%, os artigos teóricos contribuem com 1% e a estrutura conceitual contribui com 12% do trabalho realizado nessa área.

A categoria de estudo de modelagem matemática e simulação é subdividida em pesquisa gerencial, modelagem matemática e simulação. A pesquisa gerencial contribui com 5%, a modelagem matemática contribui com 3% e a simulação contribui com 14% do trabalho realizado na categoria de modelagem matemática e simulação.

A categoria de implementação é dividida em protótipo e estudo de caso. O protótipo contribui com 18% e o estudo de caso contribui com 22% da implementação.

4.3 TENDÊNCIAS FUTURAS DO ML NA CADEIA DE SUPRIMENTOS DE MANUFATURA

As tendências futuras de aprendizado de máquina na cadeia de suprimentos de manufatura estão posicionadas para revolucionar a indústria, aprimorando eficiência e eficácia. À medida que o setor de manufatura continua a evoluir, o influxo de volumes massivos de dados tornou-se um desafio para as técnicas tradicionais lidarem. É aqui que os algoritmos de ML desempenham um papel significativo no processo de tomada de decisão empresarial ao prever com precisão a demanda do cliente e escassez de materiais. A adoção de técnicas de ML no setor de manufatura espera-se que tenha um impacto positivo, especialmente no contexto da Indústria 4.0, onde beneficia a gestão da cadeia de suprimentos e inventário, rastreando dados históricos, identificando padrões e prevendo com precisão a escassez de materiais e a demanda do cliente (ISLAM; AMIN, 2020).

Além disso, a integração de algoritmos de aprendizado de máquina para a evolução da rede de cadeia de suprimentos foi proposta, enfatizando os mecanismos de entrada, saída e cooperação de fabricantes (LI et al., 2022). Adicionalmente, a adoção de algoritmos de ML pode analisar e prever big data, melhorando assim a eficiência da cadeia de suprimentos (RAN, 2021).

O impacto do ML na cadeia de suprimentos de manufatura não se limita à gestão de inventário e previsão de demanda. Ele se estende à gestão de riscos na cadeia de suprimentos, onde modelos de ML tornaram-se uma consideração crítica (KUMAR; SHARMA, 2023). Além disso, o estudo da gestão do conhecimento e aprendizado organizacional no contexto das redes globais de manufatura propôs o efeito de moderação da educação ambiental, indicando a ampla influência do ML na indústria (KUMAR; SHARMA, 2023).

Em conclusão, as tendências futuras do ML na cadeia de suprimentos de manufatura são multifacetadas, abrangendo previsão de demanda, gestão de inventário, gestão de riscos na cadeia de suprimentos e gestão do conhecimento. A integração de algoritmos de ML espera-se que aprimore a eficiência e eficácia da cadeia de suprimentos, contribuindo para a revolução da manufatura inteligente.

4.4 DESAFIOS DA IMPLANTAÇÃO DE APRENDIZADO DE MÁQUINA NO SCM DA INDÚSTRIA MANUFATUREIRA.

A aprendizagem de máquina tem o potencial para lidar com vários desafios e impedimentos na indústria manufatureira e na gestão da cadeia de suprimentos. Ela oferece vantagens, como melhoria na tomada de decisões, otimização de processos e a capacidade de analisar conjuntos de dados grandes e complexos (WUEST et al., 2016). No entanto, existem vários desafios que impedem a ampla adoção da aprendizagem de máquina nesses domínios.

Um dos desafios é a interpretabilidade dos modelos de aprendizagem de máquina. Embora algoritmos de aprendizado de máquina possam fornecer previsões precisas, muitas vezes eles carecem de transparência, tornando difícil para os usuários entender o raciocínio por trás das previsões (BARYANNIS; DANI; ANTONIOU, 2019). Essa falta de interpretabilidade pode ser uma barreira para a adoção, especialmente em setores onde a tomada de decisões precisa ser explicável e auditável.

Outro desafio é a disponibilidade e qualidade dos dados. Algoritmos de aprendizado de máquina requerem grandes quantidades de dados de alta qualidade para treinar modelos precisos (ALMANEI et al., 2021). No entanto, na indústria manufatureira e na gestão da cadeia de suprimentos, os dados podem ser fragmentados, incompletos ou de baixa qualidade (ZHOU et al., 2020). Isso pode limitar a eficácia dos algoritmos de aprendizado de máquina e dificultar sua adoção.

Além disso, pode haver resistência à mudança e falta de conscientização ou compreensão da aprendizagem de máquina entre os profissionais da indústria (WUEST et al., 2016). A implementação da aprendizagem de máquina requer o apoio organizacional, investimento em infraestrutura e recursos, e o desenvolvimento de culturas orientadas por dados (GHAHRAMANI et al., 2020). Sem educação e conscientização adequadas, os benefícios potenciais da aprendizagem de máquina podem não ser totalmente realizados.

Além disso, podem surgir considerações regulatórias e éticas que precisam ser abordadas ao implementar a aprendizagem de máquina na indústria manufatureira e na gestão da cadeia de suprimentos. Por exemplo, preocupações com a privacidade

podem surgir ao lidar com dados sensíveis, e considerações éticas podem precisar ser levadas em conta ao tomar decisões com base em previsões de aprendizado de máquina (NAVED, 2022).

Para superar esses desafios, a colaboração entre pesquisadores, profissionais e profissionais da indústria é crucial. Os esforços de pesquisa devem se concentrar no desenvolvimento de modelos de aprendizado de máquina interpretáveis que possam fornecer explicações transparentes para suas previsões (BARYANNIS; DANI; ANTONIOU, 2019). Além disso, esforços devem ser feitos para melhorar a qualidade e a disponibilidade de dados, como a implementação de estruturas de governança de dados e iniciativas de compartilhamento de dados (ZHOU et al., 2020). Programas de educação e treinamento podem ajudar a aumentar a conscientização e o entendimento da aprendizagem de máquina entre os profissionais da indústria, permitindo que tomem decisões informadas sobre sua adoção (WUEST et al., 2016). Finalmente, devem ser desenvolvidos quadros regulatórios e diretrizes éticas para garantir o uso responsável e ético da aprendizagem de máquina na indústria manufatureira e na gestão da cadeia de suprimentos (NAVED, 2022).

