

From Natural Computing to Deep Learning

Tópicos Avançados II

Aula 2

Augusto Uchôa

Petran- Programa de Pós-graduação em
Engenharia de Transportes

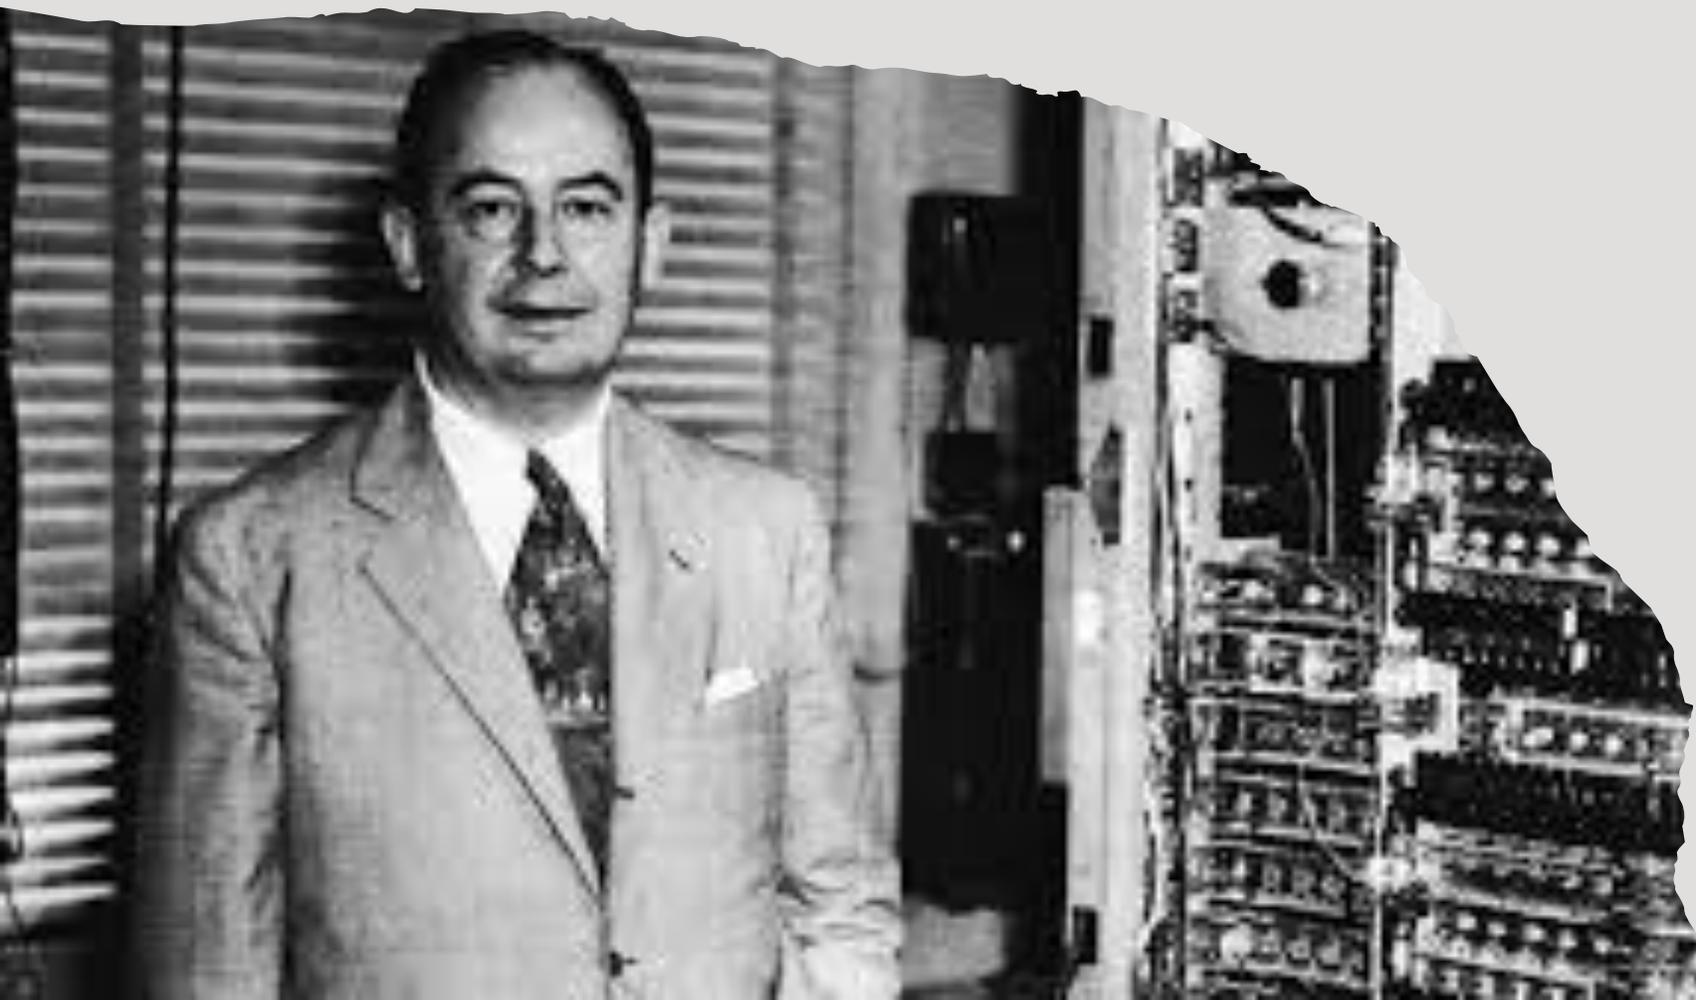


TRILHA DE HOJE:

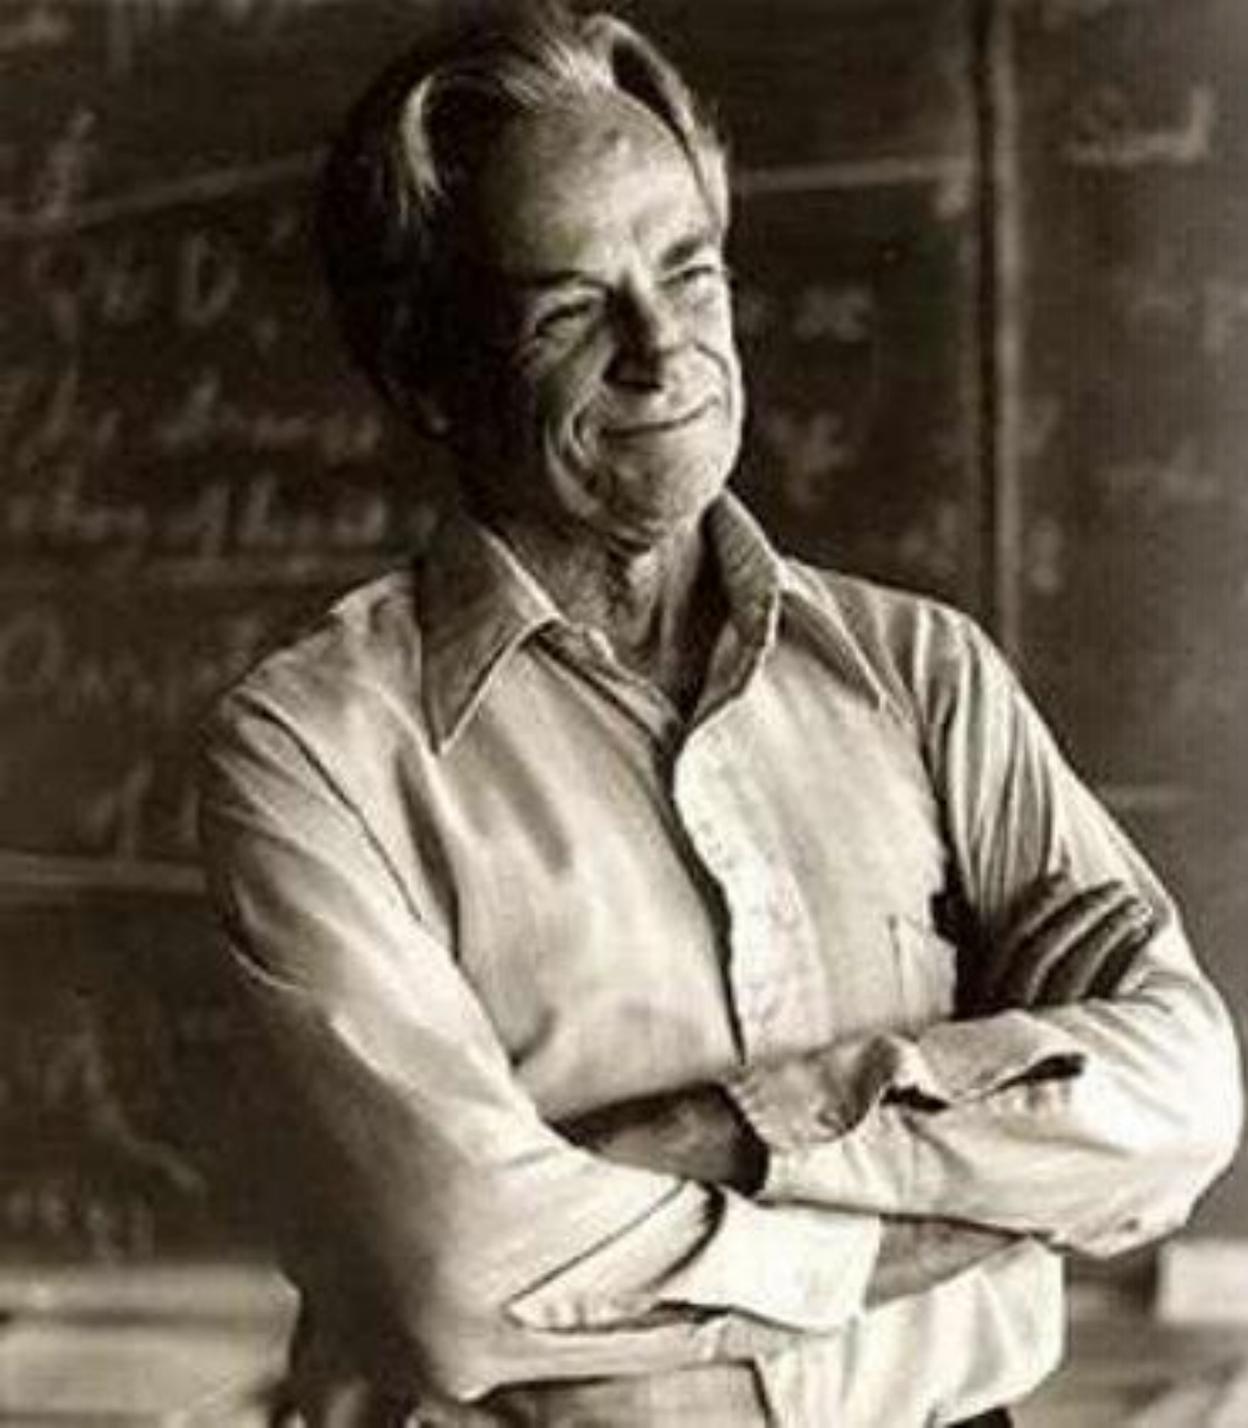
- **CONHECER** o histórico, a interrelação entre NC, AI, ML, NN e DL;
- **COMPREENDER** as principais técnicas de Machine learning e,
- **IDENTIFICAR** onde Redes Neurais Artificiais se posicionam como técnica de modelagem



COMPUTAÇÃO NATURAL NA ORIGEM



Uma possível origem do conceito de computação natural pode ser atribuída ao matemático húngaro de origem judaica, naturalizado estadunidense **John von Neumann**, que em **1956** publicou um livro chamado “**The Theory of Self-Reproducing Automata**”, onde explorou a ideia de máquinas que poderiam se replicar e evoluir, inspirado pelos processos biológicos.



