



Science Deep Tech and innovation  
16 de novembro a 18 de novembro de 2022

# Inteligência Artificial e DataScience

## Construindo Pontes entre a Ciência e a Indústria

Elisangela Lopes de Faria





## Agenda

- **Conceitos de Inteligência Artificial**
  - **Aprendizado de máquina (Machine learning)**
  - **Tipos de aprendizados**
  - **Redes Neurais Artificiais (Modelos de aprendizado profundo)**
  - **Visão computacional**
- **Aplicações na indústria**
  - **Exemplos**

## Inteligência Artificial x Machine learning x Deep learning

Artificial Intelligence:

Machine Learning:

Termo frequentemente usado para descrever **máquinas**

Modelos computacionais **inspirados pelo sistema nervoso** central de um animal (em particular o cérebro) e são capazes de realizar o “**aprendizado de máquina**” bem como “**identificar padrões**”.

# Big Data x Data Science

- **Big Data:** A manipulação de grandes quantidades de dados que precisam ser **processados, transferidos e/ou armazenados**. Representa a condição no qual existem mais dados dos que as técnicas tradicionais podem processar.
- **Data Science:** Área da ciência capaz de **processar e gerenciar grandes quantidade de dados**. Área multidisciplinar que engloba a matemática, estatística, ciência da computação, ciência da informação e Inteligência Artificial.

## “Cientistas de Dados”

Trabalha com mineração de dados, inferência de dados, modelagem preditiva e desenvolvimento de algoritmos de ML

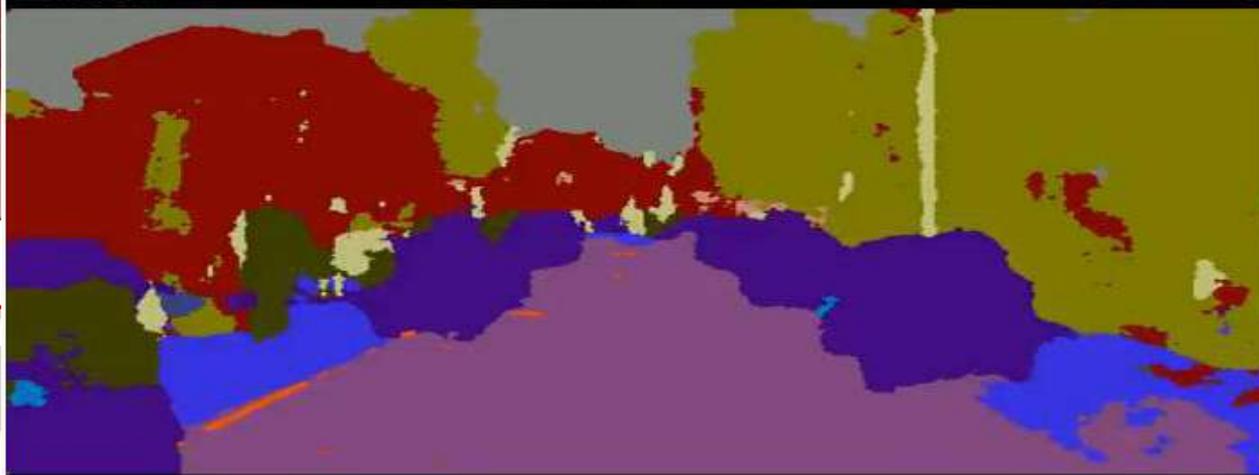
Empresas e instituições passaram de uma abordagem baseada em hipóteses para uma abordagem/decisão baseada em “dados reais”

Decisões tomadas a partir de modelos orientadas a dados (conjunto de treinamento).

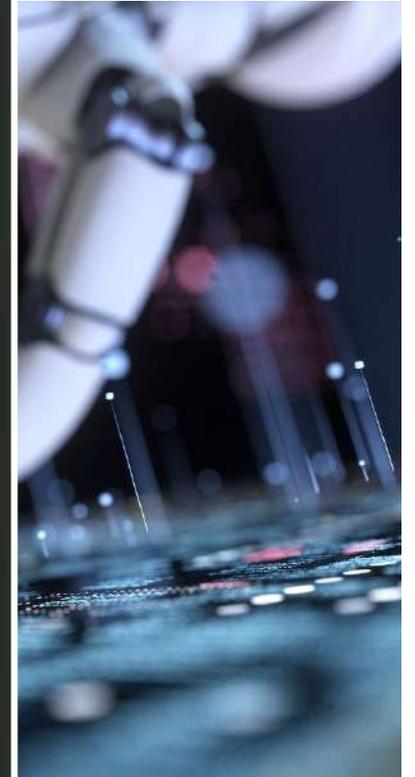
# ML: Supervisionado x Não Supervisionado

## MACHINE LEARNING

Identificação de câ



- Sky
- Building
- Pole
- Road Marking
- Road
- Pavement
- Tree
- Sign Symbol
- Fence
- Vehicle
- Pedestrian
- Bike

