

RESENHA AVALIATIVA

**AJUDANDO A “DESMITIFICAR” A INTELIGÊNCIA ARTIFICIAL EM
EDUCAÇÃO: A ABORDAGEM DO APRENDIZADO DE MÁQUINA¹**

**HELPING TO “DEMYSTIFY” ARTIFICIAL INTELLIGENCE IN EDUCATION: THE MACHINE LEARNING
APPROACH**

**AYUDANDO A “DESMITIFICAR” LA INTELIGENCIA ARTIFICIAL EN LA EDUCACIÓN: EL ENFOQUE DEL
APRENDIZAJE AUTOMÁTICO**

EWERTON ALEX AVELAR¹

ORCID: <https://orcid.org/0000-0003-2374-8954>
<ewertonavelar@face.ufmg.br>

¹ Universidade Federal de Minas Gerais. Belo Horizonte, Minas Gerais (MG), Brasil.

INTRODUÇÃO

Esta resenha avaliativa é baseada no artigo intitulado “Reflexões sobre a inteligência artificial à luz dos fundamentos da educação profissional e tecnológica”, que traz à tona reflexões relevantes sobre a Inteligência Artificial (IA) e a educação profissional e tecnológica. Recentemente, o tema IA tem sido cada vez mais discutido na Academia em relação ao seu papel na Educação sob diversas perspectivas (Parreira et al., 2021; Lima et al., 2024) – em especial, após a disponibilização do ChatGPT (Azambuja & Silva, 2024; Lima & Serrano, 2024). Esse papel central da IA ecoa na vida cotidiana em diversas atividades, como assistentes virtuais (*e.g.*, Siri, Alexa e Google Assistant) ou plataformas de streaming (*e.g.*, Netflix e Spotify) (Oliveira & Avelar, 2023; Rodrigues & Rodrigues, 2023).

Na Educação, a influência da IA é cada vez mais forte. Conforme Durso (2024), independentemente do ponto de vista (tecnófilo ou tecnófobo), a realidade se impõe e, nela, a IA já se encontra inserida no processo educacional e demanda ser corretamente compreendida. O autor complementa que:

[n]esse sentido, desconsiderar a IA no processo educacional é reconhecer que os discentes de hoje não estarão preparados para os desafios de suas atuações no mercado de trabalho no futuro. [...] Não reconhecer o papel da IA no contexto das salas de aula é também assumir que os discentes estarão menos preparados para a sua atuação cidadã. Temas importantes como a ética do uso dos dados e *fake news* estão intimamente ligados à aplicação da IA na sociedade e demandam uma formação crítica sobre o assunto. [...] O campo da Educação precisa, portanto, envidar cada vez mais esforços para o acompanhamento e avaliação dos efeitos da IA no processo de ensino-aprendizagem nas mais diferentes esferas do processo educacional (Durso, 2024, p. 3).

Contudo, apesar da importância do tema IA em diversos âmbitos sociais e na Educação em especial, seus aspectos técnicos e conceituais são pouco abordados em trabalhos como os supracitados.

¹ Editora participante do processo de avaliação por pares aberta: Suzana dos Santos Gomes.

Discutir tais aspectos não era o objetivo primário dos referidos estudos; entretanto, verifica-se que essa lacuna é comum nos trabalhos da área, o que torna importantes algumas definições para uma discussão cada vez mais aprofundada que o tema demanda. Muitas vezes, tanto na sociedade quanto na Academia, o termo IA é tratado como uma espécie de “entidade mística”, algo além do conhecimento de qualquer pessoa que não seja especialista em Computação ou um *hacker* do Vale do Silício, o que não é verdade. Uma melhor compreensão técnica e conceitual possibilita um aprofundamento crítico dos leitores tanto do artigo “Reflexões sobre a inteligência artificial à luz dos fundamentos da educação profissional e tecnológica” quanto dos demais trabalhos da área que têm outros enfoques sobre o papel da IA.

Este trabalho tem a premissa de que é importante conhecer questões técnicas e conceituais para ajudar a “desmistificar” a IA, muitas vezes percebida como essa “entidade mística” que permeia todos os aspectos da vida diária, mas sobre a qual temos pouca (ou nenhuma) agência. Pressupõe-se que a capacidade de agir advém do conhecer. E, neste caso, conhecer aspectos técnicos da IA possibilita entender melhor sua relação com o cotidiano de forma geral e com a Educação em especial. É importante abrir a caixa-preta (*black-box*) dos algoritmos de IA e compreender sua história e a forma como aprendem, para refletir mais profundamente sobre suas implicações sobre a vida dos diversos atores sociais.

Nesse contexto, esta resenha enfoca algumas definições básicas relacionadas à IA de forma a melhorar a compreensão dos leitores sobre o tema em si, possibilitando a apreensão de algumas de suas nuances técnicas e conceituais. Em especial, visa apresentar sucintas respostas iniciais às seguintes questões: o que é IA? O que são os algoritmos de IA? Como os modelos de IA são desenvolvidos e avaliados? Trata-se de respostas simplificadas, mas que podem nortear algumas interpretações e abrir caminhos para uma compreensão mais profunda e técnica do tema e de suas implicações sociais.

