
FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

**O ENSINO DE APRENDIZADO DE MÁQUINA NA EDUCAÇÃO
SUPERIOR: PRÁTICAS PEDAGÓGICAS COM FOCO EM REDES
NEURAS CONVOLUCIONAIS E ÁRVORE DE DECISÃO**

**TEACHING MACHINE LEARNING IN HIGHER EDUCATION:
PEDAGOGICAL PRACTICES FOCUSED ON CONVOLUTIONAL
NEURAL NETWORKS AND DECISION TREES**

Sarita Pereira Guerra*
Marcelo Buscioli Tenorio**

Resumo

O estudo investigou como o ensino superior integra o Aprendizado de Máquina, especialmente técnicas como Redes Neurais Convolucionais, Árvores de Decisão e métodos ensemble. A análise de materiais acadêmicos mostrou que cursos combinam teoria, prática em laboratório e uso de ferramentas como Python e TensorFlow. Metodologias ativas e projetos reais são centrais para o desenvolvimento dos estudantes, embora desafios como falta de base matemática, limitações técnicas e necessidade de capacitação docente ainda dificultem o processo. Conclui-se que a articulação equilibrada entre teoria e prática é essencial para uma formação eficaz em AM.

Palavras-chave: Aprendizado de Máquina; Ensino Superior; Redes Neurais Convolucionais; Árvores de Decisão; Métodos Ensemble.

Abstract

This study investigated how higher education integrates Machine Learning, focusing on Convolutional Neural Networks, Decision Trees, and ensemble methods. The analysis of academic materials showed that courses combine theoretical instruction, laboratory practice, and the use of tools such as Python and TensorFlow. Active learning strategies and real-world projects play a central role in student development, although challenges such as limited mathematical background, technical constraints, and the need for continuous faculty training still hinder progress. The study concludes that a balanced articulation between theory and practice is essential for effective Machine Learning education.

Keywords: Machine Learning; Higher Education; Convolutional Neural Networks; Decision Trees; Ensemble Methods.

* Aluna do curso de Tecnologia em Análise e Desenvolvimento de Sistemas da Faculdade de Presidente Prudente. E-mail: sarita.guerra@fatec.sp.gov.br

**Professor orientador Dr. Em Análise e Desenvolvimento de Sistemas, da Faculdade de Presidente Prudente. E-mail: Marcelo.tenorio@fatec.sp.gov.br

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**1. INTRODUÇÃO**

A explosão do poder computacional, somada ao fluxo interminável de grandes volumes de dados (Big Data), foi o combustível que elevou o Aprendizado de Máquina (AM) a um pilar indispensável e genuinamente revolucionário da inteligência artificial. O AM evoluiu de um nicho especializado para se tornar o principal motor de inovação em praticamente todos os setores. Seu uso em áreas tão diversas quanto sistemas de recomendação, processamento de linguagem natural, diagnósticos médicos de ponta e veículos autônomos evidencia tanto sua abrangência quanto a importância vital de se ter proficiência nesse campo.

Perante essa revolução tecnológica, a cada dia mais intensa e urgente procura do mercado por profissionais qualificados em Aprendizado de Máquina, impõe às instituições de ensino superior um desafio fundamental: a urgente necessidade de preparar seus alunos com os conhecimentos teóricos e práticos que a nova era digital requer.

A aprendizagem de AM, no entanto, é complexa e requer uma abordagem pedagógica cuidadosa. É indispensável ter uma base sólida nos quatro pilares matemáticos: álgebra linear, cálculo, probabilidade e estatística, para se entender profundamente, e não de forma rasa, como os algoritmos funcionam, como nas operações intrincadas com tensores nas CNNs ou nos processos de otimização por gradiente. A evolução da área de Aprendizado Profundo (Deep Learning) ocorre em um ritmo acelerado, com a introdução constante de novos modelos e frameworks, o que torna essencial que o corpo docente esteja sempre atualizado e que os currículos sejam frequentemente revisados.