Em conclusão, embora a aprendizagem de máquina ofereça um potencial significativo para lidar com desafios na indústria manufatureira e na gestão da cadeia de suprimentos, existem vários obstáculos que precisam ser superados. Esses incluem a interpretabilidade dos modelos de aprendizagem de máquina, a disponibilidade e qualidade dos dados, a resistência à mudança e considerações regulatórias e éticas. Ao abordar esses desafios por meio da colaboração, pesquisa, educação e desenvolvimento de quadros regulatórios, a adoção da aprendizagem de máquina nesses domínios pode ser facilitada.

5 CONCLUSÃO

Este estudo oferece uma análise abrangente sobre a aplicação do Aprendizado de Máquina na indústria manufatureira e na Gestão da Cadeia de Suprimentos. As questões de pesquisa relacionadas a este campo foram minuciosamente abordadas, proporcionando uma base sólida para pesquisas futuras e avaliações. Nas últimas duas décadas, temos testemunhado um crescimento exponencial da tecnologia em todos os setores. A ascensão da Indústria 4.0 e o advento da IoT deram início a uma nova era de manufatura inteligente.

No contexto da cadeia de suprimentos de fabricação, encontramos uma rede complexa de atividades, que inclui aquisições, planejamento de produção, gerenciamento de estoque, logística e distribuição. A execução eficaz desses processos gera volumes massivos de dados, tornando desafiador para os profissionais extrair insights valiosos e tomar decisões em tempo real. É nesse cenário que o Aprendizado de Máquina assume um papel fundamental. O volume de dados continua a crescer diariamente, exigindo tecnologias inteligentes e rápidas para gerenciá-lo. As abordagens tradicionais não conseguem mais lidar com esse aumento na quantidade de dados. Nesse sentido, a IoT e as técnicas de ML se destacam, permitindo o gerenciamento e a extração de padrões desses dados, contribuindo para a previsão da demanda do cliente, um elemento vital na gestão da cadeia de suprimentos e no gerenciamento de estoques.

Este estudo realizou uma revisão sistemática da literatura sobre a adoção de técnicas de ML na cadeia de suprimentos de fabricação. A análise recente demonstra que a pesquisa está avançando em direção a tecnologias inteligentes, incluindo IoT, ML e computação em nuvem no setor de manufatura. O objetivo deste estudo foi apresentar um panorama atual das técnicas de ML no setor de manufatura. O método de pesquisa adotado tem o potencial de orientar pesquisadores, profissionais do setor de manufatura e gerentes de organizações.

As questões de pesquisa foram abordadas de forma abrangente:

QP1: Quais são as contribuições de várias fontes para o uso de ML na cadeia de suprimentos de fabricação? Os artigos de pesquisa foram analisados sob quatro diferentes perspectivas: (1) Análise com base no tipo de artigo de pesquisa, (2) Análise

por país dos artigos de pesquisa, (3) Análise por ano dos artigos de pesquisa e (4) Análise de artigos de revista com base no número de publicações.

QP2: Quais são os diversos estudos conduzidos sobre ML na cadeia de suprimentos de fabricação e suas categorias? Esta questão foi respondida por meio de uma análise detalhada dos artigos de pesquisa, que foram categorizados em estudos teóricos, modelagem matemática e simulações, e implementações. Cada uma dessas categorias foi subdividida para permitir uma exploração aprofundada dos artigos de pesquisa relacionados.

QP3: Quais são as tendências futuras do ML na cadeia de suprimentos de fabricação? Na era da Indústria 4.0, o ML proporciona uma vantagem competitiva à cadeia de suprimentos. As técnicas de ML facilitam a análise de grandes volumes de dados e a previsão dinâmica da demanda de produtos, melhorando a eficiência da cadeia de suprimentos.

É importante destacar que, embora a Aprendizagem de Máquina ofereça um imenso potencial na indústria manufatureira e na gestão da cadeia de suprimentos, sua implementação não está isenta de desafios. Questões relacionadas à interpretabilidade dos modelos, a disponibilidade e qualidade dos dados, resistência à mudança e preocupações regulatórias e éticas surgem como obstáculos significativos. No entanto, superar esses desafios é fundamental para desbloquear os benefícios substanciais que a ML pode proporcionar. A colaboração entre diferentes partes interessadas e a adoção de estratégias para abordar essas barreiras são cruciais para a plena realização do potencial da Aprendizagem de Máquina na transformação desses setores.

Além disso, exploramos as publicações indexadas no SCOPUS, categorizando-as detalhadamente e oferecendo insights sobre tendências futuras de pesquisa, que servirão como um guia valioso para pesquisadores que buscam permanecer atualizados.

Identificamos que países como China, Índia, Estados Unidos, Itália e Alemanha têm liderado os esforços na adoção de técnicas de ML na manufatura. O desenvolvimento dessas técnicas tem contribuído para prever a demanda do cliente com antecedência, resultando em uma gestão eficaz da cadeia de suprimentos. Nossa

análise também identificou diversos métodos e algoritmos de ML que pesquisadores têm explorado na adoção dessas técnicas avançadas.

Observamos que, em um ambiente competitivo, a implementação de métodos de ML se tornou mais intensa. A análise preditiva na SCM se tornou mais acessível por meio dessas técnicas avançadas. Com base na revisão sistemática, registrou-se que a indústria automobilística enfrentou diversos desafios e tem avançado com determinação na adoção de métodos de ML.

Duas implicações podem ser aferidas ao final deste Trabalho de Conclusão de Curso:

- Implicações Teóricas:

O estudo apresentado neste trabalho destacou a situação atual do uso de técnicas de Aprendizado de Máquina no contexto da cadeia de suprimentos na indústria manufatureira. Com o avanço da tecnologia, a adoção de técnicas de ML tem implicações significativas para a pesquisa. As implicações da aplicação de ML abrangem várias disciplinas e são de grande utilidade tanto para a academia quanto para a prática, uma vez que beneficiam os sistemas de produção e manufatura. A pesquisa abordada neste estudo pode ser valiosa para pesquisadores e acadêmicos, pois auxilia na compreensão das metodologias avançadas de ML e suas capacidades. Além disso, os pesquisadores podem adquirir insights sobre a adoção de técnicas de ML, conferindo vantagens competitivas às operações de cadeia de suprimentos.