O QUE É A INTELIGÊNCIA ARTIFICIAL (IA)?

Nwanganga e Chapple (2020) definem a IA como qualquer técnica utilizada com a finalidade de fazer um sistema computadorizado imitar o comportamento humano. Desde meados do século XX, o desenvolvimento da IA tem tido avanços notáveis em diversas áreas do conhecimento científico. Nas décadas de 1950 e 1960, pesquisadores como Alan Turing e John McCarthy estabeleceram os fundamentos da IA. Ao longo das décadas subsequentes, a IA expandiu sua atuação para a capacitação computacional, processamento de linguagem natural e aprendizado de máquina (*machine learning* – ML) para compreensão de problemas do mundo real.

Desde meados do século passado, mas, principalmente, ao longo do século XXI, a crescente complexidade dos problemas a serem computacionalmente tratados, assim como da velocidade e do volume de dados gerados, incentivou o desenvolvimento de ferramentas computacionais cada vez mais autônomas, ou seja, menos dependentes de uma intervenção humana, para a aquisição de conhecimento. A maioria dessas aplicações atualmente é baseada na abordagem ML. Segundo Nwanganga e Chapple (2020), essa abordagem pode ser compreendida como uma subárea da IA que aplica diferentes técnicas a dados com os propósitos de gerar novos conhecimentos e de generalizá-los a partir de exemplos. A Figura 1 representa essa relação conforme aqueles autores. Eles incluem ainda o Aprendizado Profundo (*deep learning*) como uma subárea da ML, o qual será abordado nesta resenha ao se tratar de redes neurais artificiais (RNA), incluindo os *large language models* (LLM), como o Chat GPT.

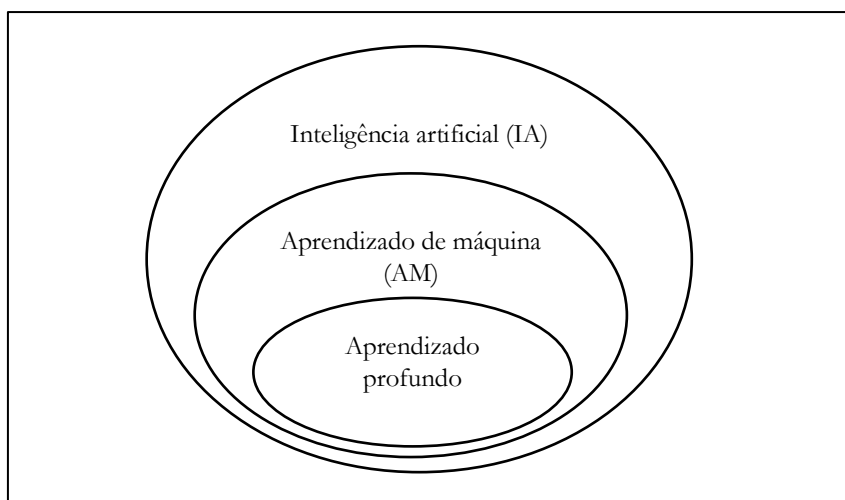


Figura 1: Relação entre Inteligência artificial, Aprendizado de máquina e Aprendizado profundo
Fonte: adaptada de Nwanganga e Chapple (2020, p. 7).

Atualmente, quando se fala de IA, salvo raras exceções, está-se falando de ML, já que se trata da abordagem amplamente utilizada neste século para aplicações no cotidiano. Lantz (2019) define ML como uma área de estudo voltada para o desenvolvimento de algoritmos capazes de transformar dados em uma ação inteligente. O processo de ML pode ser dividido em quatro etapas: (1) Armazenamento de dados – utiliza observação, memória e recuperação de dados para fornecer uma base factual para raciocínio posterior; (2) Abstração – envolve a transformação dos dados armazenados em representações mais amplas e conceitos; (3) Generalização – usa o modelo gerado na etapa anterior para criar conhecimento e possibilitar inferências que permitam a tomada de decisão em outros contextos; e (4) Avaliação – fornece um mecanismo de *feedback* para mensurar a utilidade do conhecimento aprendido e possibilitar potenciais aprimoramentos (Lantz, 2019). Essas etapas estão representadas na Figura 2.

