Machine Learning

Bibliografia

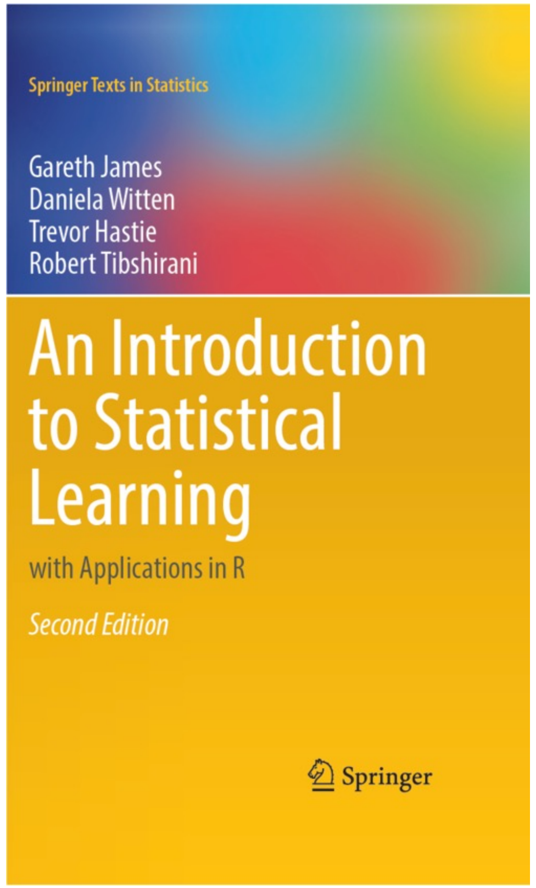

https://www.statlearning.com/

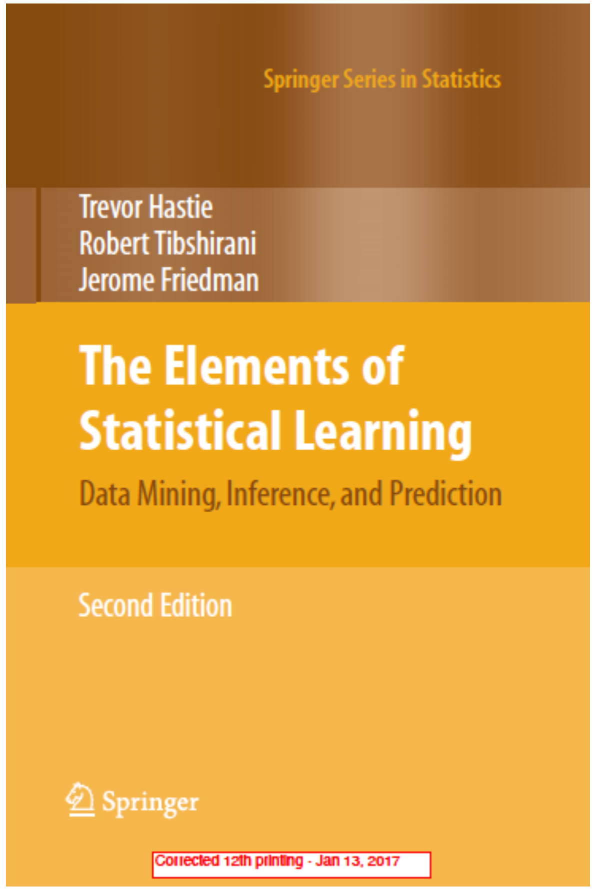

https://hastie.su.domains/ElemStatLearn/

Visão geral sobre o Machine Learning

"Machine Learning é a área de estudo que da habilidade a computadores de aprender algo que não foram explicitamente programados"

Arthur Samuel (1959)

Evolução histórica do Machine Learning

Jogar xadrez

Arthur Samuel(1950-60)

Artificial Neural Network

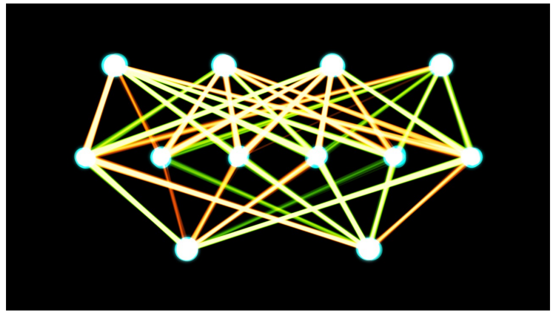

Backpropagation (1973)

Deeplearning landmark

A. Krizhevsky, I. Sutskever, and G. E. Hinton (2012)

Teoria sobre o cérebro

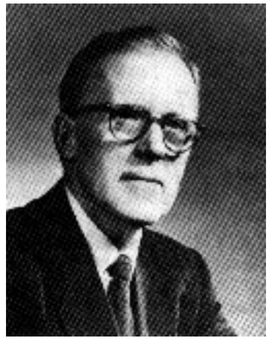

Donnald Hebb (1949)

Computador para ML

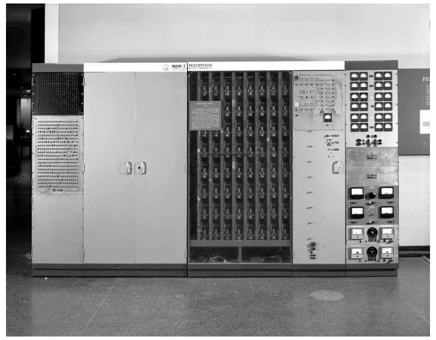

Mark 1 Percetron (1958)

- Random Forests
- Support Vector Machines
- Deep Neural Networks

(1980-1990)

Evolução histórica do Machine (statistical) Learning

Linear Regression

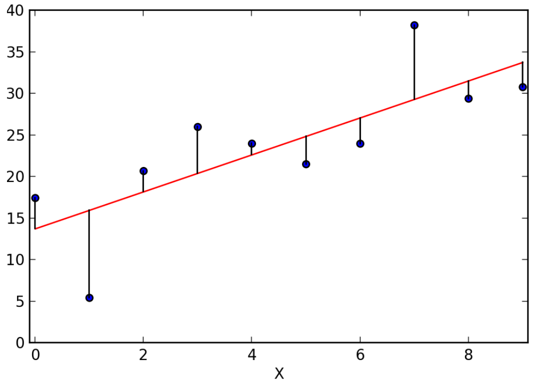

Linear Discriminant Analysis

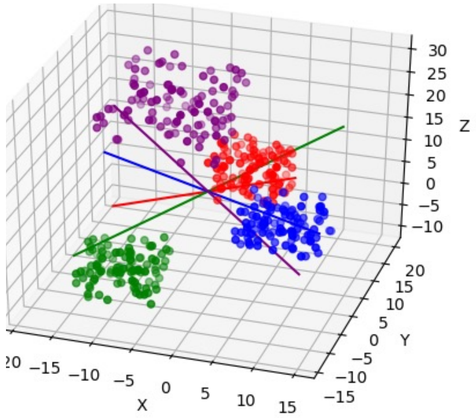

Logistic Regression

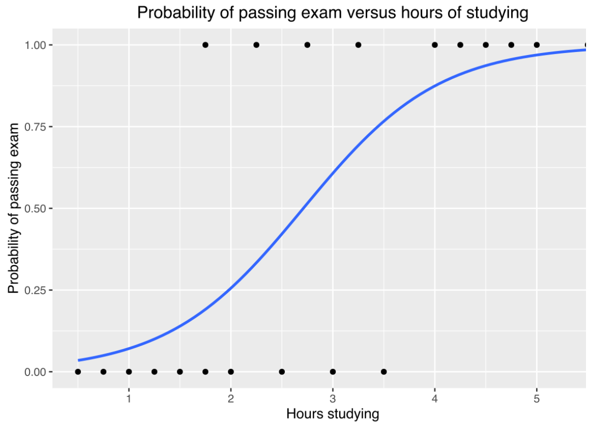

1800 **1900** **1930** **1960** **1990** **Presente**

Evolução histórica do Machine (statistical) Learning

Linear Regression

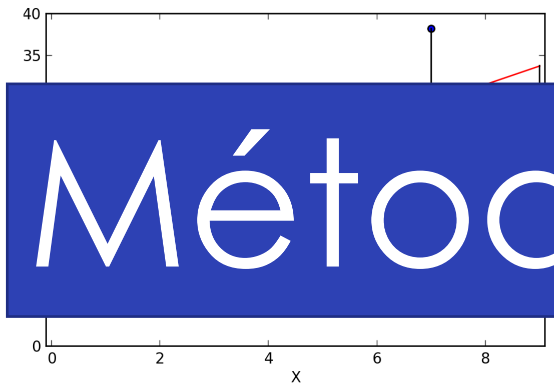

Linear Discriminant Analysis

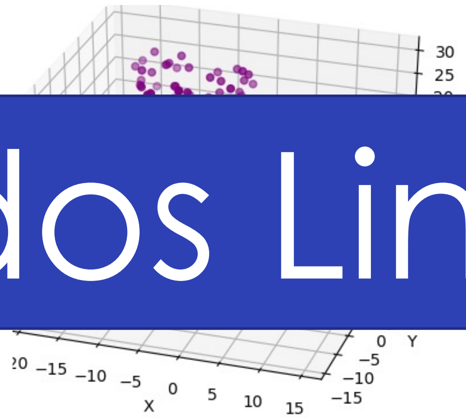

Logistic Regression

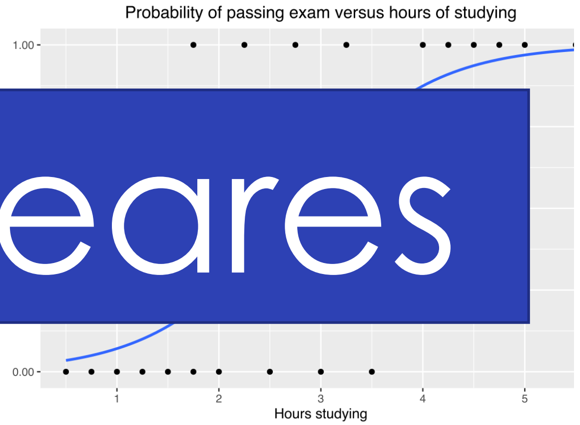

Métodos Lineares

1800 | 1900 | 1930 | 1960 | 1990 | Presente

Evolução histórica do Machine (statistical) Learning

Linear Regression

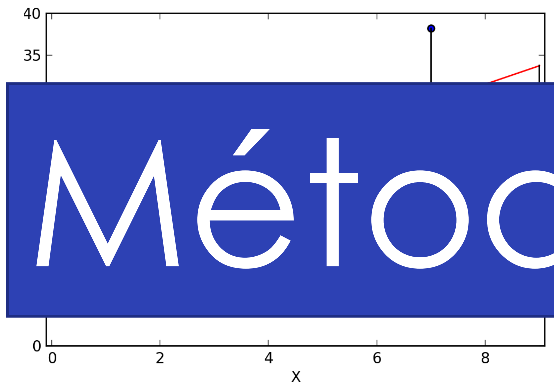

Linear Discriminant Analysis

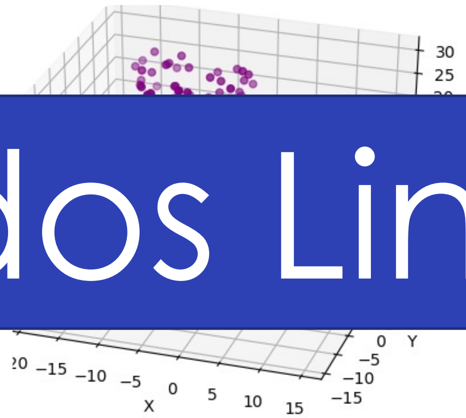

Logistic Regression

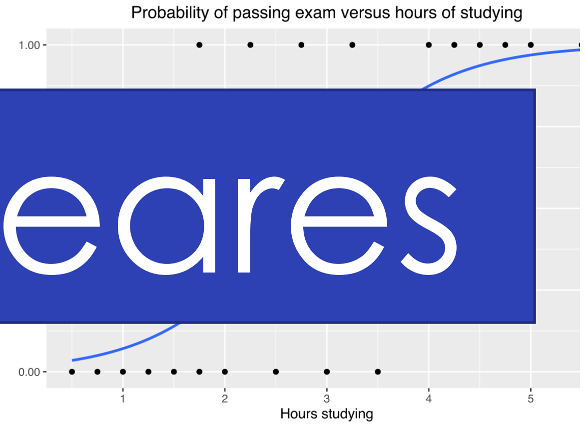

Decision Trees

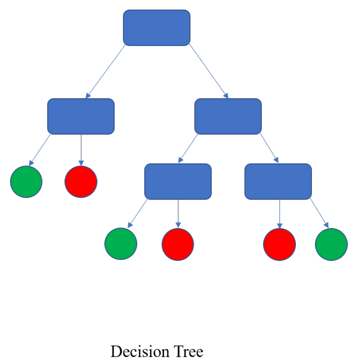

Neural Networks

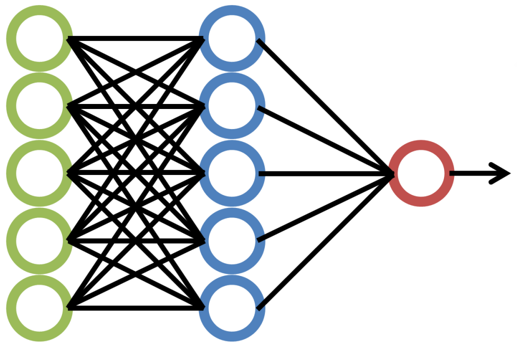

Support Vector Machines

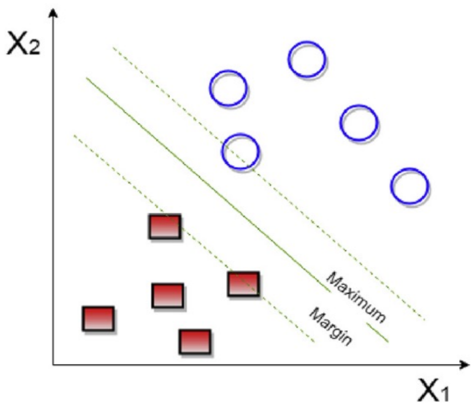

Métodos Lineares

1800 1900 1930 1960 1990 Presente

Evolução histórica do Machine (statistical) Learning

Linear Regression

Linear Discriminant Analysis

Logistic Regression

Decision Trees

Neural Networks

Support Vector

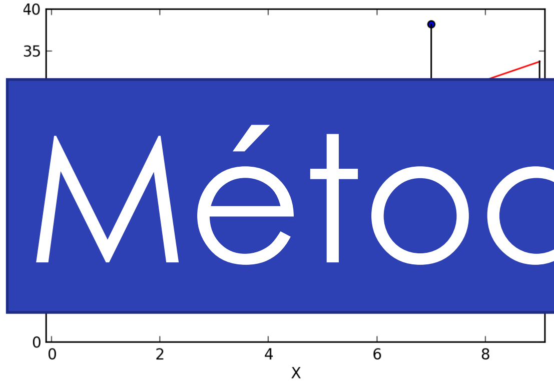

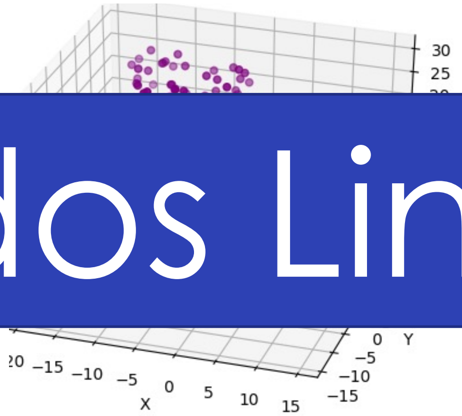

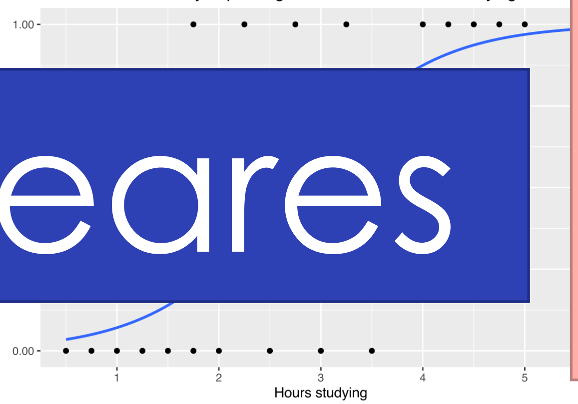

Métodos Lineares

Métodos Não lineares

1800 1900 1930 1960 1990 Presente

Grande questão atual? Ética!!

Forbes

TECH

How Target Figured Out A Teen Girl Was Pregnant Before Her Father Did

Kashmir Hill Former Staff
Welcome to The Not-So Private Parts where technology & privacy collide

Feb 16, 2012, 11:02am EST

This article is more than 10 years old.

Every time you go shopping, you share intimate details about your consumption patterns with retailers. And many of those retailers are studying those details to figure out what you like, what you need, and which coupons are most likely to make you happy. Target , for example, has figured out how to data-mine its way into your womb, to figure out whether you have a baby on the way long before you need to start buying diapers.

TARGET

Target has got you in its aim

Charles Duhigg outlines in the New York Times how Target tries to hook

MICROSOFT / WEB / TL;DR

Twitter taught Microsoft's AI chatbot to be a racist asshole in less than a day

By JAMES VINCENT
Mar 24, 2016, 10:43 AM GMT | 0 Com

It took less than 24 hours for Twitter to corrupt an innocent AI chatbot. Yesterday, Microsoft unveiled Tay — a Twitter bot that the company described as an experiment in "conversational understanding." The more you chat with Tay, said Microsoft, the smarter it gets, learning to engage people through "casual and playful conversation."

Unfortunately, the conversations didn't stay playful for long. Pretty soon after Tay launched, people starting tweeting the bot with all sorts of misogynistic, racist, and Donald Trumpist remarks. And

COLO
CREAT
Cre
Tra
Vid
Eas

Forbes

DIVERSITY, EQUITY & INCLUSION

AI Bias Could Put Women's Lives At Risk - A Challenge For Regulators

Carmen Niethammer Former Contributor
I am a private sector development expert and gender diversity leader.

Mar 2, 2020, 04:19am EST

When the European Commission released the long awaited white paper *"On Artificial Intelligence - A European approach to excellence and trust" on February 19*, much of the initial public reaction focused on potential AI regulation further challenging the EU's position in light of fierce technological competition from China and the United States.

Few discussed the European Commission's document mention of gender and ethical guidelines. Importantly, the white paper calls for "requirements to take reasonable measures aimed at ensuring that [the] use of AI systems does not lead to outcomes entailing prohibited discrimination." Why does it matter?

This is not simply about a theoretical approach to discrimination. It is largely also about saving (women's) lives - and ensuring that essential products and services meet the needs of both women and men. However, if artificial intelligence is based on "bad" data sourced predominantly from men and/or based on male profiles, terrible things can happen.

Grande questão atual? Ética!!

W3C

Exatidão (Accuracy)

Preconceito (Bias)

Justiça (Fairness)

Segurança e proteção (Safety and security)

Privacidade (Privacy)

Transparência (Transparency)

Responsabilidade (Accountability)

Controlo humano e tomada de decisão (Human control and decision making)

Impacto Ambiental e sustentabilidade (Environmental impact and sustainability)

Grande questão atual? Ética!!

Exatidão (Accuracy)

“Porporção de casos para os quais o modelo de ML gera o resultado correto”

Source: GAO photo illustration; Andrey Popov and polkadot on stock.adobe.com.

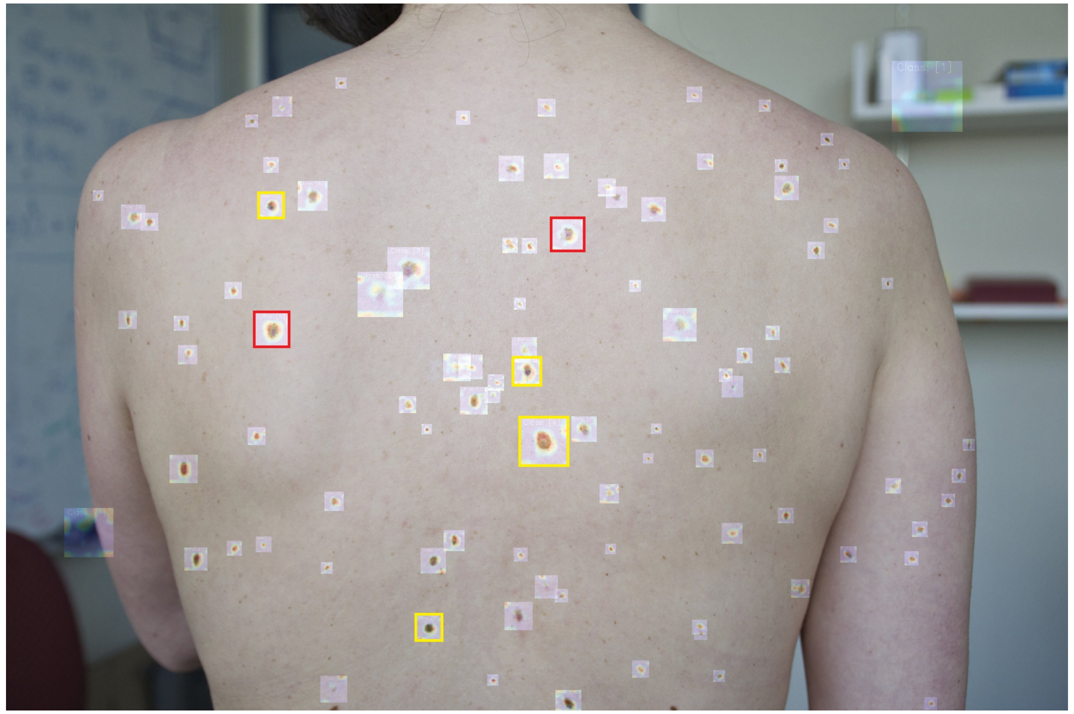

Grande questão atual? Ética!!

Preconceito (Bias)

"Desvio sistemático do valor real"

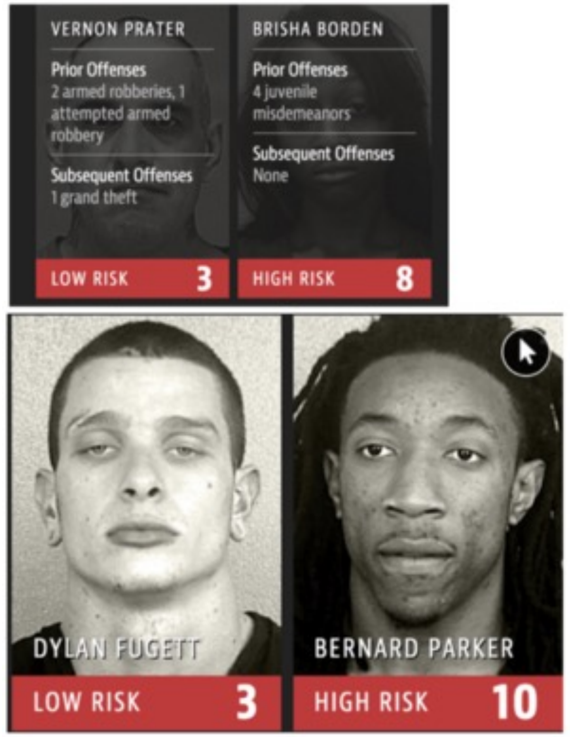

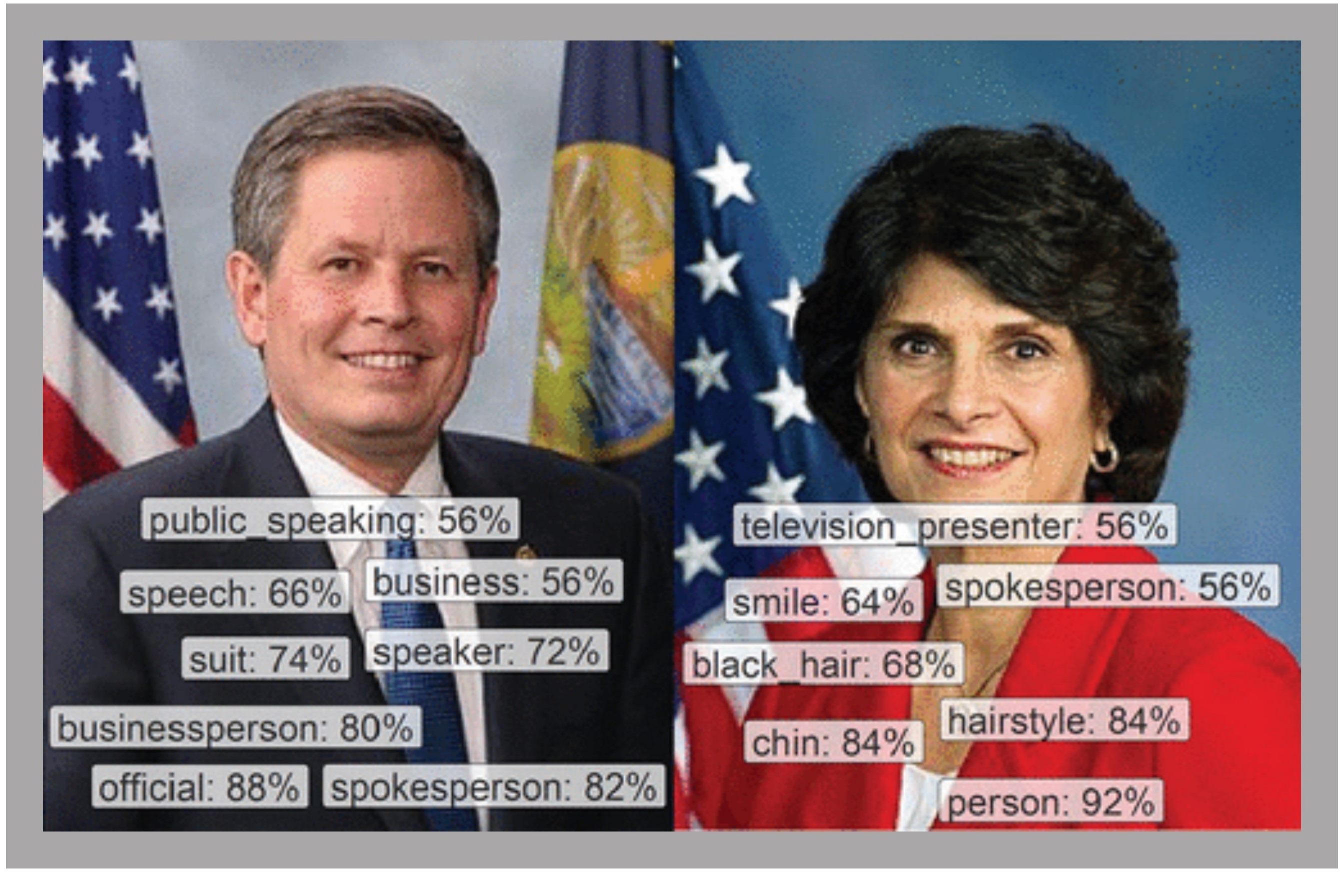

Grande questão atual? Ética!!

Justiça (Fairness)

"As pessoas devem ser tratadas de forma igual a não ser que haja uma razão que justifique o contrário"

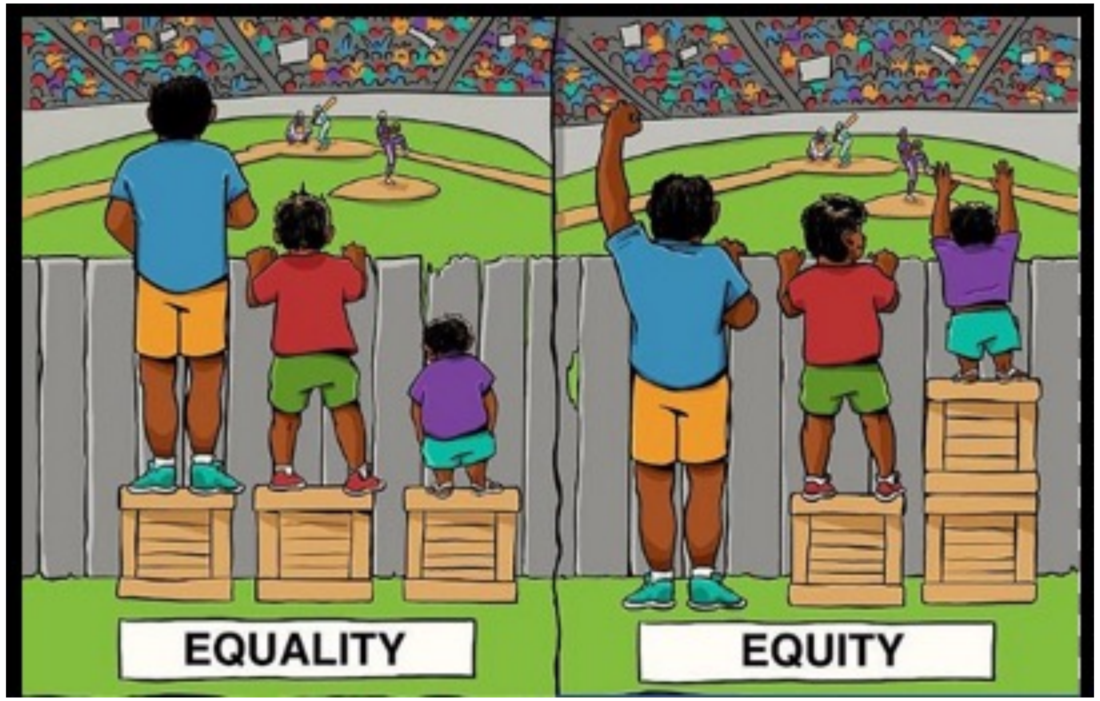

Grande questão atual? Ética!!

Segurança e proteção (Safety and security)

"Um modelo de ML deve ser exato, de confiança, seguro, e robusto"

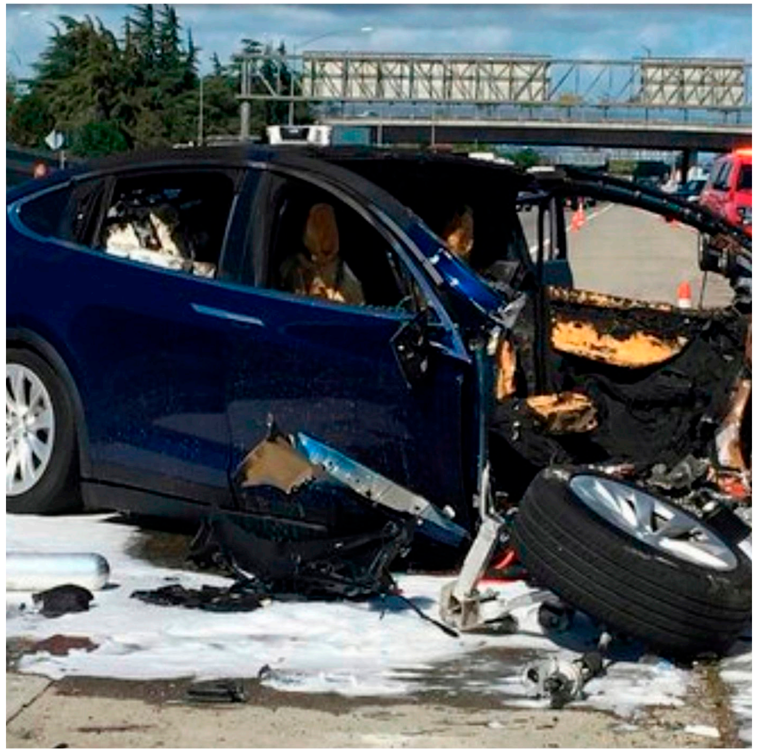

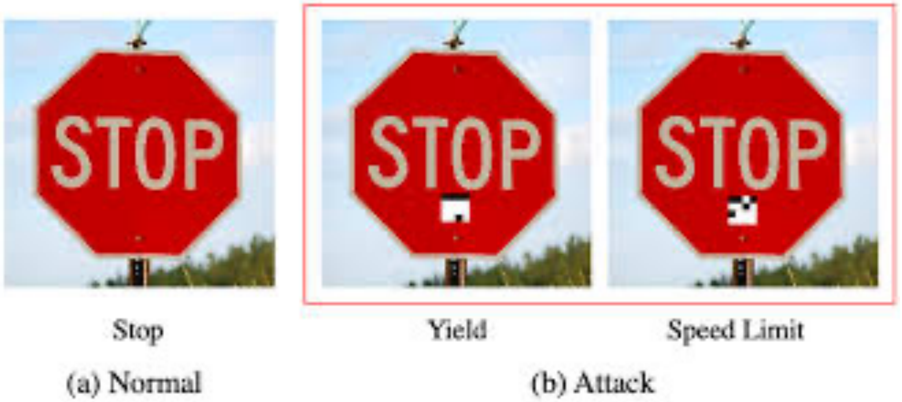

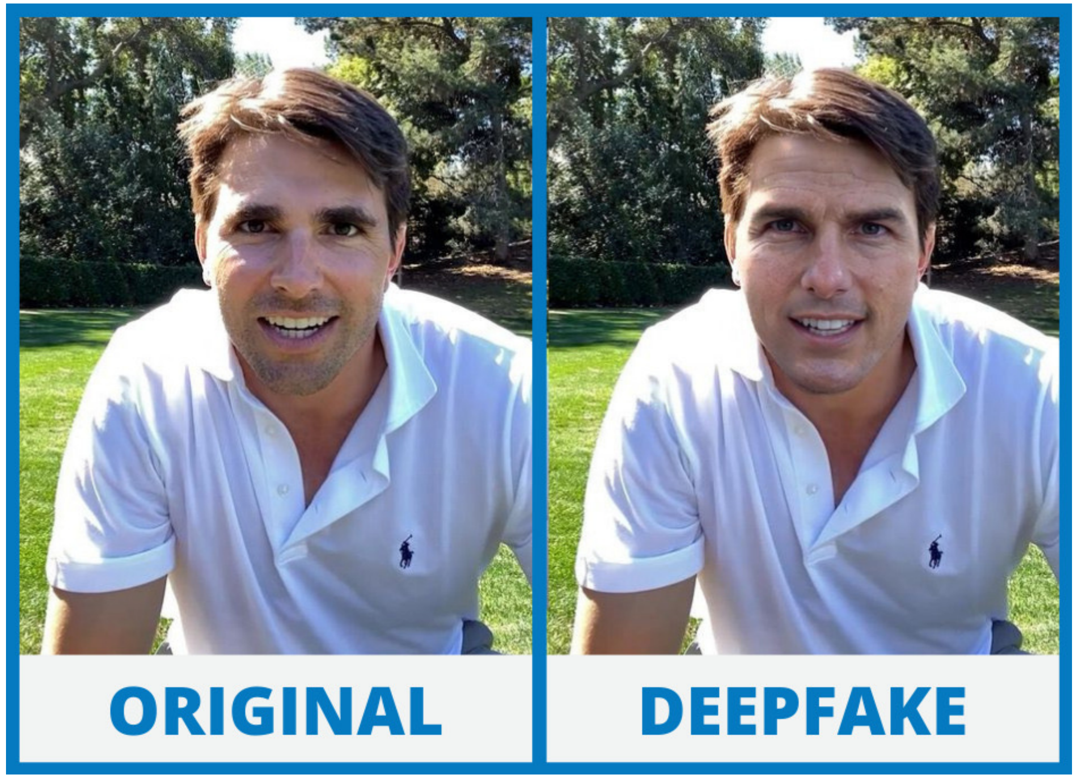

Grande questão atual? Ética!!

Privacidade
(Privacy)

“ML afeta um utilizador ou seus dados, sem seu conhecimento ou consentimento”

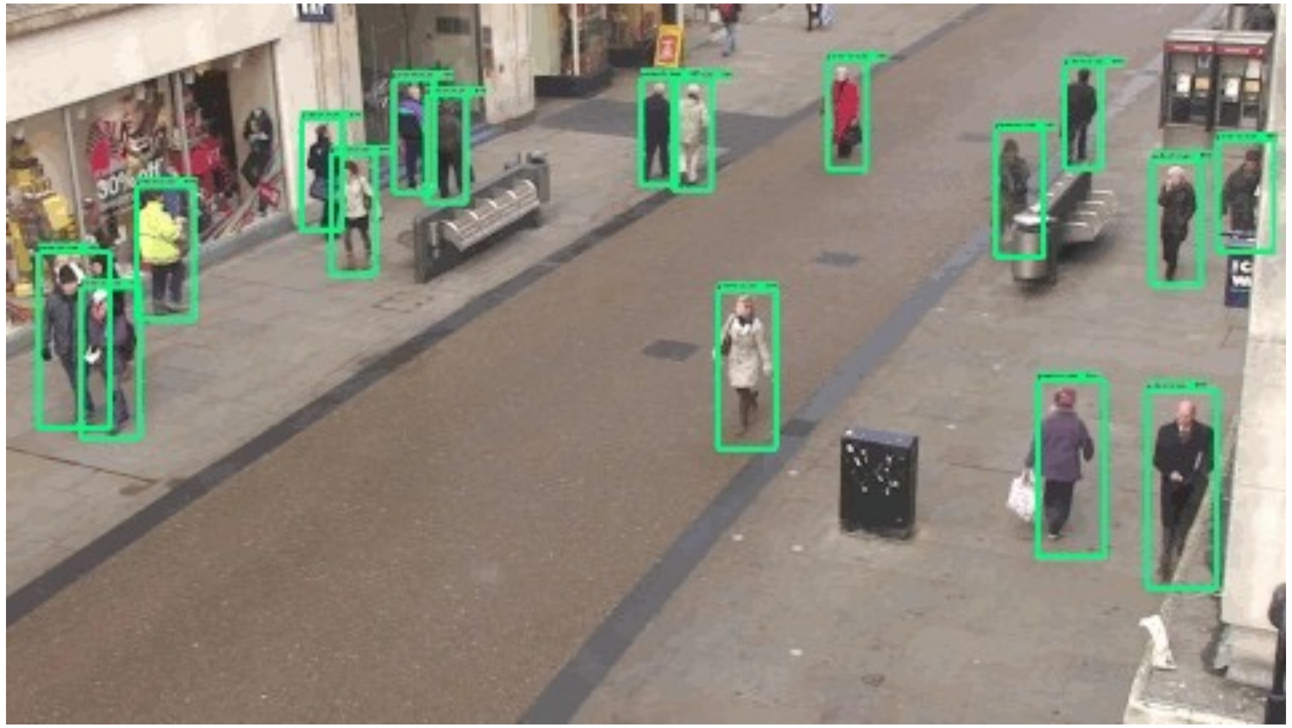

Grande questão atual? Ética!!

Transparência (Transparency)

"Ter acesso a informação de forma a tomar decisões sobre o uso de ML"

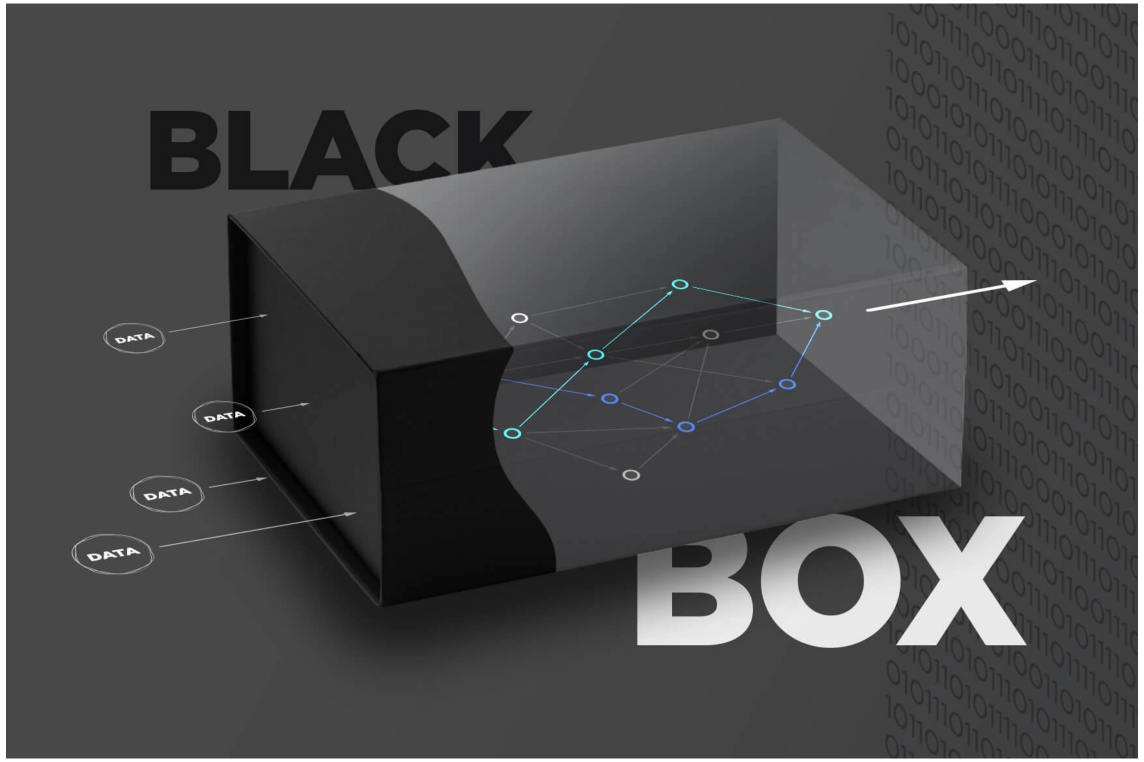

Grande questão atual? Ética!!

Responsabilidade (Accountability)

"Algoritmos e os dados que os conduzem são desenhados e criados por pessoas. Há sempre um humano responsável pelas decisões do algoritmo."

Grande questão atual? Ética!!

Controlo humano e tomada de decisão (Human control and decision making)

"Aplicações com ML devem estar sempre, no final, sob o controlo de um humano ."

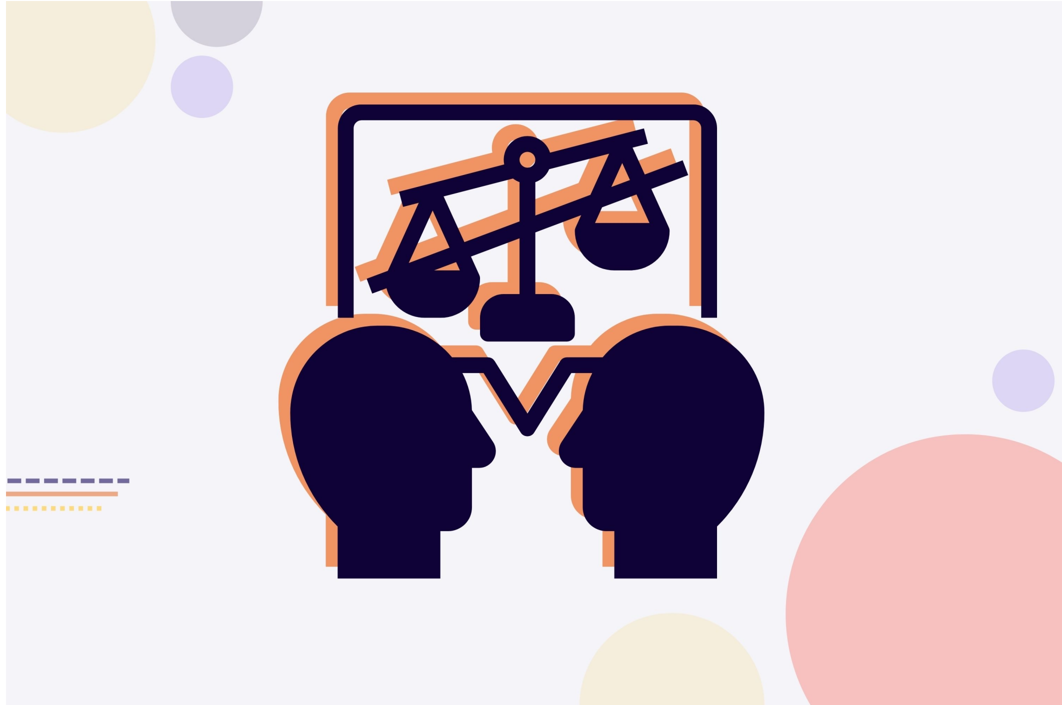

Grande questão atual? Ética!!

Impacto Ambiental e sustentabilidade (Environmental impact and sustainability)

"Métodos de ML complexos treinados em datasets muito grandes consomem muita energia na fase de treino."

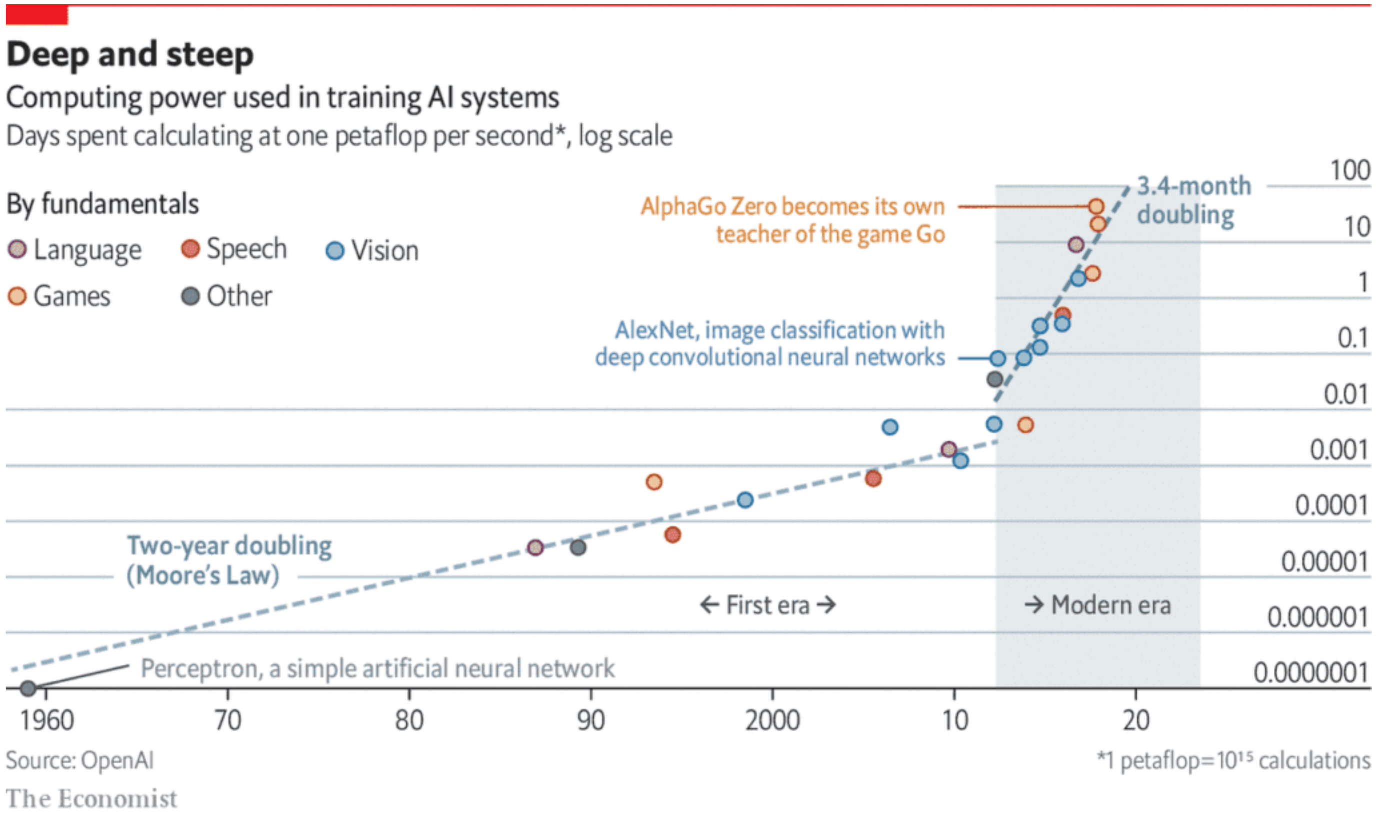

Grande questão atual? Ética!!

