

## INTRODUÇÃO SOBRE MACHINE LEARNING E DEEP LEARNING

Érika Kayoko Hamaguti<sup>1</sup>, Fabricio Aparecido Breve<sup>2</sup>

<sup>1</sup>Mestranda na área de pesquisa de Inteligência Computacional no PPGCC da Unesp, e-mail: hamaguti.e.k@gmail.com.

<sup>2</sup>Prof. Dr. da Unesp de Rio Claro.

### RESUMO

O *Machine Learning* está sendo muito utilizado em várias aplicações, como detecção de SPAM, recomendação de vídeo e classificação de imagem. Dentro dos diferentes algoritmos de *Machine Learning*, é comum a utilização do *Deep Learning* nessas aplicações. *Machine Learning* pode reconhecer padrões e atuar na classificação de um conjunto de dados, que podem ser muito grandes ou muito complexos para os seres humanos conseguirem classificar. Três das principais categorias em *Machine Learning* são: aprendizado supervisionado; aprendizado não-supervisionado; e aprendizado semi-supervisionado. Dentro da categoria de aprendizado supervisionado pode-se citar o algoritmo de redes neurais artificiais, e um dos tipos de redes neurais mais conhecidos são as redes neurais convolucionais, que conseguem reconhecer objetos a partir de imagens. Dentro da área de *Machine Learning* existe o *Deep Learning*, em que os algoritmos conseguem realizar a extração de características dos dados de maneira automática, semelhante ao processo que ocorre no cérebro humano. Este trabalho teve como objetivo trazer uma visão geral sobre *Machine Learning* e *Deep Learning* para aqueles que pretendem iniciar os estudos na área de inteligência artificial. As considerações finais são que as redes neurais artificiais ficam cada vez mais poderosas e mais utilizadas conforme o poder computacional aumenta.

**Palavras-chave:** *Deep Learning*. *Machine Learning*. Redes Neurais Artificiais. Redes Neurais Convolucionais.

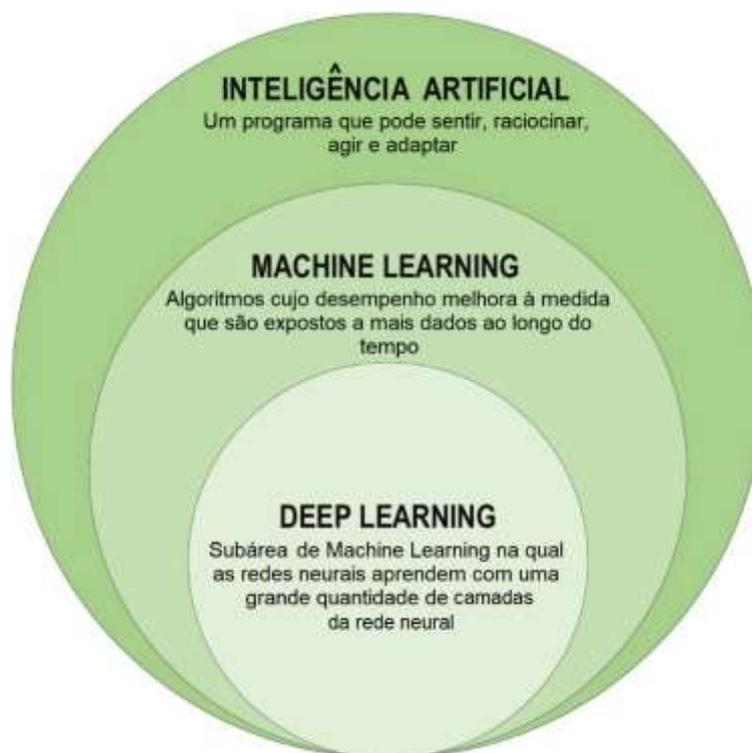
### 1 INTRODUÇÃO

A inteligência artificial é uma área de estudo que cria programas para que os computadores se tornem inteligentes e possam ser capazes de realizar o que a mente humana faz (BODEN, 1996; MCCARTHY, 2004). Uma subárea de inteligência artificial é o *Machine Learning*, que trata sobre o aprendizado de sistemas inteligentes (BODEN, 1996), com o objetivo de aprender a reconhecer padrões e conseguir tomar decisões automaticamente (MITCHELL, 1997). E uma subárea de *Machine Learning* é o *Deep Learning*, que utiliza uma grande quantidade de dados e obtém diferentes interpretações para realizar a classificação desses dados (ALZUBAIDI *et al.*, 2021).