COMPUTAÇÃO QUÂNTICA

O físico americano **Richard Feynman**, que em **1982** p contribuiu para a definição de compuração natural, quando propôs o conceito de computação quântica, baseado nas propriedades da mecânica quântica

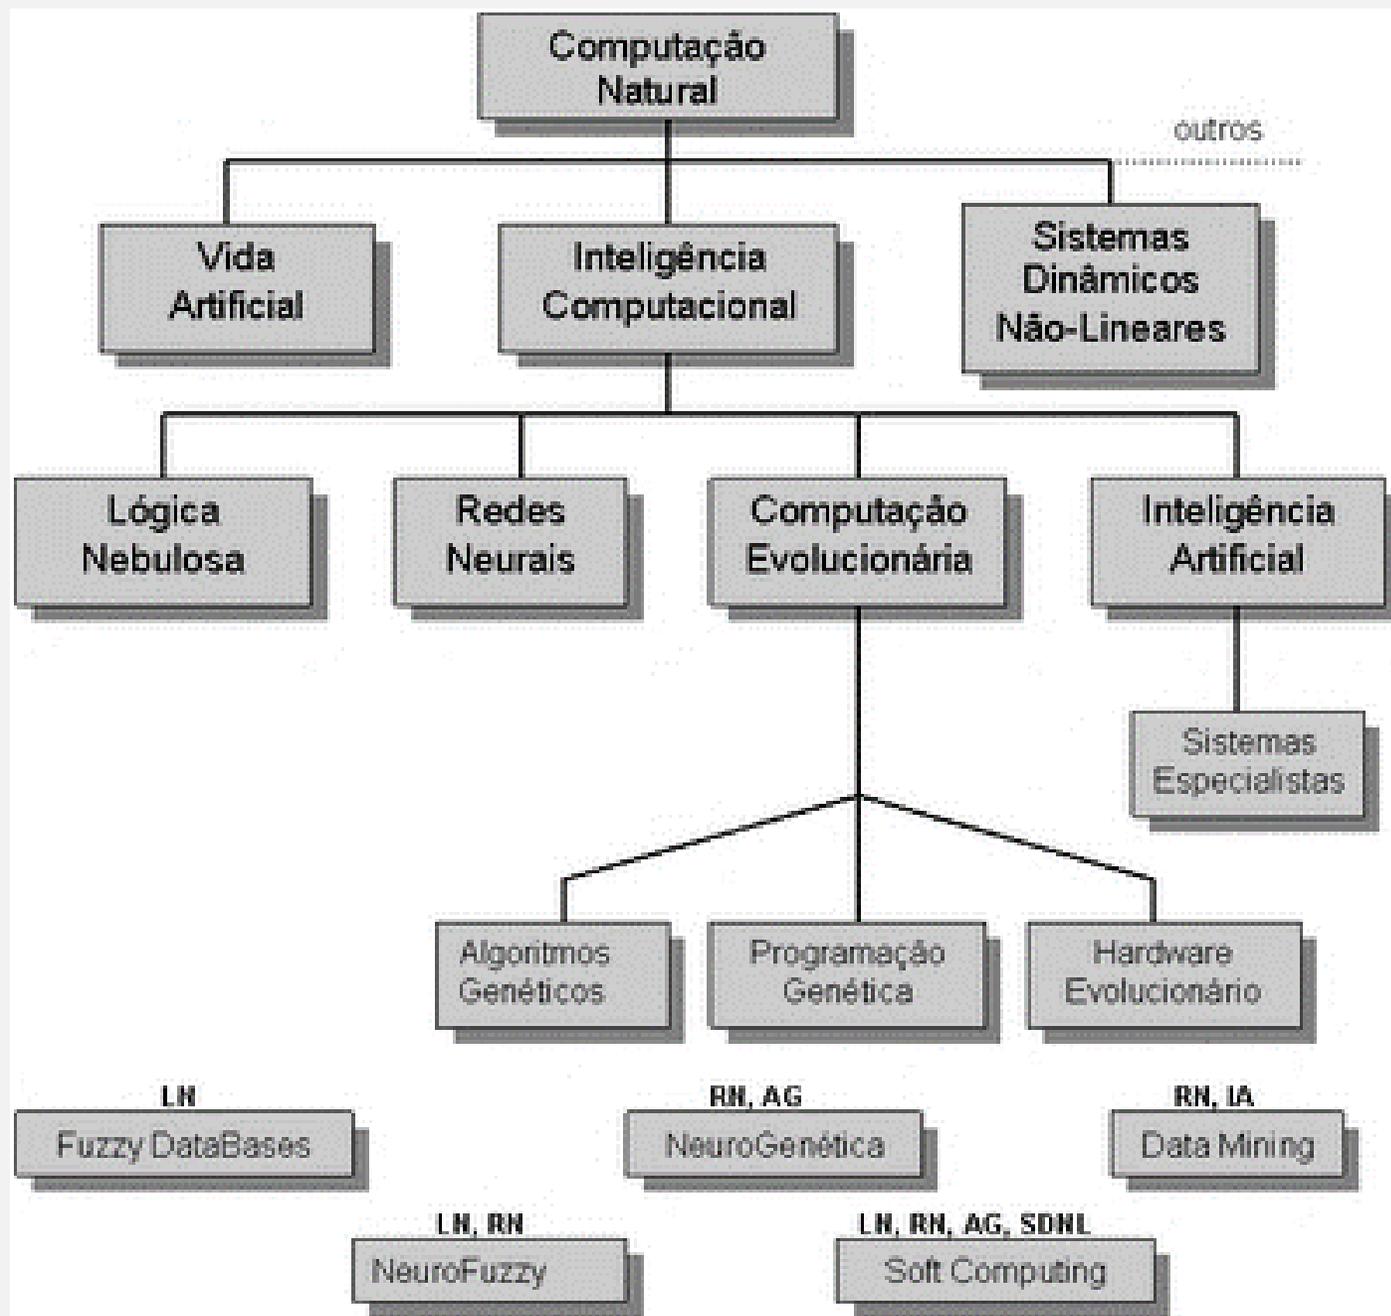
COMPUTAÇÃO NATURAL HOJE

“É o estudo de sistemas computacionais que usam ideias e obter inspiração a partir de sistemas naturais, incluindo processos biológicos, físicos e químicos “

Susan Stepney,
Universidade de York, no
Reino Unido, 2008.



NOS ANOS 2000

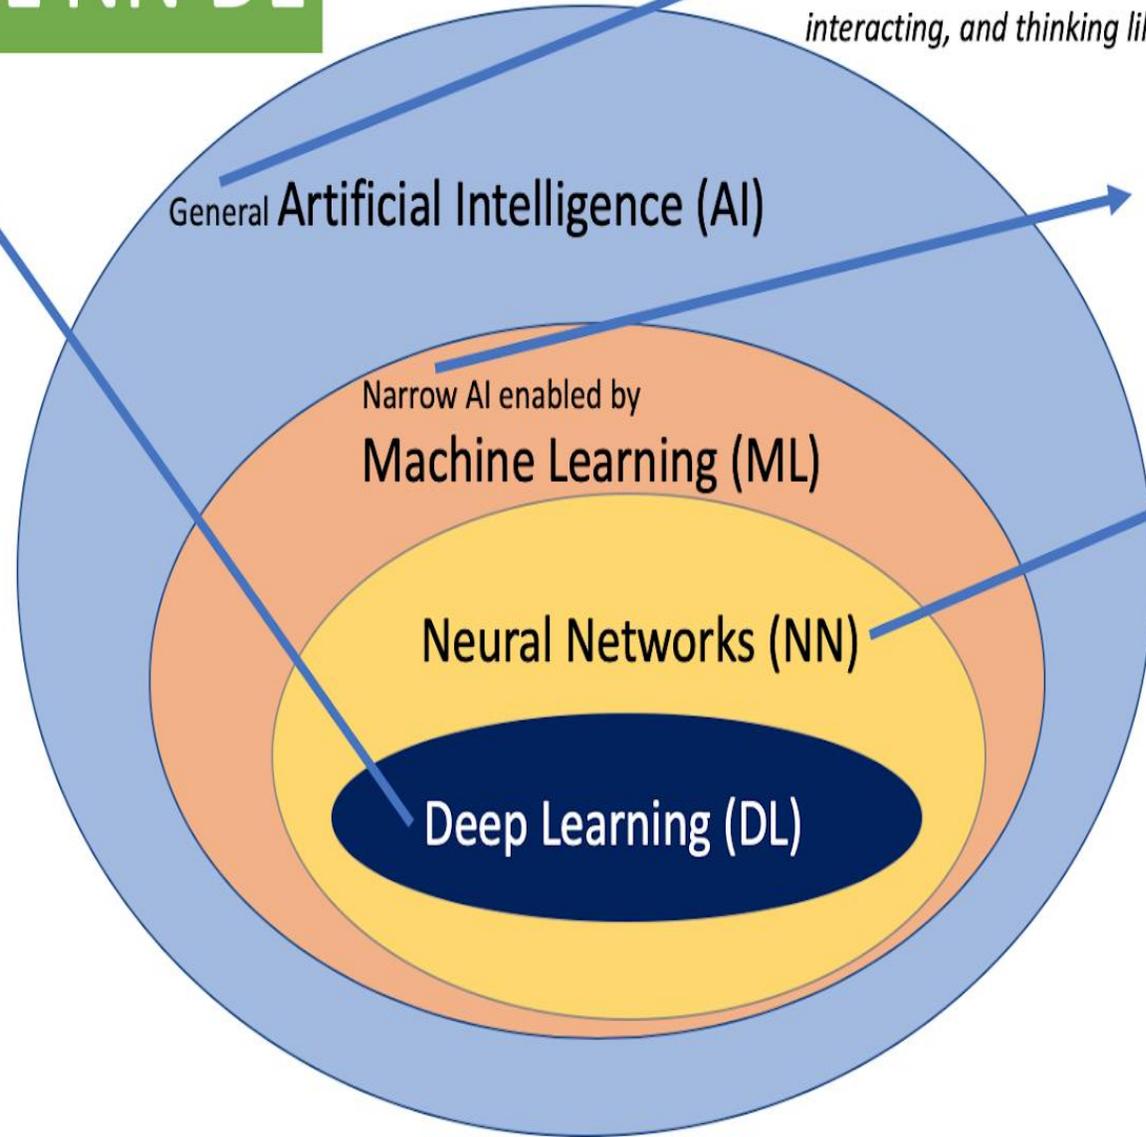


MAS EM 2023



AI ML NN DL

the word "deep" comes from the fact that DL algorithms are trained/run on deep neural networks. These are just neural networks with (usually) three or more "hidden" layers



computers possessing the same characteristics of human intelligence, including reasoning, interacting, and thinking like we do

technologies that can accomplish specific tasks such as playing chess, recommending your next Netflix TV show, and identifying spam emails

neural networks are a specific group of algorithms used for machine learning that model data using graphs of Artificial Neurons. Those neurons are a mathematical model that "mimics approximately how a neuron in the brain works"

IA E A QUEBRA DE PARADIGMAS

O que faremos para transformar essa “tendência” em algo concreto, usando o que dispomos?

“Todo progresso, evolução, mudança é fator de desestabilização ao mesmo tempo que é caminho para novos pontos de equilíbrio.”