Valores da UNESCO:

- Respeito, proteção e promoção dos direitos humanos, liberdades fundamentais e dignidade.
- Ambiente e ecossistemas prósperos
- Assegurar diversidade e inclusão
- Sociedades vivendo em paz, justas e interconectadas

Compromissos na escolha de uma técnica de ML

- Precisão da previsão ou Interpretabilidade
  (**accuracy**) (**inference**)
- Bom ajuste contra Sobreajuste ou Ajuste Insuficiente
  (**good fit**) (**overfit**) (**underfit**)
- Paramêtrico ou não-paramêtrico

Compromissos na escolha de uma técnica de ML

- Precisão da previsão ou Interpretabilidade
  (**accuracy**) (**inference**)
- Bom ajuste contra Sobreajuste ou Ajuste Insuficiente
  (**good fit**) (**overfit**) (**underfit**)
- Paramêtrico ou não-paramêtrico

- Regressão ou classificação

Flexibilidade ou Interpretabilidade

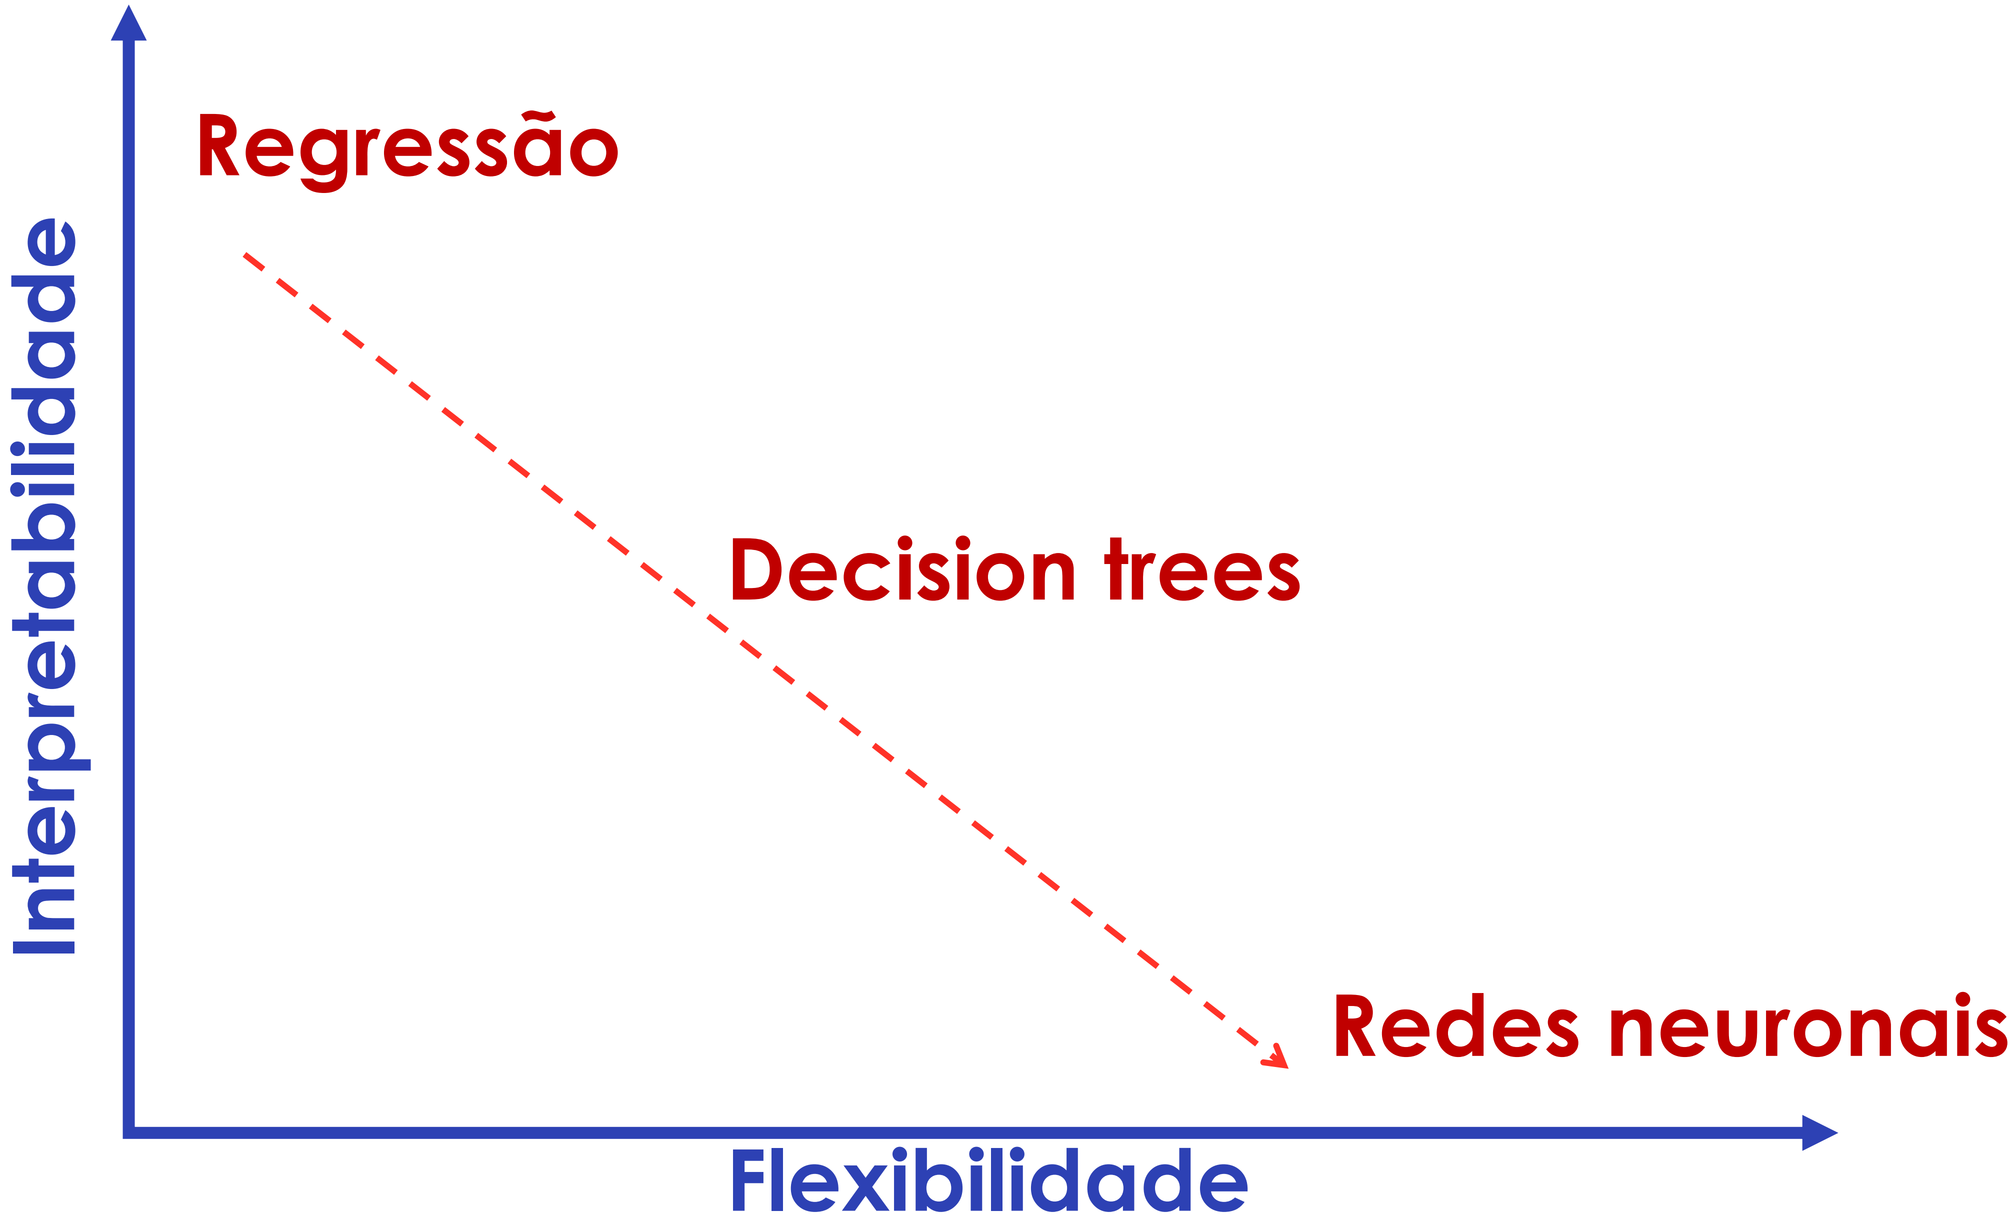

Como fazer um bom ajuste?

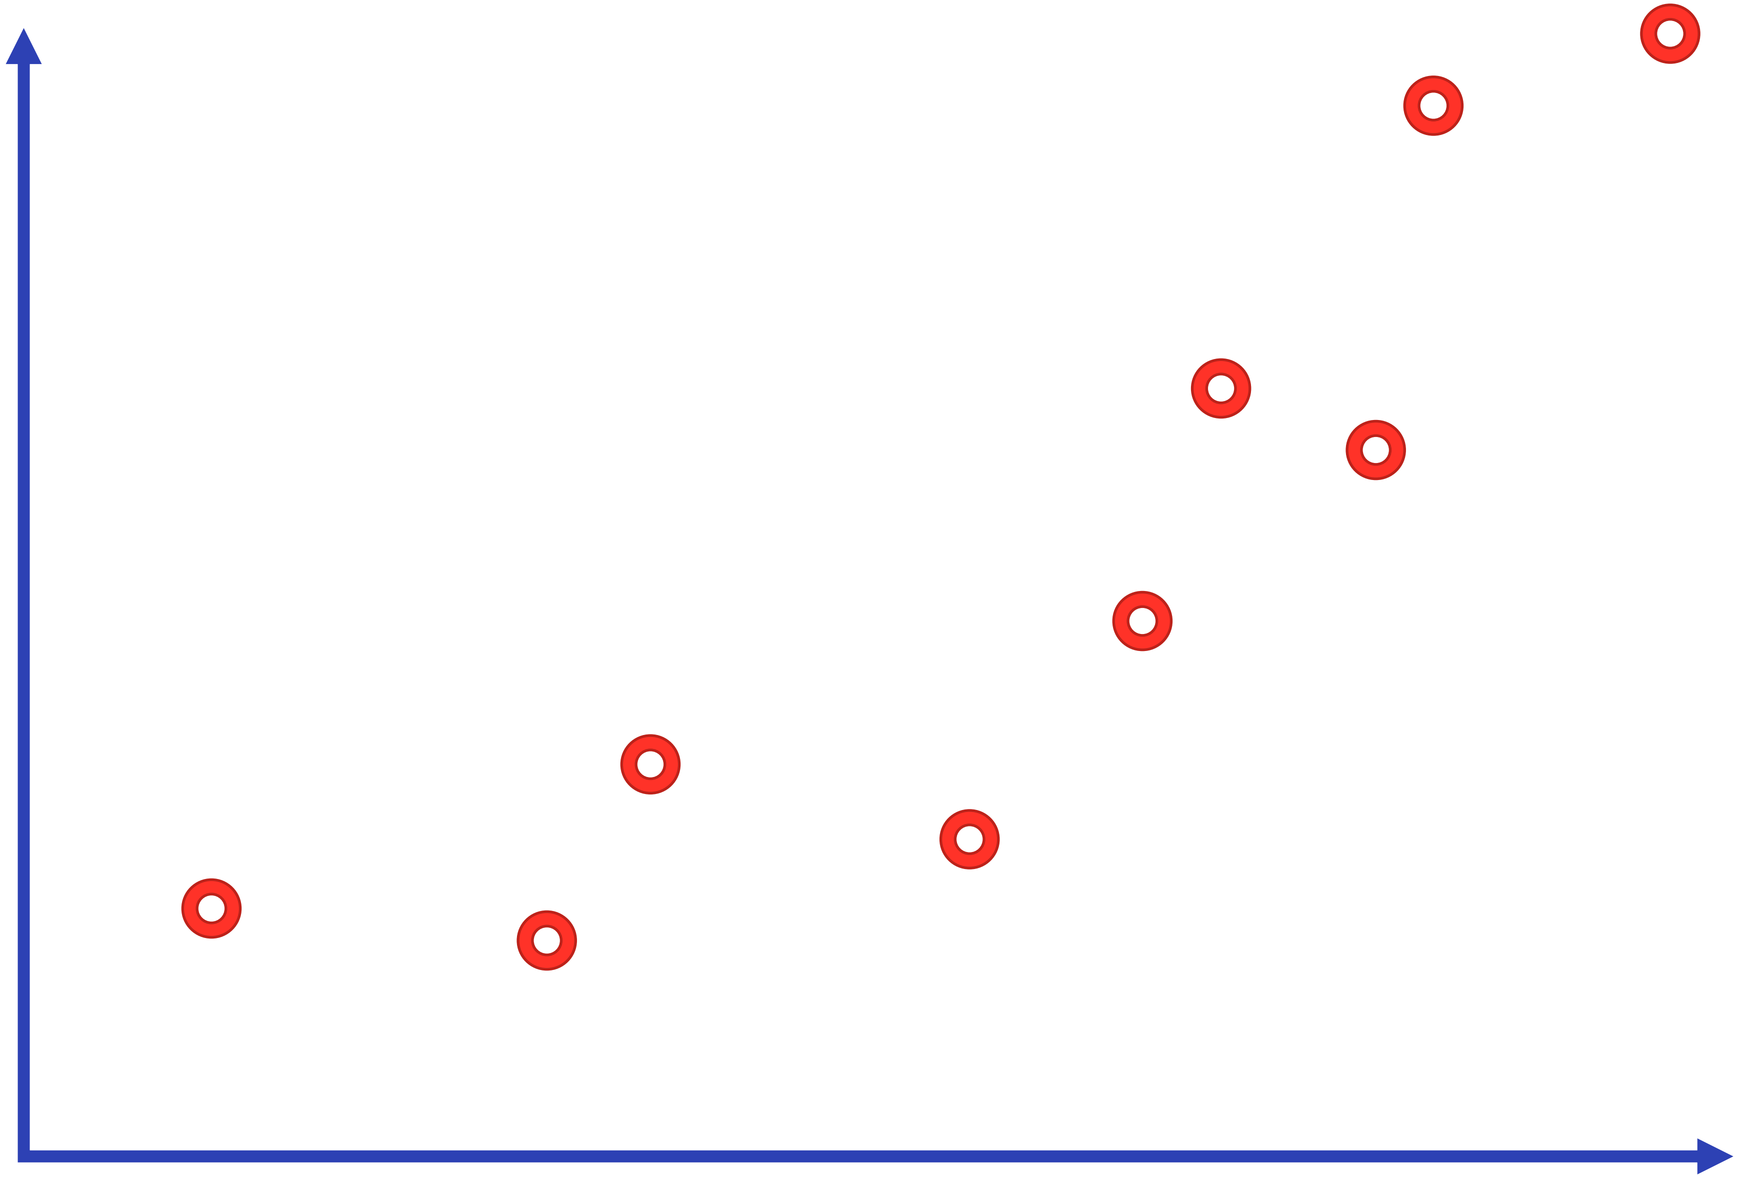

Como fazer um bom ajuste?

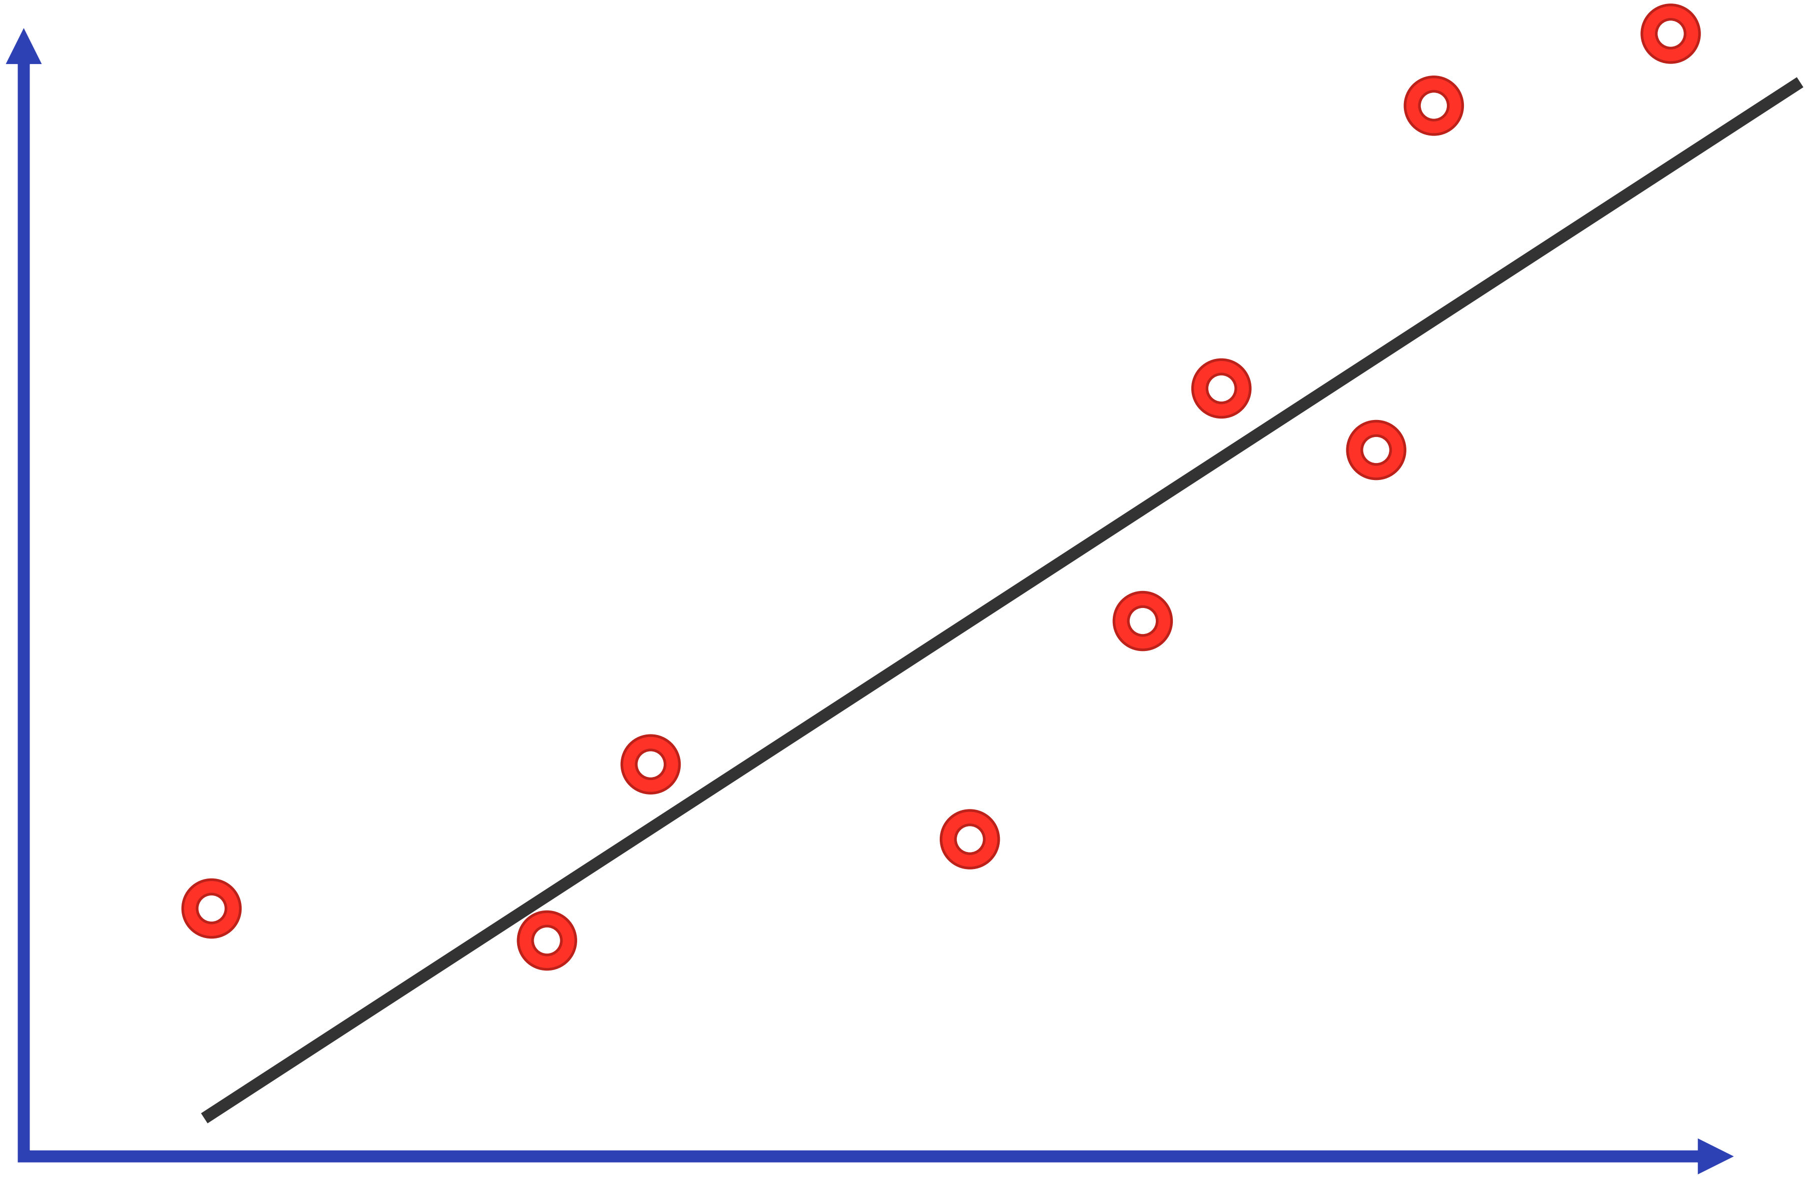

Como fazer um bom ajuste?

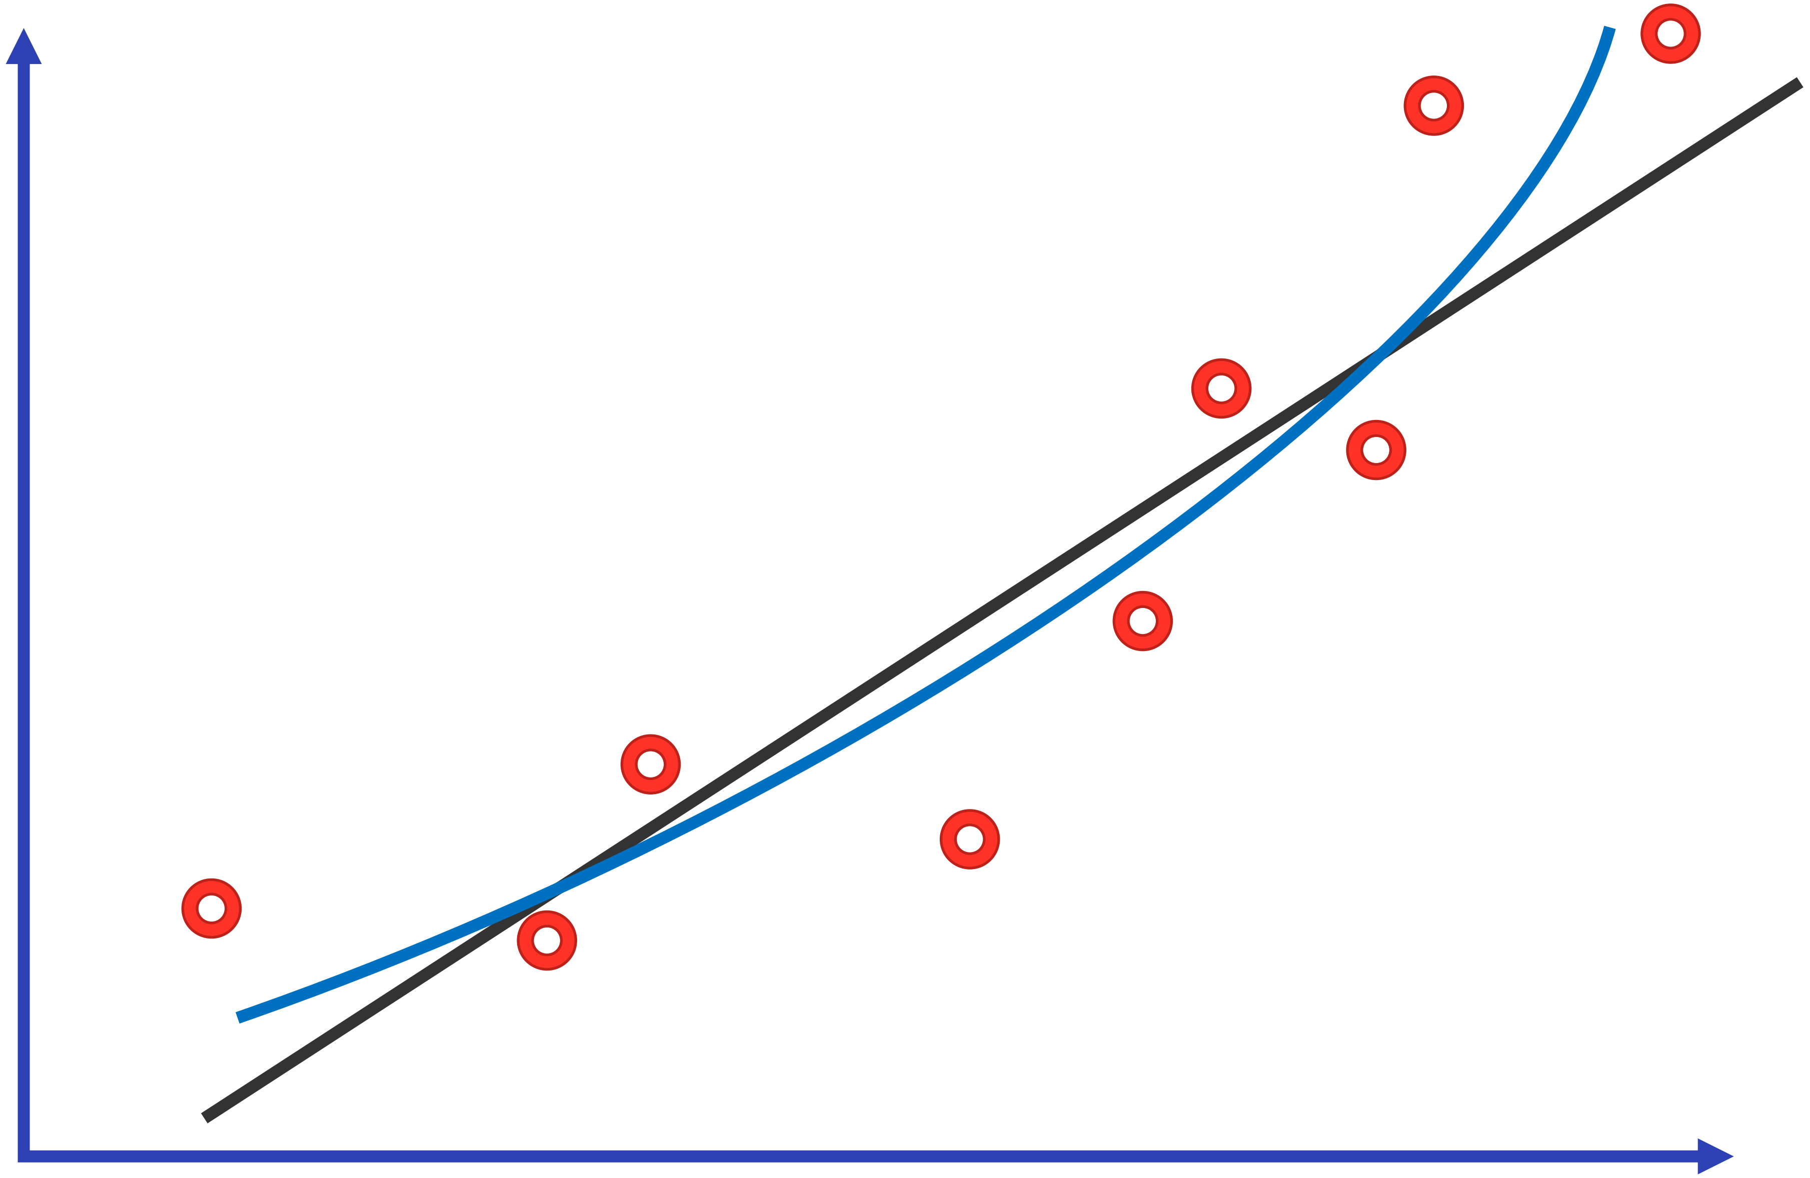

Como fazer um bom ajuste?

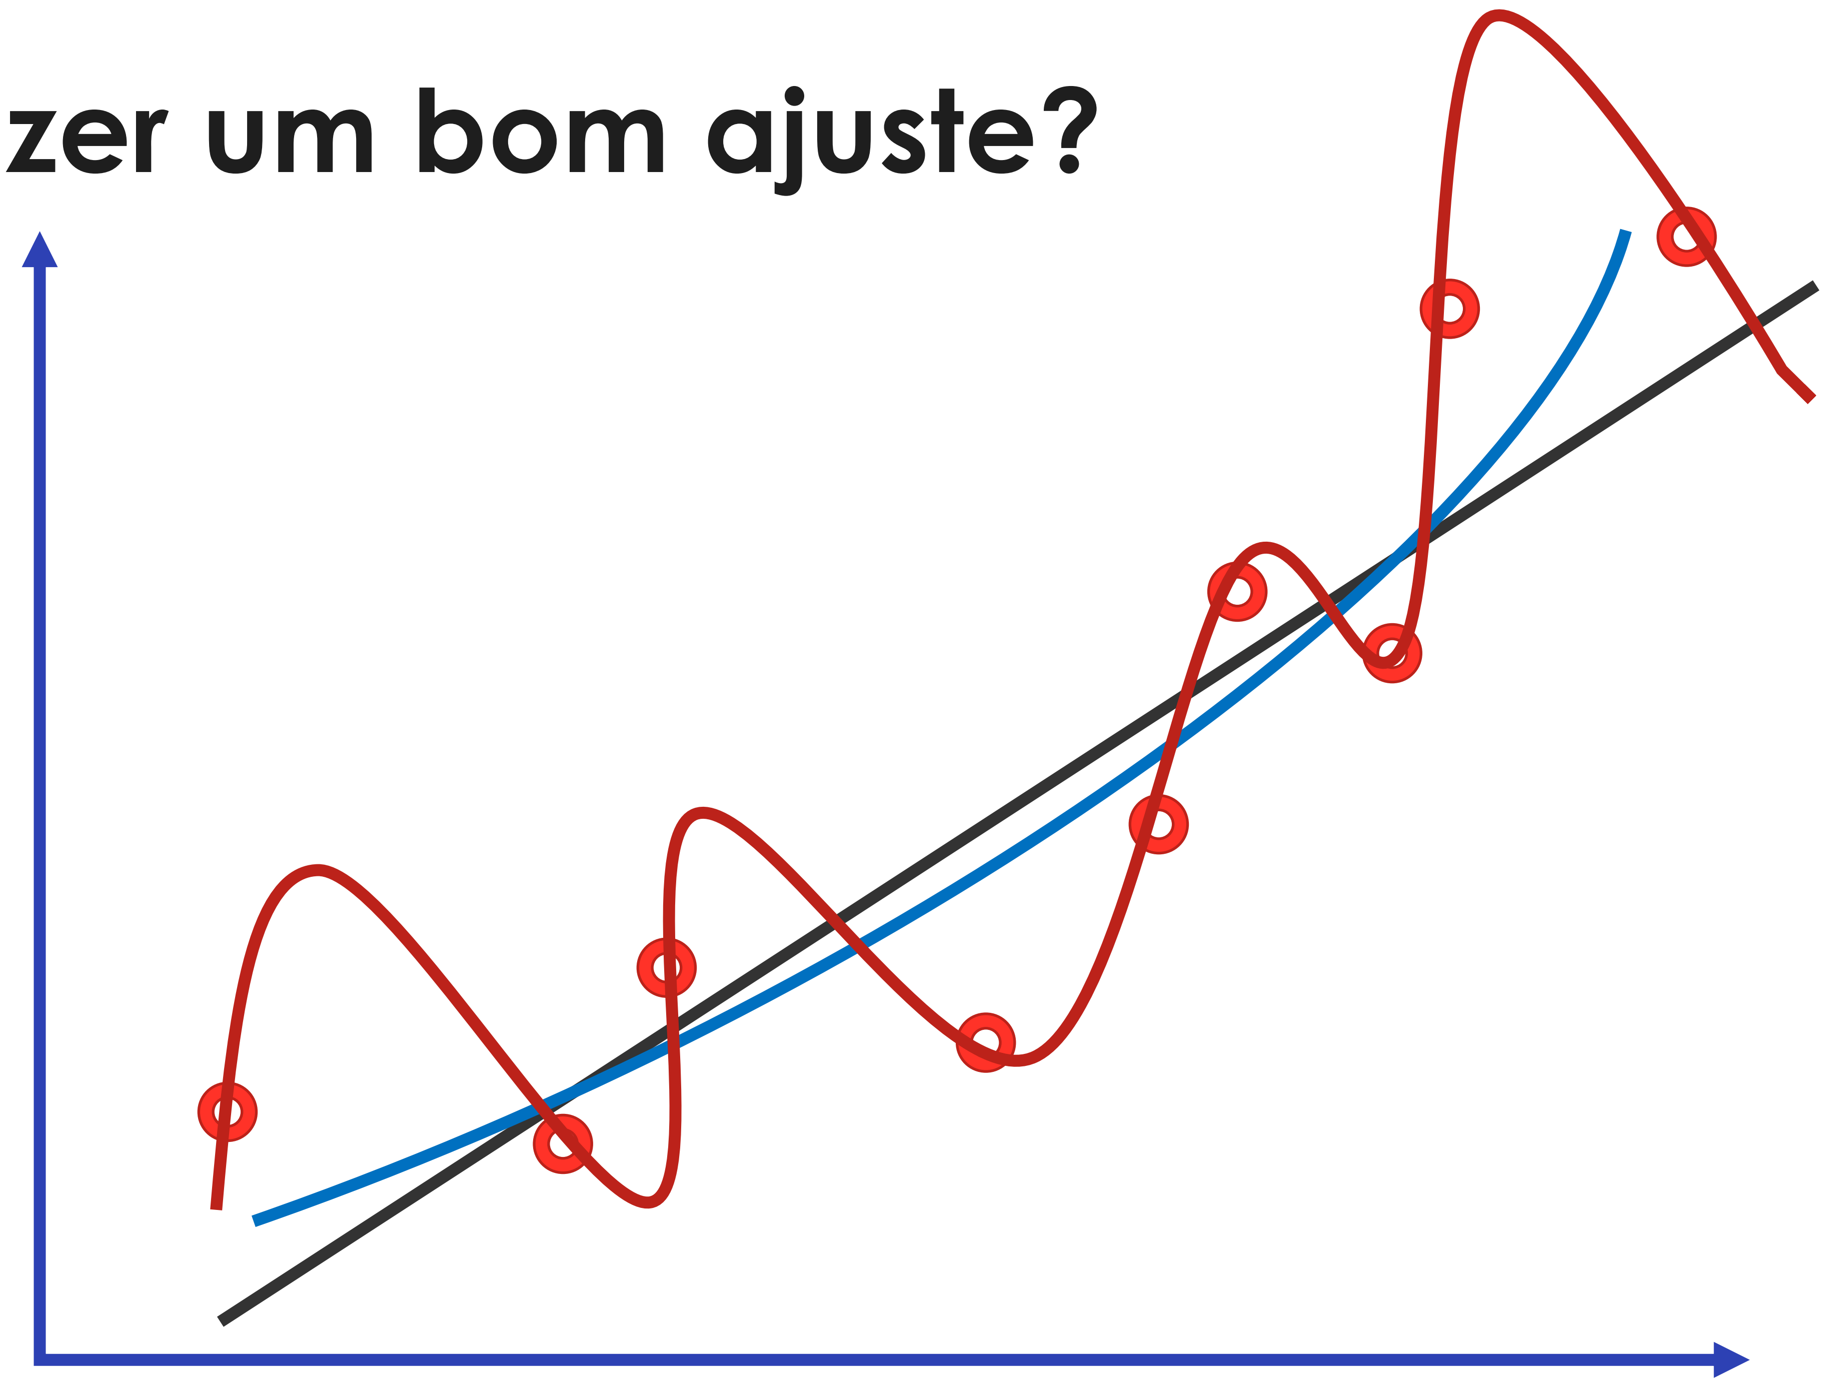

Como verificar a qualidade do ajuste?

ERRO QUADRÁTICO MÉDIO (MSE)
= MÉDIA[(REAL(X) – MODELO(x))²]

Como verificar a qualidade do ajuste?

ERRO QUADRÁTICO MÉDIO (MSE) = MÉDIA[(REAL(X) – MODELO(x))²]

