

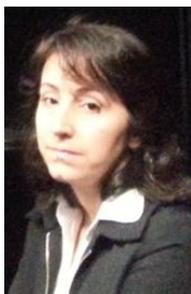


# Inteligência artificial e aplicações em física

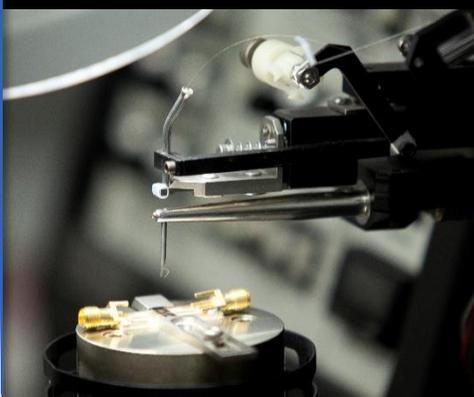
*Clécio Roque De Bom – [debom@cbpf.br](mailto:debom@cbpf.br)*



*[clearnightsrthebest.com](http://clearnightsrthebest.com)*



**Elisangela L. Faria**  
(CBPF)





## History

Founded in 1949 (70 years in 2019)  
Contributed to the creation of groups of  
excellence and Research Institutes

## Our mission

Research in physics and develop its  
national center, preparing human  
and technological development.

A **história do CBPF** está permeada de iniciativas, que estão na base  
da criação de instituições que formam hoje a **espinha dorsal**  
da **Ciência no Brasil**



LNCC



## Graduate Program (CAPES 7)

in Physics (the most traditional  
program of Physics in Brazil)  
in **Scientific Instrumentation**

## Innovation

Intellectual Property Rights (IPR), Innovation and  
Technology Transfer Office - NIT-Rio/MCTIC



C. Lattes



J.L. Lopes



G. Beck



J. Tiomno

## International Collaborations

HEP-Network (CERN, FERMILAB), CLAF, TWAS,  
CNRS, CONACYT, NSF, DAAD, SFI  
Projetos: Auger/SWGO, CTA

# Mission of Research Institutes

- **Research**  
Push forward the frontiers of knowledge
- **Innovation**  
Develop new, cutting-edge technologies
- **Education**  
Train scientists and engineers of tomorrow
- **Outreach**  
Promote Science in Society



## Experimental, Theoretical and Applied Physics

- **High Energy and Astroparticle Physics**
- **Condensed Matter & Materials**
- **Nanoscience and Nanotechnology**
- **Biophysics & Biomaterials**
- **Statistical Mechanics and Complex Systems**
- **Quantum information**
- **Cosmology and Gravitation**
- **Signal Processing and Computing for Science**
- **Scientific and Technological Instrumentation**

# International Collaborations



DELVE Survey



# Laboratórios

**LABNANO/SisNANO**



**Laboratório de Eletrônica**



**Laboratório de Superfícies e Nanoestruturas**



**Laboratório de Aplicação de Lasers**



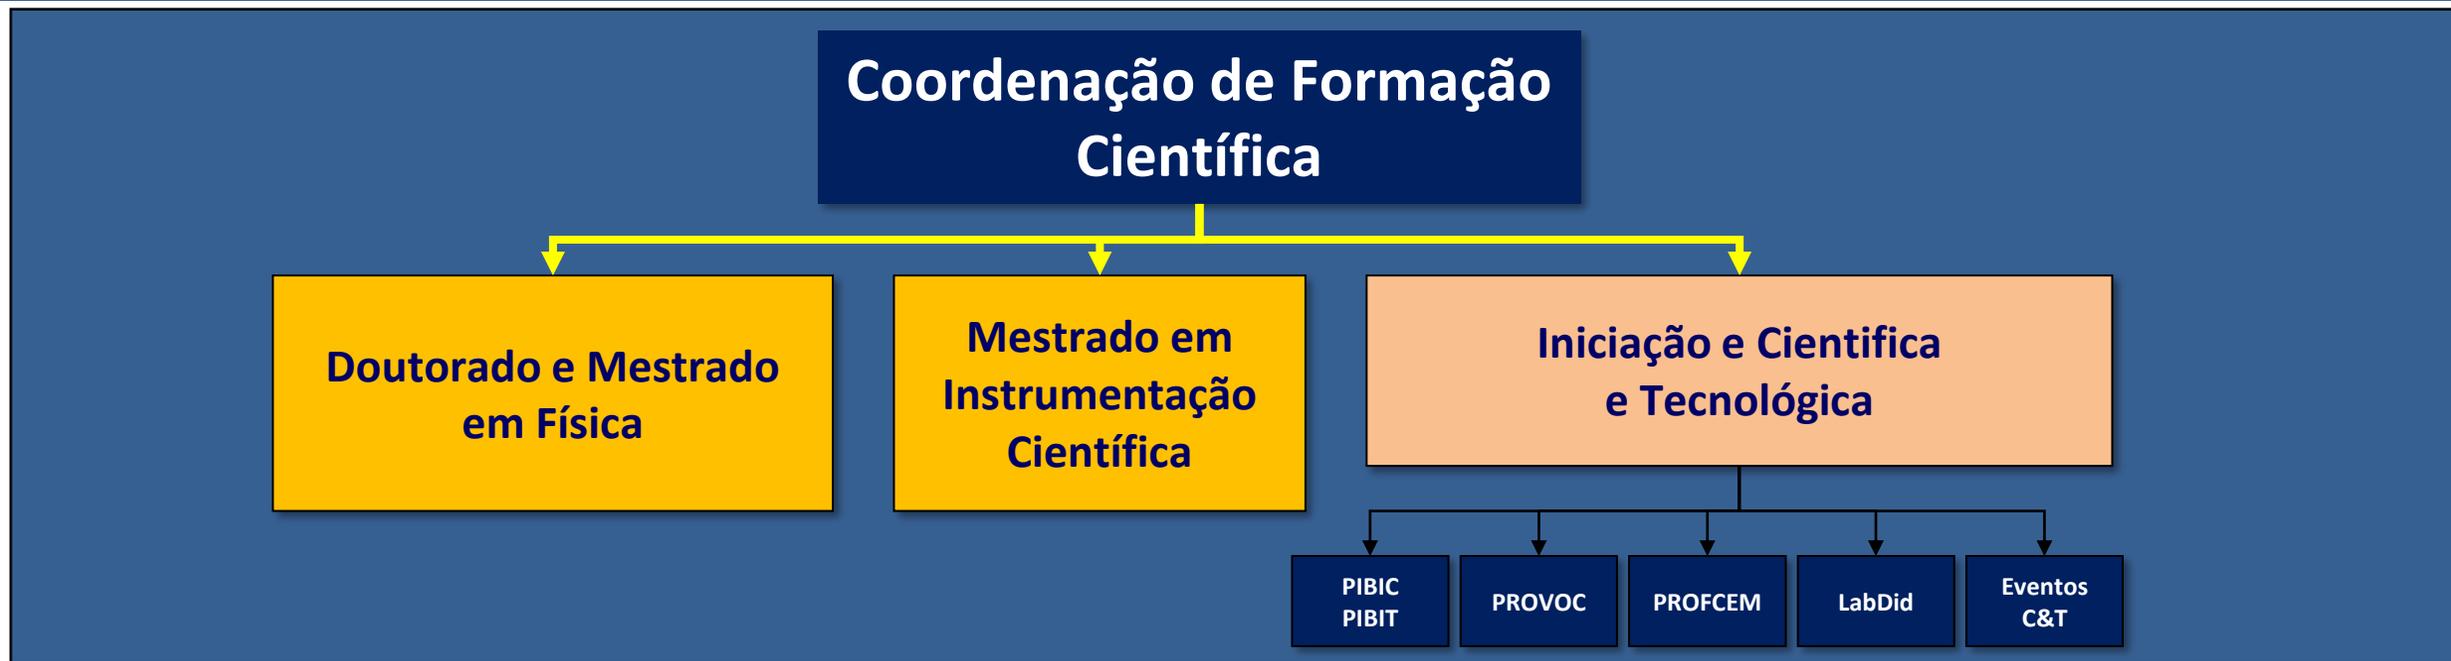
LABNANO/SisNANO



XPS-LABNANO/SisNANO



RMN



## Programa de Desenvolvimento da Instrumentação Científica

- Público alvo: físicos e engenheiros
- Formação de recursos humanos para instrumentação científica e desenvolvimento tecnológico



O Programa de Pós-Graduação do CBPF completou, em 2012, seu 50º aniversário, um marco da história da Física no Brasil

(CBPF – programa de excelência)  
 CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior)

# CBPF in Numbers

- Headquarters of the National High Energy Physics Network (RENAFAE)
- Headquarters of National Science and Technology Institute for Complex Systems and Quantum Information
- Headquarters of Rio de Janeiro Nanotechnology Network (LABNANO/CBPF is the main facility)  
*Strategic Lab under SisNANO network*



WLCG  
Worldwide LHC Computing Grid  
Science DMZ

LHC  
Open Network  
Environment  
(Tier1s - Tier2s)



**CBPF** is the technical and operational segment of the Rio de Janeiro NREN (Advanced Research and Educ. Network) - support for 160 research, academic and governmental institutions.



**100 Acadêmicos**  
**34 Prefeitura**  
**31 Metro**  
**2 Supervia**  
**Total: 167**

**≈ 400 Km de Fibras Ópticas**

# CBPF & Industry

- NMR for Petrophysics;
- Quantitative Imaging techniques for characterization of high-resolution images in geological reservoirs;
- Rock plugs with controlled porosity
- Nanotechnology for O&G industry



- New materials and techniques for medical implants



- Magnetic Resonance at the micro and nanoscale



- Material Science, Nanotechnology and Magnetics Devices



- Cherenkov Telescope Array

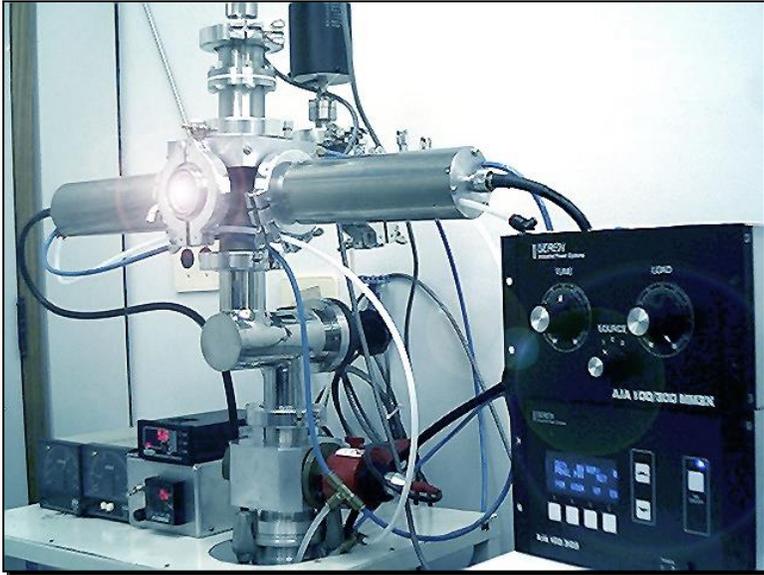


- Surface Science



# Group of Surfaces and Nanostructures

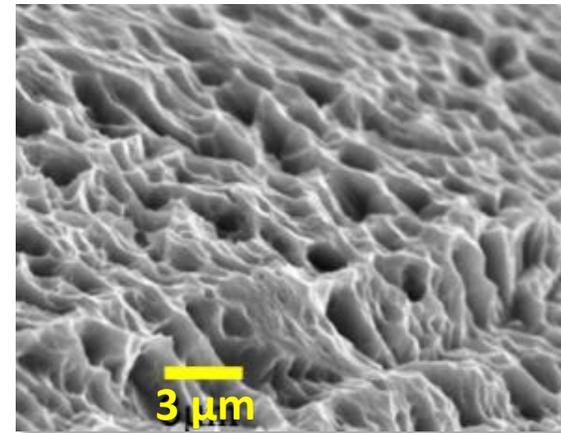
## Biocompatible Coatings



- **Instrument** for Crystalline and **biocompatible nanometer coatings** of Calcium-Phosphates produced at room temperatures.
- Pre-clinical studies in dogs and rabbits indicated **high adhesion** and proliferation of bone tissue around titanium implants
- Improves clinical behaviour and push up values to medical metallic implants, saving loading time and solving rejections

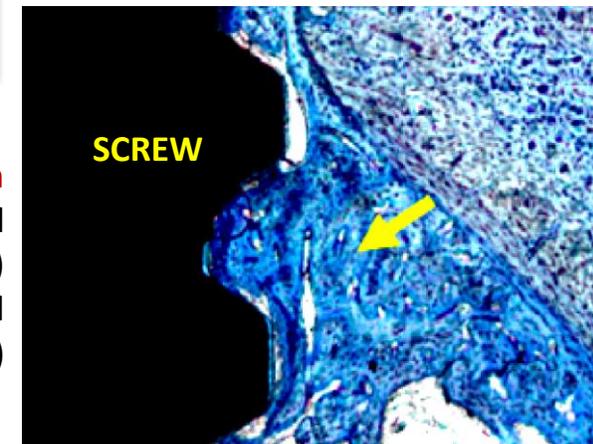


Commercial titanium screw with nanosized hydroxyapatite coating (100 nm)



Metal implant surface with micrometric roughness for mechanical bonding and homogeneous coating

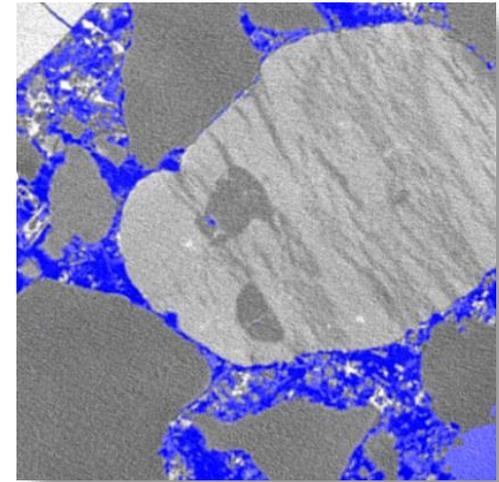
Preclinical tests with strong adhesion and bone growth (in blue) to screw coated HAPnano (black)



# Image/Signal: Emerging techniques

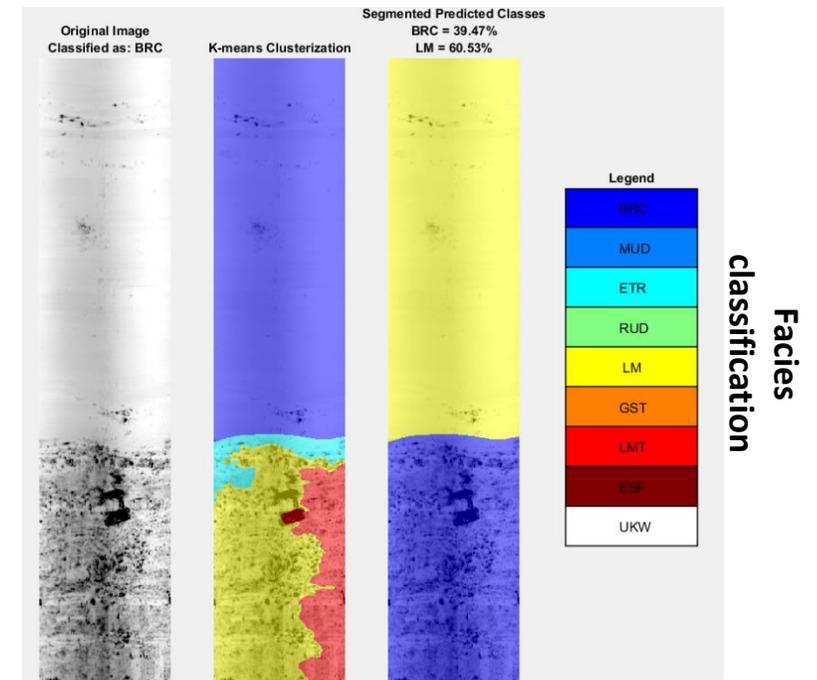
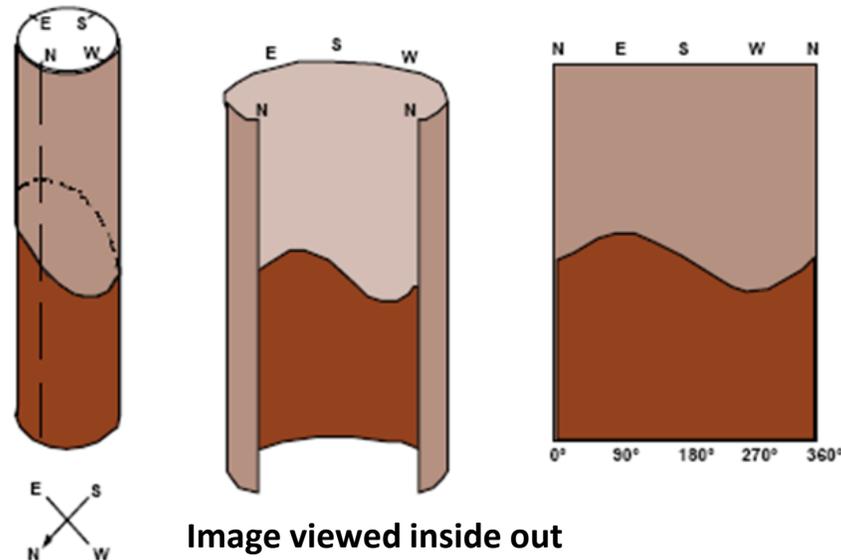
Exploring multimodal imaging protocols in association with powerful imaging processing techniques

- **X rays quantitative imaging**
  - Dual Energy / Multispectral  $\mu$ CT
  - Synchrotron based techniques
- **Signal and image processing**
  - Advanced approaches for enhancement and segmentation
  - Machine learning / Deep Learning
- **Complexity and statistical physics**
  - Porous media characterization through information theory and fractal geometry



## Characterization of Borehole Profile

Clustering and facies classification  
texture segmentation



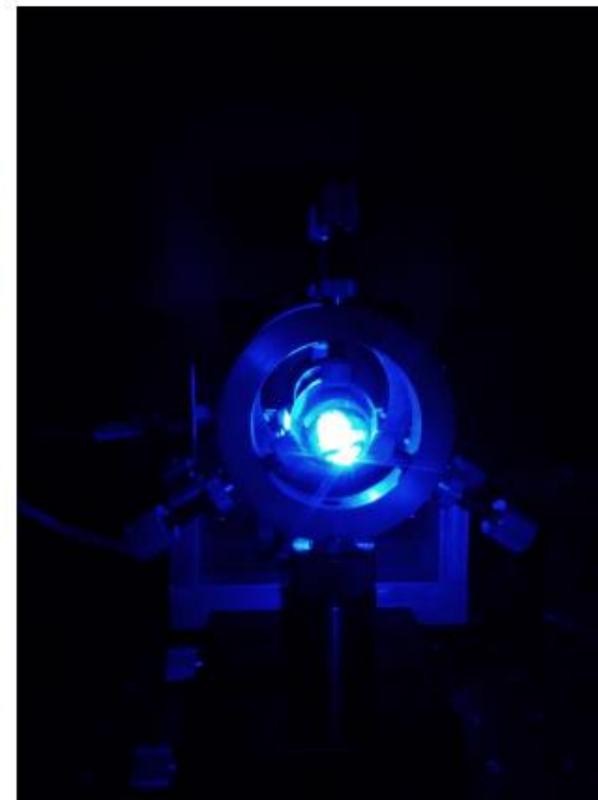
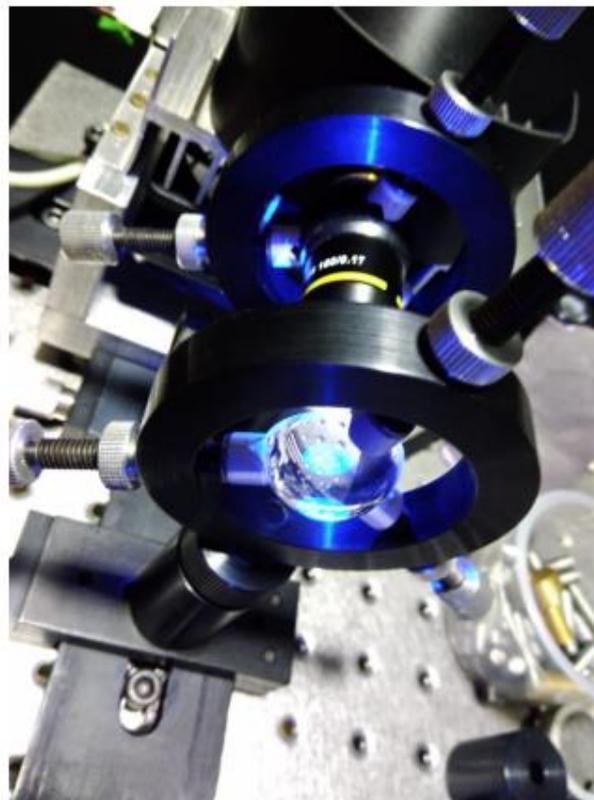
## Instrumentos avançados & tecnologias de medidas

óptica aplicada

computação científica

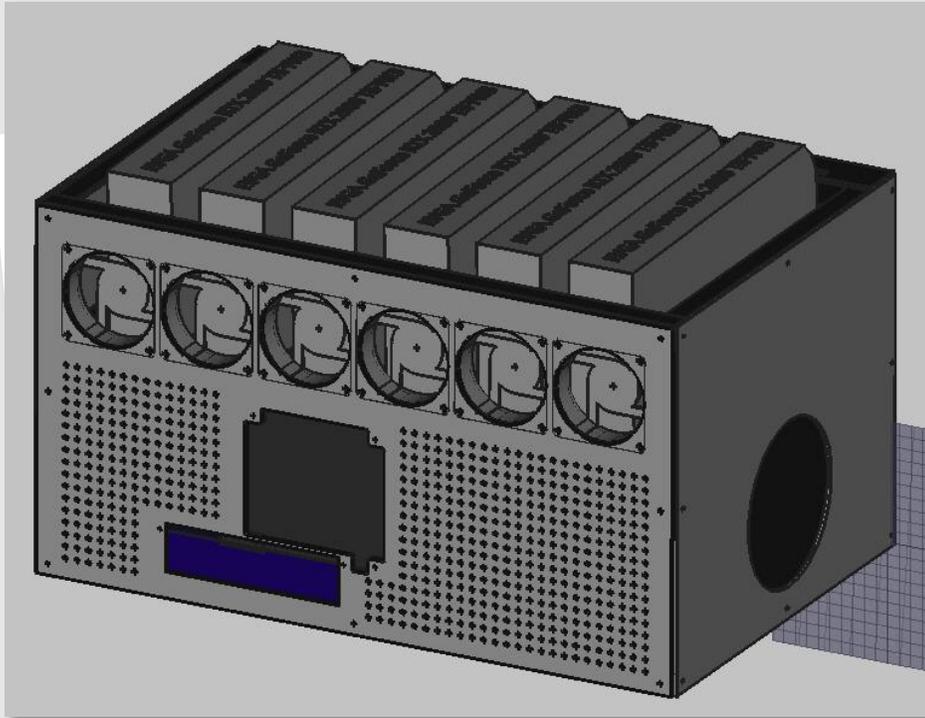
eletrônica

mecânica



*Desenvolvimento de Módulo Laser para Sistema de Imageamento de Alta-Resolução*

# Laboratório Avançado de Redes e Sistemas (LARS) – CBPF/MCTIC



**NVIDIA.**  
GPU Computing

42x **RTX 2080Ti**

6x **1080Ti**

7x **1050Ti**

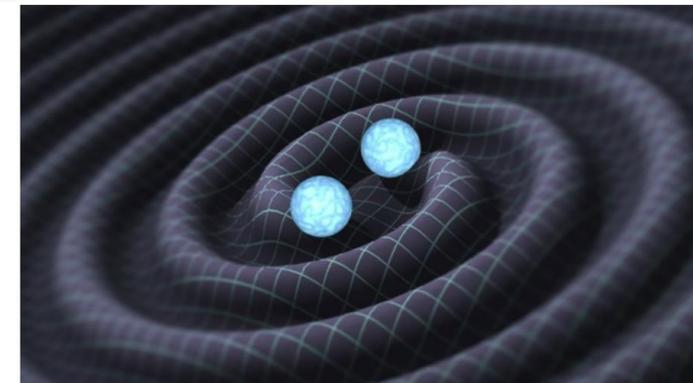
- 32 CPU cores, 128 GB RAM (expansível até 1TB),
- 26112 CUDA cores, 84 Teraflops , 66GB VRAM,
- 4xWaterCoolers - completo silêncio,
- 1632 Tmus unidades de texturas e 528 ROps unidades para renderização,
- 4TB HD/backup Enterprise e 500 GB SSD/OS, 2 fontes 1600W

