

# Inteligência Artificial: noções básicas para os profissionais de saúde

Artificial Intelligence: basics for healthcare professionals

Milena Martello Cristófal<sup>1</sup> , Renan Martello Cristófal<sup>1</sup> ,  
Soraya Gomes de Amorim Andrade<sup>1</sup> , Fernando Moreira de Andrade<sup>1</sup> ,  
Alexandre Dias Porto Chiavegatto Filho<sup>1</sup> , José Mendes Aldrighi<sup>1</sup> 

## RESUMO

**Introdução:** Nos últimos anos, a inteligência artificial (IA) tem se mostrado um campo em constante evolução, capaz de proporcionar benefícios significativos em diversas áreas, incluindo a saúde. Através do desenvolvimento de algoritmos e modelos estatísticos, a IA tem o potencial de auxiliar na tomada de decisões, impulsionando o avanço, por exemplo, da Medicina de Precisão. **Objetivos:** Nesse contexto, os autores propõem uma revisão prática para esclarecer e nortear conceitos em inteligência artificial. **Métodos:** Trata-se de uma revisão narrativa da literatura, a partir de artigos publicados no MEDLINE. **Resultados:** Dentre os diversos modelos possíveis de uso da IA, o mais tradicional segue sendo o fluxograma de captação de dados, seguido pela limpeza, manipulação e preparação dessas informações. Então, elabora-se o treino e a validação do modelo, otimização de hiperparâmetros para posterior disponibilização do conteúdo criado, método que será pormenorizado ao longo deste texto. **Conclusão:** A incorporação da IA em saúde é inequívoca, contribuindo para análise de bancos de dados complexos, auxílio em ferramentas diagnósticas e otimização de terapias, dentre outros.

**Palavras-chave:** Inteligência artificial, Tecnologia de informação em saúde, Informática, Saúde, Ciência de dados, *Big data*.

## ABSTRACT

**Introduction:** In recent years, artificial intelligence (AI) has proven to be a rapidly evolving field capable of providing significant benefits in various areas, including healthcare. Through the development of algorithms and statistical models, AI has the potential to assist in decision-making, driving advancements such as Precision Medicine. **Objectives:** In this context, authors propose a practical review to clarify and guide concepts in artificial intelligence. **Methods:** This is a narrative literature review based on articles published in MEDLINE. **Results:** Among the various possible models for AI usage, the most traditional is still the data capture flowchart, followed by data cleaning, manipulation, and preparation. Then, the model training and validation, hyperparameter optimization, and subsequent deployment of the created content are elaborated upon in this text. **Conclusion:** The incorporation of AI in healthcare is undeniable, contributing to the analysis of complex databases, assisting in diagnostic tools, and optimizing therapies, among other applications.

**Keywords:** Artificial intelligence, Health information technology, Informatics, Health, Data science, Big data.

## INTRODUÇÃO

Há alguns anos foi lançado um documentário sobre a história do jogo de tabuleiro *Go*, surgido na China há mais de 2,5 mil anos, e que recentemente tinha adquirido popularidade no resto do mundo devido à sua rápida disseminação pela internet.

Muito praticado na Coreia, o jogo é disputado por dois jogadores e exige uma grande aptidão estratégica e raciocínio mental, envolvendo a movimentação de pedras pretas e brancas sobre um tablado semelhante ao jogo de xadrez. A meta é desafiante e visa buscar a soma zero e a informação perfeita.

Conscientes desse desafio, os produtores do documentário se interessaram em contar a história de uma empresa inglesa de tecnologia que promoveu um jogo do seu algoritmo de inteligência artificial (IA) contra o campeão mundial de *Go*, com o intuito de comparar a capacidade de decisão entre ambos.

Os diretores da empresa supunham que se o algoritmo fosse treinado previamente para praticar esse jogo, seria possível desenvolver uma estratégia ideal para atingir a vitória e, assim, dominar o campeão mundial. De fato, os diretores admitiam que o computador poderia atuar como um *dispositivo mágico* capaz

<sup>1</sup>Universidade de São Paulo, Faculdade de Saúde Pública – São Paulo (SP), Brasil.