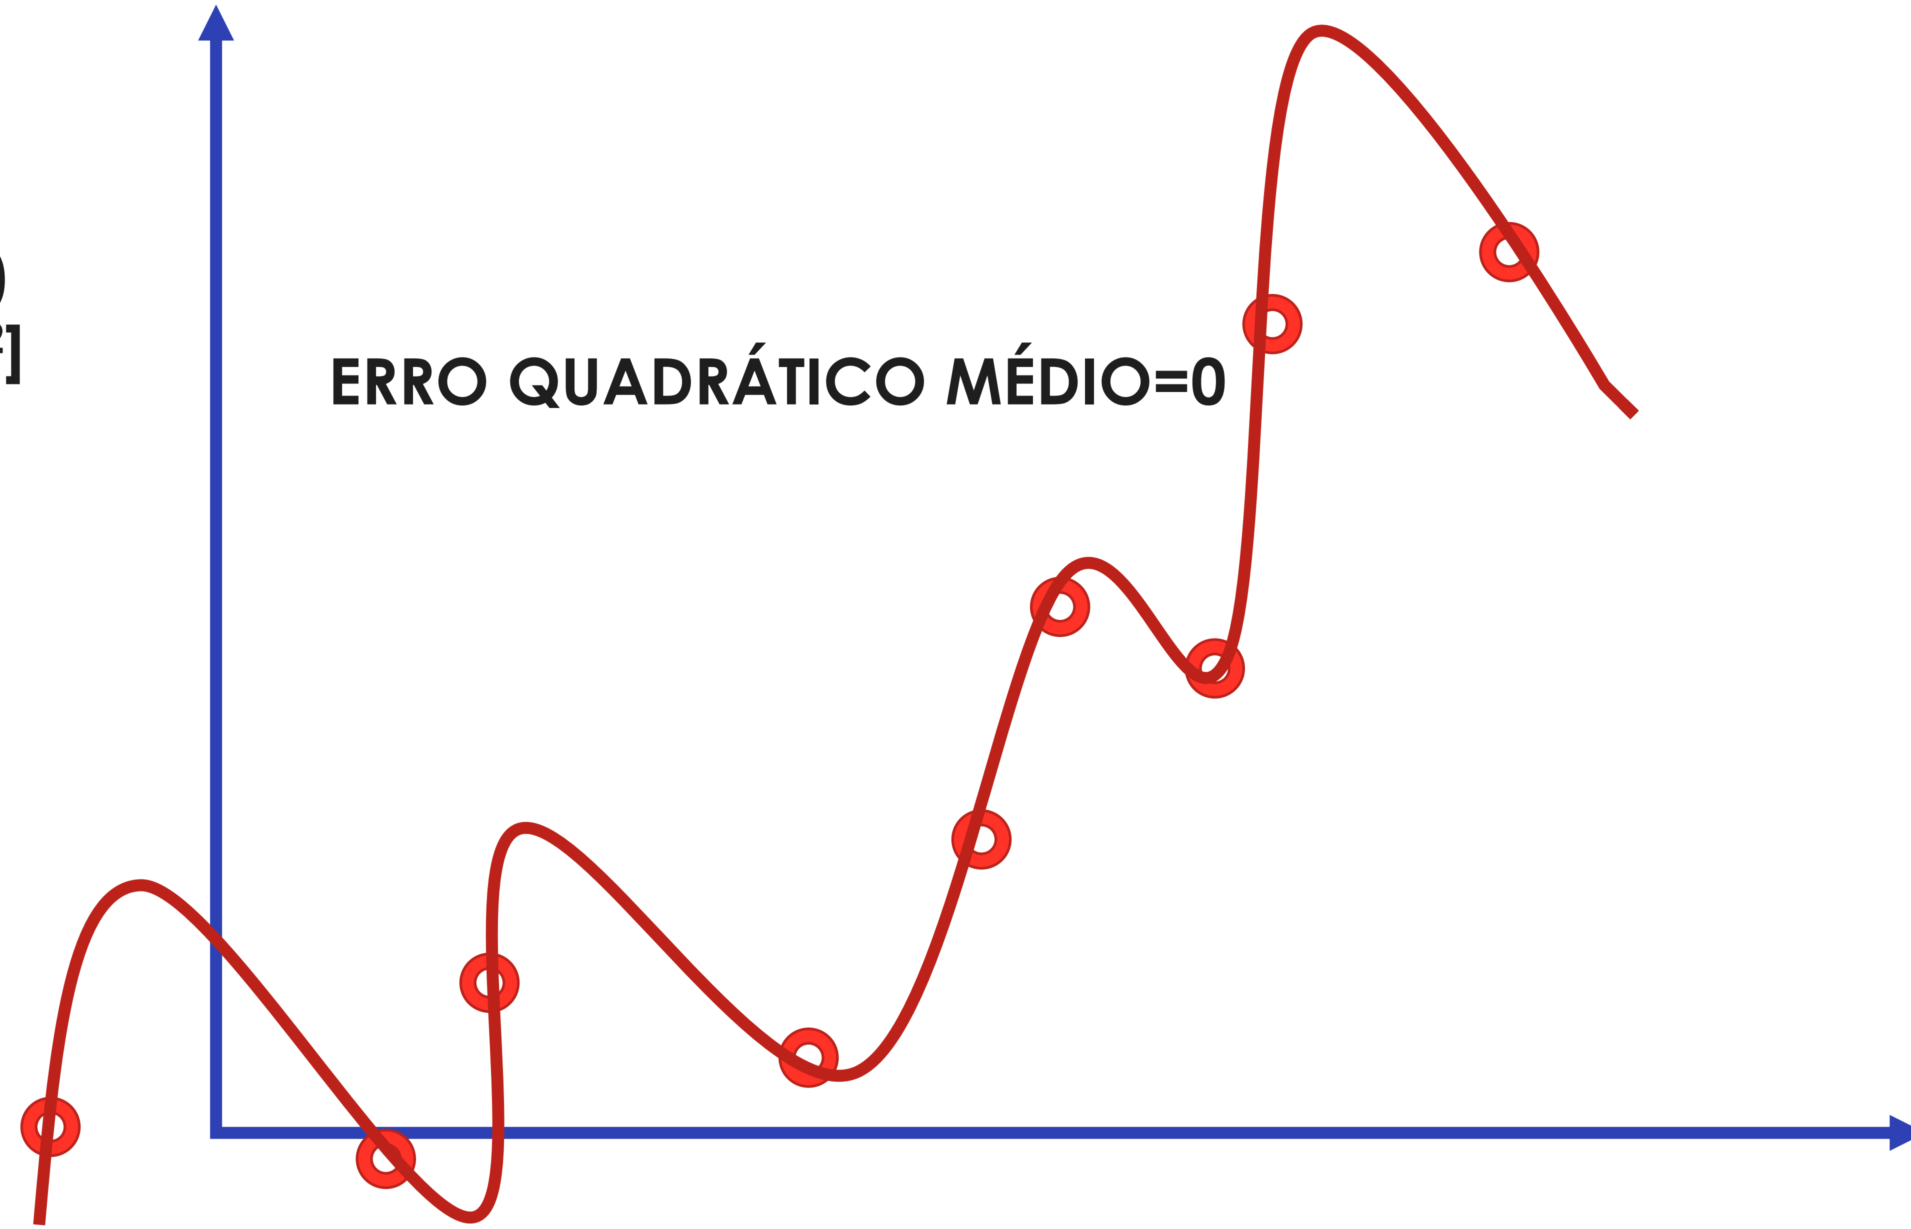

Separar os dados de treino dos dados de teste

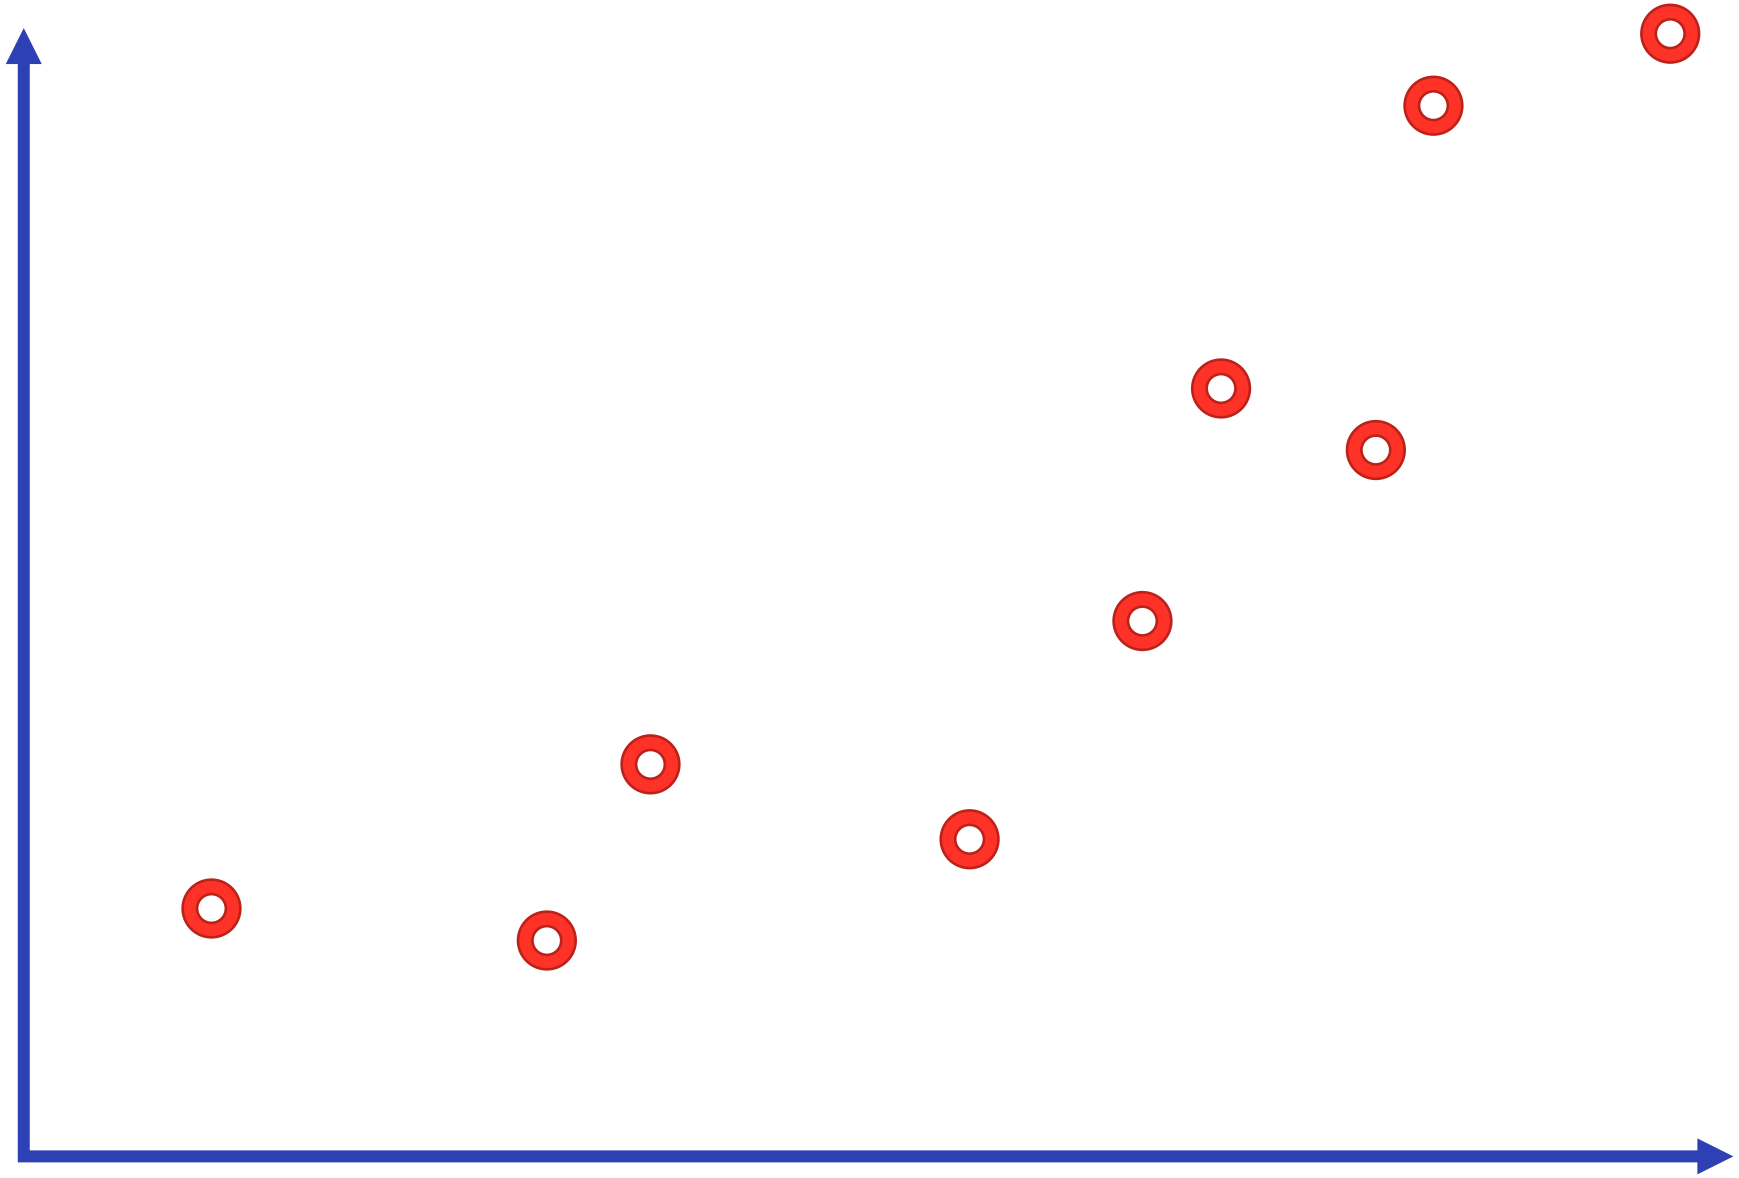

Separar os dados de treino dos dados de teste

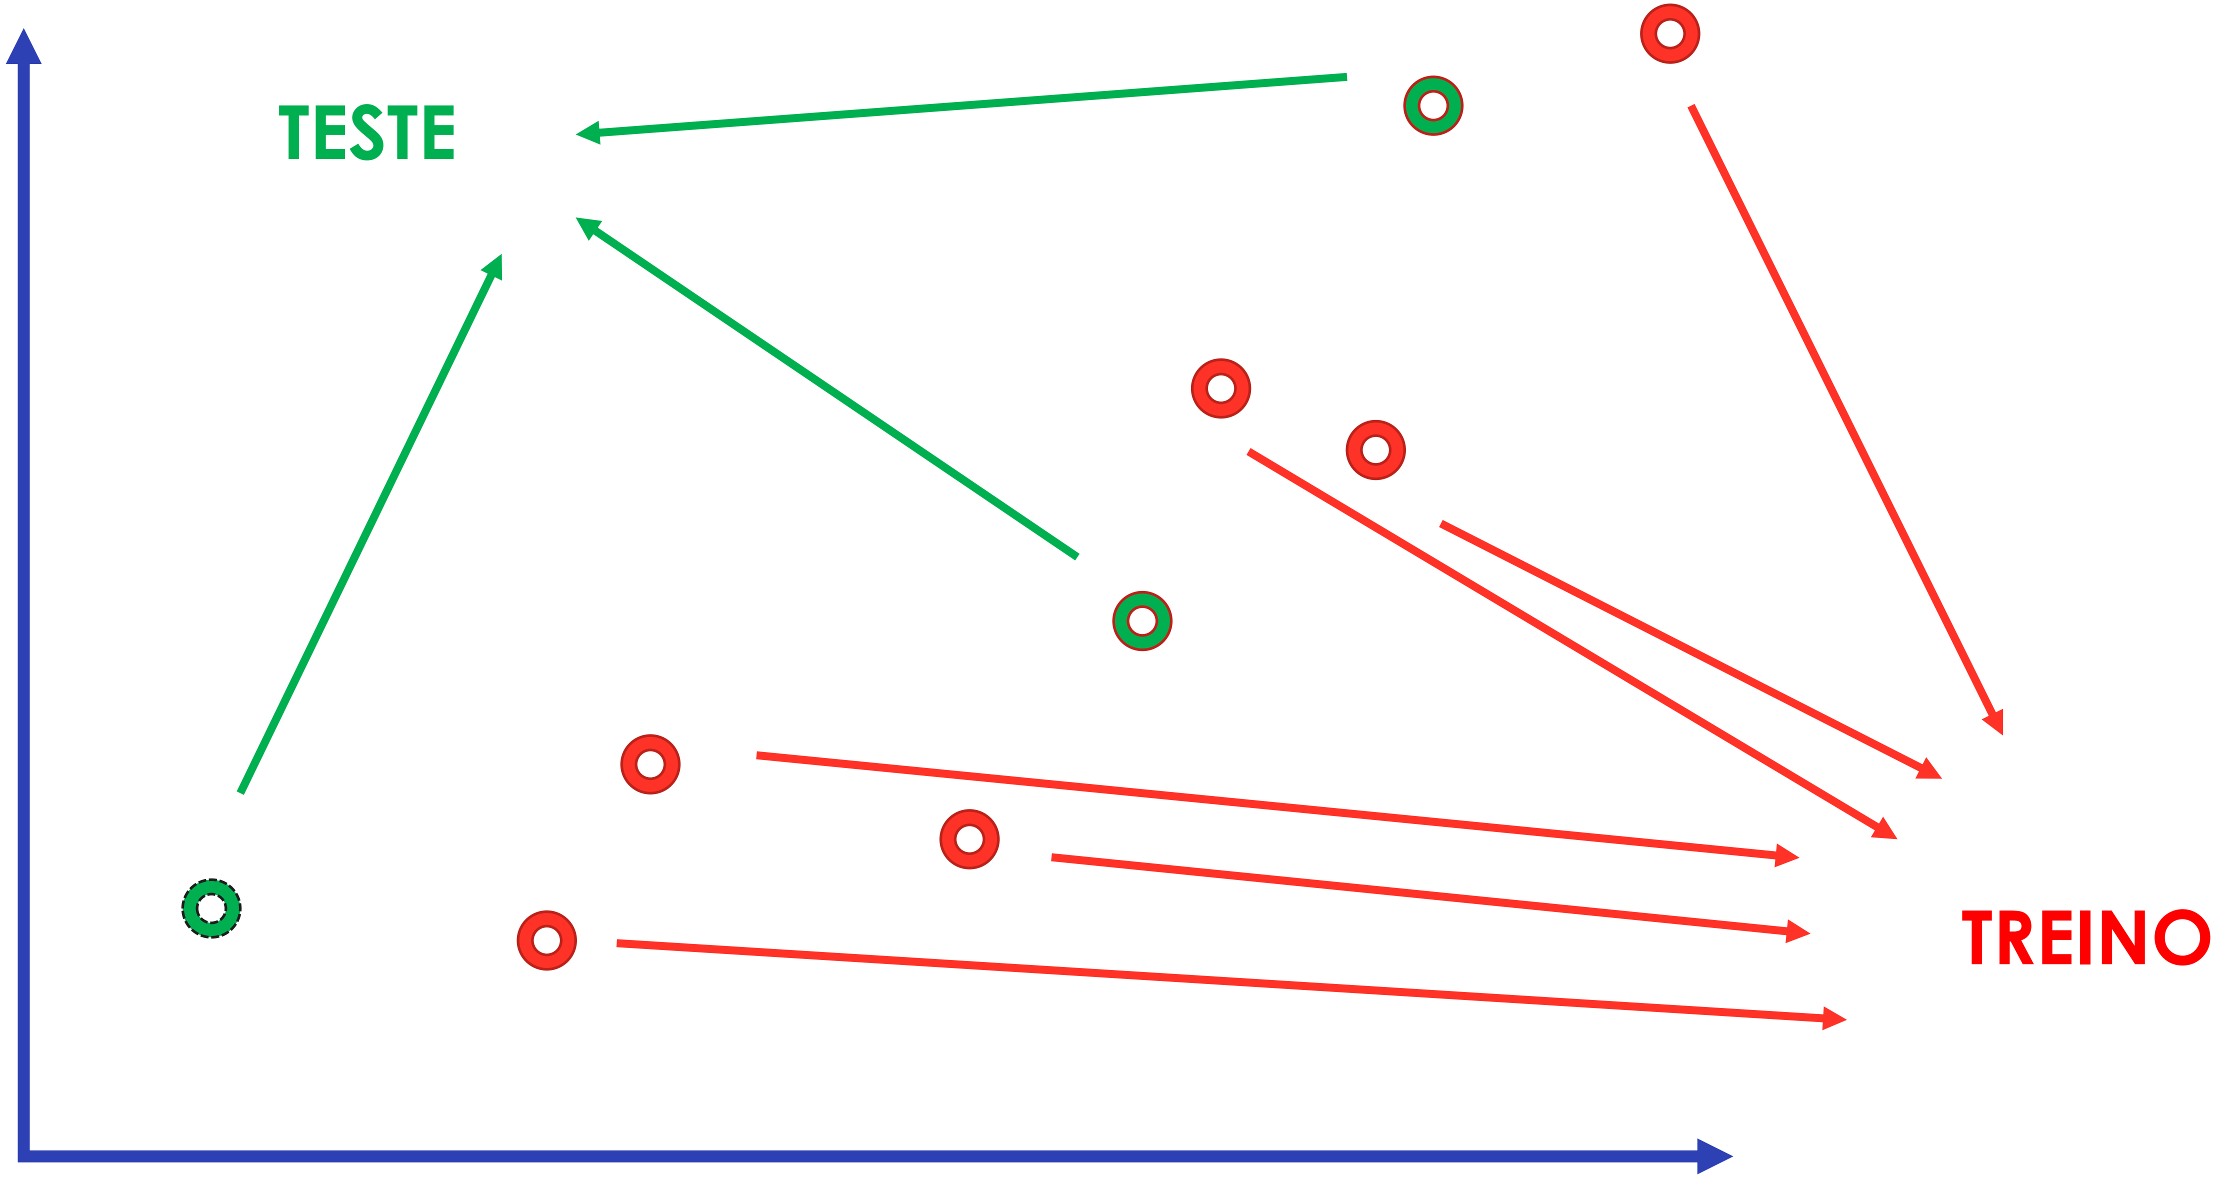

Separar os dados de treino dos dados de teste

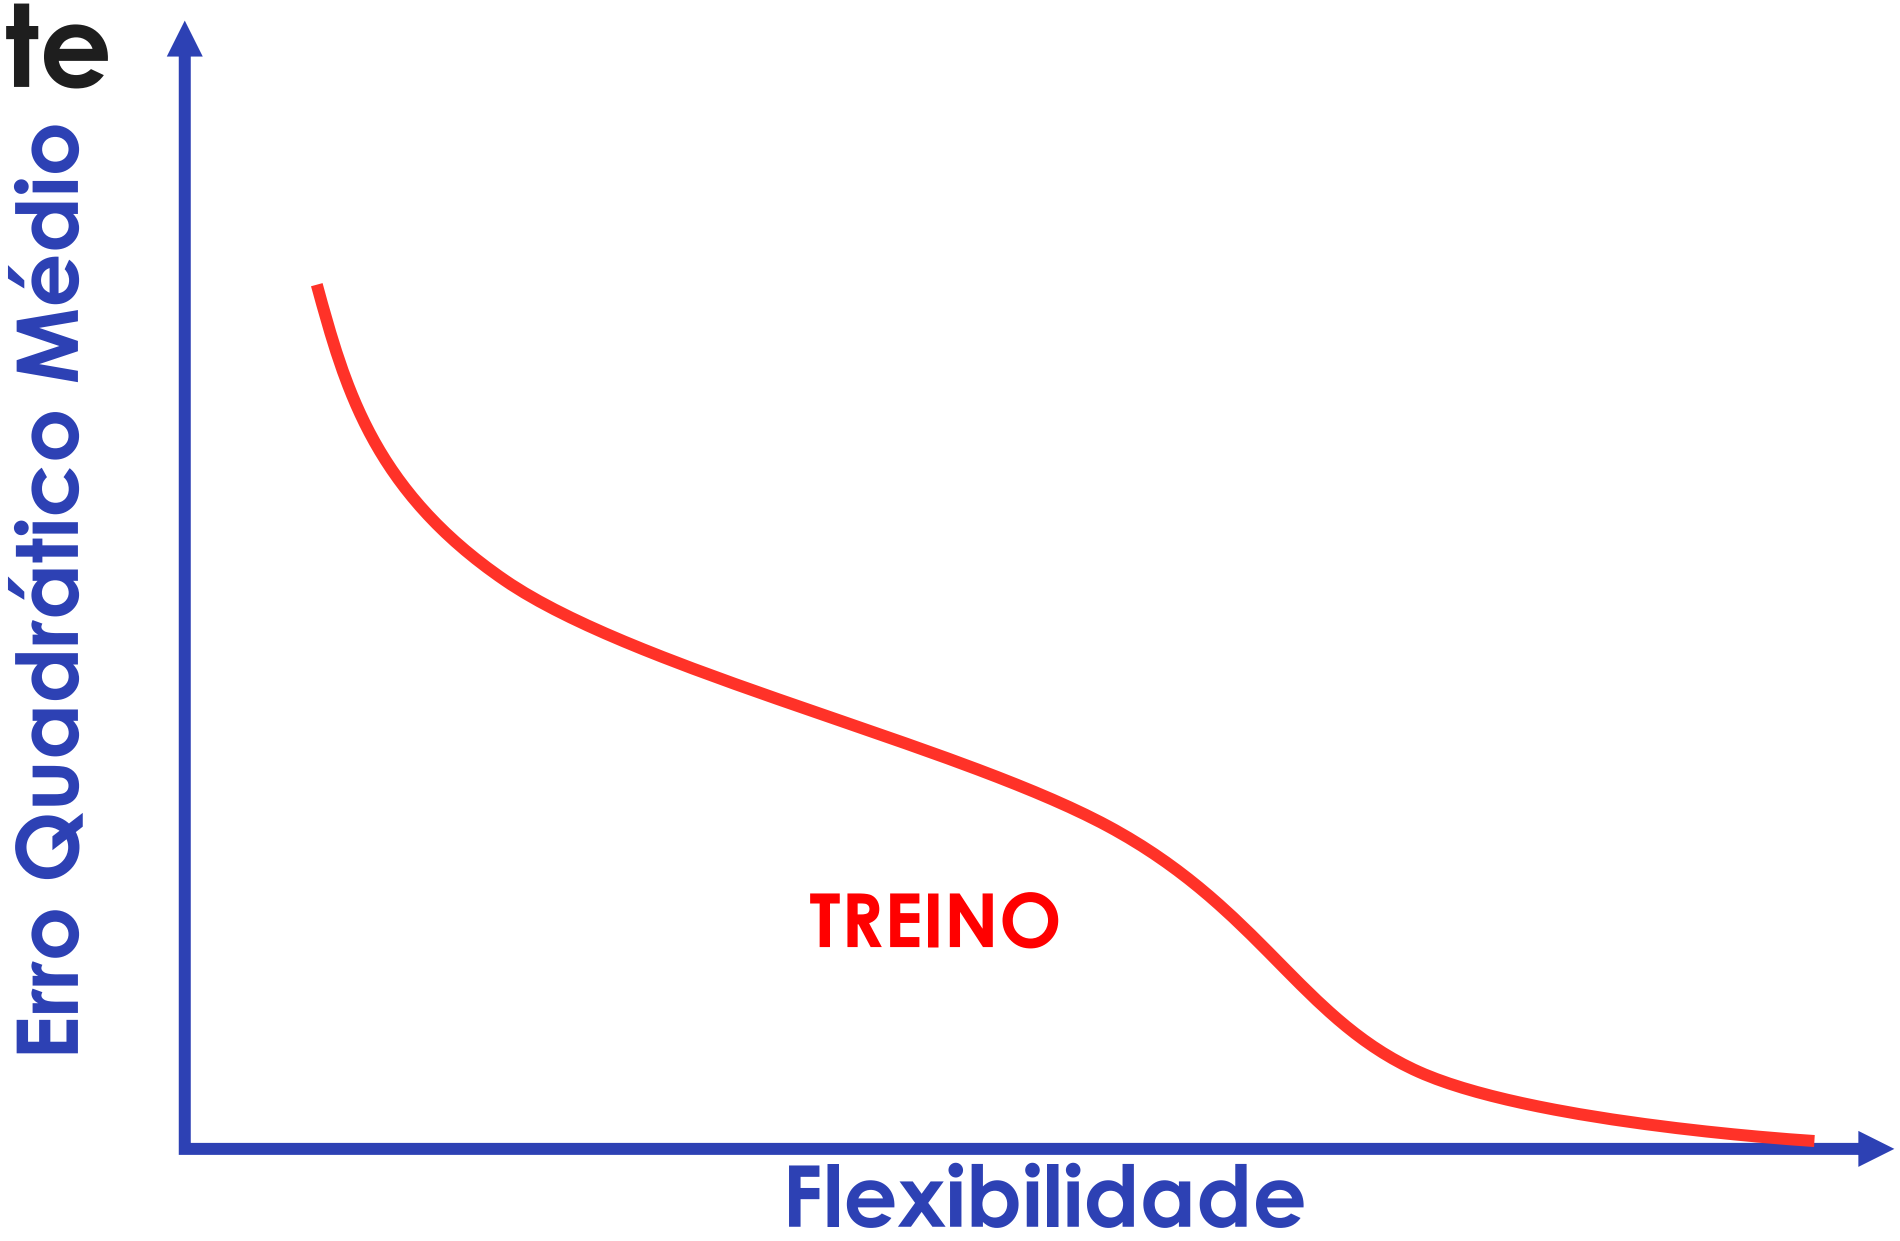

Separar os dados de treino dos dados de teste

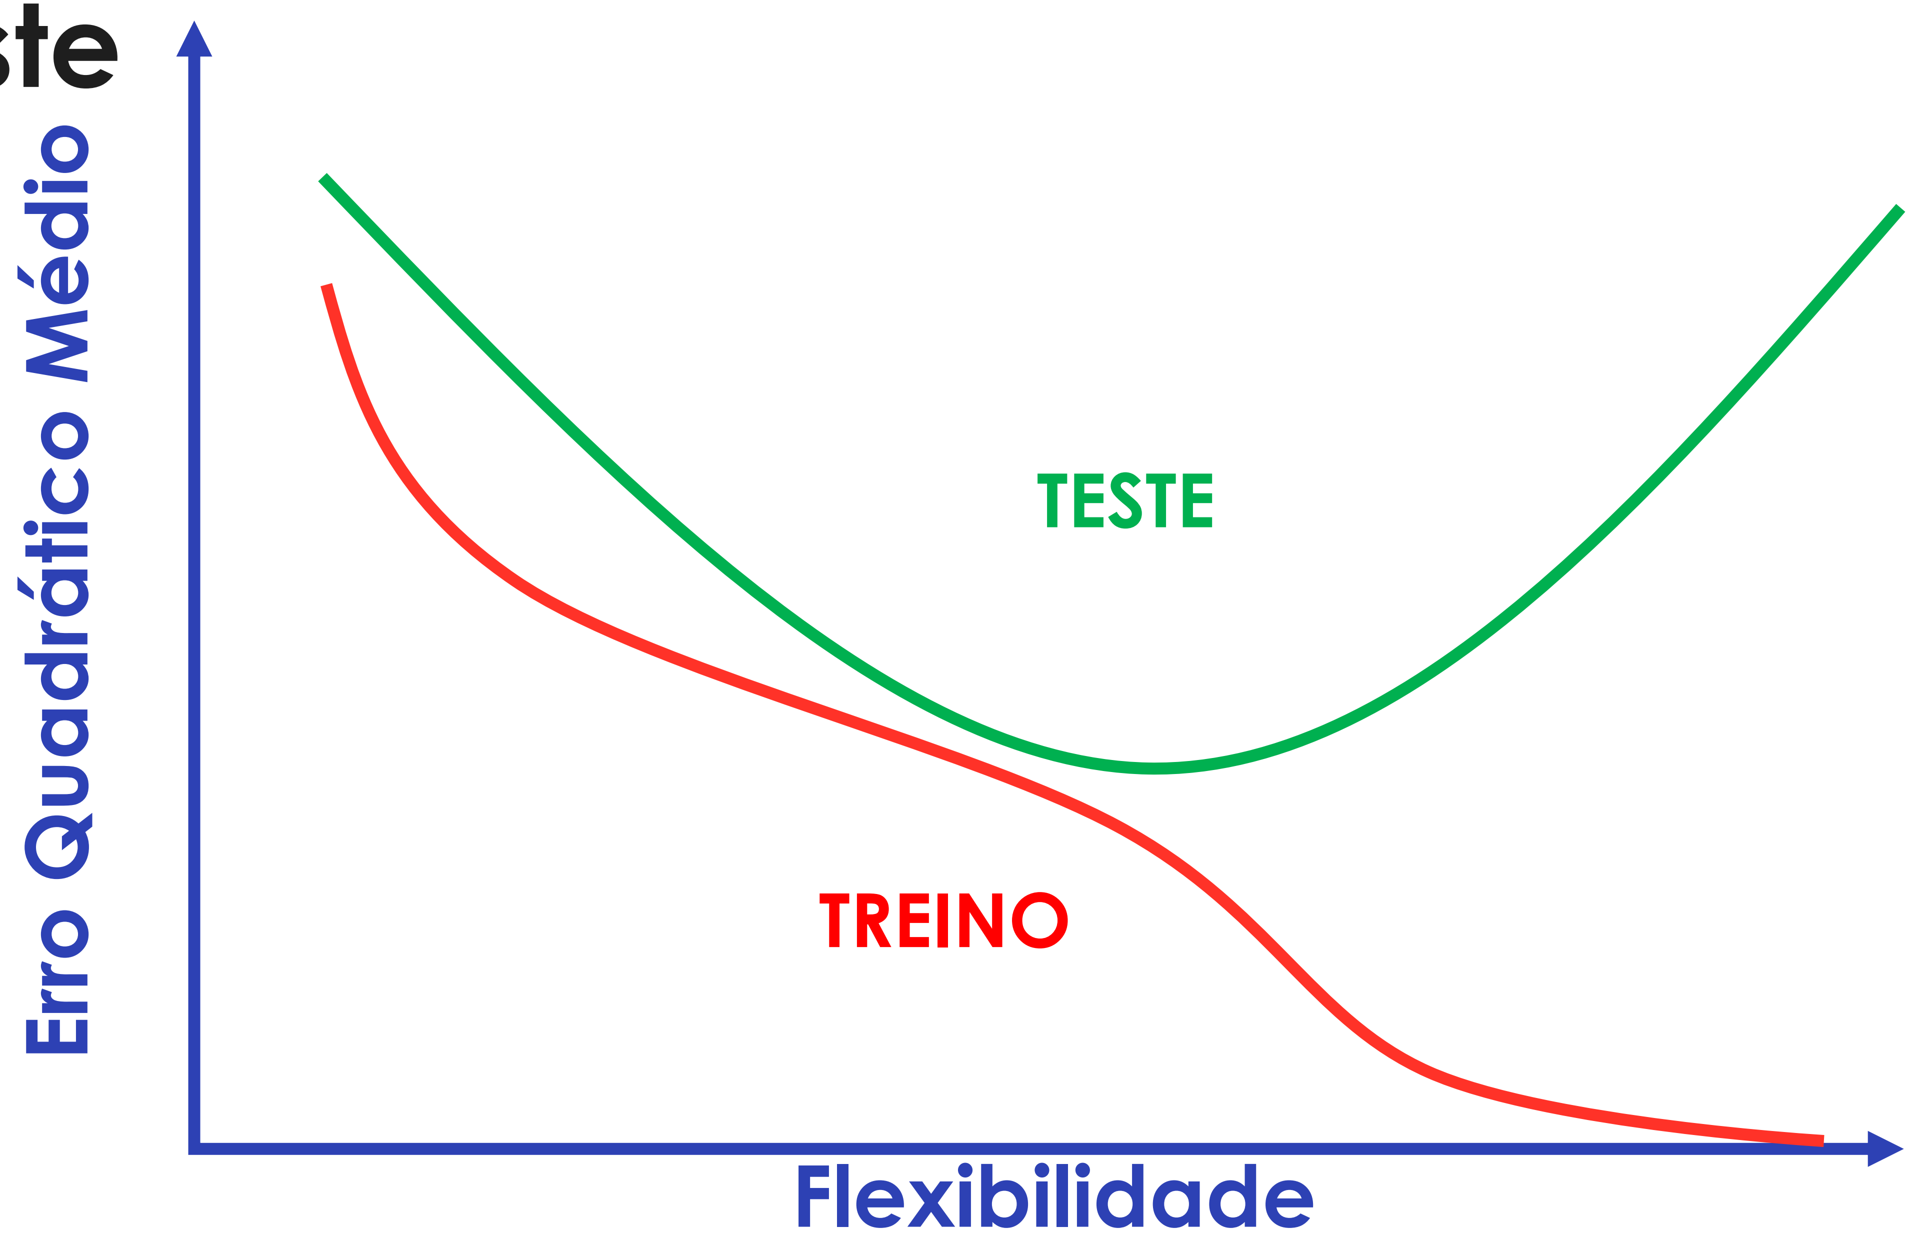

Regressão ou Classificação

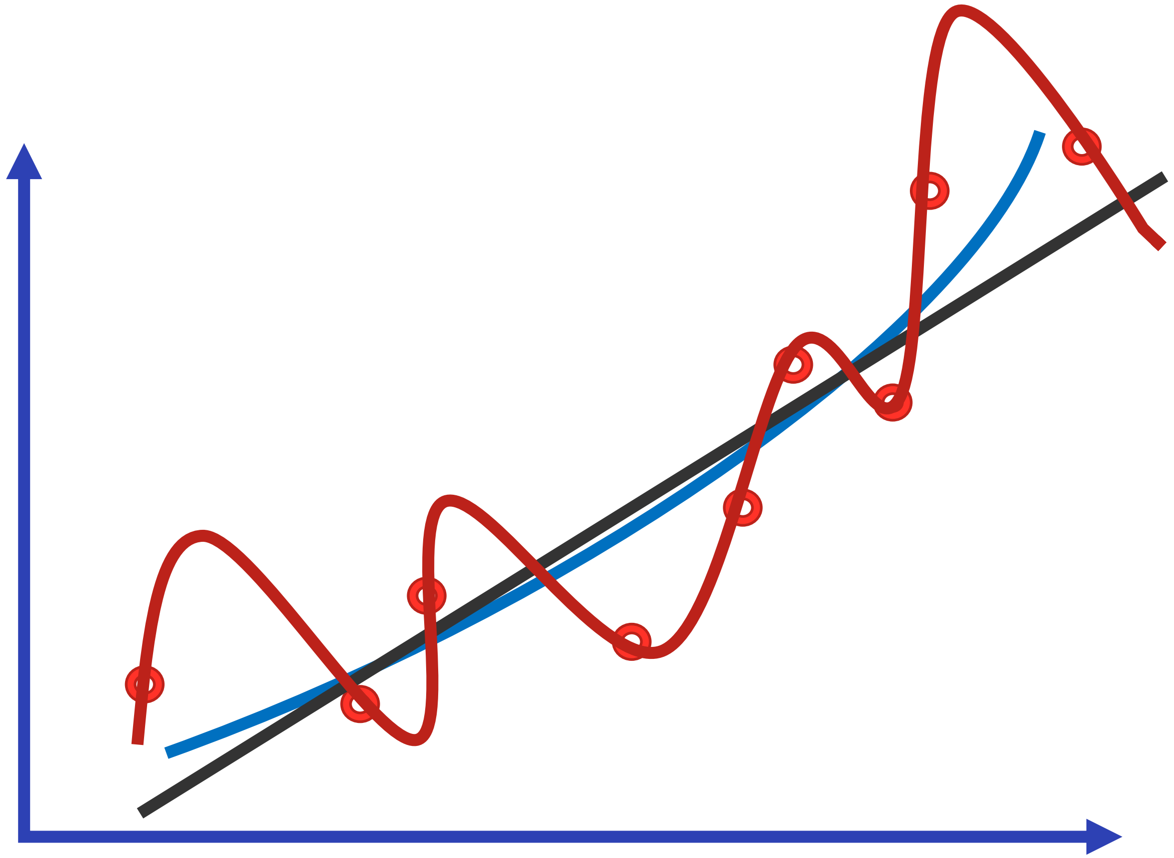

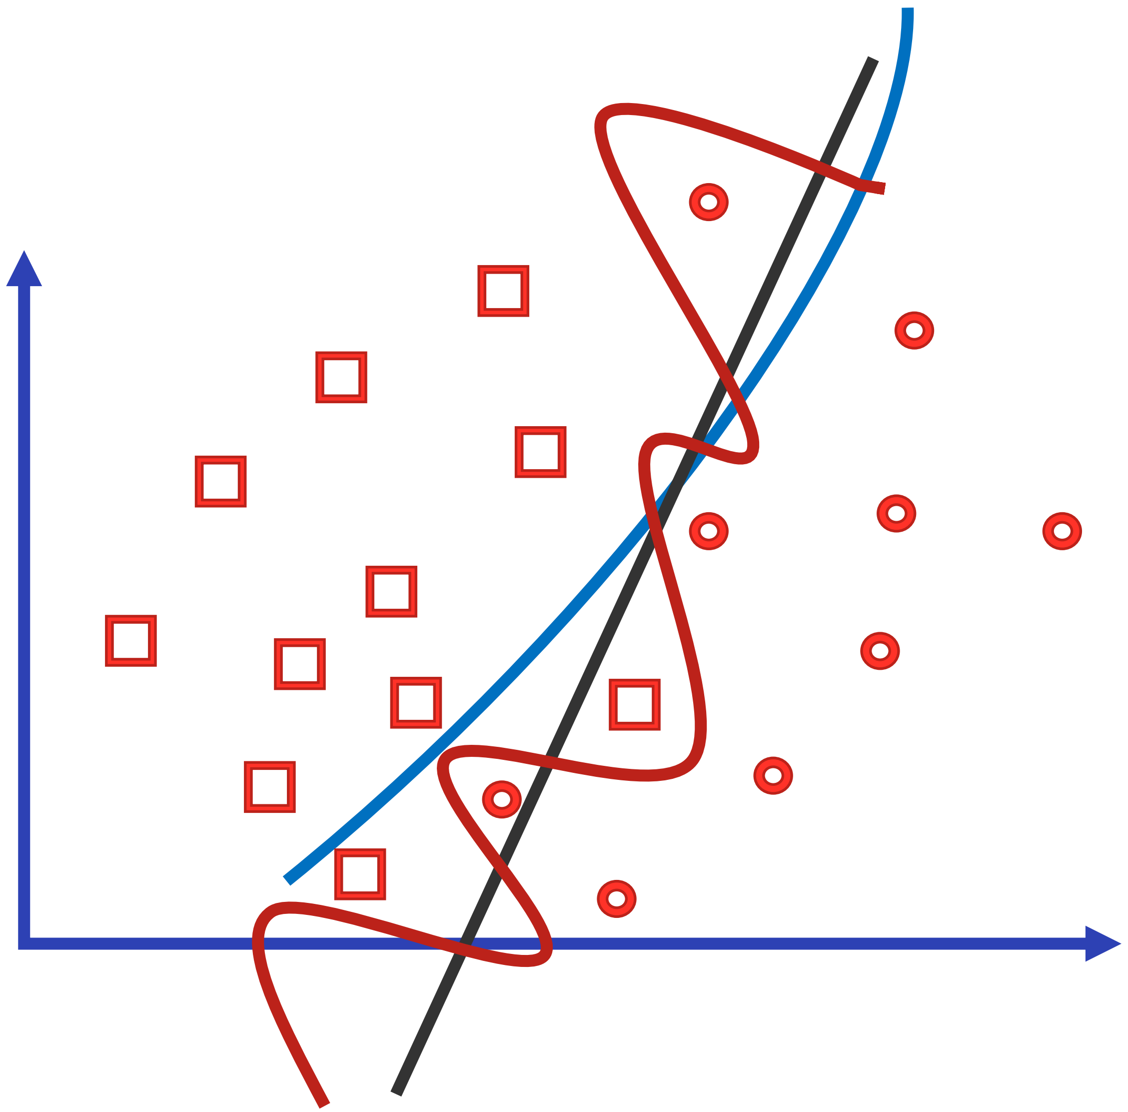

Como verificar a qualidade da classificação?

