

TÓPICOS À DISCUSSÃO SOBRE APRENDIZAGEM DE MÁQUINA NA ADMINISTRAÇÃO, ECONOMIA, SAÚDE E EDUCAÇÃO FÍSICA

BARRETO, Ana Cristina Lopes y Glória¹; CARVALHO JUNIOR, Sergio²; EVERTON, Adriana Nunes da Fonseca³; BRASIL, Roxana Macedo⁴; BRITO, Diogo de Freitas^{5,6}; JUNIOR, Homero da Silva Nahum^{1,7}

83

Resumo

A investigação discutiu a Aprendizagem de Máquina, conceituando e enquadrando-a como subárea da Inteligência Artificial. A comparação entre as aprendizagens Supervisionada, Não Supervisionada e por Reforço solidificou a necessidade de pesquisas. Aplicações à Administração, Saúde e Educação Física foram apresentadas, sem negligenciar os problemas éticos, políticos ou jurídicos. As tendências em investigações científicas e aplicações foram relatadas, possibilitando concluir que a Aprendizagem de Máquina deteria adequações aos problemas das áreas citadas, auxiliando a tomada de decisão.

Palavras-chave: Inteligência artificial. Ciências de dados. Negócios. Tecnologia da informação. Análise de dados.

Abstract

The investigation discussed Machine Learning, conceptualizing and framing it as a subfield of Artificial Intelligence. The comparison between Supervised, Unsupervised, and Reinforcement Learning solidified the need for research. Applications to Administration, Health, and Physical Education were presented, without neglecting ethical, political, or legal issues. Trends in scientific research and applications were reported, allowing the conclusion that Machine Learning would be suitable for addressing problems in the aforementioned areas, assisting in decision-making.

Keywords: Artificial intelligence. Data science. Business. Information technology. Data analysis.

Introdução

Conceitualmente, a Aprendizagem de Máquina ou Aprendizado de Máquina (*Machine Learning* - ML) dotaria determinado sistema computacional da capacidade de aprender padrões (Lecun, Bengio e Hinton, 2015), tendo por material de ensino, banco(s)

¹ Docentes do Curso de Educação Física do Centro Universitário Celso Lisboa;

² Pesquisador convidado do BIODESA;

³ Profissional de Educação Física da Adriana Nunes Consultoria de Corrida;

⁴ Docente Ph.D. em Educação Física;

⁵ Docente do Curso de Gestão Desportiva e do Lazer do Centro Universitário Celso Lisboa;

⁶ Consultor da Iceberg Business Academy

⁷ Docente da Escola de Saúde da Universidade Cândido Mendes

de dados, submetido(s) a modelos matemáticos ou estatísticos (método de ensino), apresentados por algoritmos (técnica de ensino). A ocorrência da aprendizagem eliminaria a necessidade de programação explícita, portanto tratar-se-ia de subárea da Inteligência Artificial (IA), particularmente pela base de aprendizado residente no passado (Barreto, Brasil e Junior, 2024). De toda sorte, a predição e tomada de decisão seriam os objetivos (Junior *et al.*, 2025).

Sinteticamente, todo o conhecimento aplicado (tecnologia) originaria um modelo, do latim *modulus*, diminutivo de *modus*, que significaria medida (Japiassú e Marcondes, 1990), assim a ML seria um modo de explicação da determinada realidade, ou seja, uma representação dentre tantas potencialmente existentes no universo de representações, conseqüentemente uma percepção reduzida daquela realidade.

O reducionismo de qualquer modelo ocorreria como consequência do plano geométrico definido por 1) pontualidade, a representação se limitaria a um e somente um fenômeno, esse seria necessário e suficiente à alteração de resultados; 2) redutividade, haveria disponível e, conseqüentemente, selecionado finitas quantidades de elementos, variáveis, parâmetros ou exemplos (Gouveia Jr, 1999); 3) espírito da época (*Zeitgeist*, do alemão), os grupos que criaram os bancos de dados ou desenvolveram os algoritmos poderiam, comumente o seriam, influenciados por respectivas percepções de mundo, conjunto de crenças, valores, princípios e objetivos, por exemplo (Simonton, 2004; Mudde, 2004; Mayo e Nohria, 2005; Pujó, 2013; Krause, 2019; Kraus, 2025), valeria afirmar que a influência seria determinada pelo espaço-tempo social e histórico.

Entretanto, o modelo seria adequado, em consequência funcionaria ao escopo de desenvolvimento, logo o valor utilitário dependeria da capacidade preditiva e aproximação do fenômeno de interesse (Gouveia Jr, 1999). Alicerçada no exposto, a presente investigação objetivou discutir a Aprendizagem de Máquina à luz das características e aplicações, essas particularmente nos domínios da Administração, Saúde e, de forma estrita, Educação Física.

Histórico

As raízes da ML se estruturaram nas décadas de 1950 e 1960, particularmente com a ideia de máquinas capazes de aprender (Turing, 1950) e o alicerce das Redes Neurais Artificiais (RNA) com o desenvolvimento do *perceptron* (Roseblatt, 1958). Assim como, os algoritmos de Aprendizagem Profunda ou Aprendizado Profundo (*deep learning*) utilizando

múltiplas de camadas com funções de ativação polinomiais (Ivakhnenko e Lapa, 1965), aplicando o método dos mínimos quadrados para ajustar os recursos em cada camada, independentemente das camadas posteriores, ou seja, as RNAs não eram treinadas por retropropagação.

Valeria destacar que a Aprendizagem Profunda seria subárea da ML e caracterizada pela análise de volumosos bancos de dados para aprendizagem de padrões complexos, tais como predição de resultados, processamento de linguagem natural e reconhecimento de imagens. Para tanto, empregaria RNAs com múltiplas camadas (Machado e Mundim, 2022). Não obstante, a consolidação das redes neurais ocorreria nas décadas de 1980 e 1990, alavancada pelos algoritmos de *backpropagation* (retropropagação) que estimavam a propagação de retorno de erros pelas redes e ajustavam de pesos das conexões entre neurônios (Rumelhart, Hinton e Williams, 1986)

Paralelamente, criados foram os algoritmos para identificação de classes de dados, considerando a maior distância interclasse, originando vetores de suporte, e nomeando essa família de códigos de Máquina de Vetores de Suporte (*Support Vector Machine – SVM*), tendo singular aplicação em problemas com elevada quantidade de variáveis (alta dimensionalidade), independentemente de comportamento linear, como em bioinformática, análise de imagens em vídeos ou fotografia, classificação de textos, e regressões com saídas contínuas (Lorena e Carvalho, 2007; Mechelli e Vieira, 2019).

O crescimento da ML foi acompanhado por propostas de métodos estatísticos robustos (Vapnik, 1995), como a Floresta Aleatória (*Random Forest*) voltada à classificação e regressão pela combinação de árvores de decisão, reduzindo a “memorização” de padrões e ruídos (*overfitting*). Logo, adequado à predição de aceitação de produto ou serviço em *e-commerce*; identificação de fraudes, predição desempenho financeiro, de investimentos, comportamento do consumidor; produção nos setores econômicos ou inflação; e análise de histórico de saúde para identificação de doença e combinação de medicamentos (Biau e Scornet, 2016).

Visando melhorar as predições foi desenvolvido o método *boosting*, no qual um primeiro modelo simples seria estimado e treinado, observando os erros de predição, outro modelo seria desenvolvido para corrigi-los, esse processo de combinação de modelos seria repetido iterativamente, elevado a capacidade preditiva do sistema final (Rodrigues, Prudêncio e Barros, 2009), tendo sido implementado para prever demissão de cliente

interno e preço de ações; avaliação de créditos; identificar nódulos cancerígenos; auxiliar diagnósticos; desempenho de atletas e predição de carga de treino.