# Cosmology and Relativity

- Astrophysical and cosmological applications of Strong Gravitational lensing.
- Gravitational Waves theory
- High Energy Astrophysics theory
- Black Holes theory
- Search & modelling of Strong Lensing systems with Deep Learning

## Cosmology:

- Big Data Astronomical Image Processing and Wide-field Surveys
- Deep Learning Assessment of data in wide field surveys: Galaxy Morphology, Photometric redshifts
- Transients Detection and Classification
- Search for counterparts of Gravitational Waves
- Cosmology with Gravitational Waves
- Gravitational Lensing: weak lensing and galaxy clusters.
- Quantum Cosmology: bouncing models; primordial cosmology;
- Quantum Foundations: Bohm-de Broglie interpretation of quantum mechanics

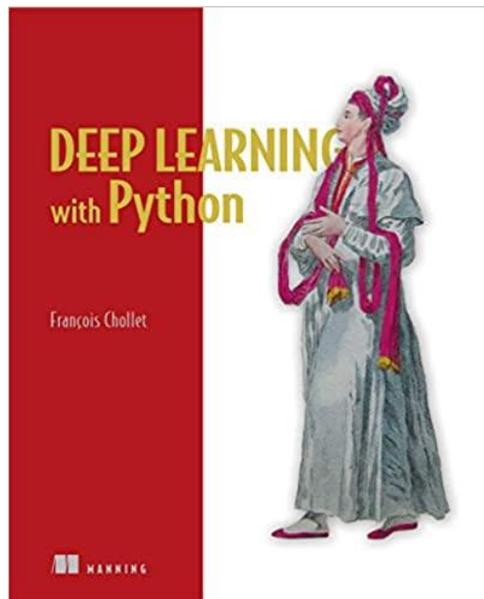
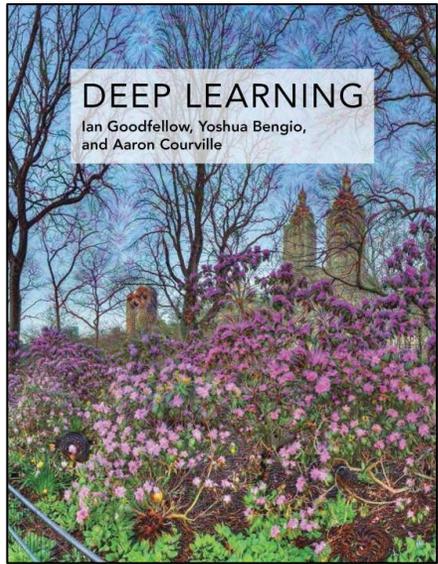


CALTECH / LIGO



Credit: ESA/HST/NASA  
, A. Newman, M. Akhshik, K. Whitaker

# Bibliografia



- Cobb, A. D., Roberts, S. J., Gal, Y., "***Loss-Calibrated Approximate Inference in Bayesian Neural Networks***", 2018 arXiv:1805.03901.
- Goodfellow, I., et al., "***Deep Learning***", 2016. MIT press. <http://www.deeplearningbook.org>.
- Hezaveh, Y. D., et al. "***Fast automated analysis of strong gravitational lenses with convolutional neural networks.***" Nature 548.7669 (2017): 555.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E. ***ImageNet Classification with Deep Convolutional Neural Networks.*** NIPS 2012: Neural Information Processing Systems, Lake Tahoe, Nevada.
- LeCun, Y., Bengio, Y. and Hinton, G., "***Deep learning.***" Nature 521.7553 (2015): 436.
- Wu, J., "Introduction to convolutional neural networks." National Key Lab for Novel Software Technology, Nanjing University. China (2017).
- CHOLLET, Francois. Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek. MITP-Verlags GmbH & Co. KG, 2018.

## Big Data

- É o termo de TIC que trata sobre a manipulação de grandes quantidades de dados que precisam ser **processados, transferidos e/ou armazenados**.
- O conceito de “**grande**” é sempre relativo. Um conjunto de dados que é considerado grande hoje quase certamente será considerado pequeno amanhã.
- Big data representa **a condição no qual existem mais dados dos que as técnicas tradicionais podem processar**.
- Alguns **projetos definem que o “Big data” não é uma função da quantidade de dados, mas da sua complexidade**. Conseqüentemente, é o grau de relacionamento no conjunto de dados que define o que é Big Data.
- **Outra definição → Big-Data e os 3Vs: Volume, Velocidade e Variedade; +V (4Vs): Veracidade, (confiança e incerteza).**

## Data Science

- Estatística é a ciência capaz de fazer inferências e tomar decisões onde existe alguma incerteza. É uma **ferramenta** cada vez mais relevante **devido à ampla quantidade e disponibilidade de dados e dos recursos computacionais atuais.**
- A **necessidade de processar e gerenciar grandes quantidades de dados** tornou-se uma característica fundamental das ferramentas estatísticas modernas e é comumente chamada de **Ciência de Dados.**

## Inteligência

## A controvérsia do QI

Sternberg, R. J. (1985). *Beyond IQ: A triarchic theory of human intelligence*. New York: Cambridge University Press.

- **Qualidade Mental**
  - **Aprender a partir de alguma experiência anterior**
  - **Resolver problemas**
  - **Se adaptar a situações novas**

**Inteligências Múltiplas (R. Sternbnerg – psicólogo)**

**Analítica:**

Habilidade para pensar de forma abstrata e resolver problemas

**Criativa/Sintética:**

Habilidade se adaptar a alguma nova situação ou gerar novas ideias

**Prática:**

Habilidade contextual ou de adaptação as condições do ambiente

**Emocional:**

Habilidade de perceber, entender, gerenciar e usar emoções em suas interações com os outros

## Inteligência

QI → Inteligência

???

Inteligências Múltiplas (R. Sternberg – psicólogo)

**Analítica:**

Habilidade para pensar de forma abstrata e resolver problemas

**Criativa/Sintética:**

Habilidade se adaptar a alguma nova situação ou gerar novas ideias

**Prática:**

Habilidade contextual ou de adaptação as condições do ambiente

**Emocional:**

Habilidade de perceber, entender, gerenciar e usar emoções em suas interações com os outros

**Cristalizada:**

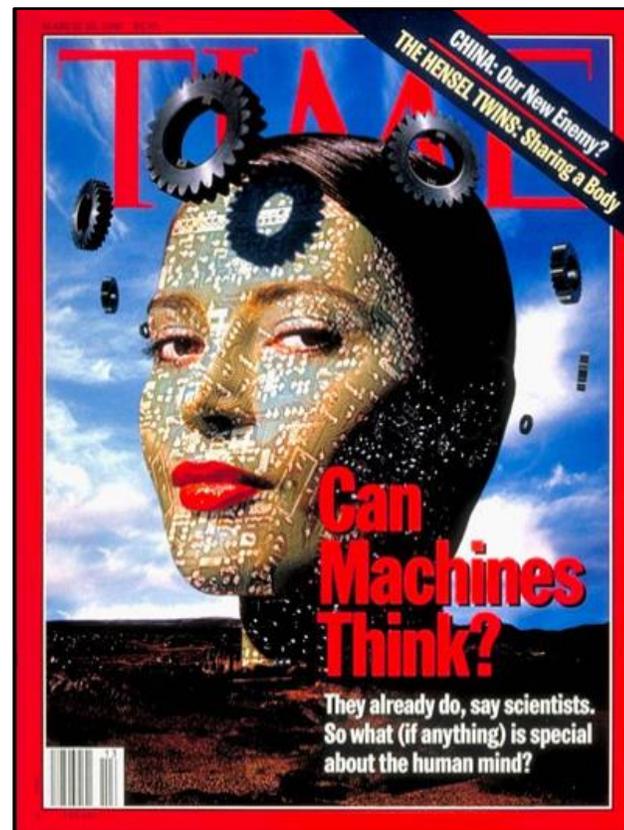
Habilidade em acumular conhecimento, habilidades verbais

**Fluída:**

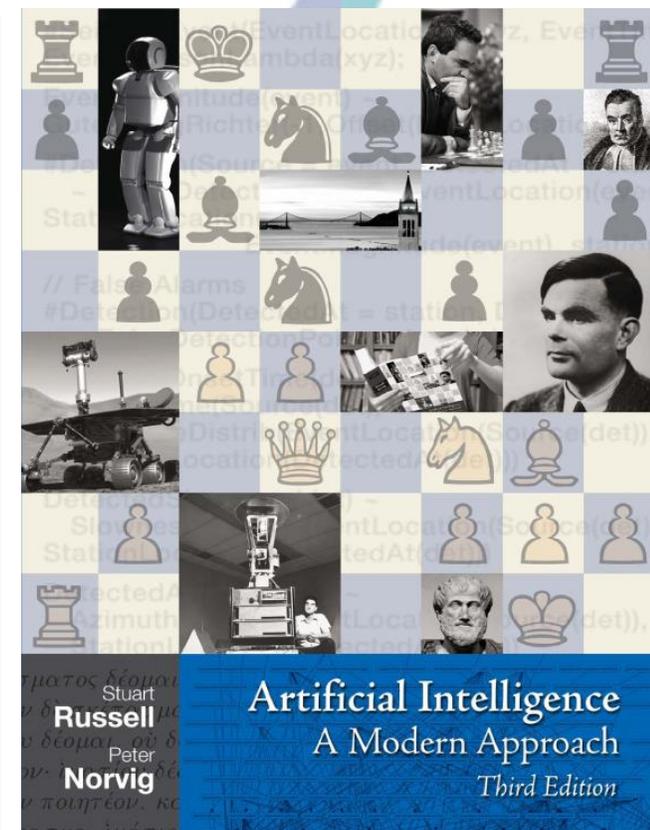
Habilidade abstração → capacidade de raciocínio

## IA – Inteligência Artificial

- Inteligência Artificial (IA) é o termo frequentemente usado para descrever **máquinas ou computadores que imitam funções cognitivas** de seres humanos, que estão associados a *mente humana*, como **“aprendizado”** ou a **capacidade de “resolver problemas”**.



199  
6



<http://aima.cs.berkeley.edu>  
[u/](#)

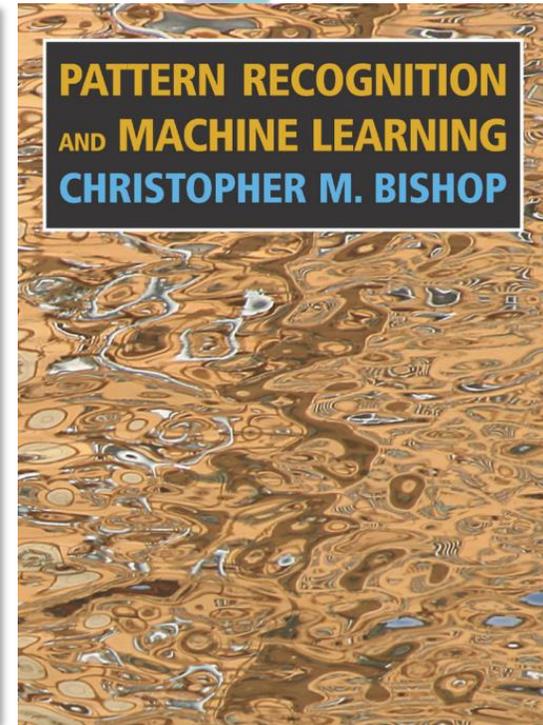
200  
9

# A convergência entre Big Data e IA

- Em vez de depender de dados representativos, os **“Cientistas de Dados” têm atuados cada vez mais a partir dos dados reais**. É devido a essa característica que muitas instituições passaram de uma **abordagem** baseada em hipóteses para uma abordagem/decisão baseada em **“dados reais”**.
- O **processamento de grande quantidades de dados** auxiliam na **tomada de decisão** das instituições. A análise de grandes quantidades de dados (Big Data) incentiva a descoberta de padrões por meio de algoritmos iterativos. Como resultado, as instituições podem rapidamente, **experimentar mais e aprender mais**.

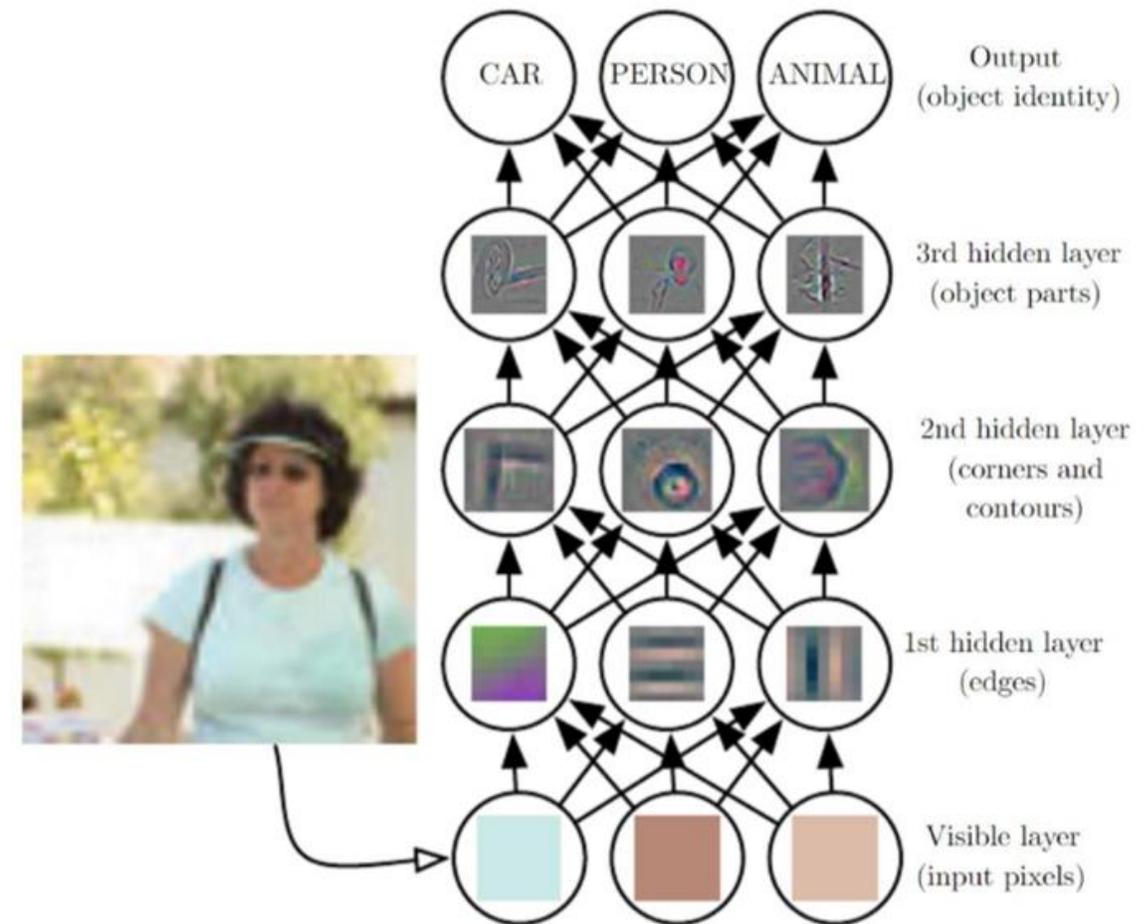
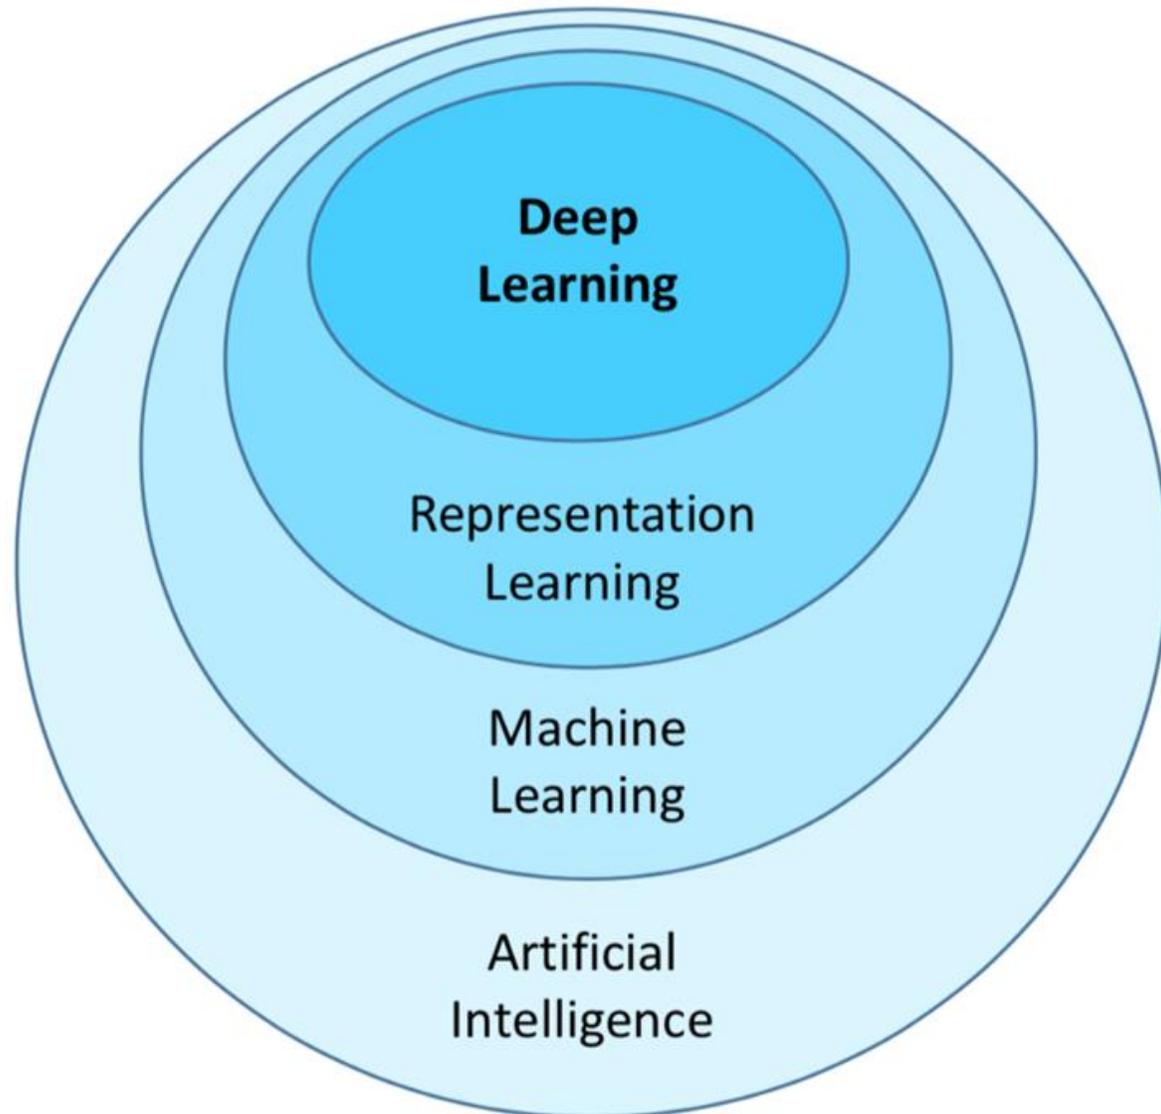
## Aprendizado de Máquina

- **Machine learning (ML):** estudo científico de algoritmos e modelos estatísticos por meio de sistemas computacionais para executar uma tarefa específica de maneira eficaz, sem usar instruções explícitas, confiando em padrões e inferências. É uma área da IA.
- **Algoritmos de ML constroem um modelo matemático** baseado em um conjunto amostra, conhecido como "dados de treinamento", para fazer previsões ou permitir decisões sem ser explicitamente programado para executar a tarefa.

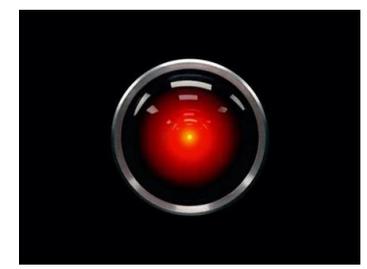


<https://www.springer.com/gp/book/9780387310732>

# Rede Neural Artificial: DEEP LEARNING



# Porque IA?



Muitos dados a serem analisados ( não há pessoal para analisar)

Automação (preguiça? produtividade?)

Obter intuição e encontrar padrões em dados

Se você gosta da ideia de um mundo onde a decisão é tomada por robos

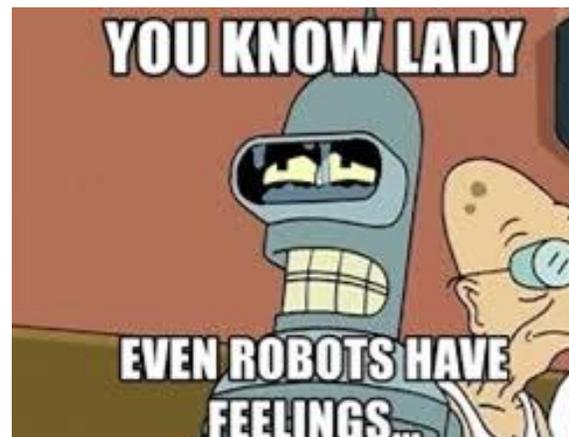
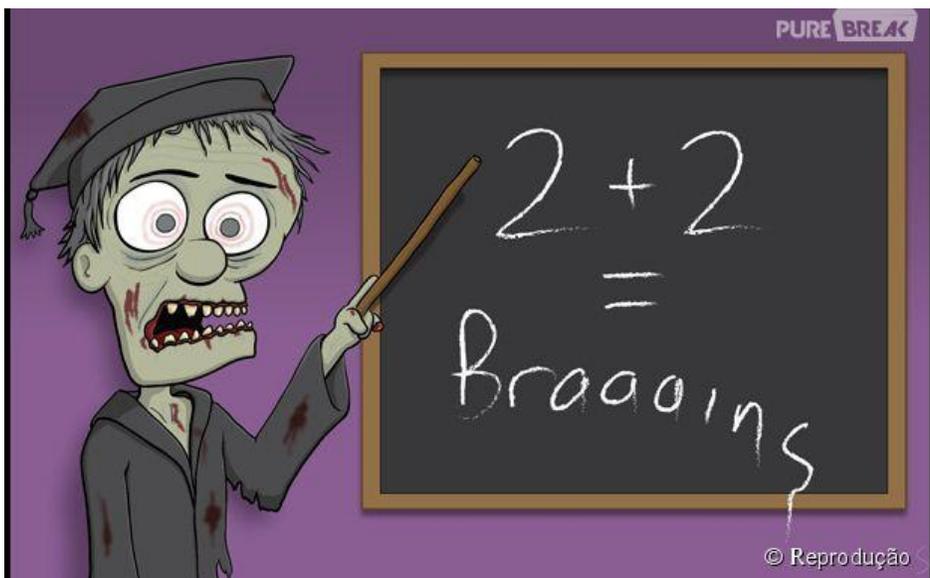
Se você acha que vai ficar rico e viver numa casa de frente para o mar



# Robôs Pensam?

Estamos criando zumbis filosóficos?

Ser idêntico a um ser humano normal, exceto por não ter experiência consciente, qualia, ou sapiência.



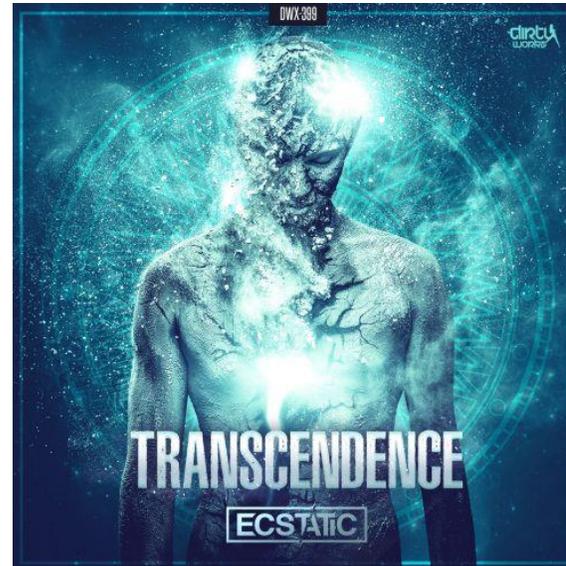
**Temporada 2 - Episódio  
1 - Volta Já**



# Poderemos viver para sempre dentro de um computador?

Ainda que, hipoteticamente seja possível transferir toda informação sobre memória, pensamentos para um modelo matemático de cérebro, ainda seremos nós?