TAXA DE ERRO = NÚMERO DE ENGANOS[(REAL(X) ≠ MODELO(x))]/TOTAL DE TESTES

Aprendizagem supervisionada e não supervisionada

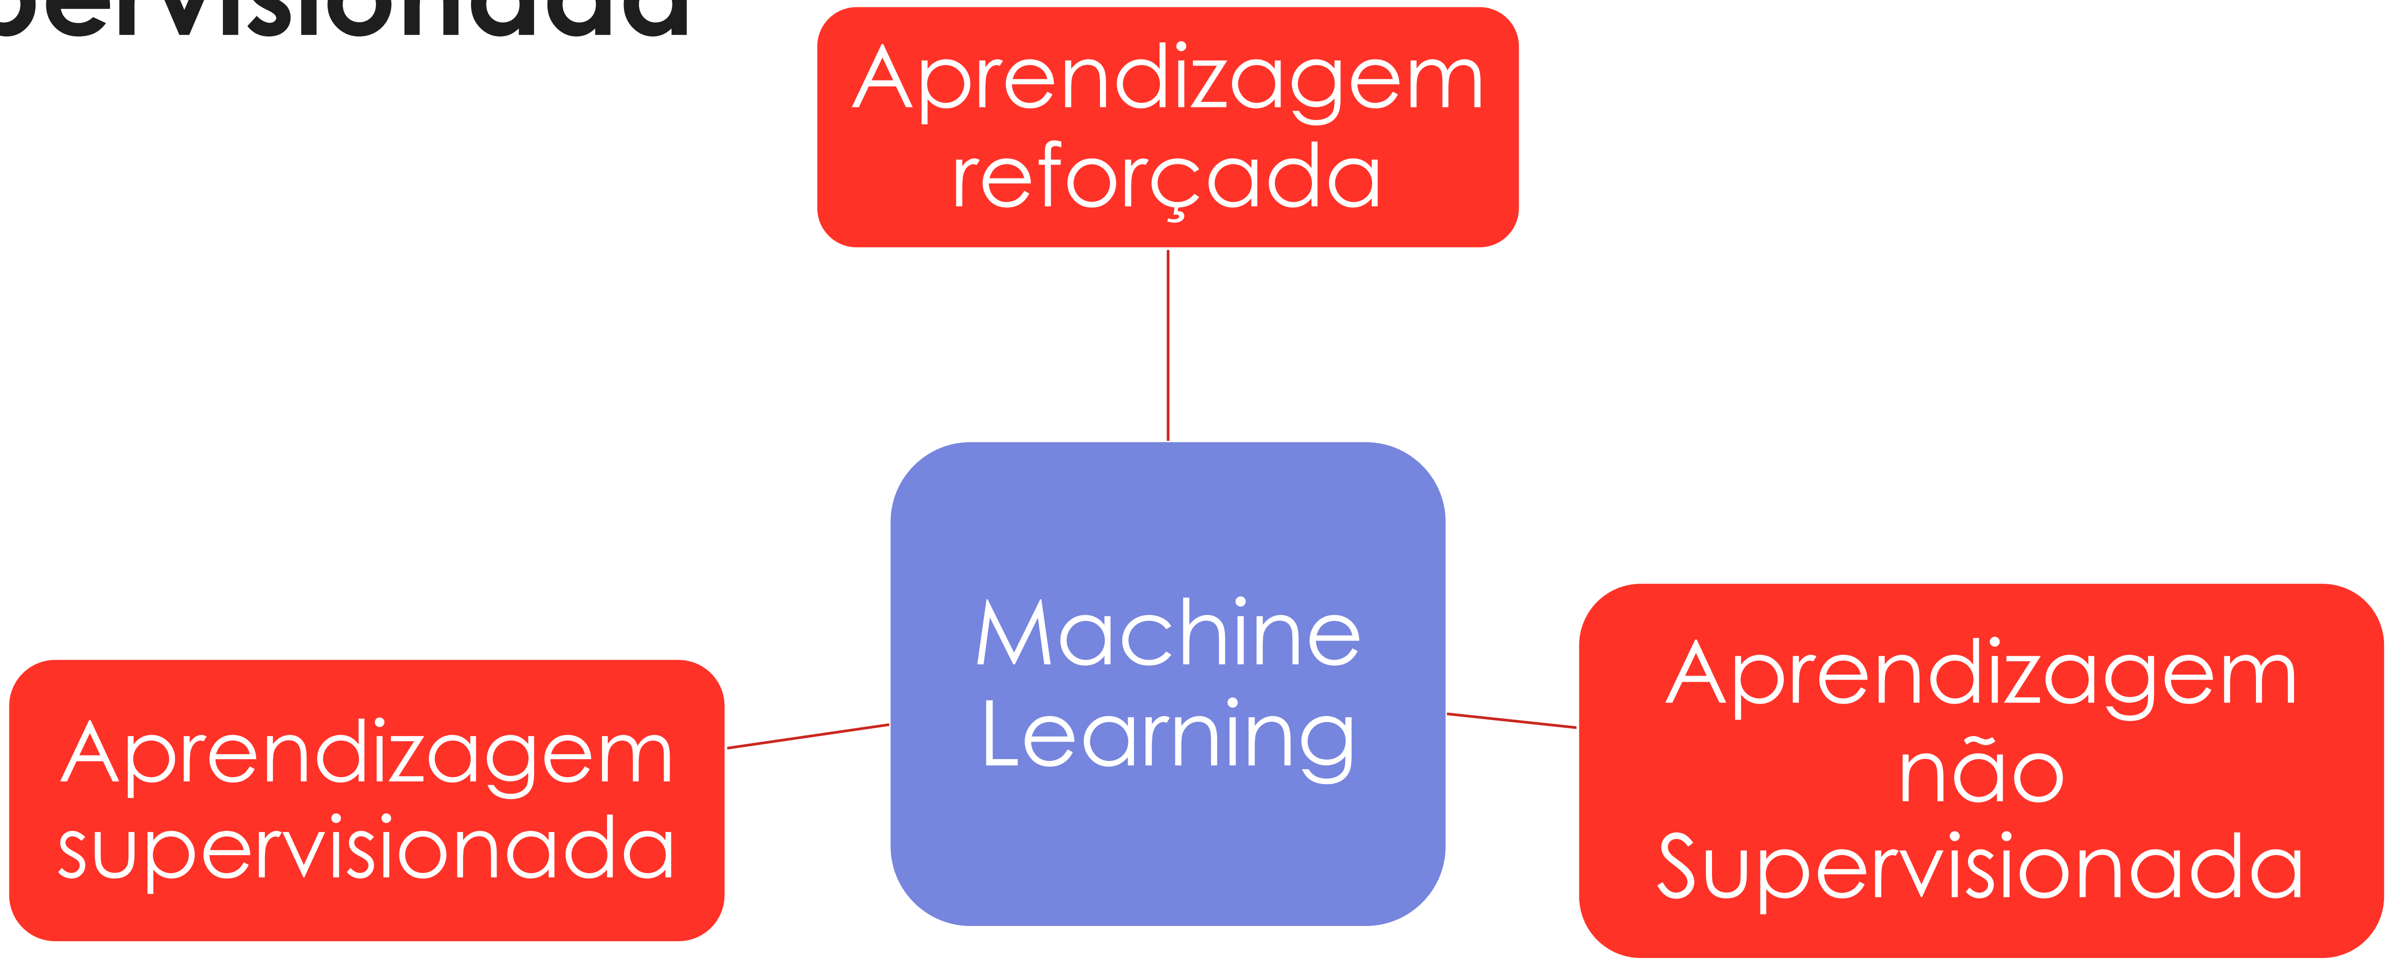

Supervisionada

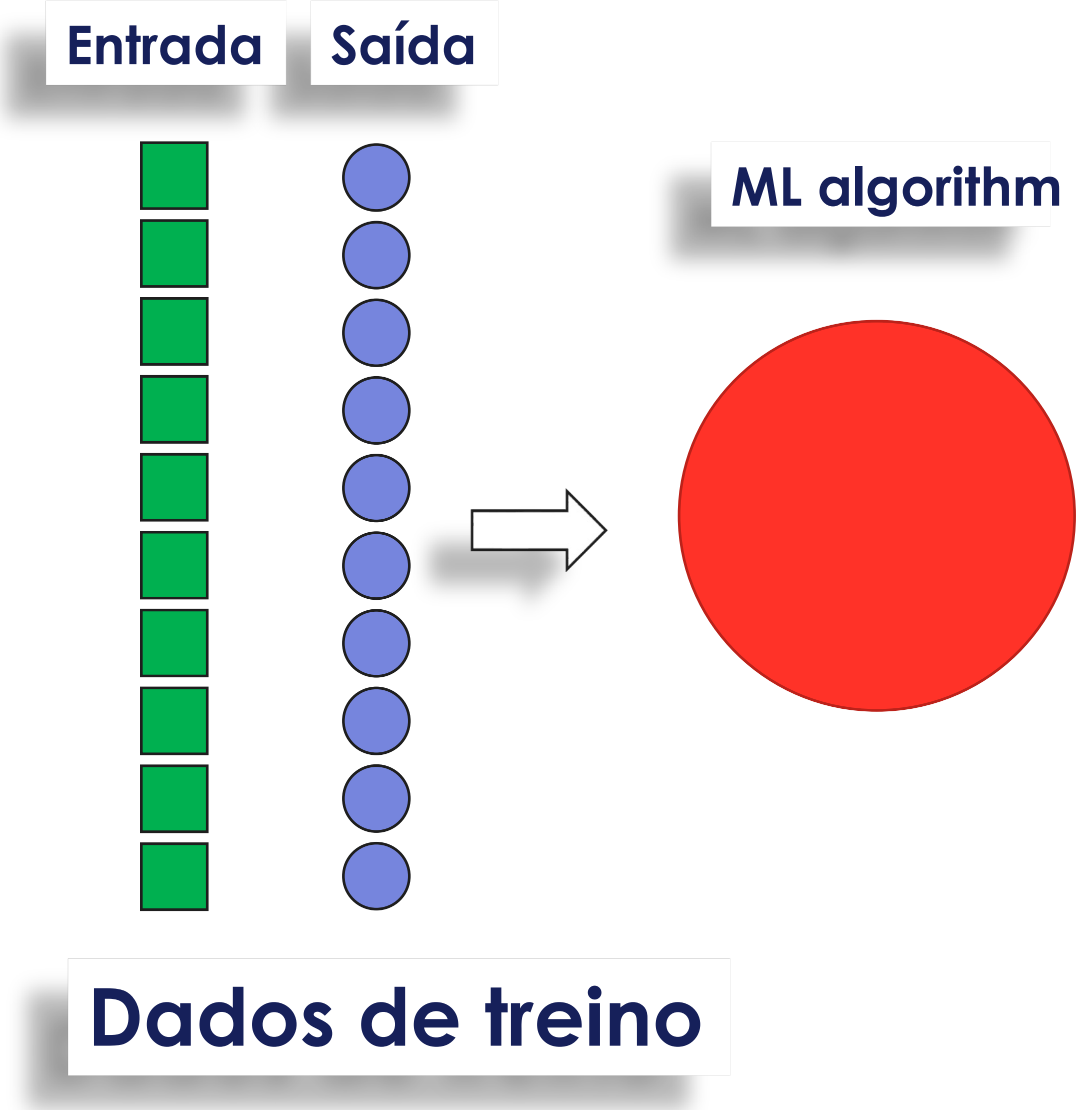

Não Supervisionada

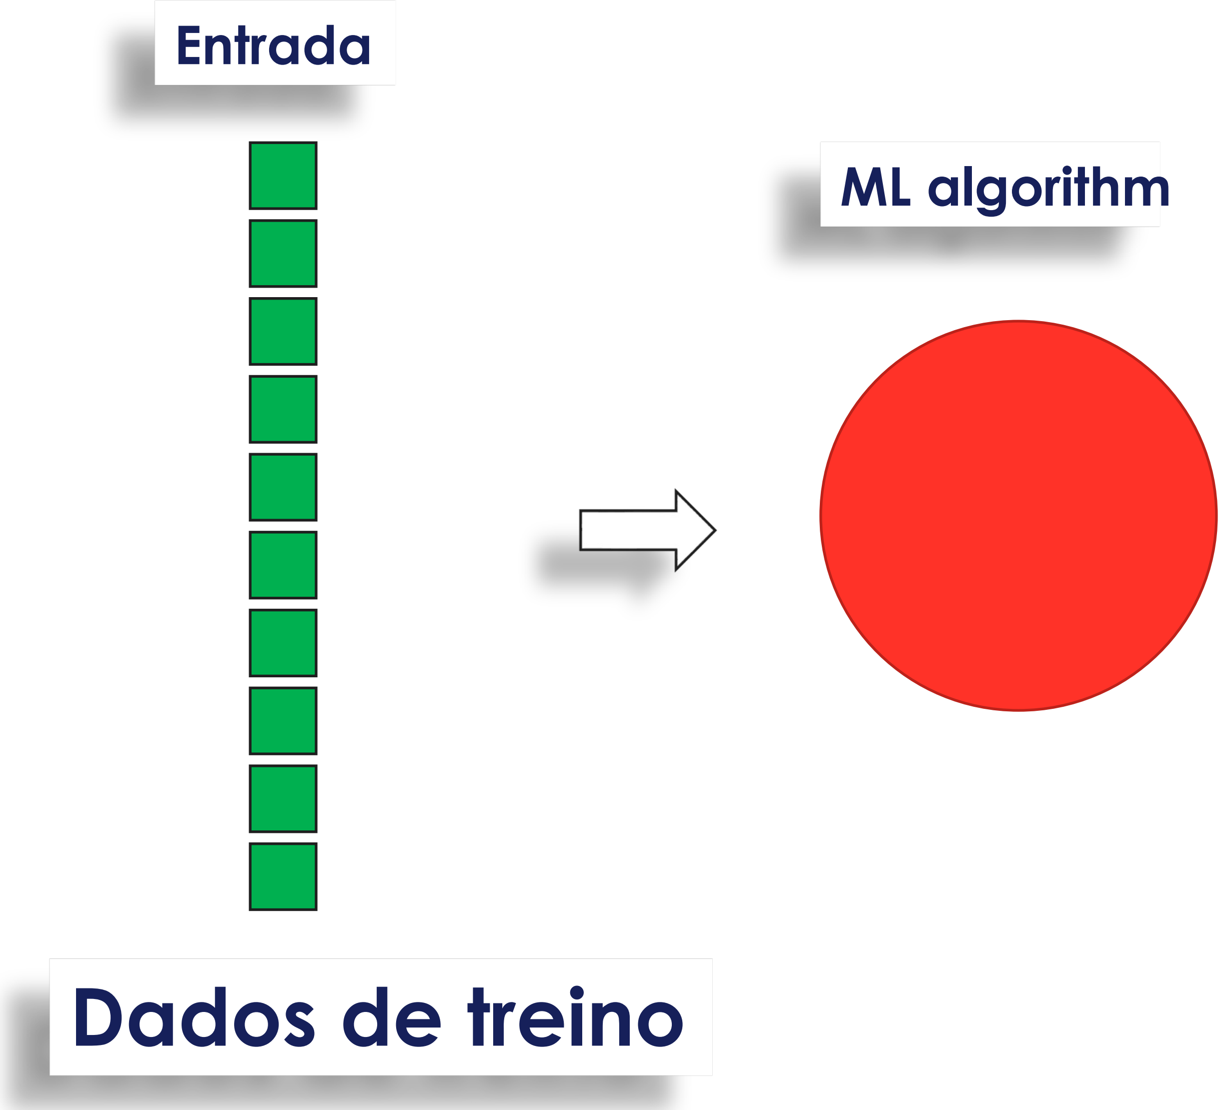

Supervisionada

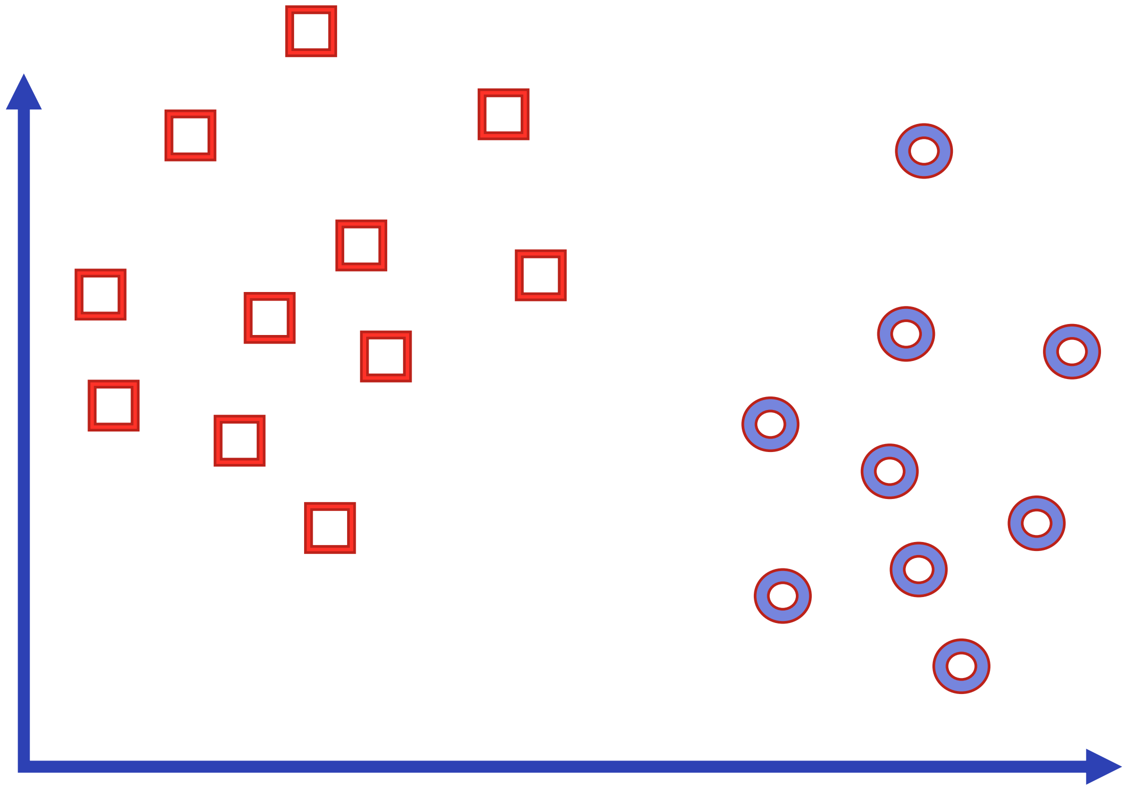

Não Supervisionada

Supervisionada

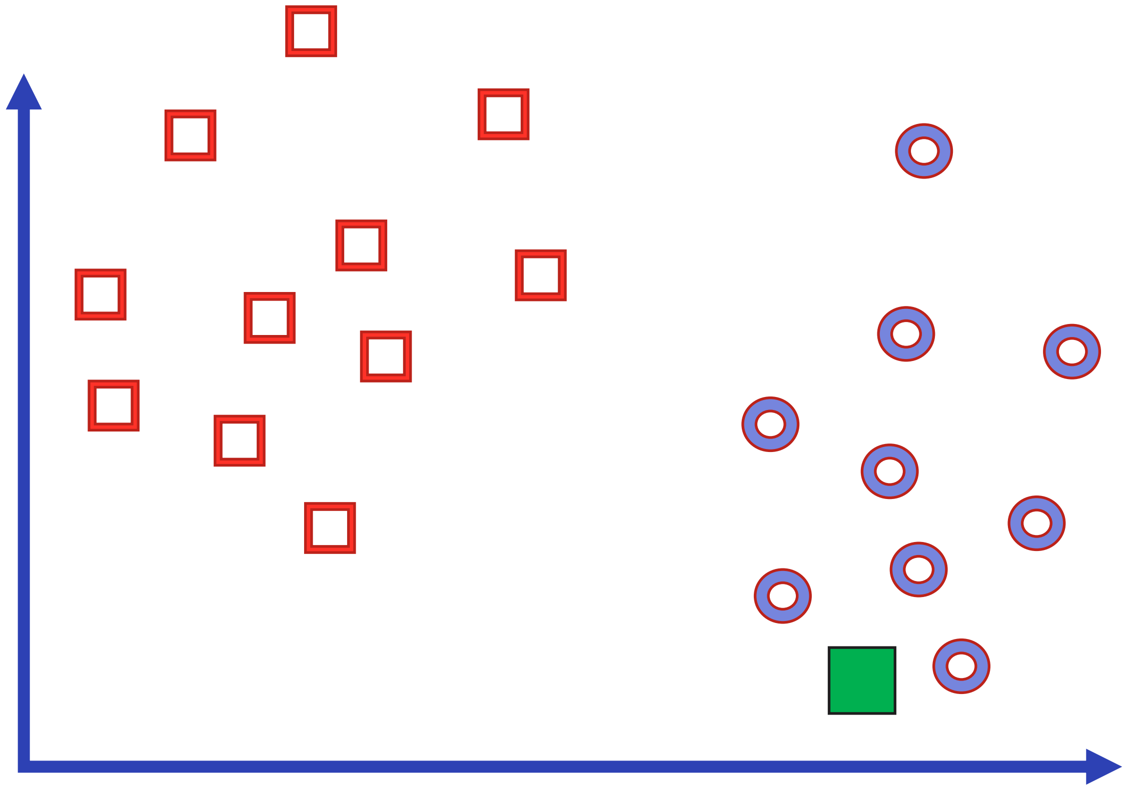

Não Supervisionada

Supervisionada

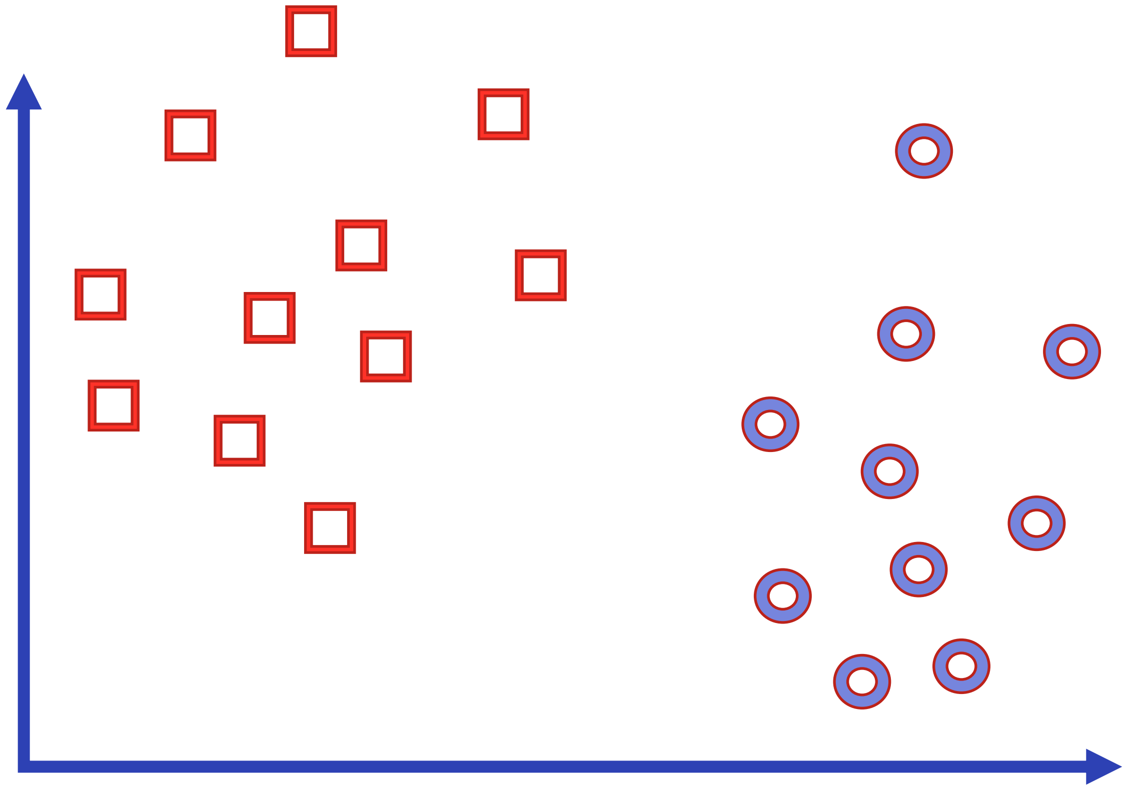

Não Supervisionada

Supervisionada

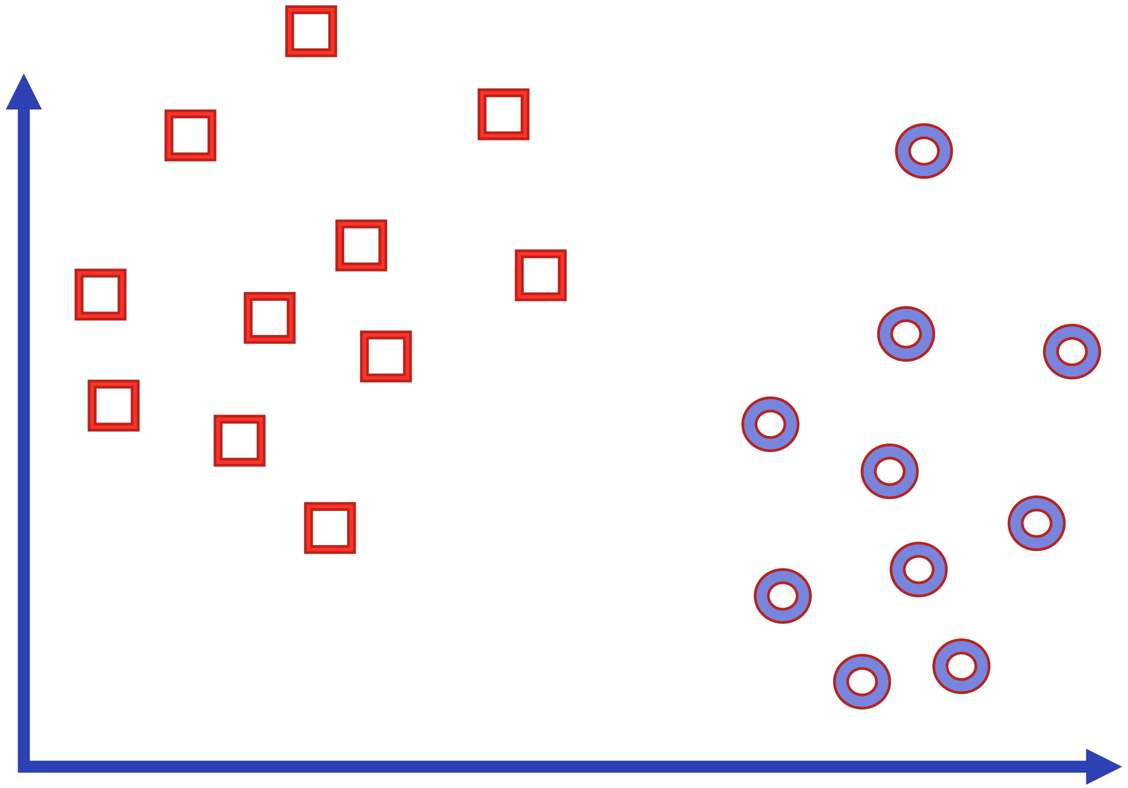

Não Supervisionada

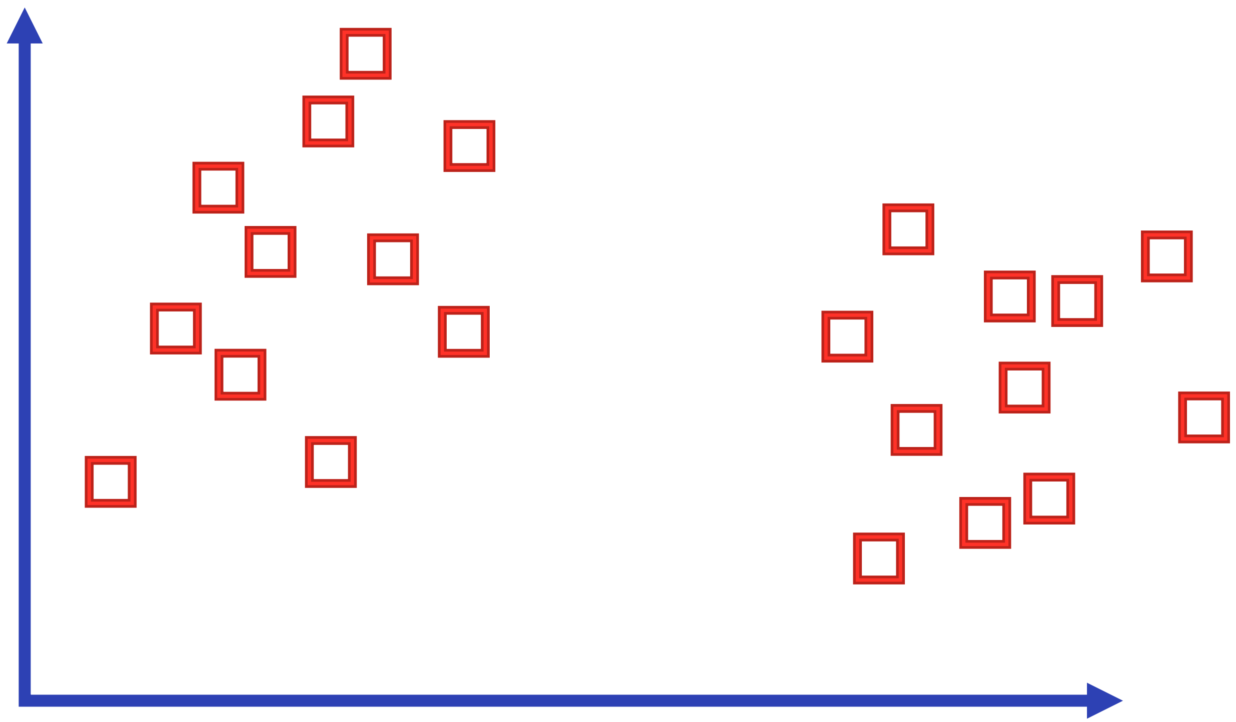

Supervisionada

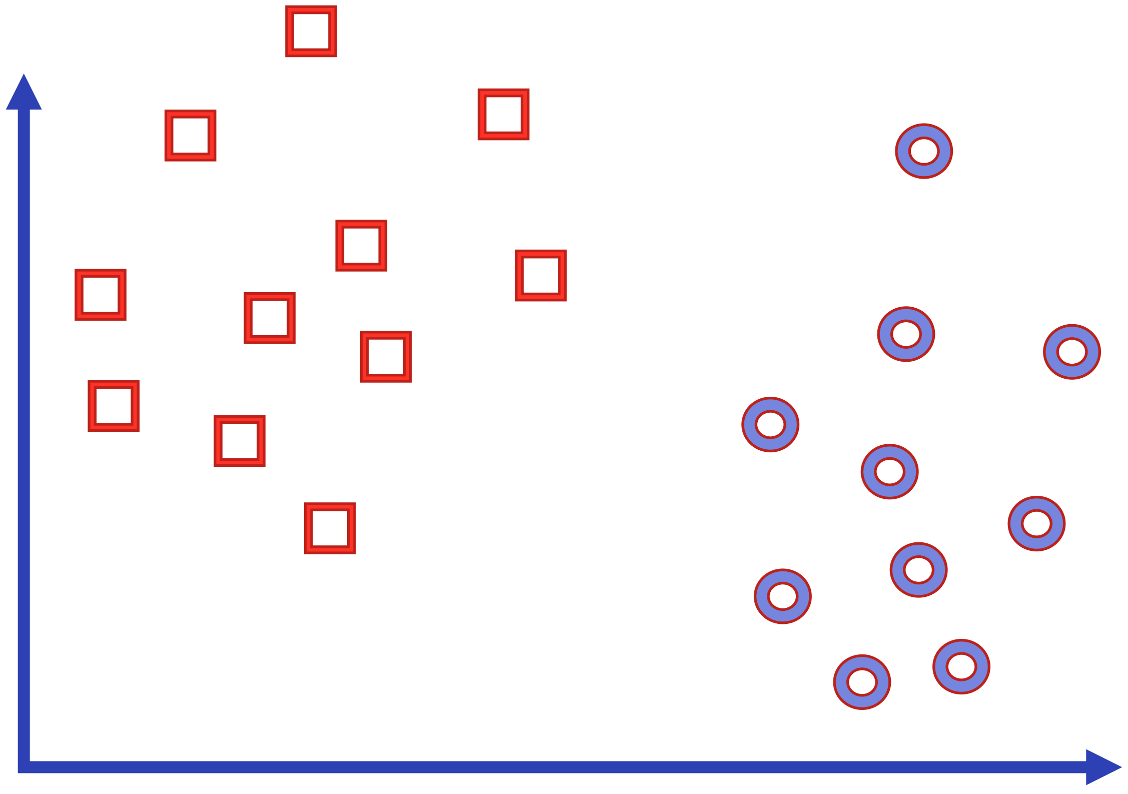

Não Supervisionada

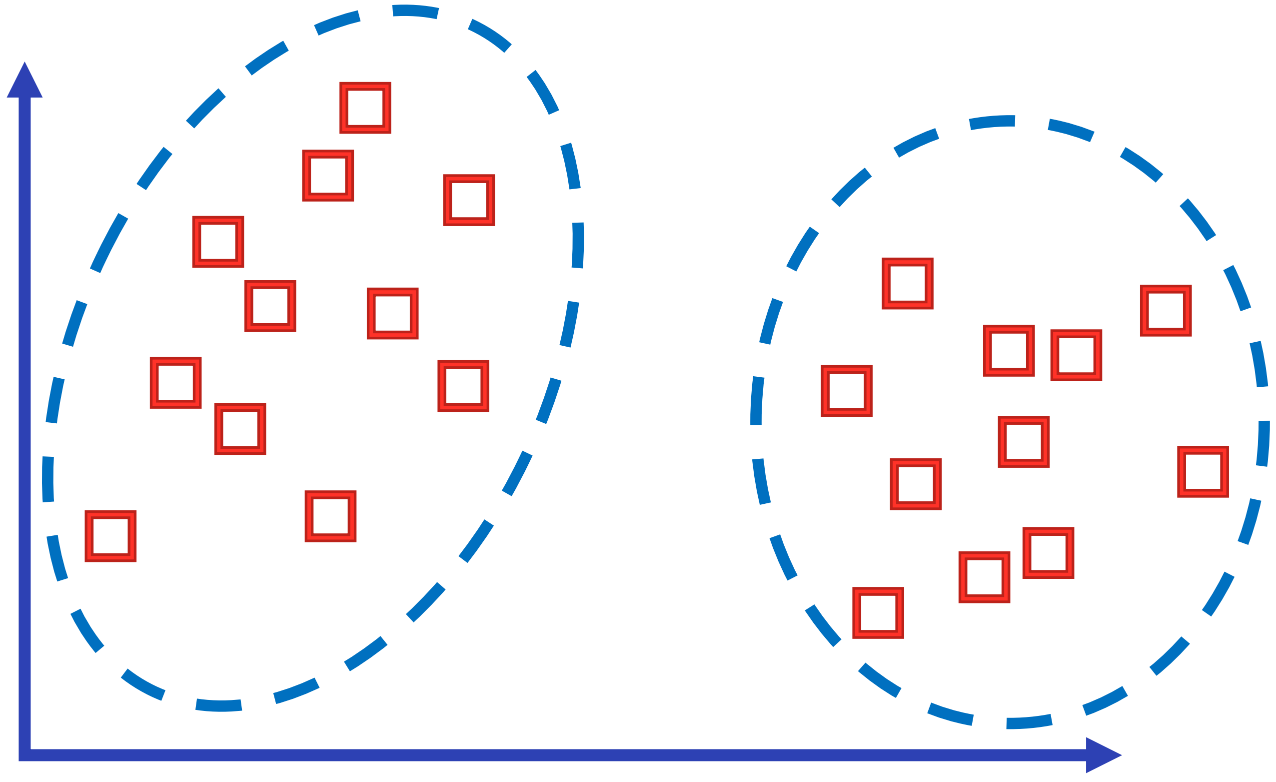

Supervisionada

- Reconhecimento de escrita
- Deteção de spam
- Processamento natural de texto
- Reconhecimento de objetos