O presente estudo realizou uma Revisão Sistemática da Literatura com base em artigos de pesquisa classificados, com o objetivo de investigar os benefícios da adoção de técnicas de ML no contexto da cadeia de suprimentos na manufatura. O estudo atual contribui para a compreensão de pesquisadores, acadêmicos e profissionais da indústria sobre a adoção de técnicas de Aprendizado de Máquina na gestão da cadeia de suprimentos e no gerenciamento de estoques.

Além disso, o presente estudo contribui ao destacar as contribuições feitas por autores, instituições e países no campo de pesquisa relacionado. Além disso, essa pesquisa contribui para a expansão do conhecimento existente na literatura, fornecendo uma revisão sistemática da adoção de métodos de ML na gestão da cadeia de suprimentos na manufatura. O estudo atual também identifica os países que

realizaram um número significativo de pesquisas notáveis sobre a implementação de ML, o que pode ser valioso para a formulação de políticas por organizações governamentais.

- Implicações Gerenciais

O presente estudo se dedicou à análise da atual utilização de técnicas de Aprendizado de Máquina no contexto da indústria manufatureira e da gestão da cadeia de suprimentos. Tanto gestores de empresas quanto pesquisadores acadêmicos devem considerar com profundidade as principais conclusões deste estudo no que concerne à aplicação das técnicas de ML em diferentes níveis da cadeia de suprimentos de manufatura. É de crucial importância que a alta administração das organizações adquira uma compreensão aprofundada dos benefícios inerentes à adoção de técnicas de ML, incluindo a otimização dos processos de produção, a melhoria da qualidade dos produtos e a capacidade de antever as demandas dos clientes.

Na era contemporânea, a implementação de práticas relacionadas à Inteligência Artificial e Aprendizado de Máquina oferece vantagens competitivas notáveis e um vasto potencial de aplicação no cenário da manufatura. Este estudo lança luz sobre as nações que lideraram em pesquisas sobre a adoção de técnicas de ML na gestão da cadeia de suprimentos de manufatura, o que pode fornecer informações valiosas para a formulação de políticas governamentais. Esses insights orientam os formuladores de políticas públicas a adotar estratégias inovadoras e políticas direcionadas à implementação de métodos de ML, com o propósito de aprimorar a eficiência e o desempenho da cadeia de suprimentos.

Além disso, o estudo examinou a aplicação de técnicas de ML em diversos setores da manufatura. Os resultados desta pesquisa são relevantes para a compreensão das vantagens competitivas e o fomento do crescimento sustentável da cadeia de suprimentos. A adoção de técnicas de ML na indústria manufatureira oferece uma vantagem inovadora aos sistemas de produção, permitindo que permaneçam competitivos e capitalizem sobre as vantagens proporcionadas por essas técnicas avançadas.

REFERENCIAS

AAMER, A.; EKA YANI, L. P.; ALAN PRIYATNA, I. M. Data Analytics in the Supply Chain Management: Review of Machine Learning Applications in Demand Forecasting. **Operations and Supply Chain Management: An International Journal**, p. 1–13, 6 dez. 2020.

ABDOL RAHIM, F. H. et al. Cost Minimization of Aircraft Critical Components for Planning and Maintenance Requirements. **International Journal of Integrated Engineering**, v. 12, n. 7, 31 out. 2020.

ABOLGHASEMI, M. et al. Demand forecasting in the presence of systematic events: Cases in capturing sales promotions. **International Journal of Production Economics**, v. 230, p. 107892, dez. 2020.

AGGOUR, K. S. et al. Artificial intelligence/machine learning in manufacturing and inspection: A GE perspective. **MRS Bulletin**, v. 44, n. 7, p. 545–558, jul. 2019.

AGRAWAL, R. et al. A systematic and network-based analysis of data-driven quality management in supply chains and proposed future research directions. **The TQM Journal**, v. 35, n. 1, p. 73–101, 16 jan. 2023.

AIRES, R. W. D. A.; MOREIRA, F. K.; FREIRE, P. D. S. Indústria 4.0: desafios e tendências para a gestão do conhecimento. **Revista E-Tech: Tecnologias para Competitividade Industrial - ISSN - 1983-1838**, v. 11, n. 1, p. 67–87, 20 dez. 2018.

AKBARI, M.; DO, T. N. A. A systematic review of machine learning in logistics and supply chain management: current trends and future directions. **Benchmarking: An International Journal**, v. 28, n. 10, p. 2977–3005, 5 nov. 2021.

ALDERSON, W. **Marketing Behavior and Executive Action: A Functionalist Approach to Marketing Theory**. Illinois: Martino Publishing, 1957.

ALEEM, A. et al. Implementation of Fuzzy and Adaptive Neuro-Fuzzy Inference Systems in Optimization of Production Inventory Problem. **Applied Mathematics & Information Sciences**, v. 11, n. 1, p. 289–298, 1 jan. 2017.

ALFIAN, G. et al. False Positive RFID Detection Using Classification Models. **Applied Sciences**, v. 9, n. 6, p. 1154, 19 mar. 2019.

ALMANEI, M. et al. Machine Learning Algorithms Comparison for Manufacturing Applications. Em: SHAFIK, M.; CASE, K. (Eds.). **Advances in Transdisciplinary Engineering**. [s.l.] IOS Press, 2021.

AL-SAHAF, H. et al. A survey on evolutionary machine learning. **Journal of the Royal Society of New Zealand**, v. 49, n. 2, p. 205–228, 3 abr. 2019.

AMERI SIANAKI, O. et al. Machine Learning Applications: The Past and Current Research Trend in Diverse Industries. **Inventions**, v. 4, n. 1, p. 8, 3 fev. 2019.

AMRUTHNATH, N.; GUPTA, T. **A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance**. 2018 5th

International Conference on Industrial Engineering and Applications (ICIEA). **Anais...** Em: 2018 5TH INTERNATIONAL CONFERENCE ON INDUSTRIAL ENGINEERING AND APPLICATIONS (ICIEA). Singapore: IEEE, abr. 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8387124/>>. Acesso em: 10 nov. 2023

ASLAM, F. et al. Innovation in the Era of IoT and Industry 5.0: Absolute Innovation Management (AIM) Framework. **Information**, v. 11, n. 2, p. 124, 24 fev. 2020.