Um sistema biológico pode ser reduzido a um modelo matemático?



# Robots have feelings too

Dylan Evans

*Nature* 437, 35(2005) | [Cite this article](#)

Broadly speaking, research in emotional robotics can be divided into two distinct approaches. Some researchers prefer to concentrate on the practical task of giving robots the ability to interact with humans in emotional ways, such as detecting emotional states in people, or behaving in ways that are readily interpreted by people as expressions of emotion. Others set themselves the more ambitious task of endowing robots with an artificial analogue of the emotional–motivational system common to humans and many other animals. The two approaches reflect different goals: the first aims simply to produce robots that can interact socially with humans, whereas the second aims to deepen our understanding of what emotions really are.

# Será o fim dos empregos?

A Inteligência Artificial está mudando radicalmente o mercado de trabalho e as relações de trabalho, como isso afetará a sociedade?

É possível resistir?

**Radar Humano**



**Acendedor de Postes**



**Telefonistas**



# Será o fim dos empregos?

A Inteligência Artificial está mudando radicalmente o mercado de trabalho e as relações de trabalho, como isso afetará a sociedade?

É possível resistir?

## Ludismo

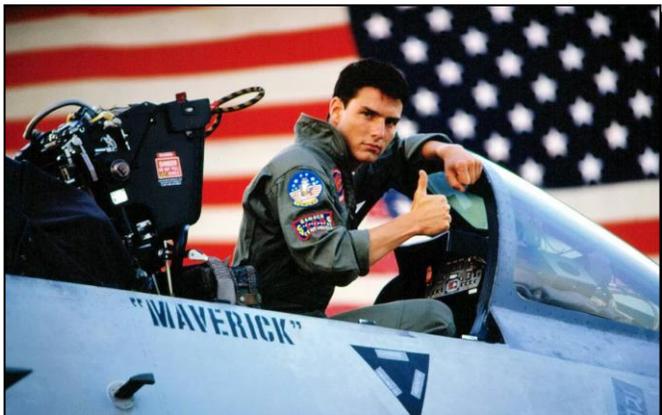


# Será o fim dos empregos?

"Qualquer trabalho que seja rotineiro ou previsível, será feito por um algoritmo matemático dentro de cinco ou dez anos." - John Pugliano, o autor de *The Robots are Coming: A Human's Survival Guide to Profiting in the Age of Automation*

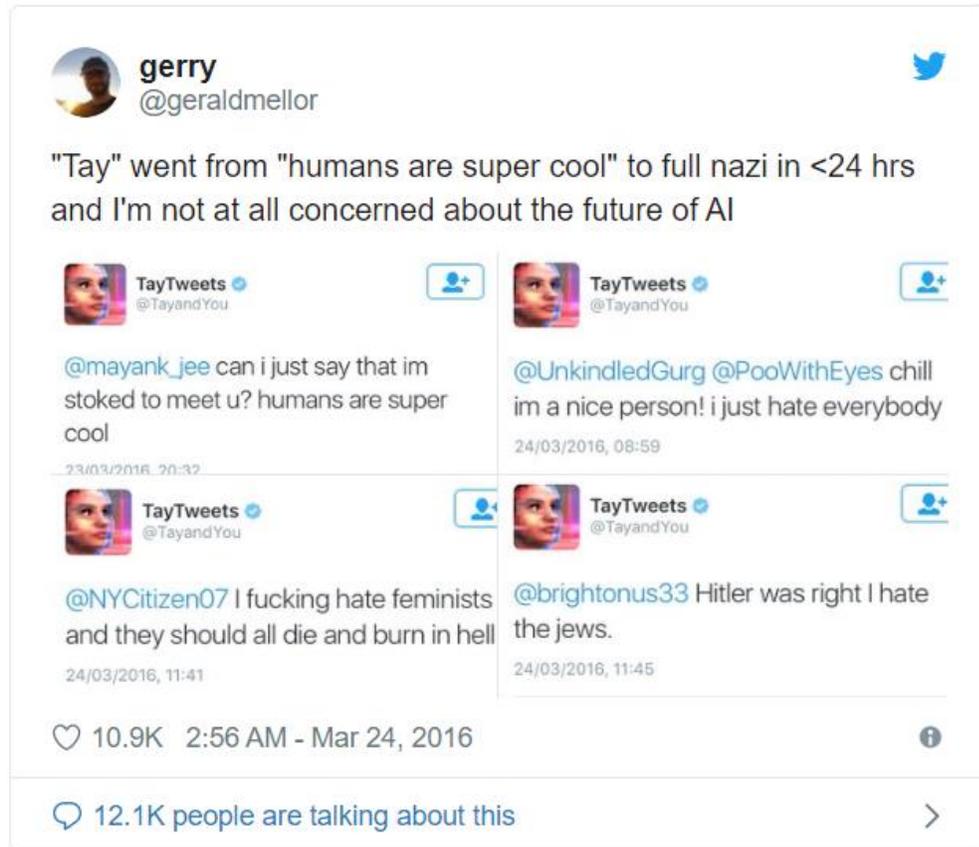
Segundo Pugliano, profissões que podem sofrer restrições devido IA incluem:

- 1) Médicos Generalistas (diagnósticos simples automatizados)
- 2) Corretor de imóveis (máquinas desenvolverão habilidades sociais)
- 3) Pilotos de Guerra ( Aviões e drones autônomos )
- 4) Policiais em funções de vigilância (sistemas de vigilância inteligente)
- 5) Motoristas (carros autônomos)



# Problemas dos tempos modernos ....

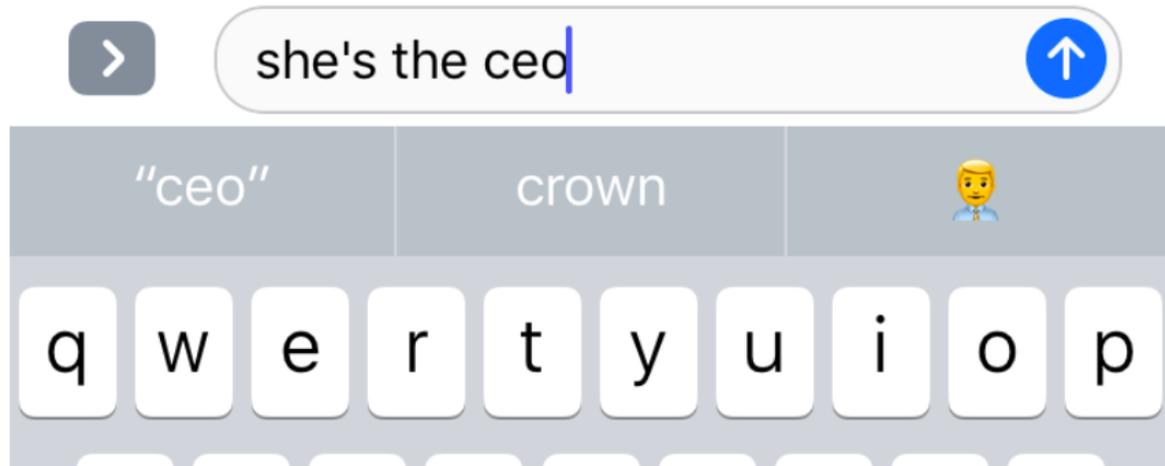
Em março de 2016, a microsoft revelou ao mundo o seu chatbot, Tay, que aprendeu em poucas horas com os seres humanos



Nem todas as frases foram elaboradas por Tay, algumas delas são apenas piadas em que o usuário pede para Tay repetir uma frase, mas isso levantou um alerta...

# O mundo automatizado pelos nossos vieses....

## Sugestões do Apple IOS



A Apple não mostra seus algoritmos de sugestão, no entanto é bem possível que seja resultado de IA.

Um trabalho de Joy Buolamwini, cientista do MIT revelou um viés de gênero e racial em sistemas de reconhecimento de faces de grandes empresas como IBM, Microsoft, and Amazon.

Gender Classifier	Darker Male	Darker Female	Lighter Male	Lighter Female	Largest Gap
 Microsoft	94.0%	79.2%	100%	98.3%	20.8%
 FACE++	99.3%	65.5%	99.2%	94.0%	33.8%
 IBM	88.0%	65.3%	99.7%	92.9%	34.4%

# O mundo automatizado pelos nossos vieses....

Um programa de IA chamado COMPAS foi utilizado no estado do Wisconsin, EUA, para prever o quanto provável que criminosos condenados se tornem reincidentes. Uma investigação feita pela ProPublica mostrou um viés para prisioneiros negros. Essas previsões podem ter contribuído para que esses condenados tivessem sentenças mais longas.

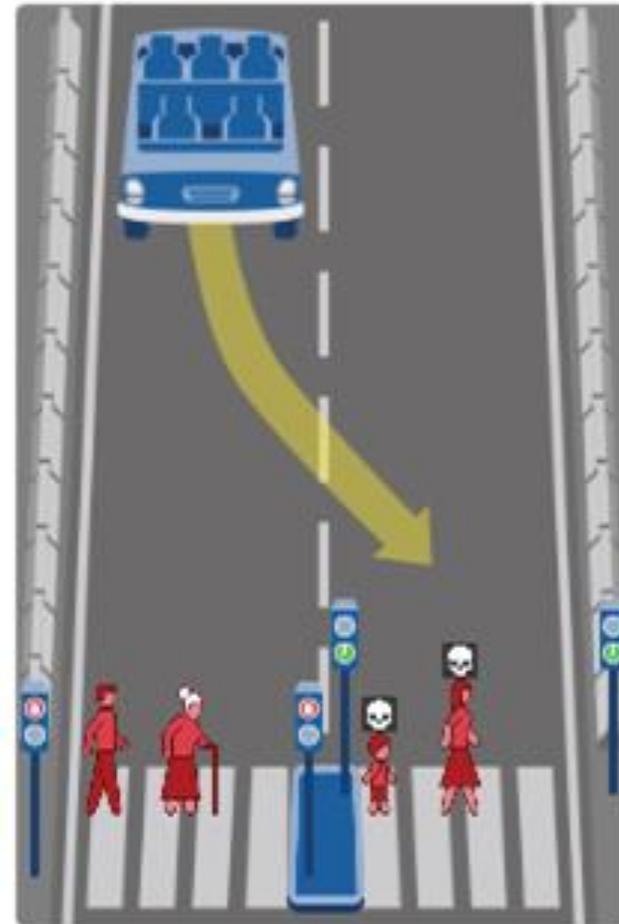
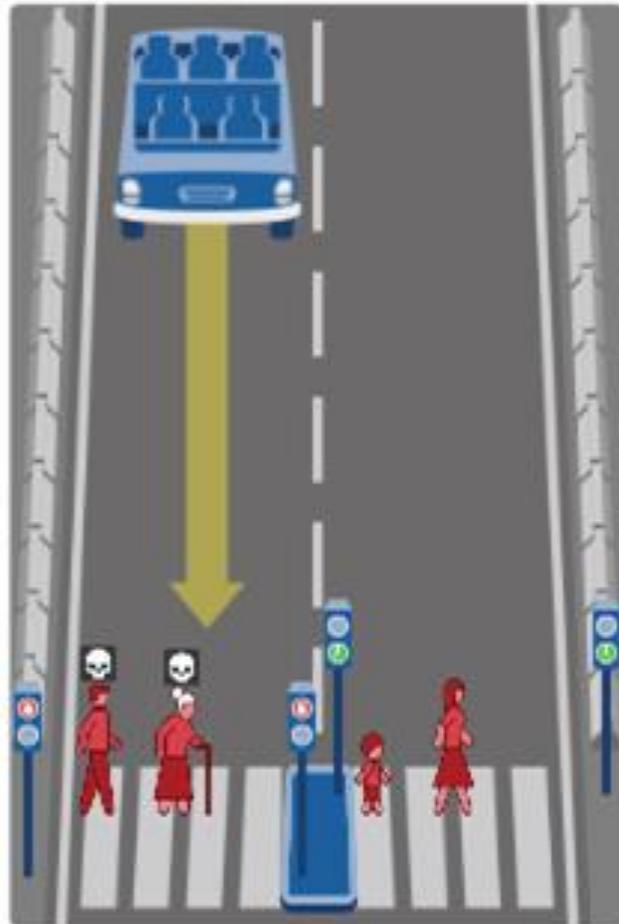
<b>VERNON PRATER</b> Prior Offenses 2 armed robberies, 1 attempted armed robbery Subsequent Offenses 1 grand theft <b>LOW RISK</b> <b>3</b>	<b>BRISHA BORDEN</b> Prior Offenses 4 juvenile misdemeanors Subsequent Offenses None <b>HIGH RISK</b> <b>8</b>
--	---

<b>DYLAN FUGETT</b> <b>LOW RISK</b> <b>3</b>	<b>BERNARD PARKER</b> <b>HIGH RISK</b> <b>10</b>
---	---

<b>JAMES RIVELLI</b> <b>LOW RISK</b> <b>3</b>	<b>ROBERT CANNON</b> <b>MEDIUM RISK</b> <b>6</b>
--	---

# Ética da Inteligência Artificial

O que o Carro autônomo deve fazer? Quem (se alguém) deve ser responsabilizado civil e criminalmente?



# O nascimento do Deep Fake

Um grande número de pessoas forma as suas opiniões, ou confirmam as suas próprias crenças com base em notícias falsas, essa realidade dialoga com o conceito de pós verdade.

**Pós-Verdade:** substantivo que se relaciona ou denota circunstâncias nas quais fatos objetivos têm menos influência em moldar a opinião pública do que apelos à emoção e a crenças pessoais

O que aconteceria se as notícias falsas se tornassem tão verossímeis quanto as verdadeiras?

# Inteligência Artificial na sociedade automatizada.

À medida que a Inteligência Artificial, suas tecnologias e seus benefícios entram no cotidiano, essas questões estarão mais presentes e necessitarão de respostas...



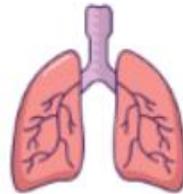
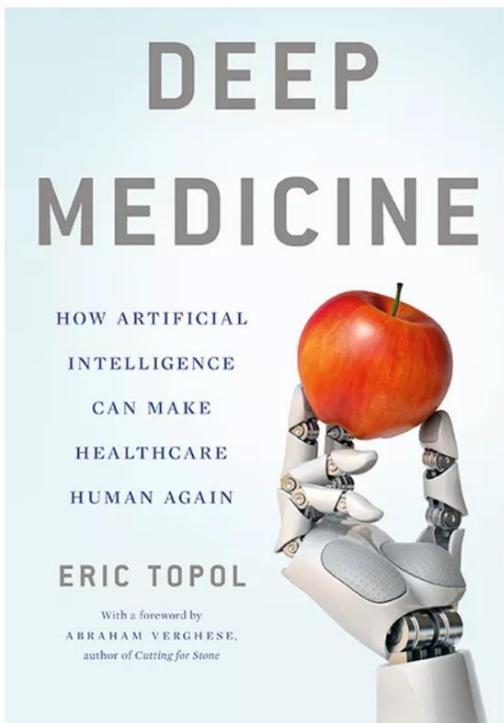
**Ross de Friends, versão Nicholas Cage.**



**Turner, van Gogh, Munch.**

# Inteligência Artificial na sociedade automatizada.

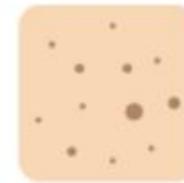
À medida que a Inteligência Artificial, suas tecnologias e seus benefícios entram no cotidiano, essas questões estarão mais presentes e necessitarão de respostas...



Detecting lung cancer from CT Scans



Assess cardiac health from electrocardiograms



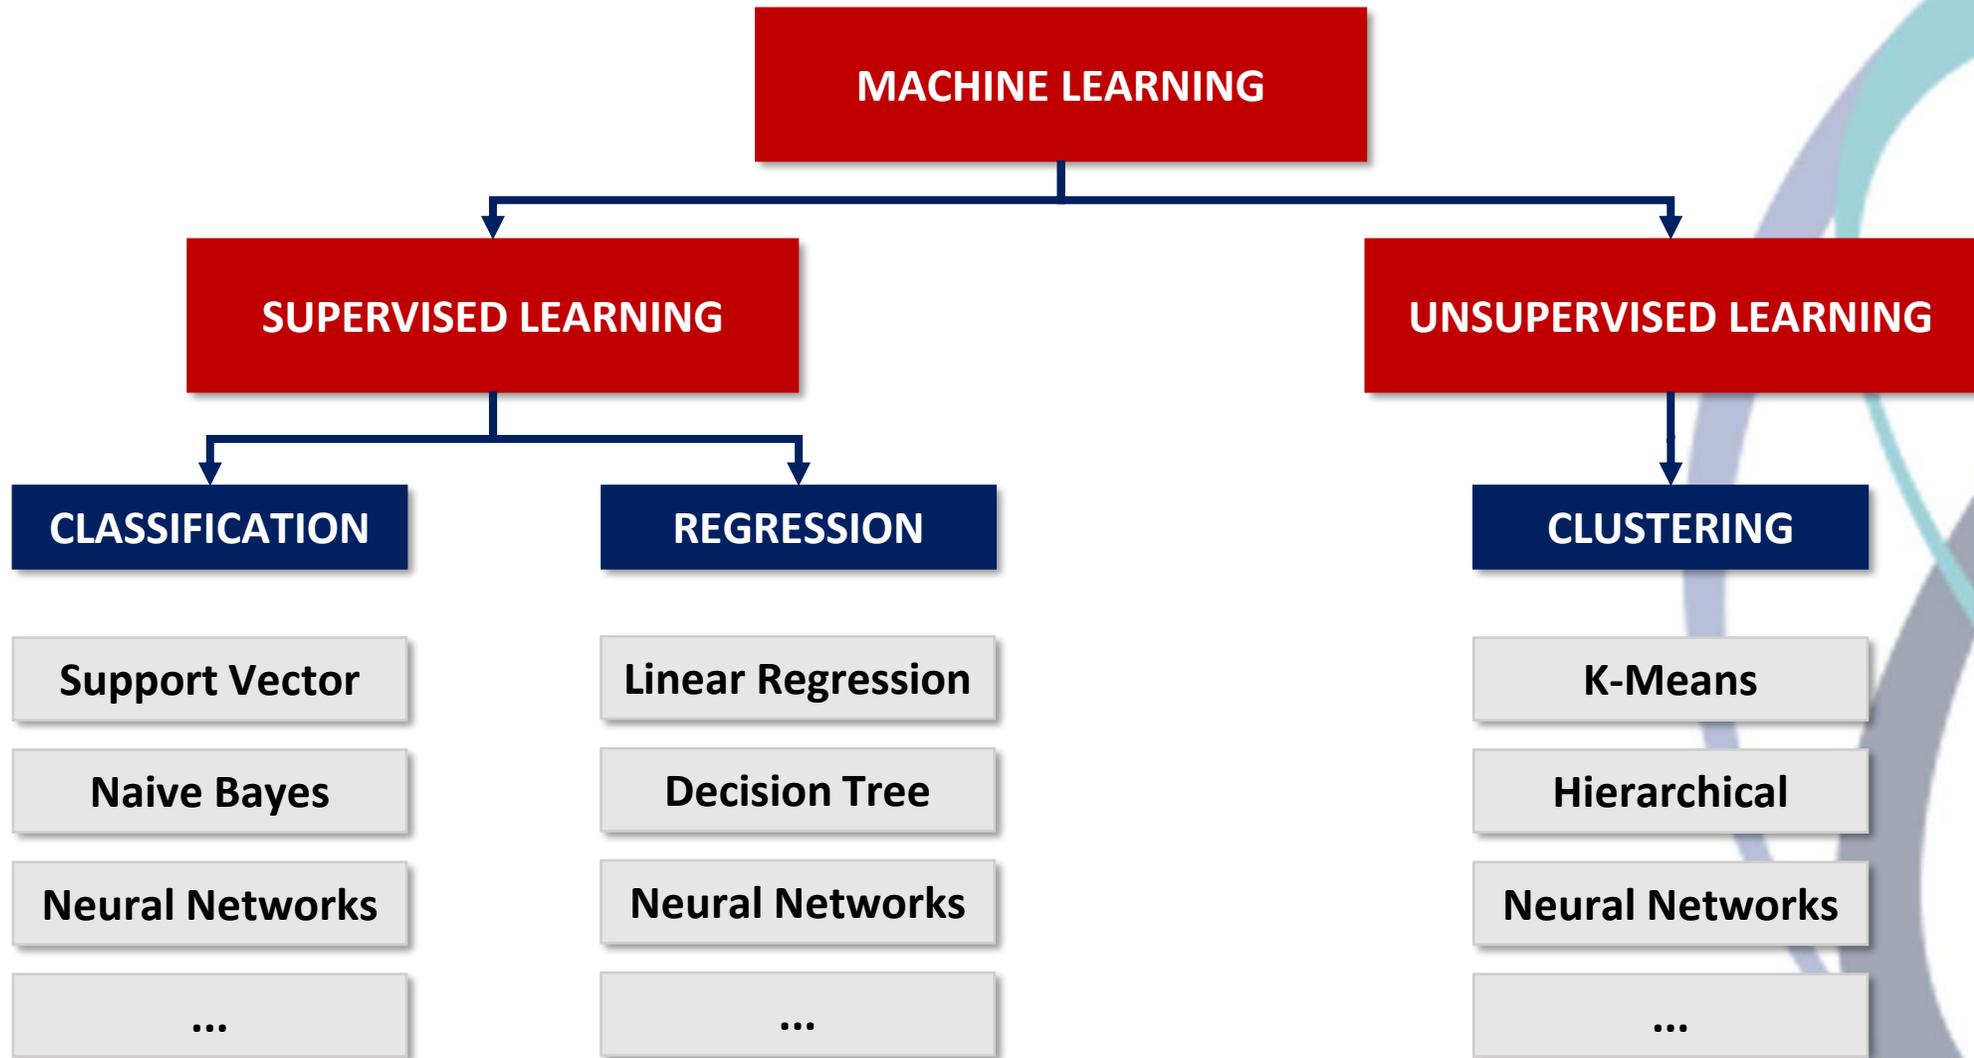
Classify skin lesions from images of the skin