Não Supervisionada

- Agrupamento de dados
- Redução de dimensionalidade
- Deteção de anomalias

Aprendizagem reforçada

Aprendizagem reforçada

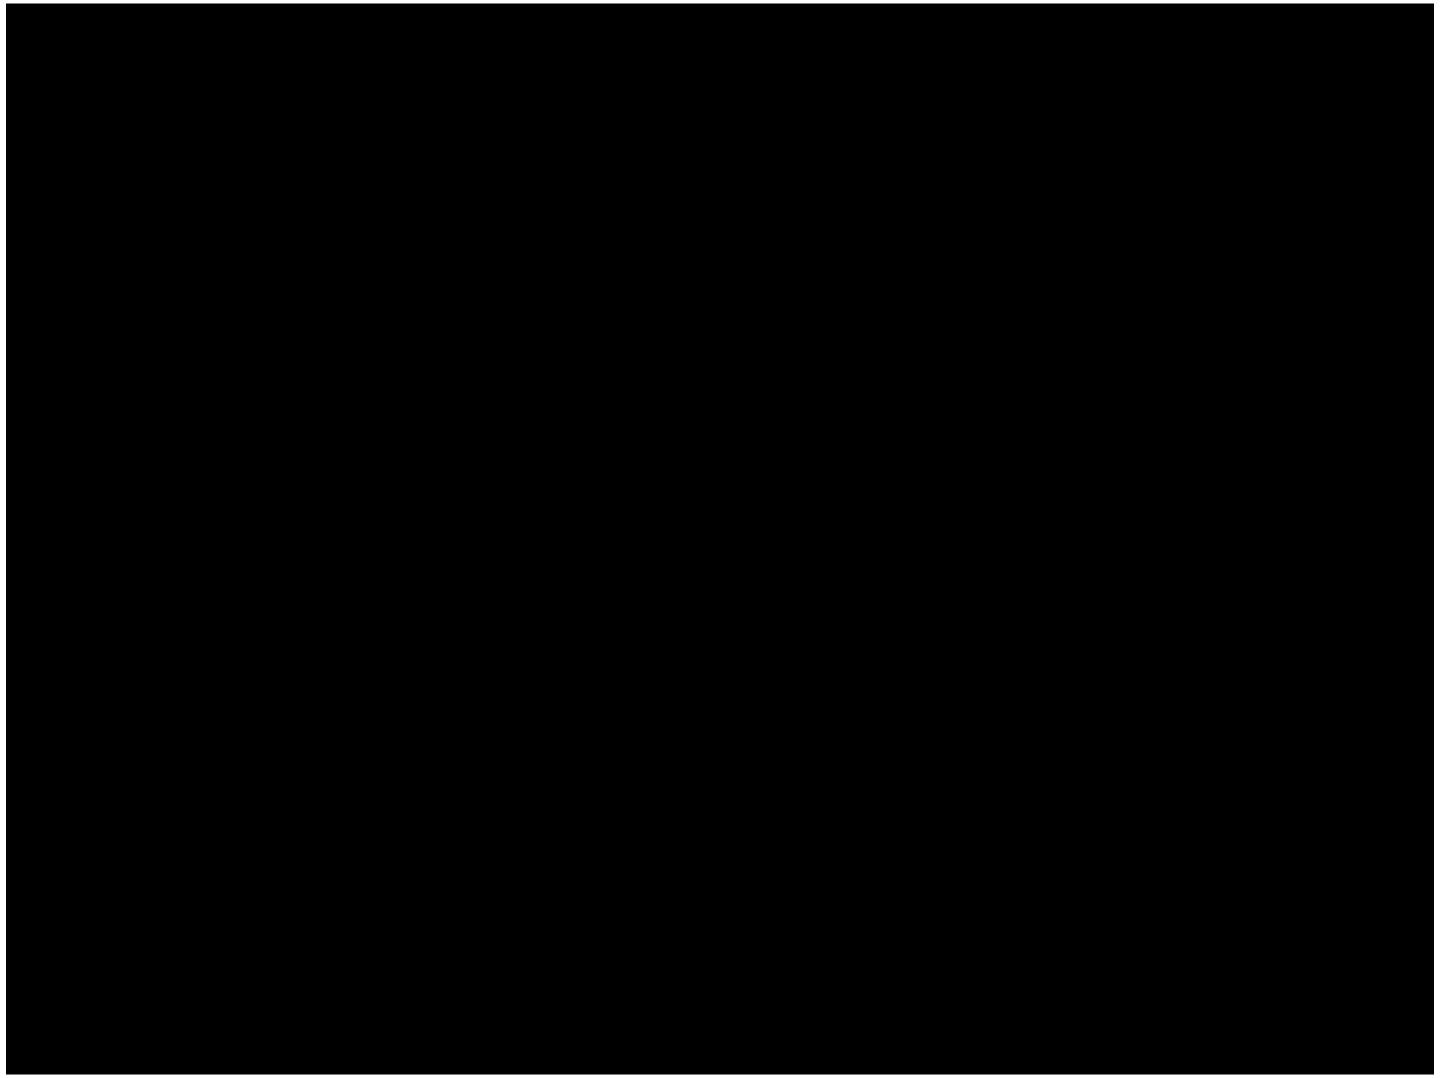

V. Mnih et al. Nature 518, 529 (2015)

Aprendizagem reforçada

Aprendizagem supervisionada: Algoritmo de k-nearest neighbors

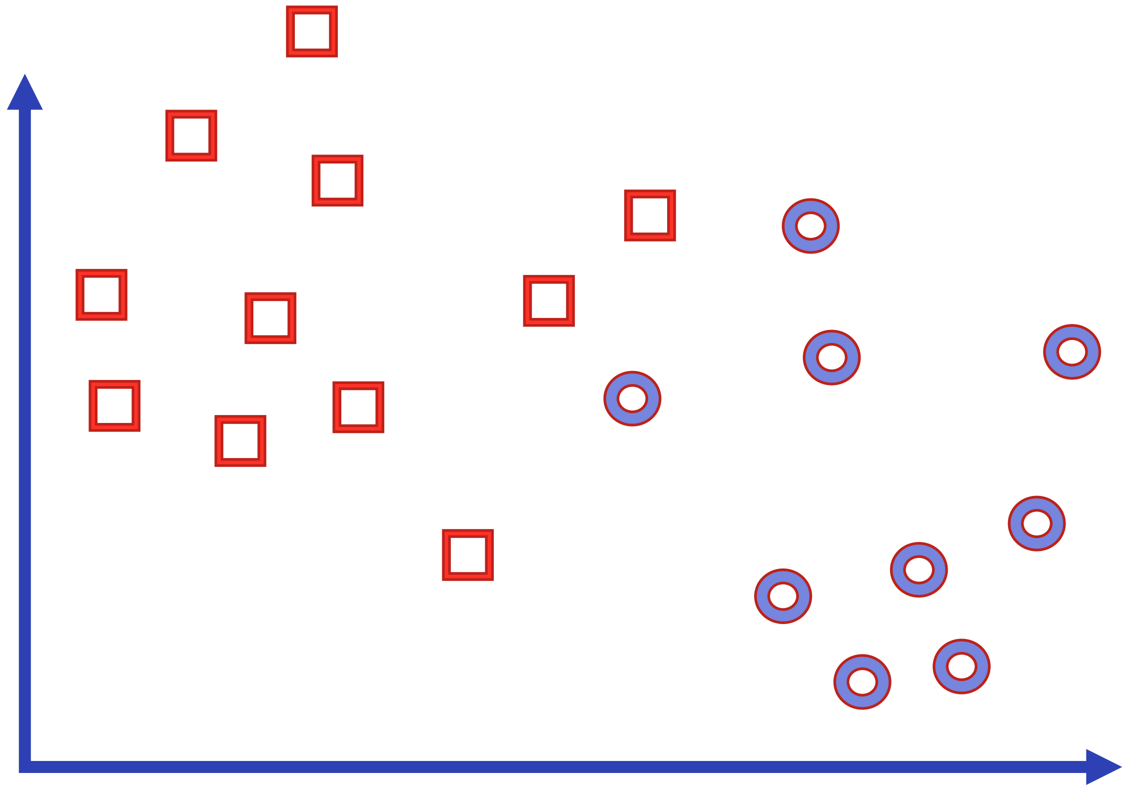

Aprendizagem supervisionada: Algoritmo de k-nearest neighbors

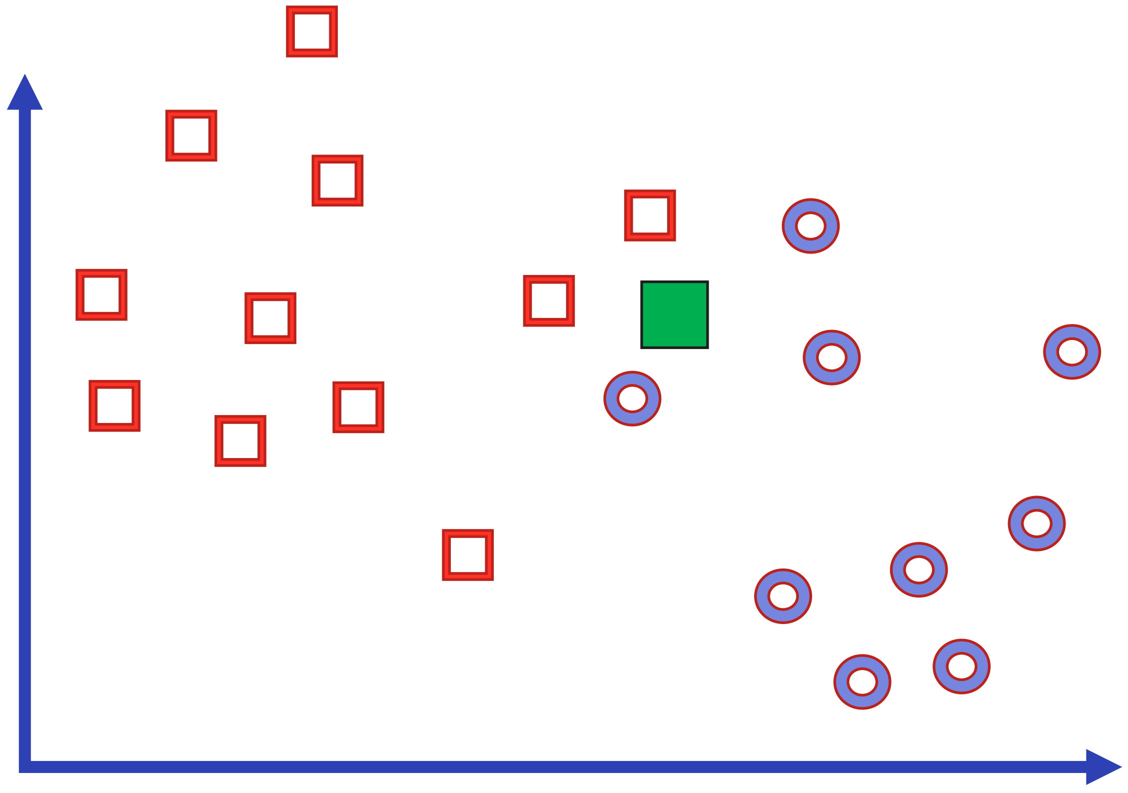

Aprendizagem supervisionada: Algoritmo de k-nearest neighbors

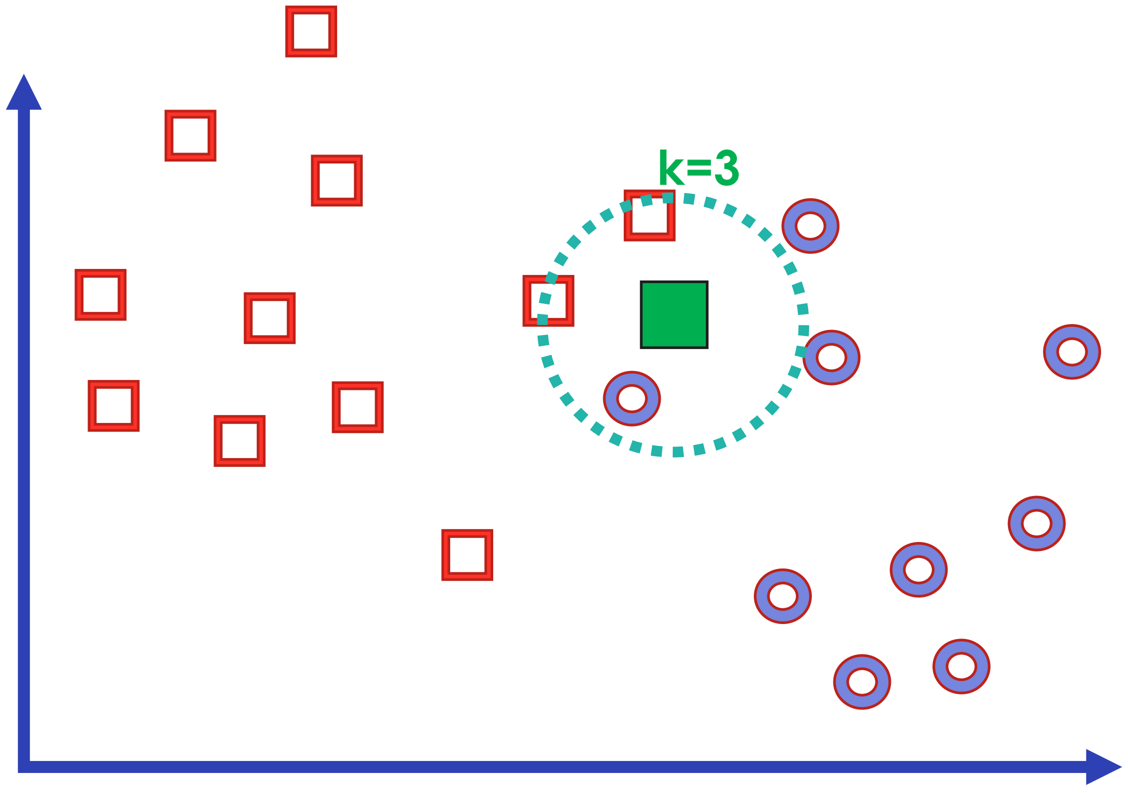

Aprendizagem supervisionada: Algoritmo de k-nearest neighbors

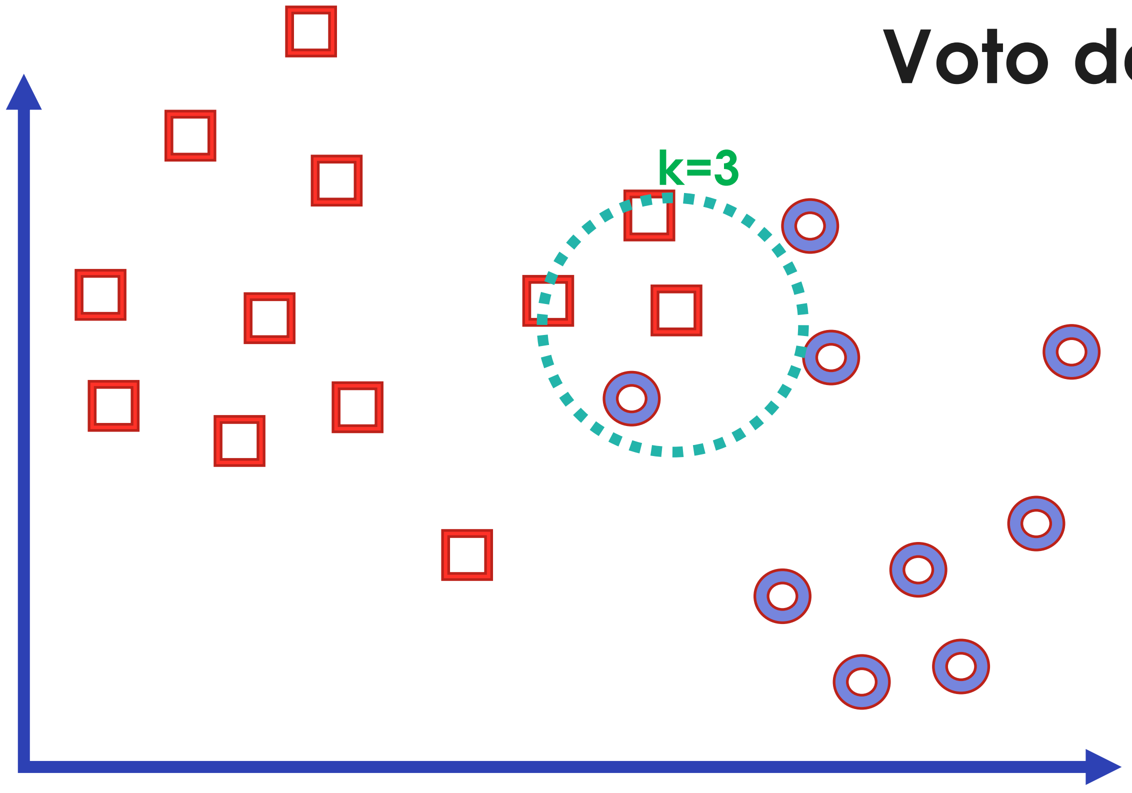

Voto da maioria

Aprendizagem supervisionada: Algoritmo de k-nearest neighbors

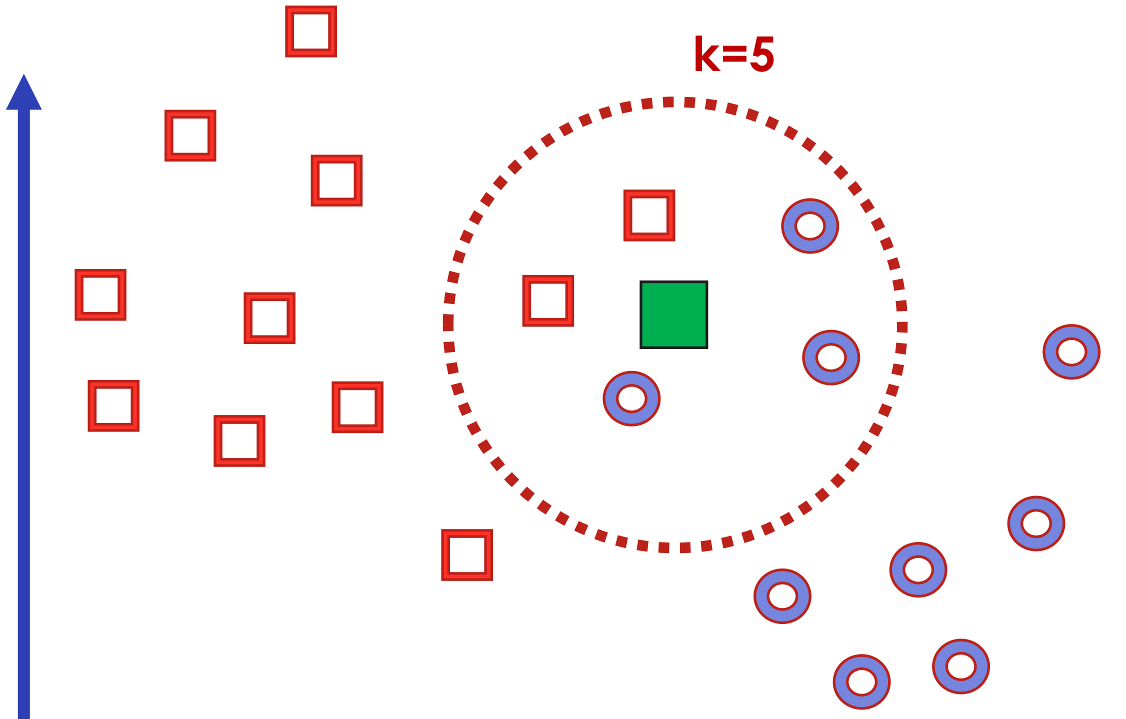

Aprendizagem supervisionada: Algoritmo de k-nearest neighbors

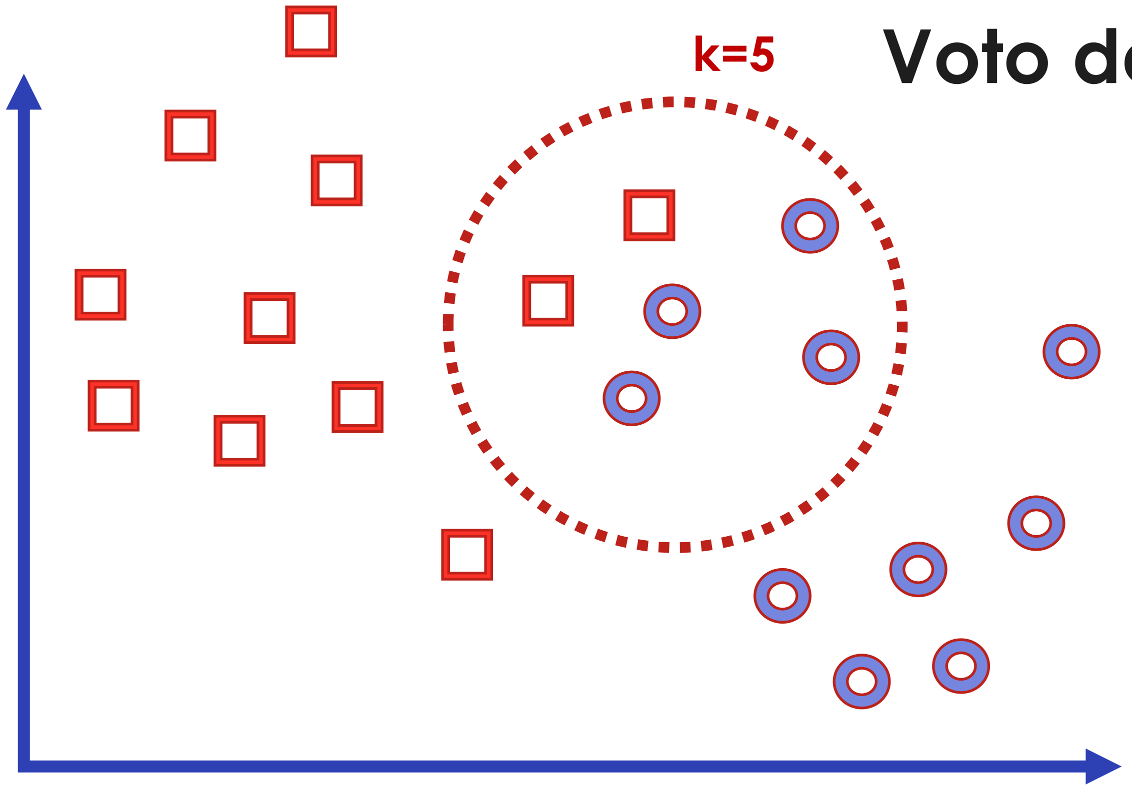

Voto da maioria

Aprendizagem não supervisionada: Algoritmo de k-means

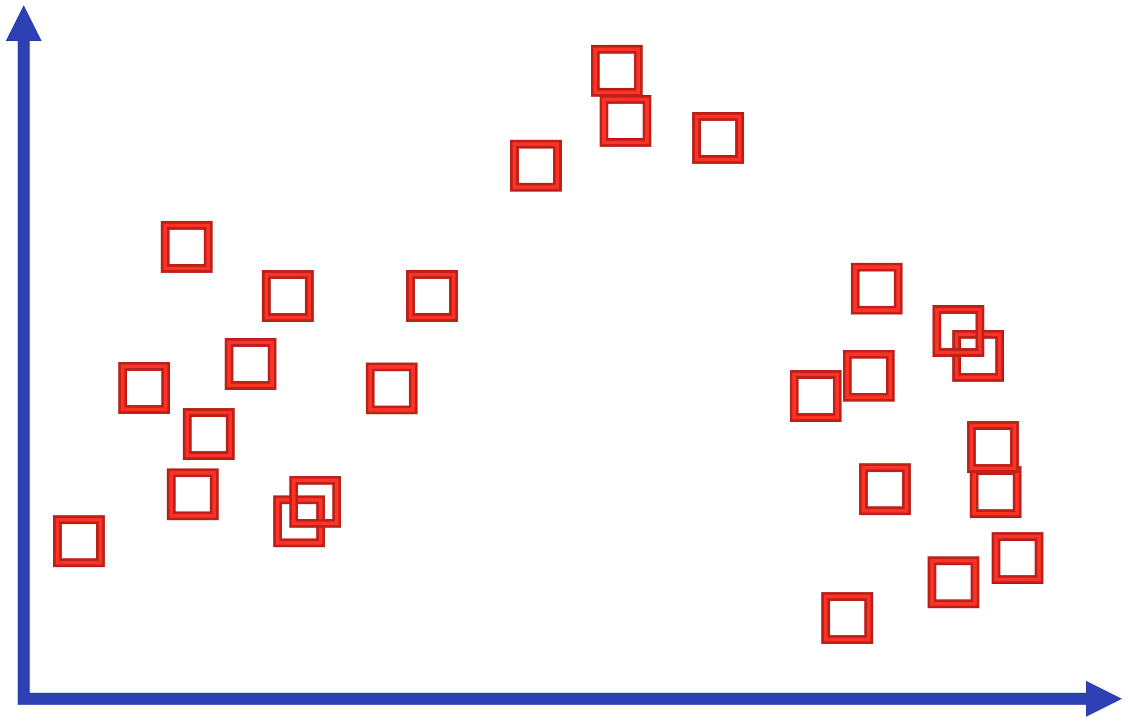

Aprendizagem não supervisionada: Algoritmo de k-means

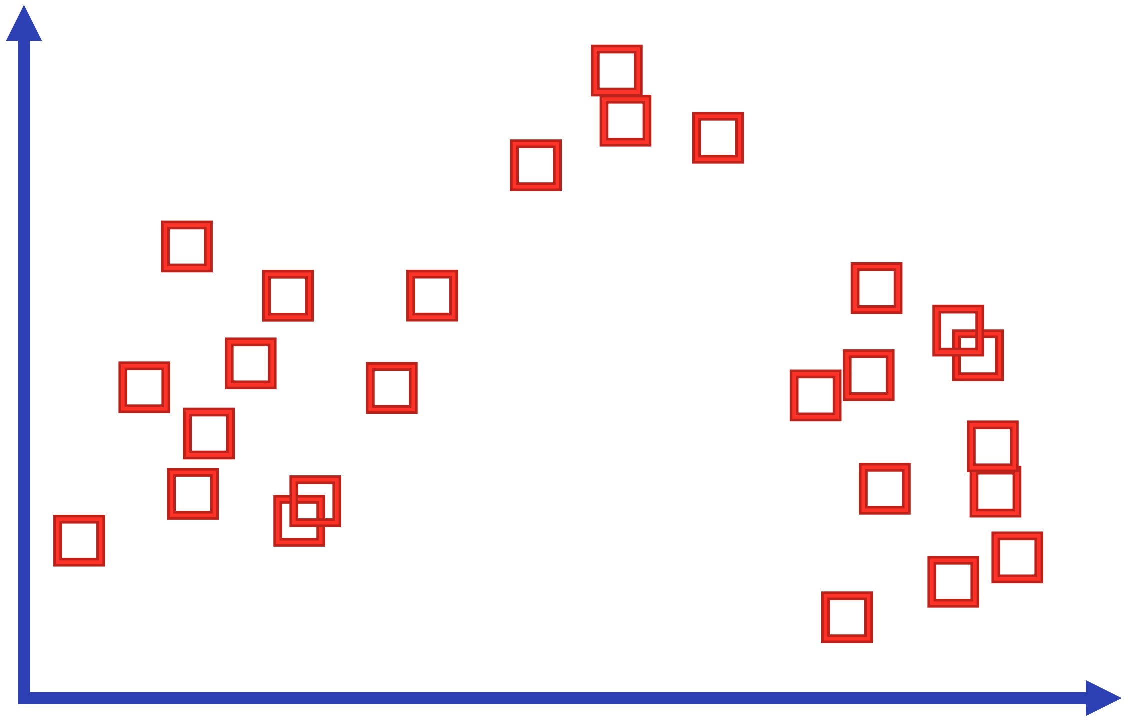

Gerar Centroides

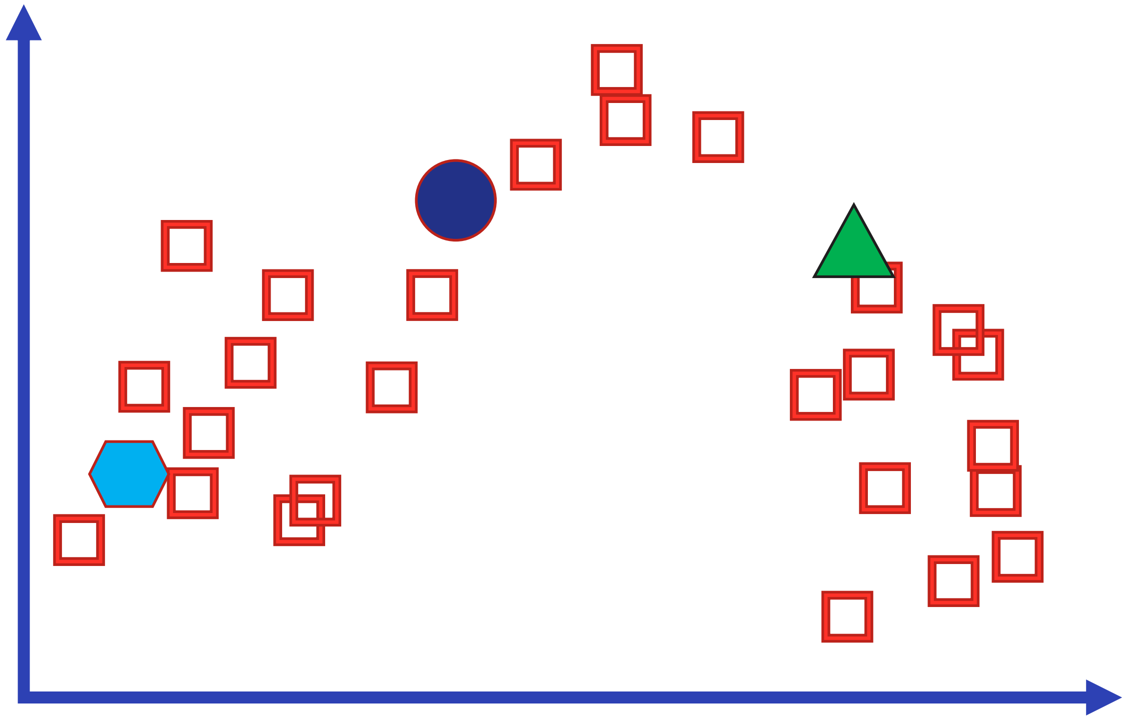

Aprendizagem não supervisionada: Algoritmo de k-means

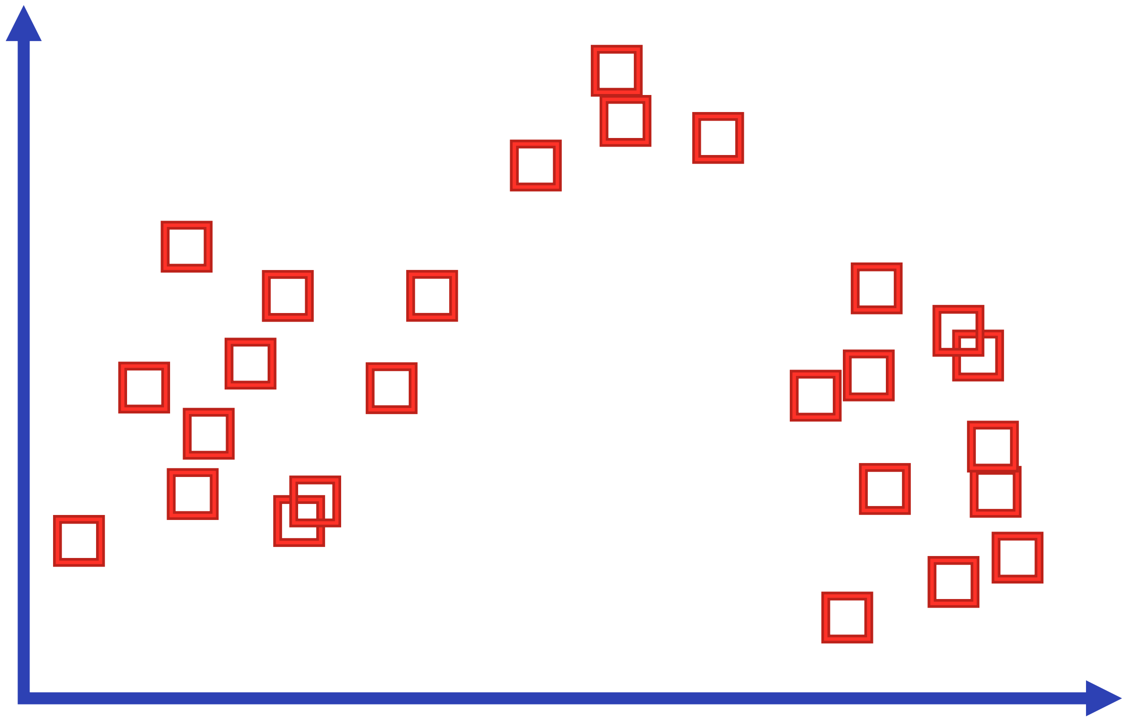

Atribuir dado a centroide mais próximo

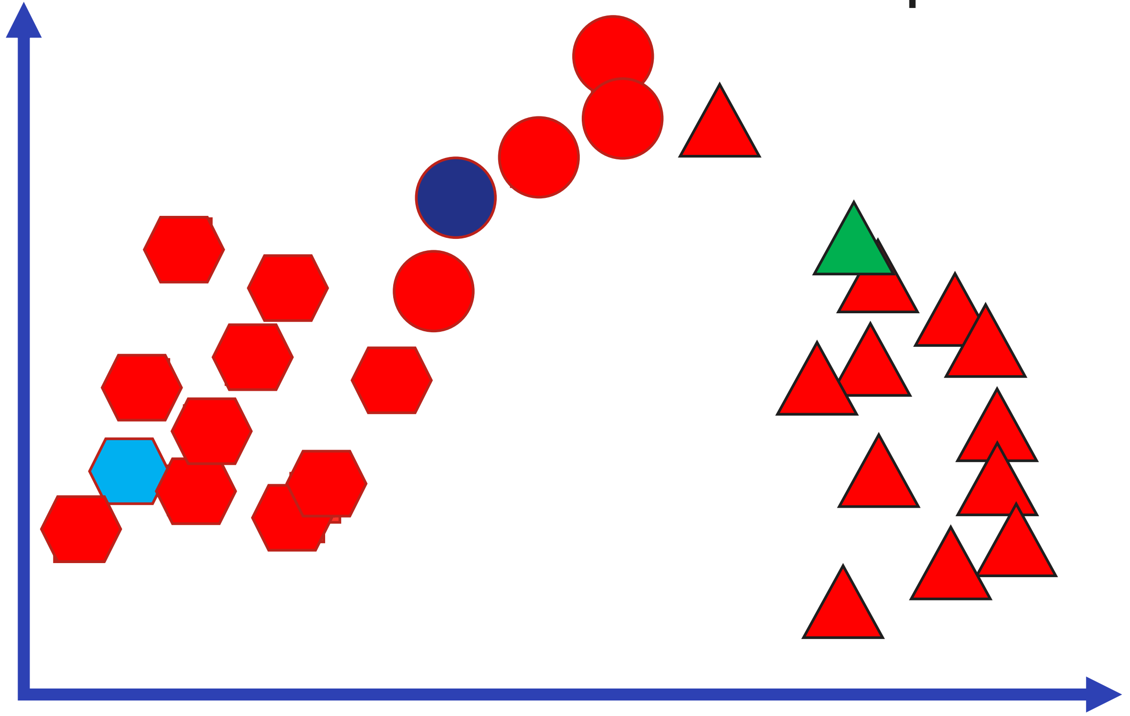

Aprendizagem não supervisionada: Algoritmo de k-means

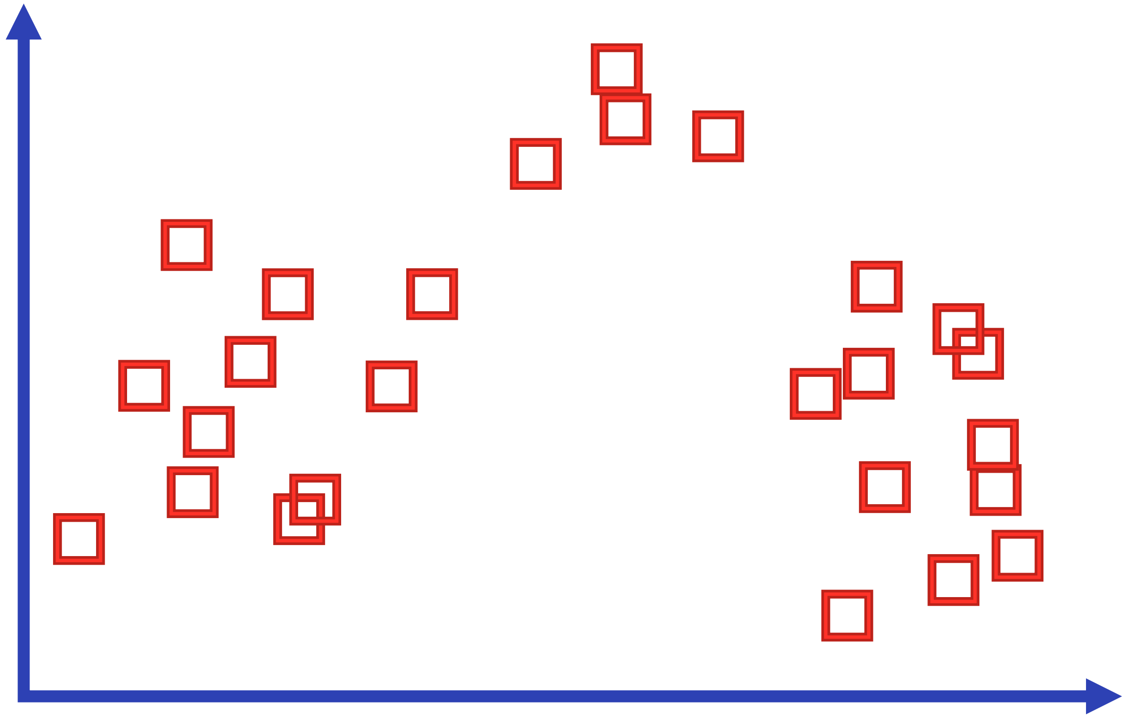

Mudar a posição do centroide para a media dos seu dados

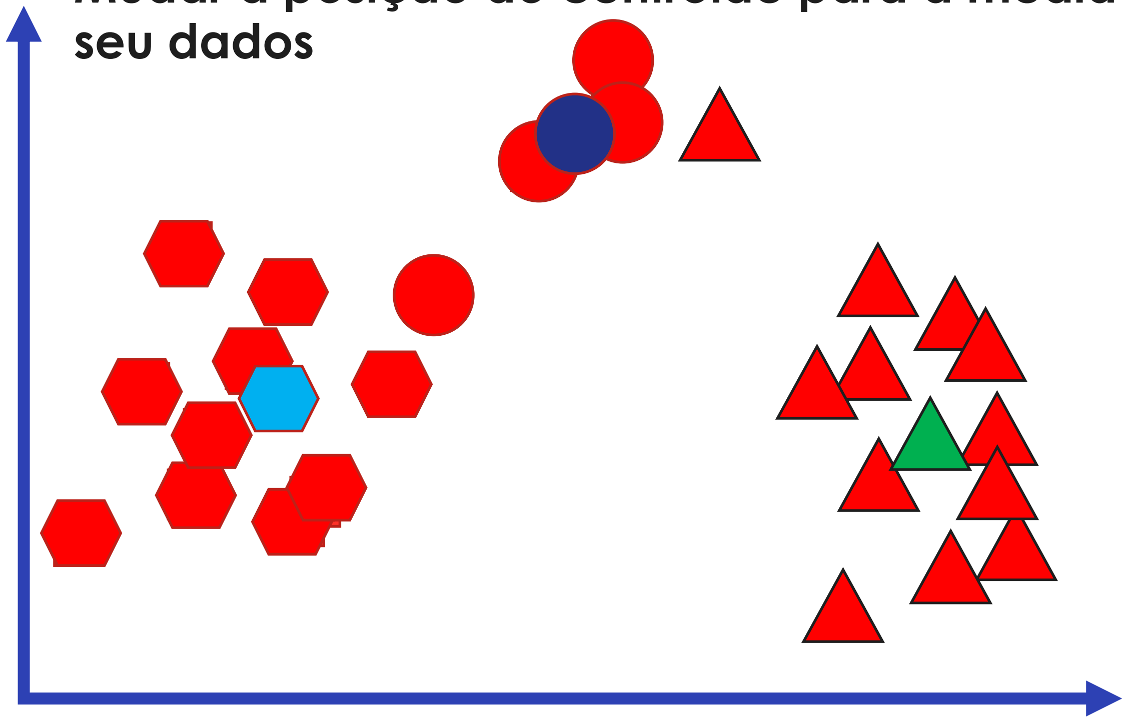

Aprendizagem não supervisionada: Algoritmo de k-means

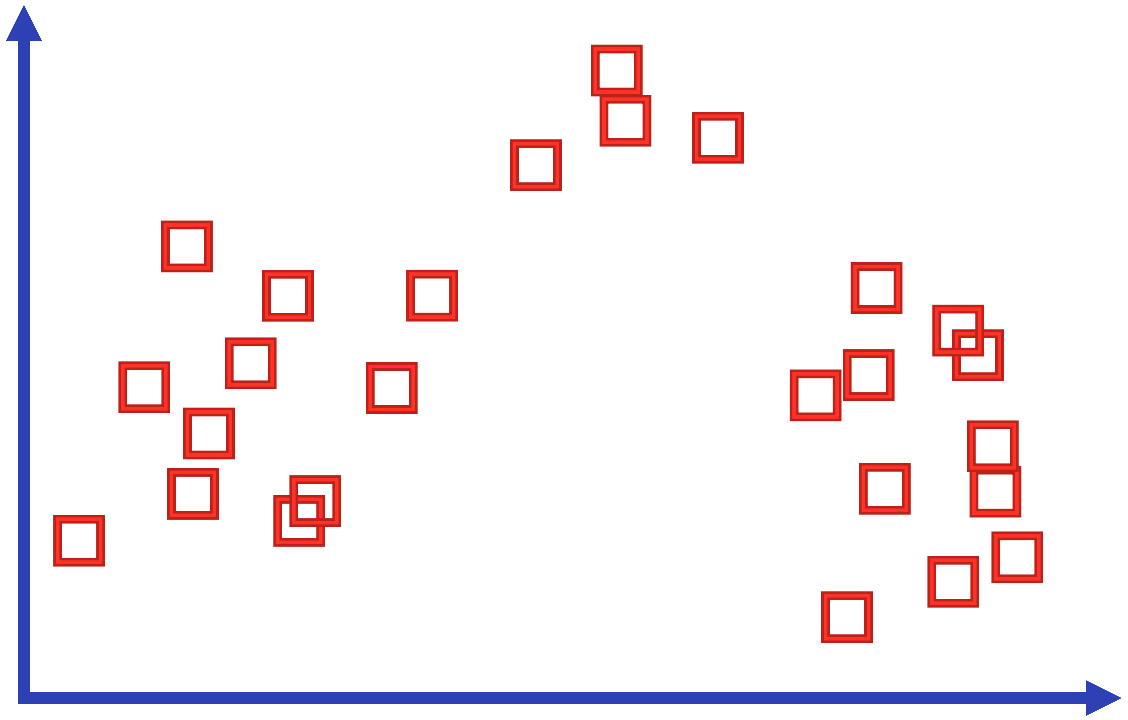

Redistribuir dados pelos centroides mais próximos

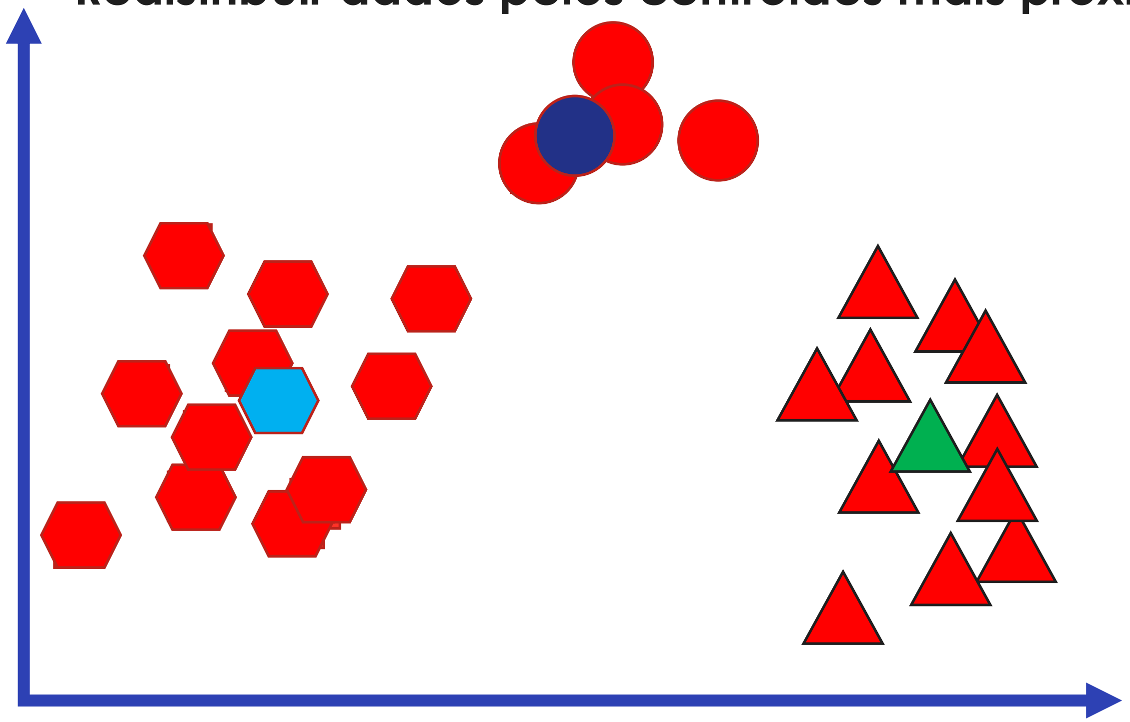

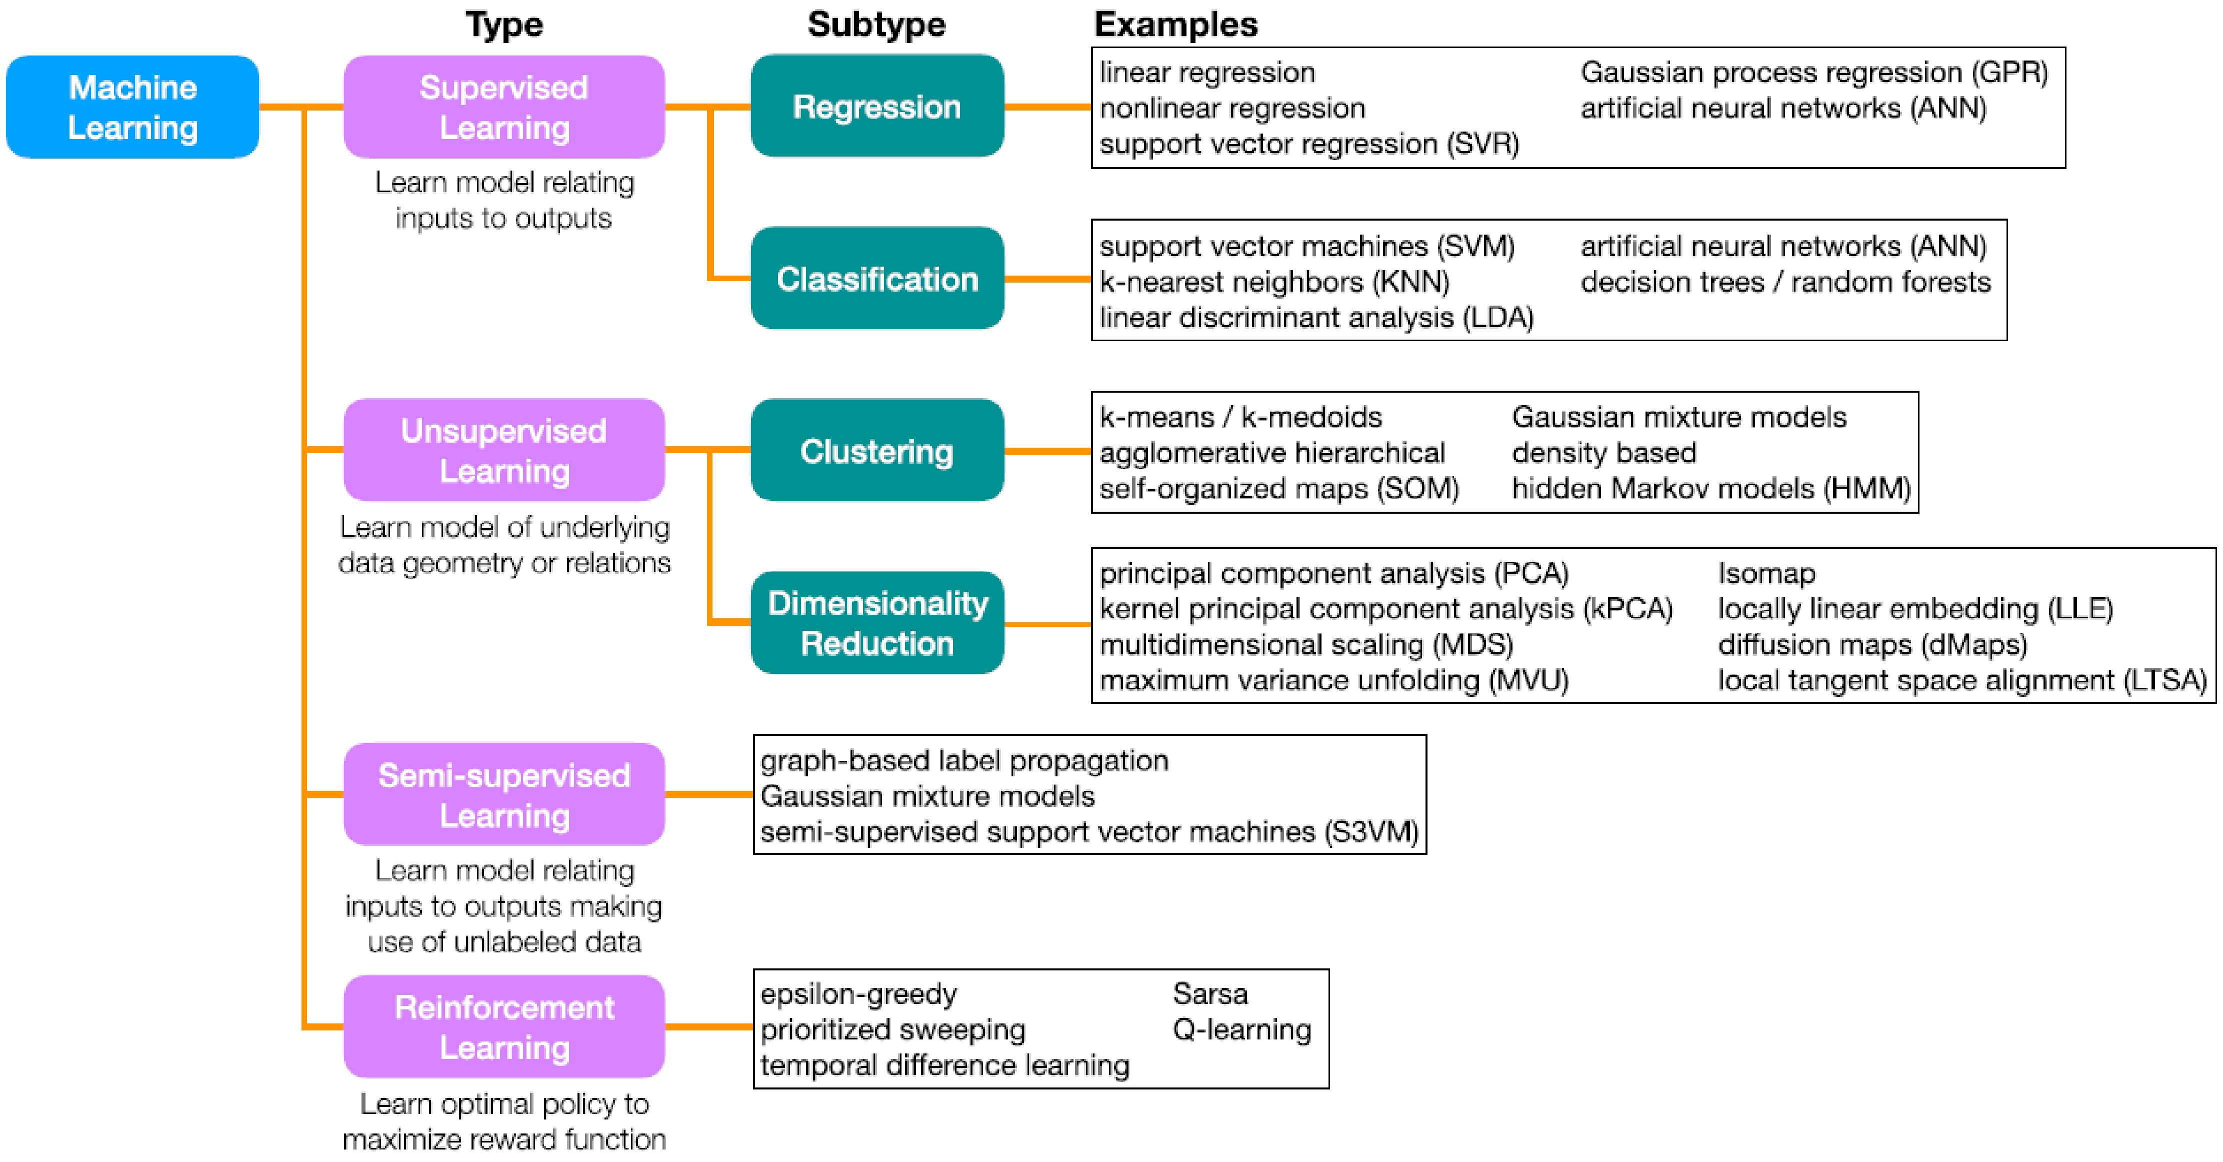

Figure 1. Taxonomy of machine learning algorithms.

Árvores de decisão

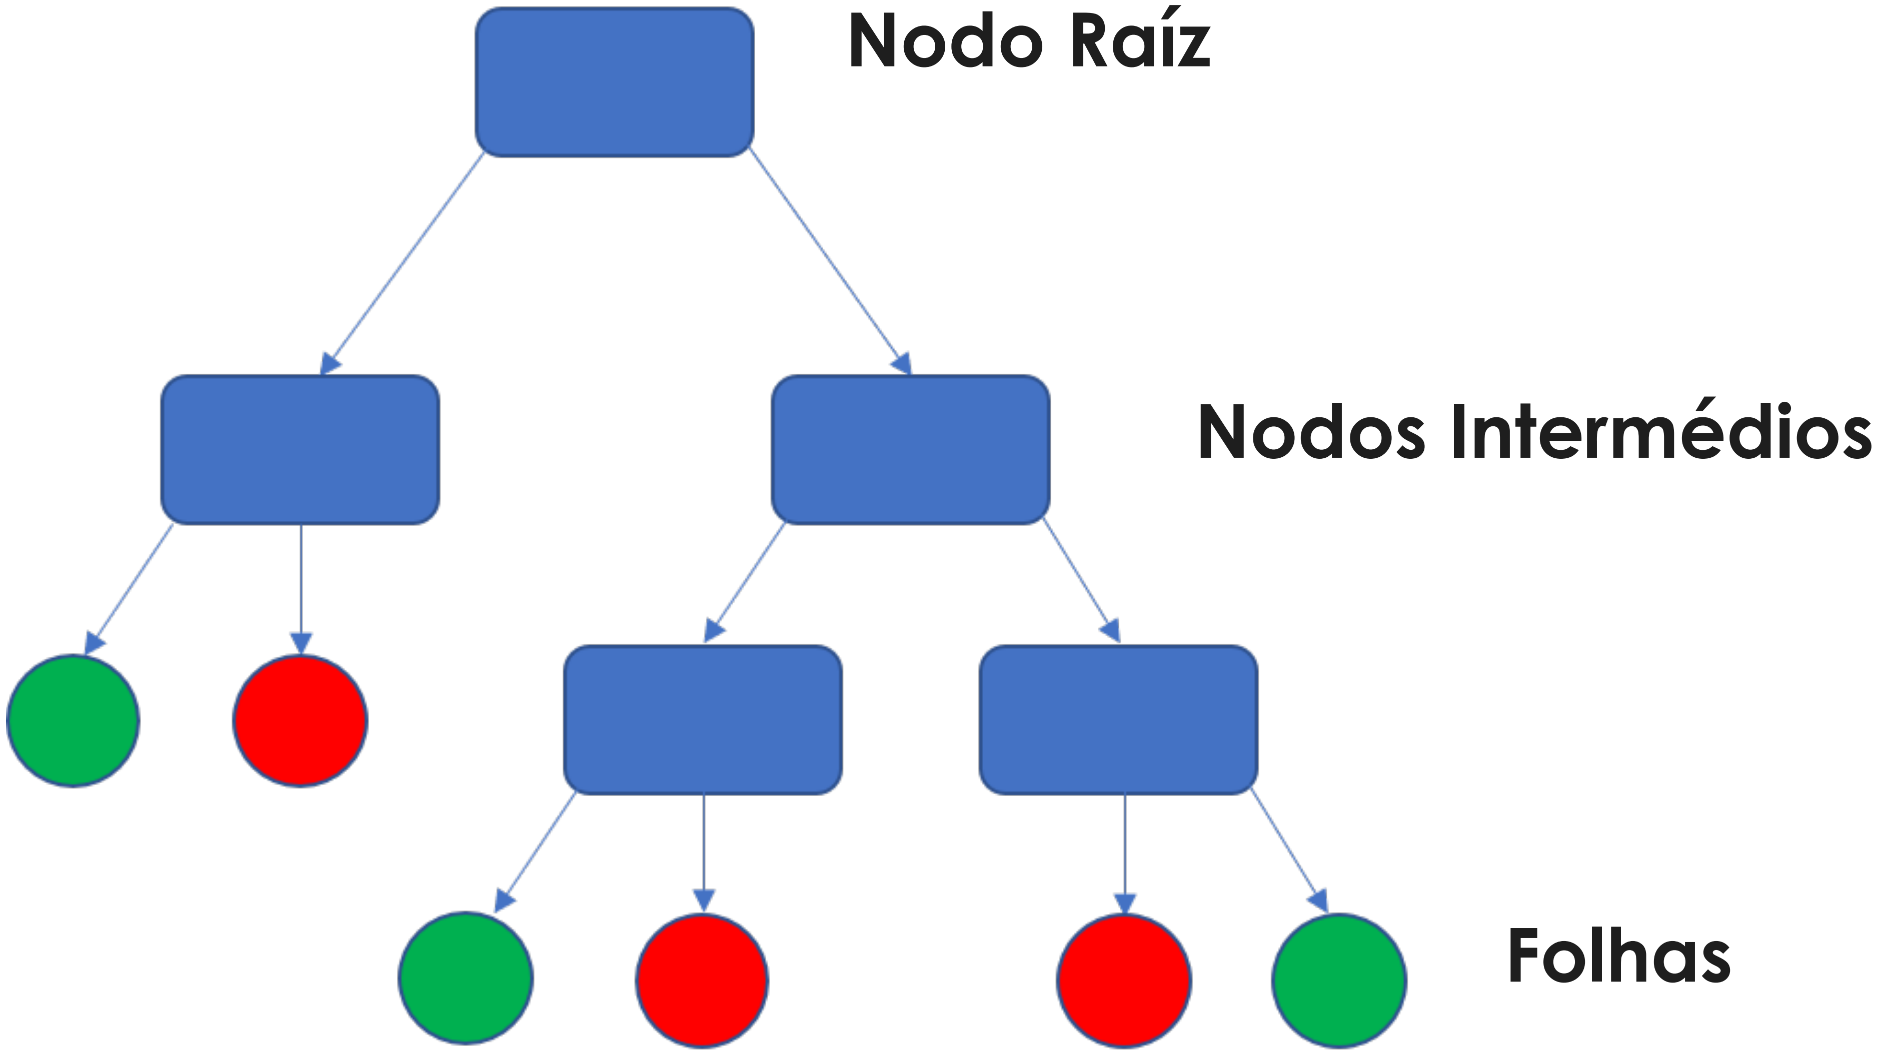

Árvores de decisão

Classificação

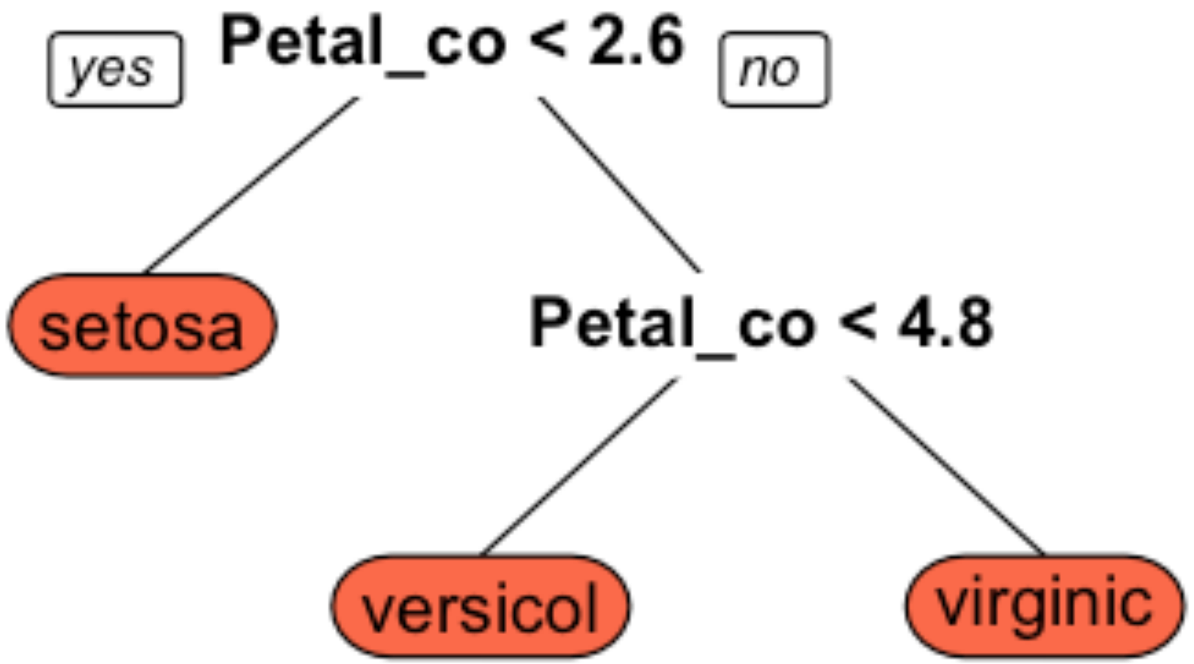

Dataset de flores Iris

Regressão

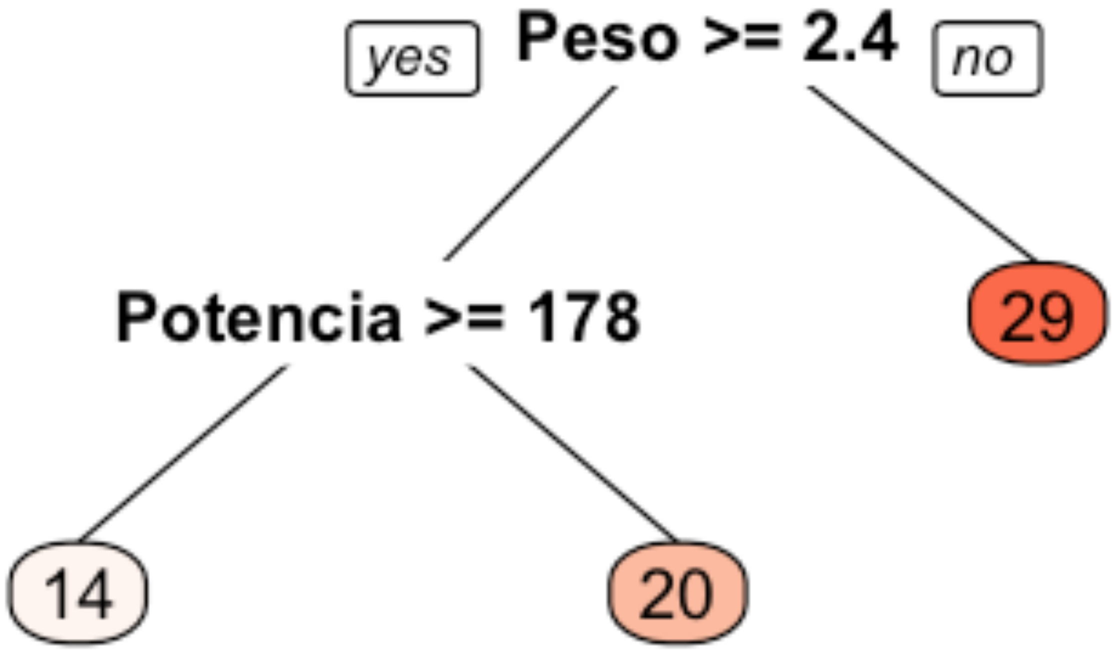

Dataset do consumo de carros em milhas por galão

Regressão com árvores de decisão

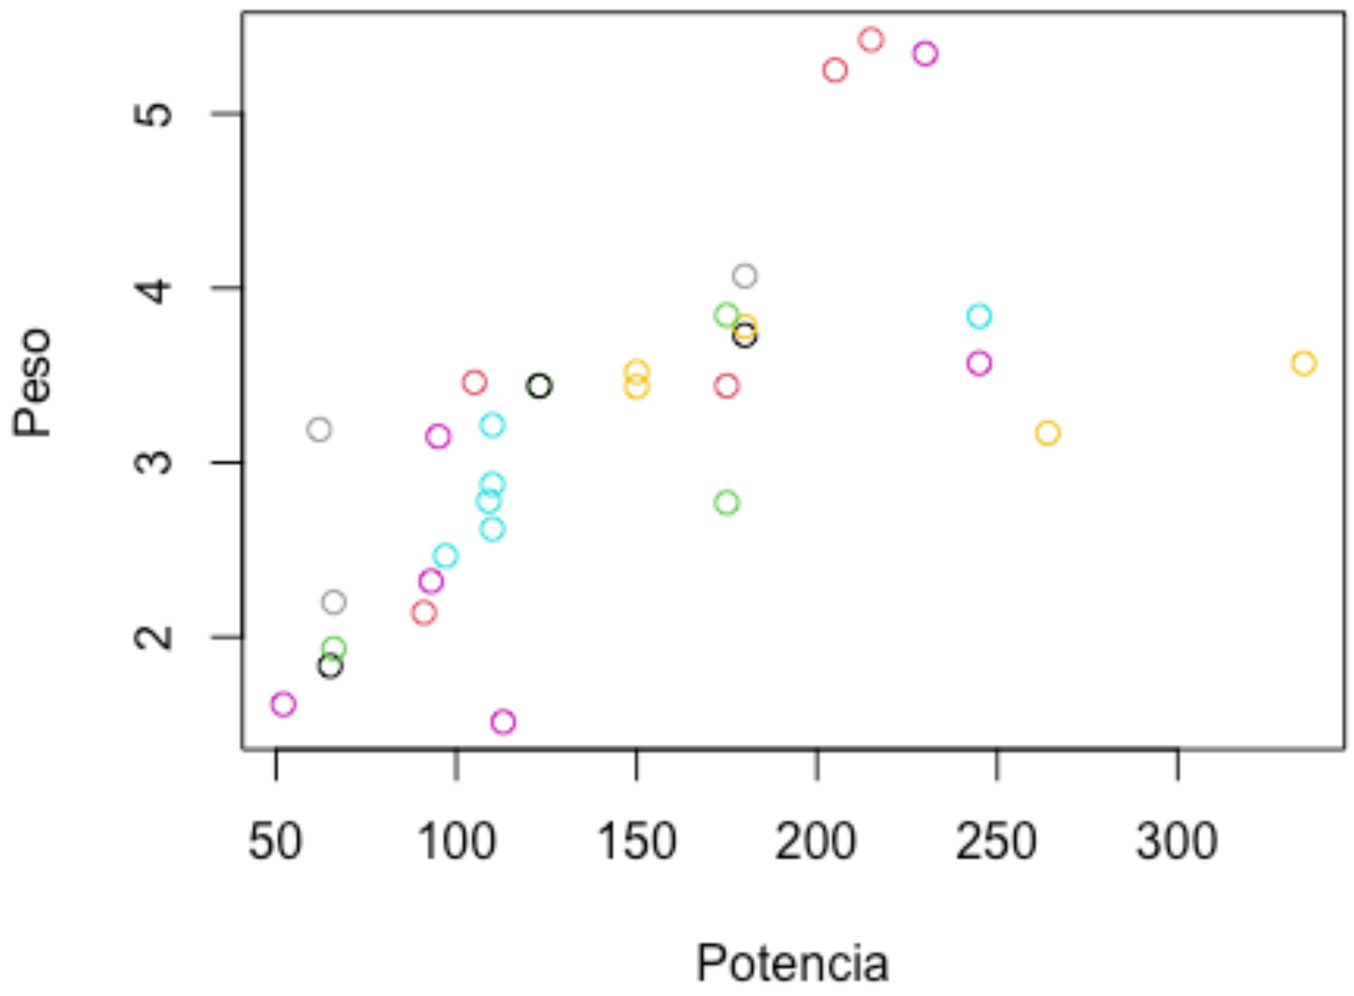

Regressão com árvores de decisão

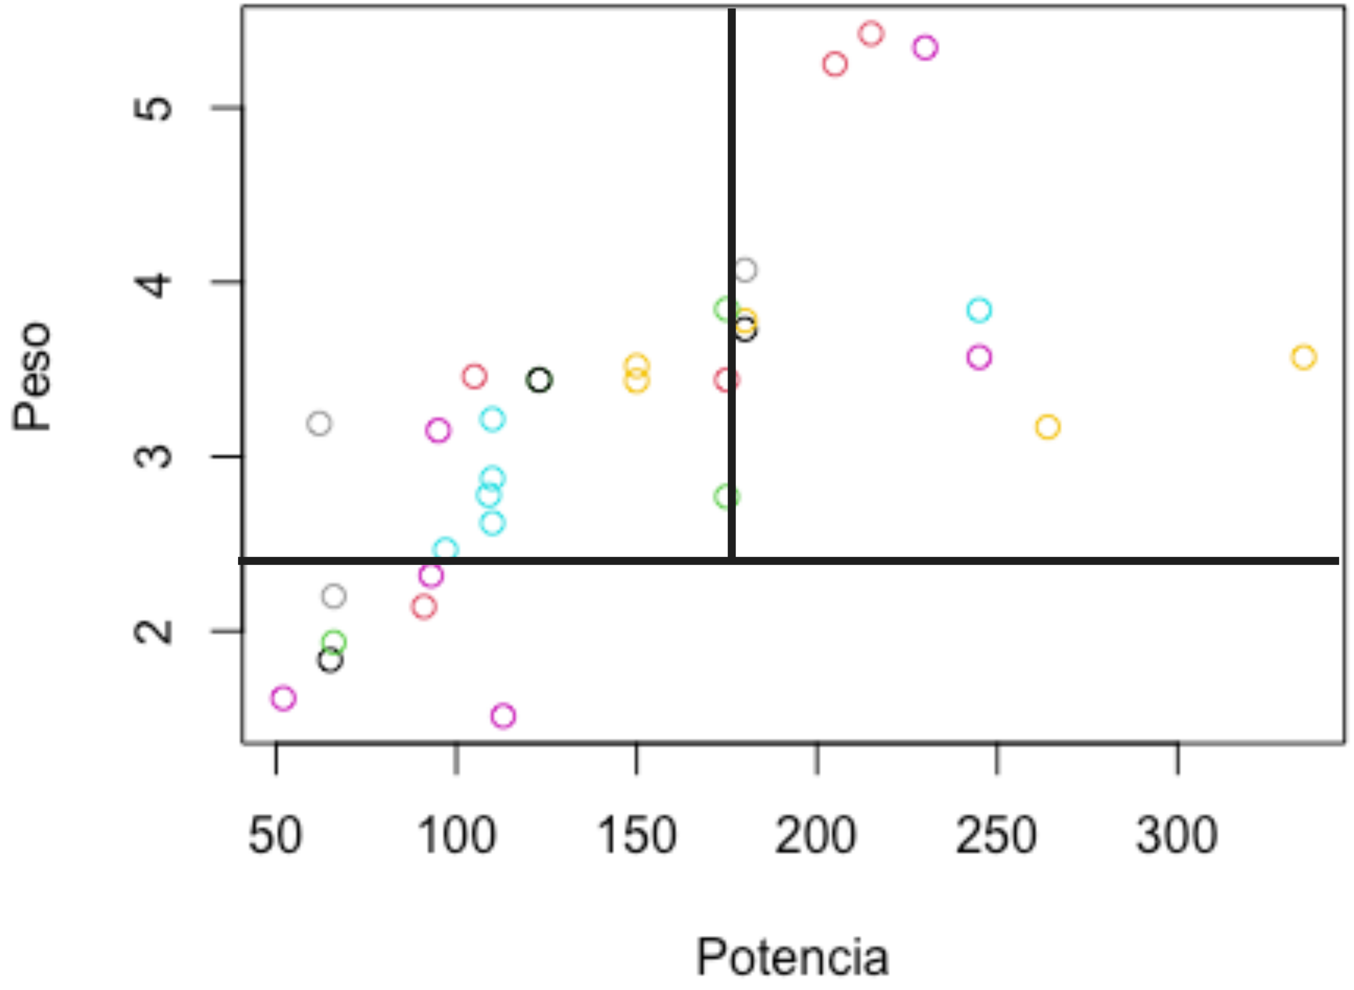

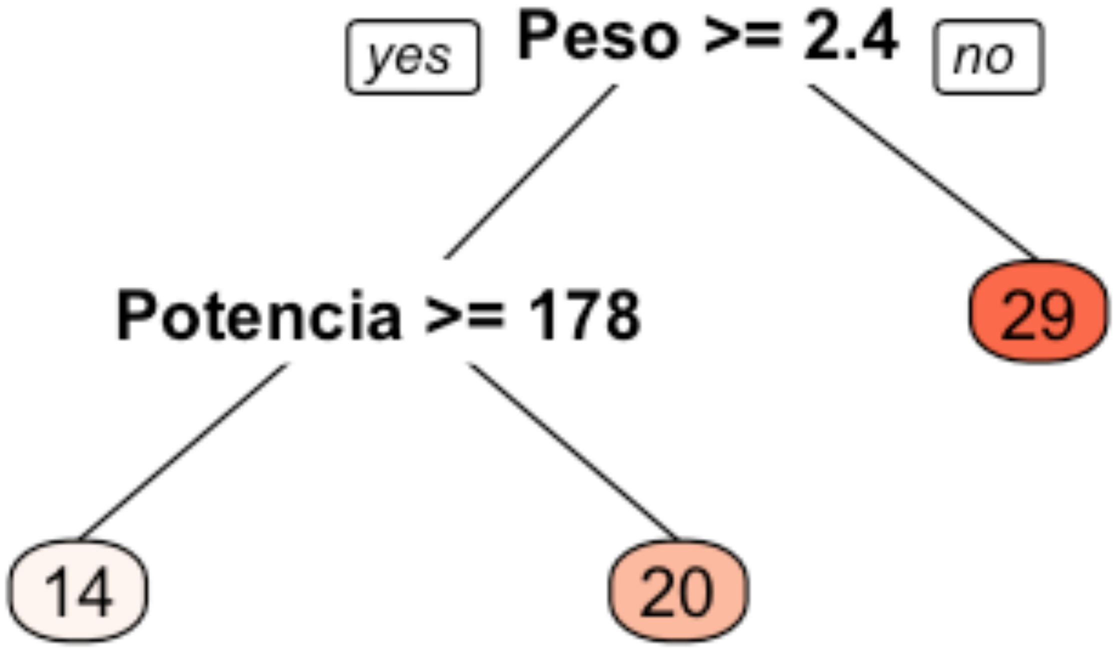

Dataset do consumo de carros em milhas por galão

Construir uma árvores de decisão

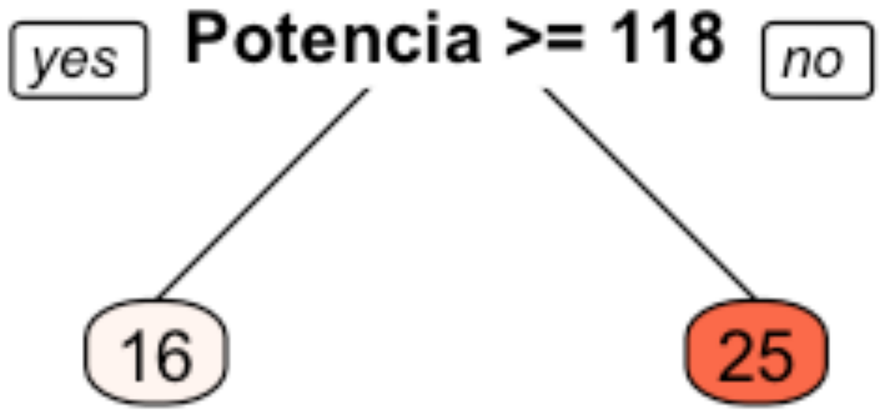

Minimizar o desvio quadrático médio:

ERRO QUADRÁTICO MÉDIO (MSE) = MÉDIA[(REAL(X) – MODELO(x))²]

Construir uma árvores de decisão

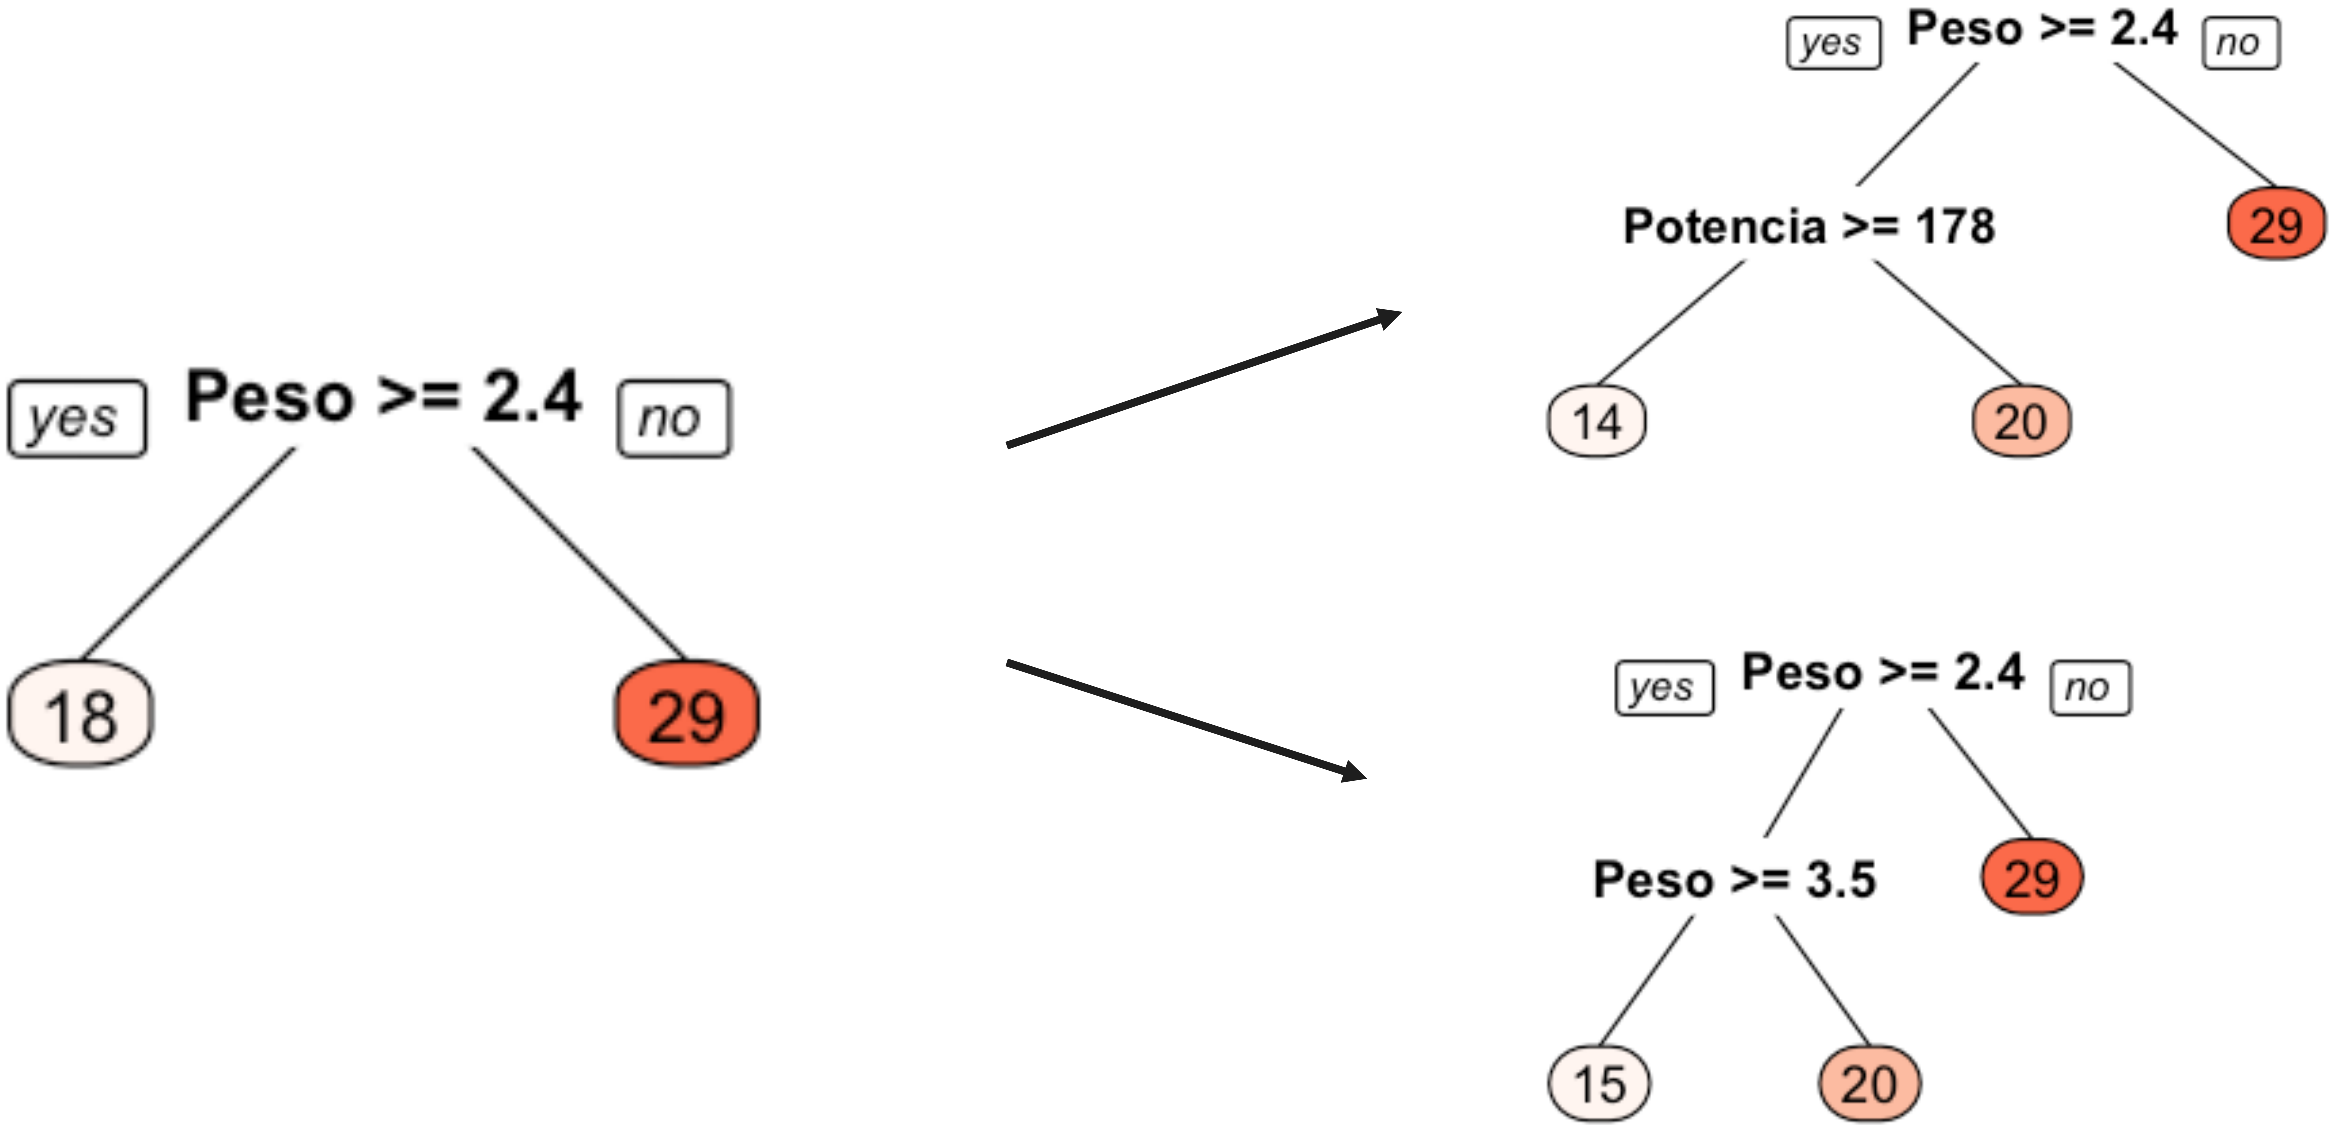

Construir uma árvores de decisão

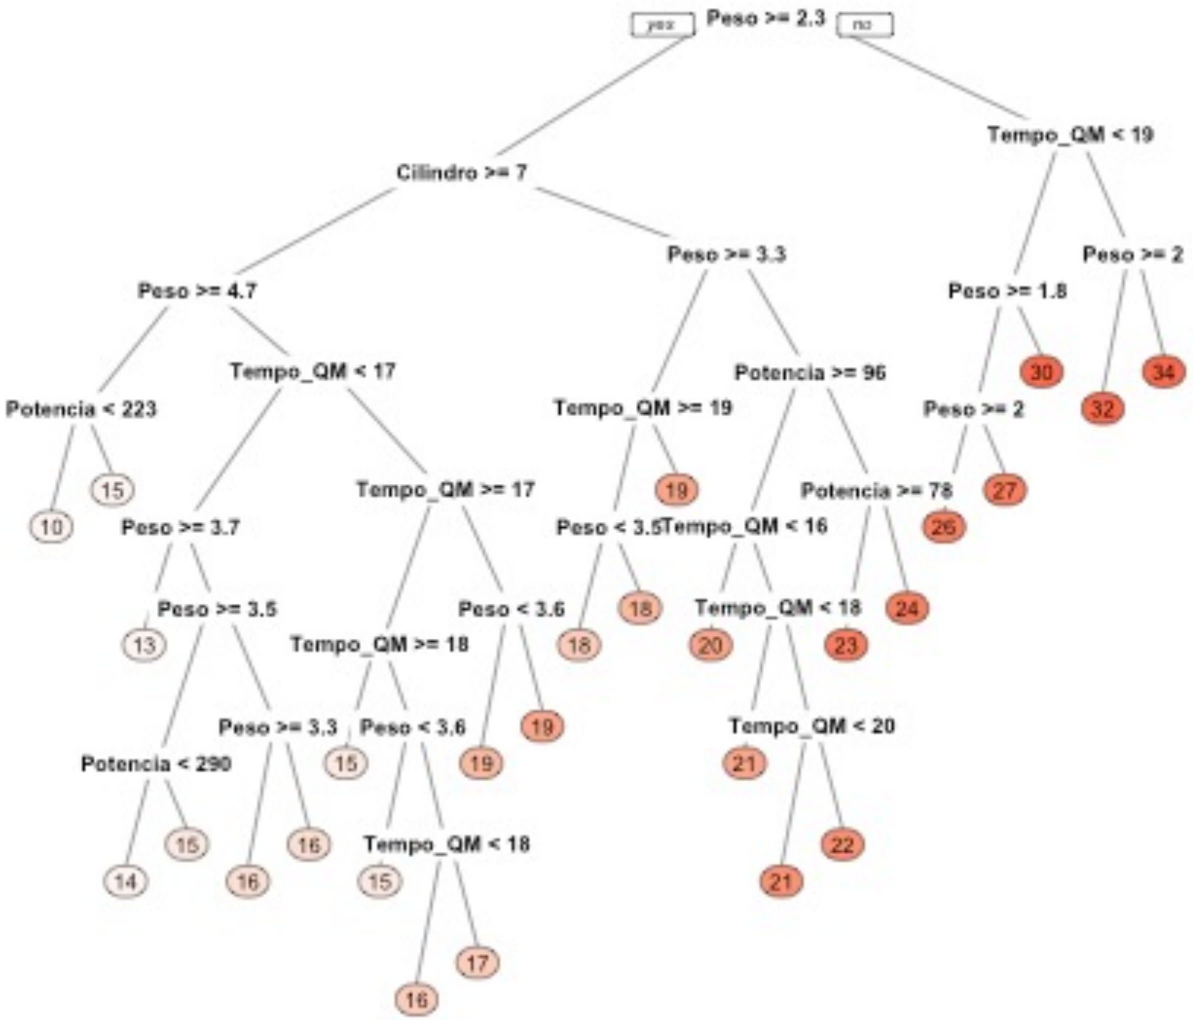

Construir uma árvores de decisão

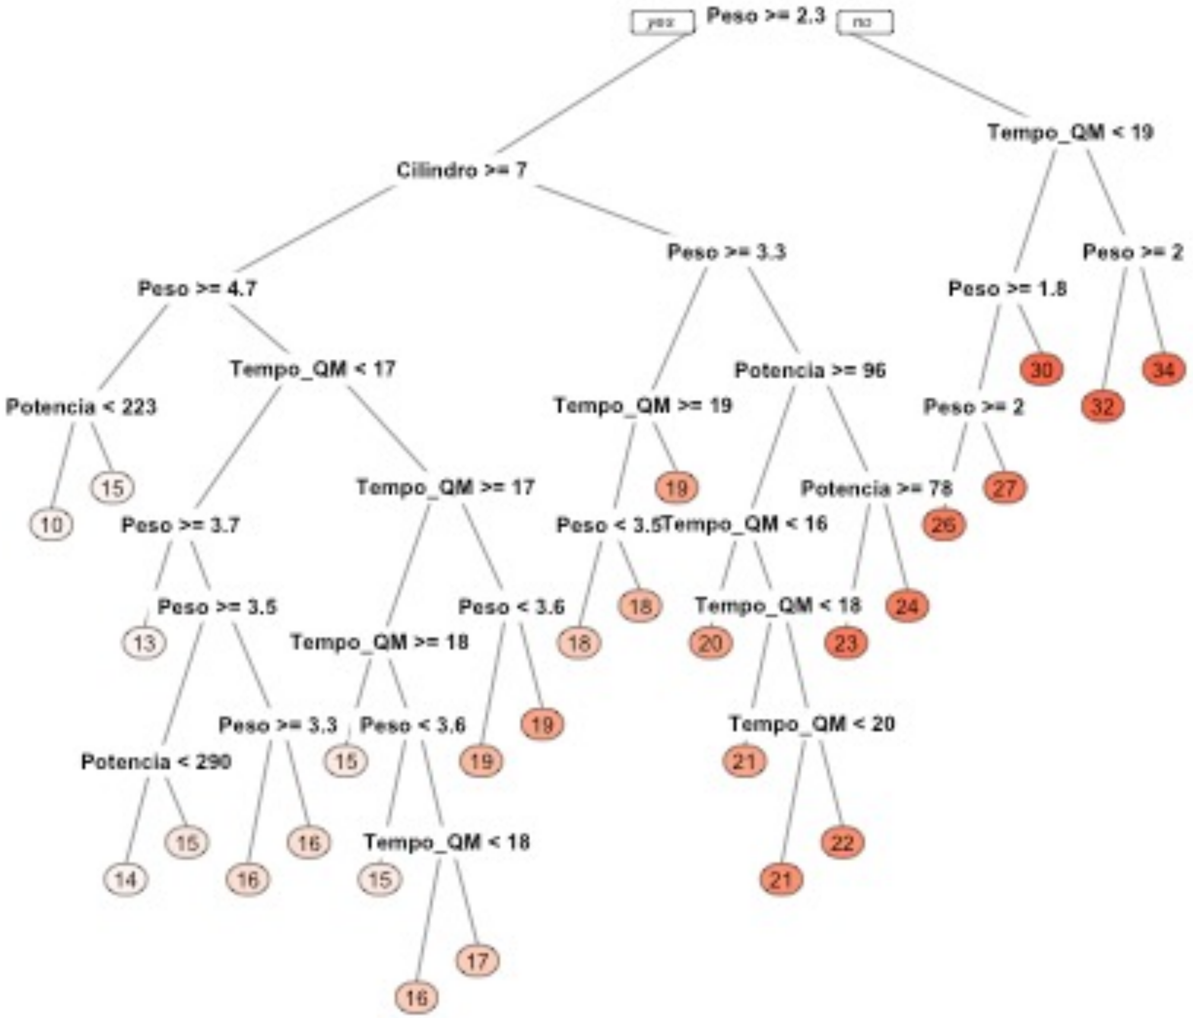

- Pode levar a um sobreajuste
- Deve-se fazer uma “poda” da árvore (pruning)