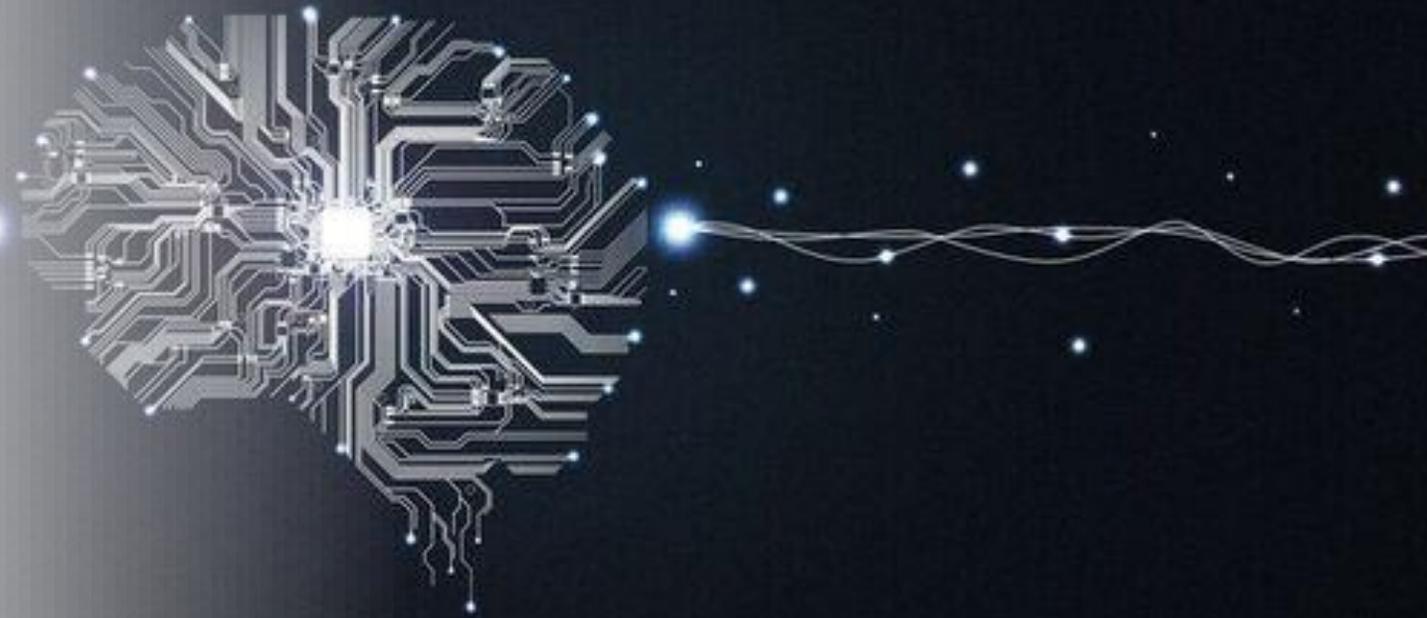
Leroi-Gourhan

A METÁFORA DA INTELIGÊNCIA ARTIFICIAL

O fato concreto é que **pouco entendemos a inteligência humana**, na qual ela se inspira. Assim, como poderíamos entender e construir uma, ou várias “inteligências artificiais”?

O termo “**inteligência artificial**” é **apenas uma figura de linguagem**, são apenas técnicas computacionais que, via de regra, apresentam maior eficiência em processos de estimação, classificação e até regressão para fenômenos dos quais se **dispõe dados (muitos)** para representá-los

Professor e se eu tiver um banco de dados pequeno? Tô no lugar errado?



A INTELIGÊNCIA HUMANA NÃO AINDA É COMPUTÁVEL

Se traduzida em números, a inteligência natural torna-se **impossível** de ser decidida por uma **máquina finita**

computação quântica resolverá o problema? NÃO. Ela será mais rápida com certeza, mas os qubits estão apenas criando uma ilusão de estados superpostos, ainda seguem o mesmo princípio de máquina finita. E qual a solução então? Sei lá, mas ela virá e logo

Não sabemos nem o que é, nem onde está a consciência, nem a inteligência humanas, se desconhecemos, não podemos simula-la nem reproduzi-la

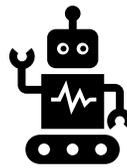


86 bilhões de
neurônios, trilhões
de conexões

“INTELIGÊNCIA ARTIFICIAL”

A computação desenvolveu **técnicas, algoritmos e dispositivos** tecnológicos que já mostram significativos **resultados em interpretar e sintetizar a voz, “visão computacional”** ou movimentos humanos e processamento de linguagem.

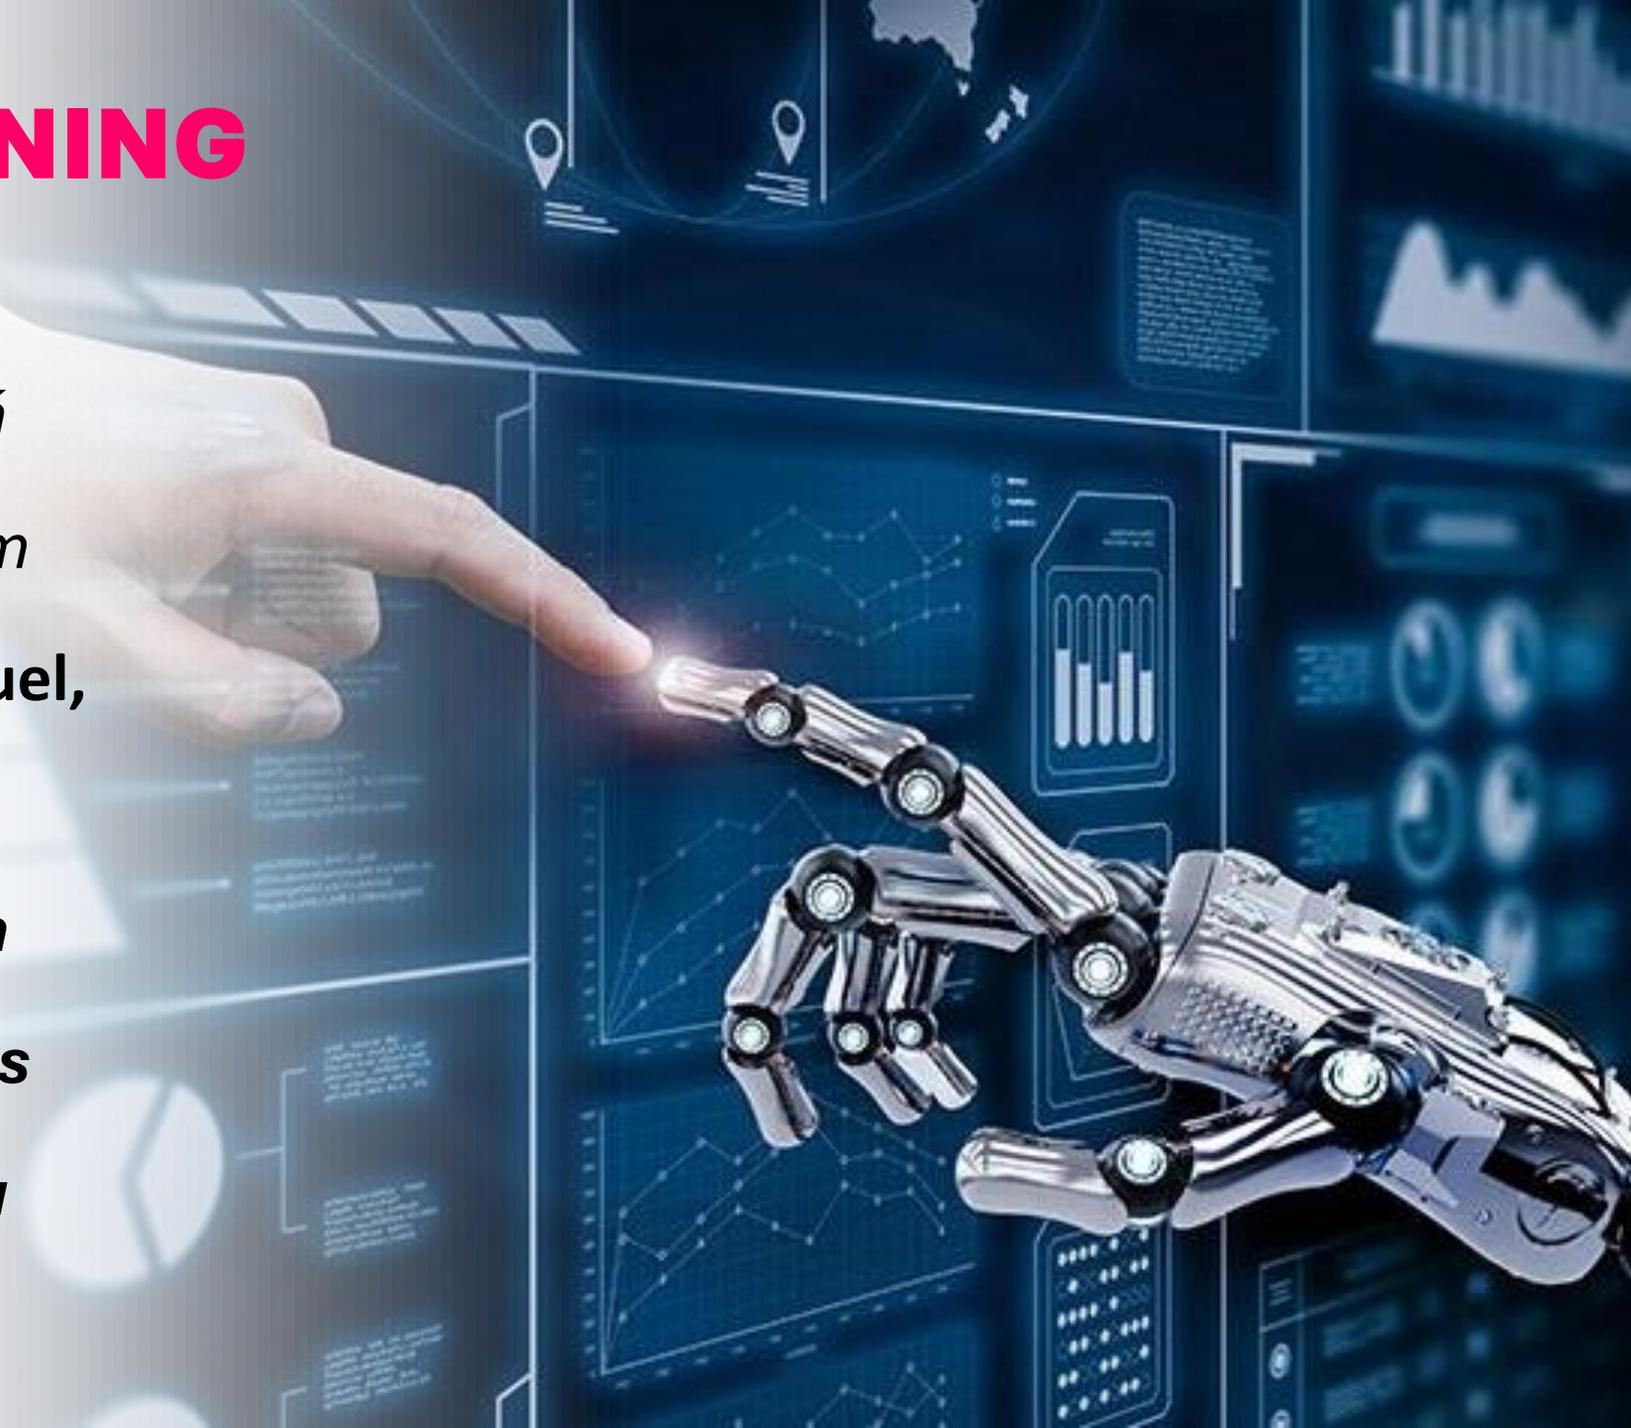
Mas, ainda **falta muito para que máquinas atinjam o conceito mais próximo possível do que seria a inteligência humana.**