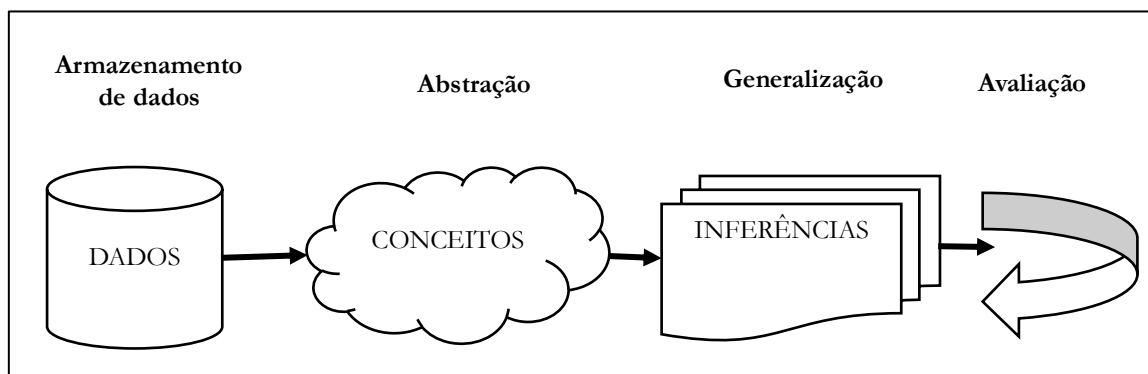


Figura 2: Processo de Aprendizado de máquina
Fonte: adaptada de Lantz (2019, p. 11).

Os conceitos (etapa de abstração) se referem à etapa de desenvolvimento dos modelos de ML. Trata-se de representações simplificadas da realidade, que se baseiam nos dados reais disponibilizados. Estes dados, previamente selecionados pelos humanos, devem ser bem trabalhados, pois tratamentos diferenciados tendem a gerar modelos distintos. Tais modelos são gerados a partir da fase de treinamento, cujos passos variam de algoritmo para algoritmo de ML.

Os algoritmos, por sua vez, podem ser definidos como conjuntos de instruções para resolver problemas (Piva Jr. et al., 2019). Uma analogia simples seria como os passos para fazer um bolo: deve-se executar sequencialmente uma série de tarefas, incluindo a adição de ingredientes e ações para garantir a existência de um bolo ao final; usualmente, por exemplo, não adianta quebrar os ovos após a massa já ter ido para o forno. Da mesma forma, os algoritmos de ML exigem que os dados sejam trabalhados de determinada forma, seguindo uma sequência previamente estabelecida, para gerar o modelo-base para as decisões. Vale destacar que os algoritmos são essenciais em programação e vão muito além daqueles relacionados à ML, os quais serão detalhados a seguir.

O QUE SÃO ALGORITMOS DE ML?

Os algoritmos de ML podem ser classificados entre não supervisionados (descritivos) e supervisionados (preditivos). Estes últimos são o foco desta resenha. No aprendizado supervisionado, o objetivo é usar dados existentes e rotulados para gerar modelos que auxiliem na previsão de dados futuros não rotulados (Faceli et al., 2023). Entenda-se como “rótulo” a variável que representa o fenômeno a ser previsto. Um exemplo seria a evasão escolar. Neste caso, o banco de dados poderia apresentar uma série de informações históricas sobre diferentes estudantes (idade, CEP, ano escolar etc.), assim como se ele evadiu da escola naquele ano ou não. O dado “evadiu” ou “não evadiu” seria o rótulo nesse caso.

As tarefas de um algoritmo de ML preditivo variam de acordo com o rótulo a ser predito: (a) classificação – rótulo discreto (dados não métricos, qualitativos), valores nominais (e.g., prever se determinado estudante irá ou não evadir); ou (b) regressão – rótulo contínuo (dados métricos, quantitativos), conjunto infinito e ordenado de valores (e.g., prever variáveis métricas determinantes da evasão escolar).

Dentre esses algoritmos, quatro podem ser destacados: k-vizinhos mais próximo (*k-nearest neighbors* – KNN), naive Bayes, árvore de decisão/*random forest* e RNA. O KNN é um dos algoritmos de ML mais simples e utilizados; baseia-se em distâncias entre observações de uma amostra de dados (Lantz, 2019). A premissa básica do KNN é que os objetos analisados provavelmente têm atributos (variáveis) similares (Nwanganga & Chapple, 2020). Na execução do algoritmo, para mensurar a distância entre os objetos, usualmente se emprega a distância Euclidiana das variáveis de cada observação, tentando verificar padrões entre essa distância e o rótulo a ser previsto. A forma de funcionamento desse algoritmo poderia ser resumida no ditado popular: “*Diga-me com quem tu andas e direi quem és...*”. Uma característica essencial para o funcionamento do KNN é a definição do valor do *k*, parâmetro vital para previsão de uma nova observação. O *k* se refere ao do número de vizinhos que serão analisados para a classificação pelo modelo, sendo este número sempre igual ou superior a 1 (um). De acordo com Nwanganga e Chapple (2020), o valor de *k* é decisão do usuário (recomendam-se números ímpares para evitar empates na classificação).