A natureza aplicada, juntamente com a complexidade dos modelos mais avançados, torna essencial o uso de metodologias de ensino que sejam ativas e práticas (hands-on), isso é ainda mais importante quando se trata de assegurar o acesso a recursos computacionais que demandam um uso intensivo, como é o caso do treinamento de modelos mais pesados (Silva; Oliveira2023).

Nesse panorama dinâmico, este trabalho se torna pertinente ao buscar e organizar as metodologias de ensino aplicadas ao Aprendizado de Máquina no ensino superior, em especial às técnicas avançadas.

O foco do trabalho está em dois grupos de algoritmos que são sofisticados, amplamente utilizados no mercado e, ao mesmo tempo, diferentes em suas aplicações. O Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

primeiro grupo é composto pelas Redes Neurais Convolucionais (CNNs), que são fundamentais para a visão computacional e essenciais para o processamento de imagens.

O ensino é voltado para entender melhor a construção modular (camadas convolucionais, pooling e ativação). Além disso, prioriza a técnica de transferência de aprendizado (Transfer Learning), que é a maneira mais eficiente e realista de lidar com a maioria dos problemas práticos quando se tem poucos dados. A segunda categoria inclui as Árvores de Decisão e suas abordagens de Ensemble.

Embora Árvores de Decisão simples sejam apreciadas por serem facilmente interpretáveis, o aprendizado se aprofunda em métodos ensemble, especialmente o Random Forest (Bagging) e o XGBoost/Gradient Boosting (Boosting), que elevam modelos fracos a potências robustas e de alto desempenho em dados tabulares. Entender o balanço entre viés e variância (bias-variance tradeoff) e a otimização de hiperparâmetros é fundamental para se tornar um especialista nessas técnicas.

Dessa forma, o foco central deste trabalho é investigar quais práticas pedagógicas e metodologias de ensino se sobressaem nas instituições de ensino superior, quais as ferramentas didáticas preferidas (Python, Scikit-learn, Keras/TensorFlow e PyTorch, entre outras) e como se dá o repasse desse conhecimento complexo aos alunos.

Não se trata, portanto, apenas de registrar o estado da arte, mas também de evidenciar desafios que ainda persistem, como a heterogeneidade na formação matemática dos estudantes e, em última análise, contribuir para que currículos e estratégias de ensino-aprendizagem sejam cada vez mais eficazes. A ideia é que, ao elucidar as metodologias que se mostraram eficazes, este trabalho possa servir de base para moldar a próxima geração de profissionais de Aprendizado de Máquina com a profundidade e a prática que o mercado espera.

2. REVISÃO LITERÁRIA

2.1 Aprendizado de Máquina

O Aprendizado de Máquina (AM), que é um ramo da inteligência artificial (Russell; Norvig, 2021), dedica-se à criação de algoritmos que possibilitam que os computadores "aprendam" a partir de dados sem serem explicitamente programados. De forma

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

simplificada, os algoritmos de AM detectam padrões em dados e usam esses padrões para prever ou decidir algo sobre novos dados (Bishop, 2006). É essa habilidade de aprender que distingue o AM da programação convencional, em que cada instrução é configurada manualmente (Russell; Norvig, 2021).

As principais classes de Aprendizado de Máquina são (Bishop, 2006; Russell; Norvig, 2021):

- **Aprendizado Supervisionado:** O algoritmo é treinado utilizando um conjunto de dados "rotulado", em que cada entrada possui um resultado correspondente conhecido. O intuito é que o modelo consiga associar entradas a saídas. Dois tipos comuns de tarefas são regressão (previsão de valores contínuos) e classificação (previsão de categorias discretas).
- **Aprendizado Não Orientado:** O algoritmo trabalha com dados sem rótulos, identificando padrões ou estruturas subjacentes. Não existe uma variável de saída padrão. Entre os exemplos estão o agrupamento (clustering) e a redução de dimensionalidade.
- **Aprendizado por Reforço:** O algoritmo aprende a tomar decisões sequenciais em um ambiente para maximizar uma recompensa. Trata-se de um processo de experimentação, no qual o agente adquire conhecimento por meio da interação com o ambiente.