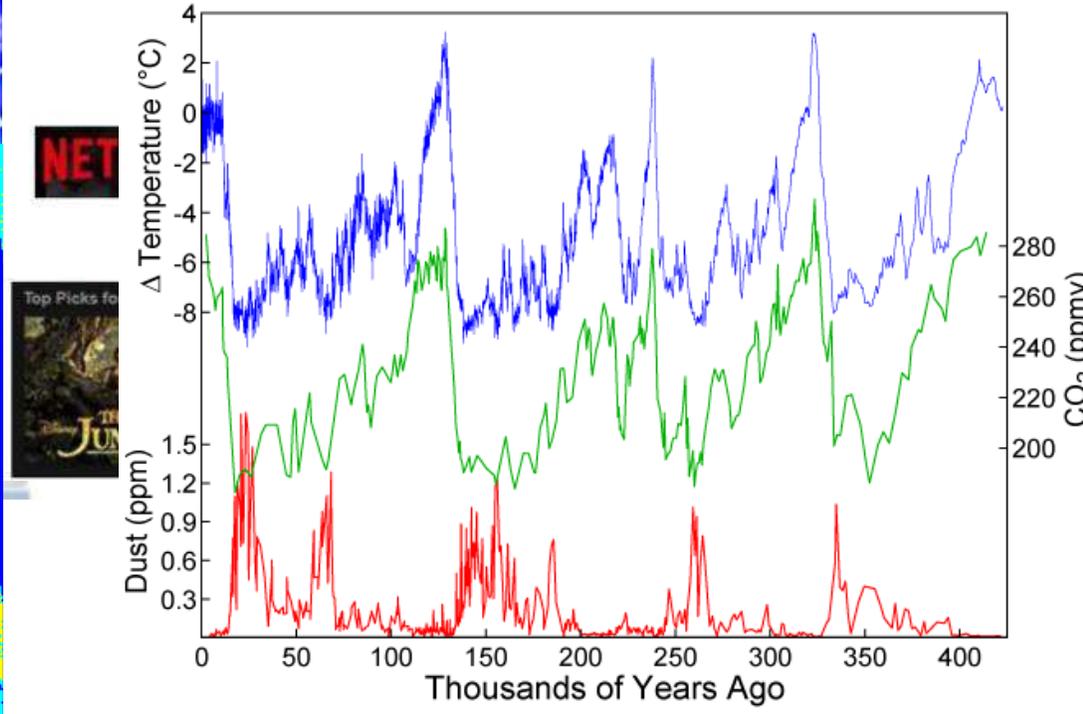


# ML: Supervisionado x Não Supervisionado

## MACHINE LEARNING

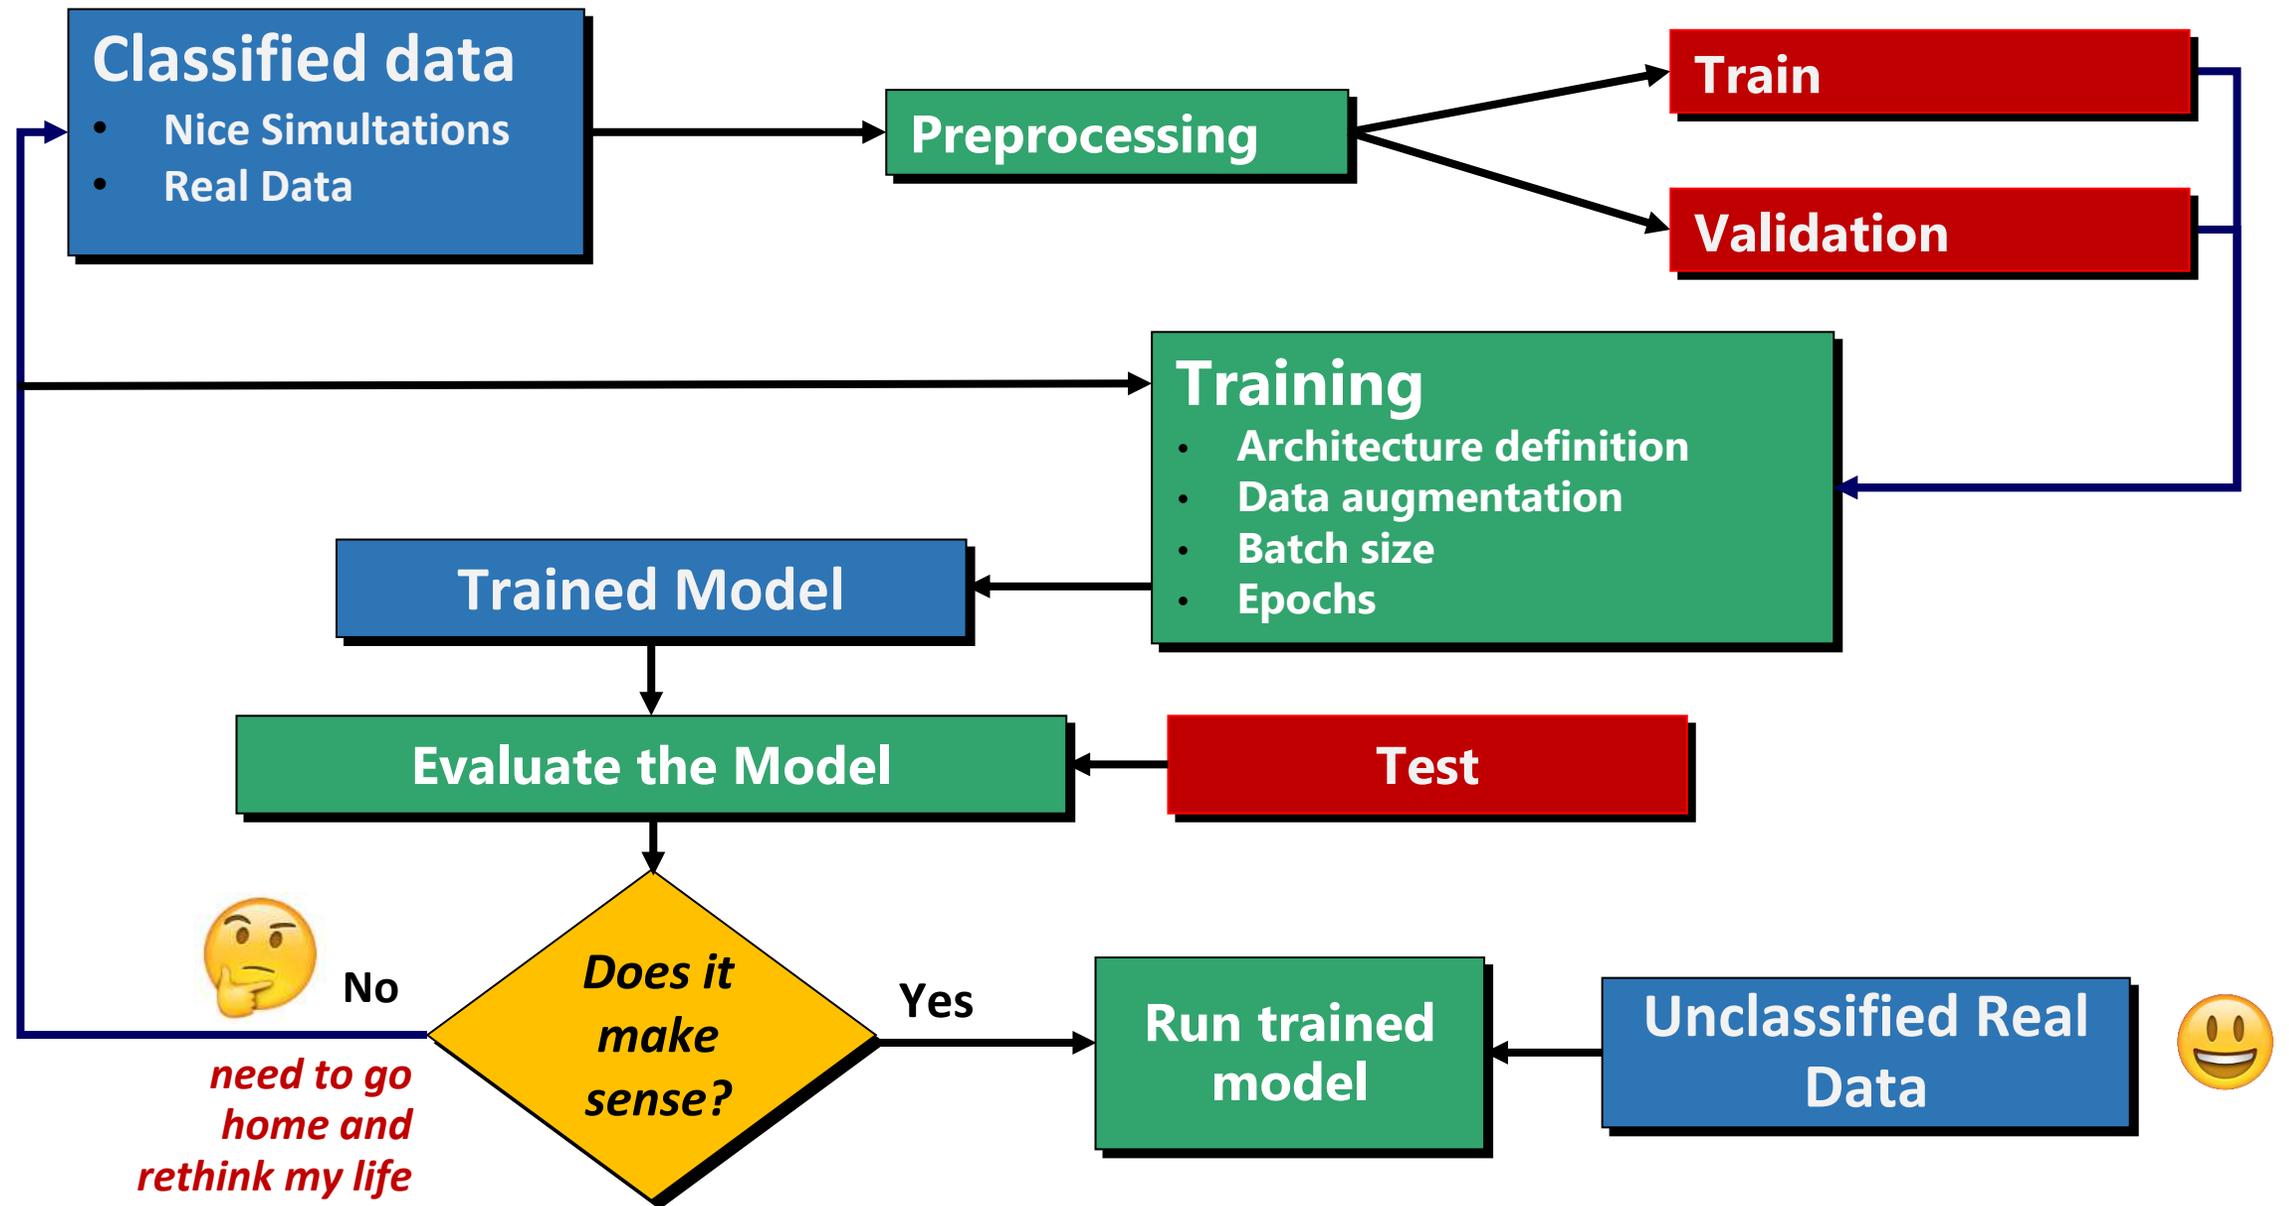


<https://www.noggle.online/knowledgebase/document>

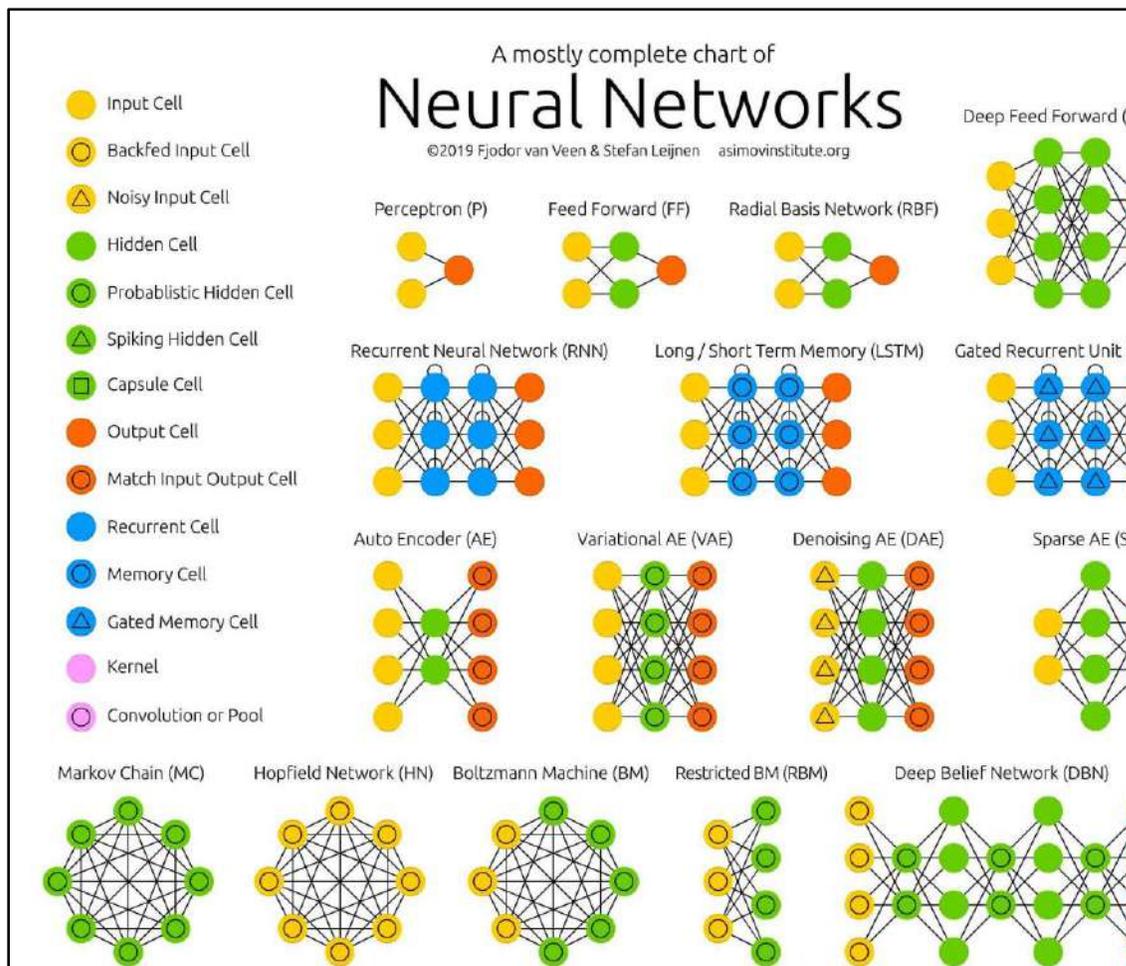


[https://serc.carleton.edu/download/images/15045/vostok\\_ice\\_core\\_data.png](https://serc.carleton.edu/download/images/15045/vostok_ice_core_data.png)

# ML: Pipeline Aprendizizado Supervisionado



# Redes Neurais: Arquiteturas



## Alguns termos básicos

Deep Learning é uma Rede Neural Artificial

Deep Learning é uma área de Machine Learning

## Alguns Termos de Redes Neurais Artificiais

**MLP:** Multi-layer Perceptron

**DNN:** Deep Neural Networks

**RNN:** Recurrent Neural Networks

**LSTM:** Long Short-Term Memory

**CNN ou ConvNet:** Convolution Neural Network

**AN:** Attention Networks

## Operações das Redes Neurais Artificiais

Função de Ativação

Backpropagation

Convolução

Pooling

<https://iaexpert.academy/2020/06/08/os-tipos-de-redes-neurais>

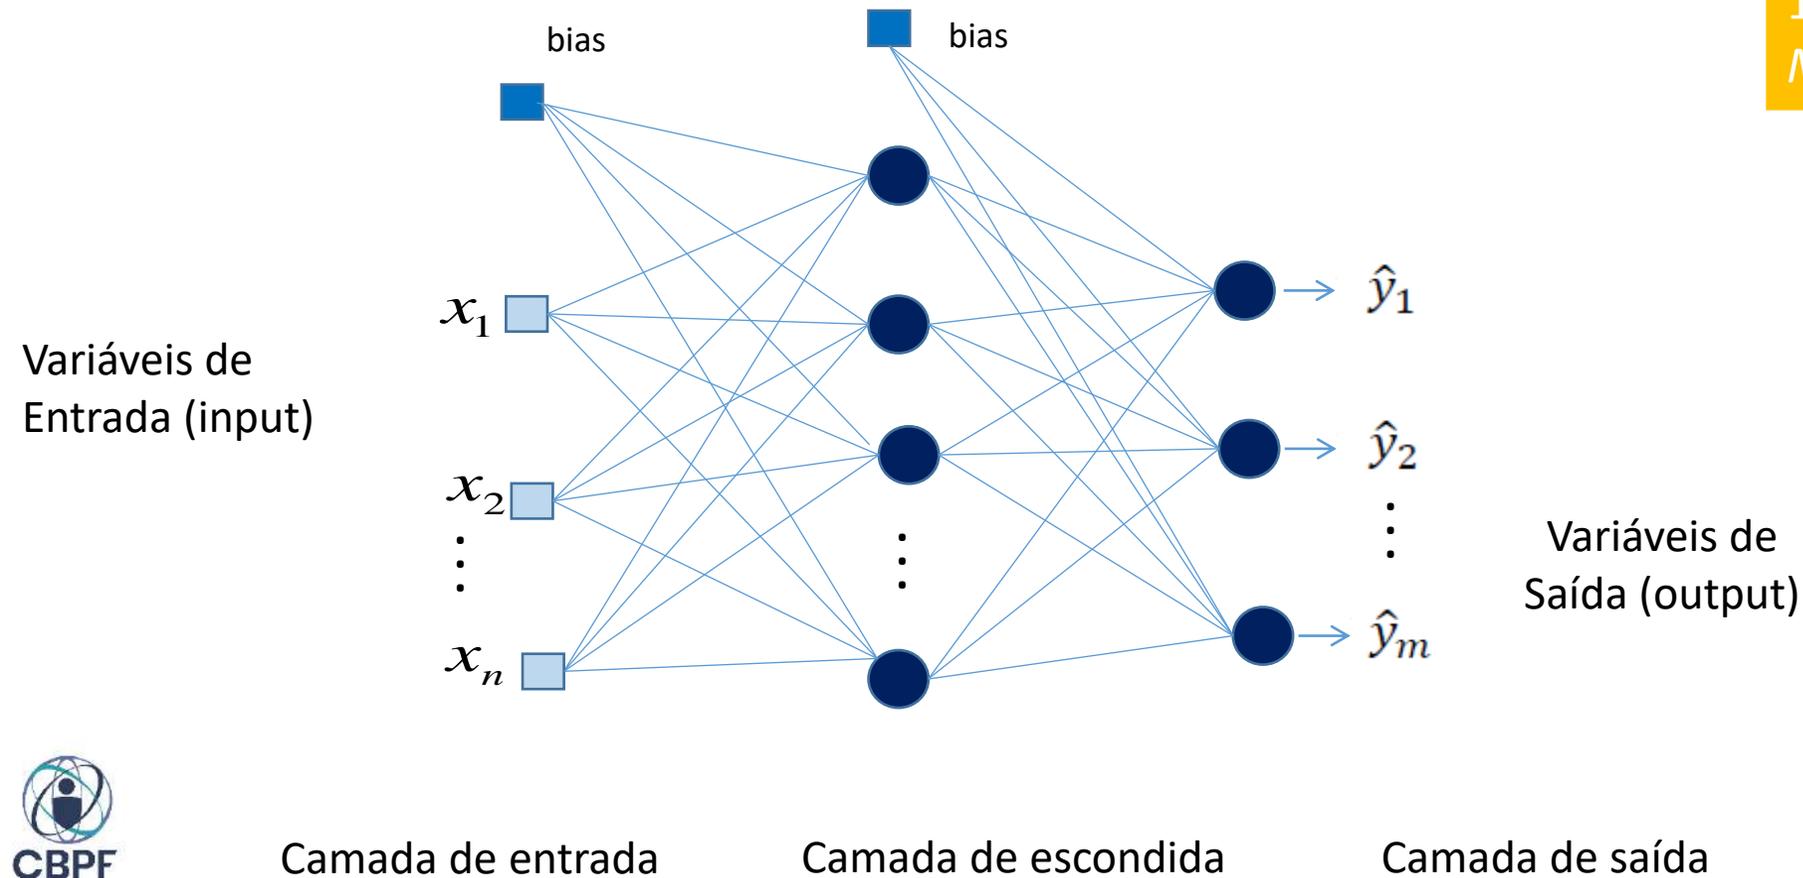
Redes Neurais Artificiais (RNAs) são modelos computacionais

particular o cérebro) e são capazes de realizar o “aprendizado de máquina” bem como “identificar padrões”.