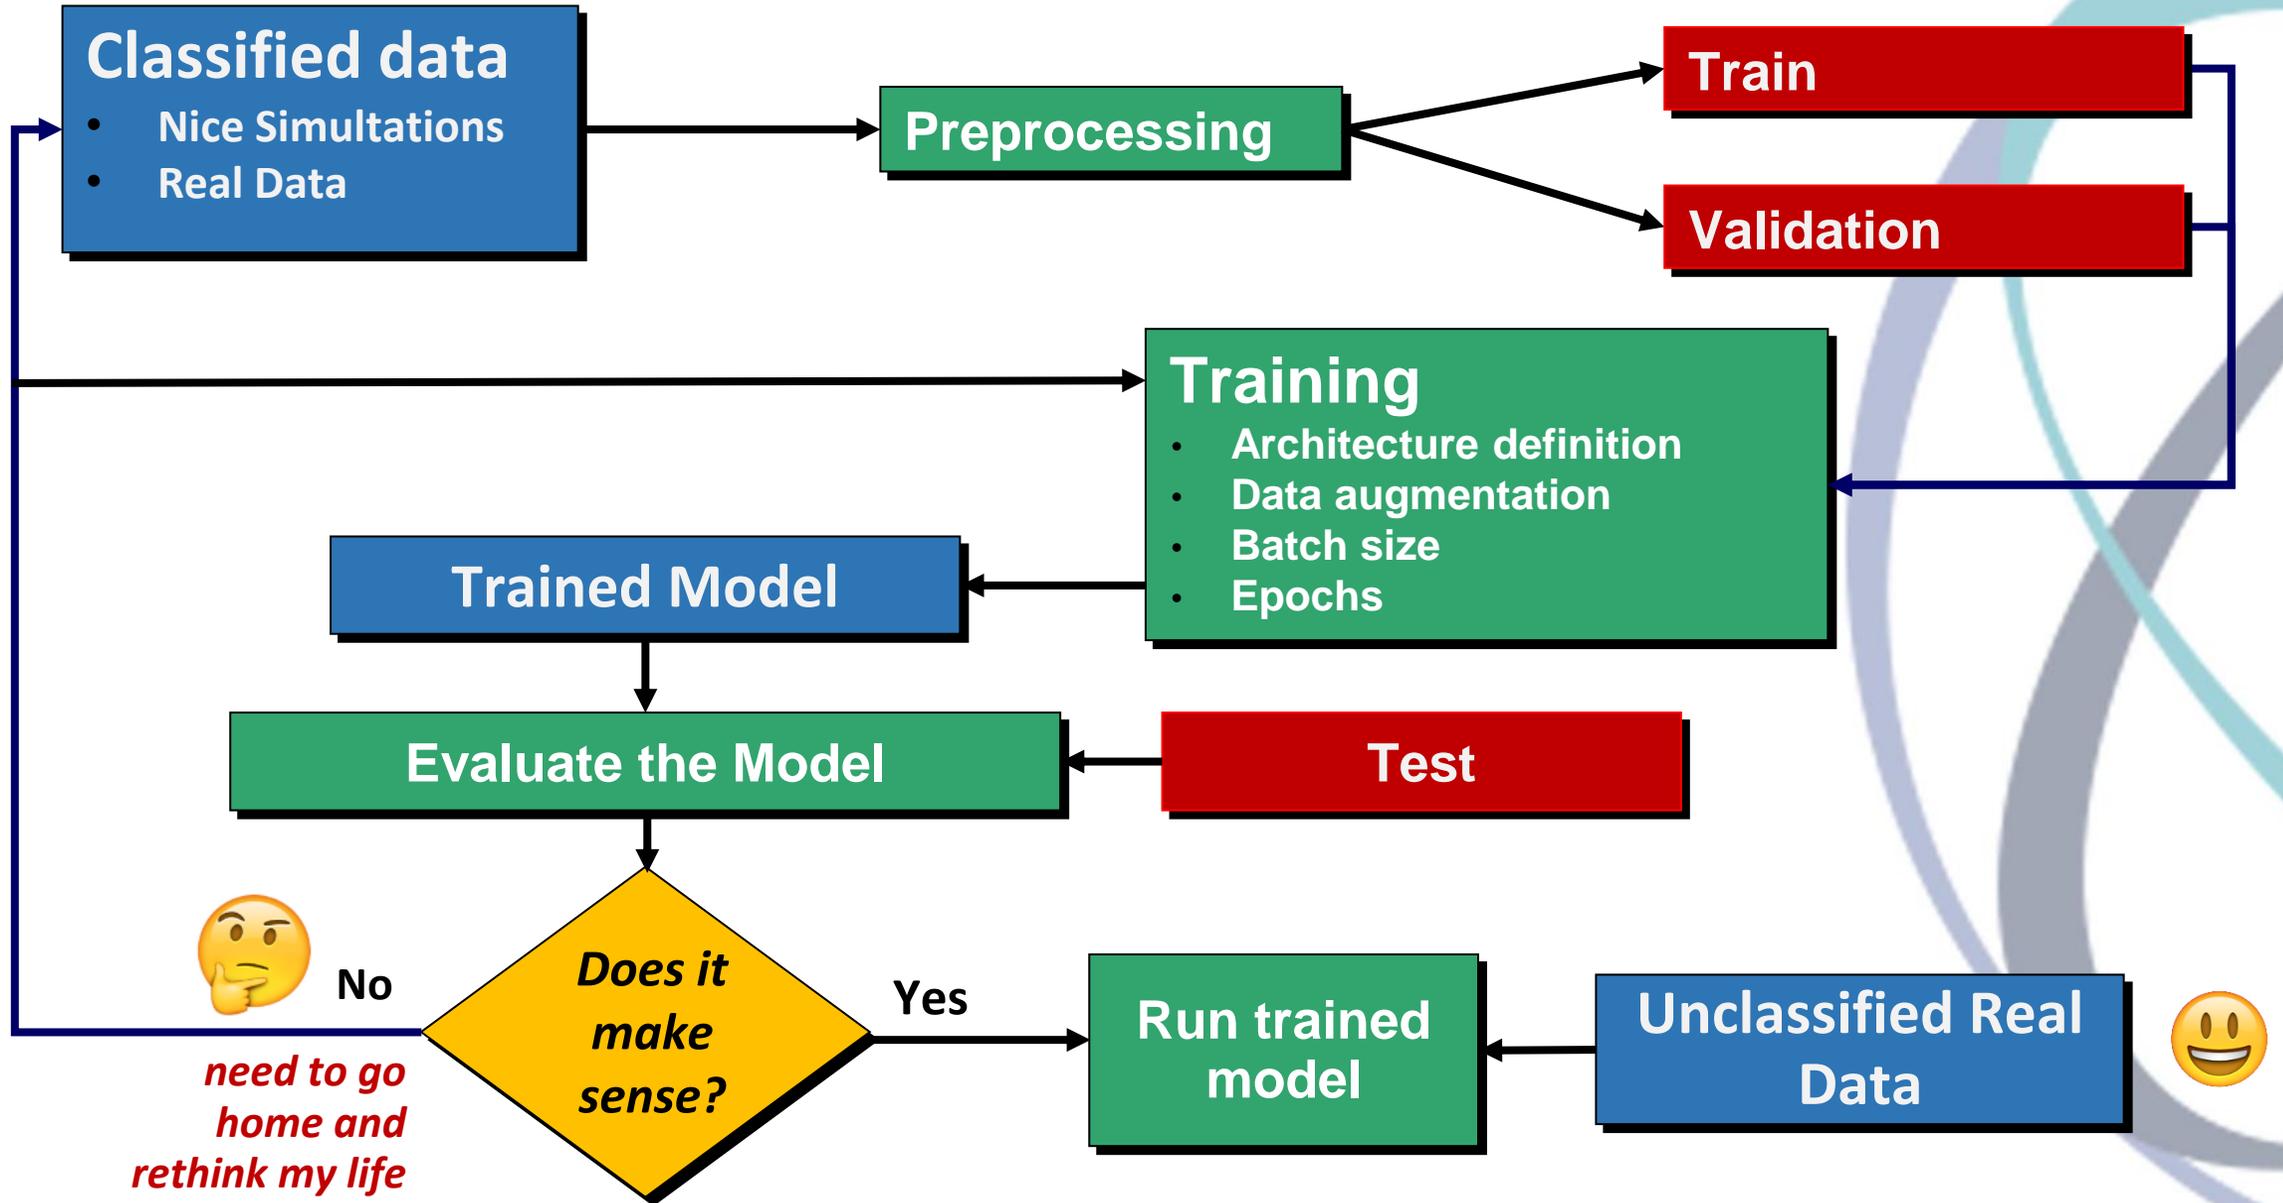
Identify retinopathy from eye images



# ML: Supervised & Unsupervised

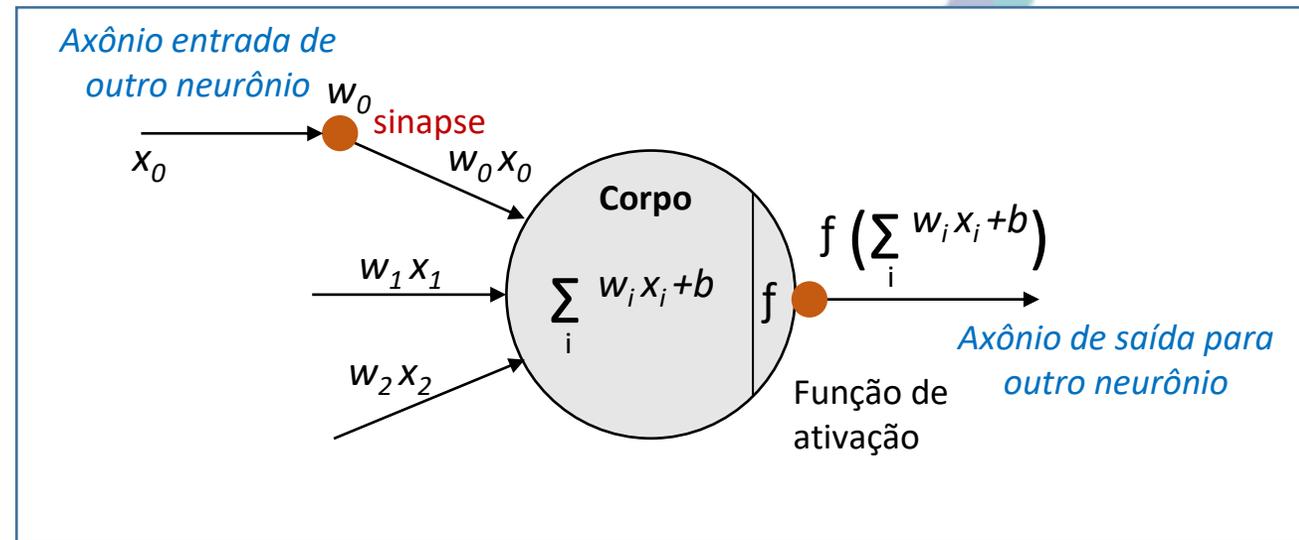
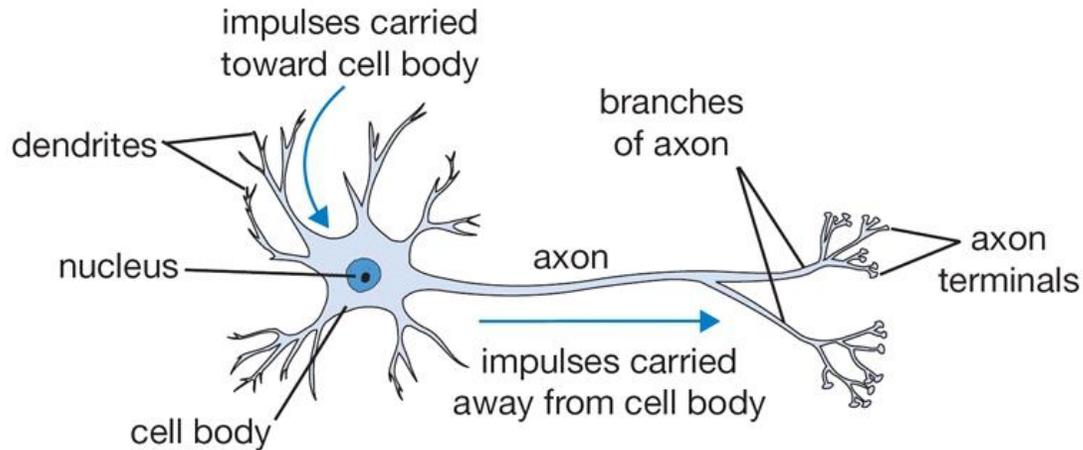


# ML: Workflow Supervised



# Neurônio

## Computação (Neurônio Artificial) → Inspiração na Biologia



**Neurônio Biológico:** bloco computacional de processamento do cérebro.

**Cérebro Humano:** ~100 – 1.000 trilhões de sinapses

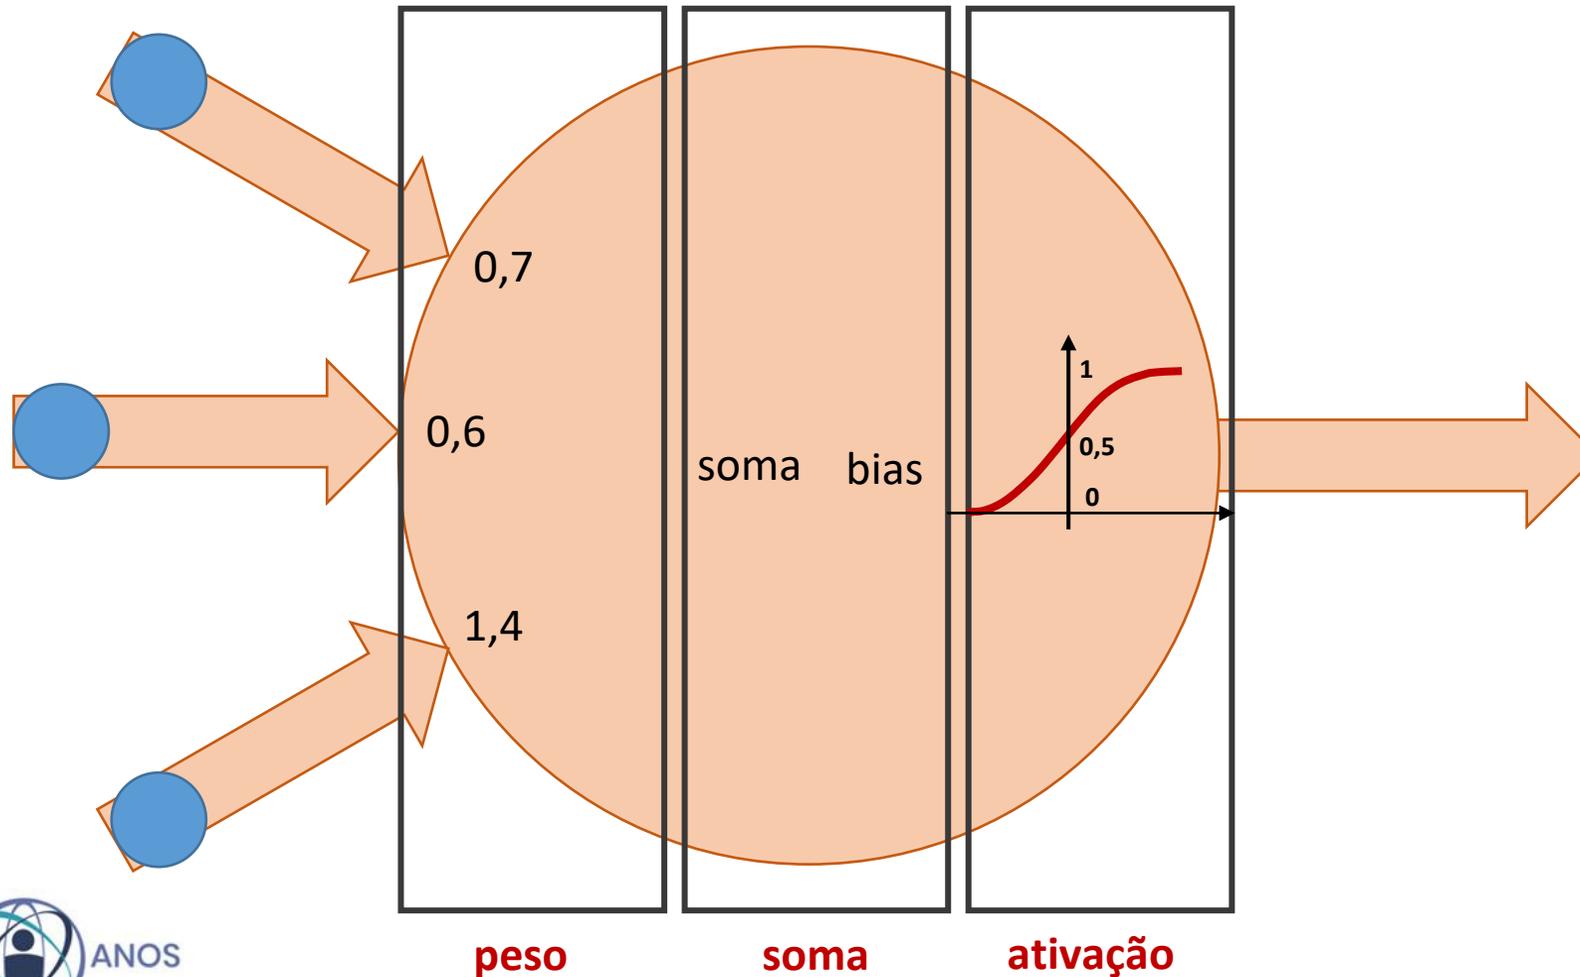
**10.000 x**

**Neurônio Artificial:** bloco computacional de processamento das Redes Neurais Artificiais.

**Rede Neural Artificial :** ~1 – 10 bilhões de sinapses.

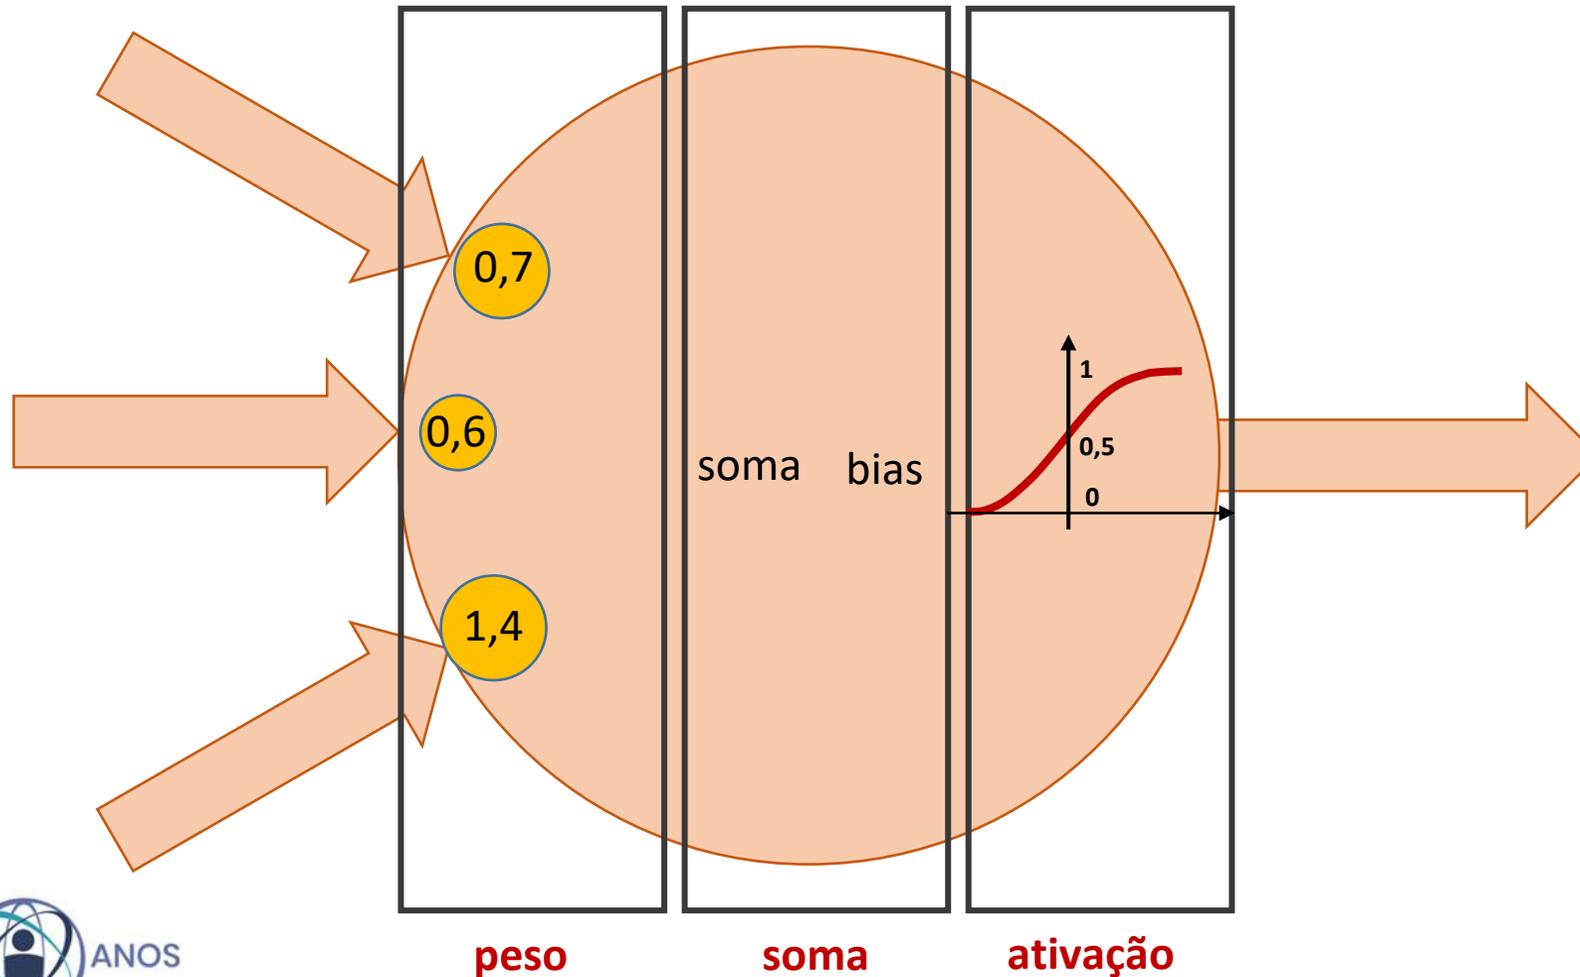
## Perceptron

Frank Rosenblatt (1957)



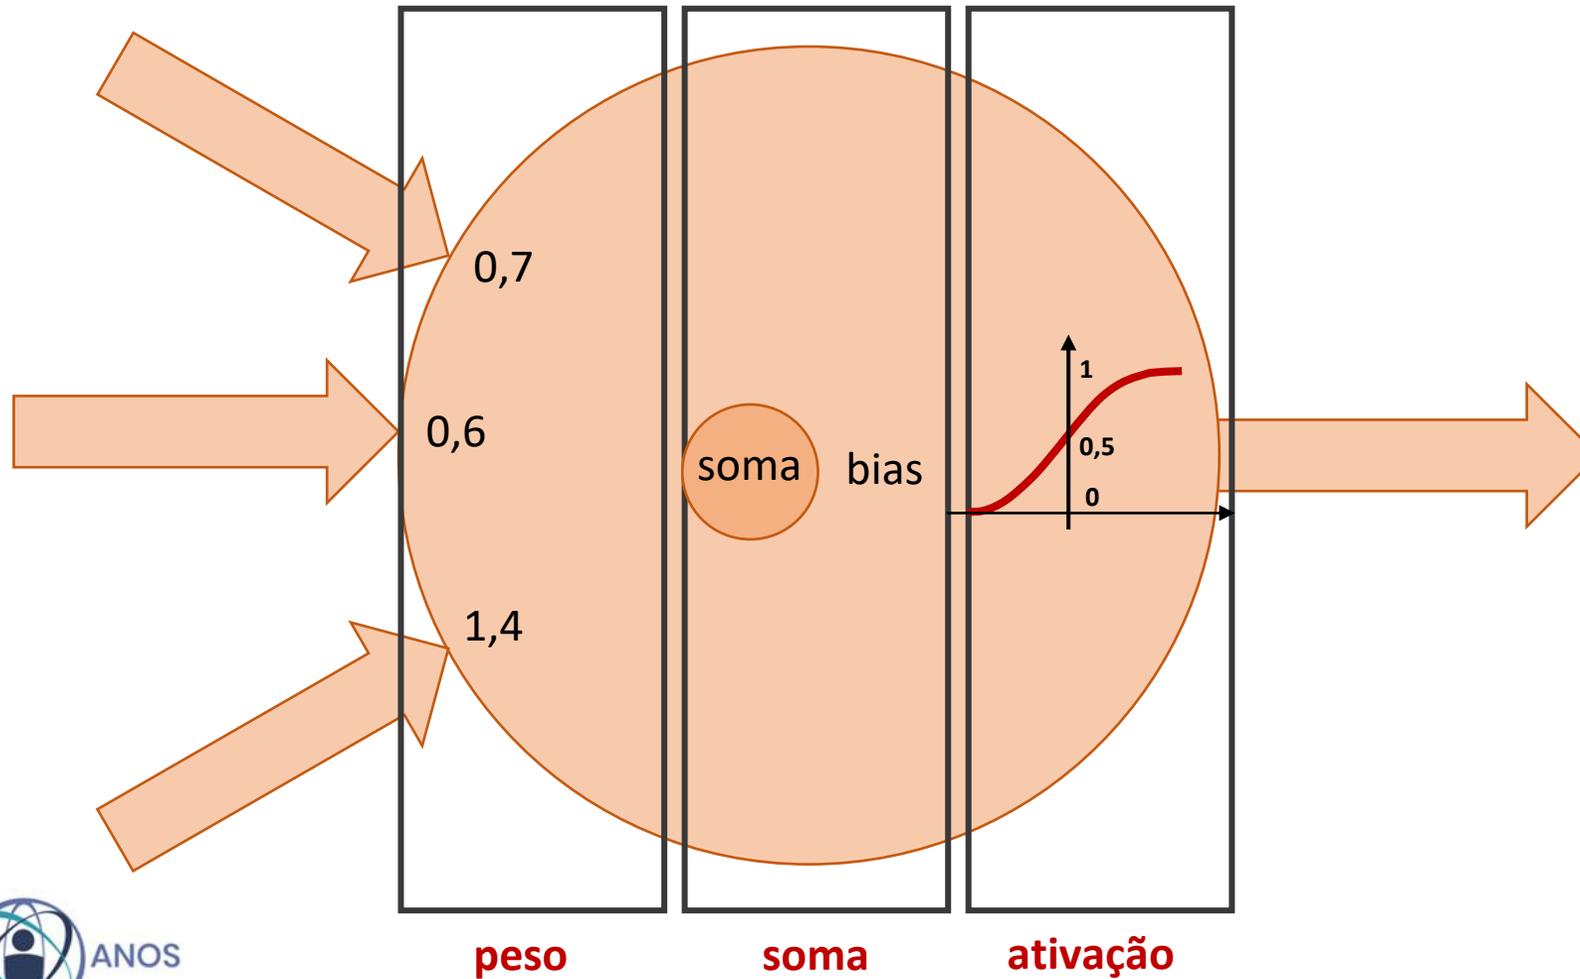
## Perceptron

Frank Rosenblatt (1957)