Já o algoritmo naive Bayes, conforme Lantz (2019), fundamenta-se no aprendizado bayesiano do matemático Thomas Bayes. Esse matemático desenvolveu os princípios fundamentais para descrever a probabilidade de ocorrência de eventos e como essa probabilidade poderia ser reavaliada em decorrência de novas informações. Essa abordagem usa todas as informações disponíveis para subsidiar a previsão. Apesar de não ser o único, o naive Bayes é o mais popular algoritmo de ML baseado no aprendizado bayesiano (Lantz, 2019). Burguer (2018) destaca que esse algoritmo realiza suas previsões com base em uma premissa essencial: todas as variáveis preditoras do fenômeno são independentes entre si. Dessa premissa advém o termo “*naive*” (ingênuo, em inglês) do algoritmo. Em outros termos, a presença (ou ausência) de uma característica particular de uma classe não tem relação com a presença (ou ausência) de qualquer outra característica. O algoritmo naive Bayes envolve a etapa de aprendizado, na qual as probabilidades dos diferentes eventos são estimadas com base nos dados de treinamento, assim como suas probabilidades condicionais com base na frequência das variáveis entre si. O conjunto dessas estimativas corresponde às hipóteses aprendidas, que são usadas para classificar qualquer nova observação.

Por sua vez, a árvore de decisão é considerada um método simbólico da ML, uma vez que organiza o aprendizado adquirido em uma hierarquia de decisões, as quais passam por um processo de refinamento até que se obtenha uma predição final do conjunto de observações. Conforme Nwanganga e Chapple (2020), a facilidade com que a árvore de decisão pode ser compreendida como uma regra do tipo “se..., então” faz com que ela seja um método muito popular de classificação. O modelo de árvore de decisão cria regras para dividir um problema complexo em uma série de problemas mais simples (subproblemas). A forma de funcionamento desse algoritmo poderia ser resumida na máxima: “*Dividir para conquistar*”. As soluções desses subproblemas, por sua vez, são combinadas em uma espécie de “árvore”, tal como apresentado na Figura 3. Essa árvore é composta pelos seguintes elementos: (i) Nós – partições que segregam os dados em dois conjuntos, sendo que o primeiro nó pode ser denominado de “nó-raiz” e os demais são geralmente designados de “nós de decisão”; (ii) Galhos (ramos) – os

produtos das decisões tomadas em cada nó; e (iii) Folhas – os resultados de cada “nó de decisão”. Esse modelo está representado na Figura 3, na qual “V” corresponde a “Verdadeiro” e “F” a “Falso”.

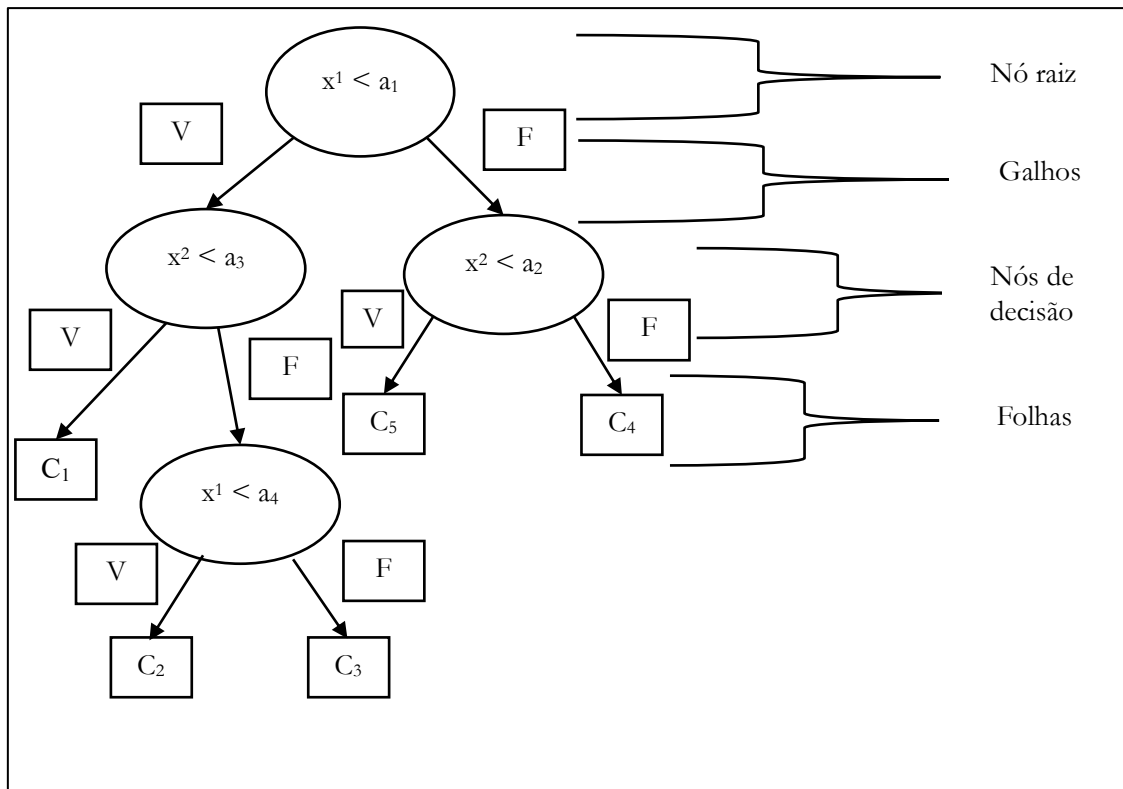


Figura 3: Esquema de representação do processo decisório em uma árvore de decisão

Fonte: adaptada de Faceli et al. (2023, p. 79).