Na primeira década do século XXI, a ML foi favorecida pelo aumento do tamanho de banco de dados, alimentados constantemente com amplo sortilégio de formatos e fontes (*Big Data*), o que elevou a complexidade das análises que apoiariam a tomada de decisão sobre, por exemplo, produção e veiculação de programas em serviços de *streaming*; otimização da navegação em plataformas digitais; monitoramento de sistemas fisiológicos; predição de demanda; identificação de fraudes; e eficiência operacional. Esse cenário requisitou robustez no treinamento de modelos para potencializar a identificação e aprendizado de padrões (Chen *et al.*, 2013; Marx, 2013; Zakir, Seymour e Berg, 2015; Camargo-Vega, Camargo-Ortega e Joyanes-Aguilar, 2015; Vesterinen, Mero e Skippari, 2025; Lin, 2025).

No mesmo momento, tarefas como tradução automática, reconhecimento da verbalização e análise de sentimentos, as quais demandavam a consideração da entrada corrente conjuntamente ao histórico, se tornaram efetivamente possíveis com a advento das RNAs recorrentes. Esses algoritmos de Aprendizagem Profunda processariam dados sequenciais, portanto, considerando a ordem, fazendo uso do conjunto de informações armazenadas em memória, o que intensificaria o reconhecimento de padrões e relações, permitindo melhorar a conversão de áudio em texto; tradução automática, legendagem de vídeo; análise de sentimentos; e predições de inundação, preços, demanda, venda, produção, e atendimento a clientes externos, dentre outros fenômenos (Härter, 2007; Nelson, 2017; Vendramini, Saldias e Tavares, 2023; Souza *et al.*, 2025; Conti e Graf, 2025).

Ainda nesse tempo e no domínio das RNAs, as convolucionais (CNN) se destacaram por processarem dados organizados em grade, possibilitando a ML sobre relações e padrões espaciais entre os pixels, logo a identificação de faces; reconhecimento de objetos; e classificação e segmentação de imagens se tornariam exequíveis. Além de proporcionar significativas melhorias na análise de sinais biomédicos e de áudio, e no reconhecimento da fala (Ferreira, 2017; Silva, 2018; Souza, 2023; Batista, Oliveira e Guidolin, 2025; Sousa *et al.*, 2025). Na atual década, 2020, destacaram-se as aplicações direcionadas ao grande público consumidor como os modelos de linguagem (Oliveira e Neves, 2023; Rodrigues e Rodrigues, 2023; Bryda e Costa, 2024), exemplificados por Chat-GPT e Bert; a aprendizagem multimodal (Sousa, 2021; Santaella, 2023; Pires, 2025), entendida como aquela processaria informações oriundas de distintos sentidos, portanto, capaz seria de

analisar dados sob os domínios visual e da linguagem, simultaneamente; a automatização da ML (Jin *et al.*, 2023; Zheng *et al.*, 2023; Gijbers *et al.*, 2024); e inserção em dispositivos localizados em ambientes domésticos (Silva, 2020; Oliveira, 2021; Pereira, 2021; Rolle, 2024).

Modelos

Norteados pela supinação dos valores utilitário, preditivo e de aproximação, os modelos de ML se diferenciariam, em razão da forma de aprendizagem e dos dados utilizados, nas aprendizagens Supervisionada, Não Supervisionada e por Reforço (Rahman, 2022; Sicsú, Samartini e Barth, 2023; Gabriel Filho, 2023):

Na Aprendizagem Supervisionada, o modelo mapearia entradas (*features*) em razão de saídas (rótulos) para prever resultados. A aprendizagem ocorreria com a comparação entre previsões e rótulos observados e armazenados no banco de dados, possibilitando o ajustamento dos parâmetros para minimizar os erros (resíduos), portanto amplamente utilizados em regressão e classificação. Por exemplo, previsão de tempo de sobrevivência em paciente oncológico (Henrich *et al.*, 2025), diagnóstico de diabetes mellitus (Damke, Damke e Gregorini, 2025), classificação de textos (Rossi, 2015), reconhecimento de gêneros musicais (Pimenta e Pugliesi, 2022) e análise de sentimentos em redes sociais (Afonso e Duque, 2019).

A Não Supervisionada objetivaria a descoberta de padrões, estruturas ou agrupamentos de dados, assim possibilitando a redução no número de variáveis (redução de dimensionalidade), segmentação de mercados por agrupamento de clientes, ou identificação de inconformidades ou anomalias. O modelo, utilizando banco de dados somente com entradas, identificaria similaridades ou divergências, possibilitando o agrupamento baseado nas identificações (características), como na análise de *clustering*. Por exemplo, identificação de multimorbidade em adolescentes de 13 anos (Branquinho, 2024), desenvolvimento de mapas astronômicos auto-organizáveis (Magalhães, 2021), segmentação de fotomicrografia bacteriana (2021) ou classificação de imagens de tomografia computadorizada de tórax (Shen, 2025), previsão de evasão de cursos EaD (Juliani, 2025) ou ensino superior em geral (Silvestri, Souza e Vieira, 2025), identificação e classificação de anomalias na qualidade de energia (Alves, 2025), investigação de decisões algorítmicas ofensivas aos direitos fundamentais (Watzko, Saikali e Hadas, 2025), e previsão de desvios e controle orçamentário (Palmas, 2023).

A aprendizagem por Reforço se basearia em tentativa e erro, levando o modelo à recompensa ou penalização. O modelo exploraria o ambiente para aprender sequências de ações, recebendo retroalimentação em conformidade ao conjunto de ações desenvolvidas, isso favoreceria a tomada de decisão em prol dos melhores resultados. Outro diferencial residiria no emprego de bancos de dados não pré-definidos, como consequência seria adequado à otimização de processos, controle de robôs e aprendizagem de jogos. Por exemplo, modelos para economia de combustível por veículos à combustão (Araújo, 2025), roteamento de veículos (Silva, 2025), previsão de precificação (Dolgov, Lyukevich e Dolgov, 2022) de venda de imóveis em João Pessoa (Melo, 2025), automóveis à indústria automobilística (Gonçalves *et al.*, 2023), equipamento de construção (Boyko e Lukash, 2023), e tomada de decisão sobre investimentos em bolsa de valores (Costa e Moura Júnior, 2023).

Aplicações

A ML teria, pelo exposto, aplicações diversas, conquistando destaque os sistemas de tutoria na educação básica (Melo, 2024) ou superior (Júnior *et al.*, 2023), ou avaliação de desempenho estudantil (Fernandes *et al.*, 2020; Franco, 2024). Na disciplina de Finanças, possível seria identificar fraudes no uso de cartão de crédito ou débito (Santos, 2023), assim como elaborar análise de crédito ao consumidor final, inclusive em nichos ou setores específicos (Batista e Menezes, 2024).

Na área de vendas, o planejamento de marketing poderia, com adequada precisão, segmentar o banco de dados de cliente externo, elevando a eficiência e eficácia das respectivas ações (Santana *et al.*, 2023). Assim como, acompanhar e se aproximar dos clientes (externos e internos) pela recomendação de produtos ou serviços, e identificação de demandas, sugestões, avaliações (positivas ou negativas) e ideias ou comportamentos divergentes dos valores organizacionais (Antunes, Issa e Hoed, 2023). À luz do gerenciamento, haveria sustentação ao ajuste de metas e dos planejamentos estratégico, tático e operacional. Em logística, o desenho de rotas poderia ser pormenorizadamente determinado, inclusive para entregas diretamente ao consumidor final, sobretudo quando do emprego de veículos autônomos (Campos, Rodrigues e Campos, 2020). Nesse norte, o deslocamento de deficientes visuais pela planta organizacional seria facilitado e otimizado com a ML em equipamentos assistivos (Andrade *et al.*, 2022), podendo elevar a segurança de recém-contratados sob aquela condição.