Endereço para correspondência: Milena Martello Cristófal. Rua das Palmeiras, 225 apto 64 – Santa Cecília, 01226-010 – São Paulo (SP), Brasil.

E-mail: milena.martello@gmail.com

Trabalho recebido: 18/11/2022. Trabalho aprovado: 12/07/2023. Trabalho publicado: 17/10/2023.

Editor Responsável: Prof. Dr. Eitan Naaman Berezin (Editor Chefe)

de superar o poder da mente, e consideravam que os jogos e ambientes virtuais eram plataformas perfeitas para desenvolver e testar algoritmos de inteligência artificial.

E quanto ao final do filme? Quem foi o vencedor?

Ambos, pois no duelo travado, apesar de a máquina vencer o torneio, o campeão coreano, após esse revés, venceu todos os jogos seguintes que teve contra seus adversários. E, o mais importante, o campeão coreano reconheceu que muito tinha aprendido nessa disputa com o computador.

Essa breve introdução permite uma reflexão sobre a importância da tecnologia no desenvolvimento de estratégias que podem auxiliar na tomada de decisões. Nesse sentido, temos o uso crescente da inteligência artificial, que pode ser definida como qualquer técnica que capacite uma máquina a se aproximar da inteligência humana.

O aprimoramento tecnológico na área de IA tem sido tão rápido nos últimos anos que já desponta como um instrumento de grandes benefícios sociais, incluindo os direcionados para a área de saúde, que atualmente vive um novo tempo, o da Medicina de Precisão.

A Medicina de Precisão caracteriza-se por ser um novo modelo de atendimento sustentado por três pilares que integram entre si: o genético, o ambiental e o estilo de vida. O propósito da Medicina de Precisão é aumentar a eficácia de diagnósticos e de tratamentos, e ela só é viável por meio da colaboração com a IA, que representa uma estratégia promissora na análise de bancos de dados complexos que contenham grandes quantidades de variáveis populacionais, também conhecido como “*big data*”.

Diferentes especialidades em saúde estão percorrendo esse caminho para auxiliar na solução de problemas que anteriormente eram realizados exclusivamente pela mente humana e

agora passam a ter soluções efetivadas por meio de máquinas que aprendem e se capacitam na tomada de decisões por meio de sistemas, programas e algoritmos.

Deve ainda ser considerado que, até pouco tempo, a IA parecia distante da prática, mas hoje ela tem se tornado realidade em praticamente todos os segmentos profissionais da sociedade, não apenas na saúde. Dentre as muitas justificativas para essa constatação, destacam-se a gigantesca quantidade de dados que é obtida em diversos segmentos, o aperfeiçoamento de novos modelos de máquinas — bem mais ágeis e com maior capacidade computacional — e o progresso na elaboração de novos algoritmos que possuam melhor desempenho e rendimento.

## Metodologia em *Machine Learning*

A IA reúne conhecimentos de *software*, estatística, lógica e computação com o objetivo de ensinar máquinas a realizarem funções que eram anteriormente tidas como humanas, tais como interpretar e criar textos ou gerar associações entre fatores. Como a IA tornou-se um campo amplo de possibilidades de atuação, existem diversas subdivisões para a sua aplicabilidade técnica.

*Machine learning*, ou aprendizado de máquina, por exemplo, é um importante subconjunto de IA que é definido como “a ciência do desenvolvimento de algoritmos e modelos estatísticos que sistemas de computador usam para realizar tarefas sem instruções explícitas, baseando-se em padrões e inferências”<sup>(1)</sup>.

Um projeto de aprendizado de máquina normalmente segue o fluxograma composto pelas etapas de captação dos dados, limpeza e preparação dos dados, treino do modelo, otimização de hiperparâmetros e disponibilização do modelo, apresentadas no diagrama da Figura 1 e que serão discutidas a seguir<sup>(2,3)</sup>.