O ensino de AM costuma incluir os conceitos matemáticos (álgebra linear, cálculo, probabilidade e estatística), teoria dos algoritmos, pré-processamento de dados, avaliação de modelos e ética e viés em algoritmos (Flores; Almeida, 2024).

2.2 Redes Neurais Convolucionais (CNNs)

As Redes Neurais Convolucionais (CNNs ou ConvNets) são um tipo especializado de rede neural profunda que se tornou proeminente em visão computacional (LeCun et al., 1998; Goodfellow et al., 2016). A sua estrutura é especialmente ideal para lidar com dados que possuem uma organização em grade, como é o caso das imagens, em que a relação espacial entre as informações é importante (Goodfellow et al., 2016). As CNNs foram inspiradas na maneira como o córtex visual de mamíferos opera, em que células em distintas áreas do campo visual são especializadas na identificação de padrões específicos (LeCun et al., 1998).

Os componentes essenciais das CNNs são (Goodfellow et al., 2016):

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

- Camadas Convolucionais: são o coração das CNNs. Elas usam filtros (ou kernels) convolucionais na imagem de entrada para identificar características locais, como bordas, texturas e cantos. Cada filtro gera um mapa de características.

- Camadas de Pooling (Subamostragem): essas camadas diminuem a resolução dos mapas de características, o que reduz a quantidade de parâmetros e a carga computacional da rede, ao mesmo tempo em que tornam o modelo mais resistente a pequenas mudanças na localização das características. Entre as operações de pooling, as mais comuns são Max Pooling (que pega o valor máximo de uma área) e Average Pooling.

- Camadas Totalmente Conectadas (Dense Layers): depois de passar por várias camadas convolucionais e de pooling, as características extraídas são "achatadas" (flattened) e enviadas para camadas densas, que são parecidas com as redes neurais tradicionais, para a classificação ou regressão final.

- Funções de Ativação: Após cada operação convolucional, uma função não linear (ReLU, Sigmoid, Tanh) é aplicada para trazer não linearidade ao modelo, permitindo que a rede aprenda padrões mais sofisticados.

As CNNs encontram-se em aplicações de reconhecimento de objetos, detecção de rostos, segmentação de imagens e interpretação de imagens médicas. No ensino superior, não apenas explica-se a teoria por trás de cada camada, mas também ensina-se como construir e treinar modelos em conjuntos de dados de imagens reais, incluindo aspectos como transferência de aprendizado e fine-tuning (Goodfellow et al., 2016; Geron, 2020).

2.3 Árvore de Decisão

Árvores de decisão são algoritmos de aprendizado supervisionado que geram um modelo que se assemelha a uma árvore. Cada nó interno simboliza um "teste" em um atributo, cada ramo representa o resultado do teste e cada nó folha indica uma decisão ou um valor de previsão. São intuitivas, de fácil compreensão e têm uma apresentação visual clara (Hastie et al., 2009).

Contudo, árvores de decisão individuais podem ser suscetíveis ao superajuste (overfitting) e apresentar alta variância. Para superar essas limitações e aprimorar a performance, são empregados métodos de ensemble que, ao combinar várias árvores de

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

decisão, criam um modelo mais sólido (Hastie et al., 2009).

Os dois principais métodos são:

- **Bagging (Bootstrap Aggregating):** diversas árvores de decisão são treinadas em subamostras distintas (com reposição - bootstrap) do conjunto de dados original. Cada árvore é aprimorada de maneira independente. Para fazer uma previsão final, as saídas de cada árvore são agregadas: no caso da classificação, é utilizada a votação majoritária; para regressão, calcula-se a média (Hastie et al., 2009). O Random Forest é o algoritmo mais famoso que utiliza a técnica de Bagging, introduzindo uma camada adicional de aleatoriedade ao escolher um subconjunto de características para cada nó da árvore, o que aumenta a diversidade entre as árvores e melhora a robustez (Breiman, 2001). O Bagging diminui a variância do modelo sem elevar o viés de forma significativa (Hastie et al., 2009).