Um aprimoramento do algoritmo de árvore de decisão é o algoritmo *random forest*, desenvolvido sob a abordagem da “aprendizagem em conjunto” (*ensemble learning*). Nwanganga e Chapple (2020) destacam que o aprendizado em conjunto assume que podemos não conseguir encontrar o conjunto ótimo de hiperparâmetros para dado modelo e, mesmo que conseguíssemos, o modelo poderia não estar apto a capturar todos os padrões subjacentes aos dados. Assim, em vez de focar em otimizar o desempenho de apenas um modelo, usam-se vários modelos fracos e complementares para desenvolver um modelo mais robusto. Conforme Burguer (2018), o *random forest* funciona como uma coleção de diferentes modelos baseados em árvores de decisão geradas a partir de diferentes subconjuntos aleatórios de dados de treinamento e de atributos (variáveis). Cada um dos modelos, a partir dos subconjuntos de dados usados, gera um resultado esperado, que é, então, combinado para uma decisão final do *random forest*. Basicamente, em vez de gerar apenas um modelo baseado em uma árvore de decisão, geram-se diferentes árvores. Burguer (2018) apresenta um exemplo com três árvores (Figura 4).

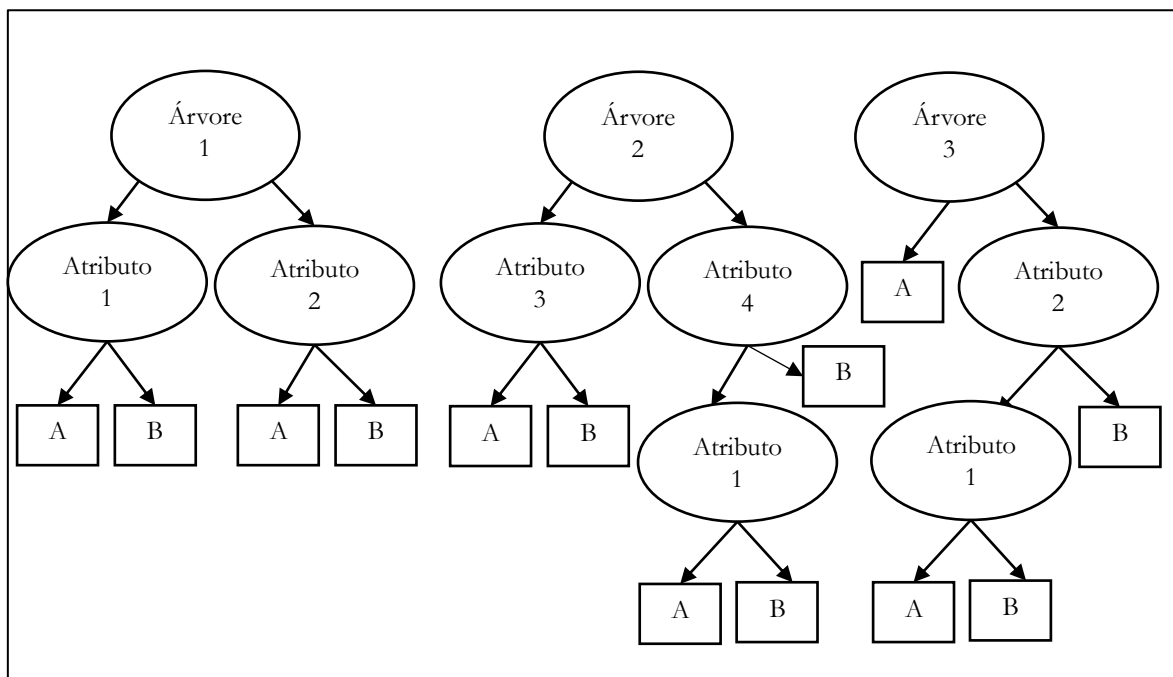


Figura 4: Exemplo de *random forest* com três árvores
Fonte: adaptada de Burguer (2018, p. 156).