BAI, R. et al. Analytics and machine learning in vehicle routing research. **International Journal of Production Research**, v. 61, n. 1, p. 4–30, 2 jan. 2023.

BALLOU, R. H.; GILBERT, S. M.; MUKHERJEE, A. New Managerial Challenges from Supply Chain Opportunities. **Industrial Marketing Management**, v. 29, n. 1, p. 7–18, jan. 2000.

BANDARU, S. et al. Generalized higher-level automated innovization with application to inventory management. **European Journal of Operational Research**, v. 243, n. 2, p. 480–496, jun. 2015.

BANJANAGARI, A. R.; VIJAY KUMAR, B. Retail Giant Sales Forecasting using Machine Learning. **International Journal of Recent Technology and Engineering**, v. 8, n. 2S11, p. 2408–2411, 2 nov. 2019.

BAROCAS, S.; HARDT, M.; NARAYANAN, A. **Fairness and machine learning: limitations and opportunities**. Cambridge, Massachusetts: The MIT Press, 2023.

BARYANNIS, G.; DANI, S.; ANTONIOU, G. Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. **Future Generation Computer Systems**, v. 101, p. 993–1004, dez. 2019.

BEDBROOK, C. N. et al. Machine learning-guided channelrhodopsin engineering enables minimally invasive optogenetics. **Nature Methods**, v. 16, n. 11, p. 1176–1184, nov. 2019.

BELHADI, A. et al. Building supply-chain resilience: an artificial intelligence-based technique and decision-making framework. **International Journal of Production Research**, v. 60, n. 14, p. 4487–4507, jul. 2021.

BENHAMIDA, F. Z. et al. Demand Forecasting Tool For Inventory Control Smart Systems. **Journal of Communications Software and Systems**, v. 17, n. 2, p. 185–196, 2021.

BERTULUCCI, C. S. **Indústria 4.0: O que é, e como ela vai impactar o mundo**. blog. Disponível em: <<https://www.citisystems.com.br/industria-4-0/>>. Acesso em: 10 set. 2023.

BODENDORF, F.; MERKL, P.; FRANKE, J. Intelligent cost estimation by machine learning in supply management: A structured literature review. **Computers & Industrial Engineering**, v. 160, p. 107601, out. 2021.

BORODAVKO, B.; ILLÉS, B.; BÁNYAI, Á. Role of Artificial Intelligence in Supply Chain. **Academic Journal of Manufacturing Engineering**, v. 19, p. 75–79, 2021.

BOUSQAOU, H.; SLIMANI, I.; ACHCHAB, S. Comparative analysis of short-term demand predicting models using ARIMA and deep learning. **International Journal of Electrical and Computer Engineering (IJECE)**, v. 11, n. 4, p. 3319, 1 ago. 2021.

BOUTE, R. N. et al. Deep reinforcement learning for inventory control: A roadmap. **European Journal of Operational Research**, v. 298, n. 2, p. 401–412, abr. 2022.

BOWERSOX, D. J.; CLOSS, D. J. **Logistical management: the integrated supply chain process**. New York: McGraw-Hill Companies, 1996.

CARVALHO, T. P. et al. A systematic literature review of machine learning methods applied to predictive maintenance. **Computers & Industrial Engineering**, v. 137, p. 106024, nov. 2019.

CAVALCANTE, I. M. et al. A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. **International Journal of Information Management**, v. 49, p. 86–97, dez. 2019.

CHEN, T. et al. Machine Learning in Manufacturing towards Industry 4.0: From 'For Now' to 'Four-Know'. **Applied Sciences**, v. 13, n. 3, p. 1903, 1 fev. 2023.

COPELAND, M. **What's the Difference Between Artificial Intelligence, Machine Learning and Deep Learning?** blog. Disponível em: <<https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>>. Acesso em: 3 jun. 2023.

DA SILVA, E. L.; MENEZES, E. M. Metodologia da Pesquisa e Elaboração de Dissertação, 4ª edição revisada e atualizada. 2005.

DATHEIN, R. Inovação e Revoluções Industriais: uma apresentação das mudanças tecnológicas determinantes nos séculos XVIII e XIX. **DECON Textos Didáticos**, v. 2, p. 8, 2003.

DE SIMONE, V.; PASQUALE, V. D.; MIRANDA, S. An overview on the use of AI/ML in Manufacturing MSMEs: solved issues, limits, and challenges. **Procedia Computer Science**, v. 217, p. 1820–1829, 2023.

DELGOSHAEI, A. et al. A FUZZY LOGIC-BASED ALGORITHM FOR SUPPLY CHAIN MANAGEMENT CONSIDERING DIFFERENT CASES. **국제산업공학저널**, v. 27, n. 6, 4 jun. 2021.

DEMEY, Y. T.; WOLFF, M. SIMISS: A Model based Searching Strategy for Inventory Management Systems. **IEEE Internet of Things Journal**, p. 1–1, 2016.

ERSOY, Y. The Advantages and Barriers in Implementing of Industry 4.0 and Key Features of Industry 4.0. **The Journal of International Scientific Researches**, v. 7, n. 3, p. 207–214, 7 out. 2022.

ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. **Nature**, v. 542, n. 7639, p. 115–118, 2 fev. 2017.

FELEA, M.; ALBĂSTROIU, I. Defining the Concept of Supply Chain Management

and its Relevance to Romanian Academics and Practitioners. **Amfiteatru Economic Journal**, v. 15, p. 74–88, 2013.

FILHO, V. A. V.; GOI, M. Y. O. Gestão da cadeia de suprimentos 4.0: Análise de conteúdo nos artigos mais relevantes das bases de dados da Scopus e Web of Science / Supply chain management 4.0: Content analysis in the most relevant articles from Scopus and Web of Science databases. **Brazilian Journal of Development**, v. 7, n. 12, p. 117868–117889, 29 dez. 2021.

FORRESTER, J. W. Industrial Dynamics: A Major Breakthrough for Decision Makers. 4. v. 36, p. 37–66, 1958.

FU, W.; CHIEN, C.-F. UNISON data-driven intermittent demand forecast framework to empower supply chain resilience and an empirical study in electronics distribution. **Computers & Industrial Engineering**, v. 135, p. 940–949, set. 2019.