Figura 1 – Diagrama do *pipeline* de *machine learning*.

## Captação dos dados

O modelo de *machine learning* realiza inferências a partir de dados apresentados. Ou seja, a etapa de captação desses dados tem um papel fundamental na construção de um projeto, pois irá determinar quais características serão contempladas. Além disso, nessa etapa são necessários cuidados para melhorar a qualidade do dado utilizado, construindo uma amostra preferencialmente representativa da realidade, reduzindo os vieses e considerando fatores exógenos que possam estar vinculados ao dado.

## Limpeza e preparação dos dados

O processo de limpeza e preparação dos dados é fundamental para o bom desempenho de um projeto de *machine learning*. Nesta etapa, são realizadas as técnicas preliminares relacionadas ao pré-processamento dos dados, como tratamento de valores nulos e *outliers*, padronização de variáveis contínuas e separação de preditores categóricos.

Também é nesta etapa que é realizado um processo conhecido como *feature engineering*, que tem como objetivo criar novas variáveis que possam ajudar o modelo em sua tarefa de aprendizado. Por exemplo, podem ser criadas novas variáveis relacionadas à data, como o dia da semana ou se é final de semana/dia útil, ou ainda criar variáveis correlacionando outras do conjunto de dados, como o índice de massa corporal (IMC), que correlaciona o peso e a altura.

Após esse processo de criação de variáveis, torna-se necessário o processo de *feature selection*, com a exclusão de variáveis pouco significativas, variáveis fortemente correlacionadas e técnicas para a redução de dimensionalidade, reduzindo ruído a fim de diminuir a complexidade e facilitar o treinamento.

## Treino e validação do modelo

Após todo o processo de pré-processamento, com a limpeza dos dados, construção e seleção de variáveis, é possível seguir para a etapa de treinamento. Para avaliar o desempenho preditivo dos algoritmos em dados futuros, uma etapa muito importante é a separação de conjuntos de treino e teste, que comumente é de 70 e 30%, respectivamente. O conjunto de treino é utilizado para definir os parâmetros e hiperparâmetros de cada algoritmo, e o conjunto de teste é utilizado para testar a capacidade de generalização do modelo e obter boas previsões em novos dados. Outro conceito utilizado para garantir maior estabilidade e robustez do modelo é a validação cruzada. Este método consiste em realizar o treinamento de um mesmo algoritmo em diferentes subconjuntos de treino e teste, realizando, ao final, uma agregação das métricas de cada um dos treinos realizados e com isso obtendo um valor mais representativo da realidade.

Existem diversas formas de a *machine learning* ser aplicada de acordo com cada problema apresentado, conforme demonstra a Figura 2.