No setor secundário da economia, a adequada gerência da cadeia de suprimentos deteria singular importância, pois afetaria todas as etapas de produção, logo poderia proporcionar redução de custos pela melhora em compra, produção e distribuição; satisfação do cliente externo pela convergência à expectativa; redução de riscos na entrega e produção; e potencializar a adaptação espaço-temporal, por exemplo, todo esse quadro depende de modelos preditivos convergentes aos padrões e relações organizacionais (Vitorino Filho e Goi, 2021). O planejamento de manutenção, também, seria aspecto fundamental no contexto industrial, dado que a utilização e desgaste de equipamentos e instrumentos requereria análise das peculiaridades que envolveriam o comportamento de falhas (Zaro e Webber, 2022).

No condizente à saúde, a ML possibilitou modelos preditivos para diagnóstico de Covid-19 (Bortolini, 2021), ansiedade, depressão e estresse (Melo e Alves, 2022), doença de Parkinson (Silva, 2024), cardiomiopatias pela análise de imagens de ressonância magnética (Silva, 2023), câncer de mama e ovário (Vedana *et al.*, 2024), fibrilação atrial (Darrieux e Wu, 2024; Estrada, 2025), doenças oculares (Abbott, 2021; Nunes, Guimarães e Dadalto, 2022) e identificação de padrões em tomografia e ressonâncias (Ahmed *et al.*, 2017). Na cirurgia teria influenciado a segurança, precisão e individualização pela inserção no planejamento até o pós-operatório, destacando-se o uso de robôs assistidos (Monteiro *et al.*, 2025). A tecnologia de desenvolvimento de fármacos, apoiada na bioinformática (Xavier, 2021), teria conseguido agrupar sequências de anticorpos (Almeida, 2024); produzir alcaloides para inibir a bactéria *Staphylococcus aureus* (Conceição, 2023), causadora de endocardite, pneumonia, infecção cutânea e septicemia, dentre outras complicações; classificar ligantes, substâncias que se associam a receptores específicos na membrana plasmática ou moléculas intracelulares, interferindo no crescimento ou na resposta a estímulos, por exemplo (Santos, 2017); e na formulação direta de medicamentos (Machado, 2023). Talvez, as aplicações mais relevantes residissem na personalização de terapias (Santos e Lopes, 2024) como nos casos de Alzheimer (Launé *et al.*, 2025) e infecção pelo vírus da Chikungunya (Burt *et al.*, 2017), ou no monitoramento e apoio à toma de decisão perinatal (Faria, 2024).

No contexto da Educação Física, a vestimenta desportiva seria planejada para coletar dados, como uniformes de ciclismo com eletrodos para monitoramento em tempo real por eletrocardiograma, ou aqueles de esgrima com sensores piezoresistivo e inerciais. Os primeiros capturariam o desempenho do toque da arma, facilitando a arbitragem e

pontuação, enquanto os outros coletariam, os movimentos do atleta, transmitindo-os para modelo digital, possibilitando a identificação das demandas do esgrimista (Gomes, 2022). O basquete foi agraciado com modelos de ML para 1) localização automática e 3D de jogadores, possibilitando estimativas técnicas e físicas, e análises táticas; e 2) estimar o comportamento da frequência cardíaca em razão da idade, características antropométricas, desempenhos em testes físicos, e distância percorrida, velocidade e tempo de atuação durante o jogo (Monezi, 2016). Tradicionalmente, o lactato seria confundido com ácido láctico, embora fosse metabólito reconhecido como molécula sinalizadora, modulando metabolismo e comunicação entre tecidos, de tal ordem que mimetizaria funcionalmente miocinas (proteínas sintetizadas e liberadas pelos músculos esqueléticos na contração) e exercinas (miocinas liberadas durante o exercício). Assim compreendido, a ML foi empregada para avaliar impacto sobre a modulação imunometabólica (Franco *et al.*, 2025).

No condizente ao treinamento, ajuste de carga no taekwondo (Silva R, 2023). Modelos para predição de resultados foram desenvolvidos para tênis (Nogara, 2023), futebol (Nabinger, 2018), *rugby* (Azevedo, 2019) e basquete (Saijo, 2023), por exemplo. Assim como ocorrência de lesões (Segura *et al.*, 2025) em futebol, futsal, basquete, handebol e atletismo (Soares, 2025), corrida, ciclismo e esportes de combate (Leckey *et al.*, 2025), natação e ginástica (Pereira, Manjon e Souza, 2023) e *cross training* (Athayde, 2025). Finalmente, o emprego em seleção de técnicos de futebol (Nunes, 2025), também alvo foi da ML.

Limitações ou Problemas

A discussão realizada permitiria inferir que conquistas, como automatização de processos industriais e comerciais, aprimoramento de diagnósticos de saúde, e vigilância, monitoramento e controle em tempo real, tiveram as respectivas eficiências potencializadas, favorecendo a identificação de padrões vantajosos à tomada de decisão com a evolução da ML. Não obstante, como toda a IA, a subárea não teria pacificado os domínios social e humano, maiormente por questões éticas (Brochado, 2023; Galiana, Gudino e González, 2024), políticas (Cóbe *et al.*, 2020; Mendes, 2022) e jurídicas (Souza, 2020; Siqueira e Wolowski, 2022).

O questionamento estaria alicerçado em aspectos como a dependência de grandes volumes de dados de alta qualidade (Leite e Ribeiro, 2023; Santos *et al.*, 2024), os quais poderiam proporcionar a reprodução e perpetuação de preconceitos. Isso originaria viés

algorítmico, ou seja, fornecimento de resultados discriminatórios ou injustos, favorecendo ou prejudicando determinados indivíduos, o que impediria a justiça algorítmica. Essa entendida como a mitigação da discriminação pela transparência e responsabilidade no desenvolvimento de algoritmos de IA (Paiva e Woropo, 2025).

Os apontamentos anteriores convergiriam a dificuldade que pessoas físicas poderiam apresentar para o entendimento e a explicação sobre as decisões ou resultados de ML, o que comprometeria negativamente a confiança e aceitação do algoritmo, em particular em aplicações voltadas às áreas de saúde e finanças, as quais demandariam elevada responsabilidade sobre as decisões e submissão à auditoria, o que incluiria identificação de erros e vieses (Kava *et al.*, 2022; Junior *et al.*, 2025). Valeria salientar a existência de relação direta entre interpretação humana e complexidade dos modelos.

O custo computacional de treinamento poderia ser demasiadamente elevado, não somente pela obtenção e modelagem dos bancos de dados, mas, também, pela necessidade de processadores especializados em tarefas de alta demanda, como unidades de Processamento Gráfico (GPU) utilizadas em processamento paralelo (divisão do problema complexo em partes a serem resolvidas simultaneamente em núcleos diversos) ou Unidades de Processamento Tensorial (TPU), circuitos integrados de aplicação específica, especificamente operações matriciais, o que favorece o desempenho em ML (Lopes *et al.*, 2020; Andrade, Santos e Freitas, 2023; Moraes *et al.*, 2025).

Normalmente, o banco de dados seria dividido em grupos de treinamento, teste e validação nos quantitativos 70,00% a 80,00%, 20,00% a 30,00%, e 10,00% das ocorrências, para respectivamente aprendizado e ajuste dos parâmetros, avaliação do desempenho e comparação e seleção do melhor modelo, objetivando garantir eficácia e robustez, evitando resultados falsos, incorretos ou não factuais, mas com aparência de lógicos (*alucinação da inteligência artificial*). Apesar desses cuidados, poderia o modelo se adaptar excessivamente ao conjunto de treinamento (*overfitting*), tornando-se inútil por disponibilizar resultados generalizados (Correia, 2018; Corcovia e Alves, 2019; Barros, 2020; Junior *et al.*, 2025).