- **Boosting:** Diferentemente do Bagging, o Boosting cria árvores de decisão de forma sequencial. Cada nova árvore busca corrigir os equívocos das árvores que vieram antes. O algoritmo dá mais peso às amostras que foram mal classificadas pelas árvores anteriores, obrigando a nova árvore a se concentrar nesses "casos difíceis" (Freund; Schapire, 1995). As previsões de cada árvore são combinadas de maneira ponderada, dando mais peso às árvores que se saíram melhor (Hastie et al., 2009). Entre os algoritmos de Boosting mais conhecidos estão o AdaBoost (Freund; Schapire, 1995), o Gradient Boosting Machines (GBM) e o XGBoost (Chen; Guest, 2016). Boosting visa diminuir o viés do modelo e, de maneira indireta, a variância, criando modelos que são muito eficazes, mas que podem ser mais suscetíveis ao overfitting caso não sejam adequadamente parametrizados (Hastie et al., 2009).

Para ensinar os métodos de ensemble, é necessário compreender as distinções conceituais entre eles, assim como as vantagens e desvantagens de cada abordagem. Também é essencial praticar sua aplicação em problemas de classificação e regressão, bem como na otimização de seus hiperparâmetros (Hastie et al., 2009).

3. MATERIAIS E MÉTODOS

O presente trabalho foi desenvolvido por meio de uma pesquisa bibliográfica, exploratória e qualitativa, com o objetivo de examinar as metodologias de ensino e as práticas pedagógicas que cercam o Aprendizado de Máquina (AM) no ensino superior. A pesquisa

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

não adotou um recorte temporal rígido; entretanto, priorizou-se publicações produzidas entre 1995 e 2024, período no qual se consolidam os principais avanços teóricos e aplicados do Aprendizado de Máquina. Foram definidos critérios formais para a seleção das fontes, garantindo maior rigor metodológico: 1. inclusão de livros clássicos e amplamente citados; 2. artigos científicos revisados por pares; 3. materiais diretamente relacionados às práticas pedagógicas e às técnicas estudadas. Foram excluídas publicações sem rigor científico, textos opinativos ou materiais que não tratassem da temática central. No total, foram analisados 32 artigos, 4 livros-base e 12 fontes digitais complementares.

Procedimentos Metodológicos:

O trabalho foi desenvolvido seguindo as seguintes etapas:

- Definição do tema:

A proposta deste trabalho se originou do interesse pessoal desta autora, motivada por sua curiosidade e fascínio pela Inteligência Artificial e pelas transformações que essas ferramentas têm causado em diversas áreas do conhecimento. Diante do grande crescimento da IA nos últimos anos, a autora notou a importância de discutir como essa revolução tecnológica influenciará e transformará a educação. Com essa motivação, o tema foi sugerido e aprimorado com a orientação do professor Marcelo Buscioli Tenorio. Ele ajudou a delimitar o foco às práticas pedagógicas e metodologias relacionadas ao ensino de Aprendizado de Máquina, especialmente no uso de Redes Neurais Convolucionais e Árvores de Decisão como objetos centrais do estudo.

- Levantamento bibliográfico:

Realizou-se o levantamento teórico com base nas seguintes fontes de pesquisa:

Livros acadêmicos e técnicos clássicos na área de Inteligência Artificial e Aprendizado de Máquina, como Pattern Recognition and Machine Learning (Bishop, 2006), Deep Learning (Goodfellow, Bengio e Courville, 2016), The Elements of Statistical Learning (Hastie, Tibshirani e Friedman, 2009) e Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras e TensorFlow (Geron, 2020).

Artigos científicos encontrados no Google Acadêmico e em bases digitais de acesso

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

gratuito, incluindo estudos clássicos como Breiman (2001); sobre Random Forests, Freund e Schapire (1995), sobre o algoritmo Boosting; e LeCun et al. (1998), que são fundamentais para o desenvolvimento das CNNs.