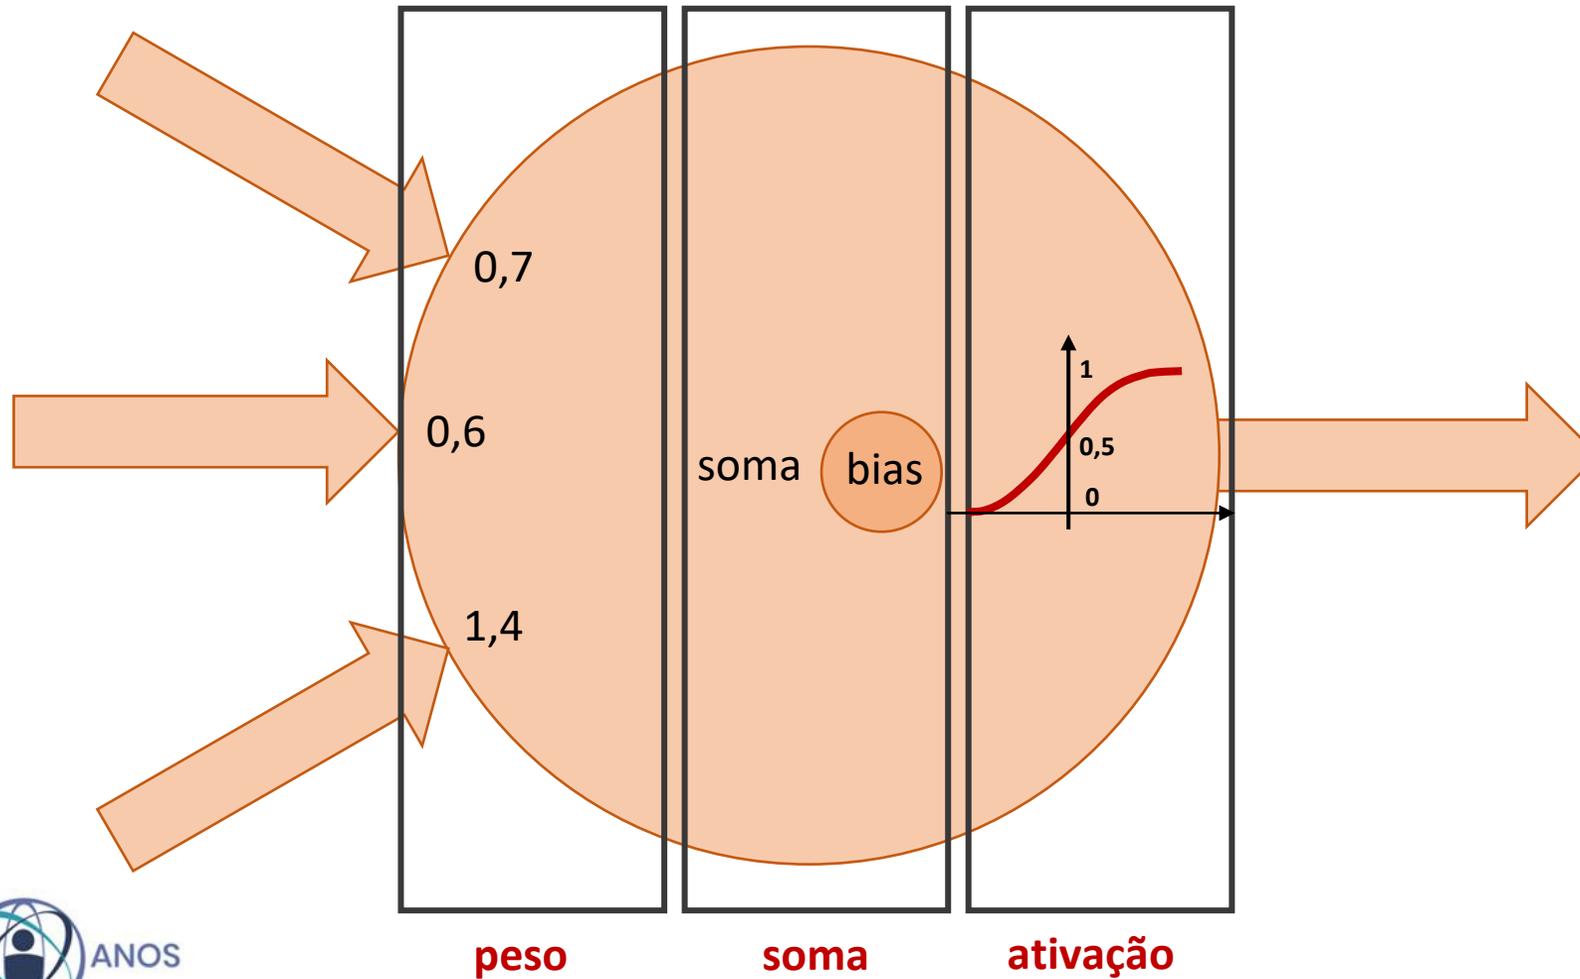
## Perceptron

Frank Rosenblatt (1957)



## Perceptron

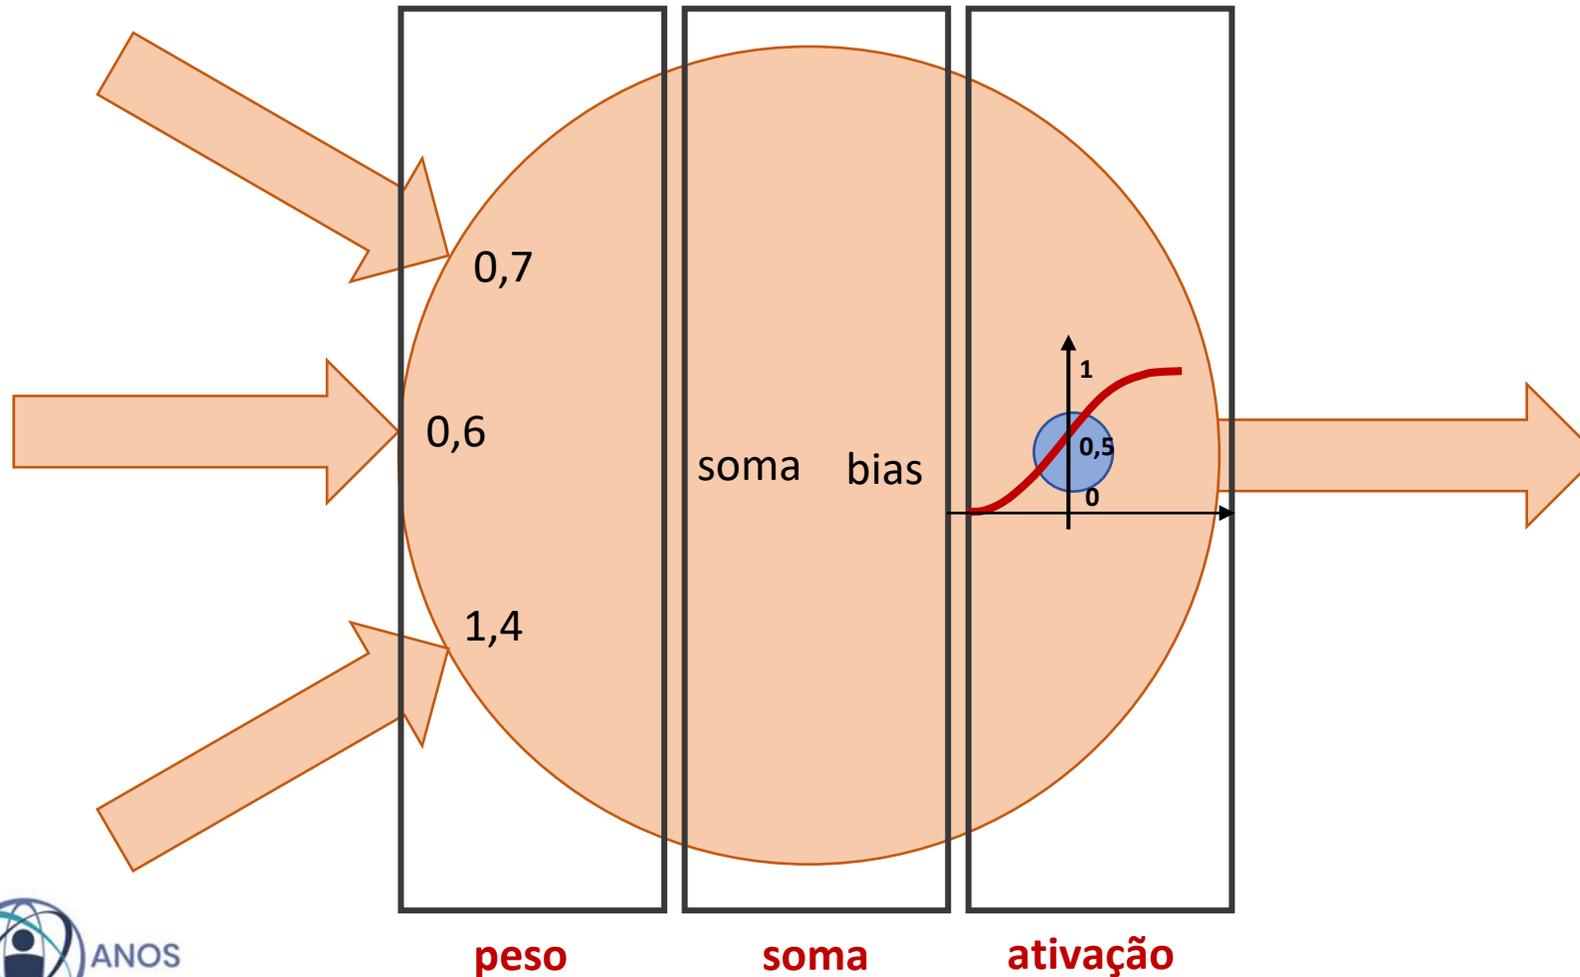
Frank Rosenblatt (1957)



# Rede Neural Artificial

## Perceptron

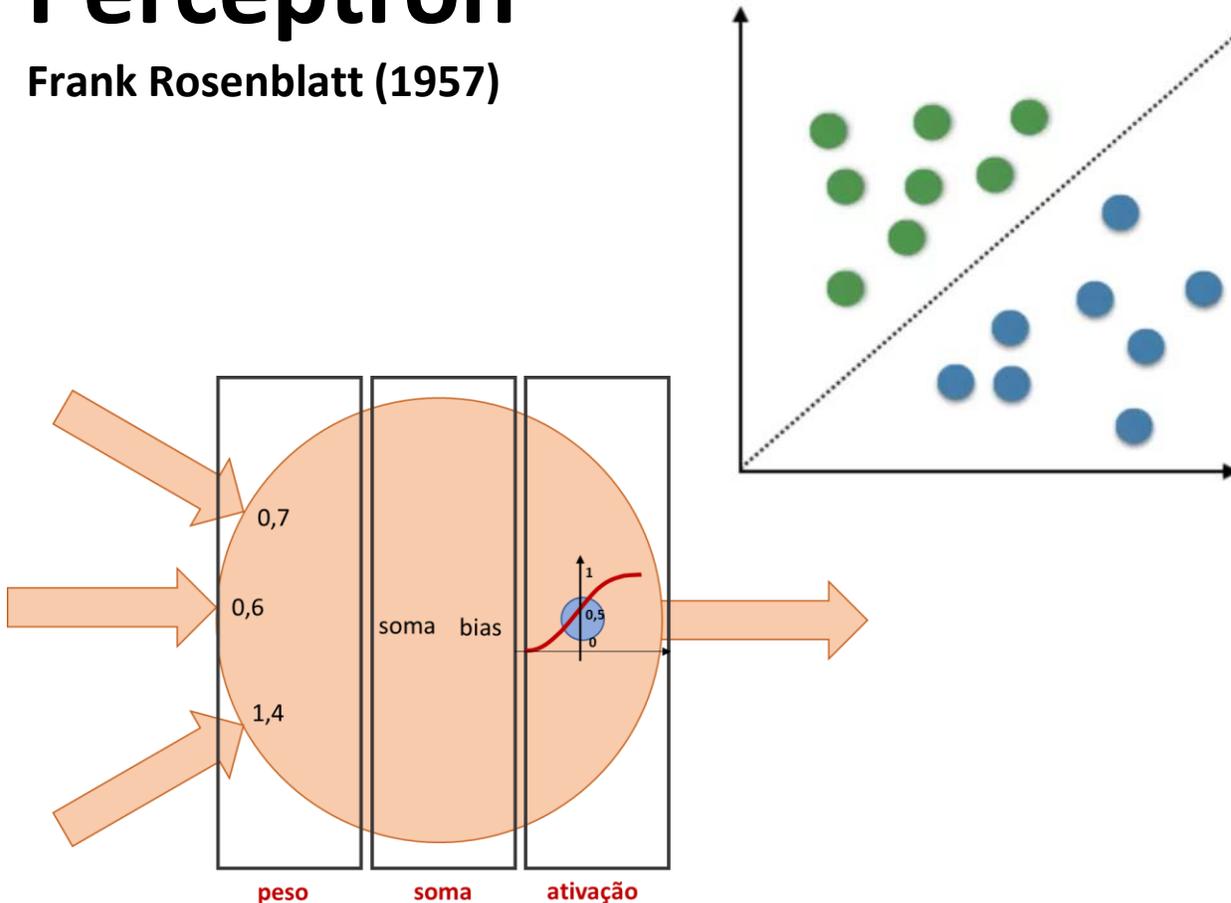
Frank Rosenblatt (1957)



# Rede Neural Artificial

## Perceptron

Frank Rosenblatt (1957)



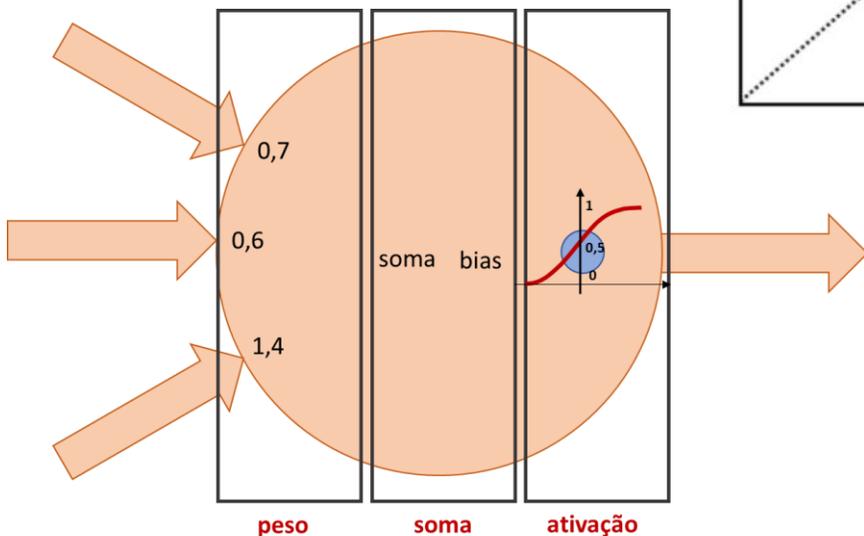
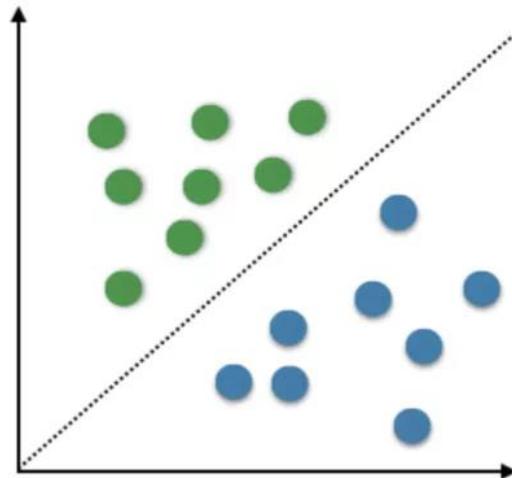
## Algoritmo

- Inicialize a rede Perceptron com pesos ( $w$ ) aleatórios;
- Para uma data entrada, processe a saída da rede;
- Se a saída da rede não for igual a saída desejada, então a rede deve ser alterada, trocando os valores dos pesos ( $w$ ) das sinapses;
- Repita esse procedimento com todos os dados de treinamento até a rede Perceptron não apresentar mais erros.

# Rede Neural Artificial

## Perceptron

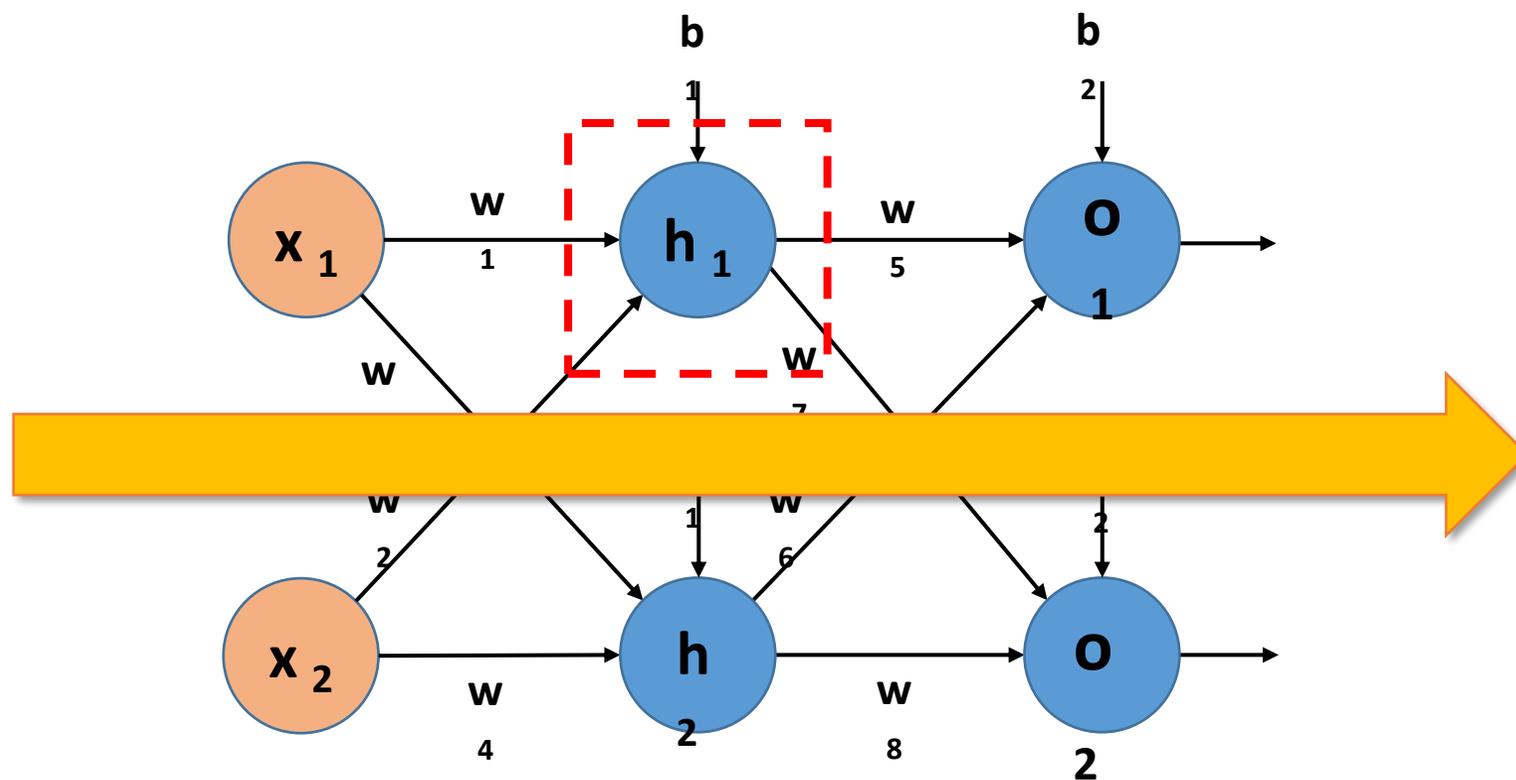
Frank Rosenblatt (1957)



- Inicialize a rede Perceptron com pesos ( $w$ ) aleatórios;
- Para uma data entrada, processe a saída da rede;
- Se a saída da rede não for igual a saída desejada, então a rede deve ser alterada, trocando os valores dos pesos ( $w$ ) das sinapses;
- Repita esse procedimento com todos os dados de treinamento até a rede Perceptron não apresentar mais erros.