Construir uma árvores de decisão

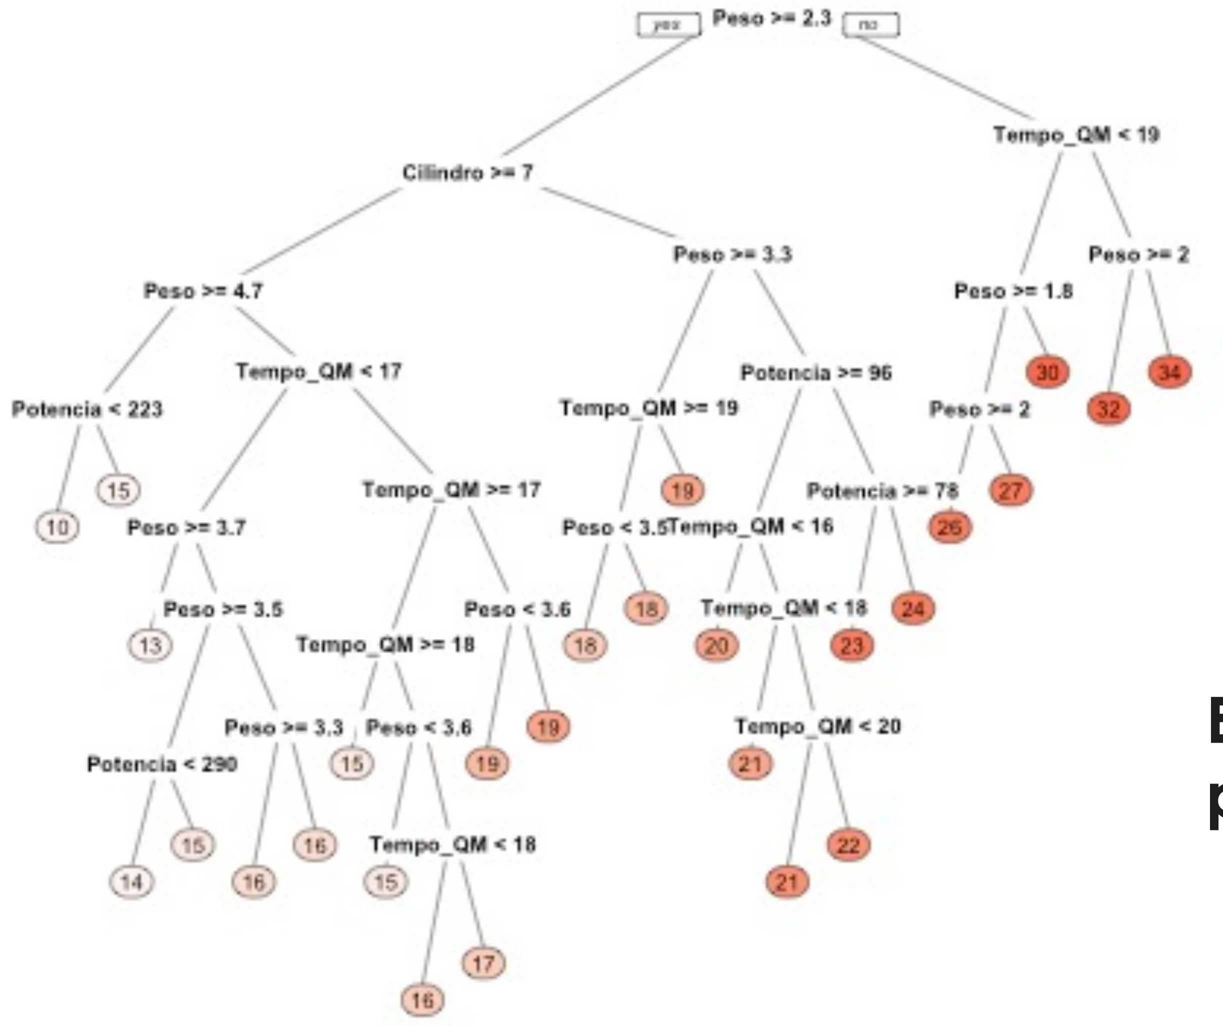

- Pode levar a um sobreajuste
- Deve-se fazer uma “poda” da árvore (pruning)

ERRO QUADRÁTICO MÉDIO (MSE) + Parametro de poda vezes o número de folhas

Classificação com árvores de decisão

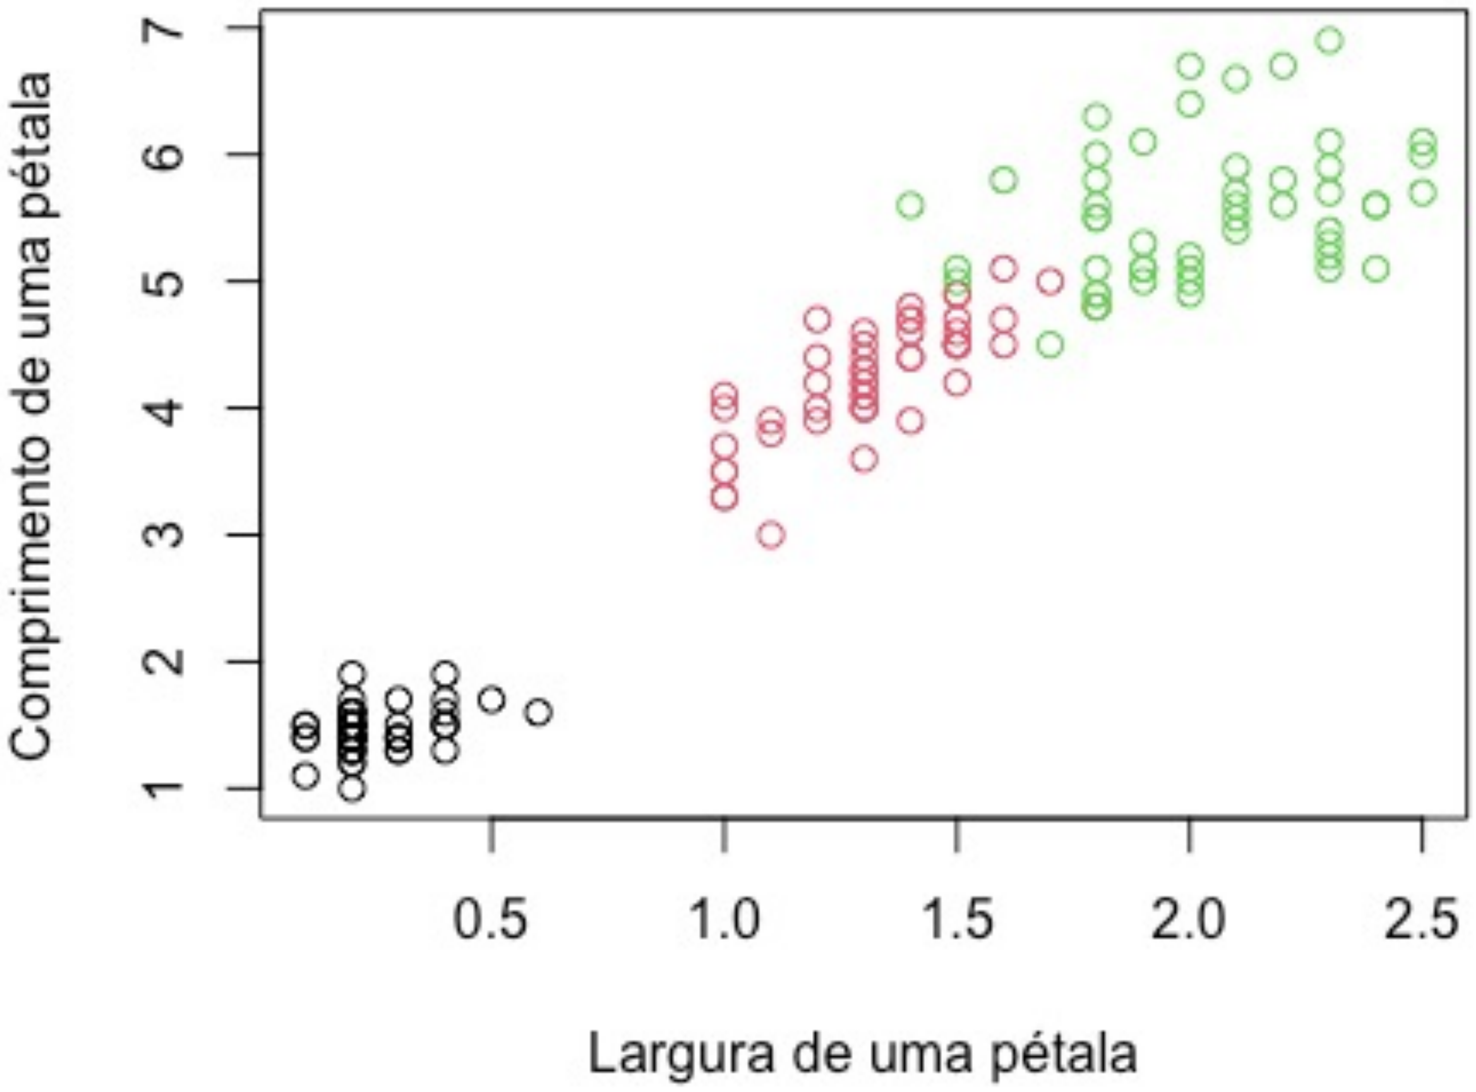

Classificação com árvores de decisão

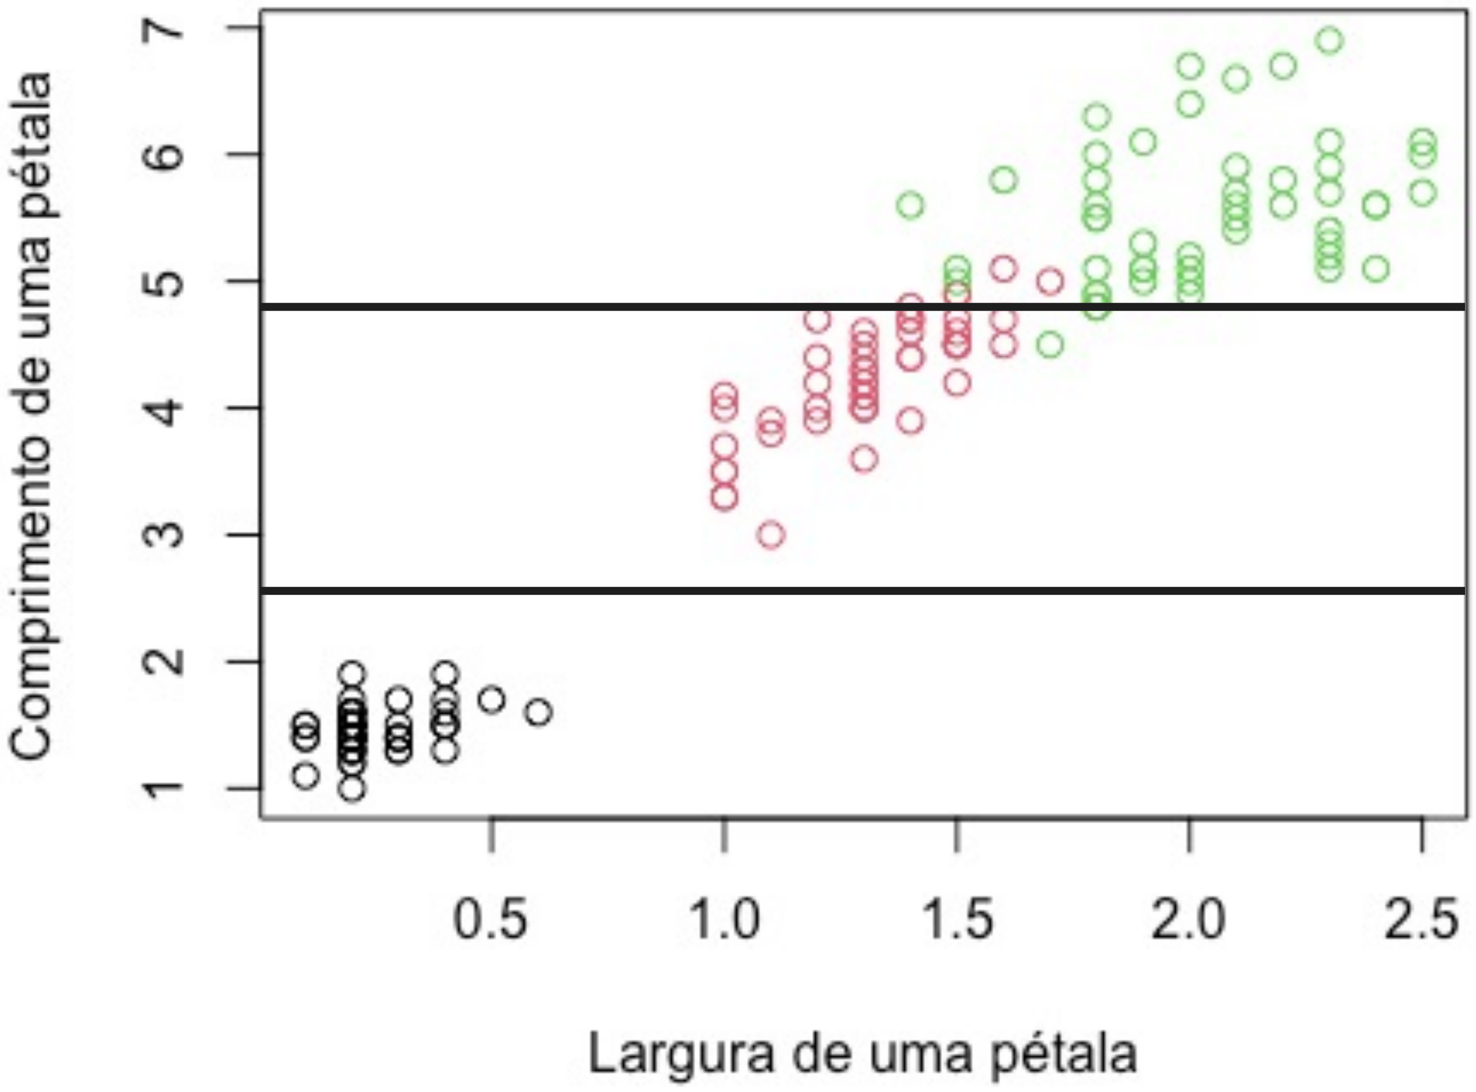

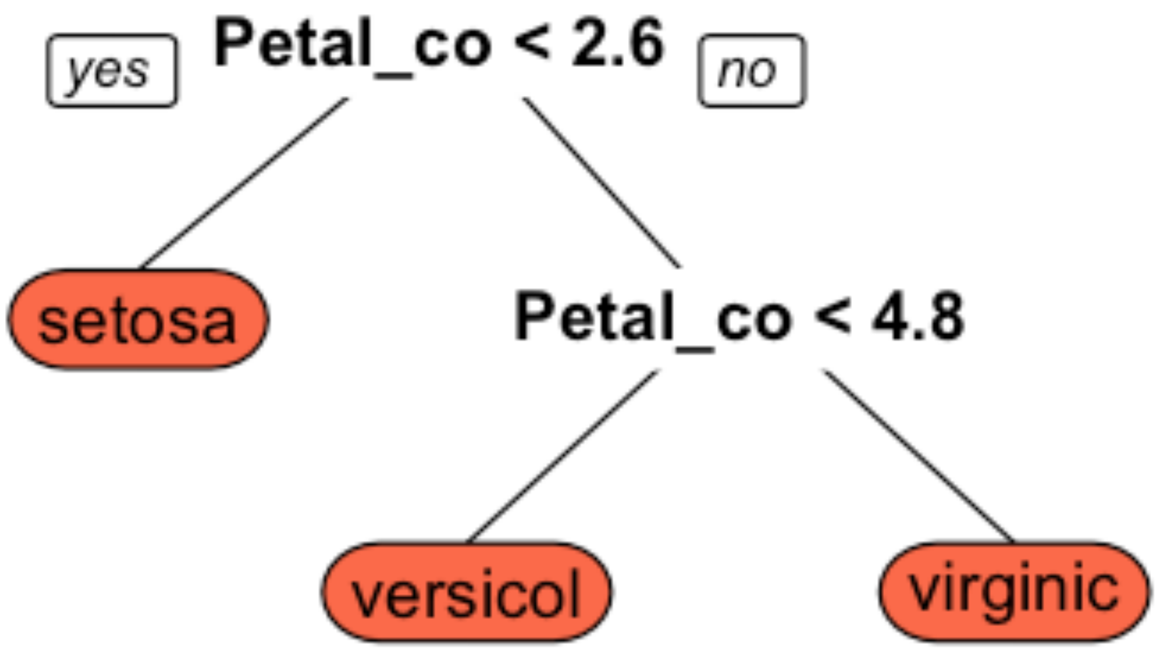

Contruir árvore de decisão para classificação

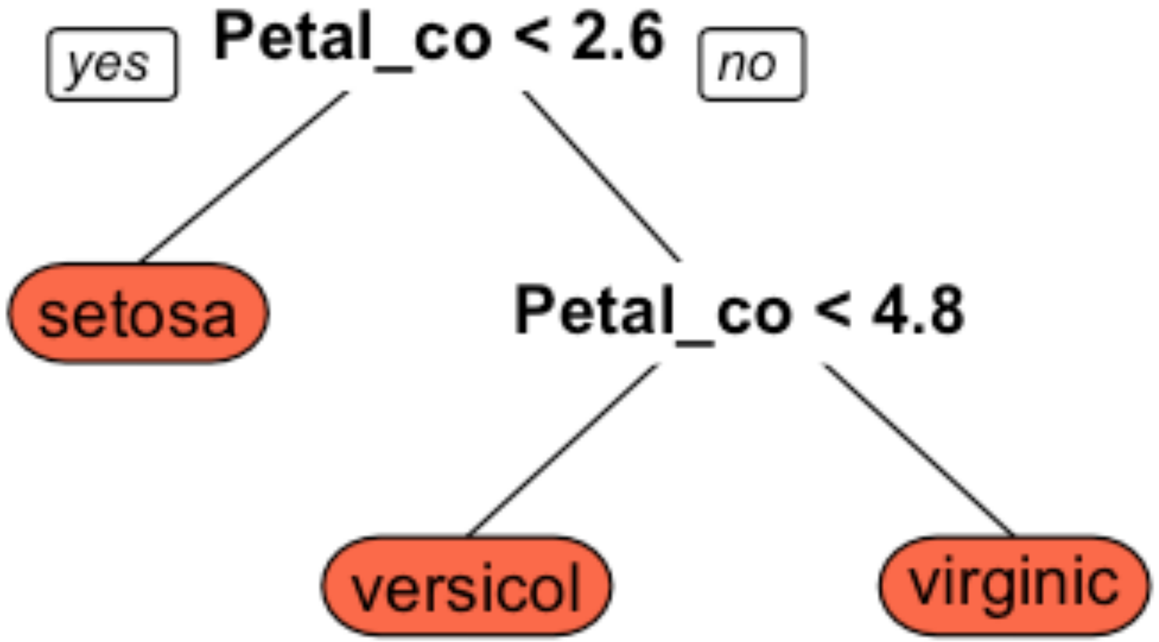

- O desvio quadrático médio não pode ser usado e a taxa de erro dá maus resultados.

- Usam-se dois parámetros:
  - O Índice de Gini
  - Entropia de informação

Vantagem e desvantagem das árvores de decisão

Vantagem:

- Simples de interpretar

Vantagem e desvantagem das árvores de decisão

Vantagem:
- Simples de interpretar

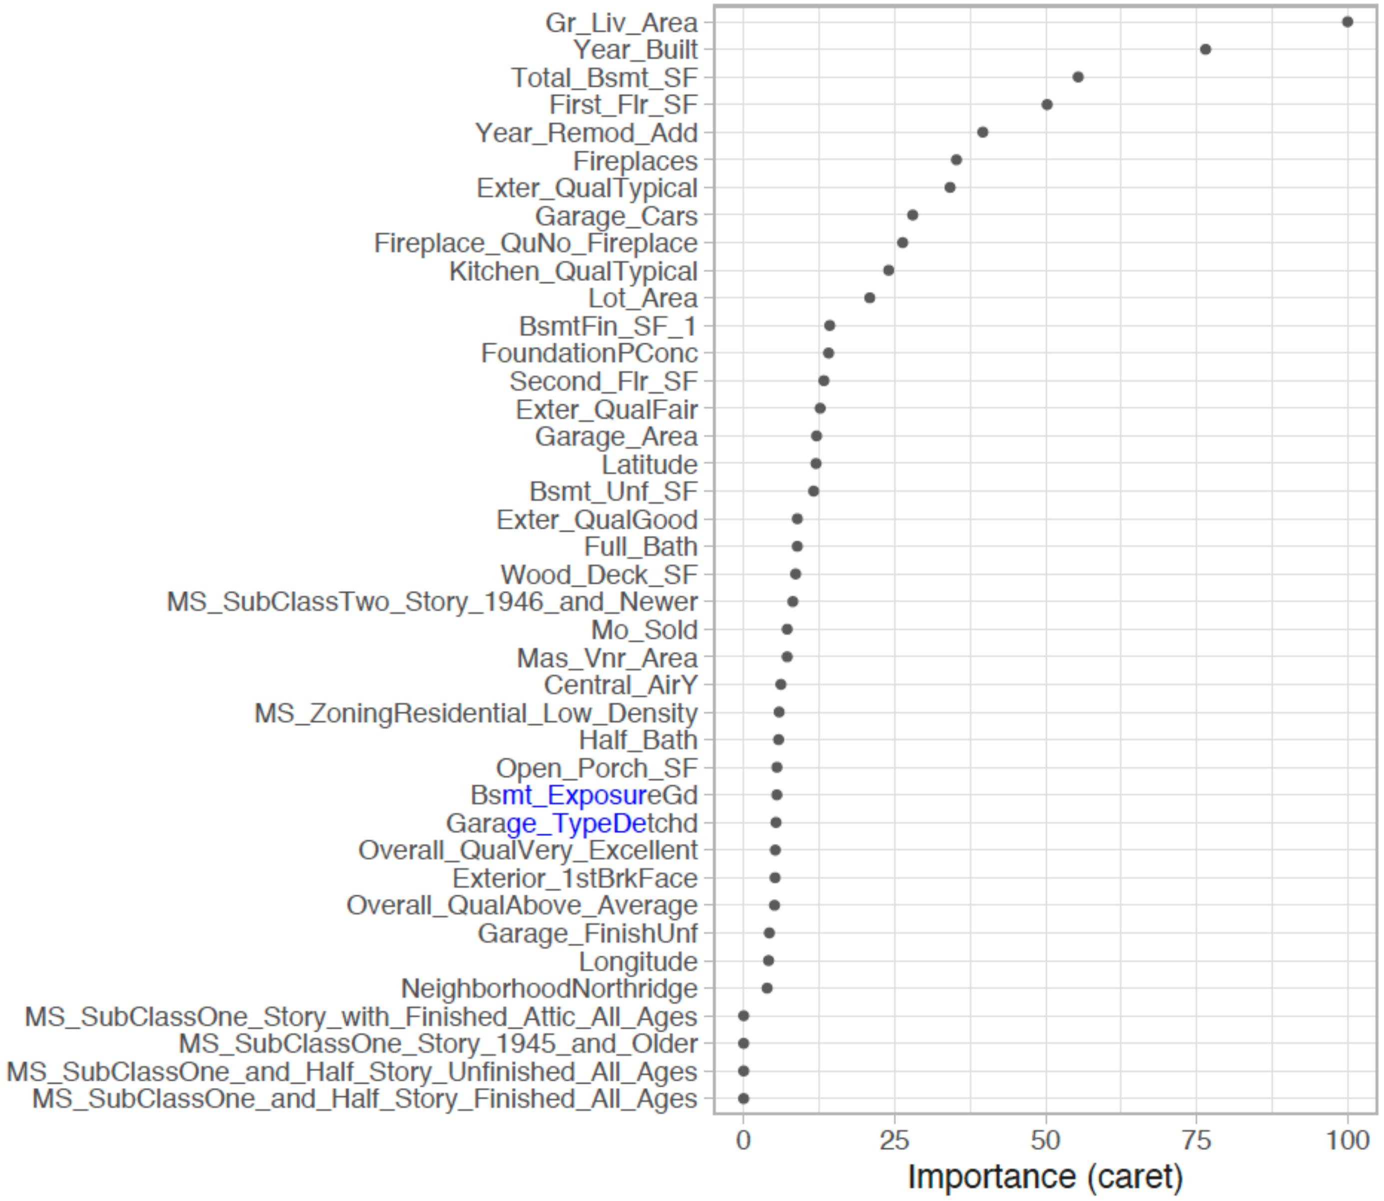

Vantagem e desvantagem das árvores de decisão

Vantagem:

- Simples de interpretar

Desvantagem:

- Em termos de precisão é pior do que a maioria dos métodos de machine learning

Vantagem e desvantagem das árvores de decisão

Vantagem:

- Simples de interpretar

Desvantagem:

- Em termos de precisão é pior do que a maioria dos métodos de machine learning

Solução:

- Combinar várias árvores em simultâneo usando métodos como bagging, boosting e random forests.

Random Forest

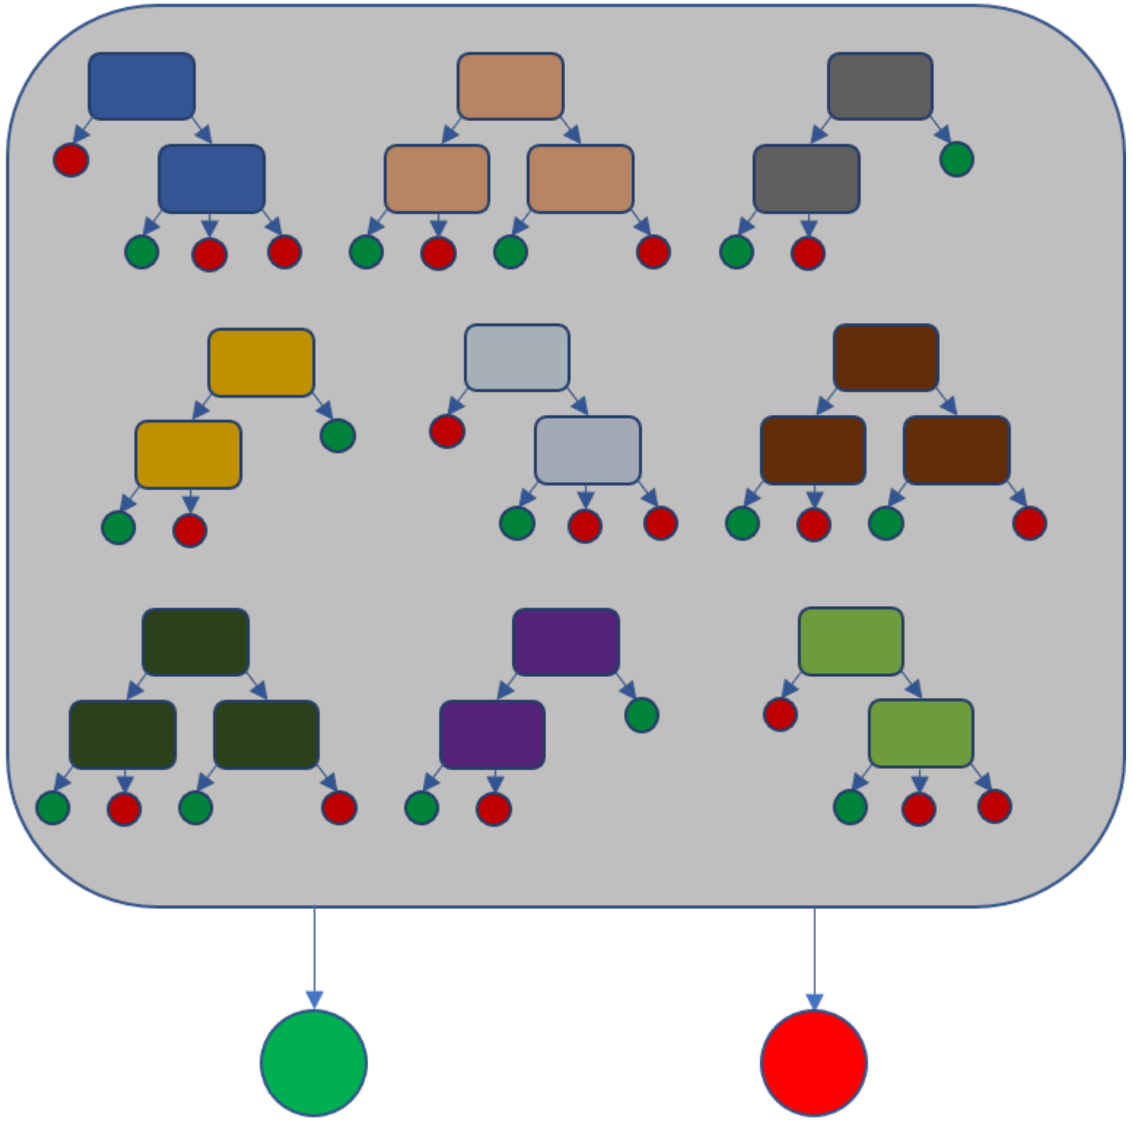

- Constroi árvores descorrelacionadas umas das outras
- Faz a media do resultado conjunto das várias arvores