GALVÃO, T. F.; PEREIRA, M. G. Revisões sistemáticas da literatura: passos para sua elaboração. **Epidemiologia e Serviços de Saúde**, v. 23, n. 1, p. 183–184, mar. 2014.

GARCÍA-BARRIOS, D. et al. A Machine Learning based Method for Managing Multiple Impulse Purchase Products: An Inventory Management Approach. **Journal of Engineering Science and Technology Review**, v. 14, n. 1, p. 25–37, fev. 2021.

GÉRON, A.; RAVAGLIA, C. **Mãos à obra aprendizado de máquina com Scikit-Learn, Keras & TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes**. 2ª edição ed. Brasil: Alta Books, 2021.

GHAHRAMANI, M. et al. AI-based modeling and data-driven evaluation for smart manufacturing processes. **IEEE/CAA Journal of Automatica Sinica**, v. 7, n. 4, p. 1026–1037, jul. 2020.

GIL, A. C. **Como Elaborar Projetos De Pesquisa**. 7. ed. São Paulo, SP: Editora Atlas Ltda, 2022.

GOLDENTAL, A.; KANTER, I. A minority of self-organizing autonomous vehicles significantly increase freeway traffic flow. **Journal of Physics A: Mathematical and Theoretical**, v. 53, n. 41, p. 414001, 16 out. 2020.

GONÇALVES, J. N. C. et al. A multivariate approach for multi-step demand forecasting in assembly industries: Empirical evidence from an automotive supply chain. **Decision Support Systems**, v. 142, p. 113452, mar. 2021.

GONÇALVES, J. R. Manual de artigo de revisão de literatura. **Brasília: Processus**, 2019.

GONZÁLEZ RODRÍGUEZ, G.; GONZALEZ-CAVA, J. M.; MÉNDEZ PÉREZ, J. A. An intelligent decision support system for production planning based on machine learning. **Journal of Intelligent Manufacturing**, v. 31, n. 5, p. 1257–1273, jun. 2020.

GOUGH, D. Weight of Evidence: a framework for the appraisal of the quality and relevance of evidence. **Research Papers in Education**, v. 22, n. 2, p. 213–228, jun.

2007.

GREEN, K. W.; WHITTEN, D.; INMAN, R. A. The impact of logistics performance on organizational performance in a supply chain context. **Supply Chain Management: An International Journal**, v. 13, n. 4, p. 317–327, 20 jun. 2008.

GUPTA, S.; SAXENA, A. Classification of Operational and Financial Variables Affecting the Bullwhip Effect in Indian Sectors: A Machine Learning Approach. **Recent Patents on Computer Science**, v. 12, n. 3, p. 171–179, 8 maio 2019.

HAN, C.; ZHANG, Q. Optimization of supply chain efficiency management based on machine learning and neural network. **Neural Computing and Applications**, v. 33, n. 5, p. 1419–1433, mar. 2021.

HAN, S. et al. Using the TensorFlow Deep Neural Network to Classify Mainland China Visitor Behaviours in Hong Kong from Check-in Data. **ISPRS International Journal of Geo-Information**, v. 7, n. 4, p. 158, 21 abr. 2018.

HANSSMANN, F. Optimal Inventory Location and Control in Production and Distribution Networks. **Operations Research**, v. 7, n. 4, p. 483–498, ago. 1959.

HARTWELL, R. M. Was There an Industrial Revolution? **Social Science History**, v. 14, n. 4, p. 567, 1990.

HAX, A. C.; MEAL, H. C. Hierarchical Integration of Production Planning and Scheduling Hierarchical Integration of Production Planning and Scheduling Hierarchical Integration of Production Planning and Scheduling. **Studies in Management Science**, v. 1, p. 53–69, 1975.

HEGDE, J.; ROKSETH, B. Applications of machine learning methods for engineering risk assessment – A review. **Safety Science**, v. 122, p. 104492, fev. 2020.

HOGENBOOM, A. et al. Adaptive Tactical Pricing in Multi-Agent Supply Chain Markets Using Economic Regimes. **Decision Sciences**, v. 46, n. 4, p. 791–818, ago. 2015.

HRAMOV, A. E. et al. Artificial neural network detects human uncertainty. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, v. 28, n. 3, p. 033607, 1 mar. 2018.

ISLAM, S.; AMIN, S. H. Prediction of probable backorder scenarios in the supply chain using Distributed Random Forest and Gradient Boosting Machine learning techniques. **Journal of Big Data**, v. 7, n. 1, p. 65, dez. 2020.

IVANOV, D. et al. Researchers' perspectives on Industry 4.0: multi-disciplinary analysis and opportunities for operations management. **International Journal of Production Research**, v. 59, n. 7, p. 2055–2078, 3 abr. 2021.

IVANOV, D. The Industry 5.0 framework: viability-based integration of the resilience, sustainability, and human-centricity perspectives. **International Journal of Production Research**, v. 61, n. 5, p. 1683–1695, 4 mar. 2023.

Jl, S. et al. An Application of a Three-Stage XGBoost-Based Model to Sales

Forecasting of a Cross-Border E-Commerce Enterprise. **Mathematical Problems in Engineering**, v. 2019, p. 1–15, 16 set. 2019.

KERASIDOU, A. Artificial intelligence and the ongoing need for empathy, compassion and trust in healthcare. **Bulletin of the World Health Organization**, v. 98, n. 4, p. 245–250, 1 abr. 2020.

KHAN, A.; TUROWSKI, K. A Survey of Current Challenges in Manufacturing Industry and Preparation for Industry 4.0. Em: ABRAHAM, A. et al. (Eds.). **Proceedings of the First International Scientific Conference “Intelligent Information Technologies for Industry” (IITI’16)**. Advances in Intelligent Systems and Computing. Cham: Springer International Publishing, 2016. v. 450p. 15–26.

KICIŃSKI, J.; CHAJA, P. Industry 4.0—The Fourth Industrial Revolution. Em: KICIŃSKI, J.; CHAJA, P. (Eds.). **Climate Change, Human Impact and Green Energy Transformation**. GeoPlanet: Earth and Planetary Sciences. Cham: Springer International Publishing, 2021. p. 115–140.