As redes neurais artificiais são métodos que podem ser aplicados no contexto geral, como a interpretação de dados complexos, para aprender funções reais por meio de treinamentos com dados a serem utilizados (MITCHELL, 1997). Dentro de redes neurais artificiais e de *Deep Learning* pode-se destacar as redes neurais convolucionais, que reconhece objetos a partir de imagens (ALZUBAIDI *et al.*, 2021).

A Figura 1 mostra como a inteligência artificial, o *Machine Learning* e *Deep Learning* estão relacionados.

Figura 1 – Relação entre as áreas de inteligência artificial, *machine learning* e *deep learning*



Fonte: Adaptado de Alzubaidi *et al.* (2021).

Com isso, este trabalho teve como objetivo trazer conceitos fundamentais para ter uma visão geral sobre *Machine Learning* e três de suas principais categorias: aprendizado supervisionado; aprendizado não-supervisionado; e aprendizado semi-supervisionado. Dentro da categoria de aprendizado supervisionado será dada particular ênfase em redes neurais artificiais e, dentro de redes neurais artificiais, as redes neurais convolucionais. Além disso, será tratado sobre conceitos básicos de *Deep Learning*. Também teve como objetivo facilitar o acesso ao conteúdo desse tema traduzindo para português, pois boa parte dos conteúdos disponibilizados na internet sobre *Machine Learning* e *Deep Learning* estão em inglês.

## 2 MACHINE LEARNING

*Machine Learning*, ou aprendizado de máquina, é uma disciplina relacionada ao desenvolvimento de algoritmos que possibilitam a aprendizagem e a adaptação por meio de experiências (treinamento), imitando o aprendizado humano (BLUM, 2007; MITCHELL, 1997).

Por conta do surgimento do *Machine Learning*, os computadores podem realizar várias atividades que somente os humanos realizavam antes (DE FERNANDES TEIXEIRA, 2014). Dentre essas várias atividades, uma das mais significativas no uso de *Machine Learning* é a de classificação, que possibilita a previsão de determinados fenômenos, como classificação de objetos (ENGELEN; HOOS, 2020). Uma das razões que torna isso possível é a capacidade de reconhecer padrões automaticamente em dados utilizados para o treinamento de algoritmos (ALPAYDIN, 2004; MITCHELL, 1997). O objetivo principal, portanto, é aprender de forma automática a realizar o reconhecimento de padrões e a tomada de decisões (MITCHELL, 1997).

Um exemplo de como funciona um modelo de *Machine Learning* para a tarefa de classificação é mostrado na Figura 2. Inicialmente um conjunto de dados de entrada, representado pelas imagens de gato e cachorro, passa pelo pré-processamento, em que esses dados são preparados para realizar, em seguida, a extração de características existentes nos dados. Depois, passa pela seleção de características, onde são selecionadas as características mais relevantes dos dados. E, finalmente, é realizada a classificação de cada dado em uma determinada classe de saída. Nesse caso, as classes são a classe gato e a classe cachorro, e as características selecionadas são a base para que o modelo de *Machine Learning* possa classificar as próximas imagens em gato ou cachorro.

Figura 2 - Exemplo do funcionamento de um modelo de *machine learning*



Fonte: Adaptado de Alzubaidi *et al.* (2021).

A seguir serão apresentadas algumas das principais categorias de *Machine Learning*.

## 2.1 Aprendizado supervisionado

O aprendizado supervisionado é uma categoria que utiliza conjuntos de dados que são rotulados com base no conhecimento de especialistas de uma determinada área (HAYKIN, 2001). Esse aprendizado infere uma função ou regra para poder atribuir uma classe a um objeto nunca visto antes a partir de dados de treinamento previamente classificados (ALPAYDIN, 2004; MITCHELL, 1997). Ou seja, o objetivo do aprendizado supervisionado é prever uma saída para cada dado de entrada, baseando-se

no padrão aprendido em cada uma das classes no treinamento realizado com dados rotulados (MITCHELL, 1997). Um exemplo de uso de algoritmos do aprendizado supervisionado é a classificação de e-mails como *SPAM* e não-*SPAM*.