Por fim, têm-se os algoritmos de ML mais popularmente conhecidos: as RNA. Lantz (2019) salienta que esses algoritmos modelam a relação entre um conjunto de *inputs* (entradas) e de *outputs* (saídas) usando um modelo baseado no funcionamento do cérebro humano. Segundo o autor, enquanto o cérebro humano usa uma rede de células interconectadas (os neurônios biológicos) para fornecer uma vasta capacidade de aprendizado, as RNA usam uma rede de neurônios artificiais para resolver problemas desafiadores. Faceli et al. (2023) apresentam uma relação entre os neurônios biológicos do cérebro humano e os neurônios artificiais de uma RNA (Figuras 5a e 5b).




Figura 5a: Neurônio biológico simplificado
Fonte: Faceli et al. (2023, p. 102).




Figura 5b: Neurônio artificial
Fonte: Faceli et al. (2023, p. 103).

Conforme Faceli et al. (2023), uma RNA é caracterizada por dois aspectos básicos: a arquitetura e o aprendizado. A arquitetura se refere ao tipo de RNA, ao número de unidades de processamento e à forma como os neurônios são conectados. Conforme os autores, o neurônio é a unidade de processamento fundamental, recebendo um valor, que é ponderado e combinado por uma função matemática f , sendo a saída da função a resposta do neurônio para a entrada (várias funções podem ser utilizadas). Uma das principais questões nesse contexto se relaciona às quantidades de camadas e de neurônios a serem incluídos em cada camada para lidar com problemas complexos. Quando há duas camadas ou mais camadas ocultas em uma RNA, tem-se o chamado aprendizado profundo. Trata-se de modelos usados para gerar as chamadas *deep fakes* ou a base para os LLM (e.g., o ChatGPT), por exemplo. Consoante o próprio ChatGPT:

Eu sou um modelo de aprendizado de máquina baseado em redes neurais, mais especificamente, um *transformer*, que é um tipo avançado de rede neural profunda. Fui treinado usando grandes

quantidades de texto para aprender a gerar respostas, interpretar perguntas e produzir informações com base no contexto da conversa. Diferente de algoritmos como k-NN ou árvores de decisão, meu foco está em entender e gerar linguagem natural, em vez de tomar decisões diretas com base em dados numéricos ou categóricos (OPEN IA, 2025).

Independentemente do algoritmo de ML empregado, todos apresentam benefícios e limitações em seus modelos gerados. O Quadro 1 apresenta um compilado de tais informações, baseando-se em Burguer (2018), Lantz (2019), Nwanganga e Chapple (2020) e Faceli et al. (2023).

Quadro 1: Benefícios e limitações de cada algoritmo de ML

Algoritmo	Vantagens	Limitações
KNN	<ul style="list-style-type: none"> • É incremental, já que é suficiente armazenar na memória os novos exemplos de treinamento disponibilizados para o modelo. Assim, o KNN é adaptável a mudanças no conjunto de dados; • É não paramétrico, ou seja, não faz suposições sobre a distribuição dos dados ou a forma da relação entre as variáveis de entrada e a saída, o que o torna adequado para lidar com dados não lineares e não gaussianos; e • Tem treinamento simples (memoriza apenas objetos). Como não demanda uma modelagem complexa, torna-se uma opção atraente para iniciantes em ML. 	<ul style="list-style-type: none"> • A escolha do hiperparâmetro k é usualmente arbitrária e pode afetar significativamente o desempenho do modelo. • A fase de teste costuma ser mais lenta do que a fase de treinamento na operacionalização do método; • É afetado pela presença de atributos redundantes e irrelevantes; e • Não apresenta uma representação compacta dos objetos, uma vez que não há um modelo explícito a partir dos dados, o que pode gerar problemas de predições custosas.
Naive Bayes	<ul style="list-style-type: none"> • Apresenta melhor desempenho que outros algoritmos quando se trabalha com muitos atributos preditivos; • É fácil de implementar e interpretar, pois utiliza uma abordagem simples de probabilidade; • É robusto à presença de atributos irrelevantes; • Não é afetado por valores atípicos nos dados; • Não requer a definição de um valor de hiperparâmetro; e • Todas as probabilidades exigidas podem ser calculadas a partir dos dados de treino em uma única ocorrência. 	<ul style="list-style-type: none"> • A assunção de independência condicional de classe assume que todos os valores dos atributos são independentes, o que pode afetar negativamente o cálculo de probabilidades em conjuntos de dados com atributos altamente correlacionados; • Considera que os atributos não são apenas independentes, mas igualmente importantes; • É afetado pela presença de atributos redundantes, que têm maior peso no modelo; e • O tratamento de atributos contínuos não é direto; assim, é necessário discretizá-los, perdendo-se informação.
Árvore de decisão	<ul style="list-style-type: none"> • O processo de construção seleciona os atributos a usar no modelo de decisão; • Os atributos irrelevantes são automaticamente eliminados; • É facilmente interpretado, permitindo que os usuários entendam e expliquem como o modelo está tomando suas decisões; e • É invariante a transformações monótonas de variáveis de entrada. 	<ul style="list-style-type: none"> • Árvore de decisão com diversos nós, galhos e folhas podem ser difíceis de interpretar; • Pequenas variações no conjunto de treinamento podem levar a grandes variações na árvore final, o que pode prejudicar a estabilidade do modelo; • Pode ter uma baixa acurácia preditiva; e • Tem dificuldades em lidar com valores ausentes, devido ao fato de ter uma hierarquia de testes.
RNA	<ul style="list-style-type: none"> • Tem alto desempenho preditivo; • Tem capacidade de modelagem de padrões mais complexos que outros algoritmos; • Pode ser usado para problemas de classificação e de regressão com base em dados numéricos; e • Tem tolerância a falhas e ruídos. 	<ul style="list-style-type: none"> • É computacionalmente muito intenso e tem treinamento lento – principalmente, quando a rede é muito complexa; • Dependendo da complexidade, há uma dificuldade em se entender como e por que os modelos tomam determinadas decisões (caixas-pretas); • É difícil escolher o melhor conjunto de parâmetros para a arquitetura da rede; • Lida apenas com valores numéricos; e • Seus resultados são estocásticos e dependem da ordem de apresentação dos objetos e dos pesos iniciais atribuídos a suas conexões.