Tendências e Evolução

O desenvolvimento de métodos e ferramentas para facilitar a compreensão dos modelos e respectivos resultados de IA originou o campo de pesquisa denominado Inteligência Artificial Explicável (*Explainable AI - XAI*), cujo objetivo seria favorecer o

entendimento e a auditoria de modelos complexos como aprendizagem profunda (*deep learning*), os quais empregariam redes neurais com múltiplas camadas, cada uma realizando determinado processamento, tornando progressivo o aprendizado do modelo, mas dificultando a interpretação por pessoas físicas (Dwivedi *et al.*, 2023; Pradhan *et al.*, 2023).

A associação da ML com a Internet das Coisas (IoT), *Tiny Machine Learning* - TinyML, pretenderia desenvolver dispositivos minúsculos, autônomos e seguros para coletar dados, processar modelos e fornecer resultados, a partir de limitados recursos computacionais e com baixo consumo de energia, e sem utilização acessória de entidades externas. As vantagens inerentes seriam a baixa latência, dada a resposta em tempo real; aumento da privacidade para dados sensíveis; necessidade de conectividade limitada à internet; e custo reduzido. Esse conjunto proporcionaria maior acesso à ML pelos diversos segmentos sociais e econômicos (Tsoukas *et al.*, 2024; Kallimani *et al.*, 2024).

Similares desafios existiriam na proposta de treinamento descentralizado, preservando a privacidade, ou seja, a Aprendizagem Federada (*Federated Learning*), na qual os modelos seriam treinados em dispositivos remotos ou centros de dados isolados, mantendo os dados localmente. Isso envolveria ML em larga escala, utilizando redes heterogêneas e massivas, exigindo otimização distribuída e de privacidade (LI *et al.*, 2020; LI L *et al.*, 2020).

Modelos generativos (*Generative AI*), como GPT-4, DALL-E, Stable Diffusion, DeepSeek e Copilot, utilizariam dados de treinamento para gerar conteúdos em formato de texto, imagem ou áudio, cujas aplicações abarcaria modelos de linguagem, educação, inovação, marketing e pesquisa acadêmica, por exemplo. Entretanto, a tendência seria a extrapolação a sistemas sociotécnicos, especificamente, sistemas de informação para auxiliarem o planejamento, a organização, direção e o controle no contexto das Organizações (Euchner, 2023; Feuerriegel *et al.*, 2024).

À primeira luz, a democratização da ML incluiria a implementação de modelos por não especialistas, o que requisitaria o desenvolvimento do Aprendizado de Máquina Automatizado (*Automated Machine Learning* – AutoML) e Aprendizado de Máquina sem Código (*No-code Machine Learning* – No-code ML). No primeiro caso, a ideia seria automatizar tarefas complexas, porém repetitivas como preparação de dados, seleção de variáveis ou atributos, eleição do algoritmo adequado e ajuste de hiperparâmetros, para tanto o emprego autônomo de diversas combinações de testes deveria assegurar a alta

acurácia e eficiência do modelo. Na segunda proposta, o protagonismo seria reservado à eliminação da codificação, então, o desenvolvimento seria realizado com interfaces visuais. Com esse foco, o objetivo faria morada na acessibilidade e facilidade de utilização de plataformas gráficas, particularmente para aplicações empresariais (Simons *et al.*, 2023; Truss e Schmitt, 2025).

Finalmente, a interseção entre ML e computação quântica criou o ML Quântico (QML), que almejaria a resolução de problemas demasiadamente complexos para a computação clássica, como simulação de moléculas para novos fármacos, criação de materiais supercondutores ou baterias de amplo armazenamento, otimização de desenho aerodinâmico e planejamento de produção, e sistemas de criptografia, por exemplo. Assim, os dados de entrada seriam codificados em estados quânticos (qubits) e seriam submetidos ao processamento com portas parametrizadas. As estimativas aproveitariam o paralelismo, elevando exponencialmente a eficiência computacional, em particular no uso de banco de dados volumosos e complexos. A extração de padrões seria realizada por aferições, ajustando o modelo para alcance da otimização (Miano, 2021; Gomes *et al.*, 2024).

Considerações Finais

A investigação discutiu a Aprendizagem de Máquina, conceituando-a. A comparação entre os principais tipos de modelagem demonstrou a vasta linha de pesquisa, substancializada em diversas aplicações à Administração, Saúde e Educação Física. Em qualquer caso, presente estariam as limitações de diversas ordens, transcendendo o domínio da informática, ou mesmo, das ciências exatas. Isso possibilitou concluir que a ML deteria adequações aos problemas das áreas citadas, entretanto, necessário seria não a compreender por solução, mas como recurso.

Necessário será aprofundar a discussão sobre os modelos básicos, apresentando os aspectos matemáticos e aplicações específicas. A demonstração de emprego associado a modelos de árvores de decisão, regressão e redes neurais, por exemplo, lançaria luz nas possibilidades de apoio à decisão, especialmente, na consideração das especificidades das áreas focadas. O desenvolvimento de modelos nas complexas fronteiras desenhadas pela Economia da Saúde, Comportamento do Consumidor, Saúde Pública, Atenção Primária à Saúde, dentre outras, tende a demonstrar a versatilidade pragmática de aplicações, especialmente na manutenção de eficiência e robustez.

Referências

- ABBOTT, R. The Reasonable Robot-Introdução: a inteligência artificial e a lei. **Revista Rede de Direito Digital, Intelectual & Sociedade**, v. 1, n. 1, p. 17-44, 2021.
- AFONSO, AR; DUQUE, CG. Análise de sentimentos em comentários de vídeos do YouTube utilizando aprendizagem de máquinas supervisionada. **Ciência da Informação**, v. 48, n. 3, p. 21-33, 2019.
- AHMED, MN *et al.* Cognitive computing and the future of health care cognitive computing and the future of healthcare: the cognitive power of IBM Watson has the potential to transform global personalized medicine. **IEEE pulse**, v. 8, n. 3, p. 4-9, 2017
- ALMEIDA, MV. **Aplicação de autocodificador variacional para agrupamento de sequência de anticorpos**. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Departamento de Computação. Centro de ciências. Universidade Federal do Ceará. Fortaleza (CE), 2024.
- ALVES, LAM. **Classificação de distúrbios de qualidade da energia utilizando técnicas de aprendizado de máquina**. Monografia (Bacharelado em Engenharia Elétrica) – Departamento de Engenharias. Universidade Federal Rural do Semi-árido. Caraúbas (RN), 2025.
- ANDRADE, HGV *et al.* Desenvolvimento de Tecnologias Assistivas, de baixo custo, para mobilidade autônoma de pessoas cegas. **Revista de Sistemas e Computação-RSC**, v. 12, n. 2, p. 25-33, 2022.
- ANDRADE, MS; SANTOS, J; FREITAS, J. Sistema de detecção de intrusão utilizando métodos de aprendizagem de máquina em redes de computadores. **Revista de Ciência e Inovação**, v. 9, n. 1, p. 22-22, 2023. <https://doi.org/10.26669/2448-4091.2023.388>
- ANTUNES, MBA; ISSA, MF; HOED, RM. Técnicas de machine learning aplicada a mineração de dados e análise de sentimentos para predição de homofobia no twitter. **Revista Foco (Interdisciplinary Studies Journal)**, v. 16, n. 1, 2023. DOI: 10.54751/revistafoco.v16n1-121
- ARAÚJO, LLS. **Implementação de modelo de aprendizado por reforço em dispositivo móvel para economia de combustível em veículos a combustão**. Trabalho de Conclusão de Curso (Bacharelado em Mecatrônica) – Centro Tecnológico de Joinville. Universidade Federal de Santa Catarina. Joinville (SC), 2025.
- ATHAYDE, JMD. **Predição de lesões em cross training**: um estudo comparativo com algoritmos de aprendizado de máquina. Dissertação (Mestrado em Computação) – Programa de Pós-graduação em Computação. Universidade Federal do Rio Grande. Rio Grande (RS), 2025.
- AZEVEDO, RB. **Métodos de Machine Learning para seleção de variáveis com aplicações ao Rugby Sevens Feminino**. Trabalho de Conclusão de Curso (Bacharelado em Ciências Atuariais) – Faculdade de Ciências Econômicas. Universidade Federal do Rio Grande do Sul. Porto Alegre (RS), 2019.
- BARRETO, ACLG; BRASIL, RM; JUNIOR, HSN. O paradoxo de Moravec e a educação física: dualidade inteligência e intelectualidade. **Revista Presença**, v. 10, n. 22, p. 273-289, 2024.
- BARROS, DMS. **Uma arquitetura digital baseada em aprendizagem de máquina para diagnóstico de doenças oculares**: um estudo aplicado ao glaucoma. Tese (Doutorado) - Programa de Pós-Graduação em Engenharia Elétrica e de Computação. Universidade Federal do Rio Grande do Norte. Natal (RN), 2020.
- BATISTA, EM; MENEZES, JPCB. Aplicação da aprendizagem de máquina na análise de crédito no setor de comércio de medicamentos. **RAGC**, v. 16, p. 70-89, 2024.