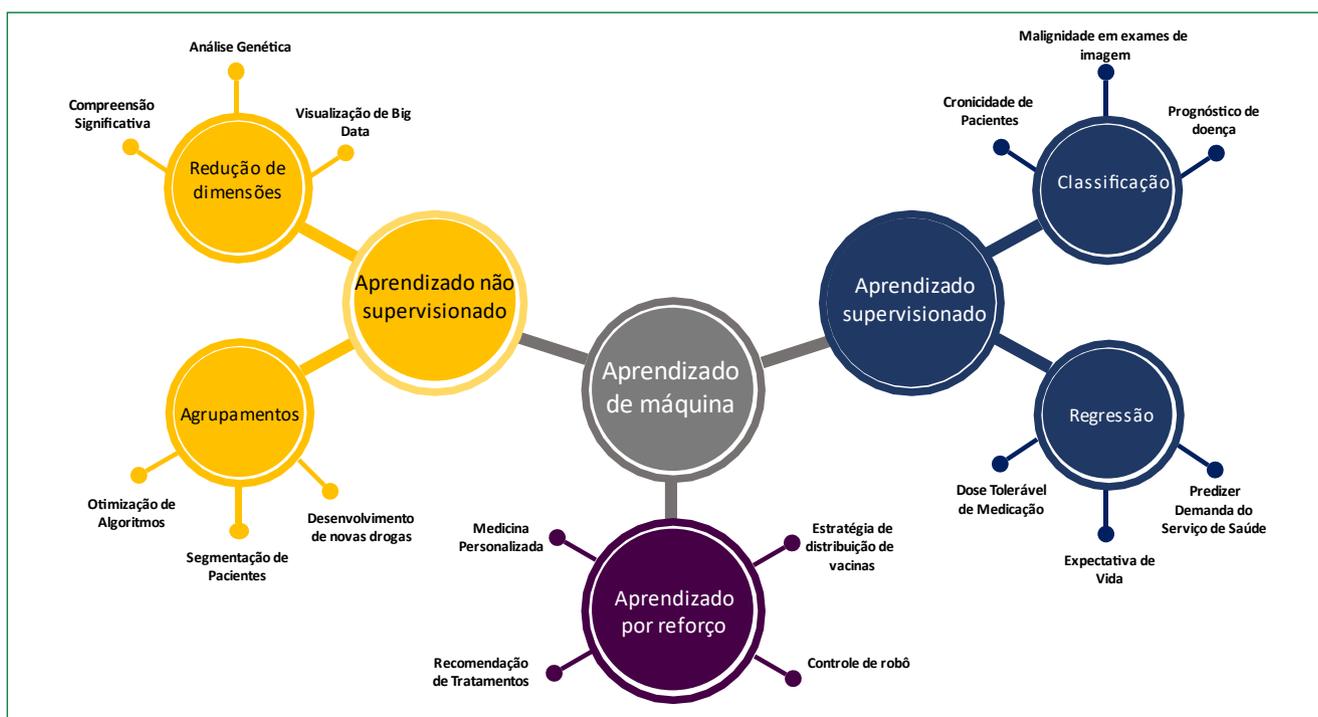


Figura 2 – Sumário dos tipos de *machine learning*.

### Aprendizado supervisionado/Supervised learning<sup>(4)</sup>

Esse tipo de algoritmo pode ser utilizado quando já se possui exemplos do resultado que a máquina deve prever. Dessa forma, o aprendizado irá acontecer por meio de um rótulo específico que precisa ser previsto. O aprendizado supervisionado possui, por sua vez, duas outras subdivisões para sua aplicação:

- Métodos de classificação: referem-se à previsão de categorias, como, por exemplo, qual animal está aparecendo em uma imagem, ou qual é o diagnóstico de um determinado paciente.
- Métodos de regressão: por meio dos métodos de regressão é possível prever valores contínuos. Por exemplo, em um hospital é possível prever a demanda futura de leitos ou a reserva de estoque de medicamentos de acordo com a sua demanda futura.

### Aprendizado não supervisionado/Unsupervised learning

O aprendizado não supervisionado é composto de técnicas de *machine learning* em que não existe uma resposta ou rótulo para a variável de interesse. Ao contrário, é permitido ao modelo aprender por conta própria e descobrir padrões gerais nos dados. A partir desses padrões e dessas regras encontrados é possível, por exemplo, criar sistemas de recomendação de fármacos<sup>(5)</sup> e agrupar pacientes com diagnóstico desconhecido de acordo com as semelhanças de suas características<sup>(6)</sup>.

São divididos principalmente em dois grandes grupos:

- Redução de dimensionalidade: com o crescimento exponencial da quantidade de dados, tem surgido a necessidade de transformar conjuntos com alta dimensionalidade e alta complexidade em conjuntos menores, mantendo a representatividade do conjunto original. Assim surgiram as técnicas de redução de dimensionalidade, que em medicina são usadas principalmente para otimização de algoritmos — em problemas de análise genética, por exemplo<sup>(6,7)</sup>.
- Agrupamento (*clustering*): o principal objetivo do *clustering* é o de identificar grupos com características semelhantes entre si, permitindo encontrar correlações e criar estratégias específicas para cada um dos grupos. Com o *clustering* é possível otimizar a prática clínica (8) e até definir fenótipos clínicos distintos, como no caso de pacientes sépticos (9).