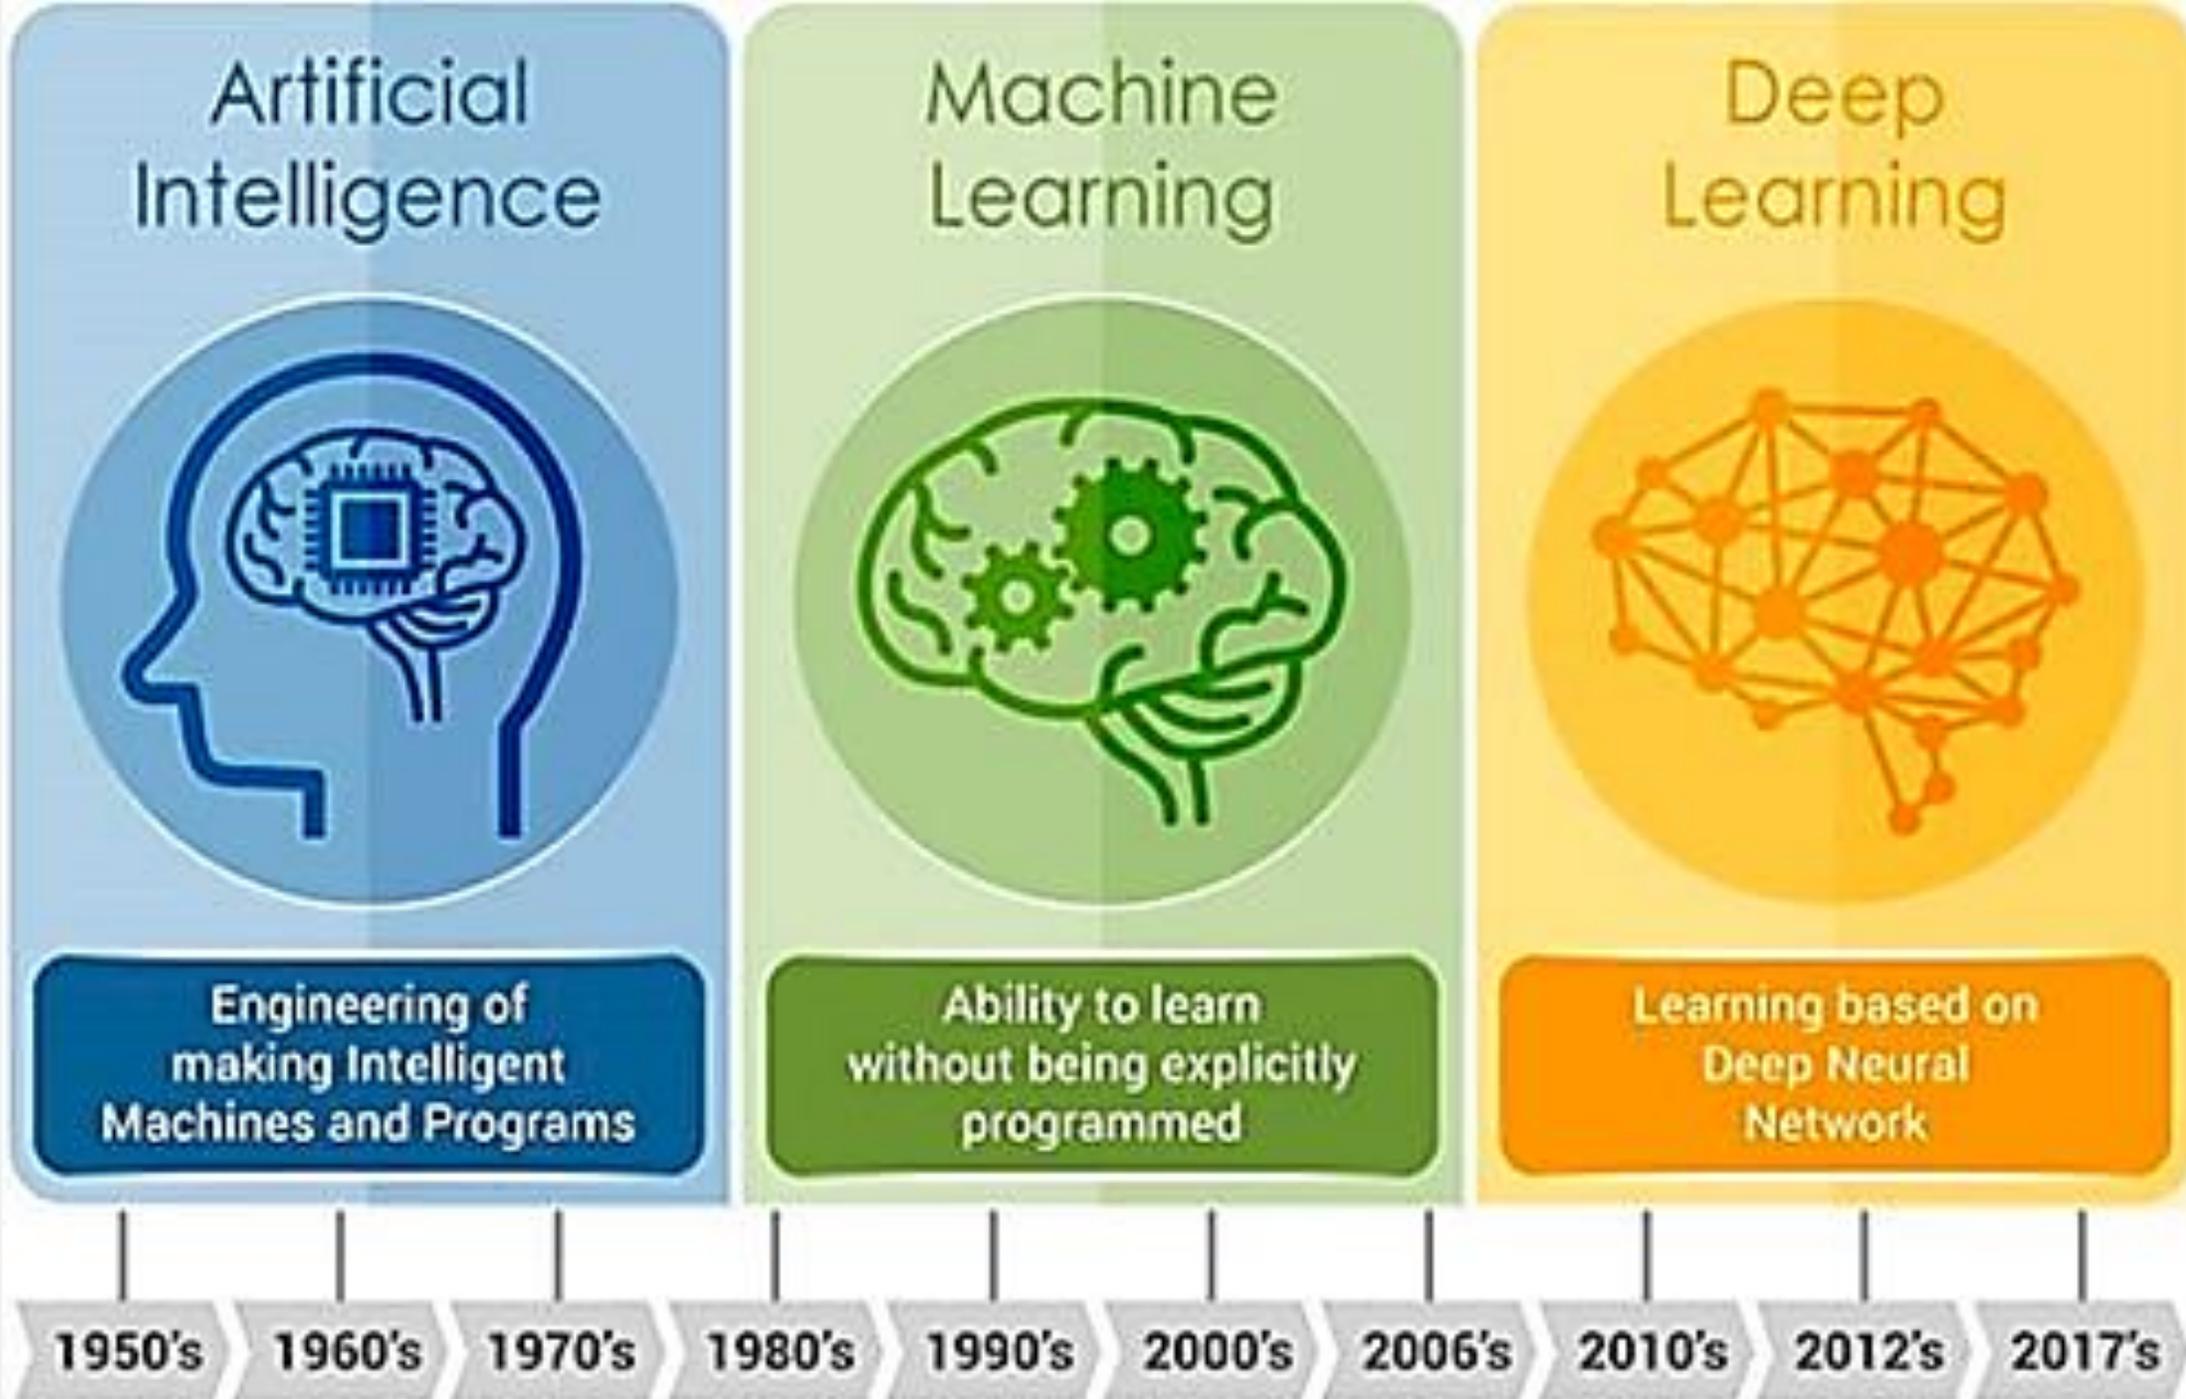
MACHINE LEARNING (ML)

É o campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados.” Arthur Samuel, 1959