BATISTA, JGS; OLIVEIRA, MGS; GUIDOLIN, LG. Rede neural convolucional aplicada ao diagnóstico de meningite. **Iguazu Science**, v. 3, n. 7, p. 59-66, 2025.

BIAU, G; SCORNET, E. A random forest guided tour. **Test**, v. 25, p. 197-227, 2016.

BORTOLINI, V. **Utilização de aprendizagem de máquina para predição do diagnóstico do Covid-19**. Monografia (Bacharelado em Sistemas de Informação) – Instituto Federal de Santa Catarina. Caçador (SC), 2021.

BOYKO, N; LUKASH, O. Methodology for estimating the cost of construction equipment based on the analysis of important characteristics using machine learning methods. **Journal of engineering**, v. 2023, n. 1, p. 1–27, 2023.

BRANQUINHO, FJF. **Compreensão da multimorbilidade na adolescência através de aprendizagem não supervisionada**. Dissertação (Mestrado em Estatística Computacional e Análise de Dados) – Departamento de Matemática. Faculdade de Ciências. Universidade do Porto. Porto (Portugal), 2024.

BROCHADO, M. Inteligência artificial e ética: um diálogo com Lima Vaz. **Kriterion: Revista de Filosofia**, v. 64, n. 154, p. 75-98, 2023.

BRYDA, G; COSTA, AP. Tecnologias transformativas: inteligência artificial e grandes modelos de linguagem na pesquisa qualitativa. **Revista Baiana de Enfermagem**, v. 38, 2024. DOI: 10.18471/rbe.v38.61024

BURT, FJ *et al.* chikungunya virus: an update on the biology and pathogenesis of this emerging pathogen. **The Lancet Infectious Diseases**, v. 17, n. 4, e107, 2017.

CAMARGO-VEGA, JJ; CAMARGO-ORTEGA, JF; JOYANES-AGUILAR, L. Conociendo big data. **Revista Facultad de Ingeniería**, v. 24, n. 38, p. 63-77, 2015.

CAMPOS, DHC; RODRIGUES, EO; CAMPOS, EC. Criação e validação de uma base de dados com elementos do trânsito brasileiro para veículos autônomos. **Brazilian Applied Science Review**, v. 4, n. 3, p. 1578-1590, 2020.

CHEN, J *et al.* Big data challenge: a data management perspective. **Frontiers of computer Science**, v. 7, n. 2, p. 157-164, 2013.

CÓBE, RMO *et al.* Rumo a uma política de Estado para inteligência artificial. **Revista USP**, n. 124, p. 37-48, 2020.

CONCEIÇÃO, ES. **Estudo in silico na busca de alcaloides potencialmente inibidores de Staphylococcus aureus**. Dissertação (Mestrado em Química) – Programa de Pós-graduação em Química. Universidade Federal de Sergipe. São Cristóvão (SE), 2023.

CONTI, GEG; GRAF, JMP. Análise e previsão do preço do ethereum utilizando redes neurais LSTM. **Iguazu Science**, v. 3, n. 7, p. 19-27, 2025.

CORCOVIA, LO; ALVES, RS. Aprendizagem de Máquina e Mineração de Dados: avaliação de métodos de aprendizagem. **Revista Interface Tecnológica**, v. 16, n. 1, p. 90-101, 2019.

CORREIA, SEB. **Classificação de valores humanos baseado em texto usando aprendizagem de máquina**. Trabalho de conclusão de curso (Bacharelado em Sistemas de Informação) – Departamento de Ciências Exatas. Universidade Federal da Paraíba. Rio Tinto (PB), 2018.

COSTA, EL; MOURA JÚNIOR, JRV. Aprendizado por reforço como ferramenta na tomada de decisão em investimentos em bolsa de valores. **Observatório de la Economía Latinoamericana**, v. 21, n. 11, p. 22437–22457, 2023.

DAMKE, GT; DAMKE, MT; GREGORINI, DM. Revisão de abordagens baseadas em aprendizado de máquina para o diagnóstico de diabetes mellitus tipo 2. **Revista Caribeña De Ciencias Sociales**, v. 14, n. 2, e4449, 2025.

DARRIEUX, F; WU, TC. Métodos de inteligência artificial para detecção de fibrilação atrial assintomática. Uma oportunidade para novas abordagens de prevenção e o papel do olho do médico. **Arquivos Brasileiros de Cardiologia**, v. 121, n. 9, p. e20240662, 2024.

DOLGOV, AM; LYUKEVICH, IN; DOLGOV, VM. Application of machine learning methods in pricing. **Vestnik Altai Academy of Economics and Law**, v. 1, n. 4, p. 52-59, 2022.

DWIVEDI, R *et al.* Explainable AI (XAI): Core ideas, techniques, and solutions. **ACM computing surveys**, v. 55, n. 9, p. 1-33, 2023.

ESTRADA, M. Revisión Sistemática y Metaanálisis: Relojes Inteligentes versus Electrocardiograma Normal para la Detección de Arritmias Cardíacas. **Revista Médica Cunoc**, v. 1, n. 1, p. 118-127, 2025.

EUCHNER, J. Generative ai. **Research-Technology Management**, v. 66, n. 3, p. 71-74, 2023.

FARIA, AJL. **O potencial dos sistemas inteligentes na monitorização e tomada de decisão médica ao longo da jornada perinatal**: uma revisão de escopo. Trabalho de Conclusão de Curso (Bacharelado em Medicina) - Departamento de Ciências da Saúde. Universidade Federal de Santa Catarina. Araranguá (SC), 2024.

FERNANDES, JD'APB *et al.* Learning Analytics como tecnologia de avaliação da aprendizagem no modelo Blended Learning: uma revisão sistemática da literatura. In: LIMA, MAM; SILVA, DM (org.). **Avaliação de programas educacionais**: diversidade de estudos e pesquisas. Rio de Janeiro: e-Publicar, 2020. cap. 10, p. 159-184.

FERREIRA, AS. **Redes neurais convolucionais profundas na detecção de plantas daninhas em lavoura de soja**. Dissertação (Mestrado em Ciências da Computação) – Faculdade de Computação. Universidade Federal de Mato Grosso do Sul. Campo Grande (MS), 2017.

FEUERRIEGEL, S *et al.* Generative ai. **Business & Information Systems Engineering**, v. 66, n. 1, p. 111-126, 2024.