Após a geração do modelo preditivo a partir de um algoritmo de ML, seu desempenho deve ser avaliado para verificar se é adequado. Nesse sentido, sua utilidade é usualmente medida pelo seu desempenho na tarefa para a qual foi desenvolvido. A seção a seguir trata melhor desse aspecto.

COMO OS MODELOS DE ML DESENVOLVIDOS SÃO AVALIADOS?

Após o desenvolvimento dos modelos baseados em algoritmos de ML, é necessário avaliar seu desempenho. Usualmente, a avaliação do desempenho é realizada com base em dados de teste, os quais são uma amostra aleatoriamente selecionada dos dados reais, mas não utilizados no treinamento do modelo. Comumente, a proporção de dados de teste é menor que a de dados de treinamento. Diversas técnicas podem ser empregadas para avaliação, sendo a adequação das métricas de desempenho dependente do objetivo.

Em modelos preditivos de classificação, pode-se empregar a análise de uma matriz de confusão $n \times n$ (matriz de comparação entre dados reais e dados previstos pelo modelo), que permite avaliar o desempenho do modelo conforme os seus acertos em relação aos dados de teste. Nesse caso, geram-se combinações de dados: “verdadeiros positivos” (VP) e “verdadeiros negativos” (VN), assim como “falsos positivos” (FP) e “falsos negativos” (FN). A partir da matriz de confusão, podem ser calculadas diferentes métricas que refletem o desempenho dos modelos de ML supervisionados preditivos: (i) Acurácia (*accuracy*) – proporção de observações que foram corretamente classificadas pelo preditor (Equação 1); (ii) Precisão (*Precision*) – proporção de observações previstas na classe positiva e que realmente pertencem a essa classe estimada (Equação 2); (iii) Revocação ou sensibilidade (*Recall*) – proporção de elementos da classe positiva que foram previstos como positivos (Equação 3); e (iv) F1-Score – média harmônica entre o *Precision* e o *Recall* (Equação 4).

$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN} \quad (1)$$

$$Recall = \frac{VP}{VP + FN} \quad (3)$$

$$Precision = \frac{VP}{VP + FP} \quad (2)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

Já no caso de modelos de ML preditivos relacionados à regressão, são estimadas métricas de análise de desempenho baseadas em erros. As principais métricas usadas nesse contexto são: (a) *Mean squared error* (MSE) – média das diferenças ao quadrado entre o previsto e o real (Equação 5); (b) *Root Mean squared error* (RMSE) – desvio-padrão das diferenças entre o previsto e o real mensurado (Equação 6); (c) *Mean absolute error* (MAE) – média das diferenças, em módulo, entre o previsto e o real (Equação 7); e (d) *Mean absolute percentage error* (MAPE) – diferenças percentuais, em módulo, entre o previsto e o real (Equação 8).

$$MSE = \frac{1}{n} \sum_{i=1}^n (|valor_{real\ i} - valor_{previsto\ i}|)^2 \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (|valor_{real\ i} - valor_{previsto\ i}|) \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (|valor_{real\ i} - valor_{previsto\ i}|)^2}{n}} \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n [|(valor_{real\ i} - valor_{previsto\ i}) \div valor_{real\ i}|] \quad (8)$$

No que se refere às métricas apresentadas, destaca-se que, no caso daquelas relacionadas à classificação, quanto maior o valor obtido, melhor o desempenho do modelo; em contrapartida, no caso das métricas de regressão, a interpretação é inversa. Ademais, dependendo do fenômeno abordado, uma

métrica pode ser mais adequada que outra. Por exemplo, no caso da evasão escolar previamente citada, modelos que prevejam com maior assertividade os estudantes que vão evadir parecem mais interessantes do que aqueles que preveem os que não vão evadir.