KROHN, S. et al. A spatiotemporal complexity architecture of human brain activity. **Science Advances**, v. 9, n. 5, p. eabq3851, fev. 2023.

KUMAR, S.; SHARMA, S. C. Integrated Model for Predicting Supply Chain Risk Through MachineLearning Algorithms. **International Journal of Mathematical, Engineering and Management Sciences**, v. 8, n. 3, p. 353–373, 1 jun. 2023.

KWASNICKA, E. L. **Introdução a administração**. 6. ed. rev. e ampl ed. São Paulo: Atlas, 2004.

LANDES, D. S. **Prometeu desacorrentado: transformação tecnológica e desenvolvimento industrial na Europa Ocidental de 1750 até os dias de hoje**. 2. ed ed. Rio de Janeiro: Elsevier, 2005.

LARSON, P. D.; HALLDORSSON, A. Logistics versus supply chain management: An international survey. **International Journal of Logistics Research and Applications**, v. 7, n. 1, p. 17–31, mar. 2004.

LEITAO, P. et al. Quo Vadis Industry 4.0? Position, Trends, and Challenges. **IEEE Open Journal of the Industrial Electronics Society**, v. 1, p. 298–310, 2020.

LEUNG, K. H. et al. Modelling near-real-time order arrival demand in e-commerce context: a machine learning predictive methodology. **Industrial Management & Data Systems**, v. 120, n. 6, p. 1149–1174, 5 maio 2020.

LI, D. et al. Developing capabilities for supply chain resilience in a post-COVID world: A machine learning-based thematic analysis. **IISE Transactions**, v. 55, n. 12, p. 1256–1276, 2 dez. 2023.

LI, J. et al. Optimal Path of Internet of Things Service in Supply Chain Management Based on Machine Learning Algorithms. **Computational Intelligence and Neuroscience**, v. 2022, p. 1–11, 24 mar. 2022.

LI, Z. Consumer behavior analysis model based on machine learning. **Journal of**

Intelligent & Fuzzy Systems, v. 40, n. 4, p. 6433–6443, 12 abr. 2021.

LILLICRAP, T. P. et al. Backpropagation and the brain. **Nature Reviews Neuroscience**, v. 21, n. 6, p. 335–346, jun. 2020.

LIU, J. et al. A Predictive Analytics Tool to Provide Visibility Into Completion of Work Orders in Supply Chain Systems. **Journal of Computing and Information Science in Engineering**, v. 20, n. 3, p. 031003, 1 jun. 2020.

LIU, L. et al. Quantum Dot Light-Emitting Synaptic Transistor for Parallel Data Transmission of Diverse Artificial Neural Network. **Advanced Materials Technologies**, v. 8, n. 16, p. 2300225, ago. 2023.

LIU, Y. et al. Prediction of vehicle driving conditions with incorporation of stochastic forecasting and machine learning and a case study in energy management of plug-in hybrid electric vehicles. **Mechanical Systems and Signal Processing**, v. 158, p. 107765, set. 2021.

LOLLI, F. et al. Decision Trees for Supervised Multi-criteria Inventory Classification. **Procedia Manufacturing**, v. 11, p. 1871–1881, 2017.

LOLLI, F. et al. Machine learning for multi-criteria inventory classification applied to intermittent demand. **Production Planning & Control**, v. 30, n. 1, p. 76–89, 2 jan. 2019.

LU, C.-J.; KAO, L.-J. A clustering-based sales forecasting scheme by using extreme learning machine and ensembling linkage methods with applications to computer server. **Engineering Applications of Artificial Intelligence**, v. 55, p. 231–238, out. 2016.

LUO, Y. Environmental cost control of coal industry based on cloud computing and machine learning. **Arabian Journal of Geosciences**, v. 14, n. 12, p. 1081, jun. 2021.

MA, Q.; LI, H.; THORSTENSON, A. A big data-driven root cause analysis system: Application of Machine Learning in quality problem solving. **Computers & Industrial Engineering**, v. 160, p. 107580, out. 2021.

MAESTRI, G. et al. REVOLUÇÕES TECNOLÓGICAS E A RELAÇÃO COM O SETOR TÊXTIL: PERSPECTIVAS BASEADAS EM INDÚSTRIA 3.5, INDÚSTRIA 4.0 E INDÚSTRIA 5.0. **Revista Eletrônica Perspectivas da Ciência e Tecnologia - ISSN: 1984-5693**, v. 13, 13 set. 2021.

MCCARTHY, J. et al. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. **AI Magazine**, v. 27, n. 4, p. 12, dez. 2006.

MELANÇON, G. G. et al. A Machine Learning-Based System for Predicting Service-Level Failures in Supply Chains. **INFORMS Journal on Applied Analytics**, v. 51, n. 3, p. 200–212, maio 2021.

MIGUEL, P. A. C. et al. Metodologia de pesquisa em engenharia de produção e gestão de operações. 2010.

MITCHELL, T. M. **Machine learning**. Nachdr. ed. New York: McGraw-Hill, 2013.

MODGIL, S.; SINGH, R. K.; HANNIBAL, C. Artificial intelligence for supply chain resilience: learning from Covid-19. **The International Journal of Logistics Management**, v. 33, n. 4, p. 1246–1268, 17 out. 2022.

MOHER, D. et al. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. **Systematic Reviews**, v. 4, n. 1, p. 1, dez. 2015.

NAVED, M. A Review of the Use of Machine Learning and Artificial Intelligence in Various Sectors. **Multimedia Research**, v. 5, n. 4, p. 26–31, 2022.

NI, D.; XIAO, Z.; LIM, M. K. A systematic review of the research trends of machine learning in supply chain management. **International Journal of Machine Learning and Cybernetics**, v. 11, n. 7, p. 1463–1482, jul. 2020.

NILSSON, N. J. **Problem-solving methods in artificial intelligence**: Tab. 11. print ed. New York: McGraw-Hill, 1979.

OLIVER, R. K.; WEBBER, M. D. Supply-Chain Management: Logistics Catches up with Strategy. Em: KLAUS, P.; MÜLLER, S. (Eds.). **The Roots of Logistics**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1982. p. 183–194.

OPPERMANN, A. **What Is Deep Learning and How Does It Work?** Disponível em: <<https://builtin.com/machine-learning/deep-learning>>. Acesso em: 1 jul. 2023.