FRANCO, GMS *et al.* A estratégia de machine learning em medicina esportiva para avaliação do lactato como chave do imunometabolismo. **Revista Eletrônica Interdisciplinar**, v. 17, n. 2, p. 94-105, 2025.

FRANCO, RJ. **ChatEduc–Uma Plataforma de Chatbot para autoavaliação e apoio à formação de Competências Digitais nos Educadores**. Tese (Doutorado em Educação) - Programa de Pós-Graduação em Educação. Faculdade de Educação. Universidade Estadual de Campinas. Campinas (SP), 2024.

GABRIEL FILHO, O. **Inteligência artificial e aprendizagem de máquina**: aspectos teóricos e aplicações. São Paulo: Blucher, 2023.

GALIANA, LI; GUDINO, LC; GONZÁLEZ, PM. Ética e inteligencia artificial. **Revista Clínica Española**, v. 224, n. 3, p. 178-186, 2024.

GIJSBERS, P *et al.* Amlb: an automl benchmark. **Journal of Machine Learning Research**, v. 25, n. 101, p. 1-65, 2024.

GOMES, BDV. **Metodologias de design para produtos têxteis inteligentes na área do desporto**. Tese (Doutorado em Design de Moda) – Escola de Engenharia. Universidade do Minho. Braga (Portugal), 2022.

GOMES, ND *et al.* Introdução ao aprendizado de máquina quântico, suas aplicações e vantagens. **Revista Brasileira de Ensino de Física**, v. 46, e20240230, 2024.

GONÇALVES, MC *et al.* Integrating machine learning for predicting future automobile prices: a practical solution for enhanced decision-making in the automotive industry. **Lecture Notes in Computer Science**, v. 14316, n. I3E 2023, p. 91–103, 15 2023.

GOUVEIA JR, A. O conceito de modelo e sua utilização nas ciências do comportamento: breves notas introdutórias. **Revista Estudos de Psicologia**, v. 16, n. 1, p. 13-16, 1999.

HÄRTER, FP. **Redes neurais recorrentes aplicadas à assimilação de dados em dinâmica não-linear**. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais. São José dos Campos (SP), 2007.

HENRICH, R *et al.* **Aprendizado de máquina aplicado na previsão do tempo de sobrevida em pacientes com câncer de pulmão**. Dissertação (Mestrado em Ciência da Computação) – Escola Politécnica. Pontifícia Universidade Católica do Rio Grande do Sul. Porto Alegre (RS), 2025.

IVAKHNENKO, AG; LAPA, VG. **Cybernetic predicting devices**. CCM Information Corporation 1965.

JAPIASSÚ, H; MARCONDES, D. **Dicionário básico de filosofia**. Rio de Janeiro: Zahar, 1990.

JIN, H *et al.* Autokeras: An automl library for deep learning. **Journal of machine Learning research**, v. 24, n. 6, p. 1-6, 2023.

JULIANI, JP. Predição de evasão em cursos EAD: um modelo baseado em árvore de decisão que integra causas exógenas e endógenas. **EaD Em Foco**, v. 15, n. 1, e2504, 2025.

JUNIOR, HSN *et al.* Lead da inteligência artificial na área de saúde. **Revista Presença**, v. 11, n. 26, p. 356-368, 2025.

JÚNIOR, JFC *et al.* A inteligência artificial como ferramenta de apoio no ensino superior. **Rebena-Revista Brasileira de Ensino e Aprendizagem**, v. 6, p. 246-269, 2023.

KALLIMANI, R *et al.* TinyML: Tools, applications, challenges, and future research directions. **Multimedia Tools and Applications**, v. 83, n. 10, p. 29015-29045, 2024.

KAVA, LE *et al.* **Além da caixa preta: aprendizagem de máquina interpretável para previsão de séries temporais macroeconômicas brasileiras**. Dissertação (Mestrado em Economia) - Programa de Pós-Graduação em Economia. Centro Sócio-Econômico. Universidade Federal de Santa Catarina. Florianópolis (SC), 2022.

KRAUS, G. "Den „Zeitgeist“ für Change- und Transformationsprojekte nutzen". **Zeitschrift für wirtschaftlichen Fabrikbetrieb**, v. 120, n. 6, p. 441-443, 2025.

KRAUSE, M. What is Zeitgeist? Examining period-specific cultural patterns. **Poetics**, v. 76, a. 101352, 2019.

LAUNÉ, ARF *et al.* Alzheimer x inteligência artificial: construindo um futuro memorável. **Aracê**, v. 7, n. 1, p. 1822-1834, 2025.

LECKEY, C *et al.* Machine learning approaches to injury risk prediction in sport: a scoping review with evidence synthesis. **British Journal of Sports Medicine**, v. 59, p. 491–500, 2025.

LECUN, Y; BENGIO, Y; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.

LEITE, EH; RIBEIRO, DF. O papel transformador da inteligência artificial na segurança. **Revista Interface Tecnológica**, v. 20, n. 1, p. 181-190, 2023.

- LI, L *et al.* A review of applications in federated learning. **Computers & Industrial Engineering**, v. 149, p. 106854, 2020.
- LI, T *et al.* Federated learning: Challenges, methods, and future directions. **IEEE signal processing magazine**, v. 37, n. 3, p. 50-60, 2020.
- LIN, X. A model of big data-based governance: China's National Government big Data Platform and an analysis of its governance competence. **Chinese Political Science Review**, p. 1-40, 2025. <https://doi.org/10.1007/s41111-025-00279-1>.
- LOPES, MPC *et al.* Reconhecimento de estresse via eletrocardiograma utilizando dimensionalidade reduzida e aprendizagem de máquina. **Journal of Health Informatics**, v. 12, número especial, p. 418-423, 2020.
- LORENA, AC; CARVALHO, ACPLF. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43-67, 2007.
- MACHADO, HG; MUNDIM, K. Revisão das tecnologias de inteligência artificial e machine/deep learning: restrições, oportunidades, estado da arte e desafios. **Revista Processos Químicos**, v. 16, n. 32, p. 9-22, 2022.
- MACHADO, VS. **Fármacos aprovados pela FDA e ANVISA desenvolvidos com o uso de Inteligência Artificial, uma revisão sistemática**. Trabalho de Conclusão de Curso (Bacharelado em Farmácia) - Departamento de Ciências Farmacêuticas. Centro de Ciências da Saúde. Universidade Federal de Santa Catarina. Florianópolis (SC), 2023.
- MAGALHÃES, NS. O que são mapas auto organizáveis na aprendizagem não supervisionada. **Journal of Production and Automation (JPAUT)**, v. 4, n. 2, p. 26-29, 2021.
- MARX, V. The big challenges of big data. **Nature**, v. 498, n. 7453, p. 255-260, 2013.
- MAYO, AJ; NOHRIA, N. Zeitgeist leadership. **Harvard Business Review**, v. 83, n. 10, p. 45-60, 2005.
- MECHELLI, A; VIEIRA, S. **Machine learning: methods and applications to brain disorders**. São Paulo: Academic Press, 2019.
- MELO, ALB; ALVES, ALF. Aplicação de técnicas de aprendizagem de máquina para diagnóstico de depressão, ansiedade e estresse. *In: Anais Encontro Nacional de Computação dos Institutos Federais (ENCOMPIF)*, 9, 2022, Niterói. Porto Alegre (RS): Sociedade Brasileira de Computação, 2022. p. 13-16
- MELO, VL. **Algoritmos de aprendizado de máquina para a previsão de preços de venda de flats em João Pessoa - PB**. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) – Departamento de Engenharia de Produção. Centro de Tecnologia. Universidade Federal da Paraíba. João Pessoa (PB), 2025.
- MELO, WP. O impacto da inteligência artificial na educação: potencialidades e desafios. **Revista Eletrônica Ciência & Tecnologia Futura**, v. 1, n. 2, p. 53-69, 2024.
- MENDES, V. A economia política da inteligência artificial: o caso da Alemanha. **Revista de Sociologia e Política**, v. 30, e003, 2022.
- MIANO, MG. Desempenho de algoritmos quânticos e clássicos em treinamento de machine learning supervisionado. **Revista Tecnológica da Fatec de Americana**, v. 9, n. 02, p. 81-99, 2021.
- MONEZI, LA. **Localização de jogadores de basquetebol e estimativa da frequência cardíaca em jogos oficiais: aplicações baseadas em aprendizado de máquina e otimização combinatória**.