# Redes Neurais: Multilayer Perceptrons - MLP

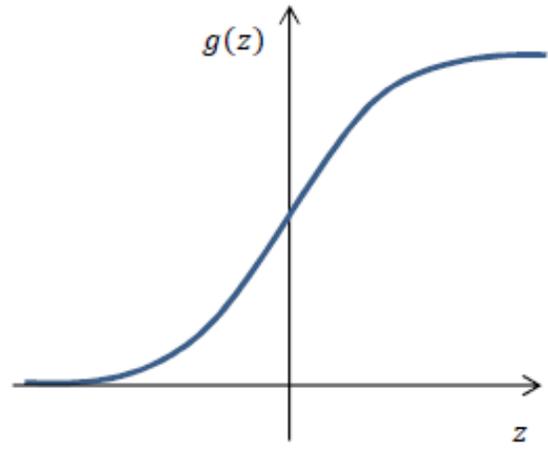
O modelo mais comum das redes neurais

Estrutura de rede:  
1 camada de processamento  
 $N$  entradas  
1 Bias  
 $M$  saídas



# Redes Neurais: Feedforward e Função de Ativação

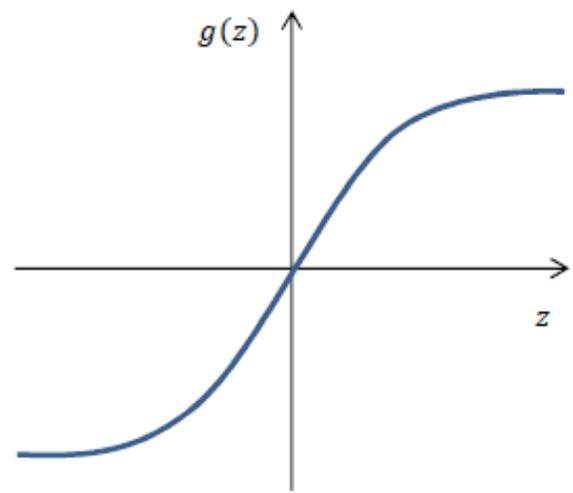
Processamento não linear do neurônio artificial é obtido pela função de ativação



Função sigmoide

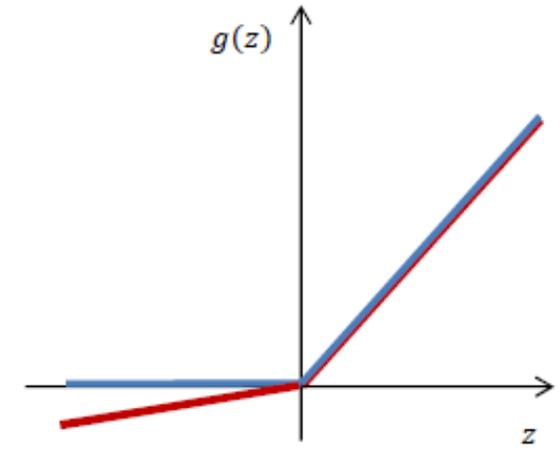
$$g(z) = \sigma(z) = \frac{1}{1 + \exp(-z)}$$

$$\tanh(z) = 2\sigma(2z) - 1$$



Função tan. hiperbólica

$$g(z) = \tanh(z) = \frac{1 - \exp(-z)}{1 + \exp(-z)}$$



Função ReLU

$$g(z) = z^+ = \max(0, z)$$

Leaky ReLU

$$g(z, \alpha) = z^+ + \alpha \min(0, z)$$

# Redes Neurais: Feedforward e Backpropagation

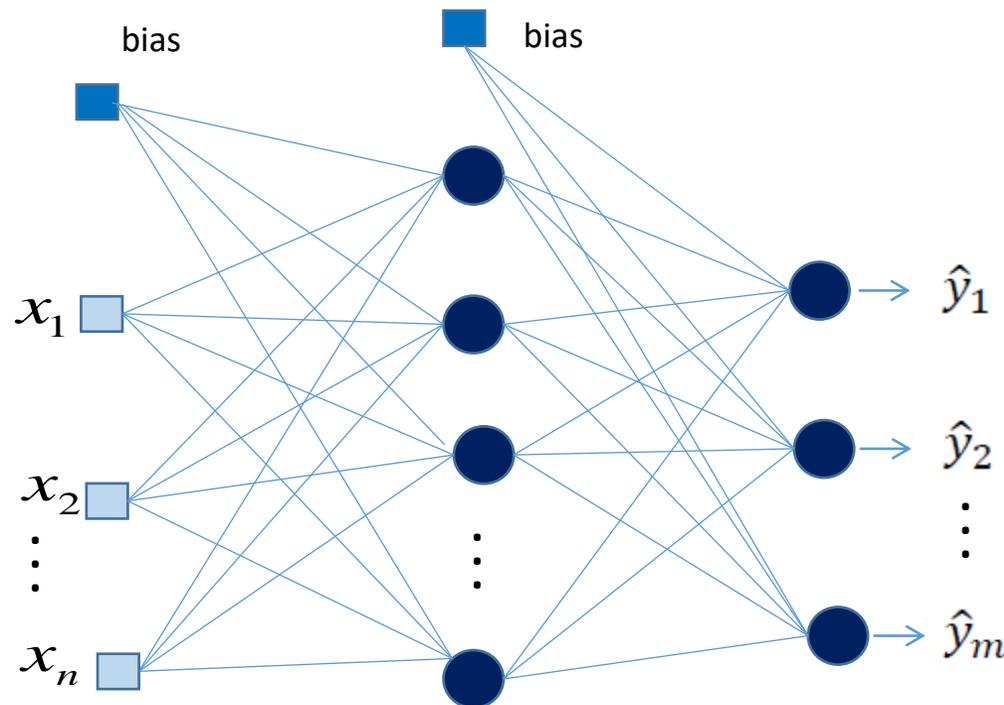
Treinamento: Algoritmo backpropagation

Treinar uma RNA é aprender os pesos, ou seja, encontrar os pesos sinápticos ( $w$ ) da rede que minimizem o erro entre a saída desejada  $y_j$  e a saída da rede neural  $\hat{y}_j$

$$E = \frac{1}{2} \sum_{j=1..m} (y_j - \hat{y}_j)^2$$

Através do método do gradiente descendente que envolve o cálculo da derivada parcial da função do erro em relação aos pesos da rede.

$$w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial E_{total}}{\partial w_{ij}}$$



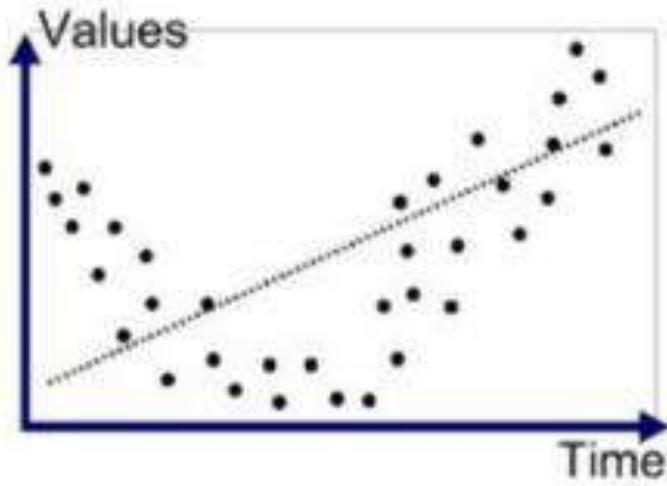
Variáveis de  
Entrada (input)