PANZER, M.; BENDER, B. Deep reinforcement learning in production systems: a systematic literature review. **International Journal of Production Research**, v. 60, n. 13, p. 4316–4341, 3 jul. 2022.

PARADA, R.; MELIÀ-SEGUÍ, J.; POUS, R. Anomaly Detection Using RFID-Based Information Management in an IoT Context: **Journal of Organizational and End User Computing**, v. 30, n. 3, p. 1–23, 1 jul. 2018.

PERANO, M. et al. Embracing supply chain digitalization and unphysicalization to enhance supply chain performance: a conceptual framework. **International Journal of Physical Distribution & Logistics Management**, v. 53, n. 5/6, p. 628–659, 1 ago. 2023.

PEREIRA, R.; SANTOS, N. DOS. Indústria 5.0: reflexões sobre uma nova abordagem paradigmática para a indústria. **XLVI Encontro da ANPAD**, 2022.

POZZEBON, E.; FRIGO, L. B.; BITTENCOURT, G. INTELIGÊNCIA ARTIFICIAL NA EDUCAÇÃO UNIVERSITÁRIA: QUAIS AS CONTRIBUIÇÕES? **Revista do Centro de Ciências da Economia e Informática da Universidade da Região da Campanha Urcamp**, v. 8, n. 13, p. 34–41, 2004.

PRIORE, P. et al. Applying machine learning to the dynamic selection of replenishment policies in fast-changing supply chain environments. **International Journal of Production Research**, v. 57, n. 11, p. 3663–3677, 3 jun. 2019.

PRODANOV, C. C.; FREITAS, E. C. DE. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. [s.l.] Universidade Feevale, 2013.

QI, M.; MAK, H.; SHEN, Z. M. Data-driven research in retail operations—A review. **Naval Research Logistics (NRL)**, v. 67, n. 8, p. 595–616, dez. 2020.

RAI, R. et al. Machine learning in manufacturing and industry 4.0 applications. **International Journal of Production Research**, v. 59, n. 16, p. 4773–4778, 18 ago. 2021.

RAMAKURTHI, V. B. et al. A Hybrid Multi-Objective Evolutionary Algorithm-Based Semantic Foundation for Sustainable Distributed Manufacturing Systems. **Applied Sciences**, v. 11, n. 14, p. 6314, 8 jul. 2021.

RAN, J. Intelligent Method of Supply Chain Circulation Industry Structure Based on Machine Learning. **Mobile Information Systems**, v. 2021, p. 1–10, 27 nov. 2021.

RASCHKA, S.; MIRJALILI, V. **Python machine learning: machine learning and deep learning with Python, scikit-learn, and TensorFlow 2**. Third edition ed. Birmingham Mumbai: Packt, 2019.

RAZA, S. A. A systematic literature review of RFID in supply chain management. **Journal of Enterprise Information Management**, v. 35, n. 2, p. 617–649, mar. 2022.

RAZA, S. A.; GOVINDALURI, S. M.; BHUTTA, M. K. Research themes in machine learning applications in supply chain management using bibliometric analysis tools. **Benchmarking: An International Journal**, v. 30, n. 3, p. 834–867, 21 mar. 2023.

ROLF, B. et al. A review on reinforcement learning algorithms and applications in supply chain management. **International Journal of Production Research**, v. 61, n. 20, p. 7151–7179, 18 out. 2023.

ROWLEY, J.; SLACK, F. Conducting a literature review. **Management Research News**, v. 27, n. 6, p. 31–39, jun. 2004.

ROŽANEC, J. M. et al. Automotive OEM Demand Forecasting: A Comparative Study of Forecasting Algorithms and Strategies. **Applied Sciences**, v. 11, n. 15, p. 6787, 23 jul. 2021.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Fourth edition ed. Hoboken: Pearson, 2021.

RÜSSMANN, M. et al. Industry 4.0: The future of productivity and growth in manufacturing industries. **Boston consulting group**, v. 9, n. 1, p. 54–89, 2015.

SACOMANO, J. B. et al. **Indústria 4.0: conceitos e fundamentos**. [s.l.] Blucher, 2018.

SAM SEKHAR, M.; CHALAPATHI, P. VENKATA. A Hybrid Statistical Data Preprocessing and Data Forecasting Model on ERP Based Supply Chain

Management (SCM) Databases. **International journal of simulation: systems, science & technology**, 3 fev. 2019.

SARDAR, S. K.; SARKAR, B.; KIM, B. Integrating Machine Learning, Radio Frequency Identification, and Consignment Policy for Reducing Unreliability in Smart Supply Chain Management. **Processes**, v. 9, n. 2, p. 247, 29 jan. 2021.

SCHNECKENREITHER, M.; HAEUSSLER, S.; GERHOLD, C. Order release planning with predictive lead times: a machine learning approach. **International Journal of Production Research**, v. 59, n. 11, p. 3285–3303, 3 jun. 2021.

SCHULES, M. V. **Proposta de diagnóstico para adoção das tecnologias da indústria 4.0 em um processo produtivo com base em indicadores de sustentabilidade : um estudo de caso**. Dissertação (mestrado)—Curitiba: Universidade Federal do Paraná. Setor de Tecnologia. Programa de Pós-Graduação em Engenharia de Produção, 2 jul. 2019.

SCHWAB, K. **A Quarta Revolução Industrial**. São Paulo: Edipro, 2019.

SEO, Y.-H. et al. Predicting demand for a bike-sharing system with station activity based on random forest. **Proceedings of the Institution of Civil Engineers - Municipal Engineer**, v. 174, n. 2, p. 97–107, jun. 2021.

SHAFIQ, S. I. et al. Virtual Engineering Object / Virtual Engineering Process: A specialized form of Cyber Physical System for Industrie 4.0. **Procedia Computer Science**, v. 60, p. 1146–1155, 2015.

SHAHROUDNEJAD, A. A Survey on Understanding, Visualizations, and Explanation of Deep Neural Networks. 2021.

SILVA, D. B.; DA SILVA, Ricardo Moreira; GOMES, Maria de Lourdes Barreto. **O reflexo da terceira revolução industrial na sociedade**. ADEPRO. **Anais...** Em: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Curitiba: 2002.