Máquinas de Vetores de Suporte

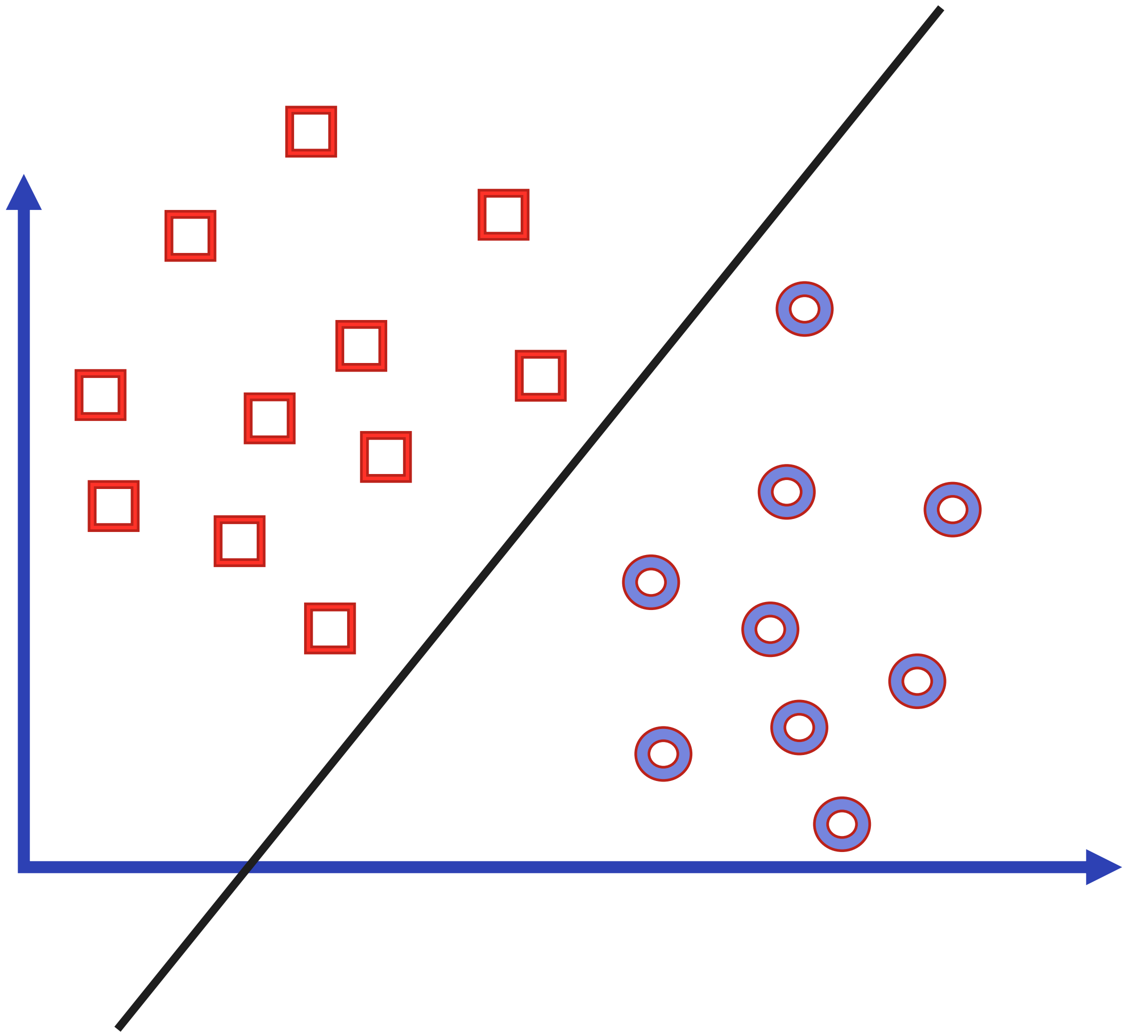

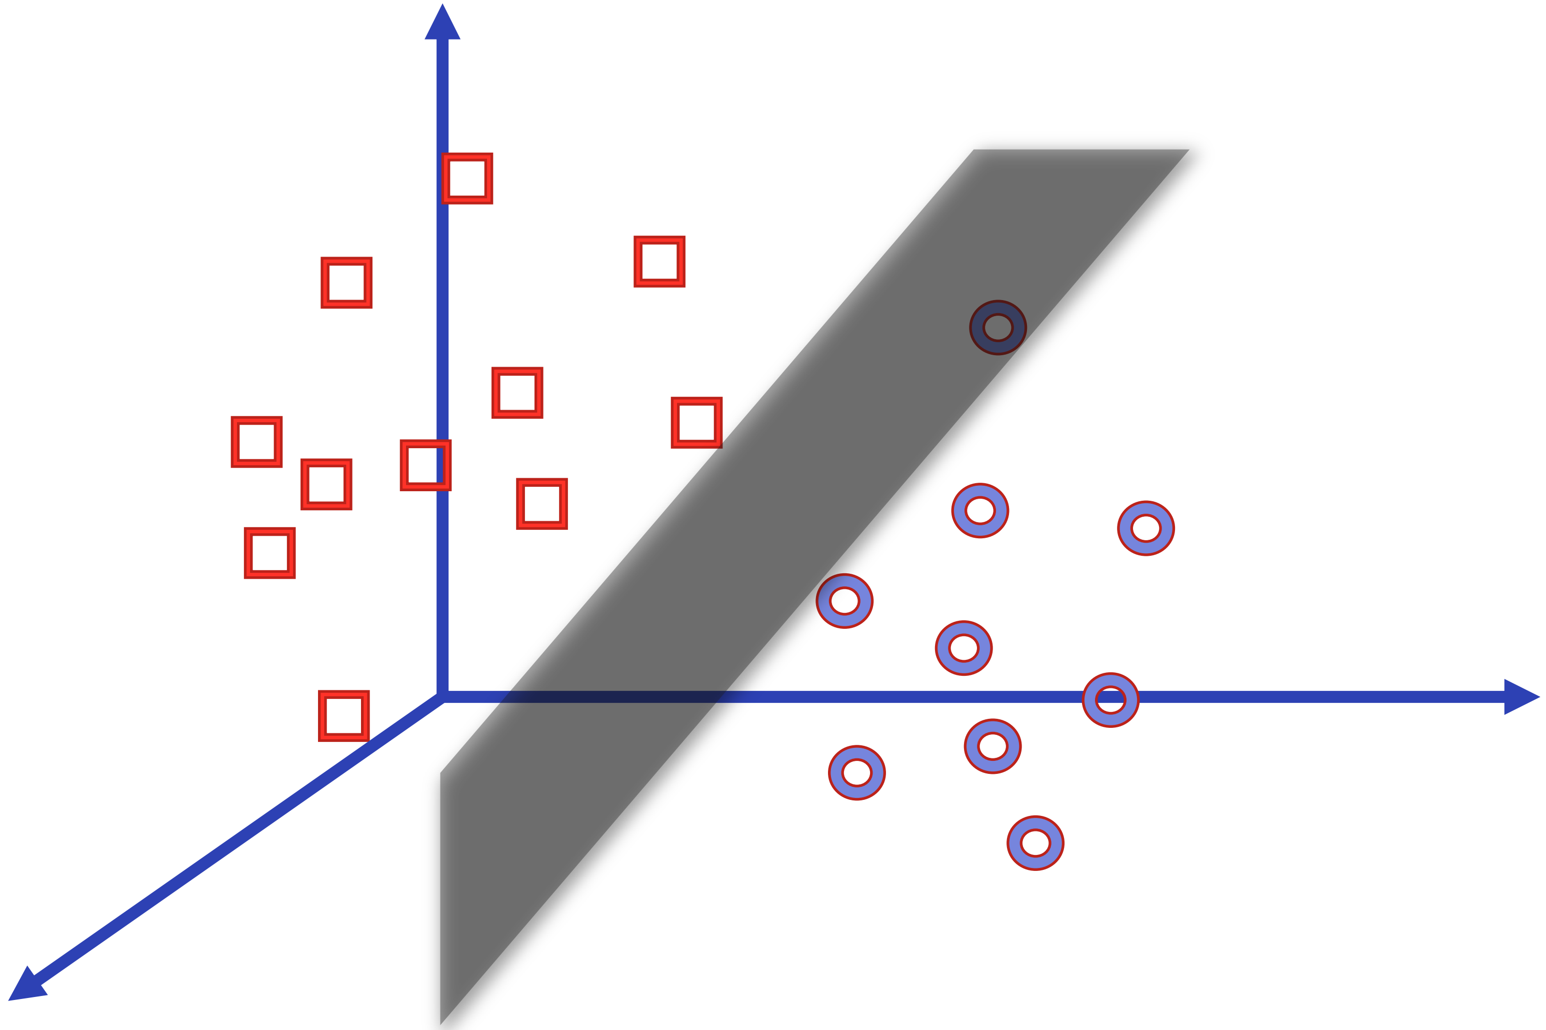

Classificador de Margem Máxima

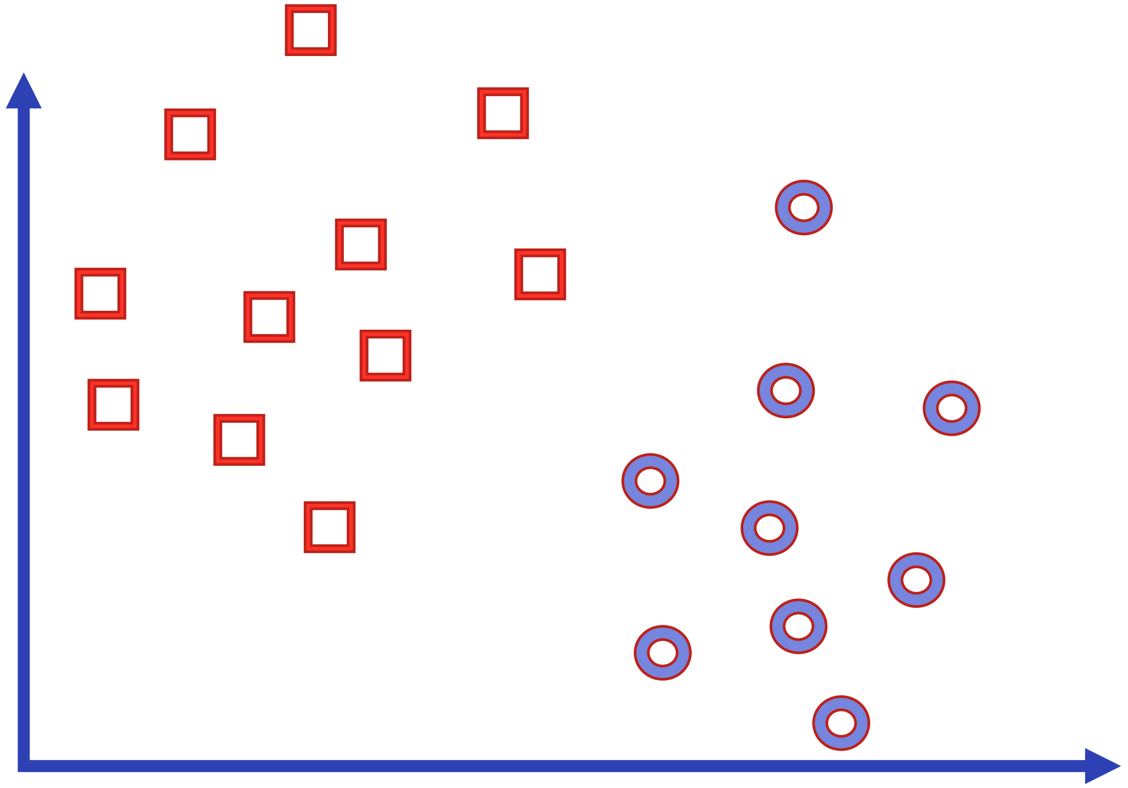

Classificador de Margem Máxima

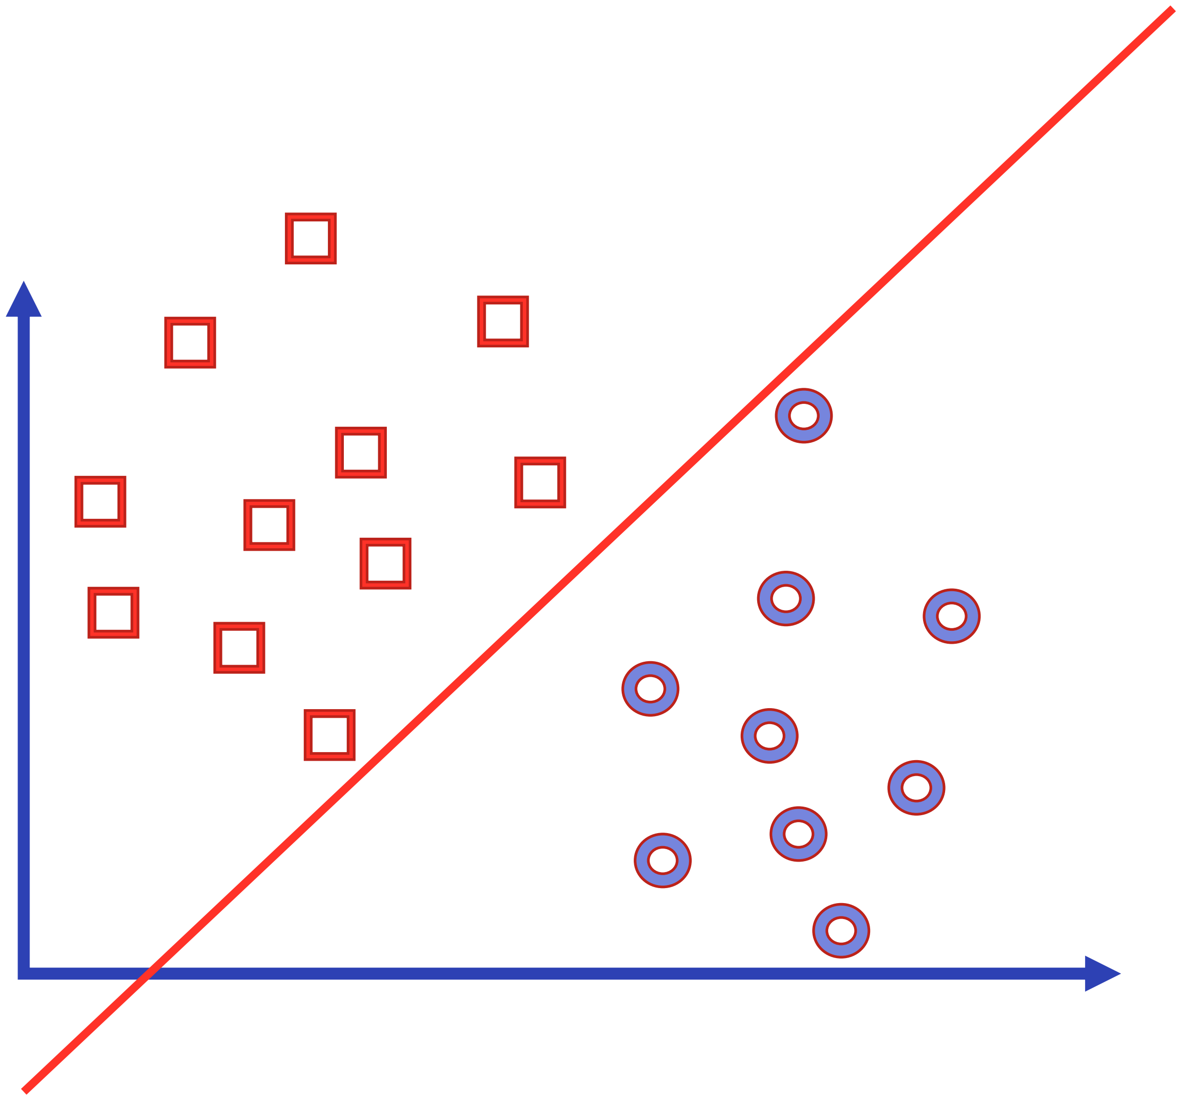

Classificador de Margem Máxima

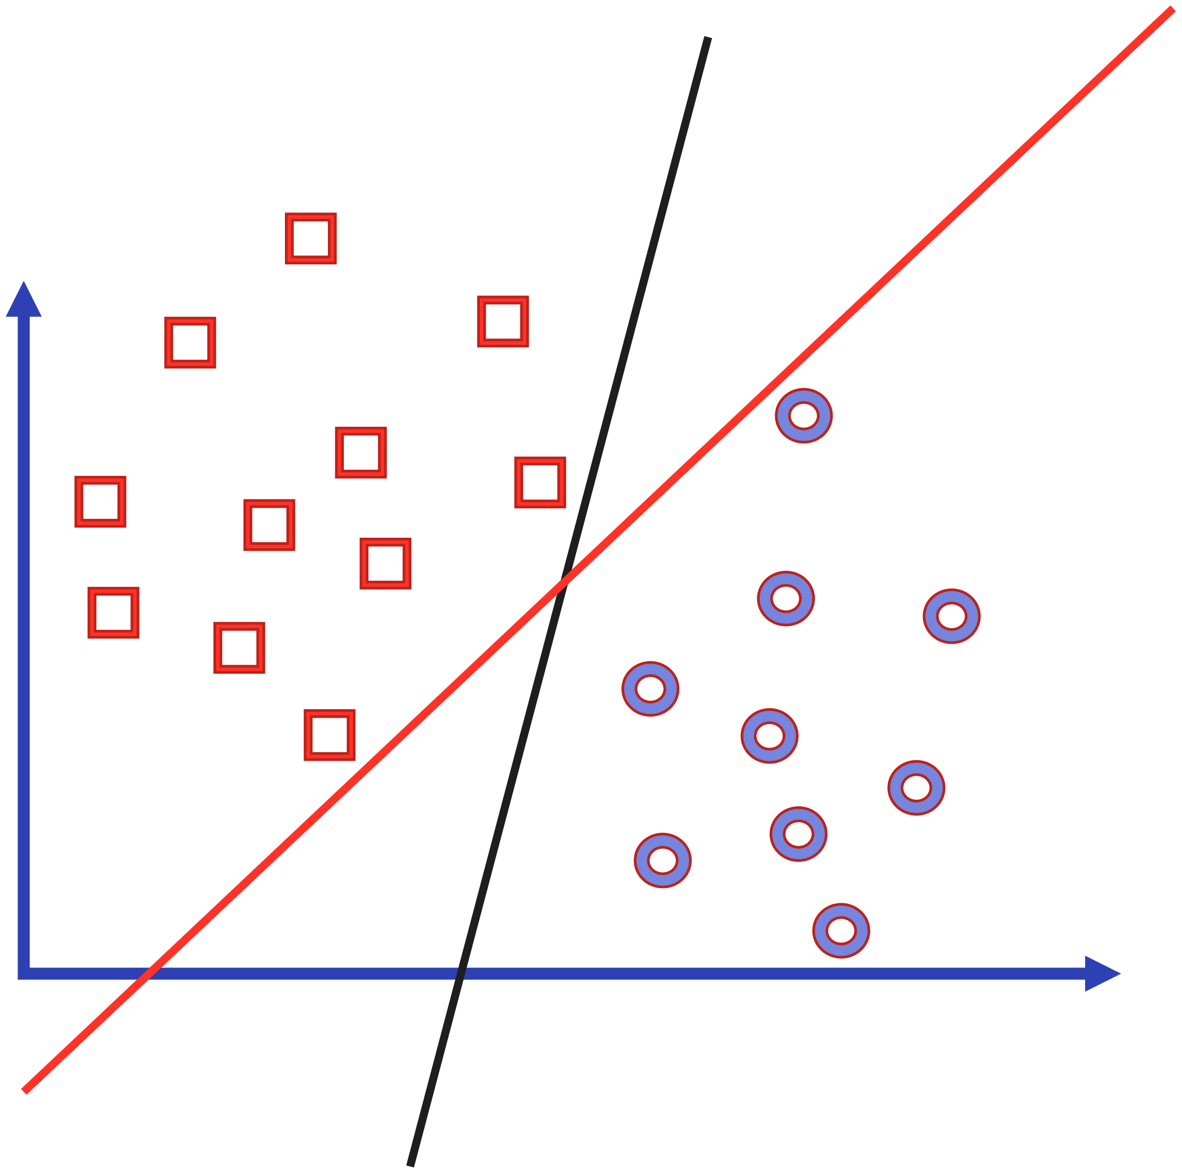

Classificador de Margem Máxima

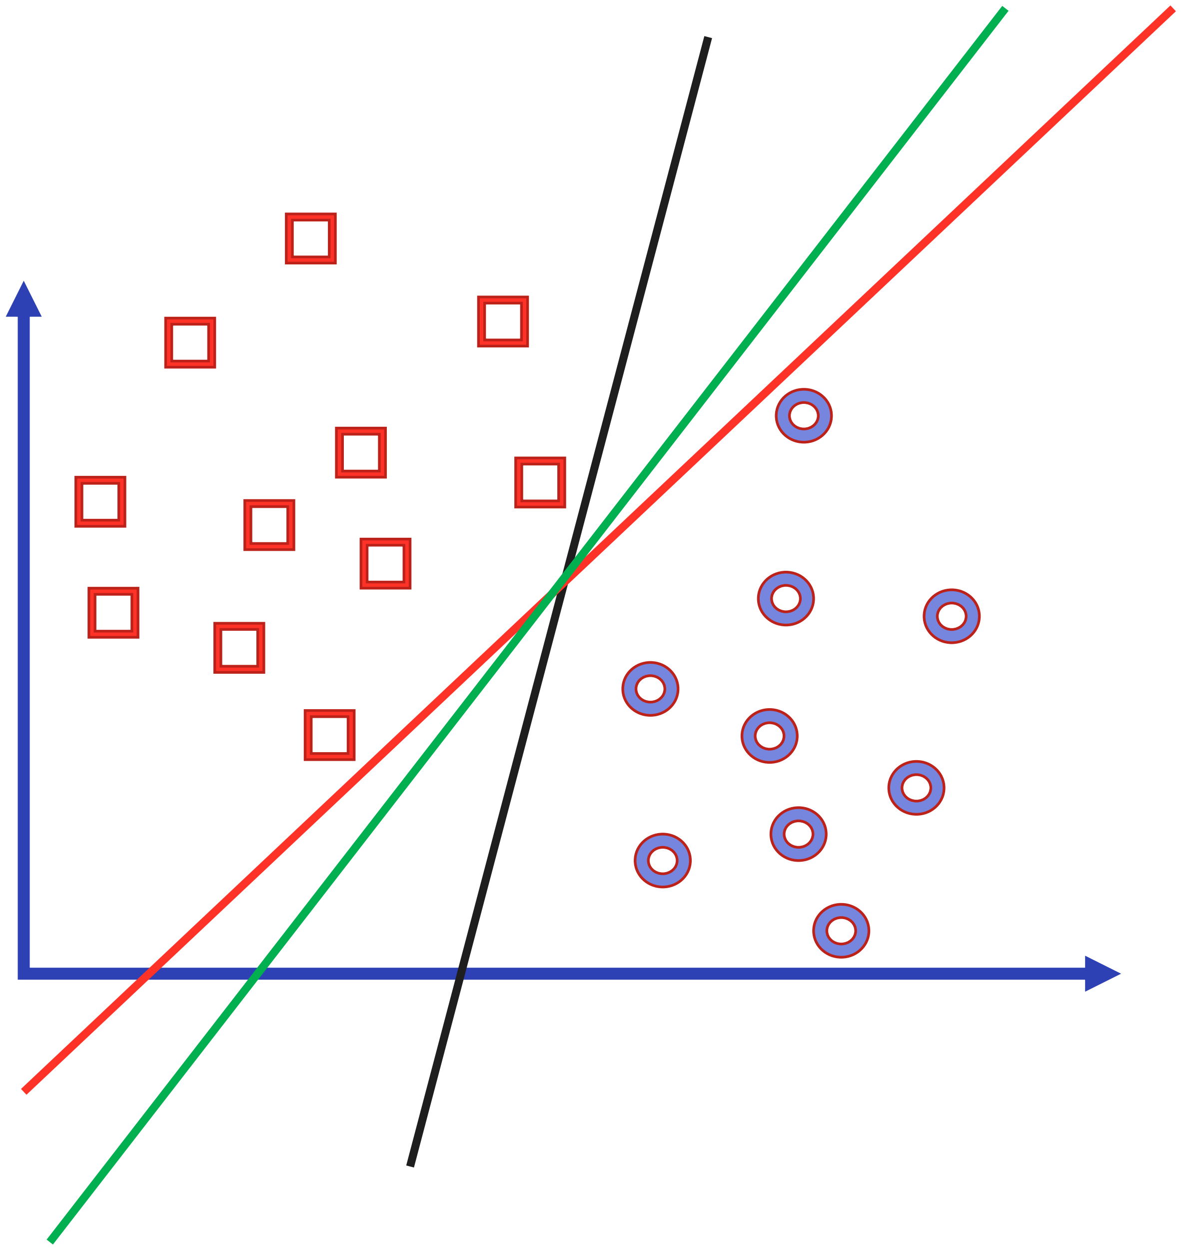

Classificador de Margem Máxima

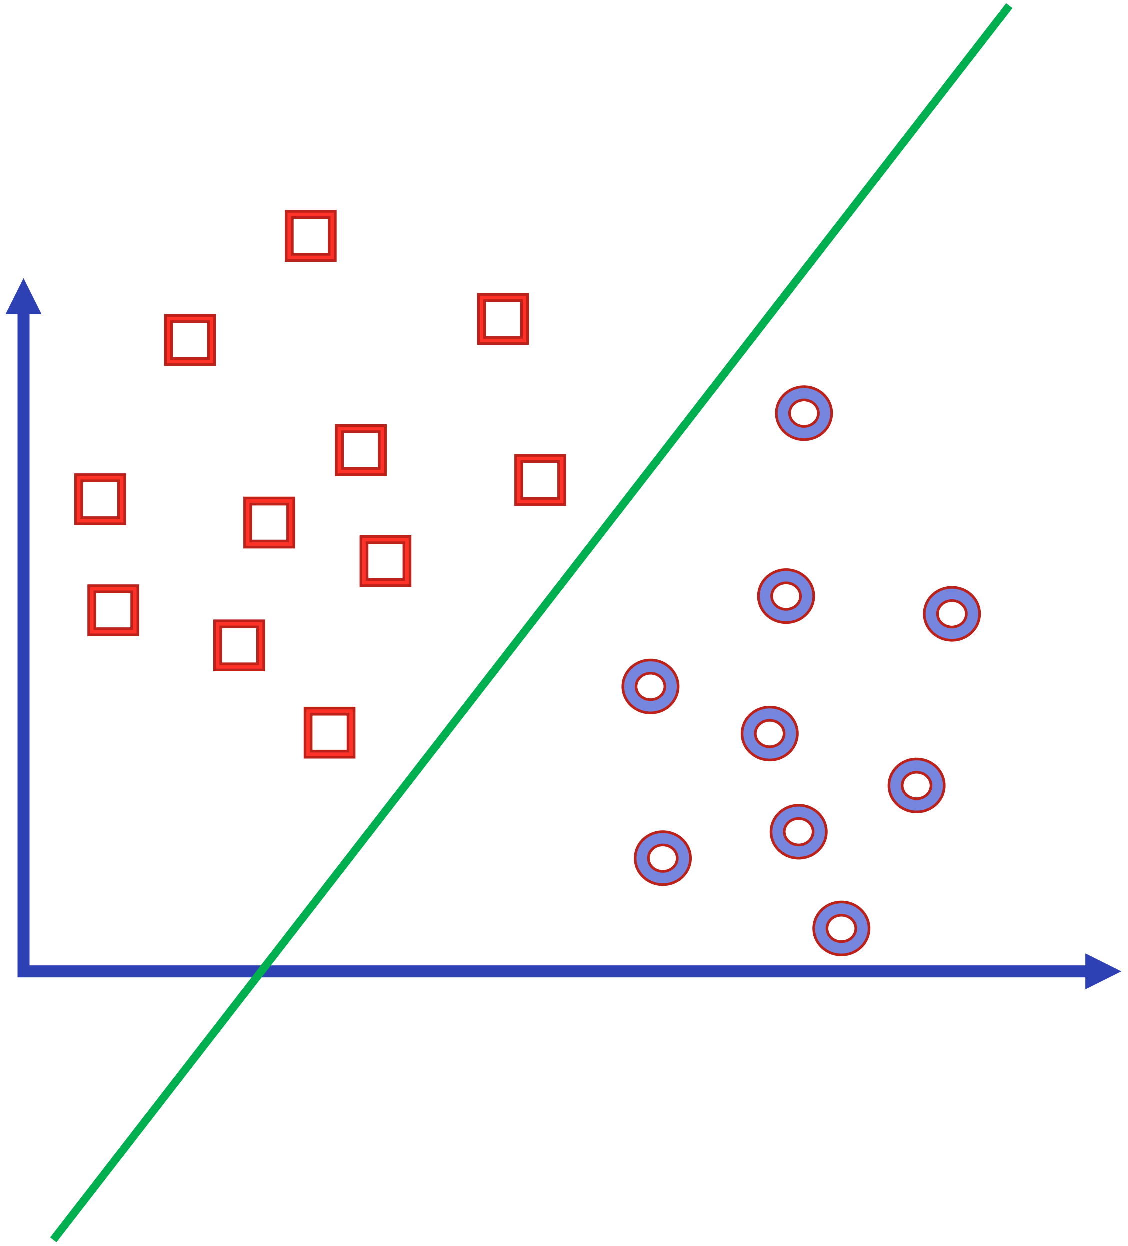

Classificador de Margem Máxima

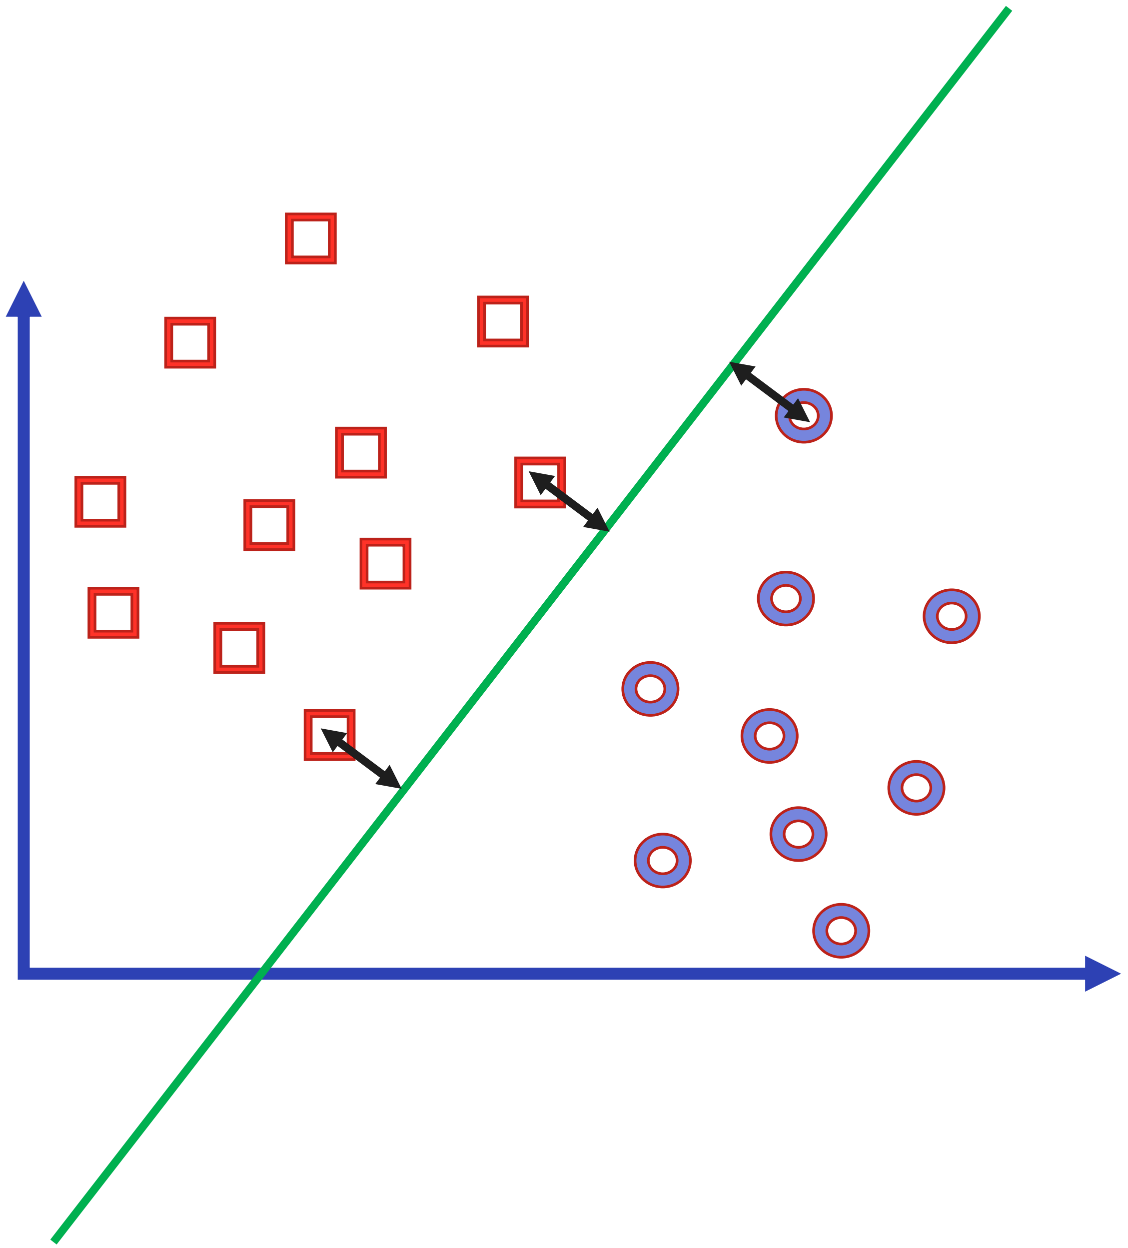

Classificador de Margem Máxima

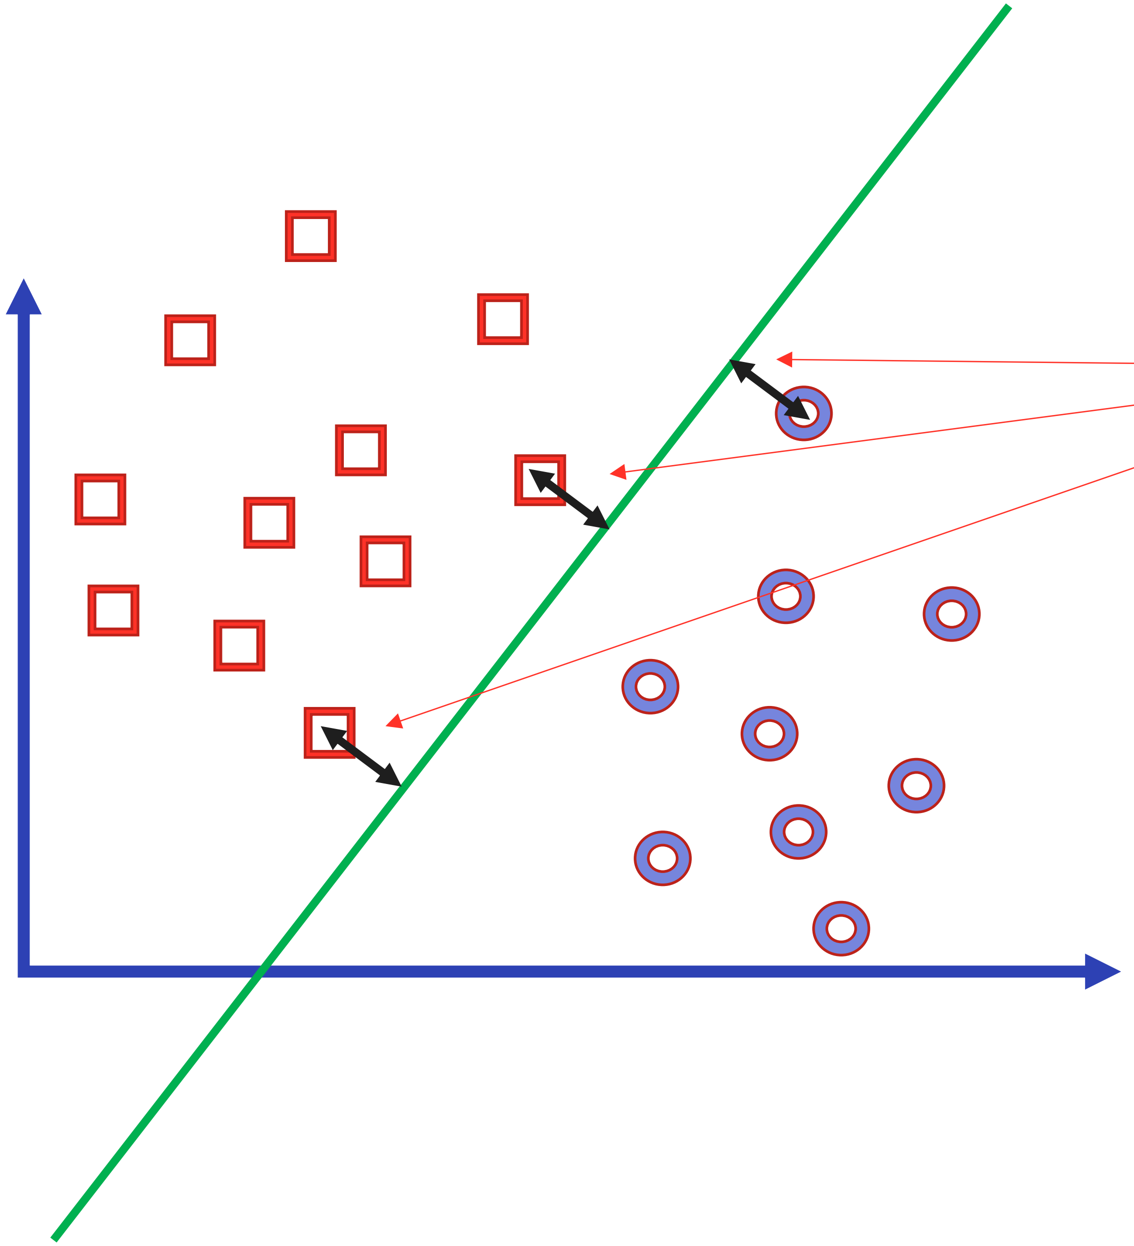

Vetores de suporte

Classificador de Margem Máxima

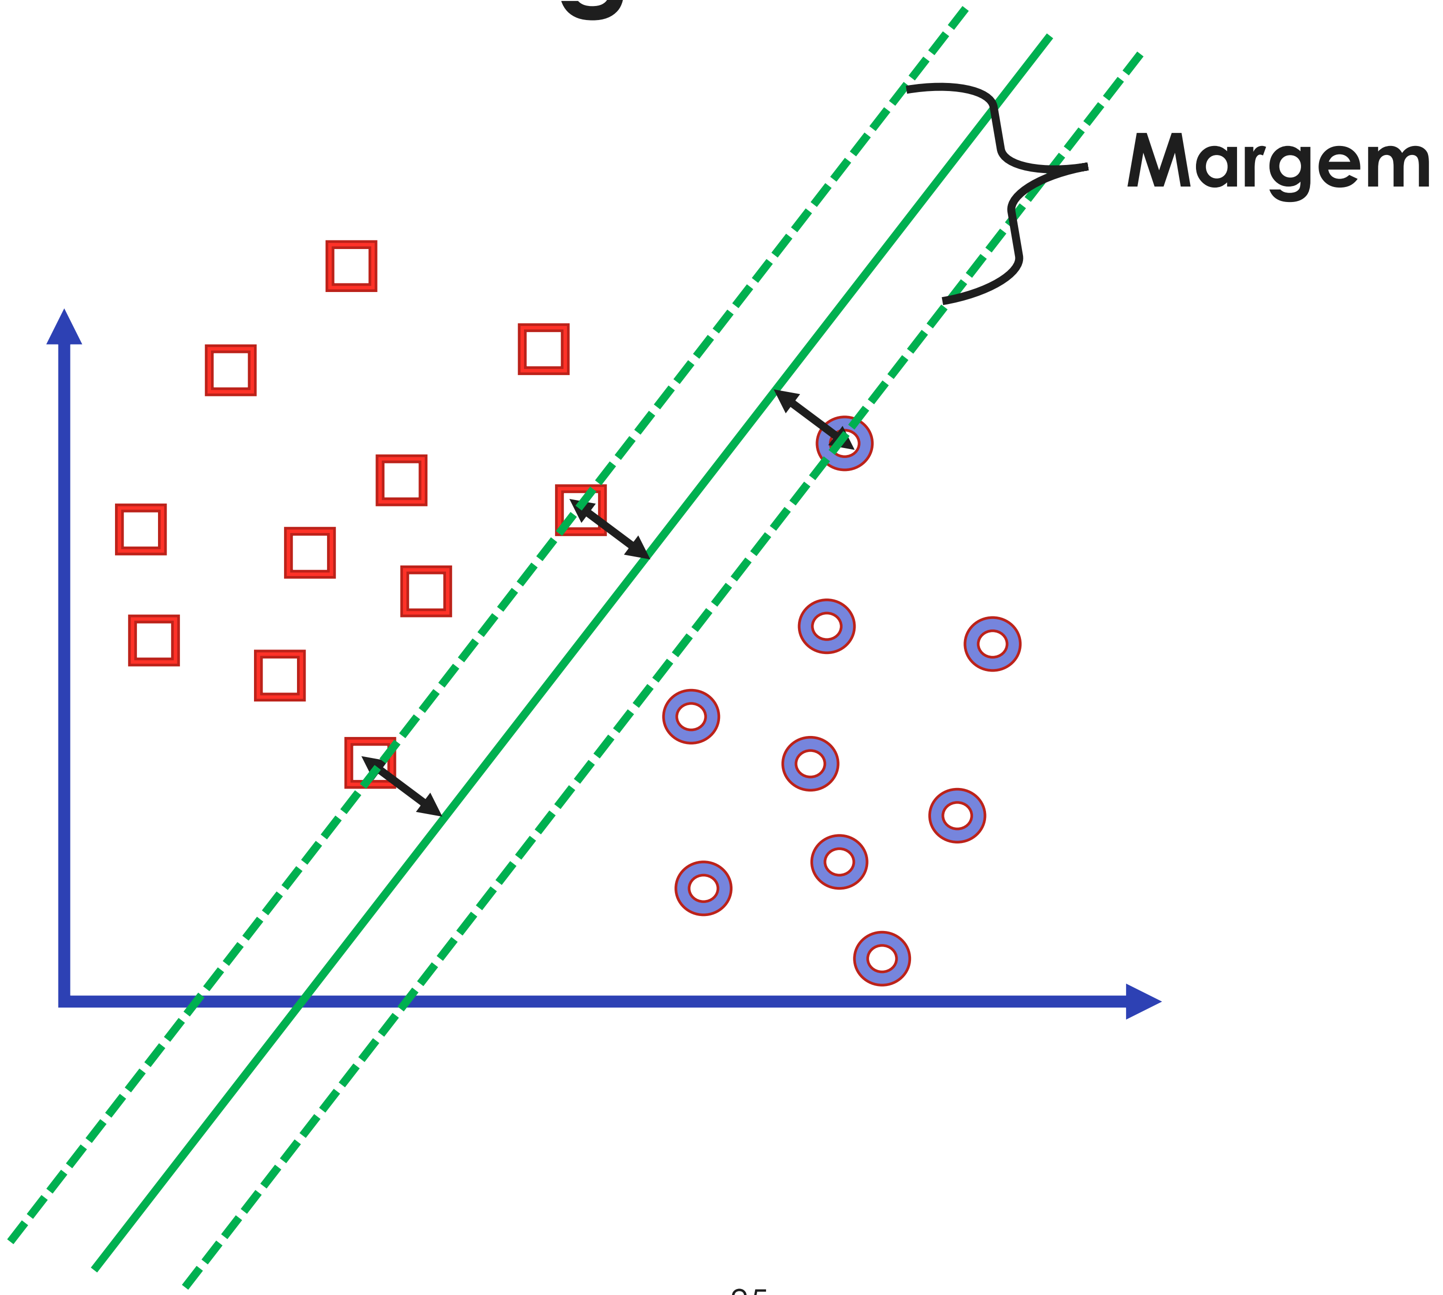

Classificador de Vetores de Suporte

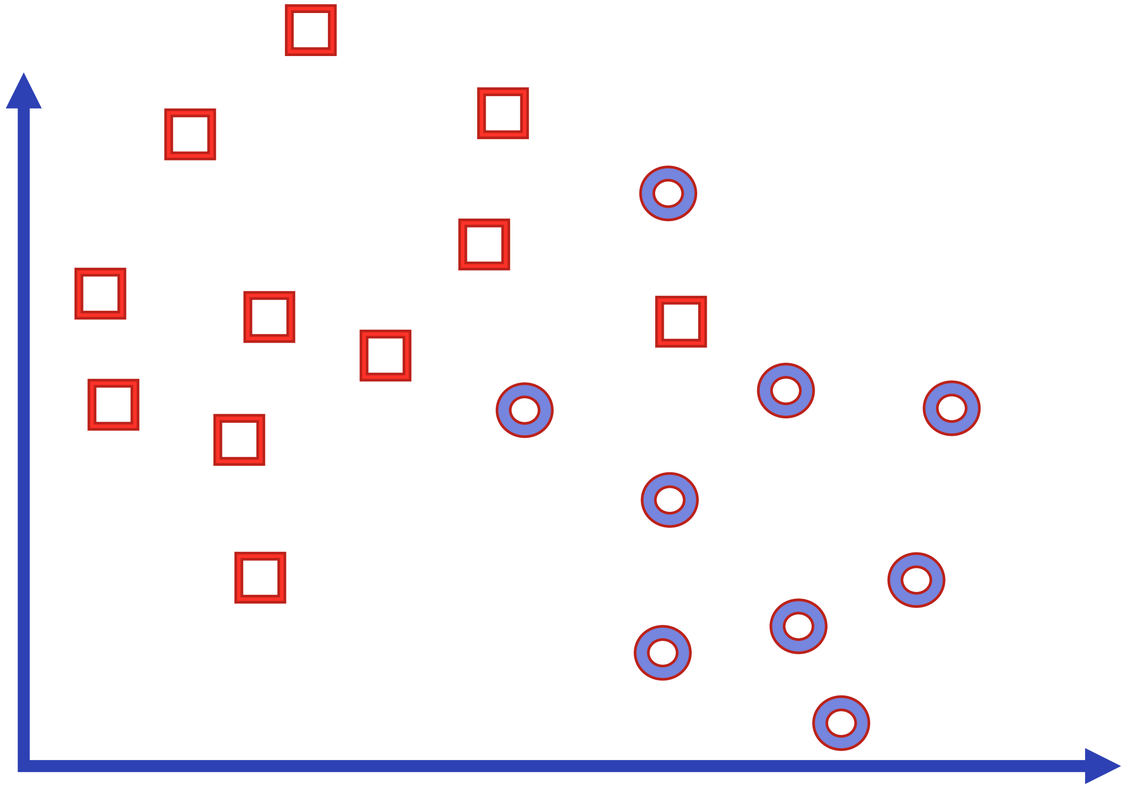

Classificador de Vetores de Suporte

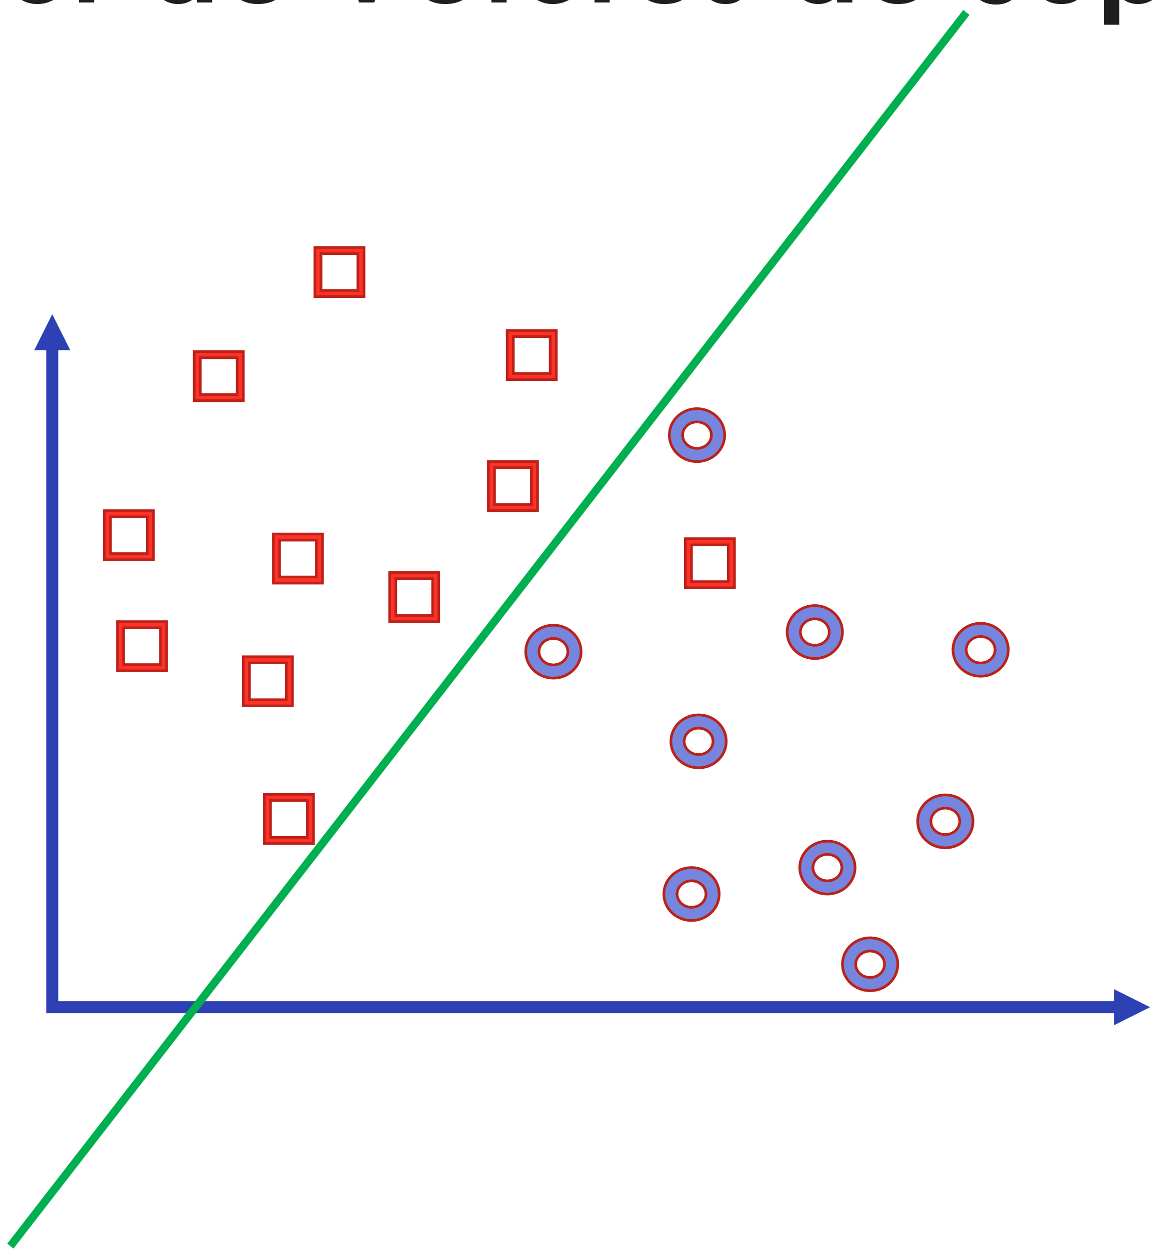

Classificador de Vetores de Suporte

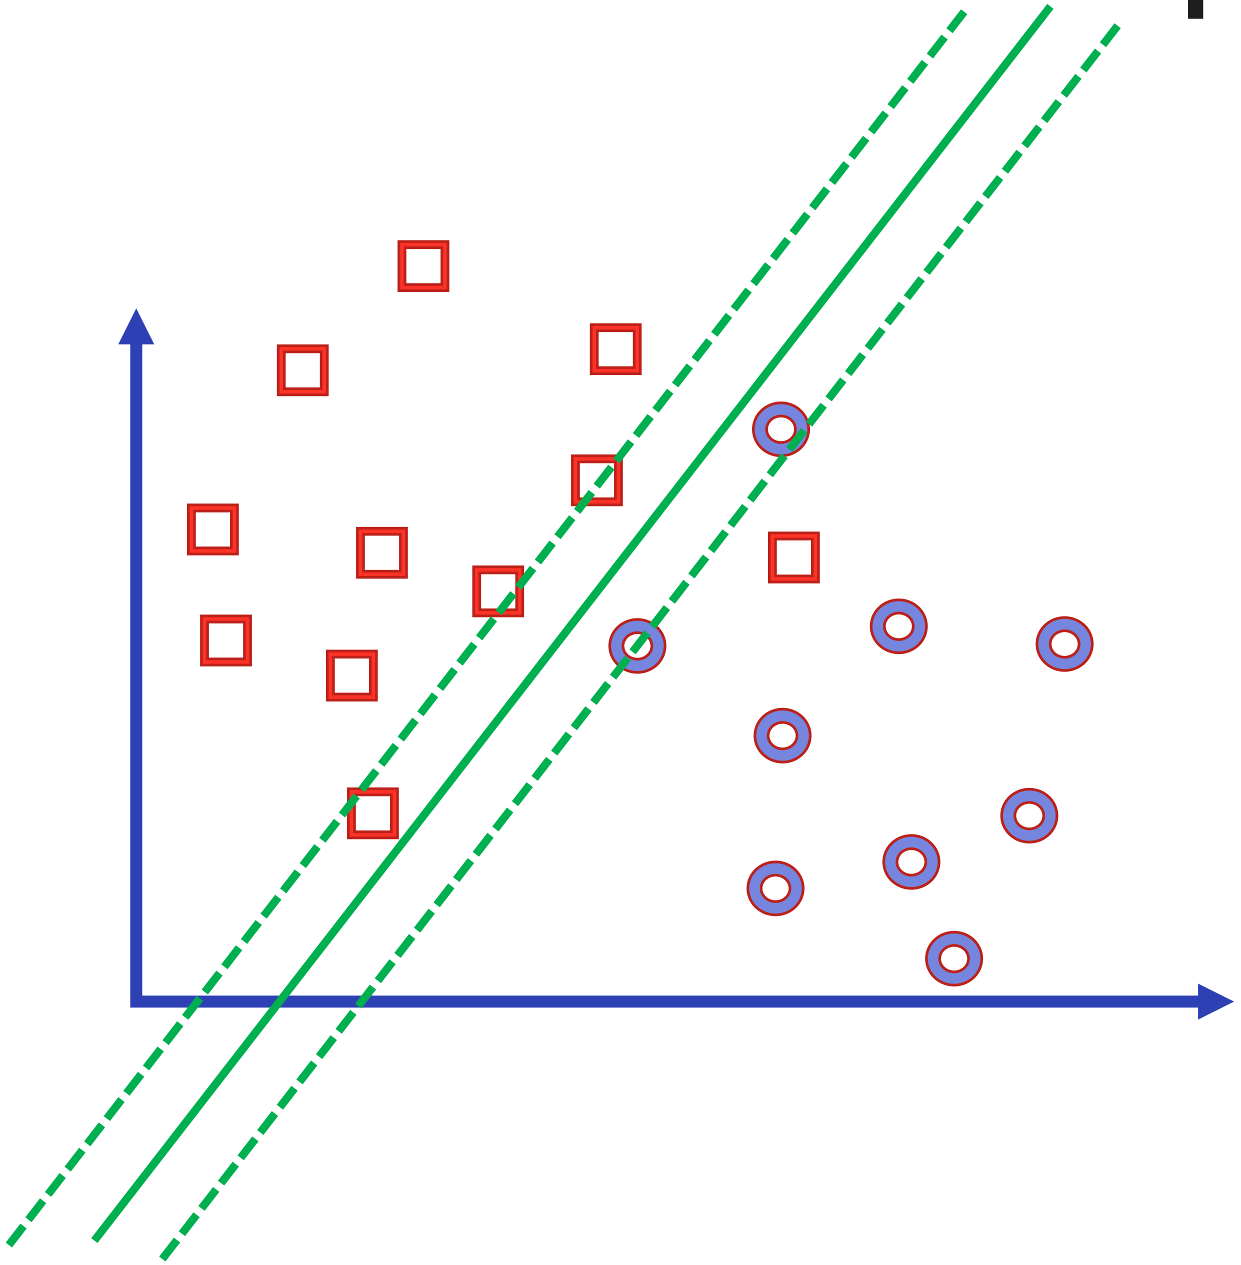

Classificador de Vetores de Suporte

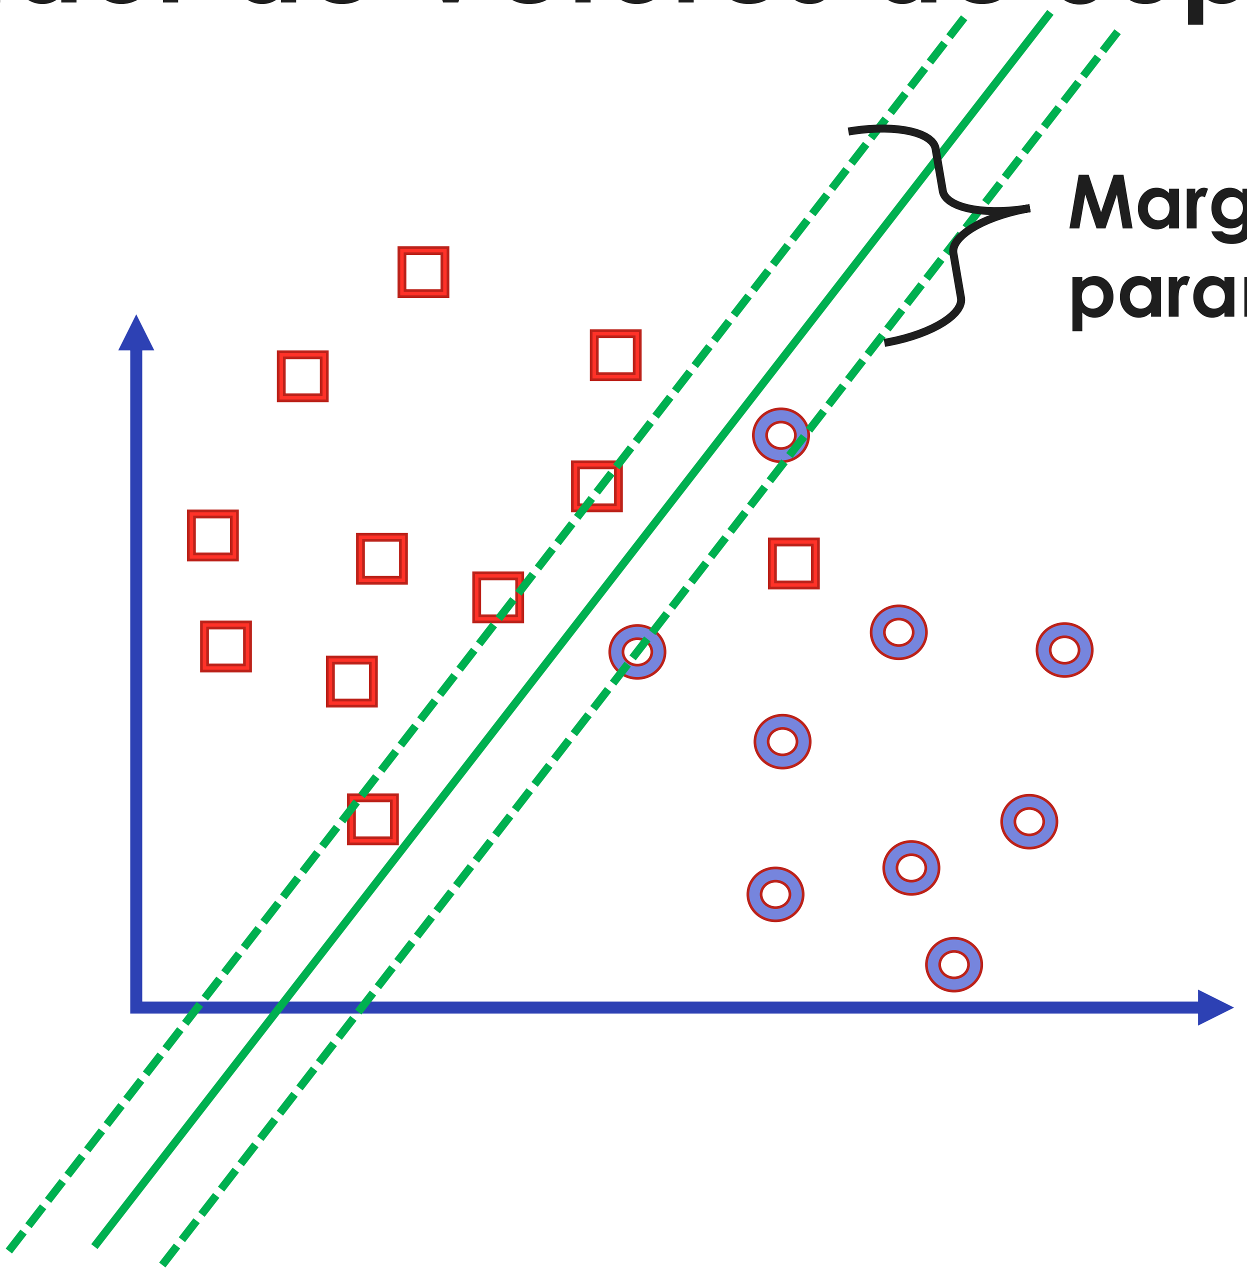

Máquinas de Vetores de Suporte

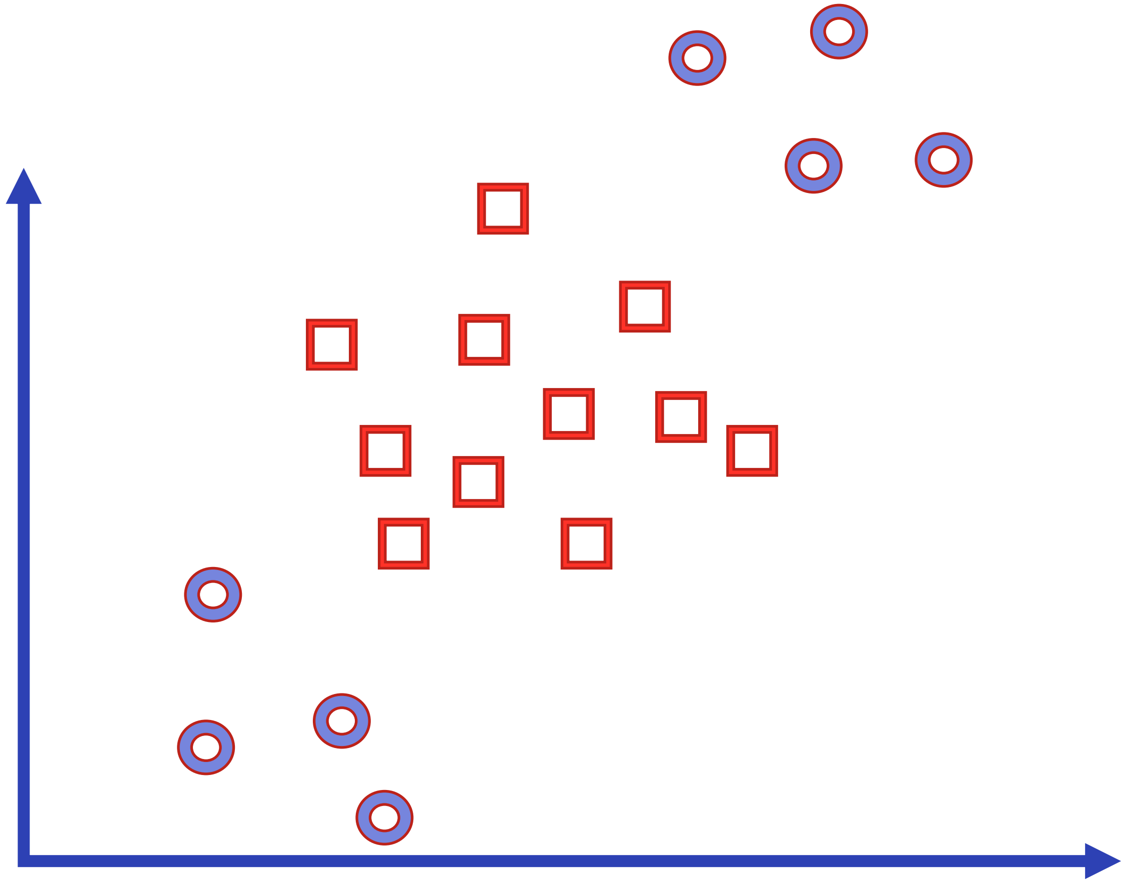

Máquinas de Vetores de Suporte

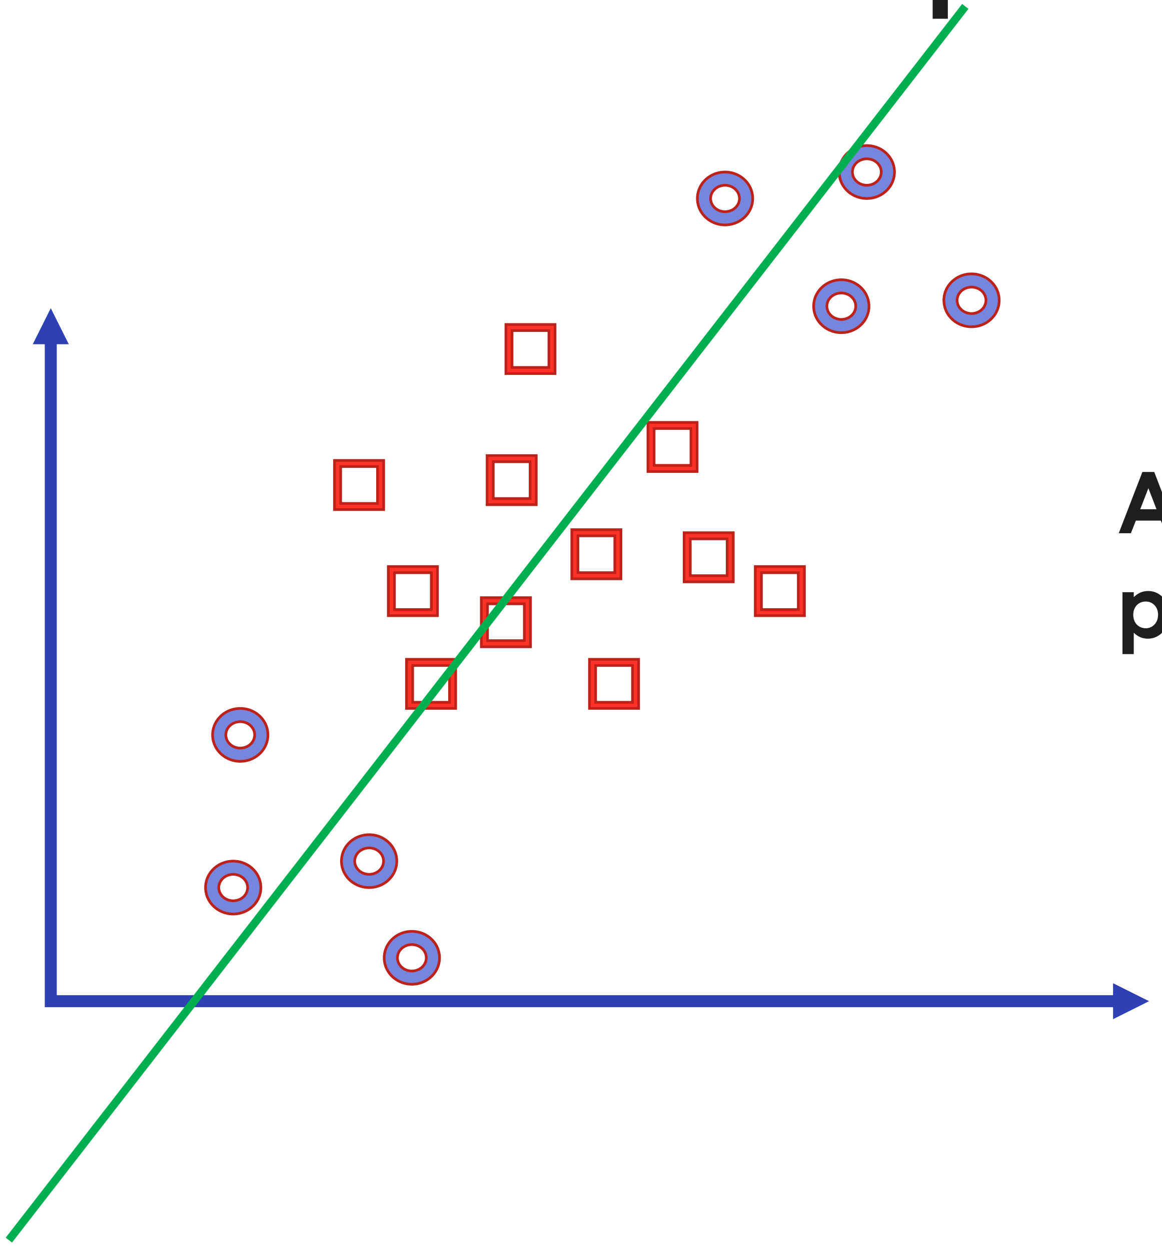

A fronteira linear
pode falhar

Máquinas de Vetores de Suporte

Kernel Polinomial

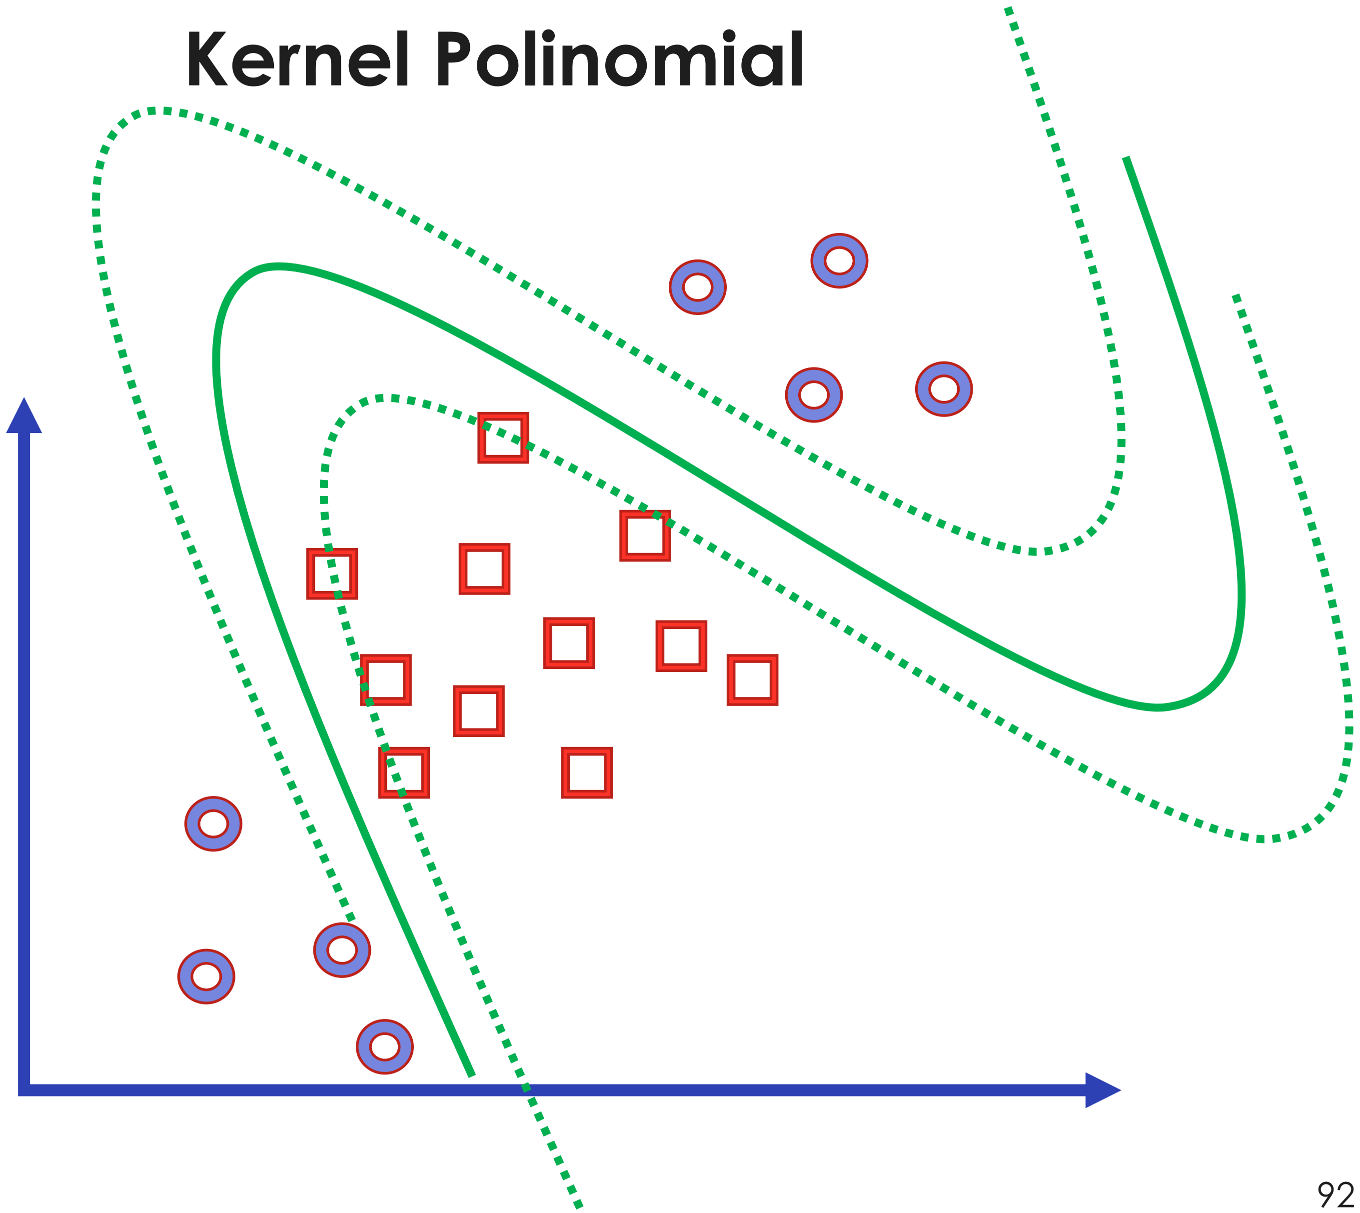

Máquinas de Vetores de Suporte

Kernel Polinomial