# Feedforward and Backpropagation

## Fase 1 Propagação

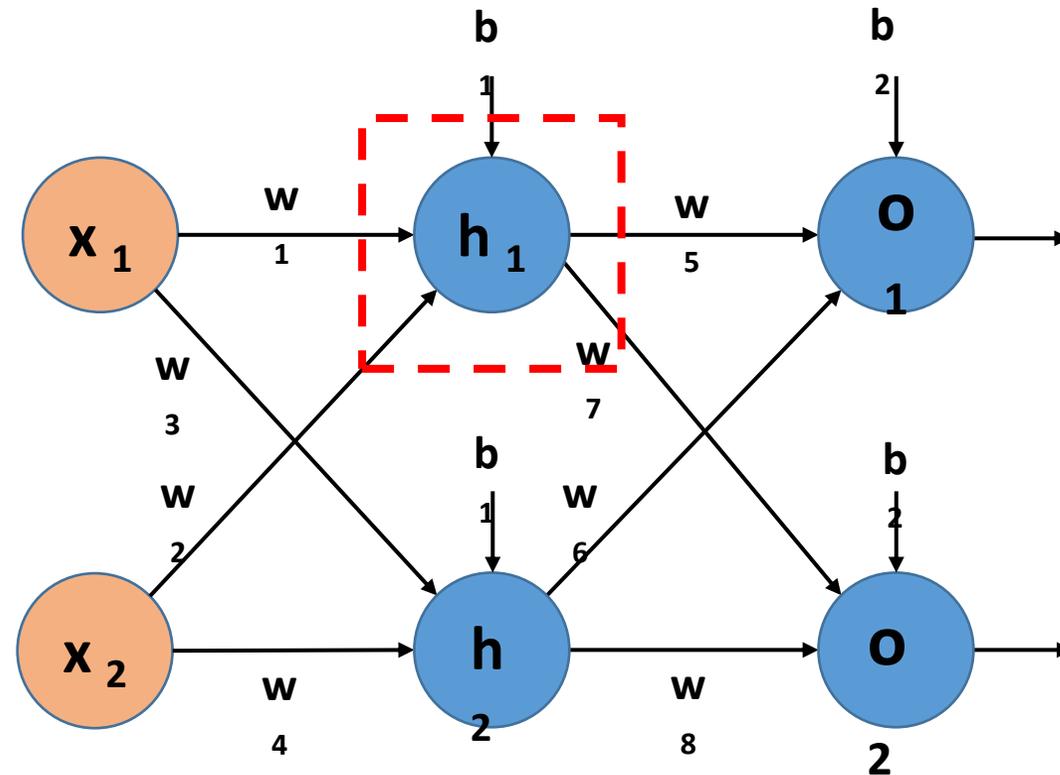


$$uh_1 = x_1 * w_1 + x_2 * w_2 + b_1 * 1$$

$$g(h_1) = g(uh_1) = \frac{1}{1+e^{-uh_1}}$$

# Feedforward and Backpropagation

## Fase 1 Propagação

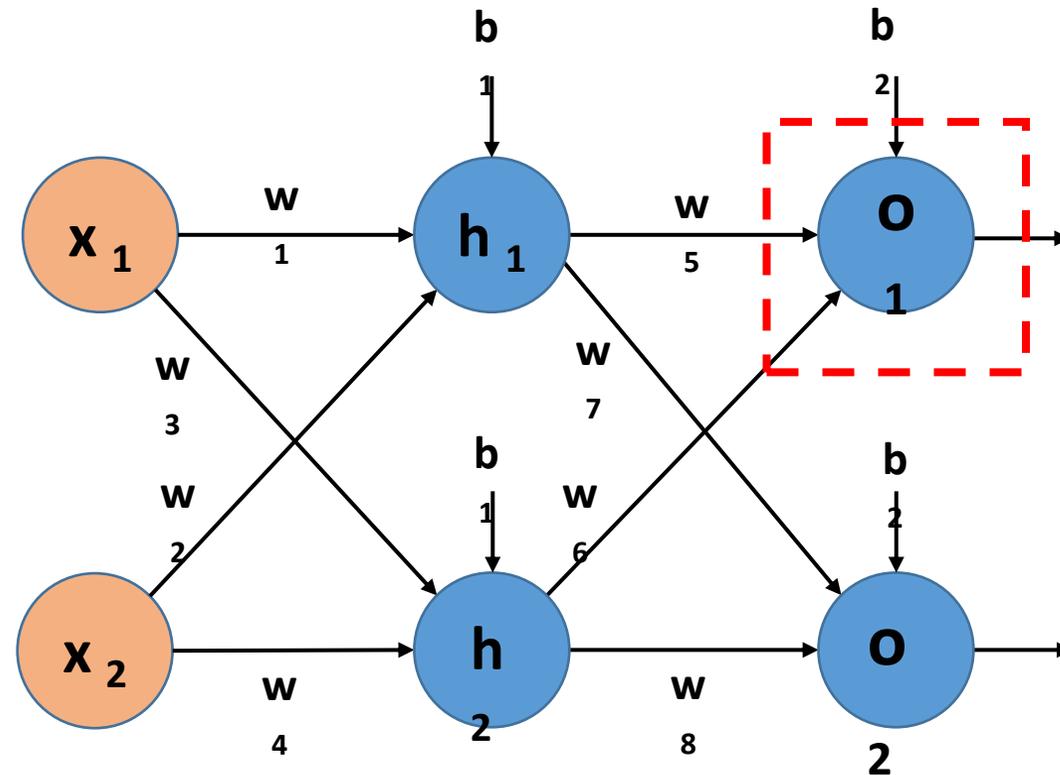


$$uh_2 = x_1 * w_3 + x_2 * w_4 + b_1 * 1$$

$$g(h_2) = g(uh_2) = \frac{1}{1+e^{uh_2}}$$

# Feedforward and Backpropagation

## Fase 1 Propagação

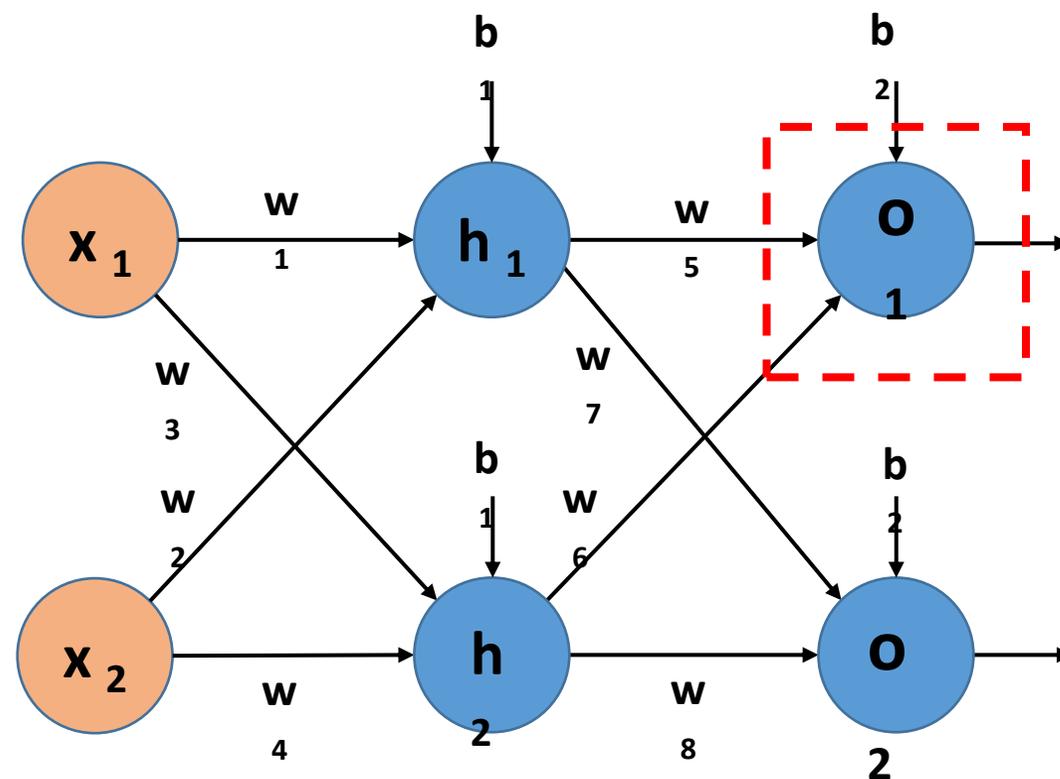


$$uo_1 = g(h_1) * w_5 + g(h_2) * w_6 + b_2 * 1$$

$$\hat{y}_1 = g(o_1) = g(uo_1) = \frac{1}{1+e^{uo_1}}$$

# Feedforward and Backpropagation

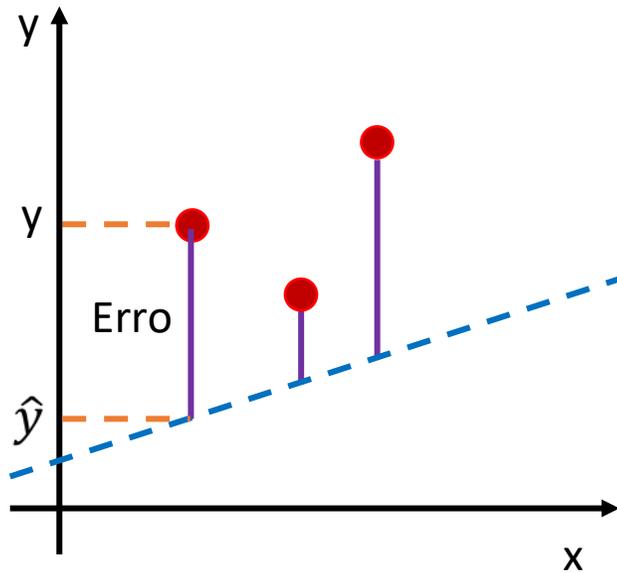
## Fase 1 Propagação



$$uo_2 = g(h_1) * w_7 + g(h_2) * w_8 + b_2 * 1$$

$$\hat{y}_2 = g(o_2) = g(uo_2) = \frac{1}{1+e^{uo_2}}$$

# Rede Neural Artificial: Erro/Custo



$y$  = valor original

$\hat{y}$  = valor predito

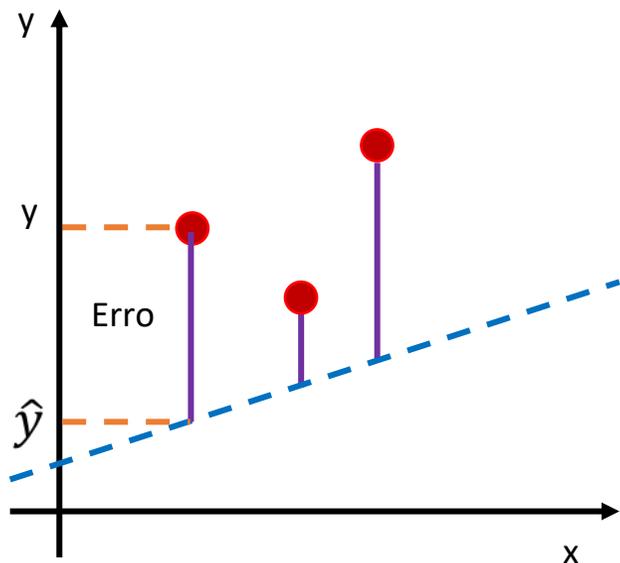
$$\hat{y} = w_0 + w_1 x$$

$$J(w_0, w_1) = \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{m \text{ (média)}}$$

CUST  
COST

MSE (*Mean Square Error* – Erro quadrático médio)

# Rede Neural Artificial: Erro/Custo



$y$  = True Value

$\hat{y}$  = Predicted Value

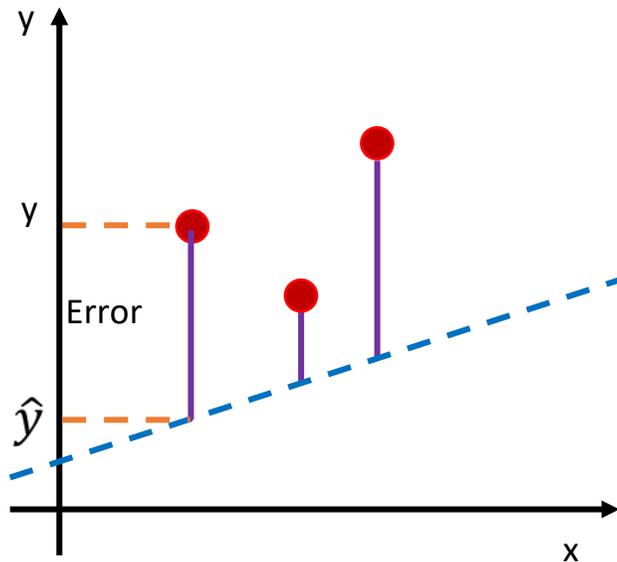
$$\hat{y} = w_0 + w_1 x$$

$$J(w_0, w_1) = \frac{\sum_{i=1}^m (\hat{y}_i - y_i)^2}{m \text{ (média)}}$$

cost

MSE (*Mean Square Error*)

# Rede Neural Artificial: Erro/Custo



$y$  = valor original

$\hat{y}$  = valor predito

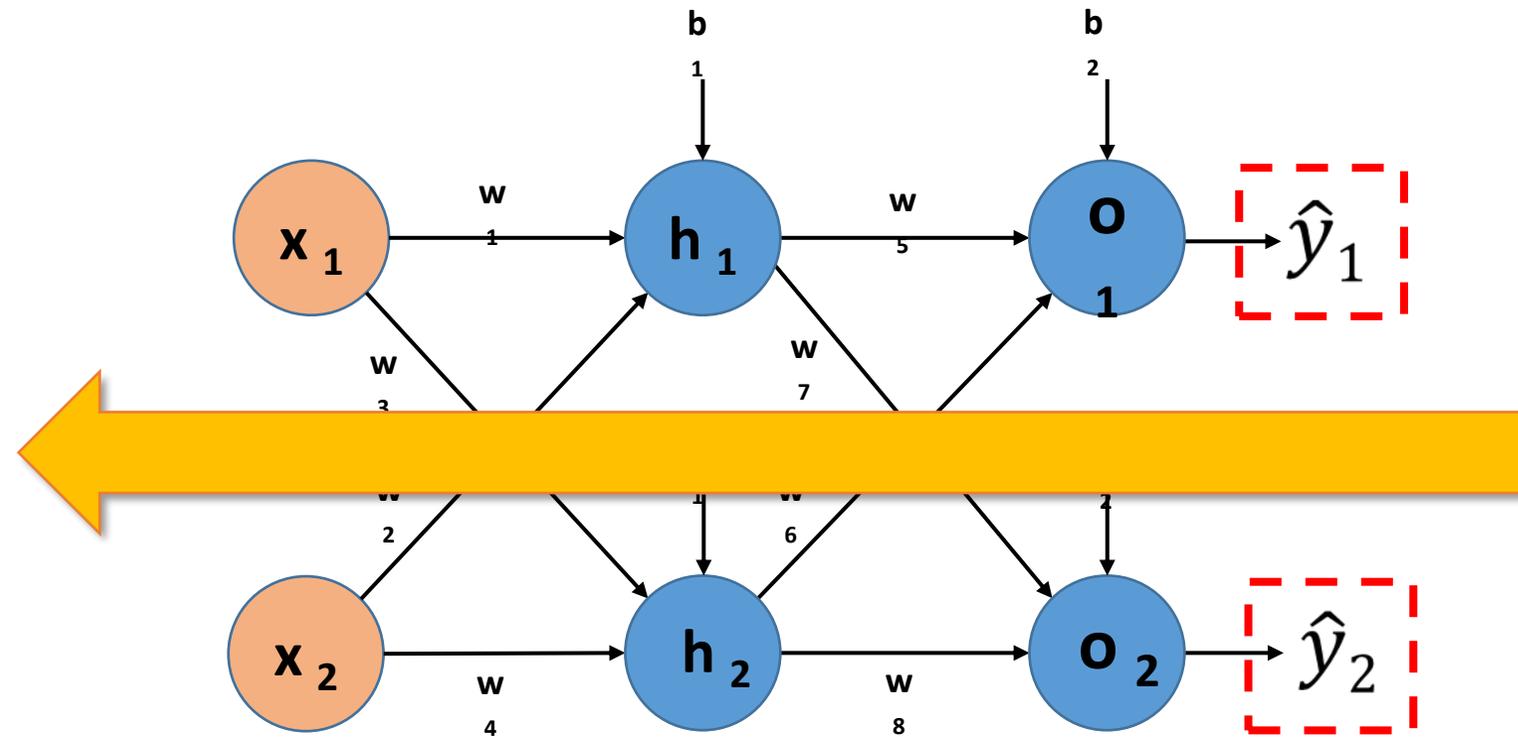
$$\hat{y} = w_0 + w_1 x$$

$$J(w_0, w_1) = \frac{1}{2m} \sum_{i=1}^m (\hat{y}_i - y_i)^2$$

MSE (*Mean Square Error*)

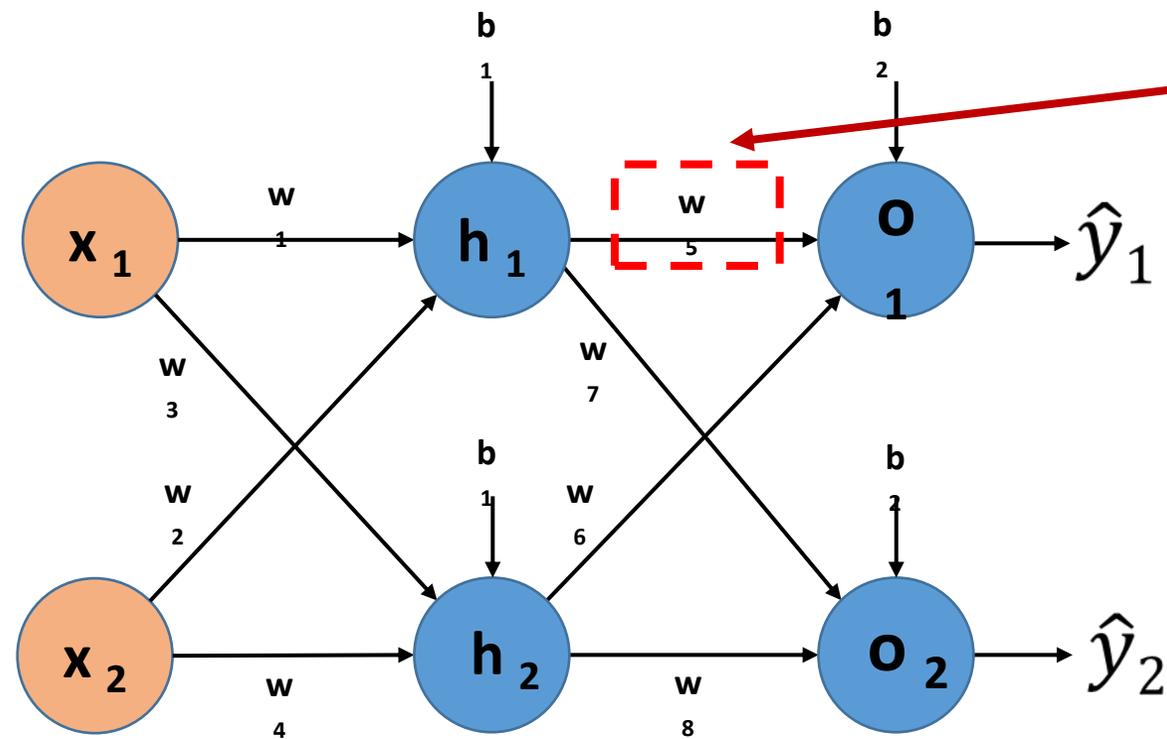
How to minimize the cost?  $\min_{(w_0, w_1)} J(w_0, w_1)$

# Feedforward and Backpropagation



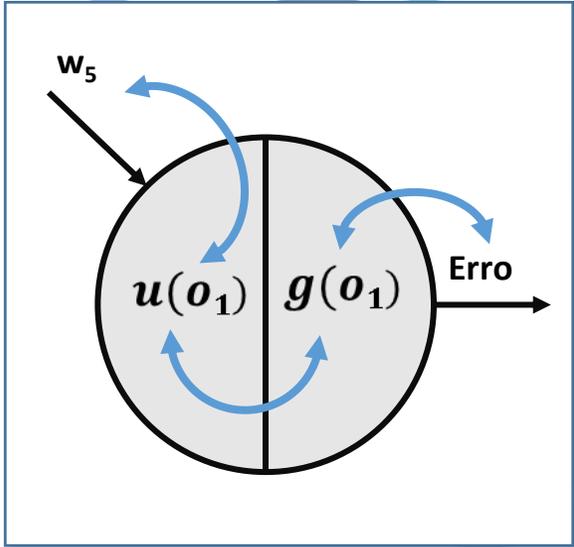
$$E_{total} = \frac{1}{2} \sum_{k=1}^N (\hat{y}_k - y_k)^2 = E_{o1} + E_{o2}$$

# Feedforward and Backpropagation



**Correção de  $w_5$ :**  
Queremos estimar quanto  $w_5$  afeta o Erro total

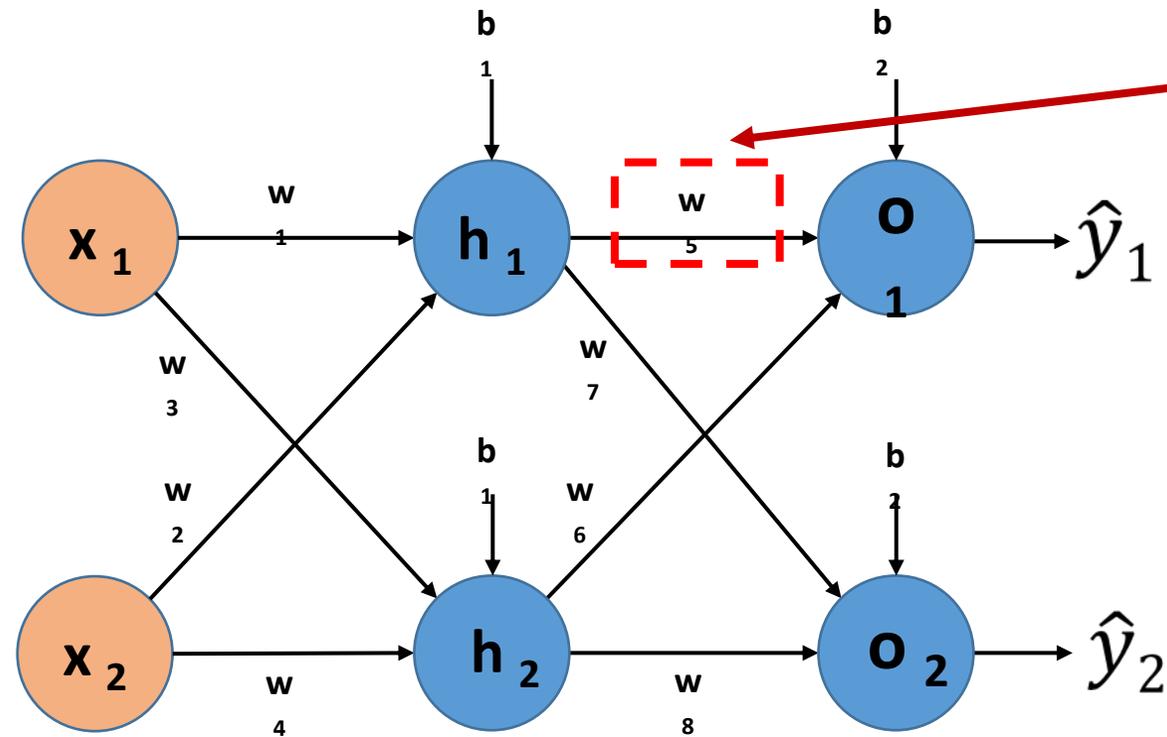
$E_{total}$



$$\frac{\partial E_{total}}{\partial w_5} = \text{gradiente em relação a } w_5$$

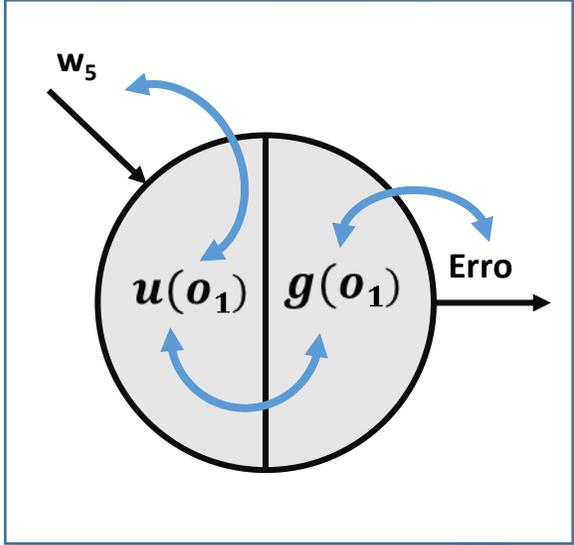
$$\frac{\partial E_{total}}{\partial w_5} = \frac{\partial E_{total}}{\partial g o_1} * \frac{\partial g o_1}{\partial u o_1} * \frac{\partial u o_1}{\partial w_5}$$