Dissertação (Mestrado em Ciências da Nutrição e do Esporte e Metabolismo) – Faculdade de Ciências Aplicadas. Universidade Estadual de Campinas. Limeira (SP), 2016.

MONTEIRO, MB *et al.* Avanços e desafios no uso da Inteligência Artificial na prática cirúrgica: uma revisão bibliográfica. **Caderno Pedagógico**, v. 22, n. 9, e18219, 2025.

MORAES, B *et al.* Aprendizagem de máquina quântica: fundamentos, potencial e desafios para a formação científica. **Premium Handbook of Science and Technology**, v. 1, n. 01, p. 41-50, 2025.

MUDDE, C. The populist Zeitgeist. **Government and Opposition**, v. 39, n. 4, p. 541–563, 2004.

NABINGER, AM. **Utilização de algoritmos do tipo machine learning supervisionado para a caracterização dos resultados da copa do mundo de futebol de 2018**. Trabalho de Conclusão de Curso (Bacharelado em Estatística) – Departamento de Estatística. Instituto de Matemática e Estatística. Universidade Federal do Rio Grande do Sul. Porto Alegre (RS), 2018.

NELSON, DMQ. **Uso de redes neurais recorrentes para previsão de séries temporais financeiras**. Dissertação (Mestrado em Ciência da Computação) - Instituto de Ciências Exatas. Universidade Federal de Minas Gerais. Belo Horizonte (MG), 2017.

NOGARA, WZN. **Construção de modelos para previsão de resultados em partidas de tênis utilizando machine learning**. Trabalho de Conclusão de Curso (Bacharelado em Estatística) – Faculdade de Ciências e Tecnologia. Universidade Estadual Paulista “Júlio de Mesquita Filho”. Presidente Pudente (SP), 2023.

NUNES, FASF. **Modelos preditores de contratação de profissionais do futebol baseado em inteligência artificial por mecanismos machine learning**. Tese (Doutorado em Administração) - Programa de Pós-Graduação em Administração. Universidade Federal de Minas Gerais. Belo Horizonte (MG), 2025.

NUNES, HC; GUIMARÃES, RMC; DADALTO, L. Desafios bioéticos do uso da inteligência artificial em hospitais. **Revista bioética**, v. 30, n. 1, p. 82-93, 2022.

OLIVEIRA, AF. **Localização 3D em ambientes internos com redes bluetooth low energy utilizando técnicas de aprendizado de máquina**. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-graduação em Engenharia Elétrica. Instituto de Ciência e Tecnologia de Sorocaba. Universidade Estadual Paulista “Júlio de Mesquita Filho”. Sorocaba (SP), 2021.

OLIVEIRA, JS; NEVES, IBS. Inteligência artificial, ChatGPT e estudos organizacionais. **Revista Organização & Sociedade**, v. 30, n. 106, p. 397-409, 2023.

PAIVA, HWA. Inteligência artificial e aprendizado de máquina na sociedade moderna. **ERR01**, v. 10, n. 2, p. 117-134, 2025.

PALMAS, PO. **Aplicação de machine learning na previsão de desvios e controlo orçamental na Força Aérea Portuguesa**. Dissertação (Mestrado em Contabilidade. Fiscalidade e Finanças Empresarias) – Faculdade de Economia e Gestão de Lisboa. Universidade de Lisboa. Lisboa (Portugal), 2023.

PAZ, MFC. **Segmentação não supervisionada em microscopia de bactérias**. Dissertação (Mestrado em Engenharia Informática) – Departamento de Informática. Universidade NOVA de Lisboa. Lisboa (Portugal), 2021.

PEREIRA, AA. **Aplicação da associação iot para o aprendizado de máquina em borda de modelos preditivos em um raspberry PI**. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica. Universidade Federal do Pará. Tucuruí (PA), 2021.

PEREIRA, JB; MANJON, K; SOUZA, RB. O uso da inteligência artificial como estratégia de minimização de riscos de lesões no esporte: revisão bibliográfica. **Revisa**, v. 32, p. 85-97, 2023.

PIMENTA, MF; PUGLIESI, JB. Reconhecimento de gêneros musicais com técnicas de aprendizagem de máquina supervisionada. **Revista Eletrônica de Computação Aplicada**, v. 3, n. 1, p. 23-46, 2022.

PIRES, K. **Aplicação da inteligência artificial em sistemas de visão noturna para ADAS e veículos autônomos**: uma revisão sistemática. Trabalho de Conclusão de Curso (Bacharelado em Tecnologias da Informação e Comunicação) – Centro de Ciências, Tecnologias e Saúde. Universidade Federal de Santa Catarina. Araranguá (SC), 2025.

PRADHAN, B *et al.* An explainable AI (XAI) model for landslide susceptibility modeling. **Applied Soft Computing**, v. 142, p. 110324, 2023.

PUJÓ, M. Zeitgeist – el espíritu de la época. **Leitura Flutuante**, v. 5, n. 1, p. 3-29, 2013.

RAHMAN, W. **Inteligência artificial e aprendizado de máquina**. São Paulo: Senac, 2022.

RODRIGUES, JP; PRUDÊNCIO, RBC; BARROS, FA. B-boost: Uma extensão do método de boosting para conjuntos de treinamento desbalanceados. In **Anais Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)**. SBC, 2009. p. 412-421.

RODRIGUES, OS; RODRIGUES, KS. A inteligência artificial na educação: os desafios do ChatGPT. **Texto Livre**, v. 16, e45997, 2023.

ROLLE, RP. **Deteção e localização de vazamentos utilizando internet das coisas e aprendizado de máquina**. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia. Universidade Estadual Paulista "Júlio de Mesquita Filho". Bauru (SP), 2024.

ROSENBLATT, F. The Perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386-408, 1958.

ROSSI, RG. **Classificação automática de textos por meio de aprendizado de máquina baseado em redes**. Tese (Doutorado em Ciências da Computação e Matemática Computacional). Universidade de São Paulo. São Carlos (SP), 2015.

RUMELHART, DE; HINTON, GE; WILLIAMS, RJ. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533–536, 1986.

SAIJO, AH. **Um estudo sobre modelos preditivos para resultados de jogos da NBA**. Dissertação (Mestrado em Matemática Aplicada e Computacional) – Instituto de Matemática, Estatística e Computação Científica. Universidade Estadual de Campinas. Campinas (SP), 2023

SANTAELLA, L. **Há como deter a invasão do ChatGPT?** São Paulo: Estação das Letras e Cores, 2023.

SANTANA, LHB *et al.* Utilização inovadora do machine learning para a segmentação da carteira de clientes em uma empresa de hortifrutigranjeiros de grande porte. **Caderno de Propriedade Intelectual e Transferência de Tecnologia**, v. 5, n. 1, p. 26-40, 2023.

SANTOS, AC. **Aprendizado de máquina aplicado na deteção de fraudes em cartão de crédito**. Monografia (Graduação em Estatística) - Instituto de Ciências Exatas e Biológicas. Universidade Federal de Ouro Preto. Ouro Preto (MG), 2023.

SANTOS, AD. **Ranking ligands in structure-based virtual screening using siamese neural networks**. Dissertação (Mestrado em Ciência da Computação) - Programa de Pós-Graduação em Ciência da Computação. Pontifícia Universidade Católica do Rio Grande do Sul. Porto Alegre (RS), 2017.