Camada de entrada

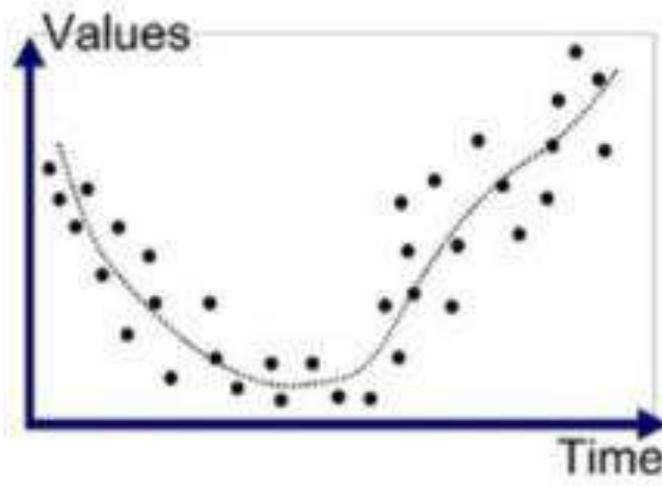
Camada de escondida

Camada de saída

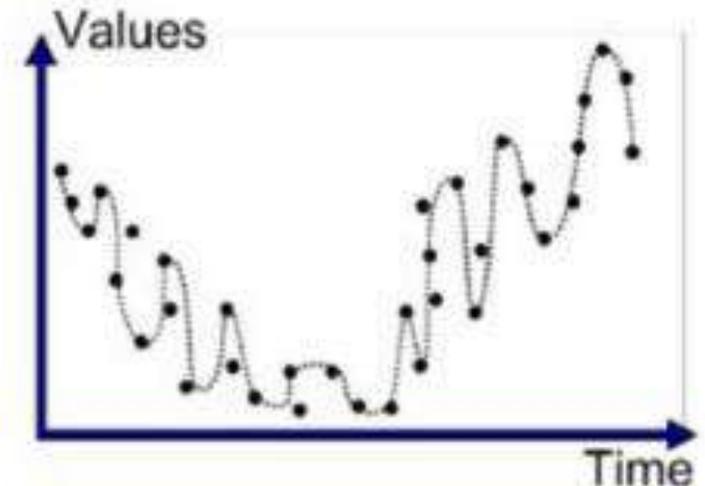
# Redes Neurais: Overfitting



Underfitted



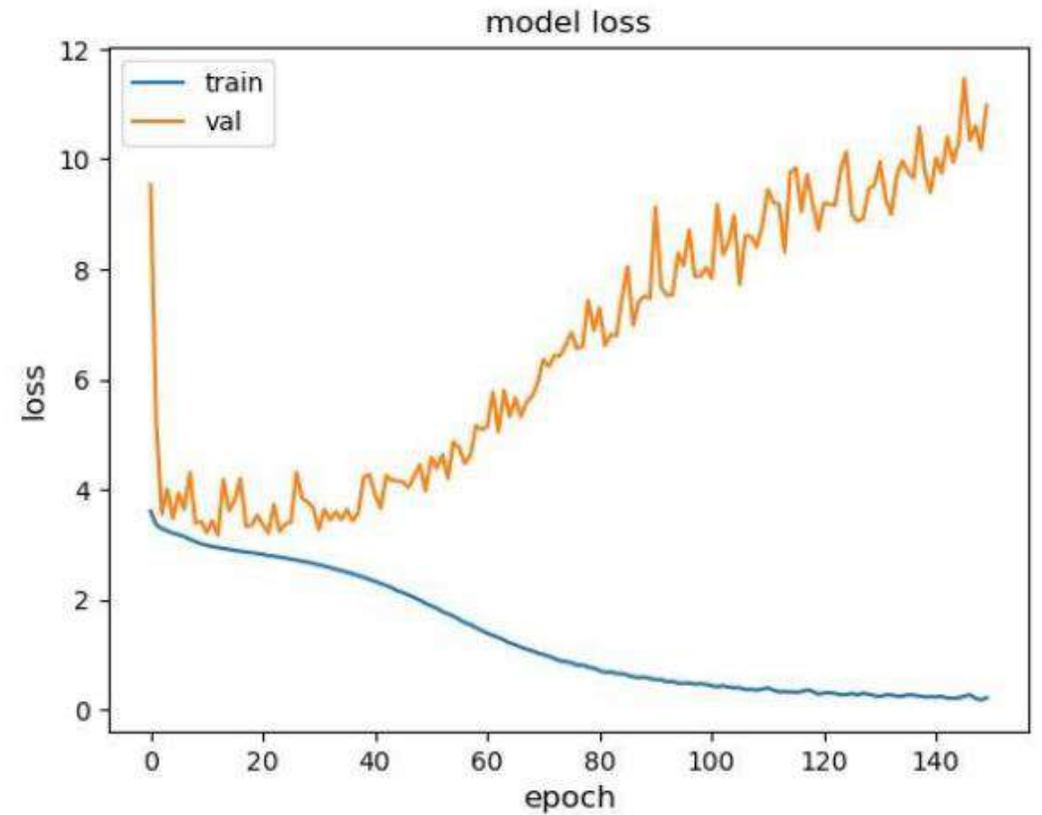
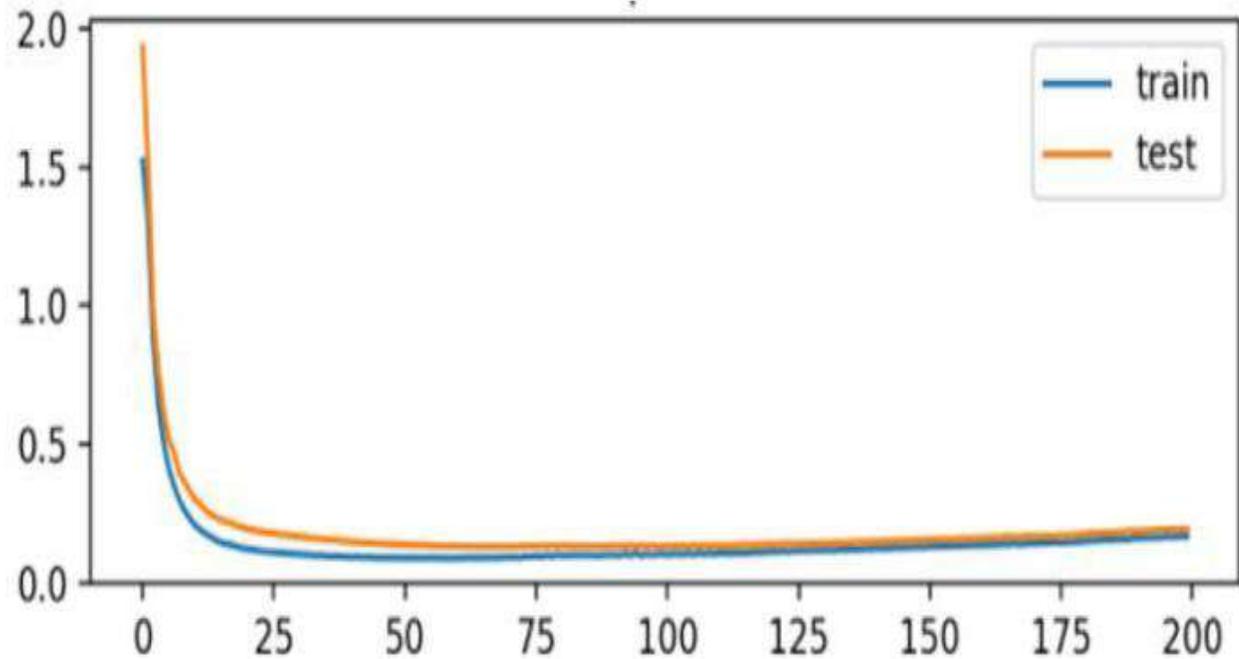
Good Fit/Robust



Overfitted

O **overfitting** (*sobreajuste*) é um termo para descrever quando um modelo se ajusta muito bem ao conjunto de dados, mas se mostra ineficaz para prever novos resultados.

# Redes Neurais: Loss e Overfitting



# Redes Neurais: Épocas x Batch x Iterações

**one epoch:** fase forward e backward (algoritmo backpropagation) de todos os exemplos do treinamento.

**Batch size:** quantidade de amostras do treinamento a serem utilizadas em uma fase forward/backward (atualização dos pesos). Quanto maior é o batch, mais espaço de memória será necessário.

**number of iterations:** número de batches necessários para completar uma época.

**Example: Para 1000 amostras do treinamento, e batch size de 500, então o algoritmo levará 2 iterações para completar uma época.**

# Redes Neurais: Deep Learning

## DEEP LEARNING = APRENDIZADO PROFUNDO

### • SISTEMAS COMPUTACIONAIS

- CPUs, GPUs, ASICs
- MEMÓRIA



### • BANCO DE DADOS ESTRUTURADOS

- Imagenet

IMAGENET

14,197,122 images, 21841 synsets indexed

[Explore](#) [Download](#) [Challenges](#) [Publications](#) [CoolStuff](#) [About](#)

### • P&D (CONCEITOS e ALGORITMOS)

- CNN, RCNN, BACKPROP, LSTM, ...

### • INFRAESTRUTURA DE SOFTWARE

- Git, AWS, AMAZON MECHANICAL TURK, GOOGLE TENSORFLOW



### • INTERESSE COMERCIAL E FINANCIAMENTO POR GRANDES COMPANHIAS

- Google, Facebook, Amazon, ...

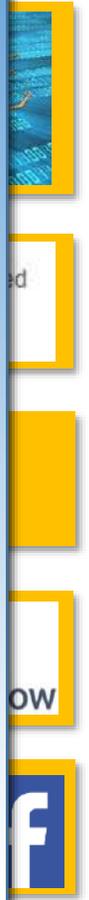
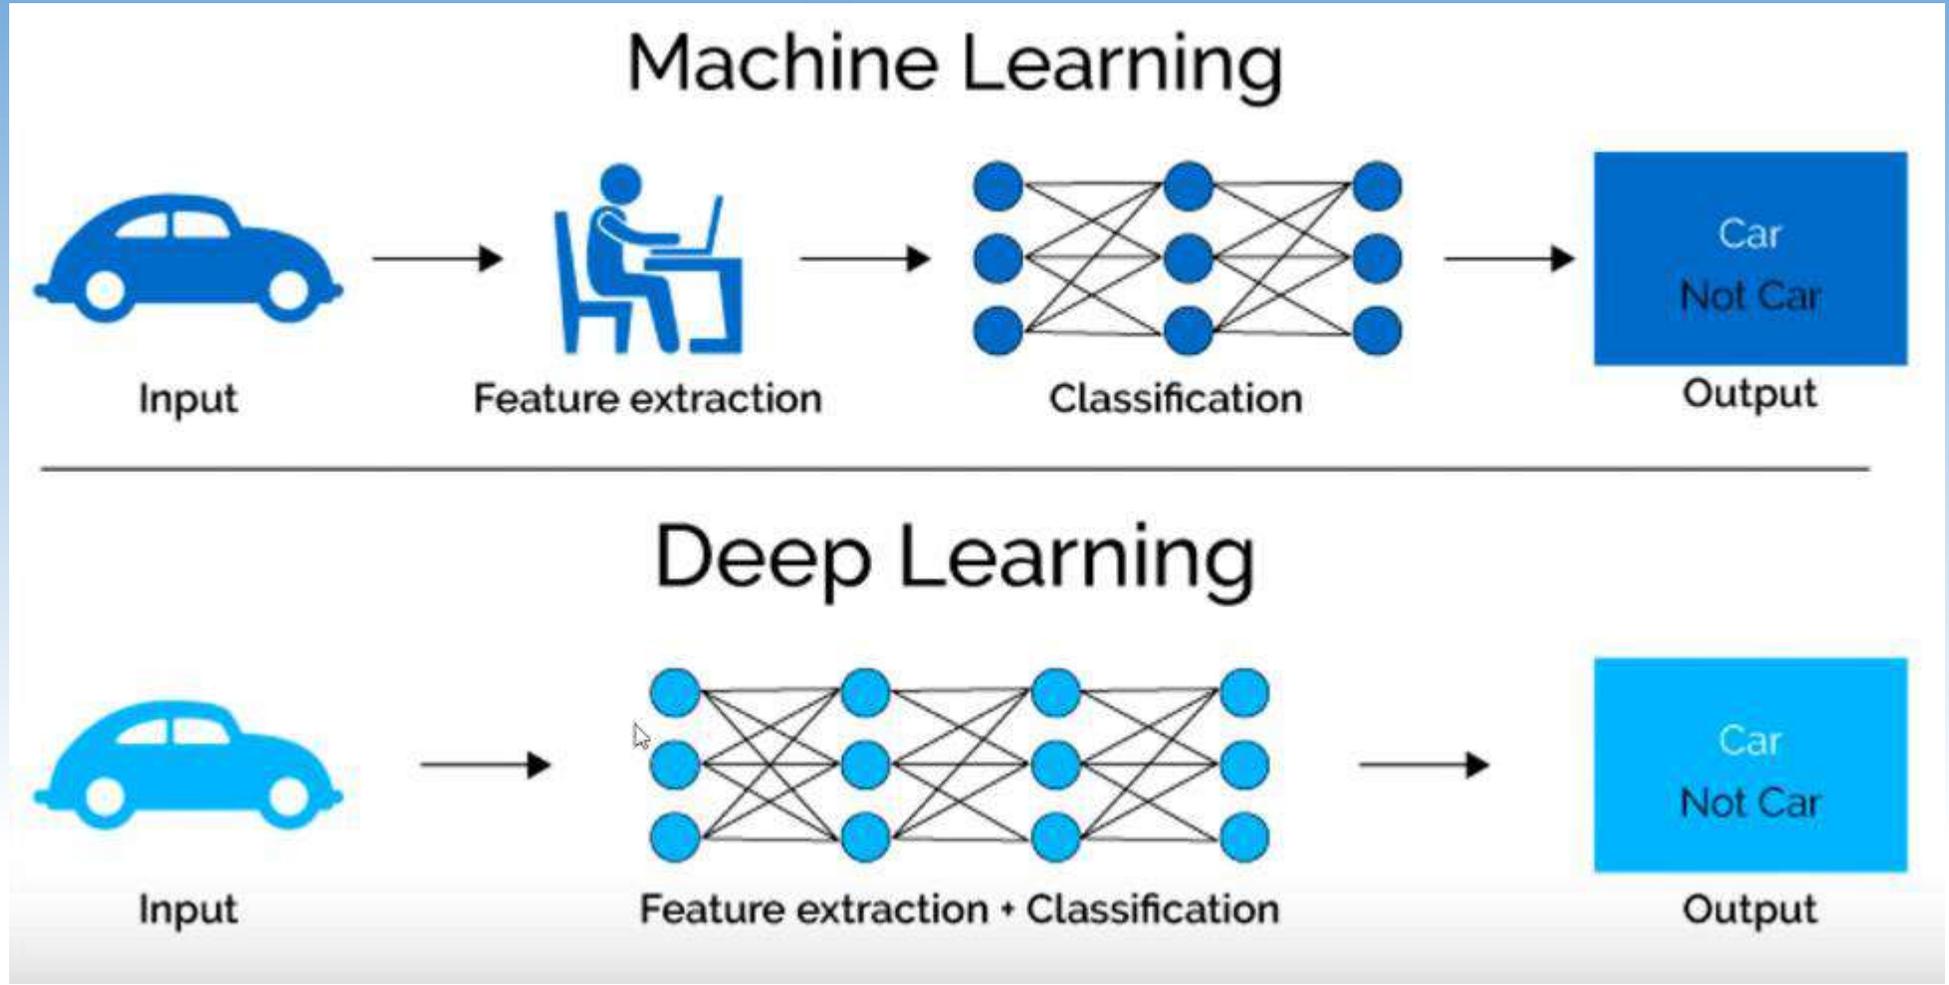