## 2.2 Aprendizado não-supervisionado

O aprendizado não-supervisionado utiliza conjuntos de dados que não estão rotulados. Sendo assim, os algoritmos buscam determinar como os dados estão organizados (MITCHELL, 1997). Ou seja, o objetivo do aprendizado não-supervisionado é encontrar possíveis padrões no conjunto de dados que antes eram desconhecidos para reconhecer agrupamentos (ALPAYDIN, 2004; MITCHELL, 1997). Um exemplo didático para o uso de algoritmos do aprendizado não-supervisionado é agrupar vários balões de diferentes cores por semelhança de cores.

## 2.3 Aprendizado semi-supervisionado

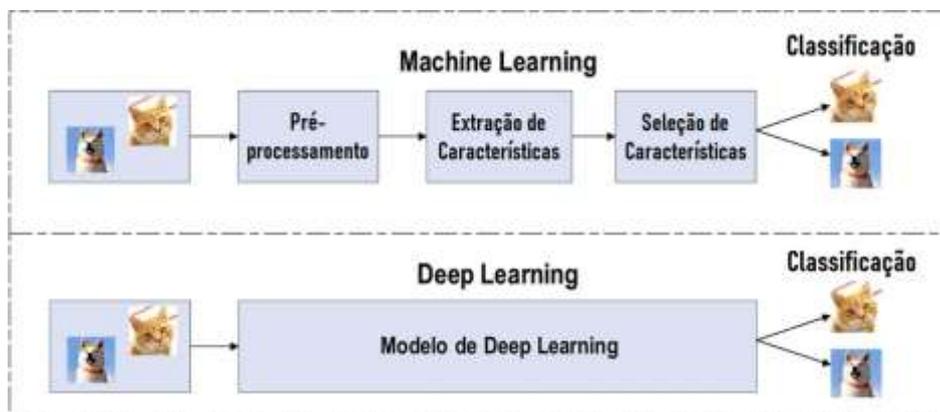
O aprendizado semi-supervisionado é um meio termo entre o aprendizado supervisionado e o não-supervisionado, ou seja, essa categoria utiliza tanto os dados rotulados quanto os não-rotulados no treinamento de um algoritmo. Para utilizar o aprendizado semi-supervisionado, é necessário que o conjunto de dados contenha informações relevantes de cada classe. Basicamente, os algoritmos do aprendizado semi-supervisionado realizam comparações entre os dados e classificam-os por alguma medida que identifique a semelhança entre esses dados para serem rotulados com base nos dados que já possuem rótulos (CHAPELLE; SCHÖLKOPF; ZIEN, 2006). Um exemplo para o uso de algoritmos de aprendizado semi-supervisionado é identificar fraudes em todas as transações feitas com cartão de crédito a partir de algumas transações que tem conhecimento que são fraudes ou não.

## 3 DEEP LEARNING

*Deep Learning*, ou aprendizado profundo, é uma subárea de *Machine Learning* e é baseado nos padrões de como o cérebro humano processa as informações (ALZUBAIDI *et al.*, 2021). *Deep Learning* é uma forma de explorar várias camadas de processamento de informações não-lineares por meio de técnicas de *Machine Learning*, de maneira que os algoritmos consigam aprender múltiplos níveis de representação e abstração, dando sentido nos dados (DENG; YU, 2014).

Diferente de *Machine Learning*, o *Deep Learning* consegue aprender e classificar em uma única etapa, como é mostrado na Figura 3.

Figura 3 - Diferença entre *deep learning* e *machine learning*



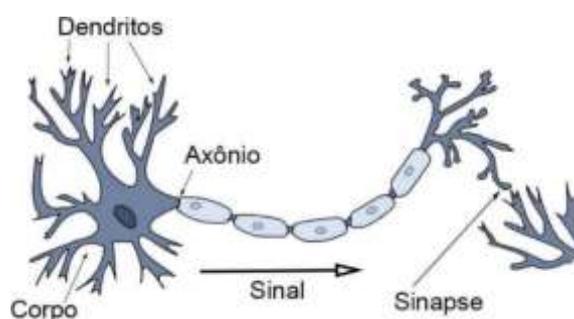
Fonte: Adaptado de Alzubaidi *et al.* (2021).

#### 4 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais, em geral, são algoritmos que imitam o cérebro humano na realização de uma tarefa específica. Elas utilizam os neurônios artificiais, que são baseados nos neurônios biológicos (HAYKIN, 2001).

No neurônio biológico, os sinais são recebidos de outros neurônios pelos dendritos e as conexões são feitas pelas sinapses. Quando recebe um estímulo, os sinais de entrada são definidos, depois são reunidos no corpo de um neurônio para gerar um sinal de saída para ser transmitido pelo axônio e, assim, para outros neurônios (KANDEL *et al.*, 2000). A Figura 4 mostra uma imagem das partes principais de um neurônio biológico.