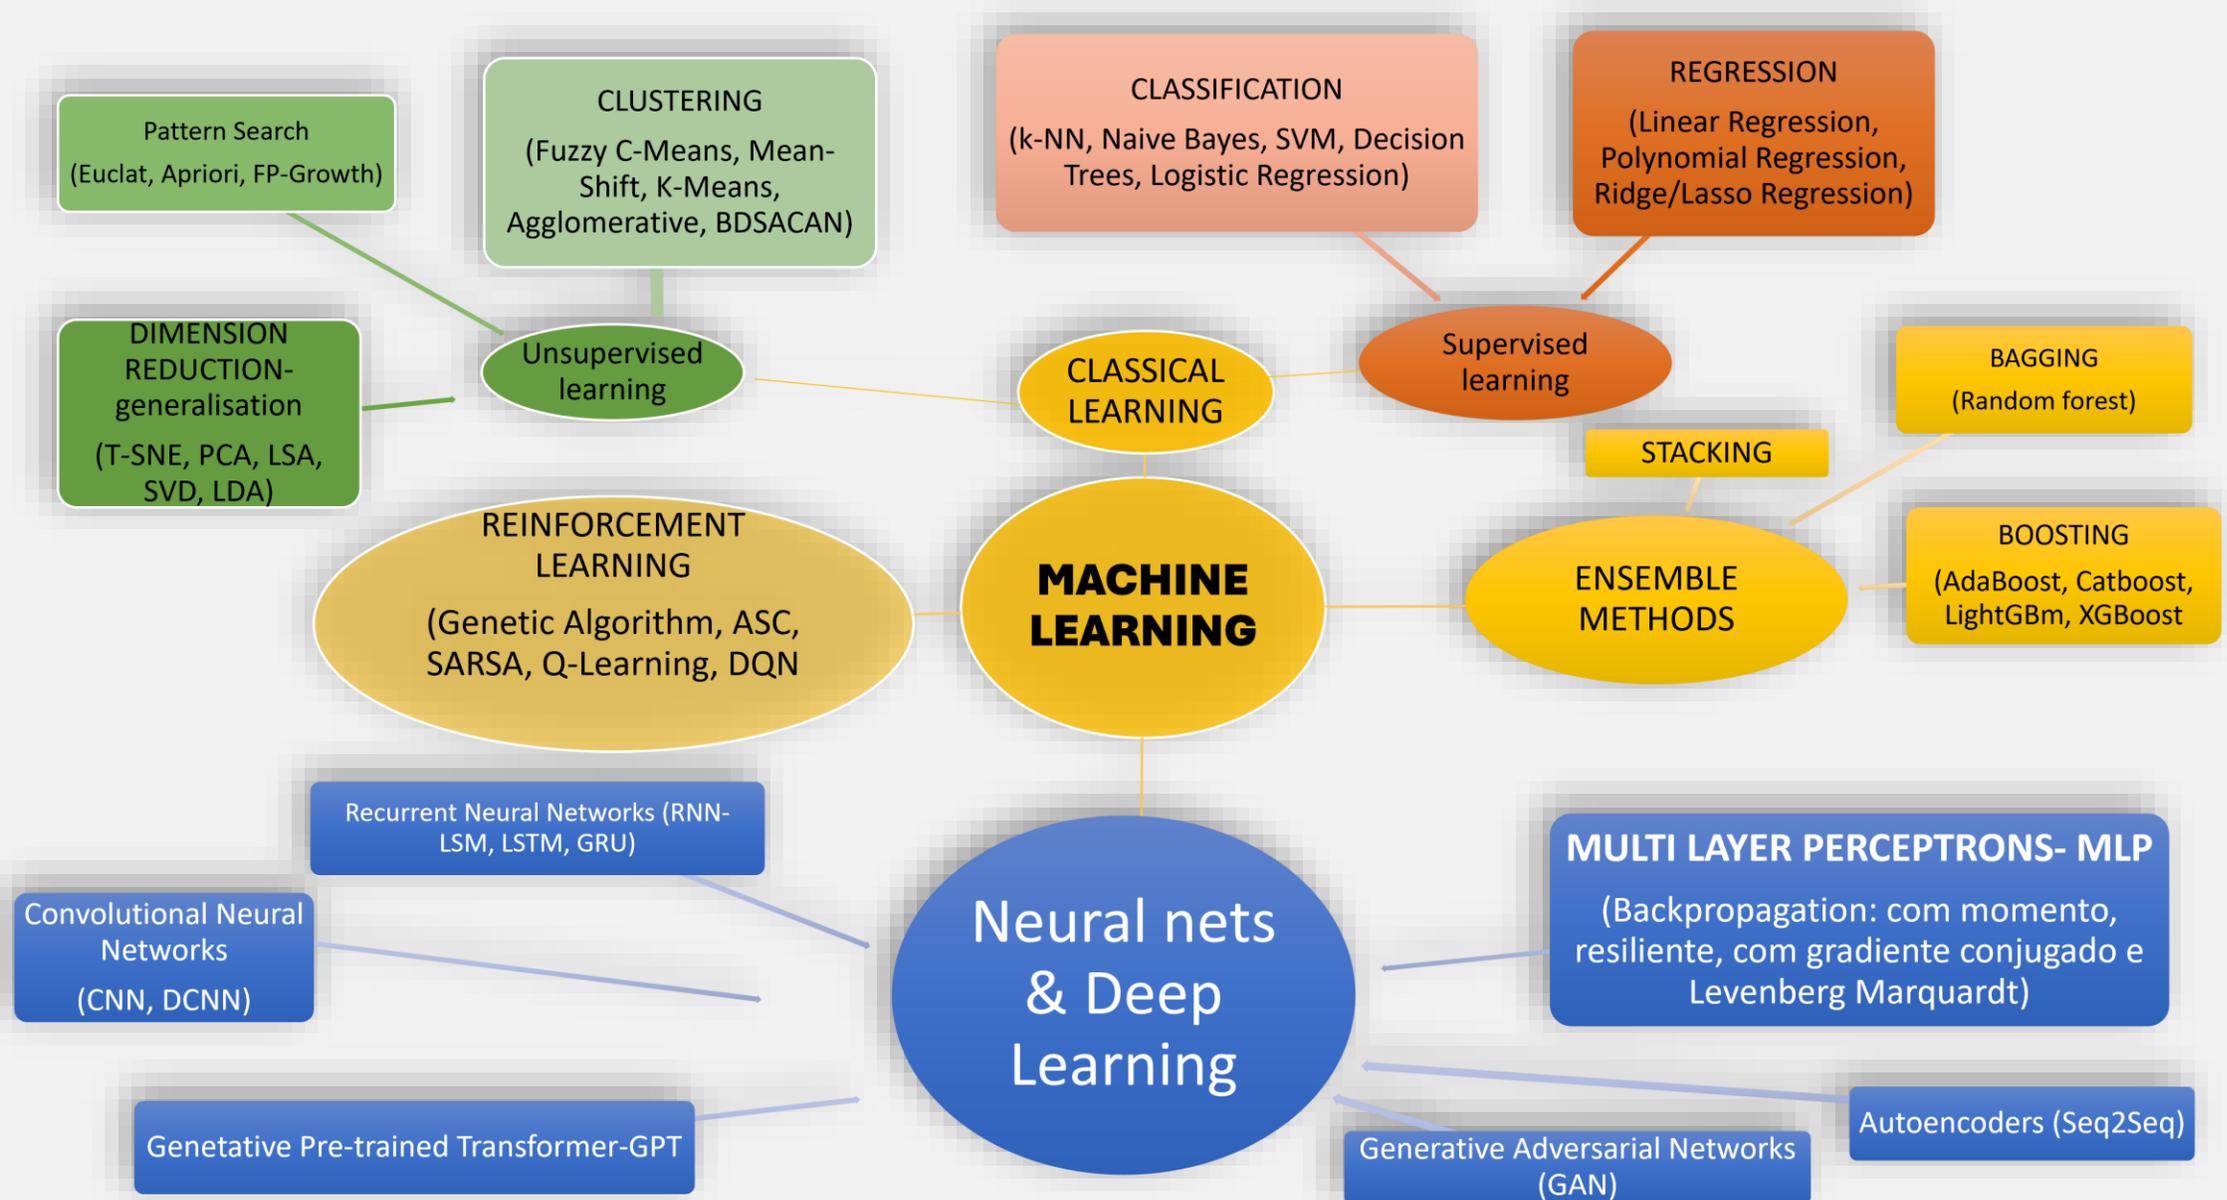
“É um ramo da inteligência artificial que se concentra em usar dados e algoritmos para criar sistemas que aprendem e melhoram seu desempenho com base na experiência.

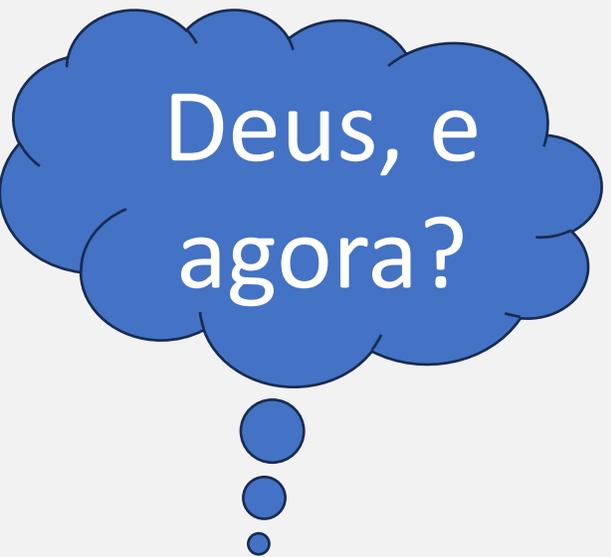


CRONOLOGIA



MACHINE LEARNING: TÉCNICAS E ALGORITMOS





Deus, e agora?

● CLUSTERING

- k Means
- k Medians
- BIRCH
- Fuzzy C-Means
- Fuzzy K-Modes
- Mini Batch K-Means
- DBSCAN
- Fuzzy clustering
- Mean-shift
- Optics algorithm
- Expectation Maximization
- Hierarchical Clustering
- Minimum spanning tree

● OTHER ML ALGORITHMS (Part 1)

- ALOPEX
- CN2 algorithm
- FastICA
- Feature selection Algorithms
- Linde Buzo Gray Algorithm
- Forward Backward algorithm
- Algorithm Accuracy Evaluation
- Performance Measures
- Optimization Algorithm
- Dynamic Time Warping
- Local Outlier Factor
- Logic Learning Machine
- Markov Chain Monte Carlo
- T Distributed Stochastic neighbor Embedding
- Wake Sleep Algorithm
- Prefrontal Cortex Basal Ganglia Working Memory

● DIMENSIONALITY REDUCTION

- PCA Algorithm
- PCR Algorithm
- PLSR Algorithm
- Sammon Mapping
- MDS Algorithm
- Projection Pursuit
- LDA Algorithm
- ICA Algorithm
- NMF Algorithm
- RDA Algorithm
- MDA Algorithm
- PLSDA Algorithm
- QDA Algorithm
- CCA Algorithm
- Diffusion Map

● RULE SYSTEM

- Cubist
- OneR
- ZeroR
- Ripper

● OTHER ML ALGORITHMS (Part 2)

- LogitBoost
- Sparse PCA
- Structured kNN
- WMA Algorithm
- GeneRec
- Leabra
- RProp

● REGRESSION

- Ordinary Least Squares Regression
- Linear Regression
- Logistic Regression
- Stepwise Regression
- MARS Algorithm
- Locally Estimated Scatterplot Smoothing

100+ MACHINE LEARNING ALGORITHMS

● DEEP LEARNING

- CNN
- RNNs
- LSTMs
- Stacked Auto Encoders
- Deep Boltzmann Machine
- Deep Belief Networks

● DECISION TREE

- Conditional Decision Trees
- Decision Stump
- C4.5 and C5.0
- CHAID
- CART
- ID3
- M5

● REGULARIZATION

- Ridge Regression
- Elastic Net
- LASSO
- LARS

● EMSEMBLE

- GBDT
- GBRT
- Boosting
- Bagging
- AdaBoost
- Random Forest
- Blending Algorithm
- Stacked Generalization
- Gradient Boosting Machines

● INSTANCE BASED

- Learning Vector Quantization
- K Nearest Neighbor
- Self-Organizing Map
- Locally Weighted Learning
- Support Vector Machines

● BAYESIAN

- AODE
- Naive Bayes
- Gaussian Naive Bayes
- Multinomial Naive Bayes
- Bayesian Belief Network
- Bayesian Network

● REINFORCEMENT LEARNING

- Q Learning
- SARSA Algorithm
- Deep Q-network
- Learning Automata
- DDPG Algorithm
- NAF Algorithm
- A3C Algorithm
- TRPO Algorithm
- PPO Algorithm
- Constructing Skill Trees

● ANNs

- Perceptron
- MLP Algorithm
- Back-Propagation
- Stochastic Gradient Descent
- Hopfield Network
- RBFN Algorithm