# Redes Neurais: Deep Learning

DEE

## FEATURE EXTRACTION

Extração de Características

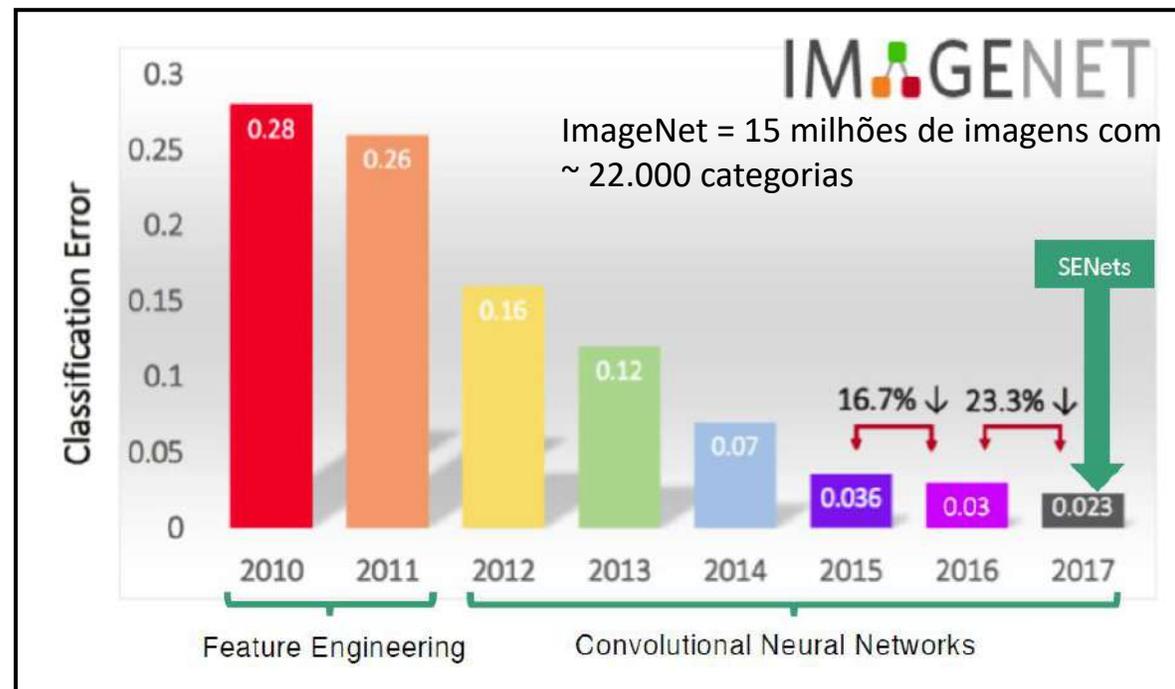
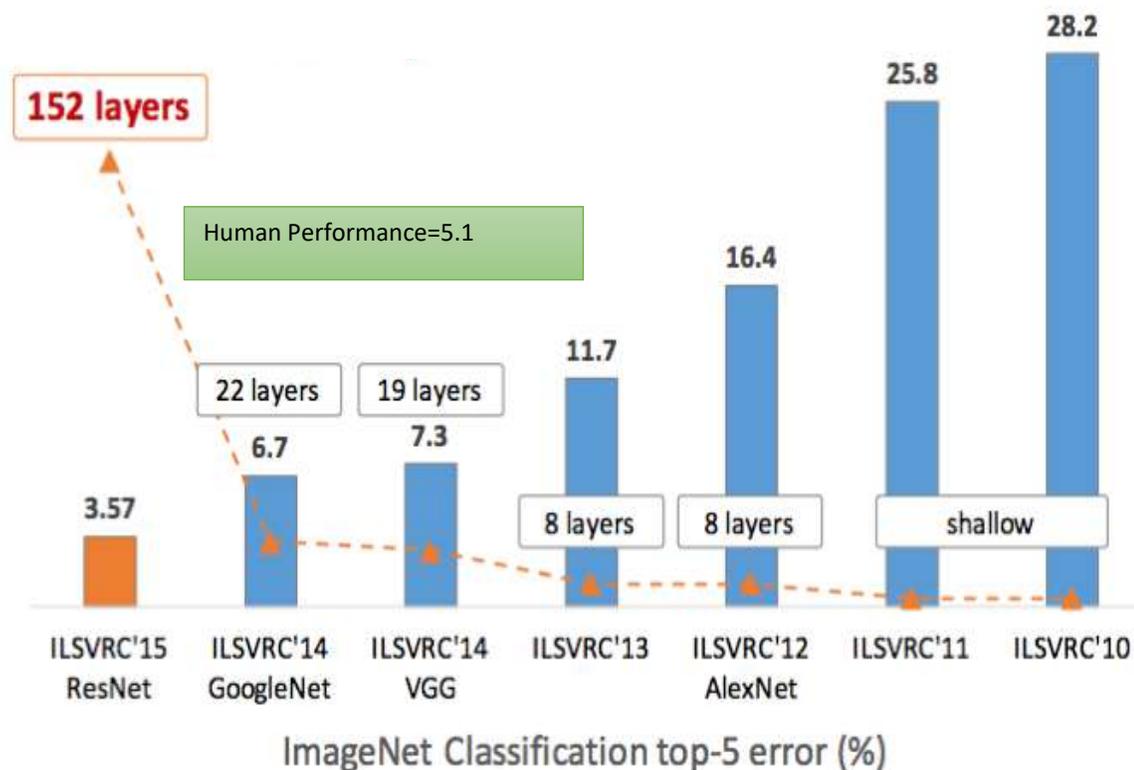


# Redes Neurais: Deep Learning

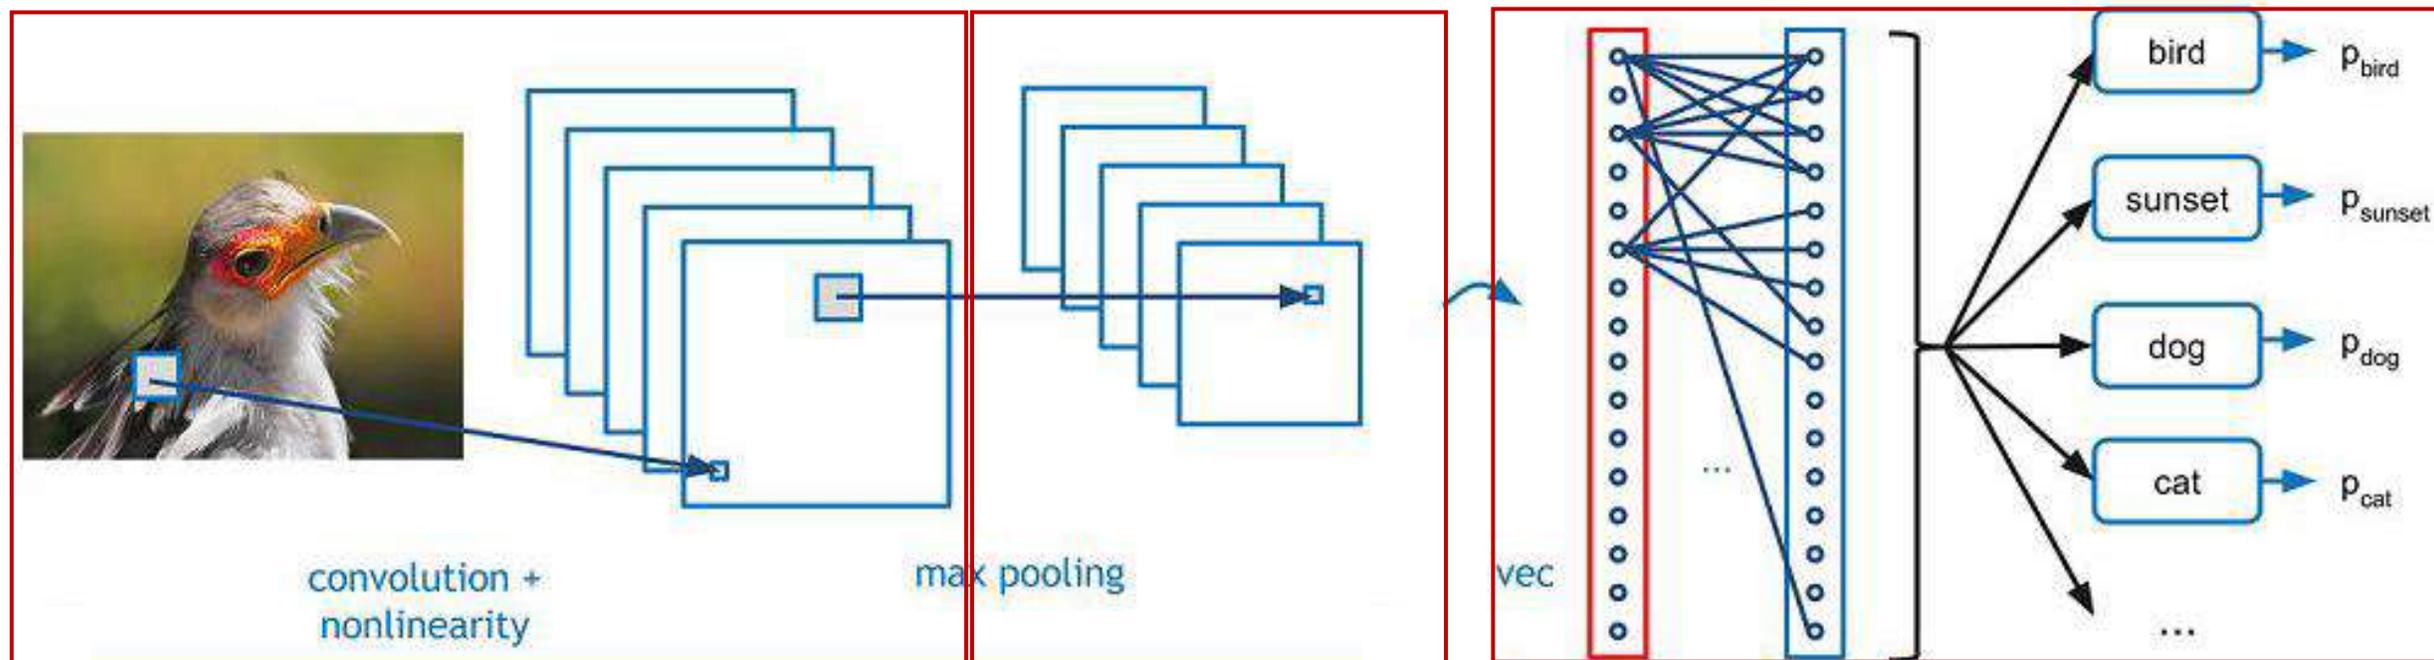
## Por que Redes Neurais Profundas?

- Disponibilidade crescente de grandes bases de dados (big data)
- Desenvolvimento de recursos de processamento em GPUs

- ResNet (2015): erro caiu de 6.7% para 3.57%
  - Mais camadas = melhor performance
  - 152 camadas
- CulImage (2106): erro caiu de 3.57 para 2.99
  - Ensemble de 6 modelos
- SeNet (2017): 2.99% para 2.251%



# Redes Neurais: Redes neurais Convolucionais



CNN é essencialmente um arranjo de camadas:

**Convencionais** – Gerar um mapa de características através de um processo de filtragem que faz uso de um kernel que é aplicado em toda a imagem de origem destacando certas características.

**Pooling** - Extrair características relevantes obtidas a partir das camadas convolucionais (saída da convolucional de uma determinada região == estatística daquela região analisada). Fornece invariância a translação e rotação.

**Totalmente Conectada** - Possui neurônios conectados a todo o volume de entrada e o tamanho da camada de saída do modelo é igual ao número de classes a serem identificadas.

# Redes Neurais: Redes neurais Convolucionais

## Porque usar Redes Neurais Convolucionais?

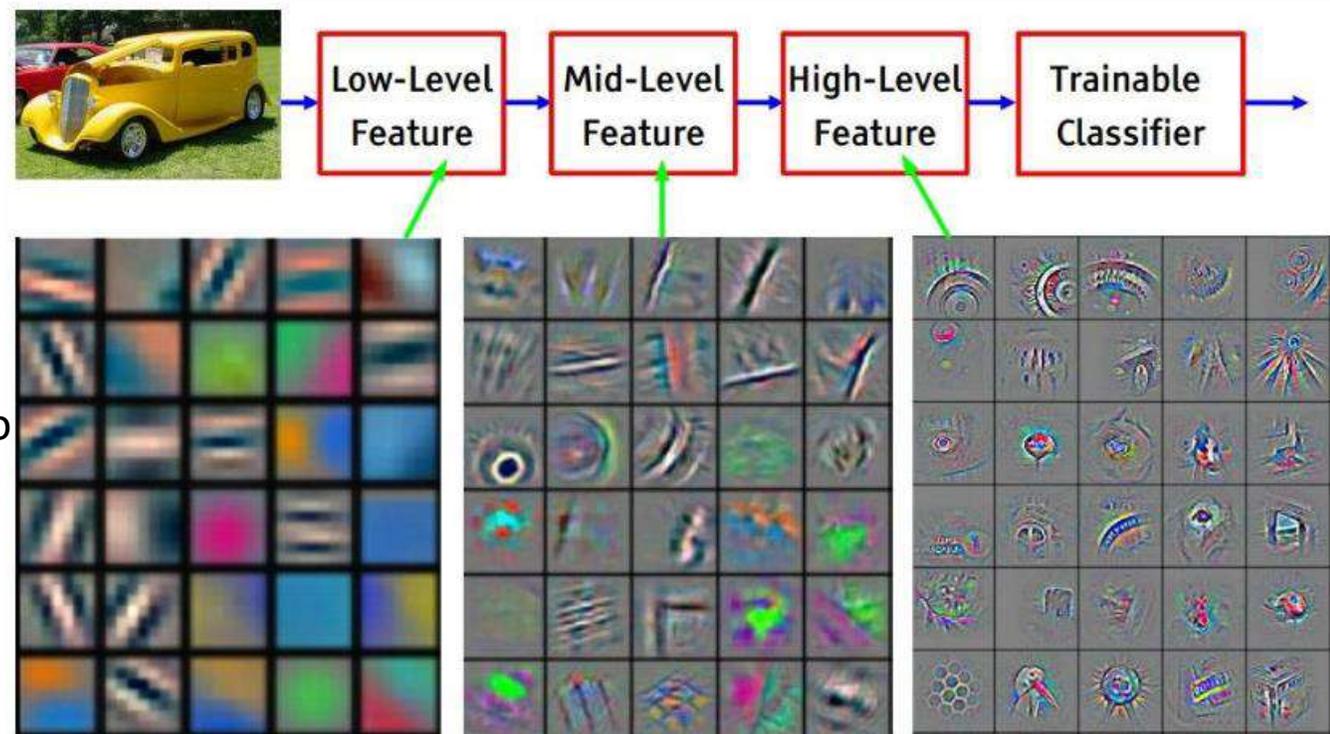
- Cada camada transforma os dados de entrada em representações mais abstratas
  - Ex: Reconhecimento de face -> contornos -> nariz -> face
- Camada final combina as representações -> Predição ou Classificação