Figura 4 - Neurônio biológico

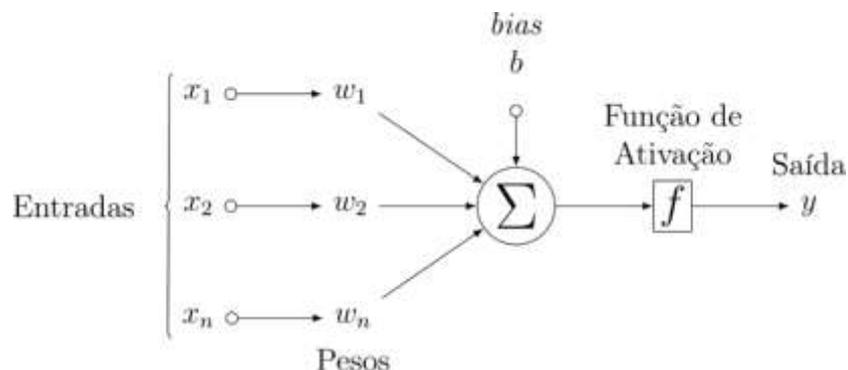


Fonte: Rodrigues (2018).

Nos neurônios artificiais, basicamente, existem os estímulos de entrada, as ligações sinápticas e as saídas, assim como nos neurônios biológicos. Porém, os neurônios artificiais não são tão complexos como os biológicos. Por esse motivo existem várias

pesquisas relacionadas às redes neurais artificiais (HAYKIN, 2001). A Figura 5 ilustra o modelo de um neurônio artificial.

Figura 5 - Neurônio artificial



Fonte: Rodrigues (2018).

A Equação 1 mostra a modelagem matemática de um neurônio artificial:

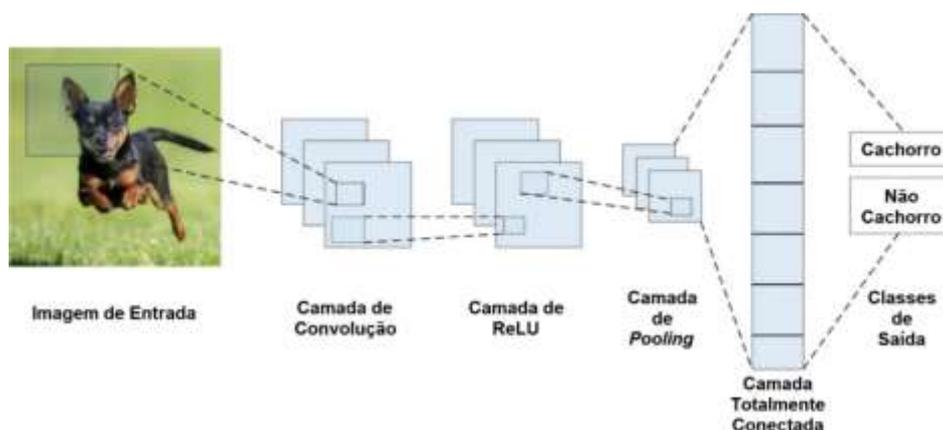
$$y_k = f \left[ \left( \sum_{i=1}^n x_i + w_{ki} \right) + b_k \right] \quad (1)$$

em que a saída de um determinado neurônio ( $k$ ) é representada por  $y_k$ . É realizada uma somatória do vetor de entrada ( $x_i$ ) multiplicado pelos respectivos pesos ( $w_i$ ), gerando um produto interno, e tudo isso somado ao bias ( $b$ ), em que o bias aumenta ou diminui a entrada da função de ativação ( $f$ ) (RODRIGUES, 2018). A função de ativação é uma função algébrica que decide se um neurônio será ativado ou não (HAYKIN, 2007), limitando a amplitude do sinal de saída de um neurônio (HAYKIN, 2001; RUSSELL; NORVIG, 2009). A ativação de um neurônio depende se o valor do produto interno gerado é maior ou menor do que um determinado limiar de ativação, que é definido dependendo da escolha de uma das funções de ativação (RUSSELL; NORVIG, 2009).