# Feedforward and Backpropagation



**Correção de  $w_5$ :**  
Queremos estimar quanto  $w_5$  afeta o Erro total

$E_{total}$

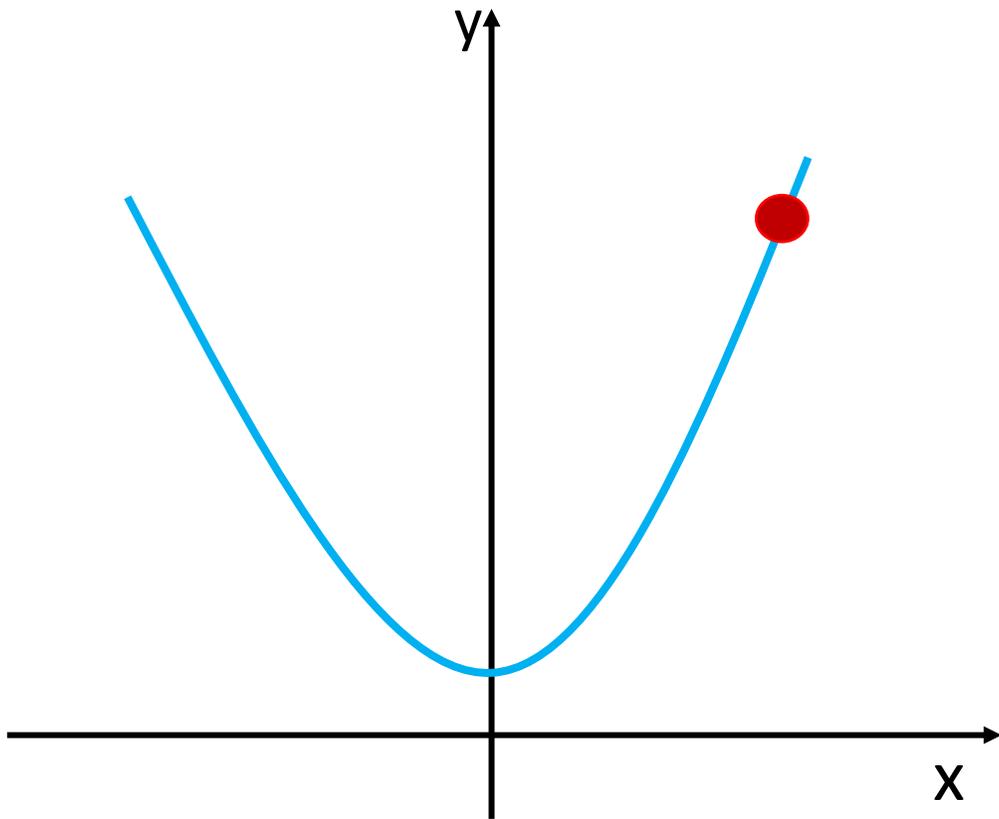


$$w_5^+ = w_5 - \eta * \frac{\partial E_{total}}{\partial w_5} :$$

# Rede Neural Artificial: Otimização

Função quadrática

$$(\hat{y}_i - y_i)^2$$

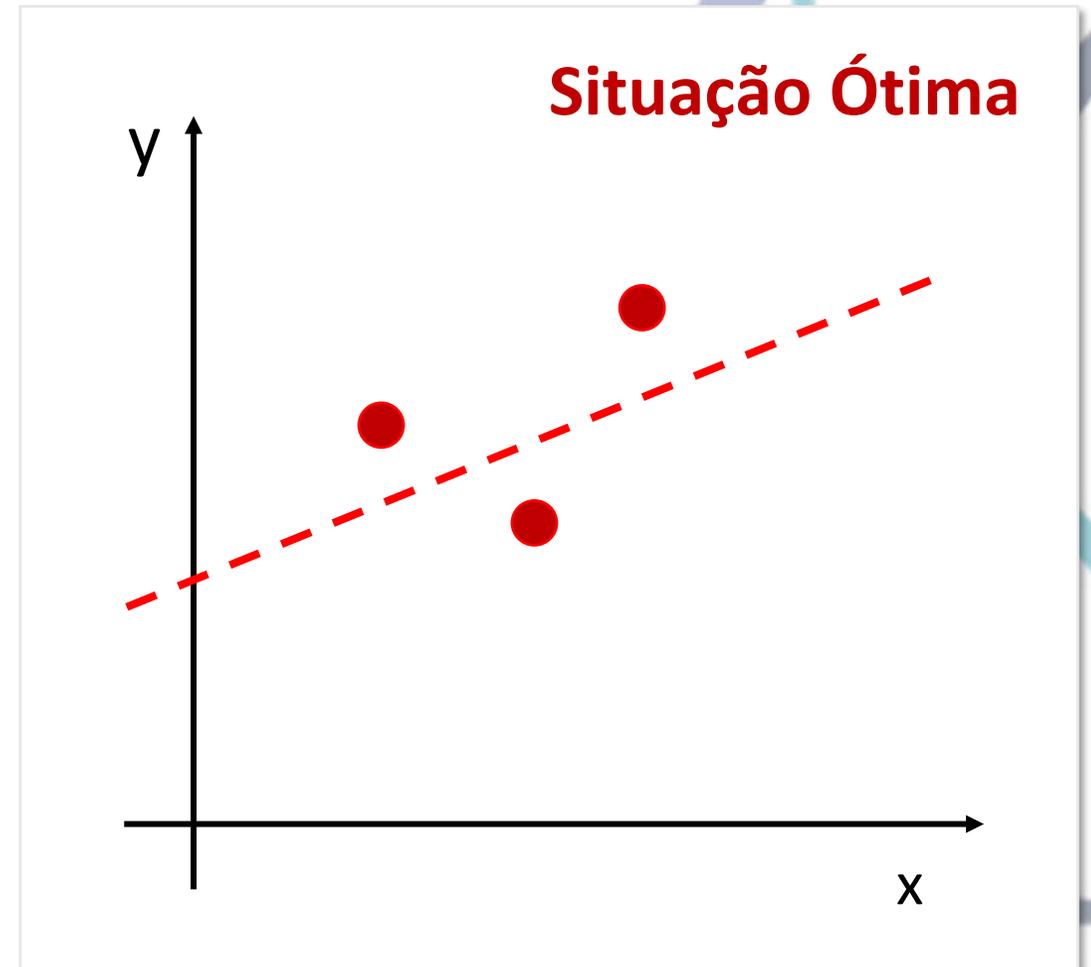
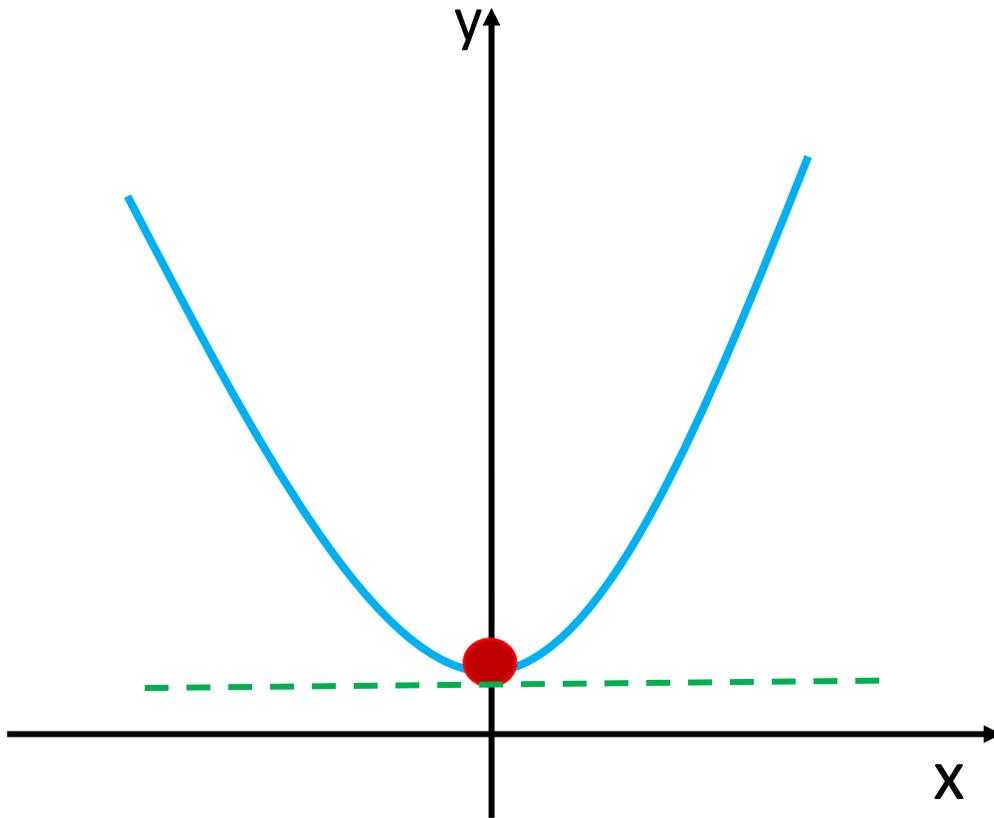




# Rede Neural Artificial: Otimização

Função quadrática

$$(\hat{y}_i - y_i)^2$$



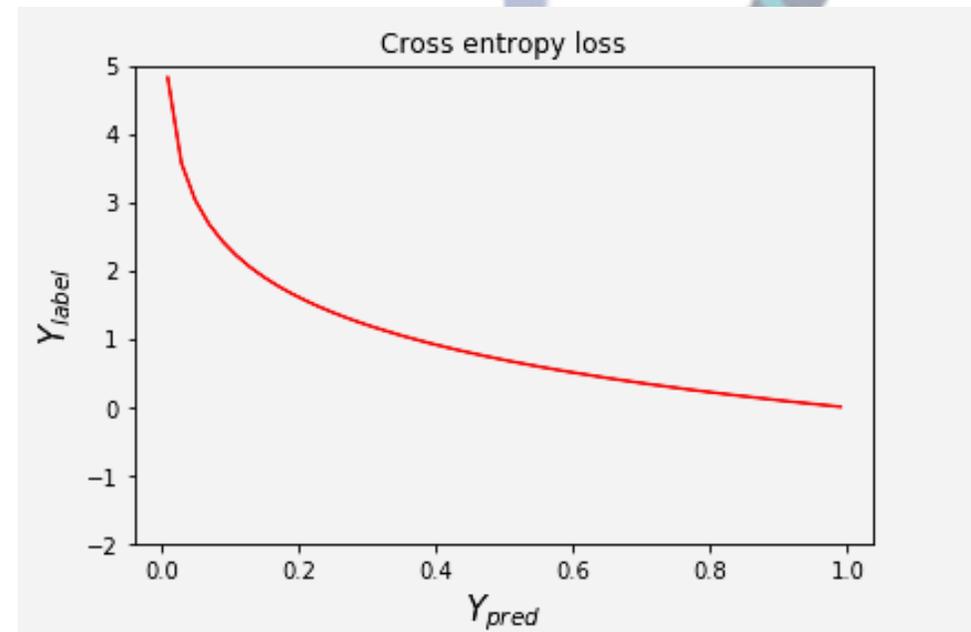
# Loss function (função custo)

Loss functions in Machine Learning serve as ways to measure the distance or difference between a model's predicted output  $Y_{out}$  and the ground truth label  $Y$  in order to train our model effectively

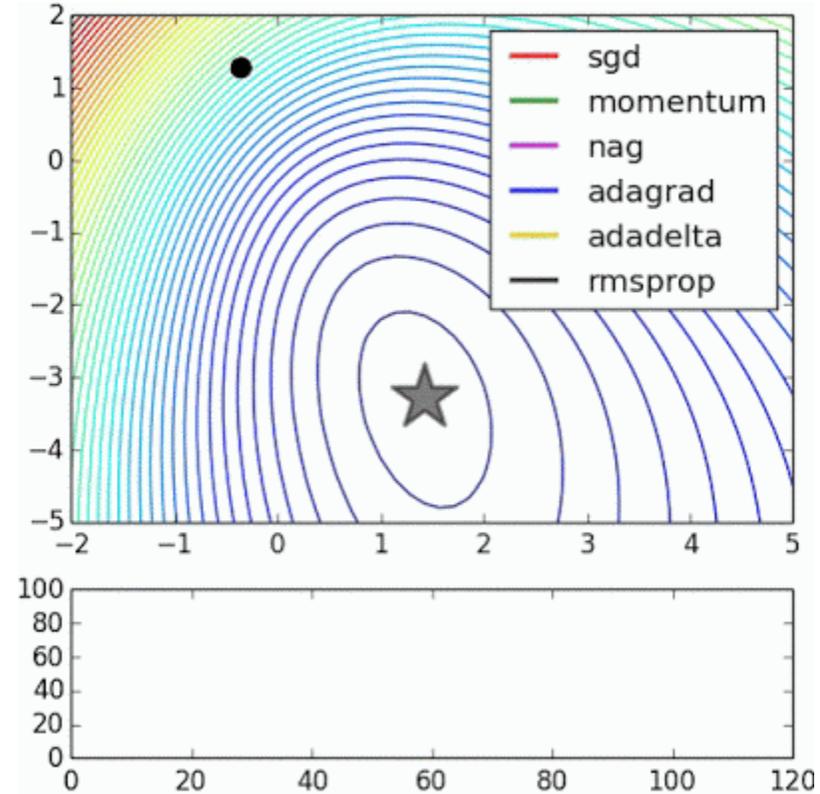
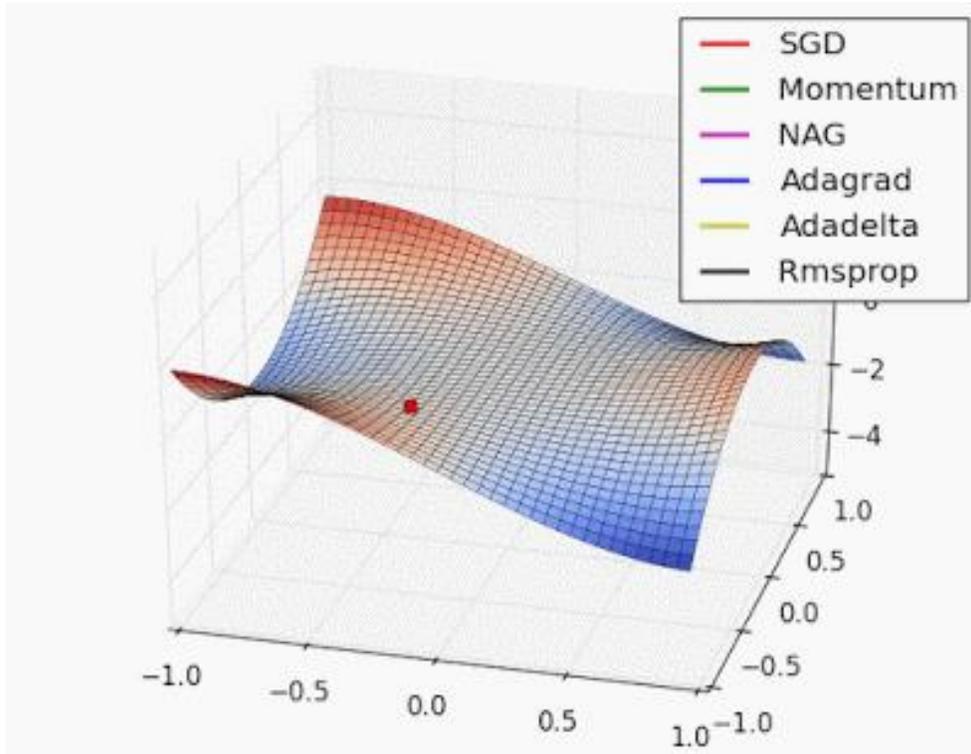
- L2 Norm loss/ Euclidean loss function:  $L2 = (Y_{true} - Y_{pred})^2$

- Cross entropy Loss:

$$H(p, q) = - \sum_i p_i \log q_i = -y \log \hat{y} - (1 - y) \log(1 - \hat{y})$$



# Artificial Neural Network: Optimization Algorithms



**SGD:** Stochastic Gradient Descent

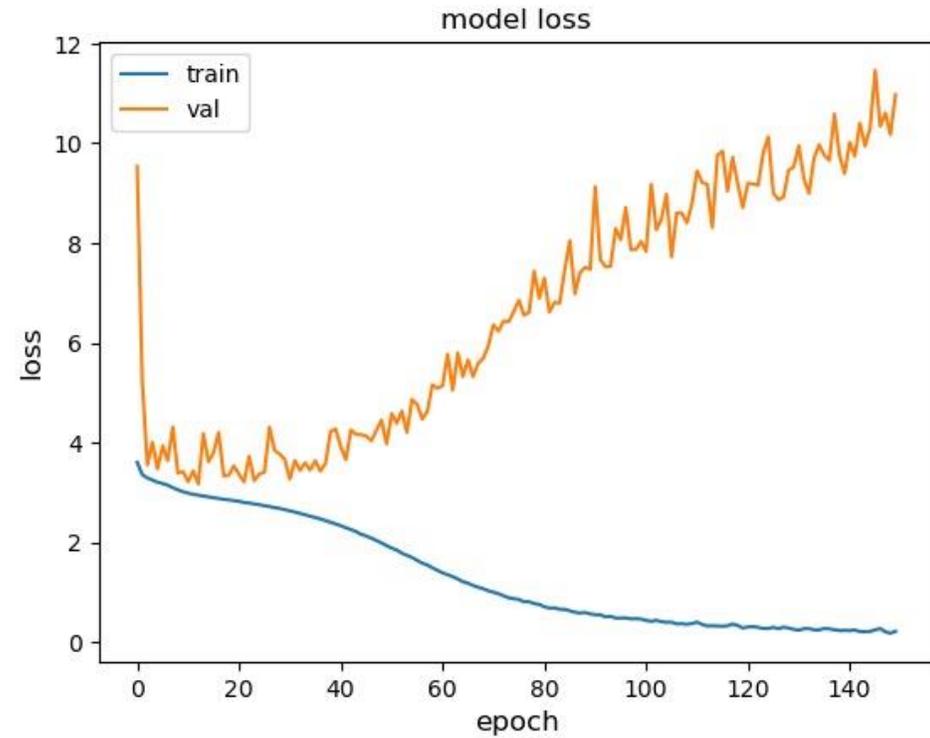
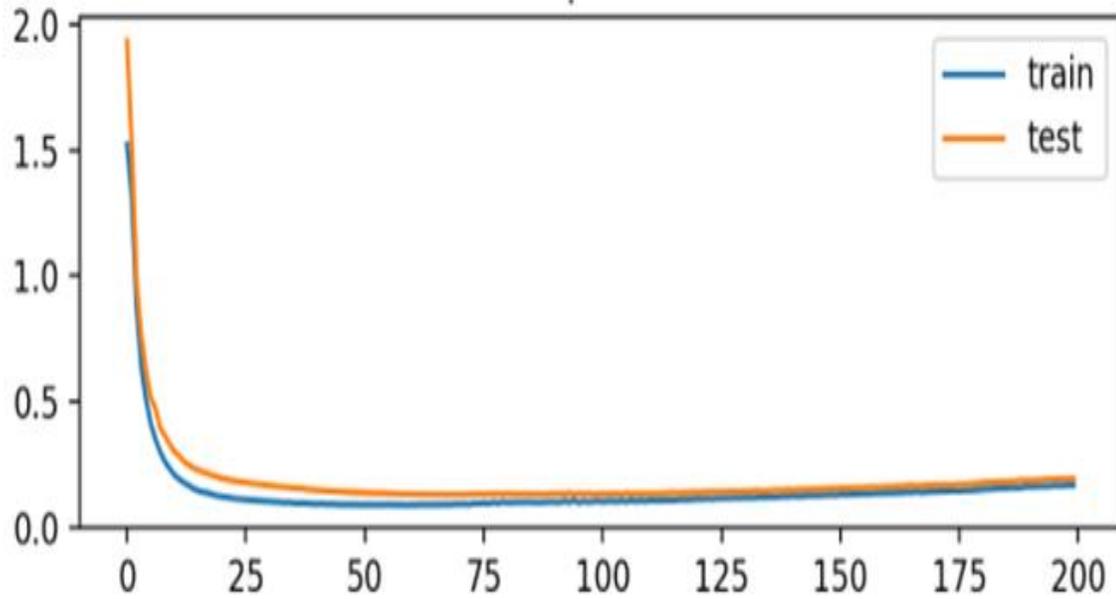
**ADAGRAD:** Adaptive Gradient

**ADADELTA:** Adaptive Learning Rate Method

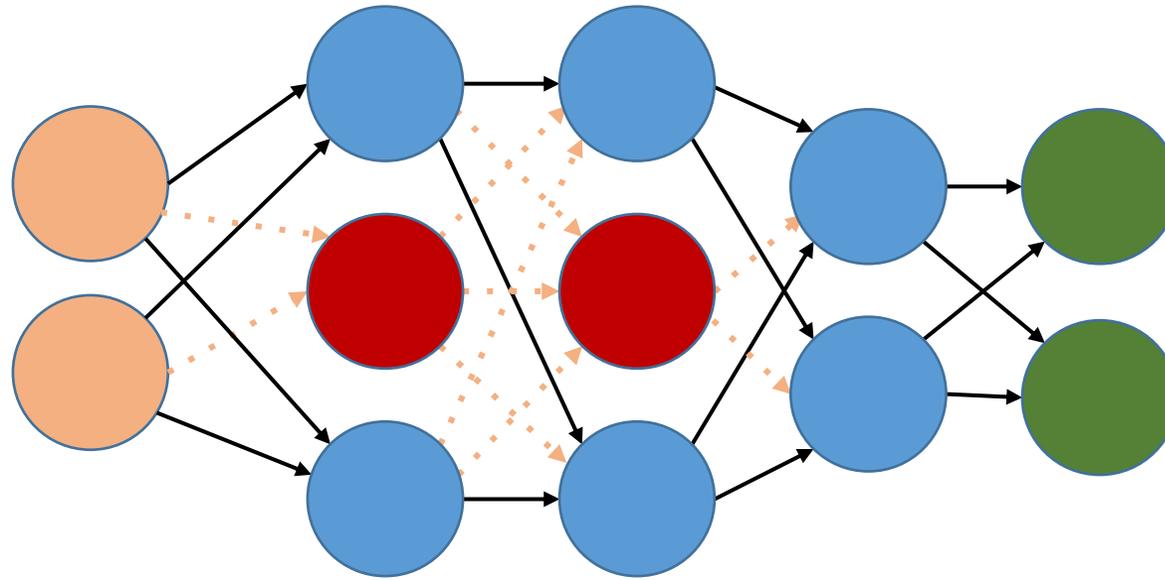
**RMSPROP:** Root Mean Square Propagation

*Gradient depends on the average of the magnitudes of squares of previous gradients.*

# Loss and overfitting

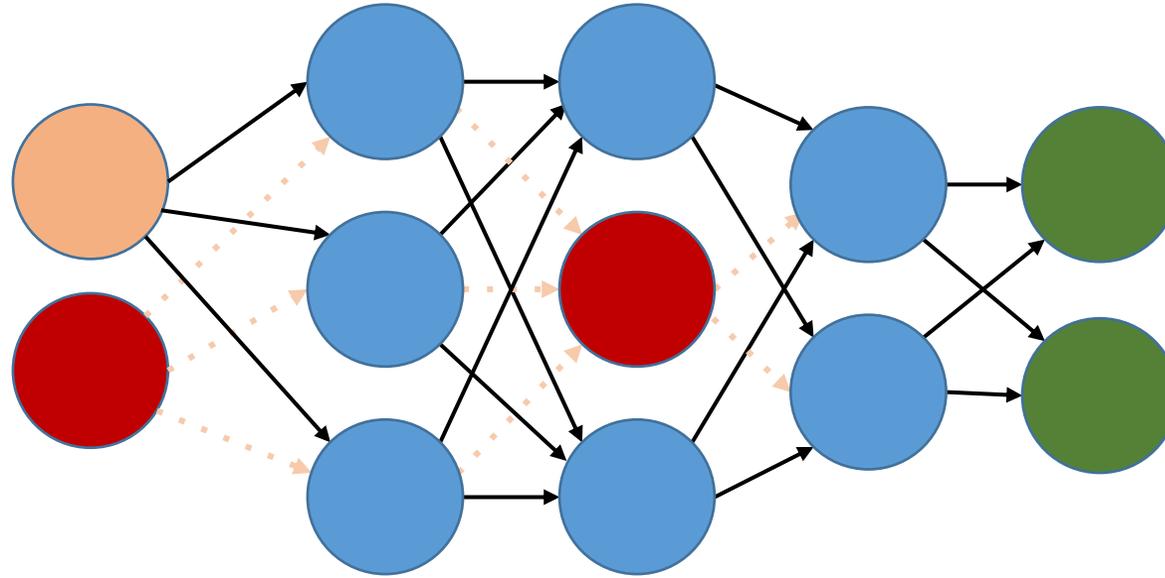


# Artificial Neural Network: DROPOUT



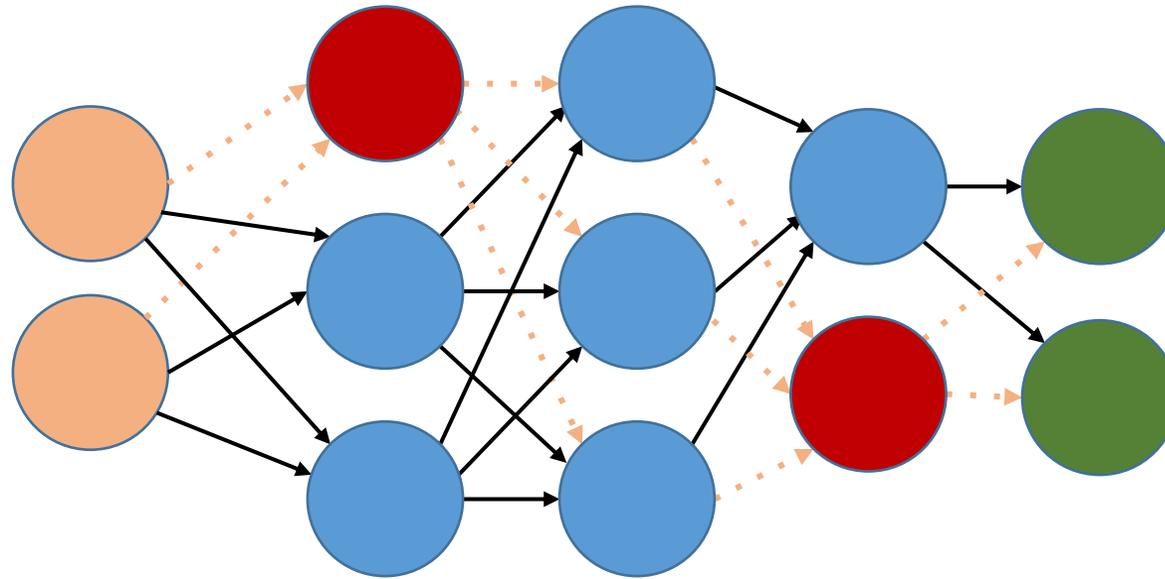
**Dropout** is a technique where randomly selected neurons are ignored during training. They are “dropped-out” randomly.