Reconhecimento de imagens:

Pixel -> bordas -> padrões -> parte do objeto -> objeto

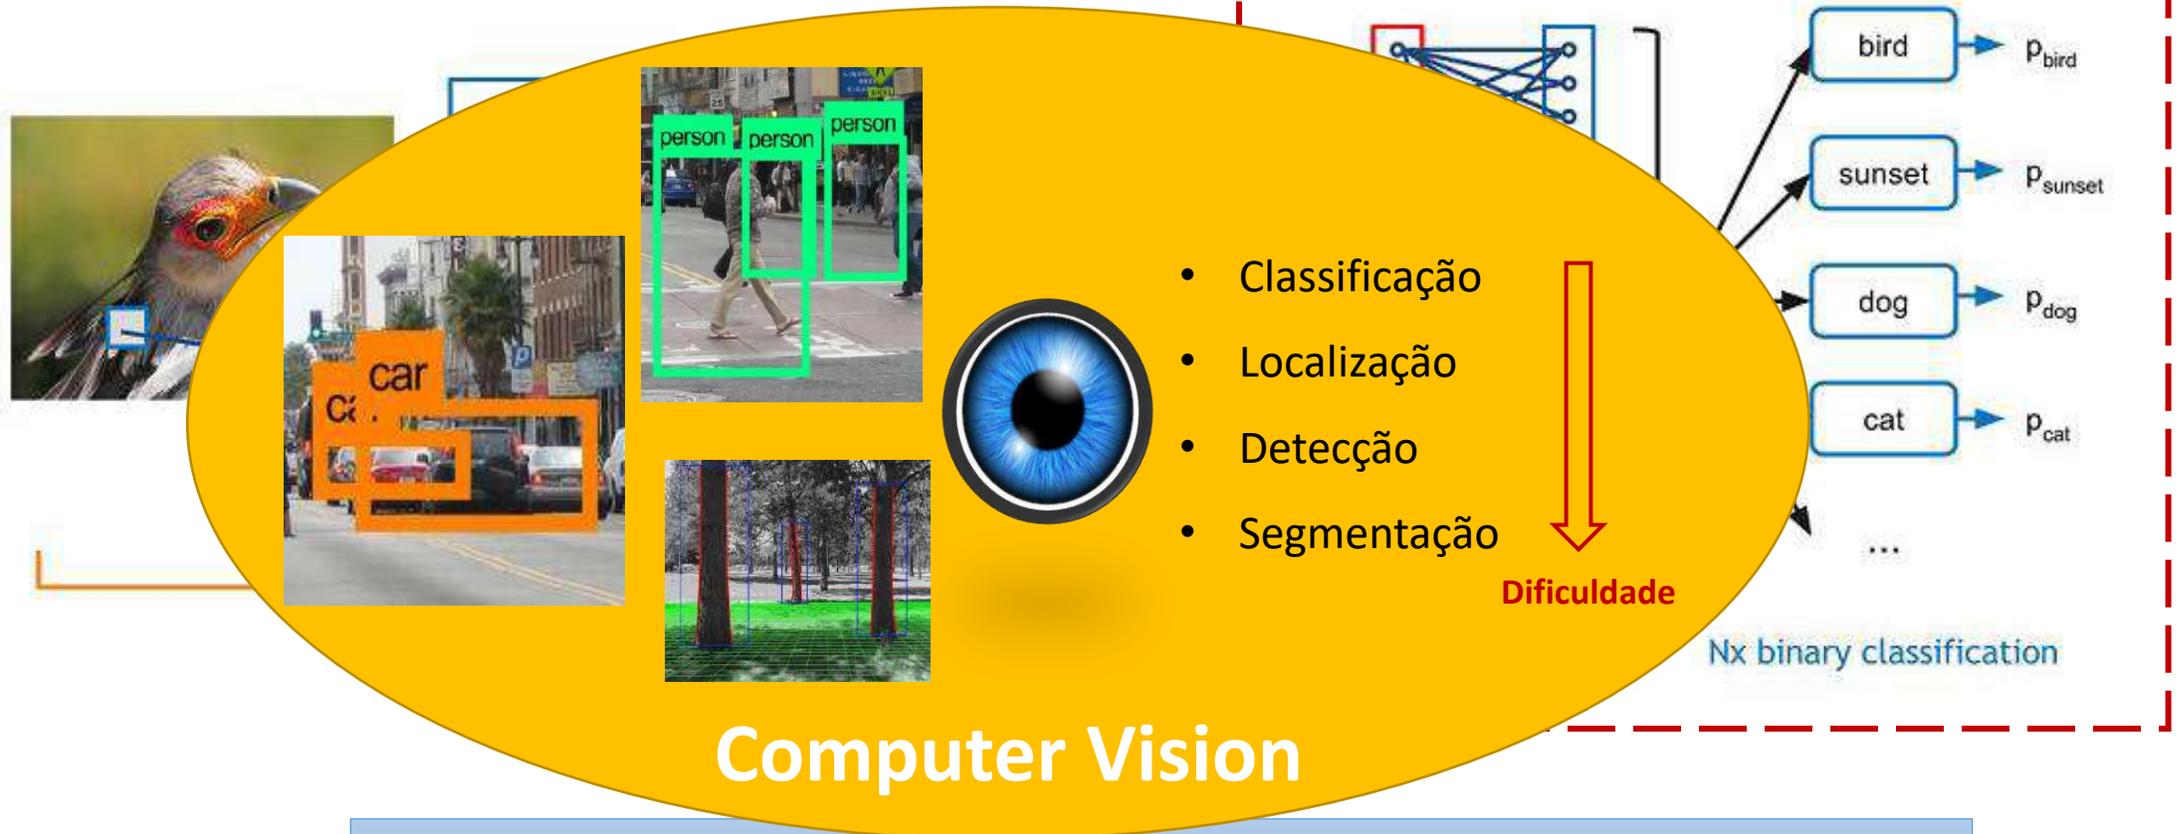
Processamento de texto:

Caracter -> palavras -> grupo de palavras -> sentença -> texto



# Redes Neurais: Redes neurais Convolucionais

Mesma Arquitetura / Muitas Aplicações

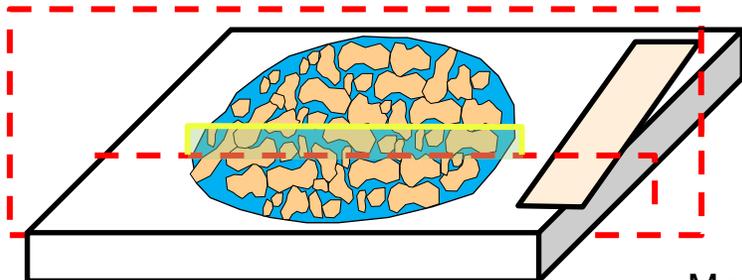
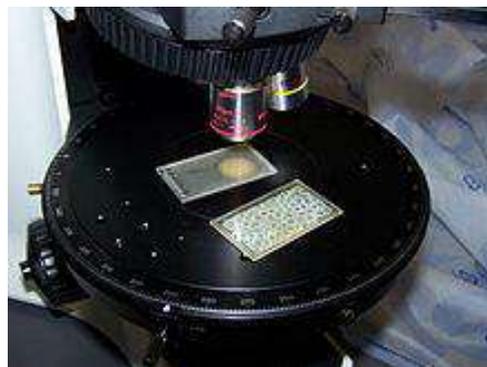
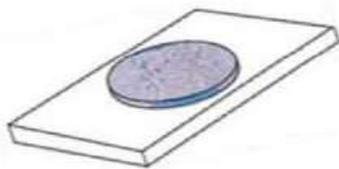


Classificação de imagens em diferentes domínios

Descrição de imagens com Redes Neurais Recorrentes (Modelo Seq2Seq)

Segmentação de imagens e localização de objetos com Redes neurais semânticas

Thin Sections



Montagem de seção de rocha sobre uma lâmina de vidro, de espessura milimétrica



Sample Example

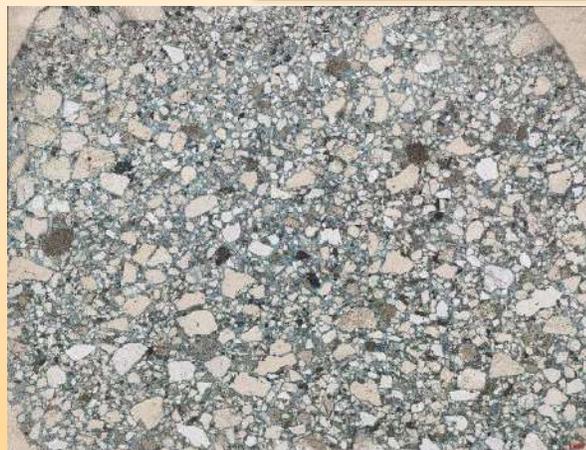


Imagem multicanal de seção delgada geológica obtida por meio de diferentes formas de iluminação a fim de se destacar características diferentes na imagem.