#### 4.1 Redes neurais convolucionais

As redes neurais convolucionais, do inglês *Convolutional Neural Network* (CNN), criado por LeCun *et al.* (1999), é baseada no córtex visual do cérebro e têm sido muito eficientes no reconhecimento de imagens, incentivando o seu uso em várias áreas de pesquisa. Uma CNN, mostrada na Figura 6 como um exemplo, é formada basicamente por camadas convolucionais, *pooling* e camadas totalmente conectadas para extrair as características dos dados de forma automática (ALZUBAIDI *et al.*, 2021; RODRIGUES, 2018). Nesse caso, a camada de ReLU representa a função de ativação.

Figura 6 - Exemplo de uma arquitetura de redes neurais convolucionais para classificação de imagens



Fonte: Adaptado de Alzubaidi *et al.* (2021).

Basicamente, a convolução é um tipo de operação matemática linear especializado que é utilizado para extrair as informações de uma imagem e manter as regiões relevantes dela (HAKIM; FADHIL, 2021). Após as camadas de convolução, vem as camadas de *pooling*, que simplificam as informações que chegam da camada anterior, reduzindo-as e mantendo somente as informações mais relevantes (ALZUBAIDI *et al.*, 2021; HAKIM; FADHIL, 2021). E, assim, chega na camada totalmente conectada (*Fully Connected*), onde utiliza as informações vindas da camada anterior para realizar a classificação das imagens, com base no conjunto de dados de treinamento (ALZUBAIDI *et al.*, 2021; HAKIM; FADHIL, 2021).

## 5 CONSIDERAÇÕES FINAIS

Neste trabalho foi possível trazer conceitos básicos sobre *Machine Learning* e *Deep Learning* de forma resumida, e ainda foi tratado sobre as Redes Neurais Artificiais e Redes Neurais Convolucionais. À medida que o poder computacional aumenta, as redes neurais artificiais vão se tornando cada vez mais poderosas e mais usadas. Com isso, foi possível ter uma visão geral sobre esse tema para aqueles que pretendem iniciar na área de inteligência artificial.

## 6 REFERÊNCIAS

ALPAYDIN, E. **Introduction to machine learning**. MIT Press, 2004.

ALZUBAIDI, L. *et al.* Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. **Journal of big Data**, v. 8, n. 1, p. 1-74, 2021.

BLUM. **Machine learning theory**. Carnegie Melon University, School of Computer Science, 2007. p. 26.

BODEN, M. A. **Artificial intelligence**. Elsevier, 1996.

CHAPELLE, O.; SCHÖLKOPF, B.; ZIEN, A. **Semi-Supervised Learning**. Adaptive Computation and Machine Learning. Cambridge: The Mit Press, 2006.

DE FERNANDES TEIXEIRA, J. **Inteligência artificial**. Pia Sociedade de São Paulo- Editora Paulus, 2014.

DENG, L.; YU, D. Introduction: Definitions and Background. In: DENG, L.; YU, D. **Deep Learning Methods and Applications**. Boston: Now Publishers, 2014. Cap. 1. p. 199-200. v 7.

ENGELEN, J. E. V.; HOOS, H. H. **A survey on semi-supervised learning**. Machine Learning, Springer, 2020. v. 109, n. 2, p. 373–440.

HAKIM, H.; FADHIL, A. Survey: Convolution Neural networks in Object Detection. **Journal of Physics: Conference Series**, 2021. v. 1804, n. 1. IOP Publishing.

HAYKIN, S. **Redes Neurais: Princípio e Prática**. Bookman, 2001.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 3rd Edition, 2007.

KANDEL, E. R. *et al.* **Principles of neural science**. McGraw-hill New York, New York, v. 4, 2000.

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

LECUN, Y. *et al.* Object Recognition with Gradient-Based Learning. In: Shape, Contour and Grouping in Computer Vision. **Lecture Notes in Computer Science**, 1999. v. 1681. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/3-540-46805-6\\_19](https://doi.org/10.1007/3-540-46805-6_19).

MCCARTHY, J. **What is artificial intelligence**. 2004. Disponível em: <<http://www-formal.stanford.edu/jmc/whatisai.html>>. Acesso em: 20 ago. 2022.

MITCHELL, T. **Machine learning**. McGraw Hill, 1997.

NATARAJAN, B. K. **Machine learning: a theoretical approach**. Morgan Kaufmann, 1991.

RODRIGUES, L. F. **Comparação entre Redes Neurais Convolucionais e técnicas de pré-processamento para classificar células HEP-2 em imagens de imunofluorescência**. 2018. 65 f. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Viçosa, Viçosa. 2018.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. Prentice Hall Press, Upper Saddle River, NJ, USA, 3rd edition, 2009.