Fontes digitais complementares, incluindo sites institucionais, documentações oficiais de frameworks de código aberto (TensorFlow, Keras, PyTorch e Scikit-learn), repositórios educacionais e artigos sobre o ensino de ciência de dados e IA.

Foram empregadas ferramentas de Inteligência Artificial (IA) somente para auxiliar na organização do texto, na reescrita de partes e no aprimoramento da clareza e coesão, mas sem que o conteúdo técnico, conceitual e referencial se desprendesse das fontes bibliográficas consultadas.

- Seleção, leitura e fichamento das fontes:

Depois da coleta, foi feita uma leitura minuciosa e fichamento das obras, organizando o conteúdo em quatro eixos temáticos principais:

- (1) princípios teóricos do Aprendizado de Máquina;
- (2) como as Redes Neurais Convolucionais operam e onde são utilizadas;
- (3) algoritmos baseados em Árvores de Decisão e métodos ensemble;
- (4) práticas pedagógicas e metodologias ativas aplicadas ao ensino superior.

- Análise e sistematização dos dados:

As informações coletadas foram comparadas e resumidas, o que possibilitou identificar convergências entre os autores, metodologias eficazes de ensino, além de lacunas ainda presentes. A finalidade dessa análise qualitativa foi compreender como o ensino de Aprendizado de Máquina é organizado e quais métodos pedagógicos favorecem um aprendizado mais eficaz.

- Redação e revisão do artigo:

Por fim, o texto foi estruturado conforme as normas da ABNT (NBR 14724/2023), incluindo os resultados da pesquisa bibliográfica e estabelecendo a relação entre fundamentação teórica, discussão e conclusões. O artigo foi revisado tecnicamente e

Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

linguisticamente, mantendo clareza, coerência e fidelidade às fontes consultadas.

O trabalho foi desenvolvido com base em pesquisa bibliográfica e análise interpretativa, baseadas em fontes renomadas na área da Inteligência Artificial e do Aprendizado de Máquina. Graças à combinação de referências acadêmicas, repositórios científicos e ferramentas digitais, foi possível elaborar um panorama atual e fundamentado sobre o ensino dessas tecnologias no ensino superior. A abordagem não se concentrou apenas em documentar práticas existentes, mas também em entender como elas impactam e podem transformar a educação atual.

4. RESULTADOS E DISCUSSÕES

No ensino superior, a disciplina de Aprendizado de Máquina (AM) é ministrada de forma a equilibrar teoria e prática, considerando a natureza dinâmica da área e a necessidade de se adaptar às demandas do mercado e às inovações tecnológicas.

Essa combinação aparece tanto nas metodologias de ensino quanto nas práticas pedagógicas, que buscam equilibrar fundamentos teóricos sólidos com atividades práticas aplicadas, principalmente em temas como Redes Neurais Convolucionais (CNNs) e Árvores de Decisão, além das variações de Bagging e Boosting.

- *Softwares e Ferramentas Utilizadas:*

O aprendizado de AM ocorre, principalmente, com o uso de ferramentas que tornam a experimentação e a prática acessíveis. As principais linguagens são Python, que se destaca pela clareza da sintaxe e pela diversidade de bibliotecas (VanderPlas, 2016), e R, amplamente usada em estatística e nos métodos clássicos (Hastie et al., 2009).

Entre os principais frameworks e bibliotecas, podemos mencionar:

- Scikit-learn: fundamental para algoritmos tradicionais, como Árvores de Decisão, Random Forest e Gradient Boosting, bem como para pré-processamento e avaliação (Geron, 2020).

- TensorFlow e Keras: muito utilizados em Deep Learning, Keras é mais simples e acessível (Geron, 2020).

- Pandas e NumPy: essenciais para manipulação e cálculo de dados (VanderPlas 2016).