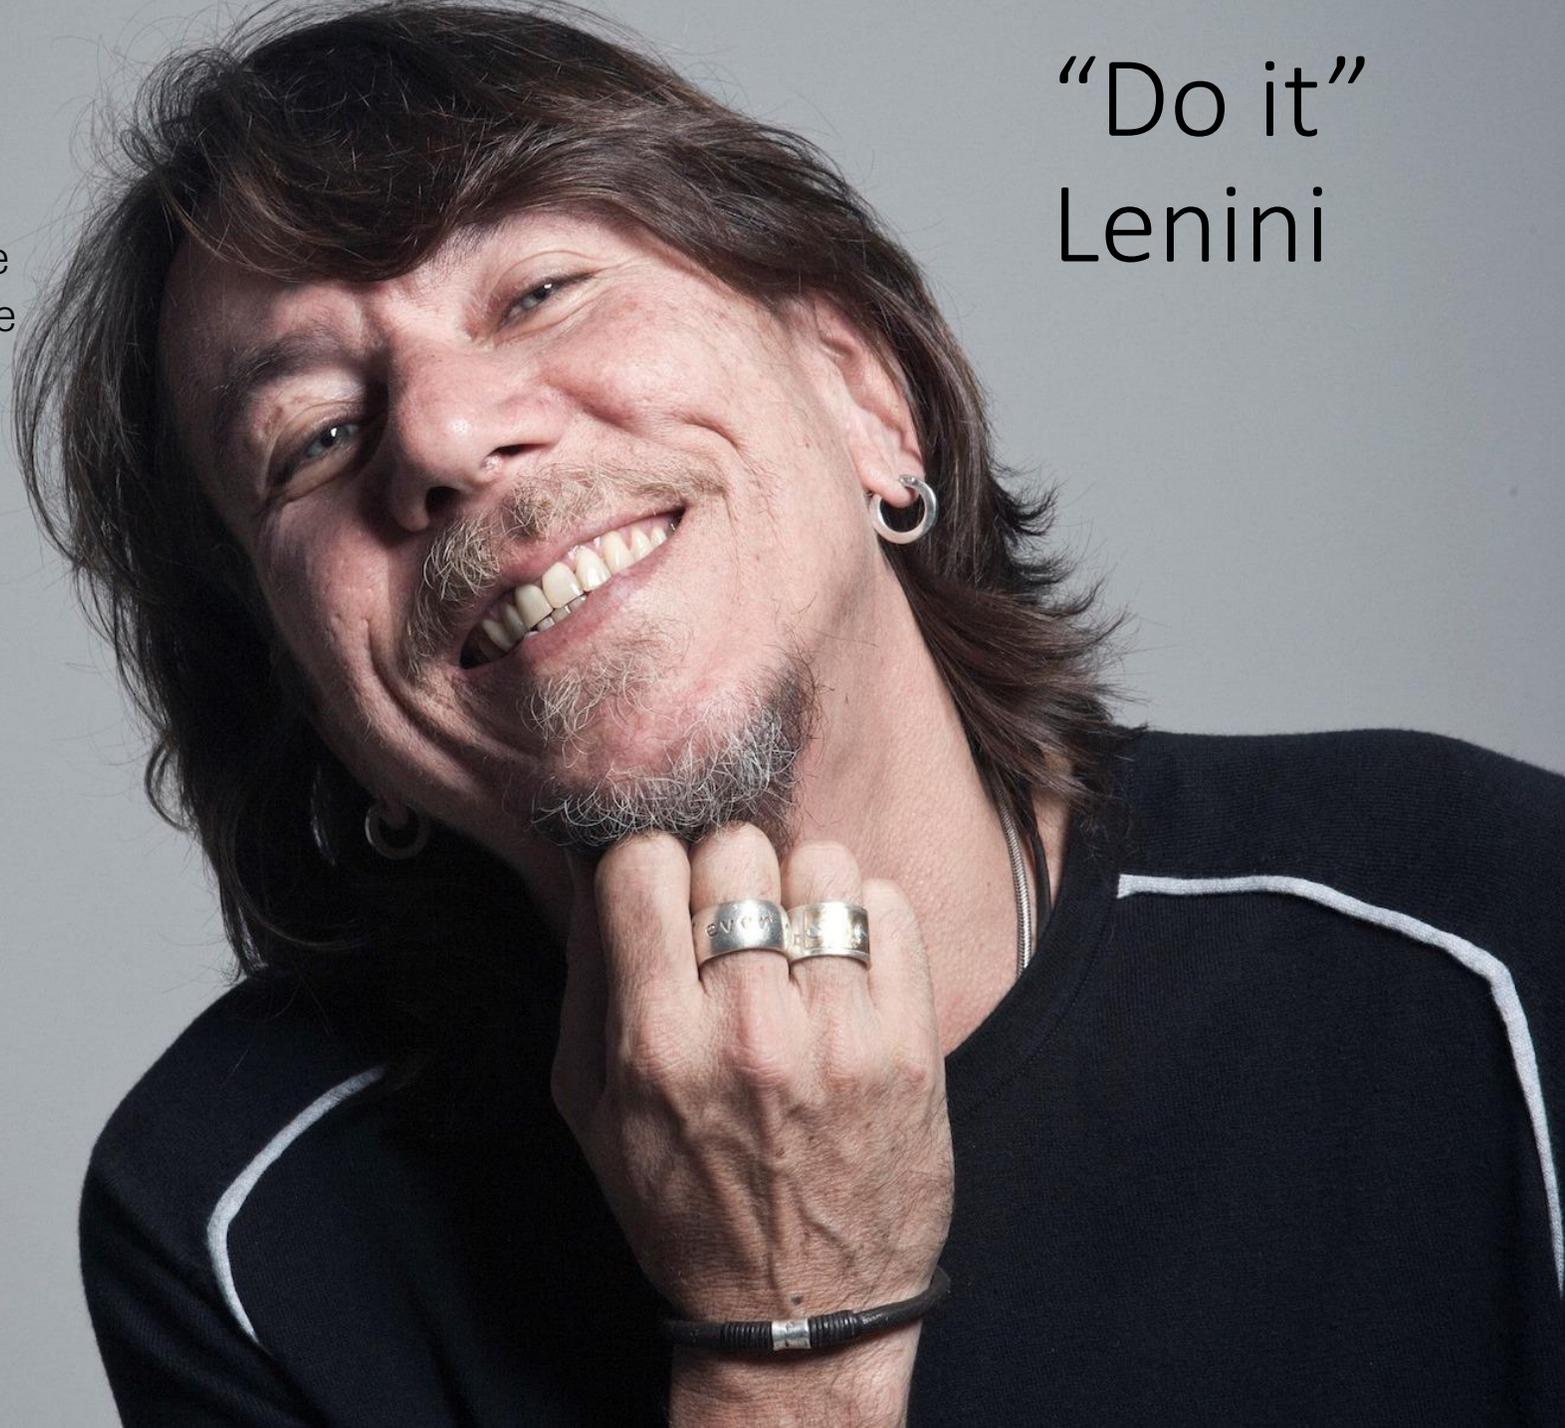
● ARL

- Apriori Algorithm
- Eclat Algorithm
- FP Growth Algorithm

“Do it” Lenini

'Tá cansada senta
Se acredita tenta
Se 'tá frio esquenta
Se 'tá fora entra
Se pediu aguenta
Se pediu aguenta
Se sujou cai fora
Se dá pé namora
'Tá doendo chora
'Tá caindo escora
Não 'tá bom melhora
Não 'tá bom melhora
Se aperta grite
Se 'tá chato agite
Se não tem credite
Se foi falta apite
Se não é imite
Se é do mato amanse
Trabalhou descanse
Se tem festa dance
Se 'tá longe alcance
Use sua chance
Use sua chance

Se 'tá puto quebre
'Tá feliz requebre
Se venceu celebre
Se 'tá velho alquebre
E corra atrás da lebre
Corra atrás da lebre
Se perdeu procure
Se é seu segure
Se 'tá mal se cure
Se é verdade jure
Quer saber apure
Quer saber apure
Se sobrou congele
Se não vai cancele
Se é inocente apele
Escravo se rebele
Nunca se atropele
Se escreveu remeta
Engrossou se meta
Quer dever prometa
Pra moldar derreta
E não se submetta
E não se submetta



QUAL TÉCNICA E ALGORITMO USAR?

Qual é o meu objetivo na investigação do fenômeno?

Existem indicações de técnicas já usadas na literatura?

o fenômeno é linear ou não? é uni ou multivariado? São linearmente separáveis ou não?

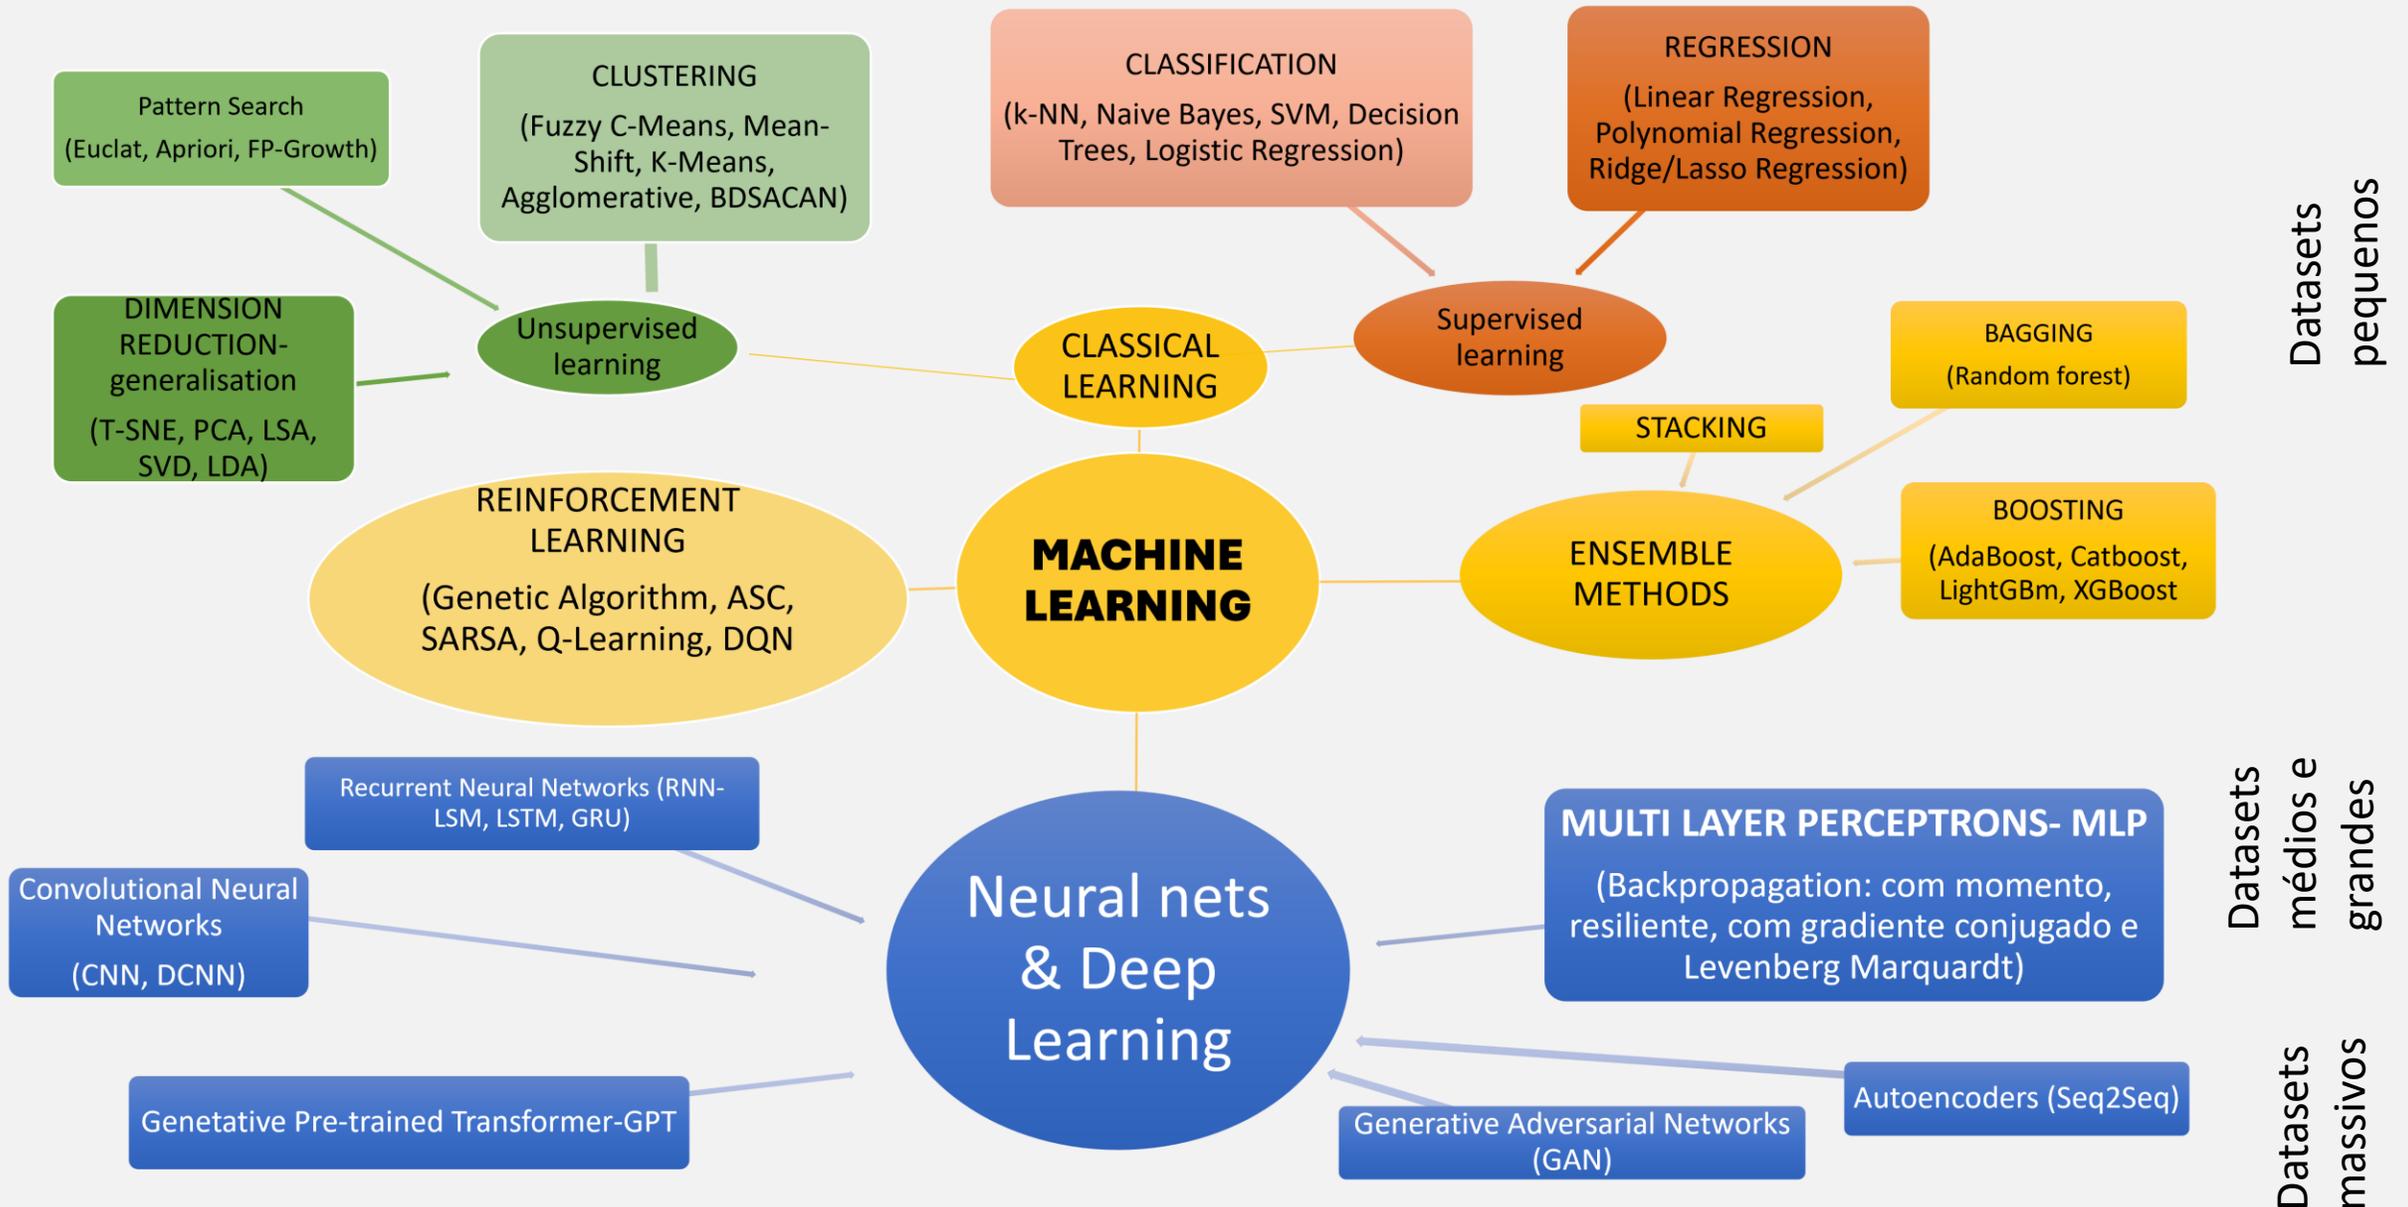
Existem dados secundários? Quais as fontes? Se não, vou ter como obter dados primários?