SANTOS, FAO *et al.* Estimativas de níveis de obesidade utilizando machine learning: explorando fatores contributivos e modelos preditivos para a prevenção e intervenção na obesidade. **Revista Científica da UNIFENAS-ISSN: 2596-3481**, v. 6, n. 5, p. 69-73, 2024.

SANTOS, H; LOPES, AA. A Inteligência Artificial nas ciências da saúde: oportunidades, desafios e perspectivas futuras. **RevSALUS-Revista Científica Internacional da Rede Acadêmica das Ciências da Saúde da Lusofonia**, v. 6, n. 1, 2024. Doi: <https://doi.org/10.51126/revsalus.v6i1.653>

SEGURA, FM *et al.* Machine learning en medicina deportiva. Evaluación del riesgo de tendinopatía rotuliana en atletas de alto nivel. **Relart**, v. 32, n. 2, p. 119-127, 2025.

SHEN, L. **Classificação de imagens de CT de tórax no contexto da COVID-19**. Dissertação (Mestrado em Ciências da Computação) – Instituto de Matemática e Estatística. Universidade de São Paulo. São Paulo, 2025.

SICSÚ, AL; SAMARTINI, A; BARTH, NL. **Técnicas de machine learning**. São Paulo: Blucher, 2023.

SILVA, FA. **Uma abordagem para localização em ambientes internos baseada em impressão digital do sinal de Wi-Fi e aprendizagem de máquina**. Dissertação (Mestrado em Informática) - Centro de Informática. Universidade Federal da Paraíba. João Pessoa (PB), 2020.

SILVA, GL. **Aprendizado de máquina aplicado à análise de imagens de ressonância magnética para detecção de cardiomiopatias**. Monografia (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação. Universidade de São Paulo. São Carlos (SP), 2023.

SILVA, JAF. **Análise comparativa de algoritmos de aprendizagem de máquina para diagnóstico da doença de Parkinson com base em características vocais**. Monografia (Bacharelado em Engenharia de Computação) - Instituto de Engenharias e Desenvolvimento Sustentável. Universidade da Integração Internacional da Lusofonia Afro-Brasileira. Redenção-Ceará, 2024.

SILVA, LV. **Aprendizado de máquina aplicado ao roteamento de veículos com janelas de tempo**. Dissertação (Mestrado em Matemática Aplicada) – Instituto de Matemática, Estatística e Computação Científica. Universidade Estadual de Campinas. Campinas (SP), 2025.

SILVA, RAD. **Machine learning para a predição da carga de treinamento de um atleta da Seleção Brasileira de Taekwondo**. Monografia (Especialização em Estatística Aplicada) – Programa de Pós-graduação em Estatística. Instituto de Ciências Exatas. Universidade Federal de Minas Gerais. Belo Horizonte (MG), 2023.

SILVA, REV. **Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens**. Trabalho de Conclusão de Curso (Graduação em Sistemas de Informação) Universidade Federal do Ceará, Quixadá (CE), 2018.

SILVESTRI, F; SOUZA, VF; VIEIRA, A. Mineração de dados educacionais: uma análise sobre os preditores da evasão no Ensino Superior. **Revista Educar Mais**, v. 9, p. 1-23, 2025.

SIMONS, M *et al.* **Künstliche Intelligenz mit AutoML, Low-Code und No-Code: Eine Markterhebung von Software-Tools**. Bad Honnef (Deutschland): Wissenschaftliches Institut für Infrastruktur und Kommunikationsdienste, 2023.

SIMONTON, DK. **Creativity in science: chance, logic, genius, and Zeitgeist**. Cambridge (UK): Cambridge University Press, 2004.

SIQUEIRA, DP; WOLOWSKI, MRO. Inteligência artificial e o positivismo jurídico: benefícios e obstáculos para efetivação da justiça. **Revista Brasileira de Direito**, v. 18, n. 1, e 4718, 2022.

SOARES, JVC. **Previsão de lesões de esportistas utilizando técnicas de aprendizagem de máquina em uma revisão de literatura**. Trabalho de Conclusão de Curso (Bacharelado em Informática) – Centro de Informática. Universidade Federal da Paraíba. João Pessoa (PB), 2025.

SOUSA, CEP *et al.* Eficiência de redes neurais convolucionais na identificação de edifícios em condições desafiadoras de imagens. **Observatorio de la Economía Latinoamericana**, v. 23, n. 5, 2025. DOI: 10.55905/oelv23n5-173.

SOUZA, CFC *et al.* Previsão da incidência de câncer por gênero em belo horizonte: inovação no uso de redes neurais artificiais para planejamento de saúde pública. **Aracê**, v. 7, n. 3, p. 15184-15201, 2025.

SOUZA, EN. Dilemas atuais do conceito jurídico de personalidade: uma crítica às propostas de subjetivação de animais e de mecanismos de inteligência artificial. **Civilistica. com**, v. 9, n. 2, p. 1-49, 2020.

SOUZA, MM. Novas tecnologias na educação: recursos para a informação à distância. **Revista Científica FESA**, v. 1, n. 1, p. 80–93, 2021.

SOUZA, VSS. **Introdução à interpretabilidade de redes neurais convolucionais**. Monografia (Graduação em Ciência da Computação) - Instituto de Ciências Exatas e Biológicas. Universidade Federal de Ouro Preto, Ouro Preto (MG), 2023.

TRUSS, M; SCHMITT, M. Human-centered ai product prototyping with no-code automl: Conceptual framework, potentials and limitations. **International Journal of Human–Computer Interaction**, v. 41, n. 15, p. 9304-9319, 2025.

TSOUKAS, V *et al.* A Review on the emerging technology of TinyML. **ACM Computing Surveys**, v. 56, n. 10, p. 1-37, 2024.

TURING, AM. Computing machinery and intelligence. **Mind**, v. LIX, n. 236, p. 433-460, 1950.

VAPNIK, VN. **The nature of statistical learning theory**. New York (USA): Springer-Verlag, 1995.

VEDANA, AB *et al.* Inteligência artificial na medicina diagnóstica. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 11, p. 765-794, 2024.

VENDRAMINI, HJ; SALDIAS, CEP; TAVARES, AA. Análise de dados para predição de cenários da matriz elétrica nacional para 2050. **Revista Vincci-Periódico Científico do UniSATC**, v. 8, n. 1, p. 117-146, 2023.

VESTERINEN, M; MERO, J; SKIPPARI, M. Big data analytics capability, marketing agility, and firm performance: a conceptual framework. **Journal of Marketing Theory and Practice**, v. 33, n. 2, p. 310-330, 2025.

VITORINO FILHO, VA; GOI, MYO. 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, 2021.

WATZKO, NAM; SAIKALI, LB; HADAS, AF. Decisões algorítmicas e direito à não-discriminação: regulamentação e mitigação de vieses na era da inteligência artificial. **International Journal of Digital Law**, v. 5, n. 3, p. 115–146, 2025.

XAVIER, J. As máquinas podem pensar. **BIOINFO–revista brasileira de bioinformática e biologia computacional**, v. 221, 2021. DOI: 10.51780/978-6-599-275326-14

ZAKIR, J; SEYMOUR, T; BERG, K. Big data analytics. **Issues in Information Systems**, v. 16, n. 2, p. 81-90, 2015.

ZARO, EM; WEBBER, CG. Estudo de caso de desenvolvimento de sistema para manutenção preditiva 4.0. **Revista Produção Online**, v. 22, n. 3, p. 3418-3340, 2022.

ZHENG, R *et al.* Automl for deep recommender systems: A survey. **ACM Transactions on Information Systems**, v. 41, n. 4, p. 1-38, 2023. DOI: <https://doi.org/10.1145/3579355>.