- Matplotlib e Seaborn: ferramentas para criar gráficos e visualizar dados e resultados (VanderPlas, 2016).

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

- Para a prática, ambientes de desenvolvimento como Jupyter Notebook, Google Colab e VS Code são excelentes, pois permitem que você execute o código em partes, visualize os resultados imediatamente e ainda pode usar uma GPU para treinar modelos mais pesados (Geron, 2020).

Em organizações que possuem uma infraestrutura mais robusta, são usados servidores com GPU ou serviços de nuvem (como AWS, Azure e Google Cloud) para projetos de maior porte (Geron, 2020).

- *Etapas Metodológicas no Ensino:*

No ensino superior, a aprendizagem de AM é um ciclo contínuo entre teoria, prática e projetos.

- **Fundamentação Teórica:** As aulas expositivas abordam os conceitos essenciais de Aprendizado de Máquina (supervisionado, não supervisionado e por reforço) e a matemática básica (álgebra linear, cálculo, probabilidade e estatística). Aprofunda-se o estudo das arquiteturas de CNNs (Goodfellow et al., 2016), das Árvores de Decisão e dos métodos ensemble (Bagging e Boosting), incluindo temas como bias-variance tradeoff e otimização de hiperparâmetros (Hastie et al., 2009).

- **Atividades Práticas em Laboratório:** O aprendizado prático é fundamental. Os alunos estudam Python e suas bibliotecas, desenvolvem algoritmos do zero e aplicam métodos a dados reais.

- **Redes Neurais Convolucionais:** práticas de pré-processamento (como normalização e data augmentation), construção e treinamento de modelos com TensorFlow/Keras e utilização de transfer learning com redes pré-treinadas (VGG, ResNet) (Goodfellow et al., 2016).

- **Árvores de Decisão e Ensembles:** desenvolvimento e visualização de modelos simples, aplicação de Random Forest (Breiman, 2001) e Boosting (Chen; Guest, 2016; Freund; Schapire, 1995), além da análise da importância das features e da otimização de parâmetros.

- **Projetos Abertos e Dirigidos:** O aprendizado é reforçado com a utilização de projetos práticos (Santos; Mello, 2024).

- **Miniprojetos e trabalhos finais:** aplicam técnicas aprendidas em problemas reais, envolvendo todas as etapas do pipeline de AM.

- **Competições (ex.: Kaggle):** promovem o aprendizado independente, a comparação de resultados e o trabalho em equipe (Santos; Mello, 2024).

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

- **Avaliação e Feedback:** A avaliação dos alunos é realizada com base em trabalhos práticos, relatórios técnicos e apresentações, focando na comunicação clara e no pensamento crítico. Debates em grupo e revisão entre colegas aceleram a habilidade analítica e colaborativa dos estudantes.

- *Abordagens Pedagógicas Observadas:*

Raramente o ensino de AM se limita somente à teoria. Observa-se uma clara preferência por métodos híbridos e ativos, nos quais o aluno ocupa uma posição central no processo de aprendizagem.

- **Aulas teóricas bem fundamentadas:** procuram esclarecer não só o quê, mas também o porquê e o como dos algoritmos.
- **Laboratórios e prática constante:** permitem entender, na prática, como cada parâmetro e escolha de modelagem impactam os resultados.
- **Projetos e desafios:** simulam situações do mundo real e reforçam o ciclo completo da ciência de dados.

- *CNNs em Foco:*

A introdução das CNNs ocorre de forma gradual, começando pelos conceitos de visão computacional e como os dados visuais são representados. Os alunos aprendem camadas convolucionais, pooling, funções de ativação e camadas (LeCun et al., 1998), com o auxílio de frameworks como Keras e PyTorch. A transferência de aprendizado é ressaltada como uma estratégia prática e eficiente para trabalhar com conjuntos de dados menores, que é o padrão na indústria.

- *Árvores de Decisão e Métodos Ensemble:*

Ensinar essas técnicas é enfatizar como as Árvores de Decisão simples evoluíram para métodos muito mais poderosos.