### Aprendizado por reforço/Reinforcement learning

Essa é a principal técnica apresentada no documentário *Go*. Nesses modelos, a máquina é programada para tomar decisões de forma autônoma, ou seja, o algoritmo utiliza tentativa e erro, recebendo *feedbacks* positivos (recompensa) ou negativos

(punição) a cada interação, visando encontrar a melhor resposta para o problema apresentado<sup>(4)</sup>.

No caso do jogo *Go*, o sistema inicia a partida com apenas algumas regras básicas. Conforme o jogo se desenvolve, a partir de seus erros e acertos, novas estratégias vão sendo definidas. O modelo inicia o jogo com estratégias aleatórias, mas alcança técnicas sofisticadas ao longo das partidas.

### Definição do algoritmo

Definida a aplicação para o modelo de *machine learning*, é possível determinar quais algoritmos podem ser bons candidatos a realizar essa tarefa, dependendo também do tipo de entrada (imagens, tabelas, texto, som). Para dados estruturados (dados que podem ser facilmente tabelados) em tarefas supervisionadas, os melhores em termos de performance preditiva são os modelos baseados em árvores de decisão e técnicas de *boosting*, como *Gradient Boosting* e *XGBoosting*. O *K-means clustering* é bastante utilizado para tarefas de agrupamento. Para o processamento de imagens, sons e linguagem natural, como texto, destacam-se os modelos baseados em redes neurais (*deep learning*), principalmente os *transformers*.

### Otimização de hiperparâmetros

Hiperparâmetros são parâmetros ajustáveis que definem a forma de treinamento. A partir dos resultados da etapa anterior, é possível realizar um processo de ajuste fino nos modelos mais promissores para obter melhorias na performance preditiva. Para isso, são comparados modelos retreinados utilizando diferentes configurações atribuídas em um espaço de busca, selecionando o que apresentar as melhores métricas preditivas. Ao final dessa etapa, o modelo final é ajustado e estará pronto para ser disponibilizado.

### Disponibilização do modelo

Após a definição do modelo final, este poderá ser disponibilizado no seu local de uso e aplicado na prática. Destaca-se, no entanto, a importância de monitoramento da performance do modelo ao longo do tempo, verificando a existência de possíveis desvios conceituais (*concept drifts*) no conjunto de dados. Esses desvios conceituais acontecem se existe alguma mudança no perfil de comportamento da população ou fatores exógenos, como a COVID-19 ou o desenvolvimento de novas vacinas.

### Demais aplicações em saúde

Em saúde, a IA tem começado a ser incorporada em diversos processos. É possível observar o início do uso de *machine learning*, por exemplo, para análise de imagens com a finalidade de diagnóstico em diferentes tipos de câncer<sup>(7)</sup> ou em reprodução assistida para a determinação da qualidade do blastocisto e seu potencial de implantação<sup>(8)</sup>.

Na Saúde Pública, é possível utilizar IA para realizar a predição de custo em saúde<sup>(9)</sup> ou detectar possíveis procedimentos fraudulentos<sup>(10)</sup>, além de prever mortalidade neonatal<sup>(11)</sup> ou risco de incidência de câncer como o de mama<sup>(12)</sup>.

Ademais, têm começado a ser incorporadas técnicas de IA em aplicações comerciais, como na análise genética para recomendação de possíveis linhas de tratamento para cânceres<sup>(13)</sup> e ferramentas para a rápida detecção de sepse em pacientes internados<sup>(14)</sup>.

## CONCLUSÃO

Do exposto, depreende-se que a colaboração da IA na Medicina de Precisão deva ser incluída na análise de bancos de dados complexos elaborados por profissionais da saúde, uma vez que tem demonstrado ser capaz de incrementar a eficácia de diagnósticos e de tratamentos, especialmente em estudos populacionais, o que poderá redundar em expressivos benefícios para a sociedade.