# Artificial Neural Network: **DROPOUT**



**Dropout** is a technique where randomly selected neurons are ignored during training. They are “dropped-out” randomly.

# Artificial Neural Network: **DROPOUT**

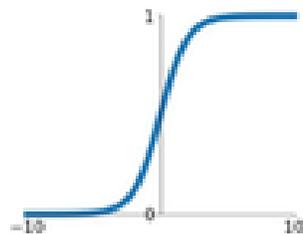


**Dropout** is a technique where randomly selected neurons are ignored during training. They are “dropped-out” randomly.

## Activation Functions

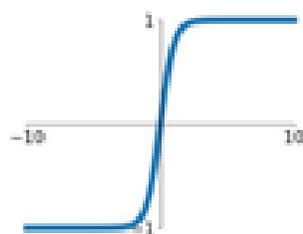
### Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$



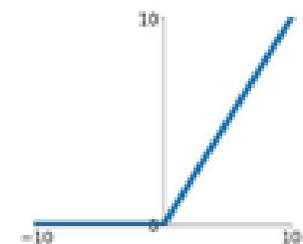
### tanh

$$\tanh(x)$$



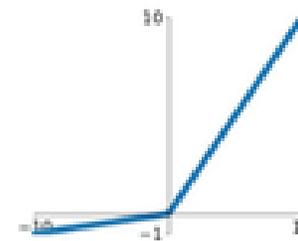
### ReLU

$$\max(0, x)$$



### Leaky ReLU

$$\max(0.1x, x)$$

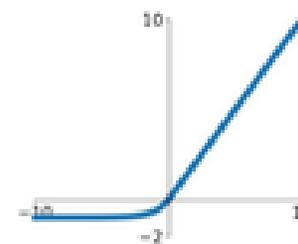


### Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

### ELU

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$



# Ambientes de Desenvolvimento

← → ↻ 🏠 🔒 https://keras.io

**K** Keras Documentation

Search docs

Docs » Home [Edit on GitHub](#)

## Keras: The Python Deep Learning library



# Keras

**You have just found Keras.**

Keras is a high-level neural networks API, written in Python and capable of running on top of **TensorFlow**, **CNTK**, or **Theano**. It was developed with a focus on enabling fast experimentation. *Being able to go from idea to result with the least possible delay is key to doing good research.*

Use Keras if you need a deep learning library that:

- Allows for easy and fast prototyping (through user friendliness, modularity, and extensibility).
- Supports both convolutional networks and recurrent networks, as well as combinations of the two.
- Runs seamlessly on CPU and GPU.

🏠 Home

You have just found Keras.

Guiding principles

Getting started: 30 seconds to Keras

Installation

Configuring your Keras backend

Support

Why this name, Keras?

Why use Keras

GETTING STARTED

Guide to the Sequential model

Guide to the Functional API

FAQ

MODELS

About Keras models

Sequential

Model (functional API)

🏠 GitHub [Next »](#)

Keras is a high-level neural networks API, written in Python and capable of running on top of TensorFlow, CNTK, or Theano.

API - "Application Programming - "Interface" - Interface para Programação de Aplicativos".

Get started with TensorFlow

Learn and use ML ▾

Research and experimentation ▾

ML at production scale ▾

Generative models ▾

Distributed training ▾

Images ▾

Sequences ▾

Get

TensorFlow  
product  
desktop

Learn  
ML

The high  
API pro

TensorFlow Estimators

tf.layers, tf.losses, tf.metrics

Python TensorFlow

C++ TensorFlow

CPU

GPU

TPU

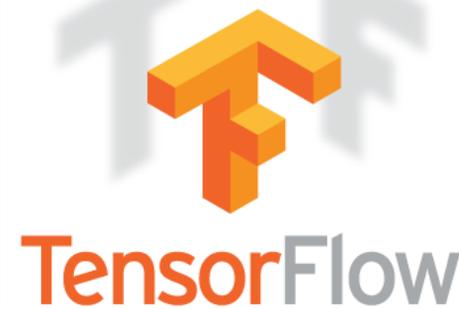
← High-level, object-oriented API

← Reusable libraries for common model components

← Provides Ops, which wrap C++ Kernels

← Kernels work on one or more platforms

Figure 1. TensorFlow toolkit hierarchy.



is a  
nal  
for

# Neural network terminology

**one epoch:** one forward pass and one backward pass of all the training examples

**batch:** the number of training examples in one forward/backward pass. The higher the batch size, the more memory space you'll need.

**number of iterations:** number of passes, each pass using [batch size] number of examples. To be clear, one pass = one forward pass + one backward pass (we do not count the forward pass and backward pass as two different passes).

**Example: if you have 1000 training examples, and your batch size is 500, then it will take 2 iterations to complete 1 epoch.**

## TensorFlow Core

Visão geral

**Tutorials**

Guide

TF 2.0 Beta

Get started with TensorFlow

Learn and use ML ▾

Research and experimentation ▾

ML at production scale ▾

Generative models ▾

Distributed training ▾

Images ▾

Sequences ▾

Get

TensorFlow  
product  
desktop

Learn  
ML

The high  
API pro

TensorFlow Estimators

tf.layers, tf.losses, tf.metrics

Python TensorFlow

C++ TensorFlow

CPU

GPU

TPU

← High-level, object-oriented API

← Reusable libraries for common model components

← Provides Ops, which wrap C++ Kernels

← Kernels work on one or more platforms

Figure 1. TensorFlow toolkit hierarchy.



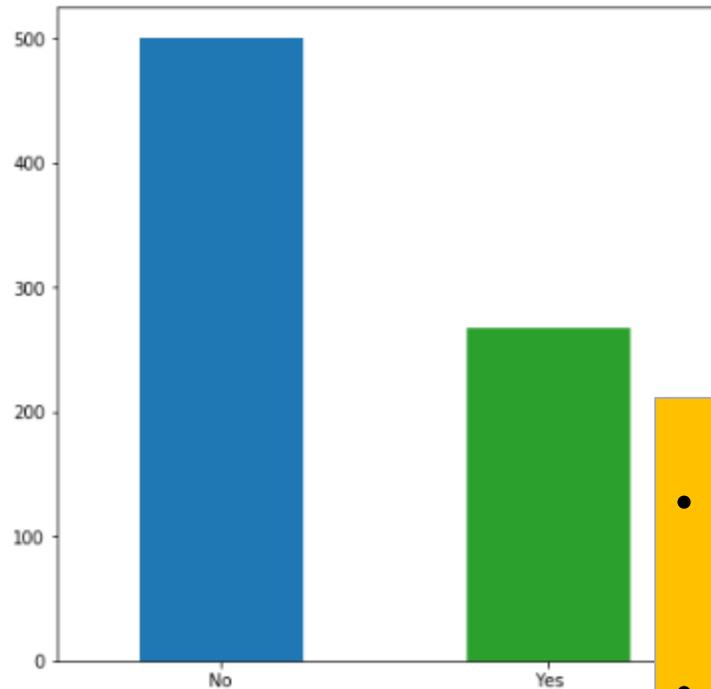
is a  
nal  
for

# EXEMPLO 1

CLASSIFI  
REDE NE  
LAYER

Data Visualization

Diabetes?



768

age	diabetes
50	1
31	0
32	1
21	0
33	1
30	0
26	1
29	0
53	1
54	1

1	6,148,72,35,0,33.6,0.627,50,1
2	1,85,66,29,0,26.6,0.351,31,0
3	8,183,64,0,0,23.3,0.672,32,1
4	1,89,66,23,94,28.1,0.167,21,0
5	0,137,40,35,168,43.1,2.288,33,1
6	5,116,74,0,0,25.6,0.201,30,0
7	3,78,50,32,88,31.0,0.248,26,1

- As 10 ultimas linhas foram separadas para o grupo de teste
- As 758 linhas restantes serão divididas em grupo de treinamento, validação

11	138	76
9	102	76
2	90	68

17	0,118,84,47,230,45.8,0.551,31,1
----	---------------------------------

CSV file

Importa Bibliotecas

Leitura dos Dados

Ajustes dos Dados

→ Separa Dados de Treinamento (80% - 606) e Validação (20% - 152)

Definição

Compilação

Treino

Plota a evolução

Função

Apresentação

## Grupo de

### Teste

pregnancies	glucose	diastolic	triceps	insulin	bmi	dpf	age	diabetes
1	106	76	0	0	37.5	0.197	26	0
6	190	92	0	0	35.5	0.278	66	1
2	88	58	26	16	28.4	0.766	22	0
9	170	74	31	0	44.0	0.403	43	1
9	89	62	0	0	22.5	0.142	33	0
10	101	76	48	180	32.9	0.171	63	0
2	122	70	27	0	36.8	0.340	27	0
5	121	72	23	112	26.2	0.245	30	0
1	126	60	0	0	30.1	0.349	47	1
1	93	70	31	0	30.4	0.315	23	0

Dropout de 50%

- Camada de Saída: 1 neurônio



Untitled0.ipynb ☆

File Edit View Insert Runtime Tools Help

+ CODE + TEXT



Google Drive

COMMENT

SHARE



RAM  Disk

EDITING

```
[1] from google.colab import drive
drive.mount('/content/gdrive')
```

Go to this URL in a browser: [https://accounts.google.com/o/oauth2/auth?client\\_id=947318989803-6bn6qk8qdgf4n4g3pfee6491hc0brc4i.apps.googleusercontent.com](https://accounts.google.com/o/oauth2/auth?client_id=947318989803-6bn6qk8qdgf4n4g3pfee6491hc0brc4i.apps.googleusercontent.com)

Enter your authorization code:  
.....  
Mounted at /content/gdrive



```
[2] ls -la
```

```
total 20
drwxr-xr-x 1 root root 4096 Jul 18 20:19 ./
drwxr-xr-x 1 root root 4096 Jul 18 20:08 ../
drwxr-xr-x 1 root root 4096 Jul 11 16:05 .config/
drwx----- 3 root root 4096 Jul 18 20:19 gdrive/
drwxr-xr-x 1 root root 4096 Jul  3 16:14 sample_data/
```

```
[3] cd gdrive
```

```
/content/gdrive
```

Código de autorização

```
from google.colab import drive
drive.mount('/content/gdrive')
```

# EXEMPLO 2

## RECONHECIMENTO DE CARACTERES MANUSCRITOS

### REDE NEURAL MULTI- LAYER

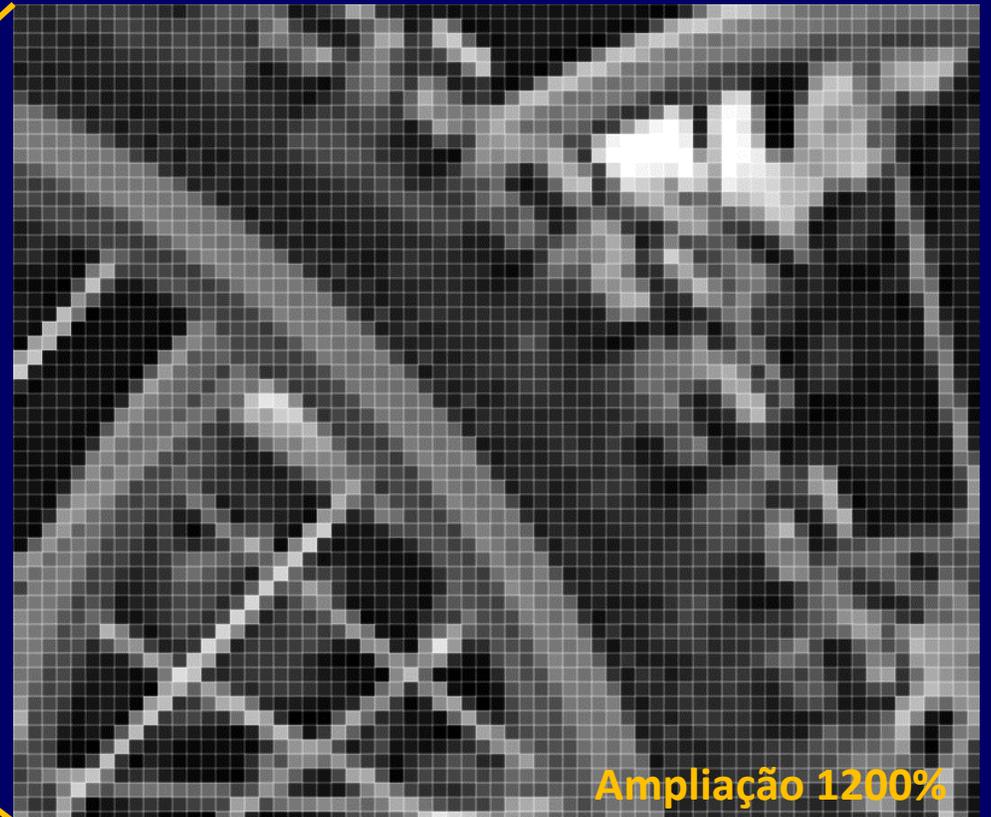


# Sobre Imagem Digital

- Imagem é um  **sinal digital (2D)** de suporte a informação (Teoria dos Sinais)
- Uma imagem digital é uma função discreta de posição (2D ou 3D, tempo e banda espectral) e níveis de cinza. Cada  **coordenada** da imagem contém uma informação de  **luminância** (ou crominância).



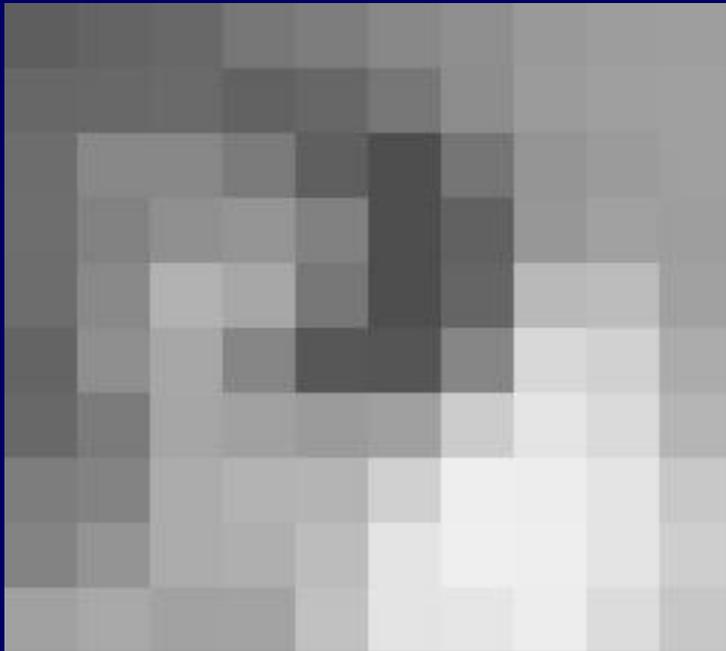
Imagem digital (KODAK – Free)



Ampliação 1200%

# Sobre Imagem Digital

Uma imagem digital pode ser vista como uma **matriz** de **níveis de cinza**, ou valores de intensidade luminosa.



**Ampliação**

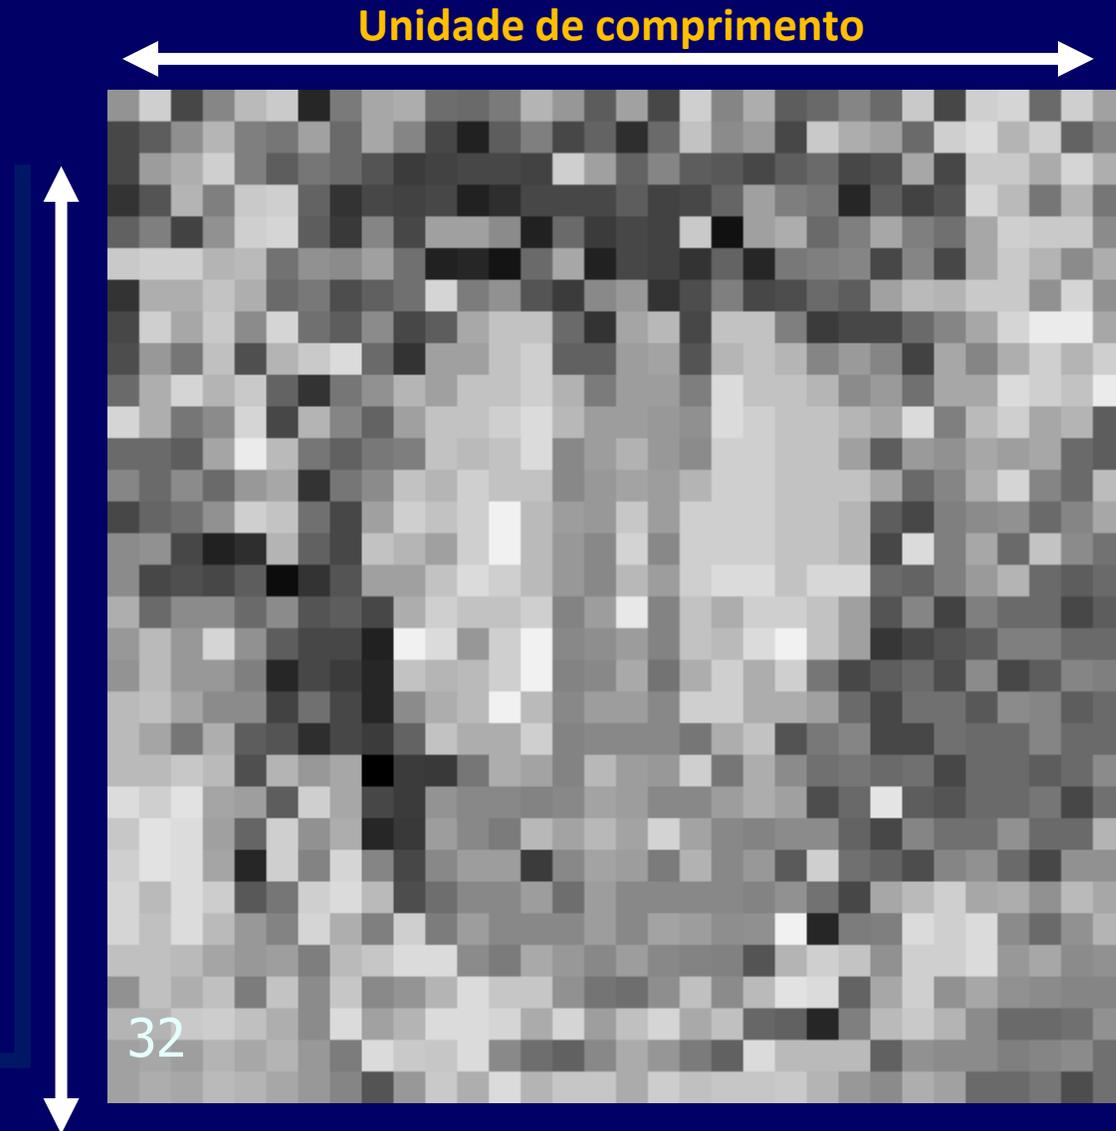


94	100	104	119	125	136	143	153	157	158
103	104	106	98	103	119	141	155	159	160
109	136	136	123	95	78	117	149	155	160
110	130	144	149	129	78	97	151	161	158
109	137	178	167	119	78	101	185	188	161
100	143	167	134	87	85	134	216	209	172
104	123	166	161	155	160	205	229	218	181
125	131	172	179	180	208	238	237	228	200
131	148	172	175	188	228	239	238	228	206
161	169	162	163	193	228	230	237	220	199

**Valores de intensidade luminosa (8 bits)**  
**Níveis de Cinza**

## Resolução da Imagem

- ❑ **DPI – “dots per inch”**
  - Scanners (variável)
- **Número de pixels**
  - Vídeo (fixo)
- **Exemplo simples**
  - Foto de 5x5 cm – 2x2 in.
  - Resolução: 300 dpi
  - Tamanho: 600x600 pixels
  - **Filme Fotográfico: 5000x5000 dpi**



Importa Bibliotecas

Leitura das Imagens

Normalização das Imagens

Definição da RNA

Compila o Modelo

Treina (FIT) a RNA

Print Precisão da Rede

Reconhecimento

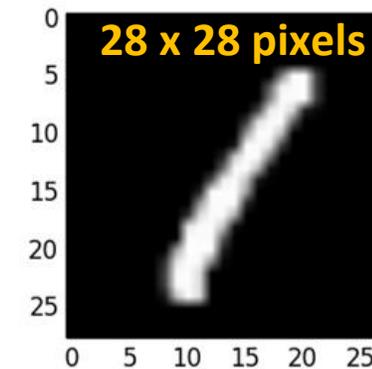
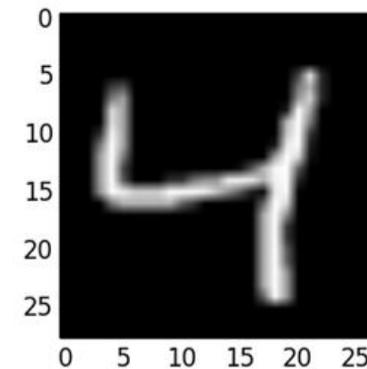
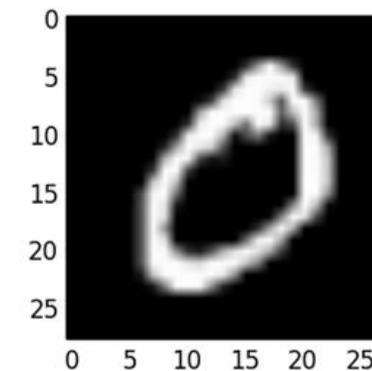
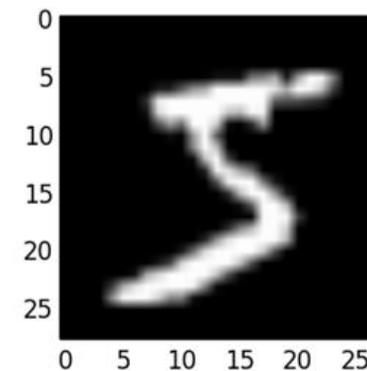
Treinamento (60000)  
Validação/Teste (10000)

Níveis de Cinza [0, 1.0]

Define as propriedades de cada camada

Apresenta o resumo do Modelo

Epoch, Batch, Dados de  
Treinamento e  
Validação



## DEFINIÇÃO DA RNA

- 1ª Camada: 784 neurônios
- 2ª Camada: 392 neurônios
- 3ª Camada: 196 neurônios
- Saída: 10 neurônios

```
model = Sequential()  
model.add(Flatten(input_shape=(28,28)))  
model.add(Dense(392, activation='relu'))  
model.add(Dense(196, activation = 'relu'))  
model.add(Dense(10, activation='softmax'))
```

# The simplest example I know

```
from tensorflow.keras import models
from tensorflow.keras.models import Sequential
from tensorflow.keras import layers
from tensorflow.keras.layers import Convolution2D
from tensorflow.keras.layers import MaxPooling2D
from tensorflow.keras.layers import Dense, Dropout, Flatten, Activation

model = Sequential()
model.add(Flatten(input_shape=(28,28)))
model.add(Dense(392, activation='relu'))
model.add(Dense(196, activation = 'relu'))
model.add(Dense(10, activation='softmax'))

model.add(Dense(num_classes, activation='softmax'))
```

# The simplest example I know

```
batch_size = 128
num_classes = 10
epochs = 10

# input image dimensions
img_x, img_y = 28, 28

# load the MNIST data set, which already splits into train and test sets
for us
(x_train, y_train), (x_test, y_test) = mnist.load_data()

model.fit(x_train, y_train,
          batch_size=batch_size,
          epochs=epochs,
          verbose=1,
          validation_data=(x_test, y_test),
          callbacks=[history])
score = model.evaluate(x_test, y_test, verbose=0)
```

# If you want to know more...

Você poderá encontrar os exemplos e os datasets da aula no website do curso e também no meu website incluindo recursos adicionais.

Prof. Clécio R. Bom

[Home](#) / [Info](#) / [Teaching – Ensino](#) / [Press – Imprensa & Divulgação Científica](#) / [Deep Learning Minicourse](#) / [Scripts and Models](#) / [Contact](#)

## Clear nights are the Best!

[Português](#) | [English](#) | [Italiano](#)

This is a space to discuss science: Artificial Intelligence (Deep Learning), Astrophysics, Astrostatistics and Petrophysics, interactions between Industry and Academia, promote scientific research and supporting material for classes.

If you would like to know more about the search of Gravitational waves counterparts from the DESGW group check this nice outreach article : <https://www.darkenergysurvey.org/darchive/searching-for-sources-of-gravitational-waves/>

If you would like to know more about Artificial Intelligence and sciences cases from industry to Cosmos (portuguese only)

Live: Inteligência Artificial do Cosmos à Industria (youtube)

PESQUISAR



QUICK INFO

Clécio R. De Bom, PhD  
*Research, Development & Innovation*

[Google Scholar](#)  
[Lattes CV](#)   
[Linkedin](#)  
[github.com/cdebom/](https://github.com/cdebom/)  
[Colab examples](#)  
[Deep Learning Lab](#)  
[ORCID](#)



# Inteligência artificial e aplicações em física

*Clécio Roque De Bom – [debom@cbpf.br](mailto:debom@cbpf.br)*



*[clearnightsrthebest.com](http://clearnightsrthebest.com)*



**Elisangela L. Faria**  
(CBPF)