## Análise de múltiplas lâminas



Descrição

Classificação

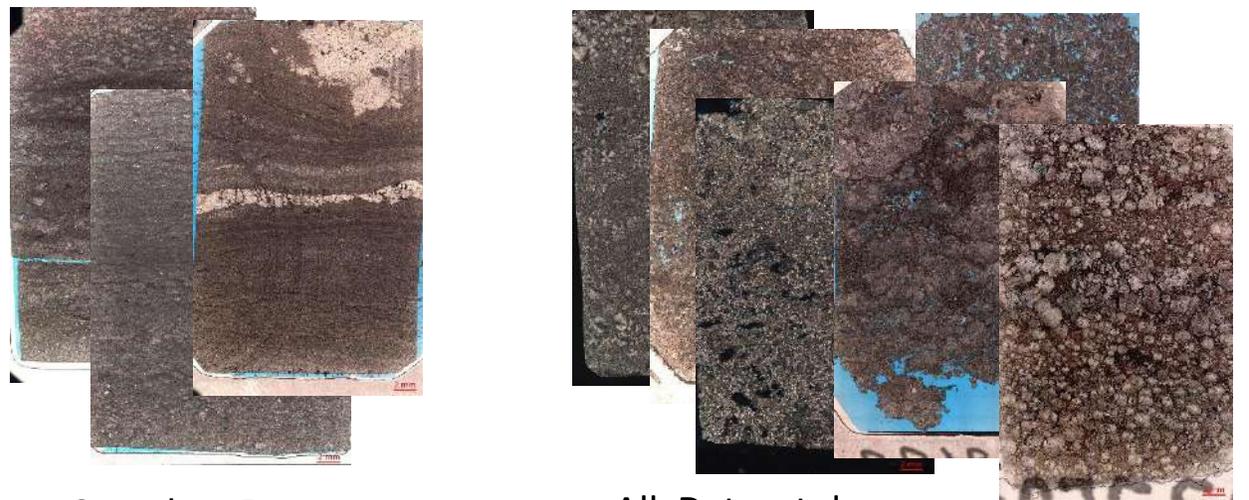
Integração



# Classificação automática de lâminas carbonáticas por meio de técnicas de visão computacional e modelos especialistas

Dissertação de Mestrado – Outubro 2022

Juliana Mota Coelho



One class Dataset Laminite

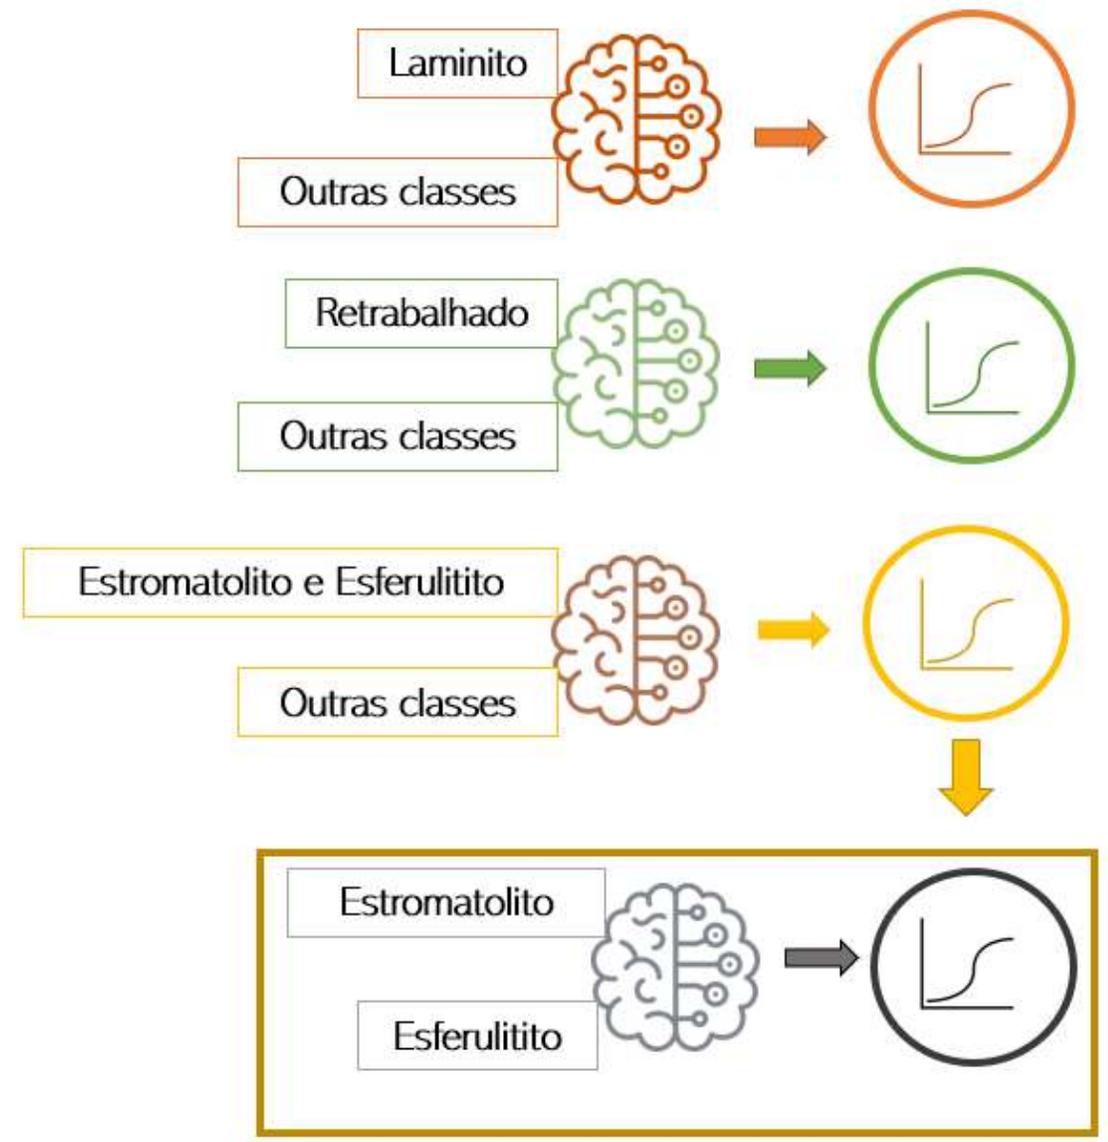
All Dataset de Estromatolite/Sferulite/Retrabalhado

CNN - Autokeras

Modelo especialista na classe Laminite



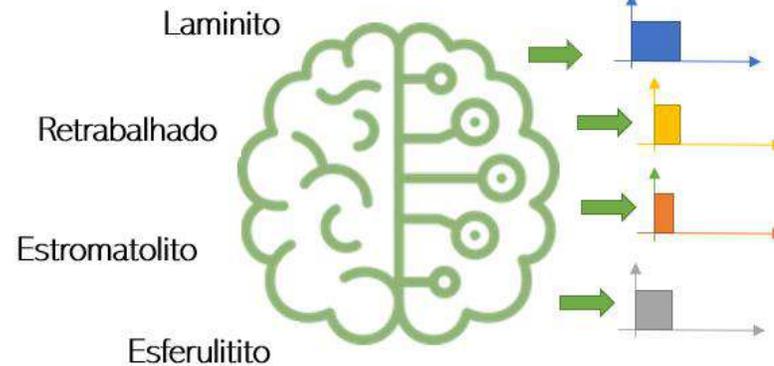
## Modelos especialistas com CNN



Matriz de Confusão

Preditto	Esferulítico	40 15.21%	24 9.13%			<b>64</b> <b>62.50%</b> <b>37.50%</b>
	Estromatolito	20 7.60%	83 31.56%	11 4.18%	2 0.76%	<b>116</b> <b>71.55%</b> <b>28.45%</b>
	Retrabalhado	6 2.28%	6 2.28%	37 14.07%	3 1.14%	<b>52</b> <b>71.15%</b> <b>28.85%</b>
	Laminito		3 1.14%	2 0.76%	26 9.89%	<b>31</b> <b>83.87%</b> <b>16.13%</b>
	Soma da Coluna	<b>66</b> <b>60.61%</b> <b>39.39%</b>	<b>116</b> <b>71.55%</b> <b>28.45%</b>	<b>50</b> <b>74.00%</b> <b>26.00%</b>	<b>31</b> <b>83.87%</b> <b>16.13%</b>	<b>263</b> <b>70.72%</b> <b>29.28%</b>
		Esferulítico	Estromatolito	Retrabalhado	Laminito	Soma da Linha
		Atual				

Acurácia: 70,72%



Matriz de Confusão

Preditto	Esferulítico	16 5.63%	43 15.14%	2 0.70%	6 2.11%	<b>67</b> <b>23.88%</b> <b>76.12%</b>
	Estromatolito	39 13.73%	39 13.73%	41 14.44%	1 0.35%	<b>120</b> <b>32.50%</b> <b>67.50%</b>
	Retrabalhado	38 13.38%	11 3.87%	11 3.87%	1 0.35%	<b>61</b> <b>18.03%</b> <b>81.97%</b>
	Laminito		8 2.82%		28 9.86%	<b>36</b> <b>77.78%</b> <b>22.22%</b>
	Soma da Coluna	<b>93</b> <b>17.20%</b> <b>82.80%</b>	<b>101</b> <b>38.61%</b> <b>61.39%</b>	<b>54</b> <b>20.37%</b> <b>79.63%</b>	<b>36</b> <b>77.78%</b> <b>22.22%</b>	<b>284</b> <b>33.10%</b> <b>66.90%</b>
		Esferulítico	Estromatolito	Retrabalhado	Laminito	Soma da Linha
		Atual				

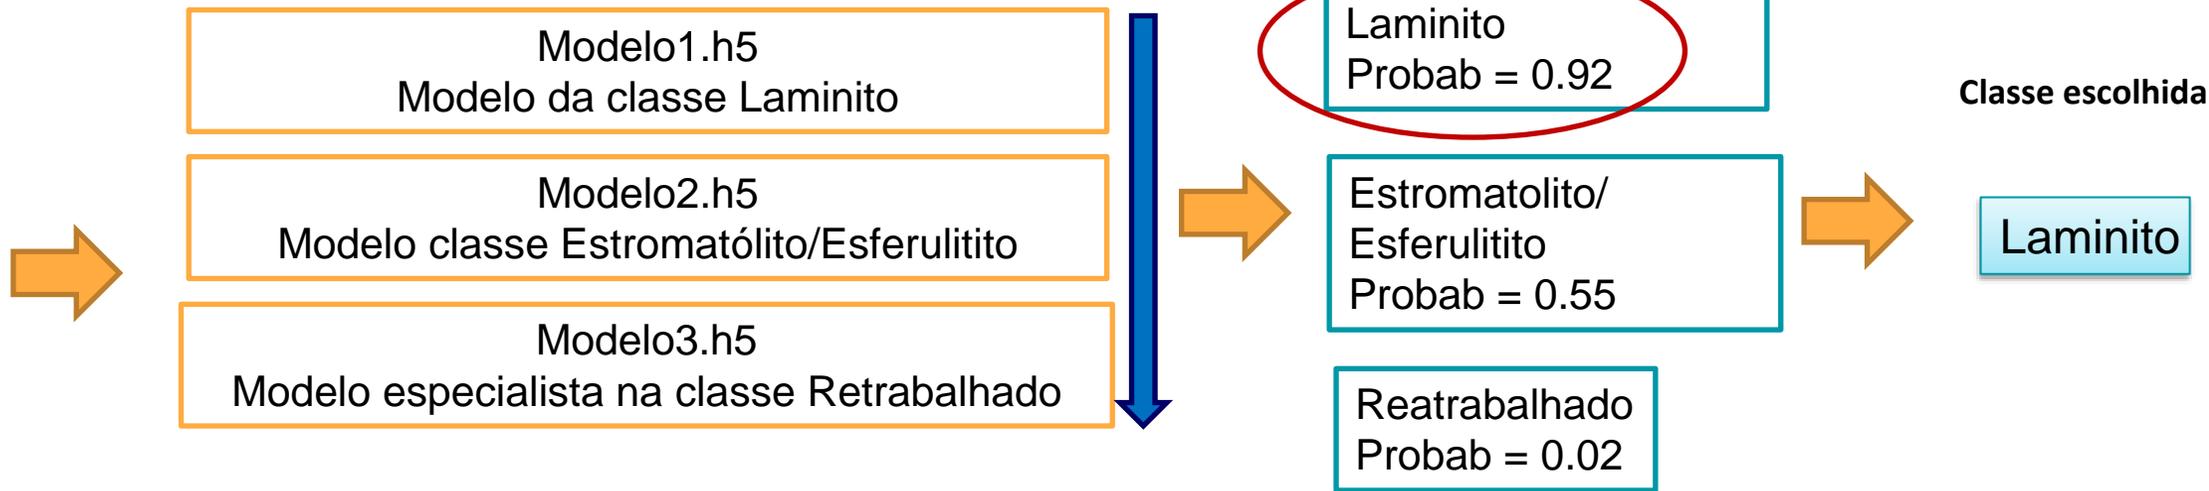
Acurácia: 33,10%



# Pipeline – Modelo Especialista



Nova imagem a ser Predita





# Pipeline – Modelo Especialista



Modelo1.h5  
Modelo da classe Laminito

Modelo2.h5  
Modelo classe Estromatólito/Esferulitito

Modelo3.h5  
Modelo especialista na classe Retrabalhado



Probabilidades do modelo especialista

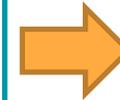
Laminito  
Probab = 0.55

Estromatolito/  
Esferulitito  
Probab = 0.92

Reatrabalhado  
Probab = 0.02

Classe escolhida

Estromatolito



Nova imagem  
a ser Predita



Modelo4.h5  
Modelo especialista na classe Estromatólito



Limiar > 0.5  
Probabilidades do modelo especialista

Esferulitito  
= 0.15

Estromatolito  
= 0.85

Classe escolhida

Estromatolito





# Lithology identification in carbonate thin section images of the Brazilian pre-salt reservoirs by the computational vision and deep learning