**Financiamento:** nenhum.

**Conflitos de interesse:** os autores declaram não haver conflito de interesse.

**Contribuição dos autores:** MMC: Escrita – primeira redação, Escrita – revisão e edição. RMC: Escrita – primeira redação, Escrita – revisão e edição. SGAA: Análise formal. FMA: Análise formal. ADPCF: Curadoria de dados, Supervisão, Validação. JMA: Análise formal, Conceituação, Curadoria de dados, Metodologia, Supervisão, Validação.

## REFERÊNCIAS

1. Amazon. Machine learning [Internet]; 2022 [cited 2022 Jul 02]. Available from: <https://aws.amazon.com/pt/training/learn-about/machine-learning/>.
2. Russell SJ, Norvig P. Artificial intelligence: a modern approach. 4<sup>th</sup> ed. London: Pearson; 2021. 1136 p.
3. Lakshmanan V, Robinson S, Munn M. Machine learning design patterns: solutions to common challenges in data preparation, model building, and MLOps. Califórnia: O'Reilly Media; 2020. 405 p.
4. Meskó B, Görög M. A short guide for medical professionals in the era of artificial intelligence. NPJ Digit Med. 2020;3:e126. <https://doi.org/10.1038/s41746-020-00333-z>.
5. Hameed PN, Verspoor K, Kusljic S, Halgamuge S. A two-tiered unsupervised clustering approach for drug repositioning through heterogeneous data integration. BMC Bioinformatics. 2018;11:e129. <https://doi.org/10.1186/s12859-018-2123-4>.
6. Lopez C, Tucker S, Salameh T, Tucker C. An unsupervised machine learning method for discovering patient clusters based on genetic signatures. J Biomed Inform. 2018;85:e30. <https://doi.org/10.1016/j.jbi.2018.07.004>.
7. Zghal NS, Derbel N. Melanoma skin cancer detection based on image processing. Curr Med Imaging Rev. 2020;16(1):50-8. <https://doi.org/10.2174/15734056146616180911120546>.
8. Bhaskar D, Chang TA, Wang S. Current trends in artificial intelligence in reproductive endocrinology. Curr Opin Obstet Gynecol. 2022;34(4):159-63. <https://doi.org/10.1097/GCO.0000000000000796>.
9. Rakshit P, Zaballa O, Pérez A, Gómez-Inhieto E, Acaiturri-Ayesta MT, Lozano JA. A machine learning approach to predict healthcare cost of breast cancer patients. Sci Rep. 2021;11(1):12441. <https://doi.org/10.1038/s41598-021-91580-x>.
10. Zhang C, Xiao X, Wu C. Medical fraud and abuse detection system based on machine learning. Int J Environ Res Public Health. 2020;17(19):7265. <https://doi.org/10.3390/ijerph17197265>.
11. Batista AFM, Diniz CSG, Bonilha EA, Kawachi I, Chiavegatto Filho ADP. Neonatal mortality prediction with routinely collected data: a machine learning approach. BMC Pediatr. 2021;21(1):322. <https://doi.org/10.1186/s12887-021-02788-9>.
12. Stark GF, Hart GR, Nartowt BJ, Deng J. Predicting breast cancer risk using personal health data and machine learning models. PLoS One. 2019;14(12):e0226765. <https://doi.org/10.1371/journal.pone.0226765>.
13. Takeda M, Takahama T, Sakai K, Shimizu S, Watanabe S, Kawakami H, et al. Clinical application of the FoundationOne CDx assay to therapeutic decision-making for patients with advanced solid tumors. Oncologist. 2021;26(4):e588-96. <https://doi.org/10.1002/onco.13639>.
14. Laura. Inteligência artificial criada para gerenciar riscos. [Internet]. [citado 2022 Ago 22]. Disponível em: <https://laura-br.com/>.