CONSIDERAÇÕES FINAIS

A pesquisa em IA tem sido cada vez mais comum nas diversas áreas da Educação. Diversos têm sido os benefícios relatados sobre o emprego de IA em diversos contextos educacionais, tais como: geração automática de conteúdo, avaliações personalizadas, estímulo à criatividade, aumento da eficiência etc. (Lima & Serrano, 2024; Lima et al., 2024). Conforme Durso (2024, p. 1), “é impossível negar que o uso de tecnologias na sala de aula (e a IA é uma delas), quando bem feito, potencializa o processo de ensino-aprendizagem”. Por outro lado, diversas limitações/preocupações são destacadas na literatura ao considerar o uso dessa tecnologia na Educação, tais como: falhas lógicas, respostas imprecisas e/ou enviesadas, risco de plágio, substituição do professor, dilemas éticos, não neutralidade da IA etc. (Durso, 2024; Lima & Serrano, 2024; Lima et al., 2024).

Considerando todo o exposto, espera-se que as definições apresentadas neste trabalho expandam a compreensão dos leitores dos trabalhos em Educação que tratem do tema IA, uma vez que tais trabalhos tendem a ser cada vez mais comuns e relevantes no curto e no médio prazo. Assim, “desmistificar” a “entidade IA” é muito importante para possibilitar a apreensão dos termos pelos pesquisadores, educadores e estudantes, que podem compreender melhor como essa tecnologia funciona do ponto de vista técnico, ao mesmo tempo que fazem reflexões sobre seus efeitos sociais.

Cumprir destacar que esta resenha é uma pequena contribuição nesse sentido, já que foram selecionados apenas alguns conceitos e classificações para explanação, assim como foram selecionados apenas alguns algoritmos e foram omitidos detalhes sobre a operacionalização da IA para fins de simplificação. Novos trabalhos nesse sentido ajudarão a consolidar tais conceitos e classificações, considerando as especificidades da Educação. Reproduzindo o exposto por Lima e Serrano (2024, p. 11), espera-se que tenha ficado “evidente que este é apenas o início de uma jornada de descoberta. À medida que a [IA] continua a evoluir e a se infiltrar nas instituições educacionais, faz-se necessário permanecer vigilantes, críticos e, acima de tudo, orientados por uma paixão inabalável pela Educação centrada no ser humano”.

REFERÊNCIAS

- Azambuja, C. C. D., & Silva, G. F. D. (2024). Novos desafios para a educação na Era da Inteligência Artificial. *Filosofia Unisinos*, 25(1), e25107. <https://doi.org/10.4013/fsu.2024.251.07>
- Burger, S. V. (2018). *Introduction to machine learning with R: Rigorous mathematical analysis*. O'Reilly Media, 2018.
- Durso, S. D. O. (2024). Reflexões sobre a aplicação da inteligência artificial na educação e seus impactos para a atuação docente. *Educação em Revista* 40, e47982 <https://doi.org/10.1590/0102-469847980>
- Faceli, K. et al. (2023). *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. 2 ed. Rio de Janeiro: LTC, 2021.
- Lantz, B. (2019). *Machine learning with R: expert techniques for predictive modeling*. Packt publishing ltd.
- Lima, C. B., & Serrano, A. (2024). Inteligência Artificial Generativa e ChatGPT: uma investigação sobre seu potencial na Educação. *Transinformação*, 36, e2410839. <https://doi.org/10.1590/2318-0889202436e2410839>
- Lima, G. D. M., Ferreira, G. M. D. S., & Carvalho, J. D. S. (2024). Automação na educação: caminhos da discussão sobre a inteligência artificial. *Educação e Pesquisa*, 50, e273857. <https://doi.org/10.1590/S1678-4634202450273857>
- Nwanganga, F., & Chapple, M. (2020). *Practical machine learning in R*. John Wiley & Sons.
- Oliveira, C., & Avelar, E. A. (2023). A era dos algoritmos de inteligência artificial no controle gerencial. *Revista Mineira de Contabilidade*, 24(2), 4-6. <https://doi.org/10.51320/rmc.v24i2.1543>

OpenAI (2025). ChatGPT (versão 4). OpenAI. <https://chat.openai.com>

Parreira, A., Lehmann, L., & Oliveira, M. (2021). O desafio das tecnologias de inteligência artificial na Educação: percepção e avaliação dos professores. *Ensaio: avaliação e políticas públicas em educação*, 29, 975-999. <https://doi.org/10.1590/S0104-40362020002803115>

Piva Jr., D. et al. (2019). *Algoritmos de programação de computadores*. 2 ed. Rio de Janeiro: Elsevier.

Rodrigues, O. S., & Rodrigues, K. S. (2023). A inteligência artificial na educação: os desafios do ChatGPT. *Texto Livre*, 16, e45997. <https://doi.org/10.1590/1983-3652.2023.45997>

Submetido: 10/03/2025

Aprovado: 11/03/2025