Qual o tamanho do meu DataSet? Formato? Confiabilidade? data de aquisição? Abrangência, Espaciais? Temporais?

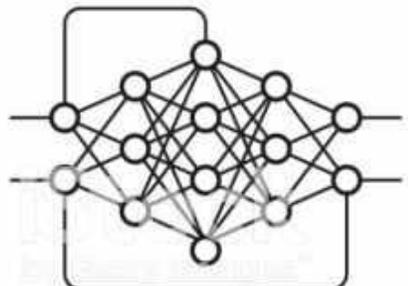
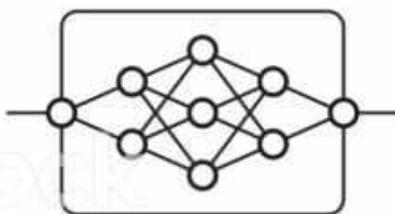
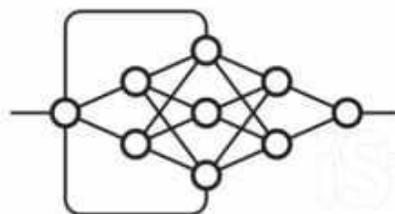
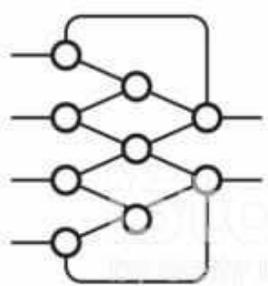
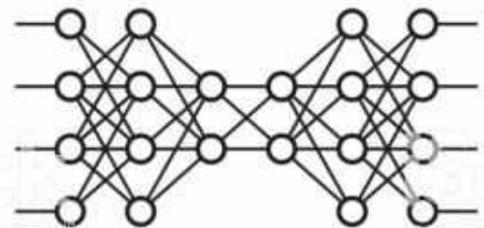
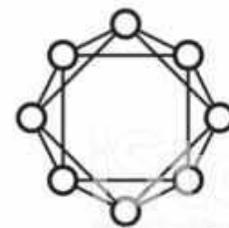
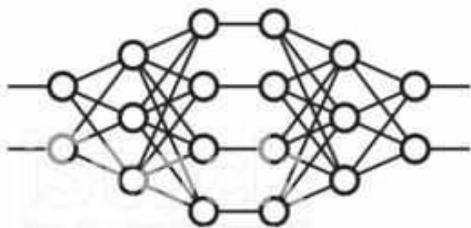
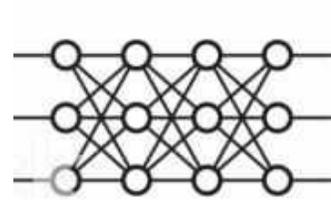
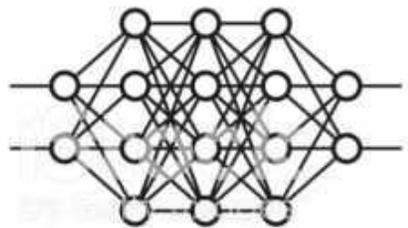
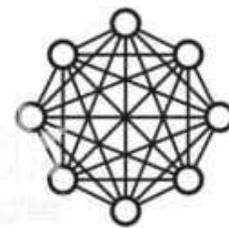
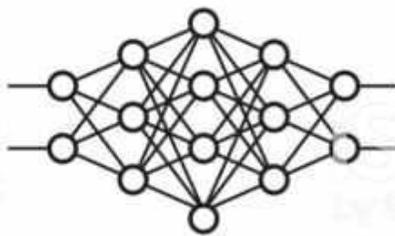
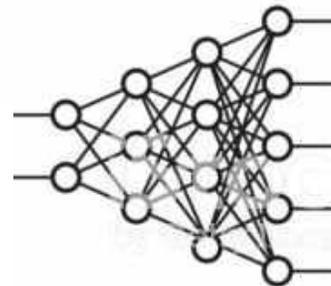
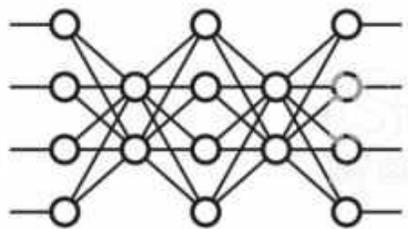
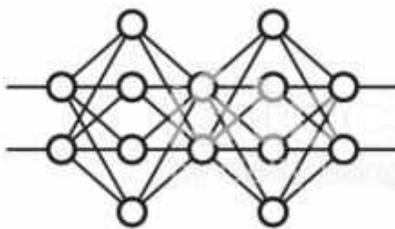
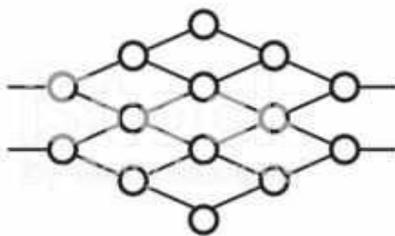
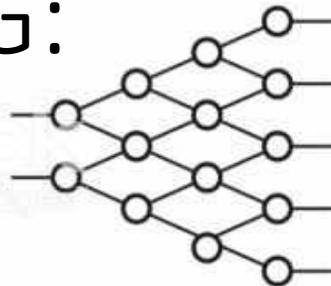
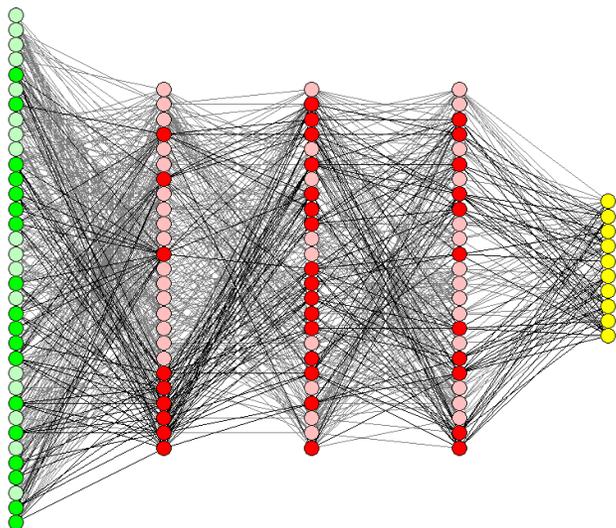
Depois de ter resposta para todas essas perguntas, aí sim, posso pensar nas técnicas



MACHINE LEARNING: TÉCNICAS E ALGORITMOS



DEEP LEARNING: Arquiteturas



PULGA ATRÁS DA ORELHA?

1. Como são os Datasets que representam os fenômenos estudados em Infraestrutura e, Planejamento & Operação de sistemas de transportes?
2. Como você justificaria aos membros de sua tese/dissertação adoção desta ou daquela técnica de modelagem?



- PERGUNTAS?
- EXPERIÊNCIAS?

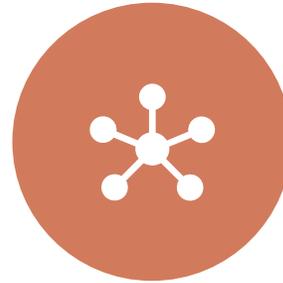
TAREFA



PONTOS CHAVE



HISTÓRICO/ORIGEM



RELAÇÕES ENTRE NC, AI,
ML, NN E DL



DEFINIÇÕES



ADEQUAÇÃO DA TÉCNICA
AO OBJETIVO DA
MODELAGEM E AOS
DADOS DISPONÍVEIS

ATIVIDADE 2:

Se você está aqui, deve pretender modelar algum fenômeno com alguma finalidade certo?

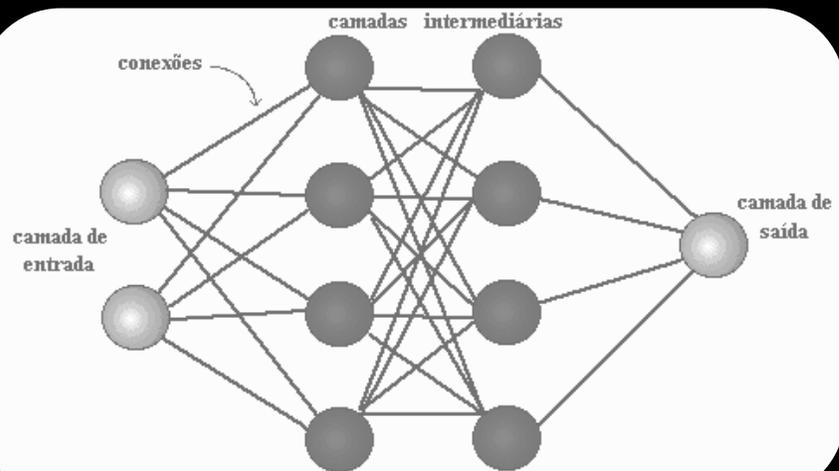
Sendo assim, você vai precisar de dados, se esses dados já existem, você já tem acesso a eles?