SIMCHI-LEVI, D.; WU, M. X. Powering retailers' digitization through analytics and automation. **International Journal of Production Research**, v. 56, n. 1–2, p. 809–816, 17 jan. 2018.

STANISAVLJEVIC, D.; SPITZER, M. A Review of Related Work on Machine Learning in Semiconductor Manufacturing and Assembly Lines. **SAMI@ iKNOW**, 2016.

SUGIURA, A. Artificial Intelligence for Medical Imaging and Hygiene. Em: TAKADA, H.; YOKOYAMA, K. (Eds.). **Bio-information for Hygiene**. Current Topics in Environmental Health and Preventive Medicine. Singapore: Springer Singapore, 2021. p. 133–147.

SZEGEDY, C. et al. **Going deeper with convolutions**. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). **Anais...** Em: 2015 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR). Boston, MA, USA: IEEE, jun. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7298594/>>. Acesso em: 10 nov. 2023

TALEB, T.; AFOLABI, I.; BAGAA, M. Orchestrating 5G Network Slices to Support Industrial Internet and to Shape Next-Generation Smart Factories. **IEEE Network**, v. 33, n. 4, p. 146–154, jul. 2019.

TAYLOR, F. W. **Princípios de administração científica**. 8. ed ed. Sao Paulo: Atlas, 2006.

TESHNIZI, S.; AYATOLLAHI, S. A Comparison of Logistic Regression Model and Artificial Neural Networks in Predicting of Student's Academic Failure. **Acta Informatica Medica**, v. 23, n. 5, p. 296, 2015.

TIRKOLAEI, E. B. et al. Application of Machine Learning in Supply Chain Management: A Comprehensive Overview of the Main Areas. **Mathematical Problems in Engineering**, v. 2021, p. 1–14, 21 jun. 2021.

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review. **British Journal of Management**, v. 14, n. 3, p. 207–222, set. 2003.

TSOLAKIS, N. et al. Artificial intelligence and blockchain implementation in supply chains: a pathway to sustainability and data monetisation? **Annals of Operations Research**, v. 327, n. 1, p. 157–210, ago. 2023.

VAN BELLE, J.; GUNS, T.; VERBEKE, W. Using shared sell-through data to forecast wholesaler demand in multi-echelon supply chains. **European Journal of Operational Research**, v. 288, n. 2, p. 466–479, jan. 2021.

VAN STEENBERGEN, R. M.; MES, M. R. K. Forecasting demand profiles of new products. **Decision Support Systems**, v. 139, p. 113401, dez. 2020.

VARSHNEY, K. R. **Engineering safety in machine learning**. 2016 Information Theory and Applications Workshop (ITA). **Anais...IEEE**, jan. 2016.

WANG, C. et al. Machine learning-based regional scale intelligent modeling of building information for natural hazard risk management. **Automation in Construction**, v. 122, p. 103474, fev. 2021.

WANG, J. et al. Deep learning for smart manufacturing: Methods and applications. **Journal of Manufacturing Systems**, v. 48, p. 144–156, jul. 2018.

WANG, S.; YANG, Y. M-GAN-XGBOOST model for sales prediction and precision marketing strategy making of each product in online stores. **Data Technologies and Applications**, v. 55, n. 5, p. 749–770, 11 out. 2021.

WOOD, I. K. Neuroscience: Exploring the brain: By Mark F. Bear, Barry W. Connors and Michael A. Paradiso. Baltimore: Williams & Wilkins, 1996. Pp. 666. **Journal of Child and Family Studies**, v. 5, n. 3, p. 377–379, set. 1996.

WREN, D. A.; BEDEIAN, A. G. **The evolution of management thought**. 6th ed ed. Hoboken, N.J. : [Chichester, England: Wiley ; Wiley, distributor], 2009.

WU, C. et al. Partner selection in sustainable supply chains: A fuzzy ensemble

learning model. **Journal of Cleaner Production**, v. 275, p. 123165, dez. 2020.

WUEST, T. et al. Machine learning in manufacturing: advantages, challenges, and applications. **Production & Manufacturing Research**, v. 4, n. 1, p. 23–45, jan. 2016.

XUAN, F. Regression analysis of supply chain financial risk based on machine learning and fuzzy decision model. **Journal of Intelligent & Fuzzy Systems**, v. 40, n. 4, p. 6925–6935, 12 abr. 2021.

YADAV, N.; SHANKAR, R.; SINGH, S. P. Impact of Industry4.0/ICTs, Lean Six Sigma and quality management systems on organisational performance. **The TQM Journal**, v. 32, n. 4, p. 815–835, 21 jul. 2020.

YAN, P.; CHOUDHURY, S.; WEI, R. A Machine Learning Auxiliary Approach for the Distributed Dense RFID Readers Arrangement Algorithm. **IEEE Access**, v. 8, p. 42270–42284, 2020.

YANG, X. et al. Evaluation of the Effect of the Dynamic Behavior and Topology Co-Learning of Neurons and Synapses on the Small-Sample Learning Ability of Spiking Neural Network. **Brain Sciences**, v. 12, n. 2, p. 139, 21 jan. 2022.

YOUNIS, H.; SUNDARAKANI, B.; ALSHARAI, M. Applications of artificial intelligence and machine learning within supply chains: systematic review and future research directions. **Journal of Modelling in Management**, v. 17, n. 3, p. 916–940, 22 ago. 2022.

ZHANG, S. et al. Importance Degree Evaluation of Spare Parts Based on Clustering Algorithm and Back-Propagation Neural Network. **Mathematical Problems in Engineering**, v. 2020, p. 1–13, 22 maio 2020.

ZHOU, B. et al. **SemFE: Facilitating ML Pipeline Development with Semantics**. Proceedings of the 29th ACM International Conference on Information & Knowledge Management. **Anais...** Em: CIKM '20: THE 29TH ACM INTERNATIONAL CONFERENCE ON INFORMATION AND KNOWLEDGE MANAGEMENT. Virtual Event Ireland: ACM, 19 out. 2020.

ZIZIC, M. C. et al. From Industry 4.0 towards Industry 5.0: A Review and Analysis of Paradigm Shift for the People, Organization and Technology. **Energies**, v. 15, n. 14, p. 5221, 19 jul. 2022.