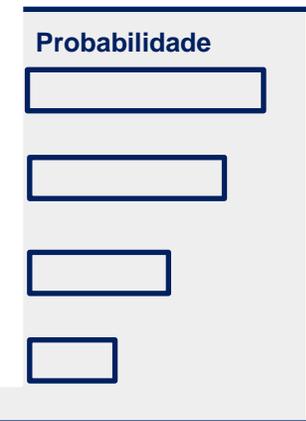
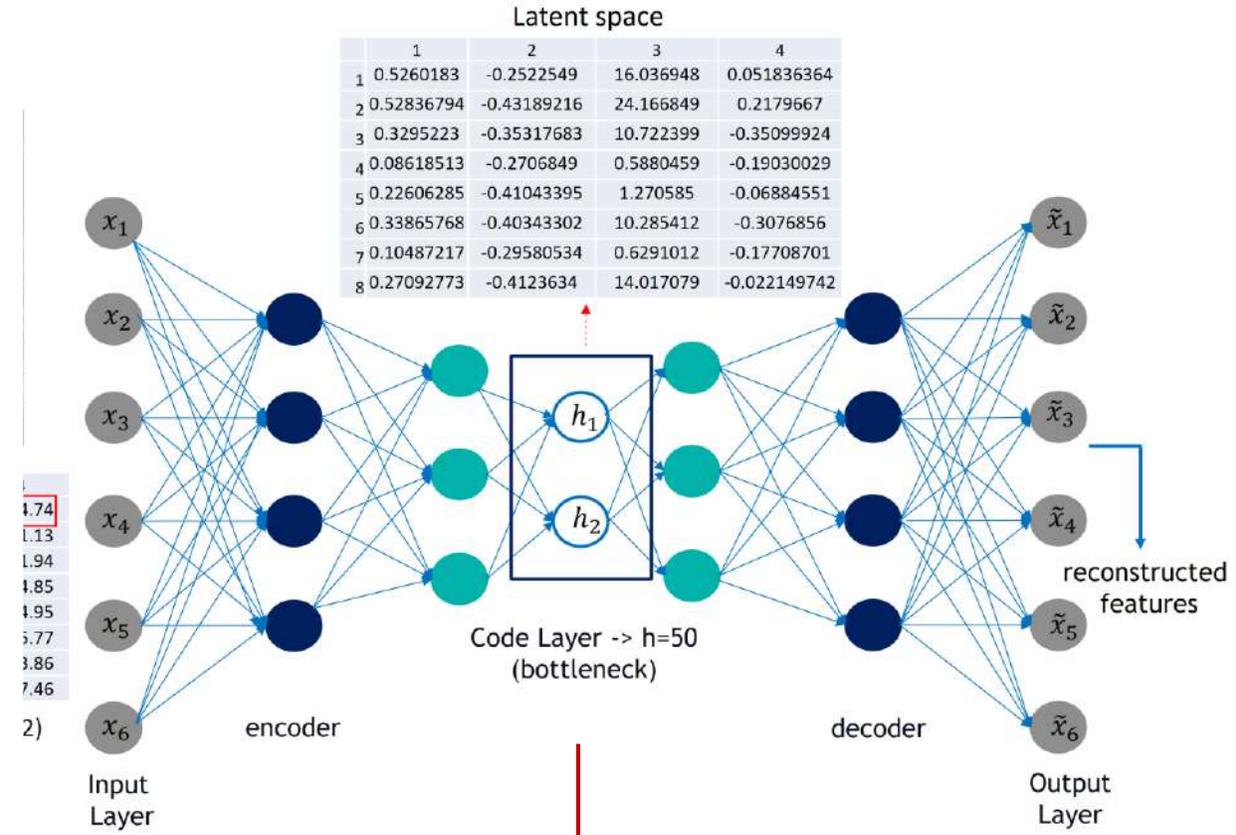
E. L. Faria<sup>1</sup> · Juliana. M. Coelho<sup>1</sup> · Thais F. Matos<sup>2</sup> · Bernardo C. C. Santos<sup>2</sup> · Willian A. Trevizan<sup>2</sup> · J. L. Gonzalez<sup>3</sup> · Clécio R. Bom<sup>1,4</sup> · Márcio P. de Albuquerque<sup>1</sup> · Marcelo P. de Albuquerque<sup>1</sup>

Received: 7 February 2022 / Accepted: 19 July 2022  
© The Author(s), under exclusive licence to Springer Nature Switzerland AG 2022

## Abstract

Currently, the computer vision area, which represents one of the subfields of artificial intelligence and machine learning, has been widely used to process data in the oil and gas industry. In this context, the detection of specific properties inside carbonate rocks in different datasets from petroleum reservoirs represents a considerable challenge, that consumes enormous resources and time. Therefore, the automatic separation of the lithologies within rocks of reservoirs has attracted the increasing attention of many research groups. The consistent classification of these lithologies is the main factor for the construction of reliable depositional, diagenetic, and reservoir models. This work deals with this last issue by presenting the development of a technique for the automatic classification of carbonate thin sections obtained from plane-polarized and cross-polarized microscopy images corresponding to natural rocks belonging to the Brazilian pre-salt reservoir. Our proposed model transforms the analyzed images into structured data by defining texture parameters (Haralick parameters), and Wavelets transforms. Later, a stacked autoencoder neural network is used to eliminate images with anomalies and/or distortions in order to define relevant characteristics of the data. This stage is followed by supervised classifier called multilayer feed-forward neural network. The definition of the model's hyperparameters is tuned by Bayesian optimization and the Gaussian process. For training and testing of the network, images of 570 thin sections were used (each image obtained with plane-polarized and cross-polarized light) totaling 1140 images. Our model reported an accuracy of 83% for the test samples, confirming the validity of the proposed model in the automatic classification of carbonate rocks.

**Keywords** Carbonate thin section · Autoencoder neural network · Texture parameters · Lithology classification

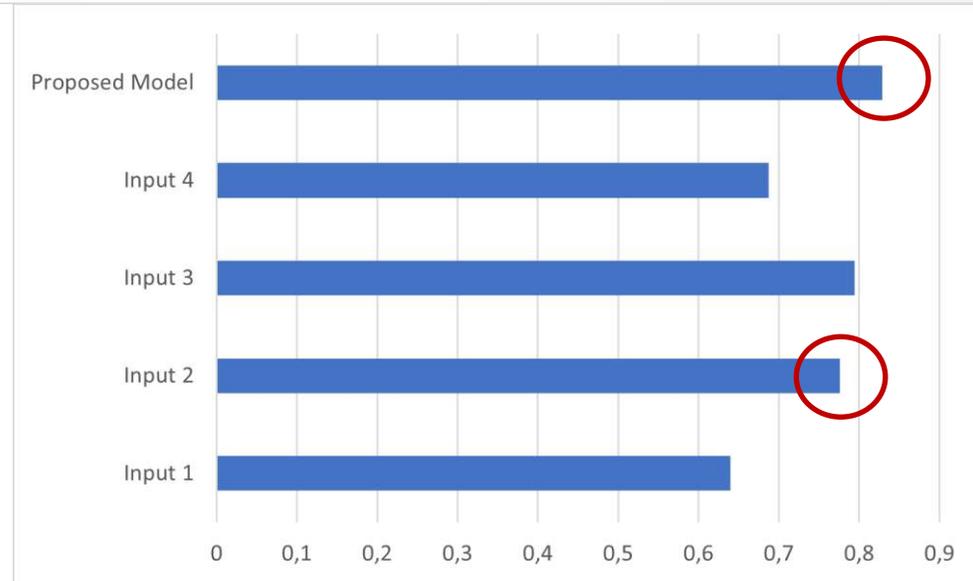
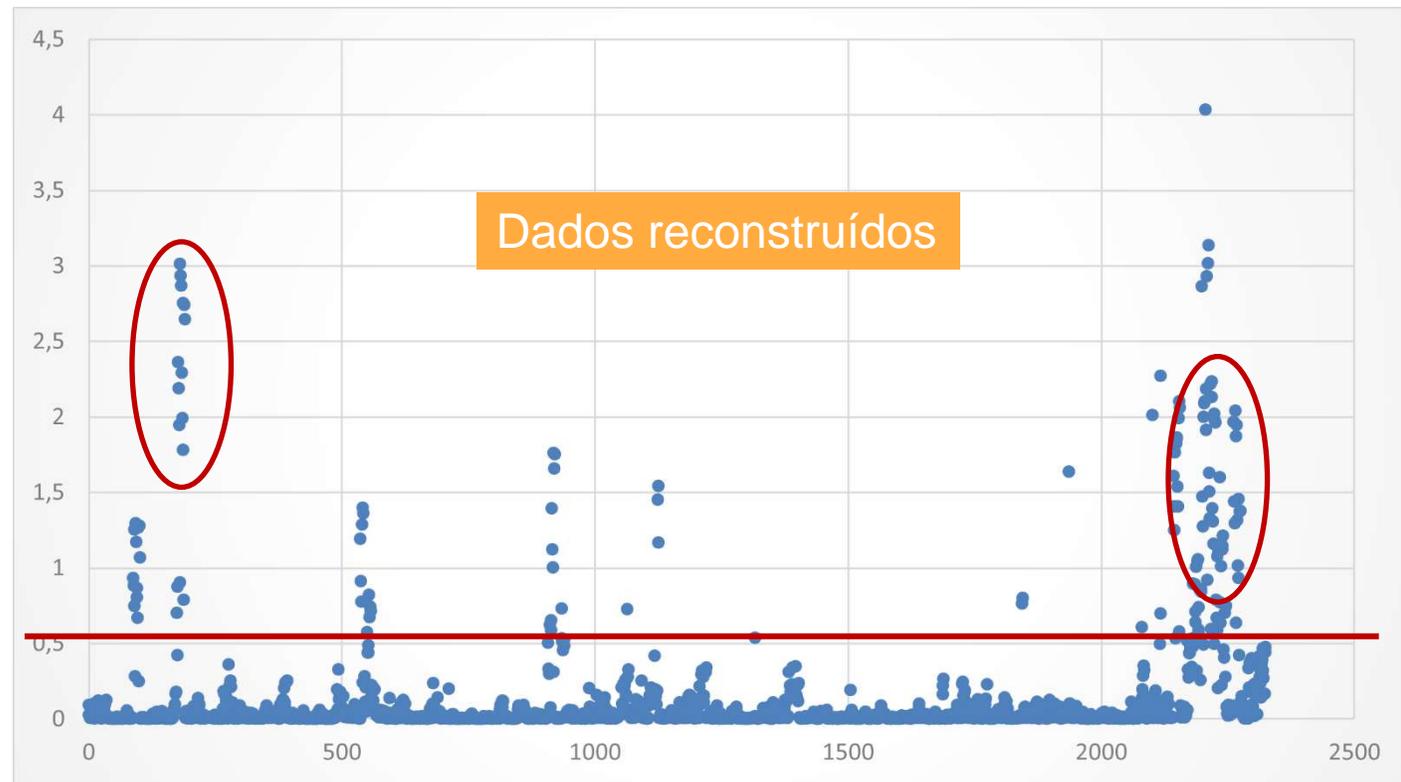
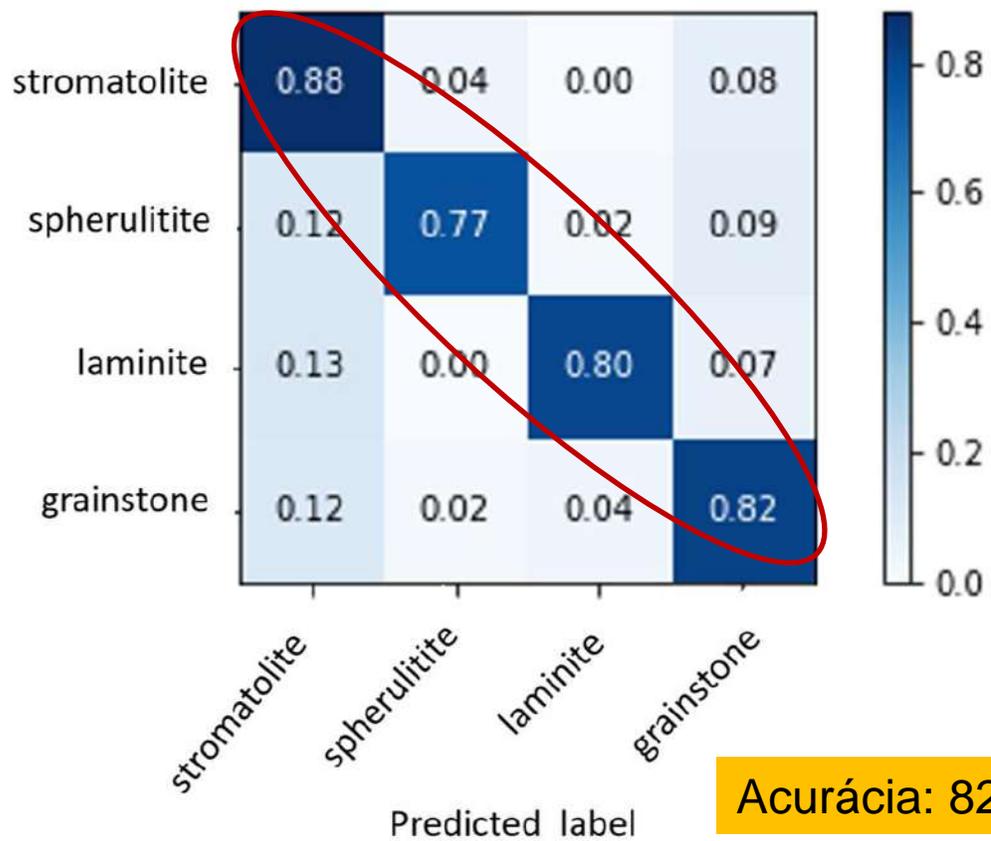


Hiperparâmetros do classificador = AutoKeras





Matriz confusão





Science Deep Tech and innovation  
16 de novembro a 18 de novembro de 2022

# Inteligência Artificial e DataScience

## Construindo Pontes entre a Ciência e a Indústria

Elisangela Lopes de Faria

Obrigada!!