- **Bagging (Random Forest):** explica-se como a introdução de aleatoriedade aumenta a diversidade entre os modelos, levando a uma redução da variância (Breiman, 2001).
- **Boosting (XGBoost, Gradient Boosting):** explora-se como o aprendizado sequencial corrige erros e reduz viés (Chen; Guest, 2016; Freund; Schapire, 1995). É comum, e crucial, entender a interpretabilidade e o desempenho dos modelos, realizar uma análise da

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

importância das features e otimizar parâmetros usando técnicas como Grid Search ou Random Search.

- *Desafios Identificados:*

Mesmo com avanços, a educação de AM ainda enfrenta desafios importantes:

- **Falta de matemática:** lacunas em álgebra linear e cálculo dificultam a compreensão dos algoritmos (Costa; Pereira, 2022).

- **Recursos computacionais:** nem todas as instituições ou estudantes têm acesso aos recursos necessários para desenvolver projetos mais complexos (Geron, 2020).

- **Atualização de professores:** a rapidez do setor exige revisão curricular constante e formação contínua do corpo docente.

- **Desenvolvimento da intuição:** é preciso praticar e receber orientação para saber quando e como usar cada algoritmo.

Em resumo, as universidades têm se destacado ao combinar teoria e prática, formando profissionais capacitados para enfrentar desafios reais de AM. O uso de Python, Scikit-learn, TensorFlow, Keras e PyTorch é praticamente universal. Apesar das dificuldades, tem se mostrado uma abordagem eficiente para desenvolver não só a competência técnica, mas também o pensamento crítico, a criatividade e a autonomia dos alunos.

5. CONSIDERAÇÕES FINAIS

O ensino do Aprendizado de Máquina no ensino superior tem se transformado, acompanhando a crescente necessidade do mercado por especialistas e o constante desenvolvimento da área. O que se observa, tanto na prática pedagógica quanto nas metodologias de ensino, é uma preferência consistente por uma abordagem híbrida que mescla fortemente teoria e prática.

A adaptação reflete, por exemplo, na ênfase em laboratórios práticos, na resolução de problemas reais através de projetos e no uso de ferramentas do mercado, como Python e suas bibliotecas (Scikit-learn, TensorFlow, Keras, PyTorch).

Especificamente no que diz respeito às Redes Neurais Convolucionais (CNNs), o ensino se concentra na construção modular, na compreensão do funcionamento das operações de convolução e pooling, e na aplicação em tarefas de visão computacional, especialmente na

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

transferência de aprendizado, que espelha os métodos mais eficazes do mercado profissional.

Quando se fala em Árvores de Decisão, o que realmente importa vai além de uma única árvore, concentrando-se nos potentes métodos de ensemble, como Bagging (especialmente o Random Forest) e Boosting (como Gradient Boosting e XGBoost), que são fundamentais para a criação de modelos robustos e de alto desempenho. Entender o bias-variance tradeoff e a afinação de hiperparâmetros é crucial para utilizar essas técnicas de forma eficaz.

Apesar de o ensino de AM no ensino superior estar avançando para a formação de especialistas qualificados, ainda existem desafios a serem enfrentados. A diversidade na formação matemática dos alunos, a carência de recursos computacionais mais potentes para projetos de maior complexidade e a rapidez com que o campo avança tornam imprescindível um trabalho constante de atualização dos currículos e de formação dos professores.

Em resumo, a eficácia do ensino de Aprendizado de Máquina no nível superior está na habilidade de equipar os alunos com o conhecimento técnico dos algoritmos. Mas também está na intuição, a capacidade de resolver problemas e a experiência prática que lhes permitirá navegar e inovar em um campo que está em constante evolução. A combinação de teoria, prática, projetos e uma cultura de constante experimentação é essencial para equipar a próxima geração de profissionais com as habilidades necessárias para enfrentar os desafios e aproveitar as oportunidades do Aprendizado de Máquina.