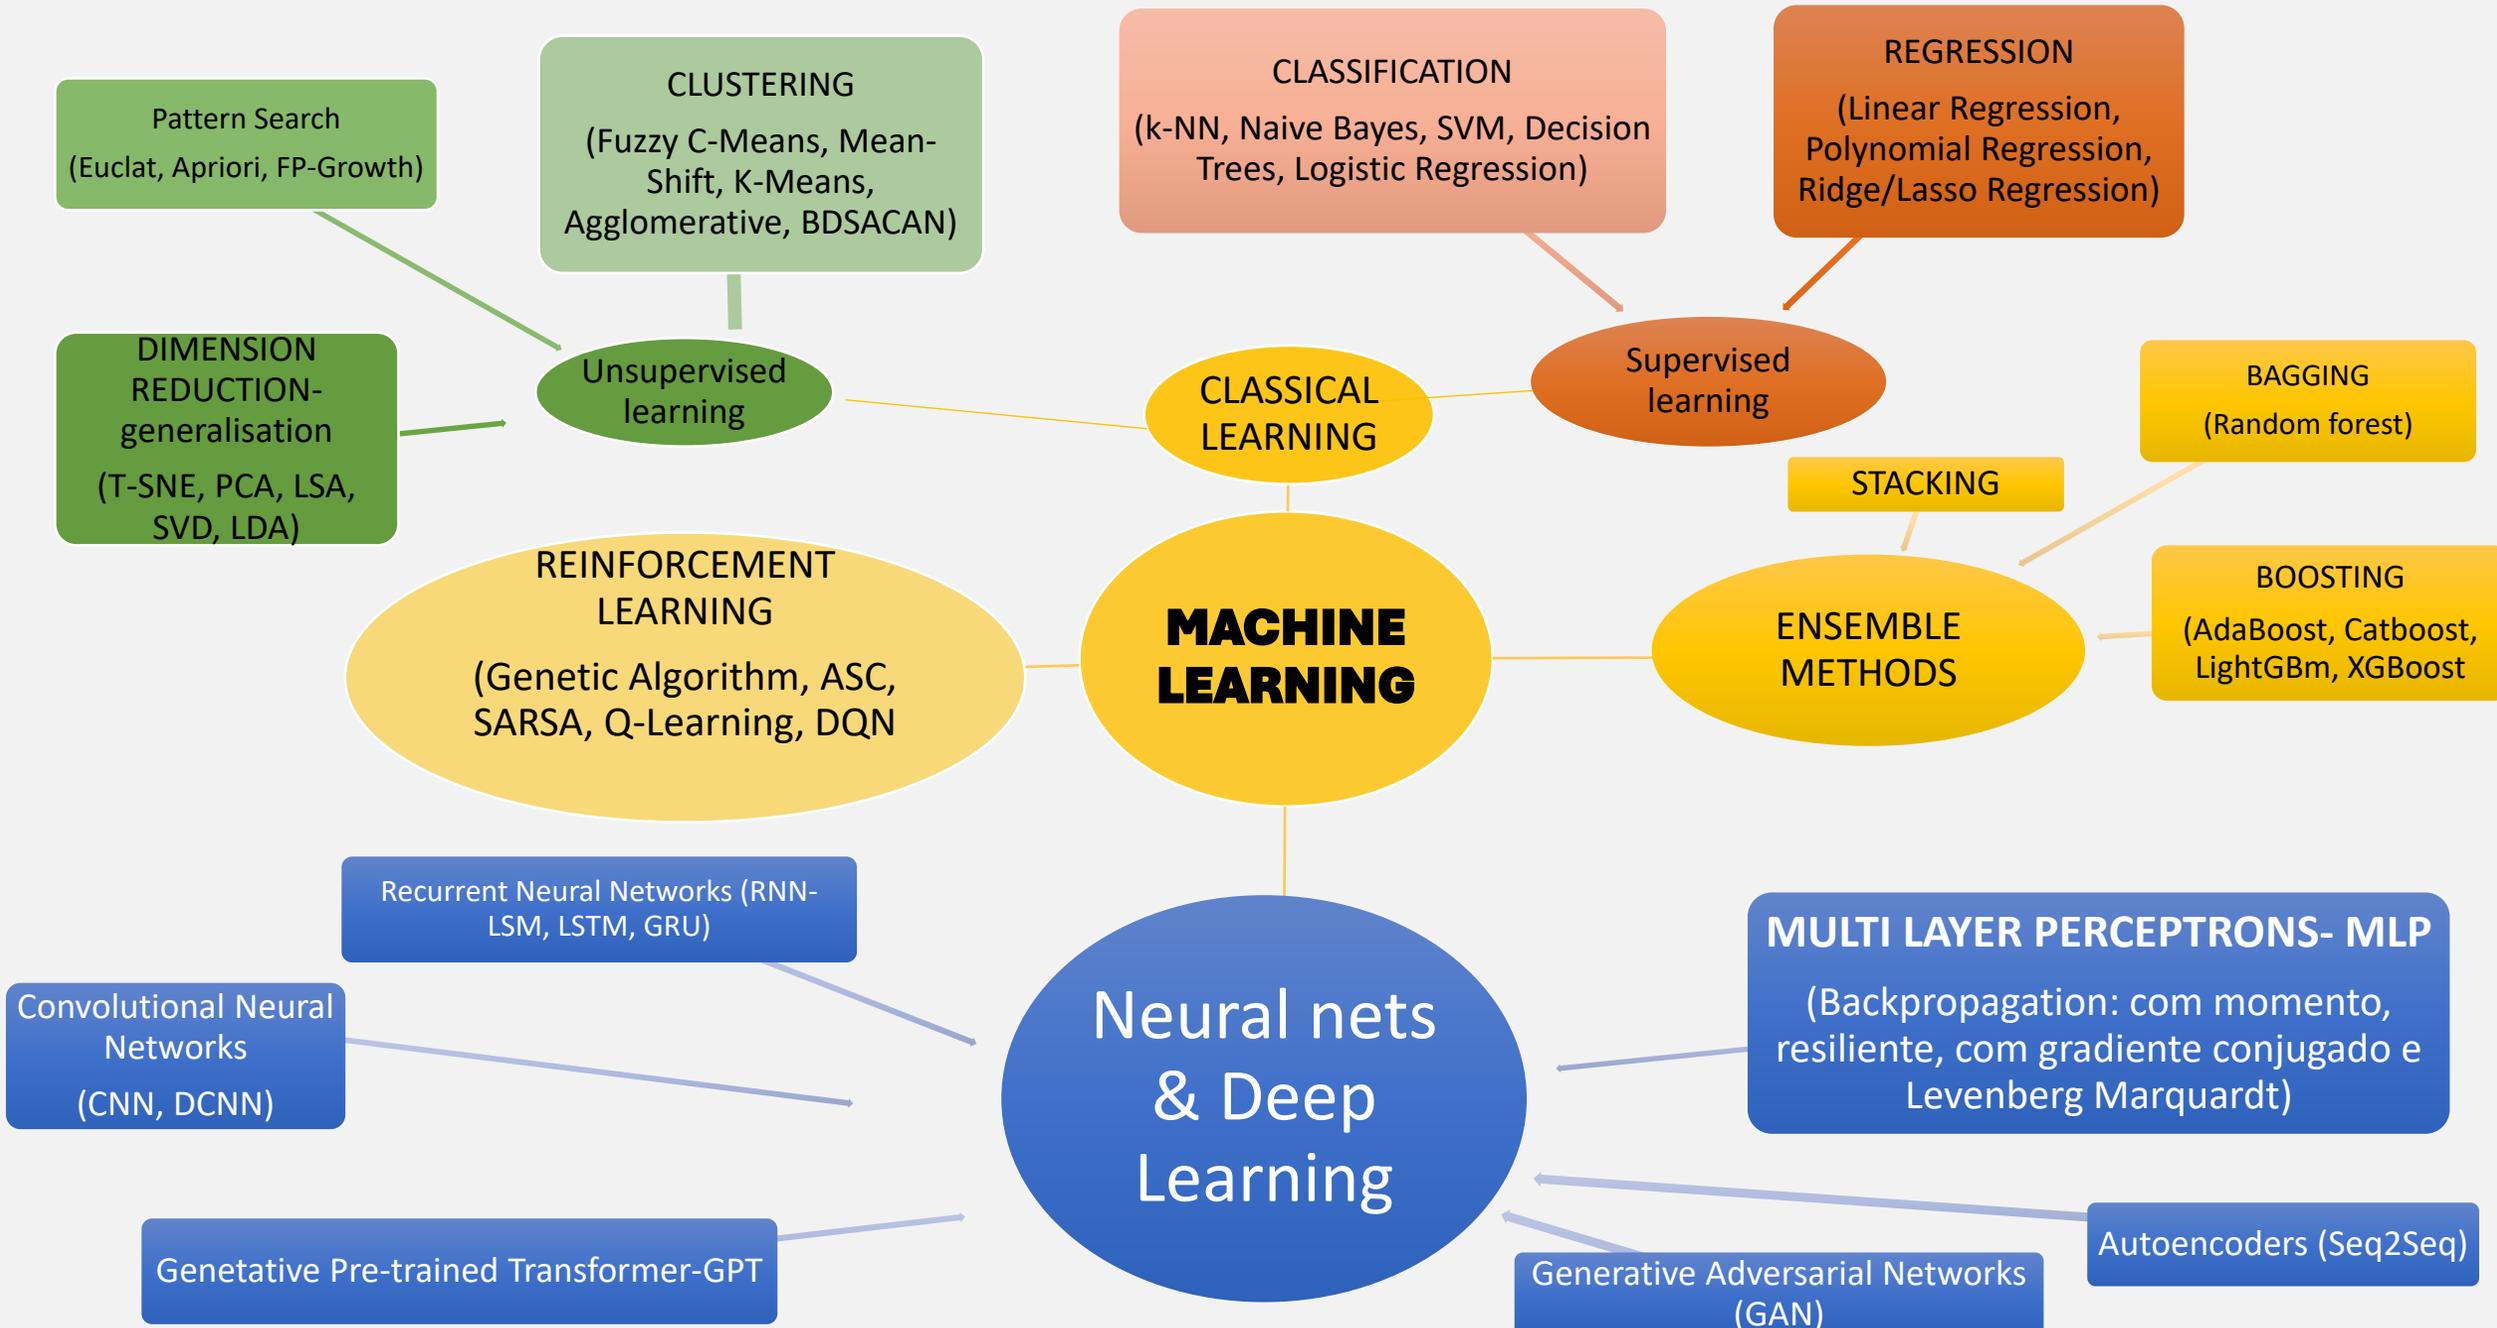
Que tal começar a tentar responder as perguntas do slide 17 e escrever uma lauda com uma justificativa para o uso desta ou daquela técnica de modelagem em sua pesquisa?

Dica: Apoie sua justificativa nas características de seu fenômeno, no dataset disponível e no objetivo que tem ao modelar e obviamente na literatura pertinente.



A SEGUIR, CENAS DO
PRÓXIMO
CAPÍTULO





MACHINE LEARNING

CLASSICAL LEARNING

Unsupervised learning

Pattern Search
(Euclat, Apriori, FP-Growth)

CLUSTERING
(Fuzzy C-Means, Mean-Shift, K-Means, Agglomerative, BDSACAN)

DIMENSION REDUCTION-generalisation
(T-SNE, PCA, LSA, SVD, LDA)

REINFORCEMENT LEARNING
(Genetic Algorithm, ASC, SARSA, Q-Learning, DQN)

Supervised learning

CLASSIFICATION
(k-NN, Naive Bayes, SVM, Decision Trees, Logistic Regression)

REGRESSION
(Linear Regression, Polynomial Regression, Ridge/Lasso Regression)

ENSEMBLE METHODS

BAGGING
(Random forest)

BOOSTING
(AdaBoost, Catboost, LightGBm, XGBoost)

STACKING

Neural nets & Deep Learning

Convolutional Neural Networks
(CNN, DCNN)

Recurrent Neural Networks (RNN-LSM, LSTM, GRU)

Genetative Pre-trained Transformer-GPT

Generative Adversarial Networks (GAN)

Autoencoders (Seq2Seq)

MULTI LAYER PERCEPTRONS- MLP
(Backpropagation: com momento, resiliente, com gradiente conjugado e Levenberg Marquardt)