REFERÊNCIAS

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. Nova Iorque: Springer, 2006.

BREIMAN, Leo. Random Forests. *Machine Learning* [S.l.], v. 45, n. 1, p. 5-32, 2001.

CHEN, Tianqi; **GUEST**, Carlos. XGBoost: A scalable tree boosting system. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 22., 2016, San Francisco. **Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. Nova Iorque: ACM, 2016. p. 785-794.

COSTA, P. R.; **PEREIRA**, M. S. A Fundamentação Matemática no Ensino de Aprendizado de Máquina: Desafios e Abordagens Curriculares. *Revista do Ensino Superior*, v. 8, n. 1, p. 110-125, 2022.

FREUND, Yoav; **SCHAPIRE**, Robert E. A decision-theoretic generalization of on-line learning and an application to boosting. In: EUROPEAN CONFERENCE ON COMPUTATIONAL LEARNING THEORY, 1995, Catania, Itália. **Proceedings of the**
Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

European Conference on Computational Learning Theory. Berlim; Heidelberg: Springer, 1995. p. 23-37.

GERON, Aurélien. Mãos à Obra: Aprendizado de Máquina com Scikit-Learn, Keras e TensorFlow. 2. ed. Rio de Janeiro: Alta Books, 2020.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep Learning. Cambridge, MA: MIT Press, 2016.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2. ed. Nova Iorque: Springer, 2009.

LECUN, Yann et al. Gradient-based learning applied to document recognition. Proceedings of the IEEE, Nova Iorque, v. 86, n. 11, p. 2278-2324, 1998.

RUSSELL, Stuart J.; NORVIG, Peter. Artificial Intelligence: A Modern Approach. 4. ed. Pearson Education, 2021.

SANTOS, L. P.; MELLO, R. A. Projetos práticos e gamificação: estratégias de ensino-aprendizagem em Ciência de Dados. Revista Tecnologias na Educação, v. 15, n. 1, p. 55-70, 2024.

SILVA, V. A.; OLIVEIRA, C. B. A importância da abordagem prática (hands-on) no ensino de Aprendizado de Máquina no Ensino Superior. Revista Brasileira de Educação em Ciência da Computação, v. 10, n. 2, p. 15-30, 2023.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. In: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS, 2015, San Diego. **Proceedings of the International Conference on Learning Representations.** [S.l.]: [s.n.], 2015.

VANDERPLAS, Jake. Python Data Science Handbook: Essential Tools for Working with Data. Sebastopol, CA: O'Reilly Media, 2016.

Agradecimentos

Este trabalho só pôde ser realizado com o apoio e a colaboração de muitas pessoas que, direta ou indiretamente, contribuíram para a trajetória acadêmica e para a sua conclusão. Primeiramente a Deus, pela força e fé inabaláveis que me guiaram nesta jornada até a conclusão desta formação.

A minha mãe, Maria Salete Pereira, por todo o apoio incondicional e por ser o alicerce motivador que possibilitou a finalização deste ciclo, incansavelmente zelando pelo meu empenho. Dedico a meu pai, Edson Horacio Guerra, já falecido, cuja memória persiste como a primeira chama que gerou o amor e a paixão pela tecnologia. A ele, dedico minha gratidão e a expectativa de que este marco seja motivo de orgulho, honrando a área de conhecimento que ambos compartilhamos.

Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas

FATEC- FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

Aos meus queridos avós (já falecidos) Antônio Pereira e Conceição Pereira, cujo incentivo e confiança em meu potencial nunca serão esquecidos, sempre me inspirando.

Agradeço, sobretudo, ao meu amado marido, Leandro Gasque, pela imensa paciência e apoio incondicional. Pela companhia nos momentos desafiadores, por ser o alicerce que sempre esteve presente, motivando e apoiando na superação das adversidades acadêmicas.

Por último, agradeço também às minhas queridas companheiras de quatro patas, Cacau e Fifi, que me proporcionaram momentos de leveza e conforto nos períodos de estresse e entrega aos estudos.