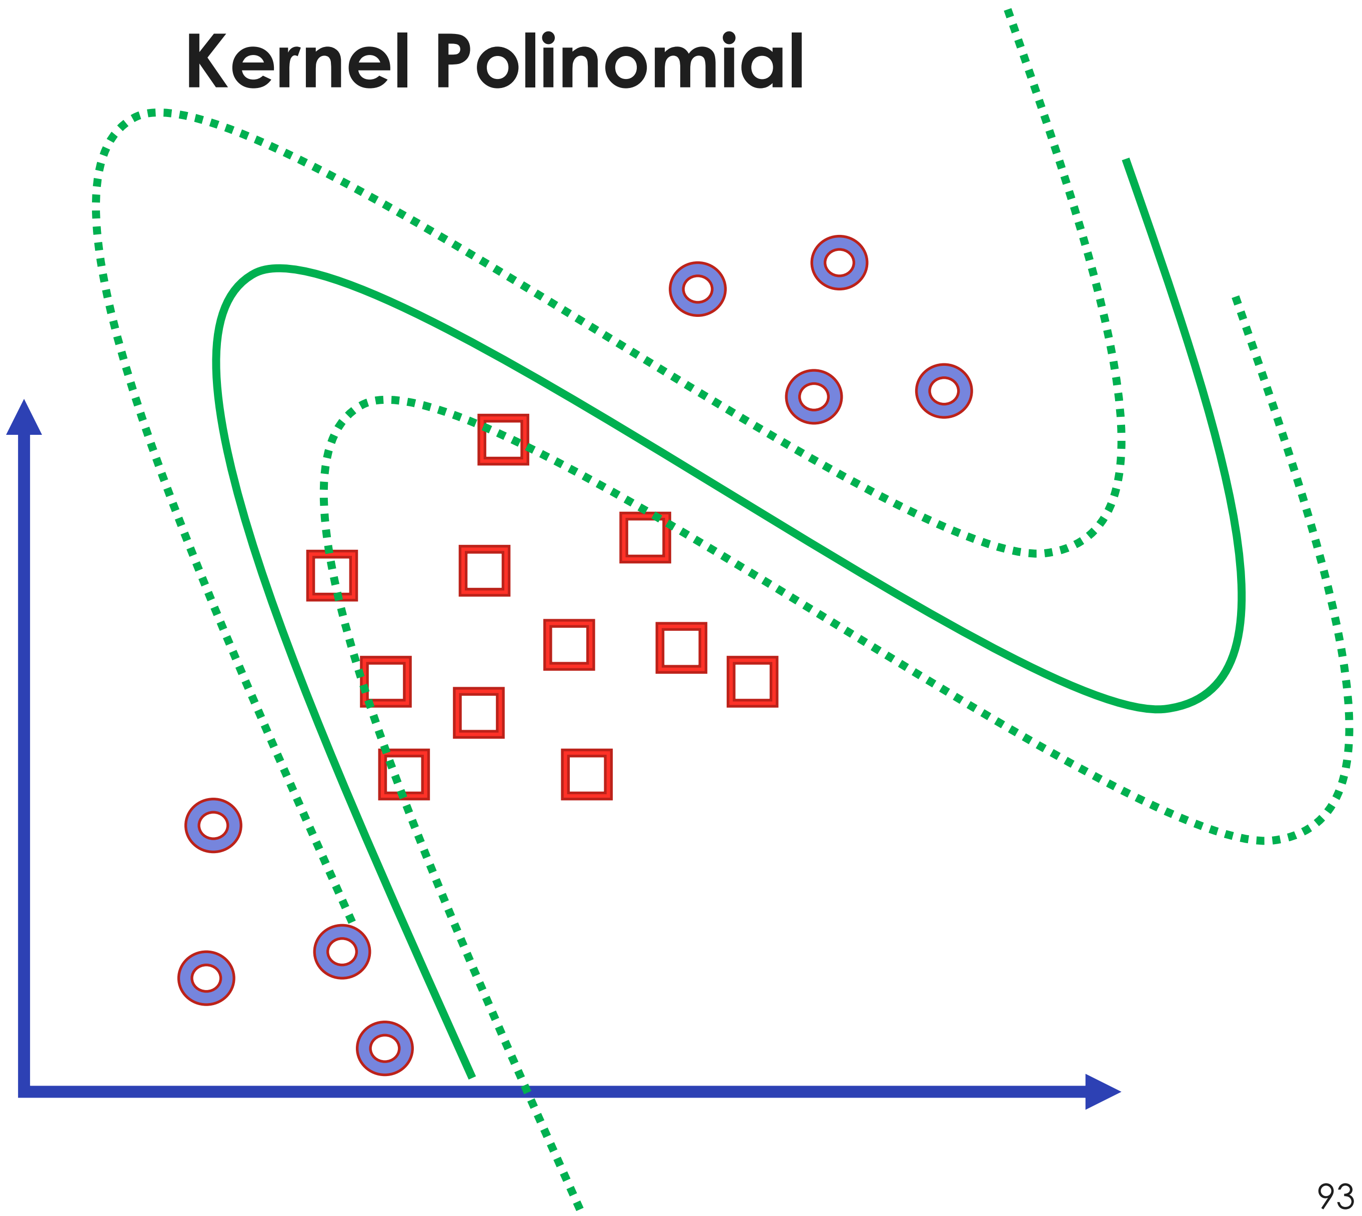

Kernel Radial

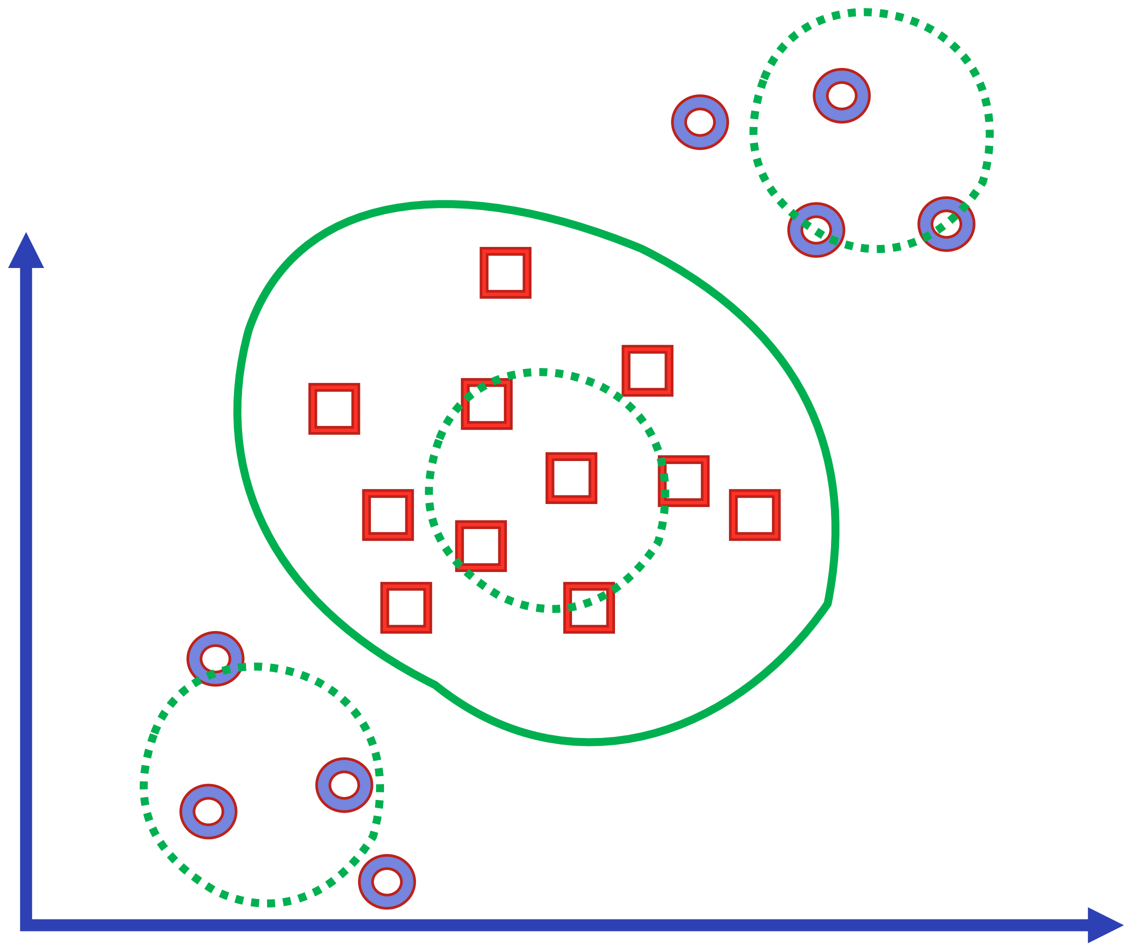

Máquinas de Vetores de Suporte

O que fazer quando ha mais de duas classes?

Duas possibilidades:
- Um contra todos: escolher a classe mais longe da fronteira
- Um contra um: escolher a classe mais frequente

Redes Neuronais

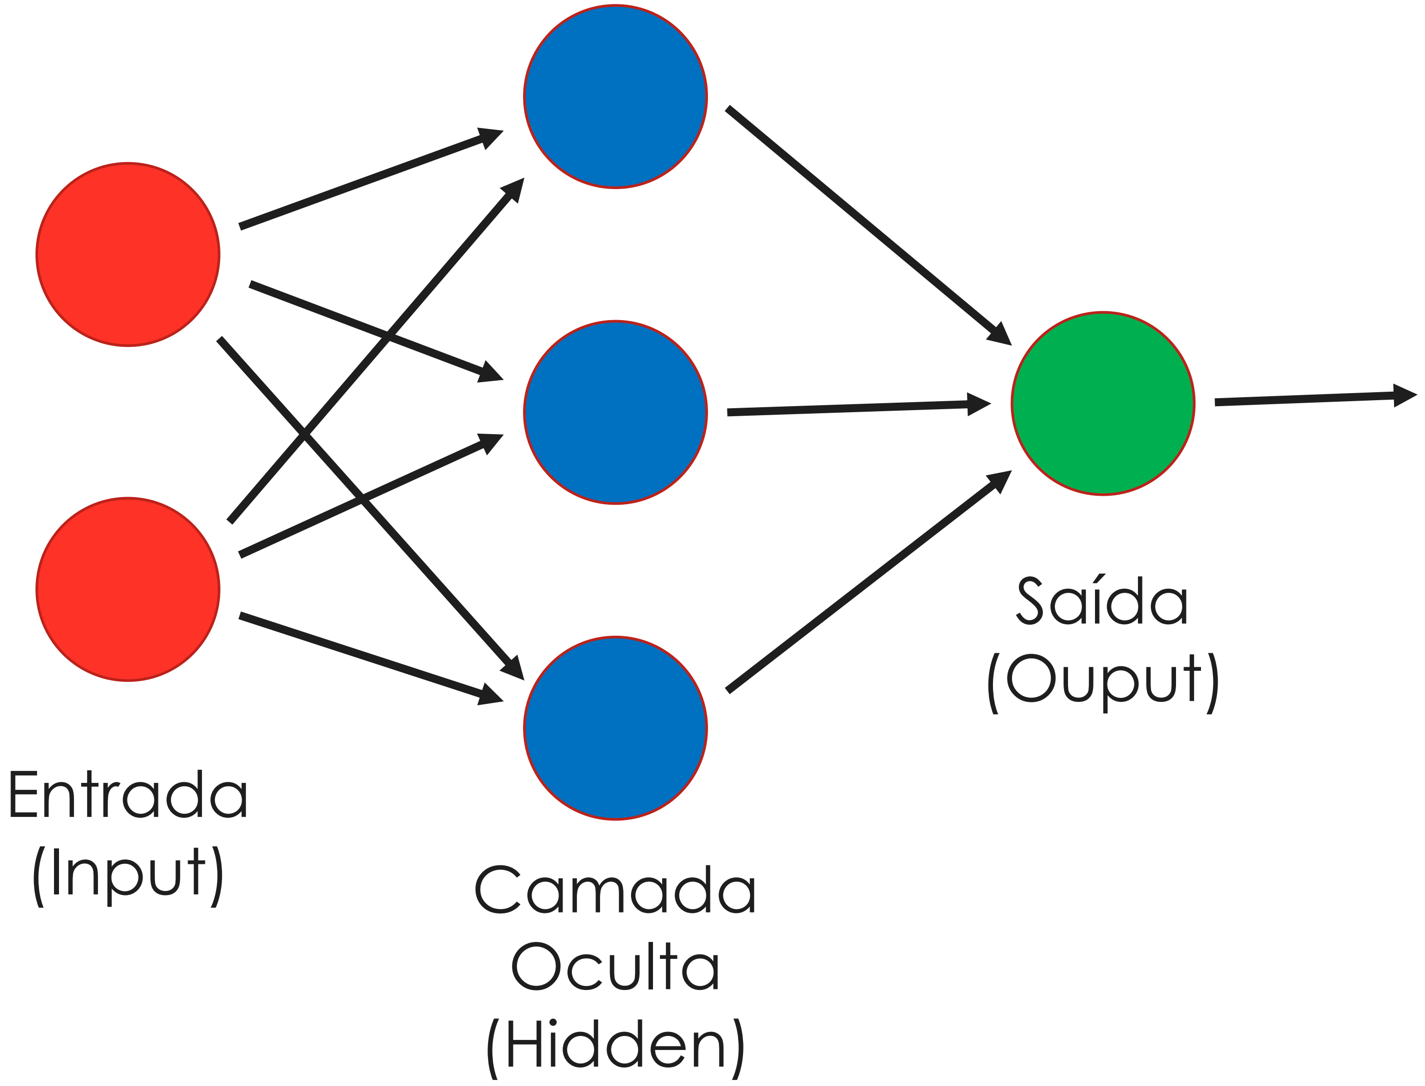

Primeiro tipo de Neurónios: Percetron

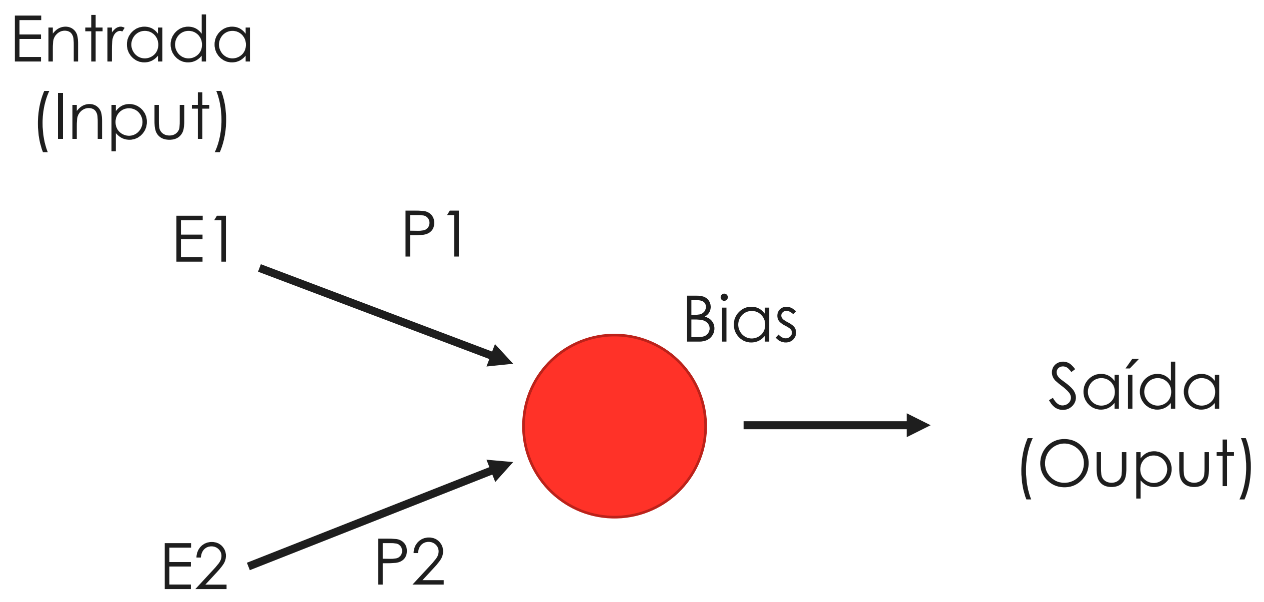

Primeiro tipo de Neurónios: Percetron

Entrada
(Input)

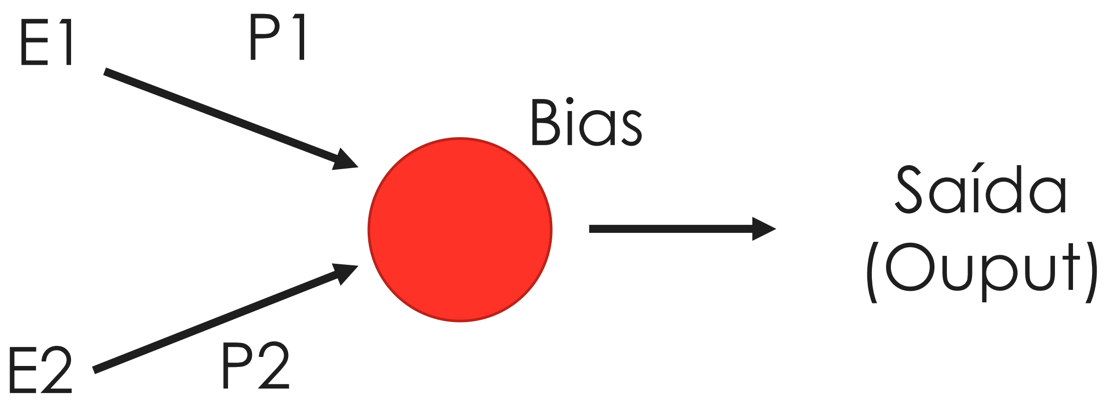

$$\text{Saída (Ouput)} \begin{cases} 1 & \text{Se } E1 \times P1 + E2 \times P2 > \text{Bias} \\ 0 & \text{Outros} \end{cases}$$

Primeiro tipo de Neurónios: Percetron

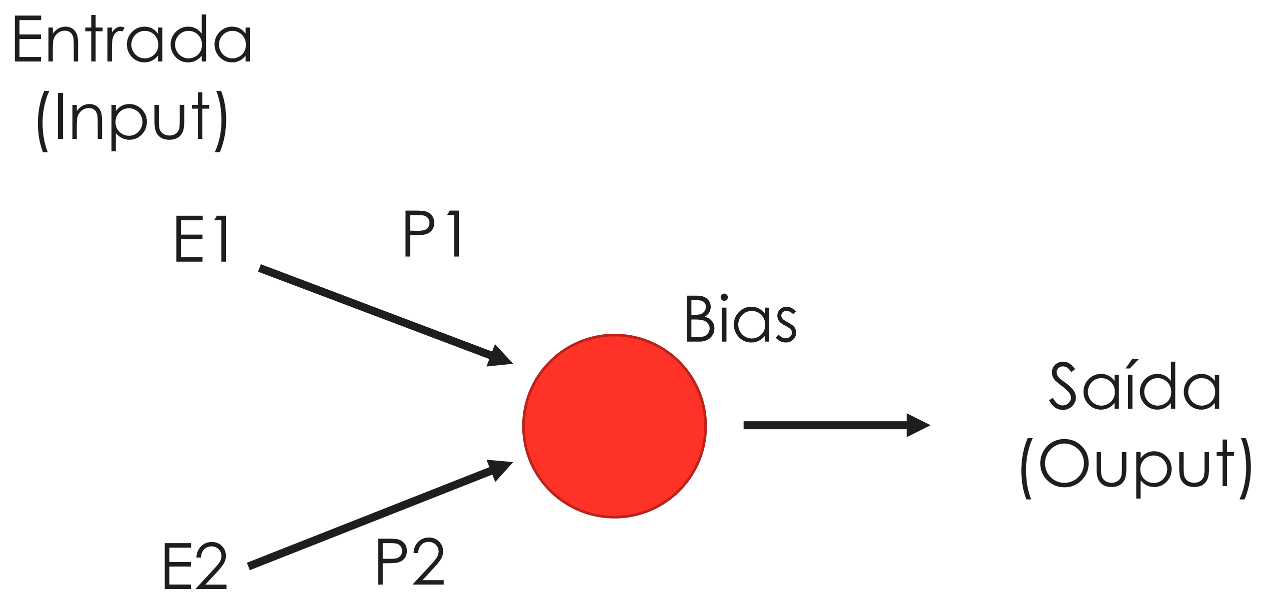

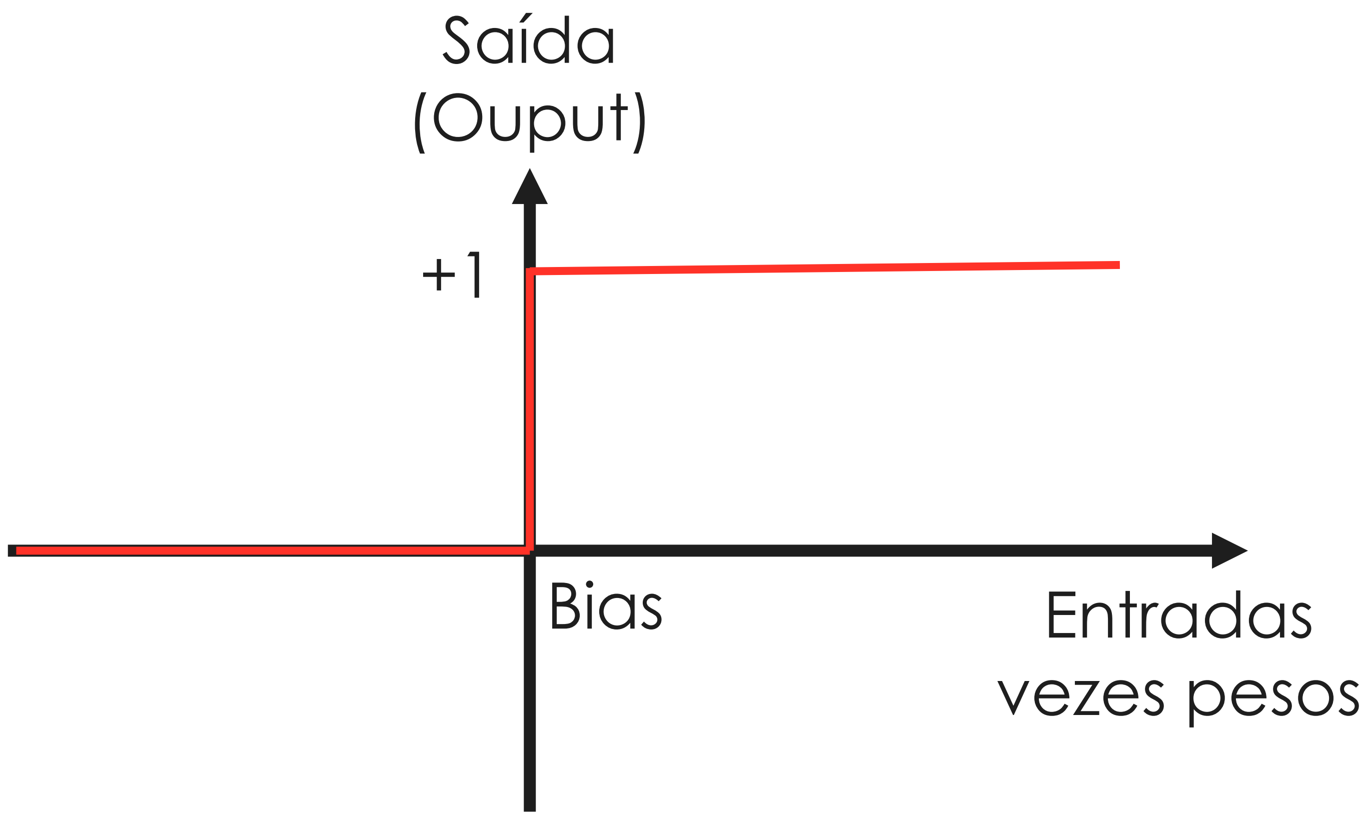

$$\text{Saída (Ouput)} \begin{cases} 1 & \text{Se } E1 \times P1 + E2 \times P2 > \text{Bias} \\ 0 & \text{Outros} \end{cases}$$

Neurónios atuais: Sigmoid ou ReLU

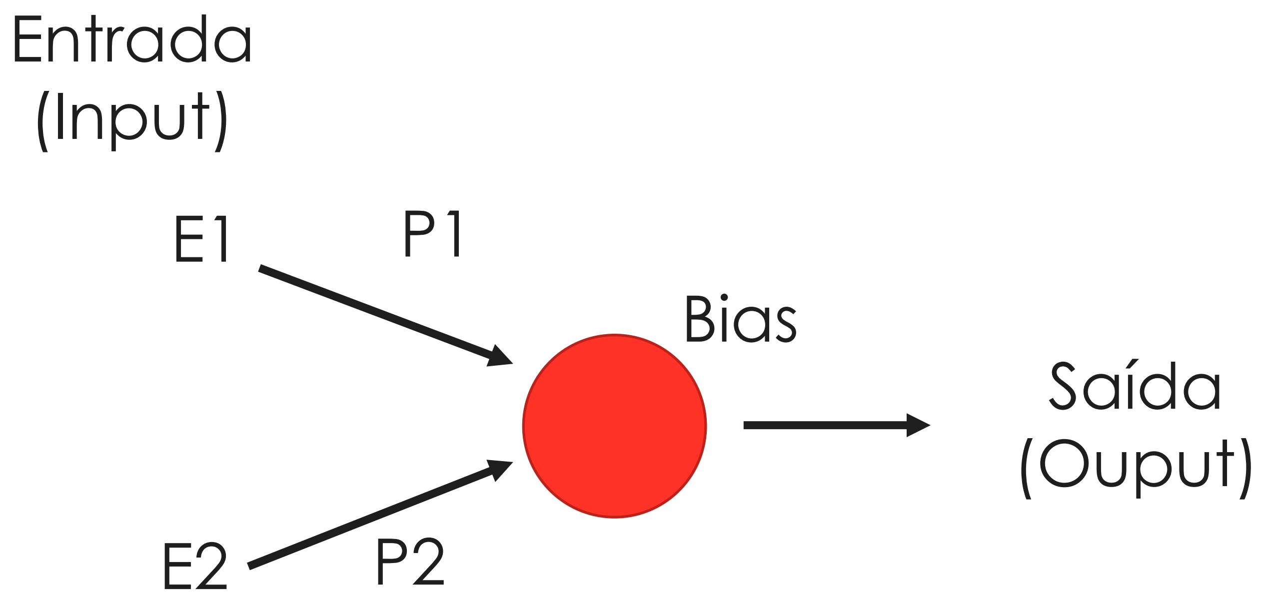

Neurónios atuais: Sigmoid ou ReLU

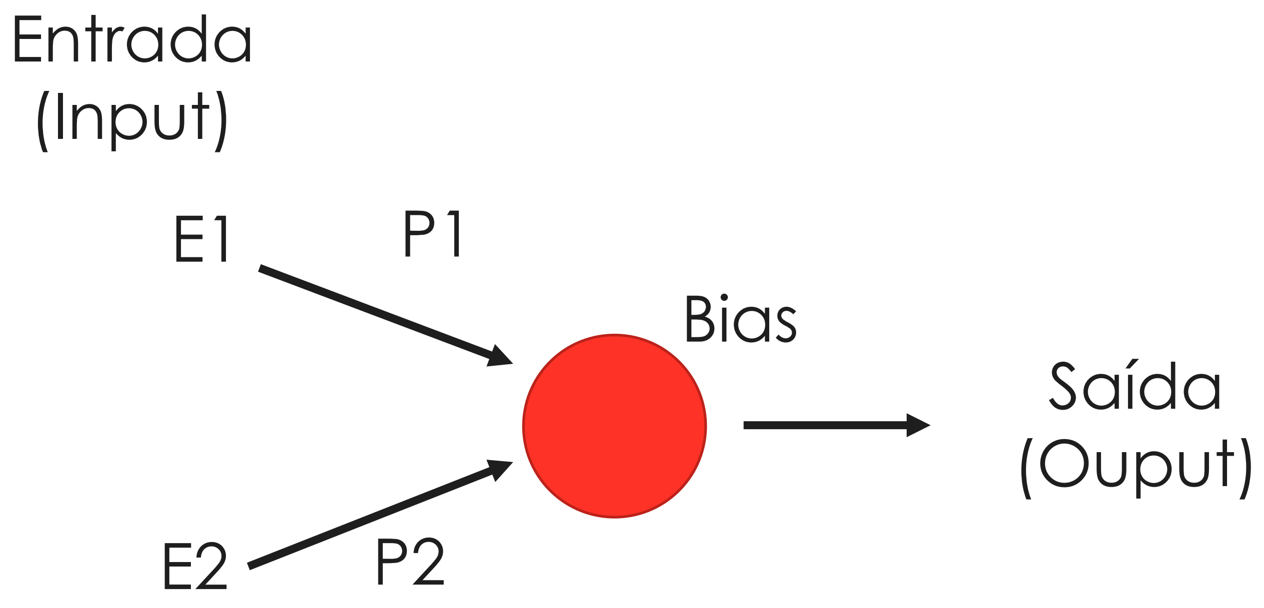

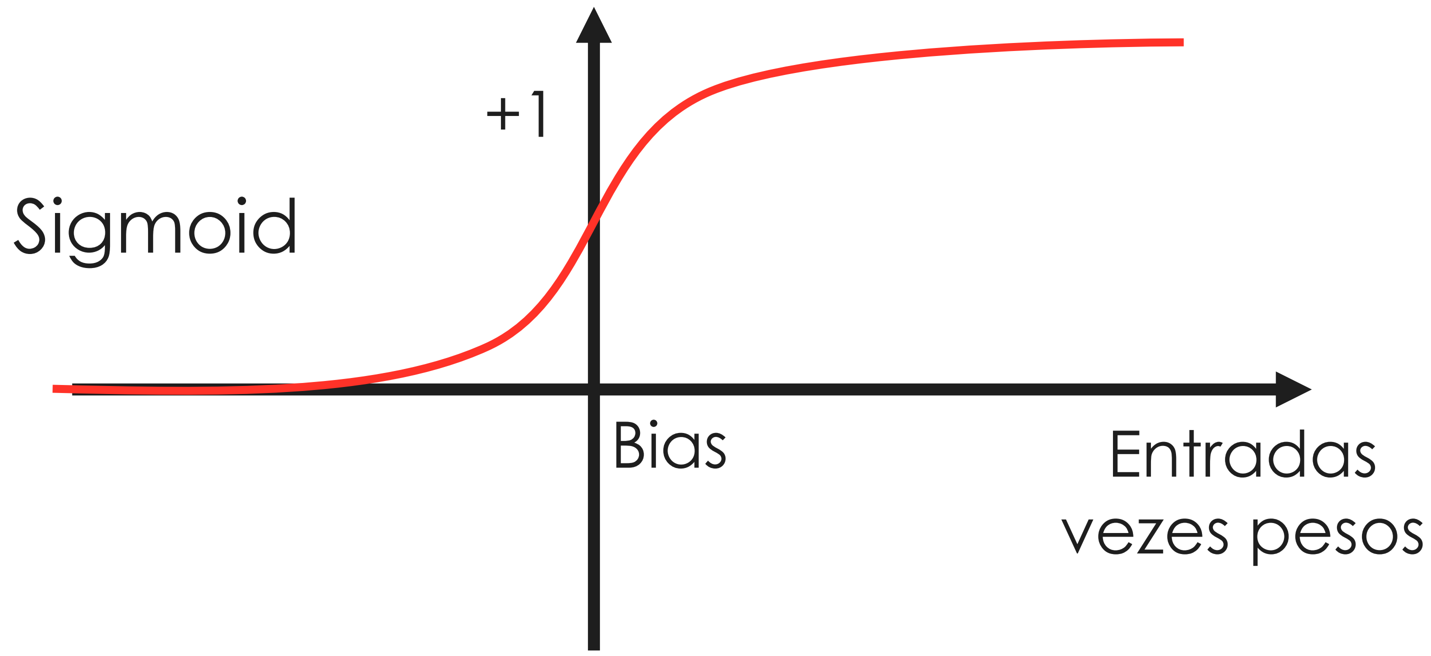

Neurónios atuais: Sigmoid ou ReLU

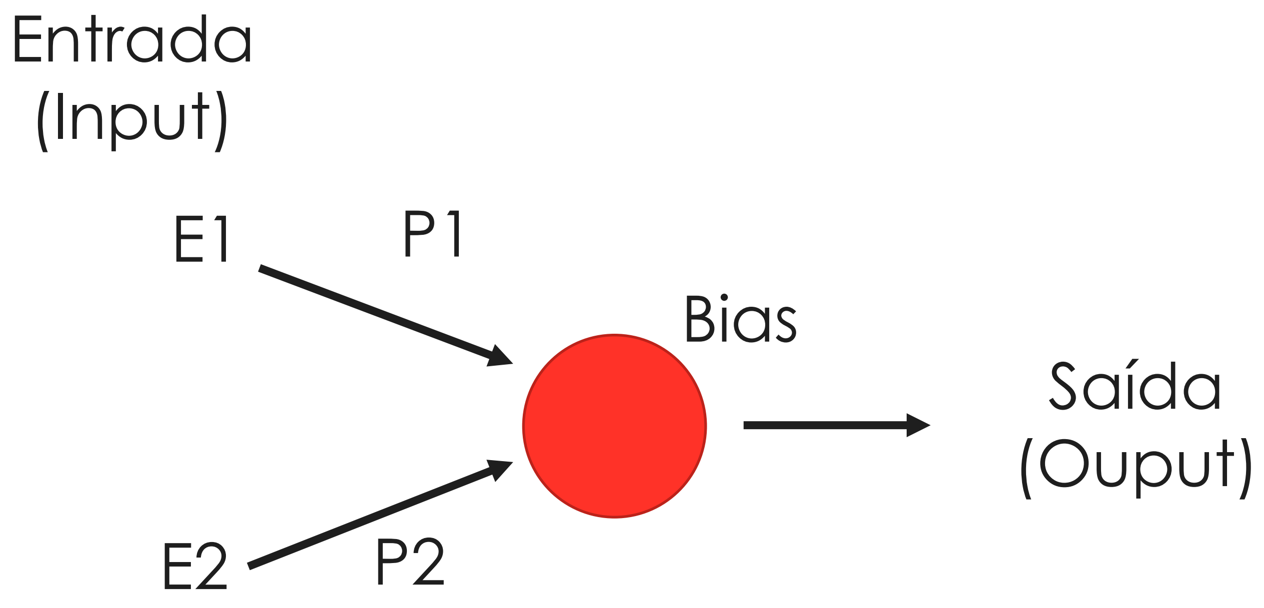

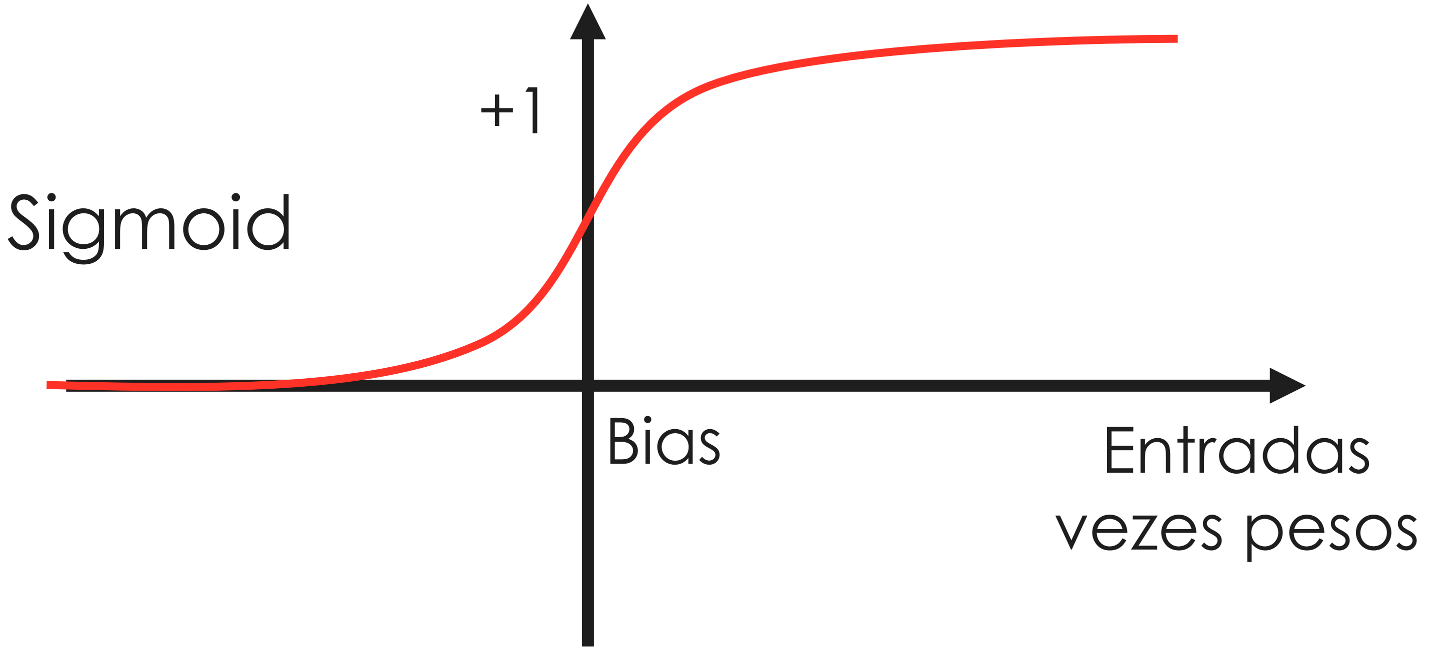

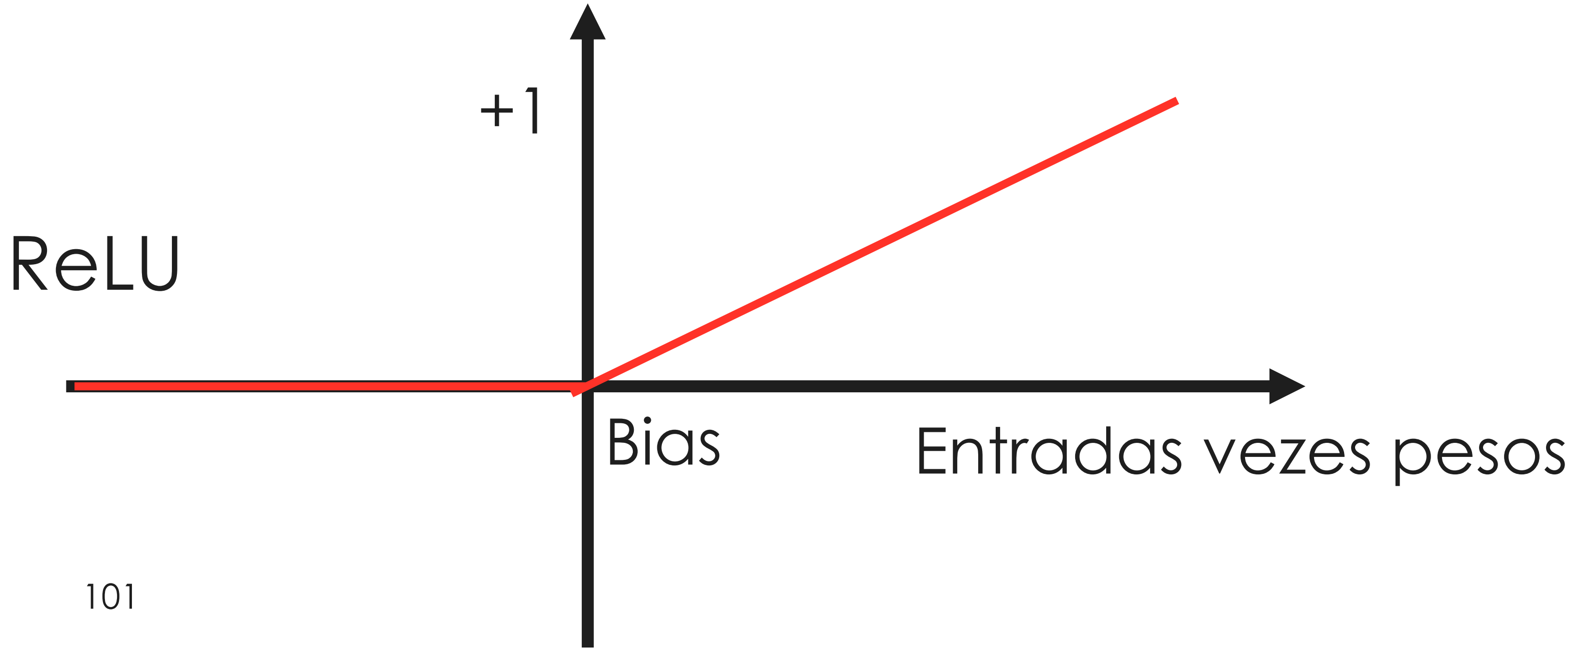

Contruir uma Rede Neuronal

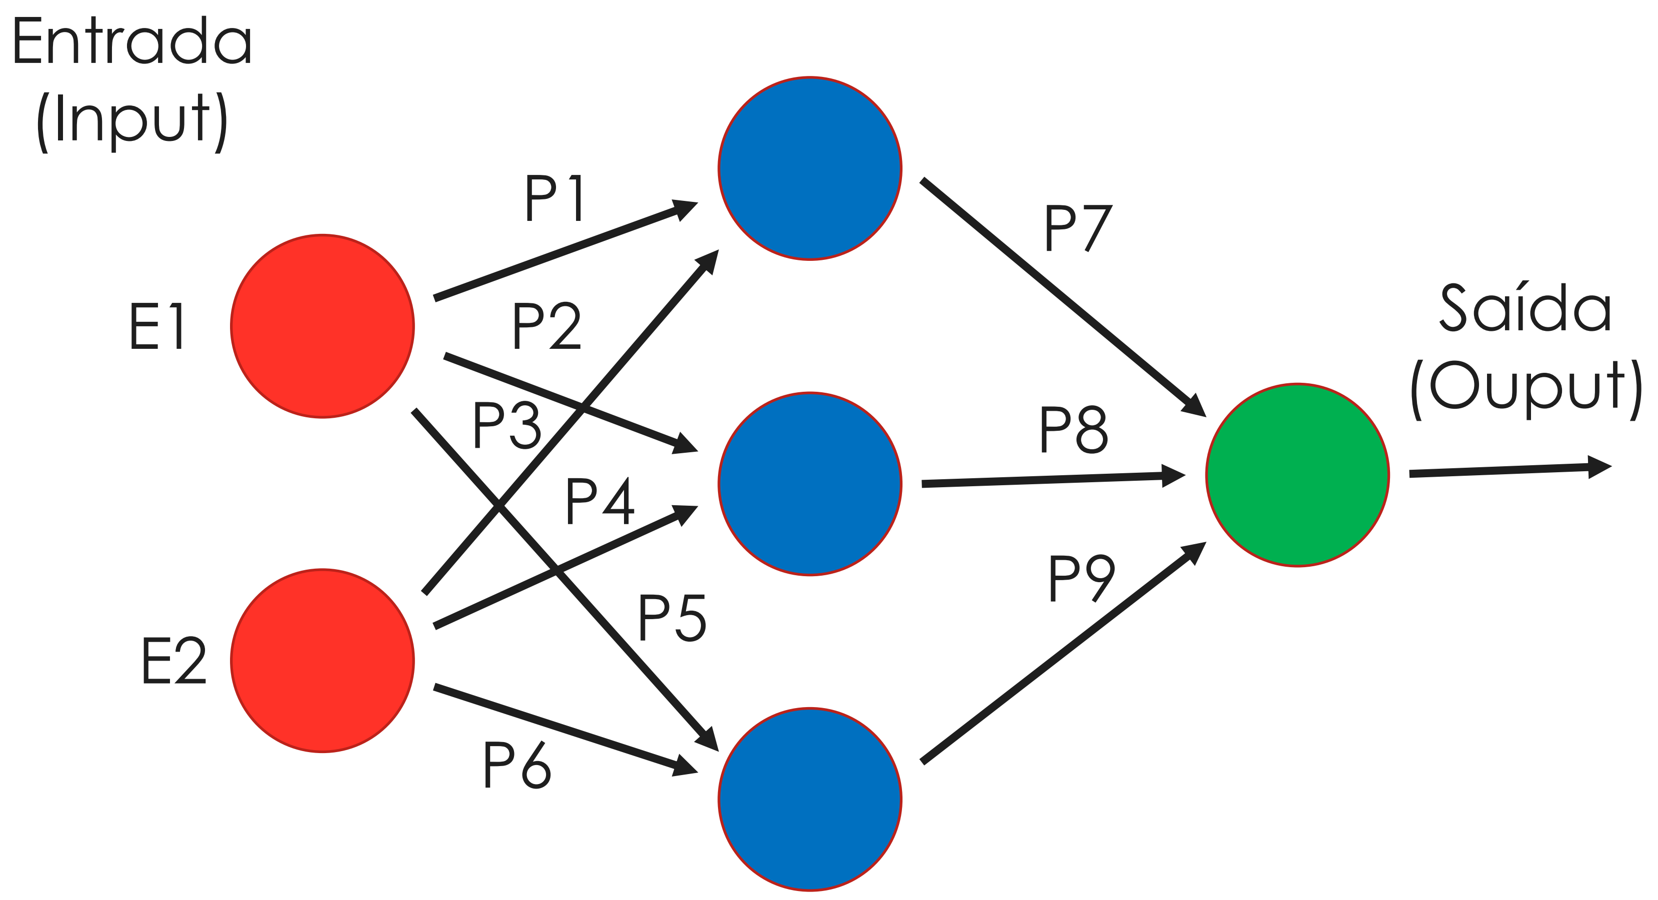

Contruir uma Rede Neuronal

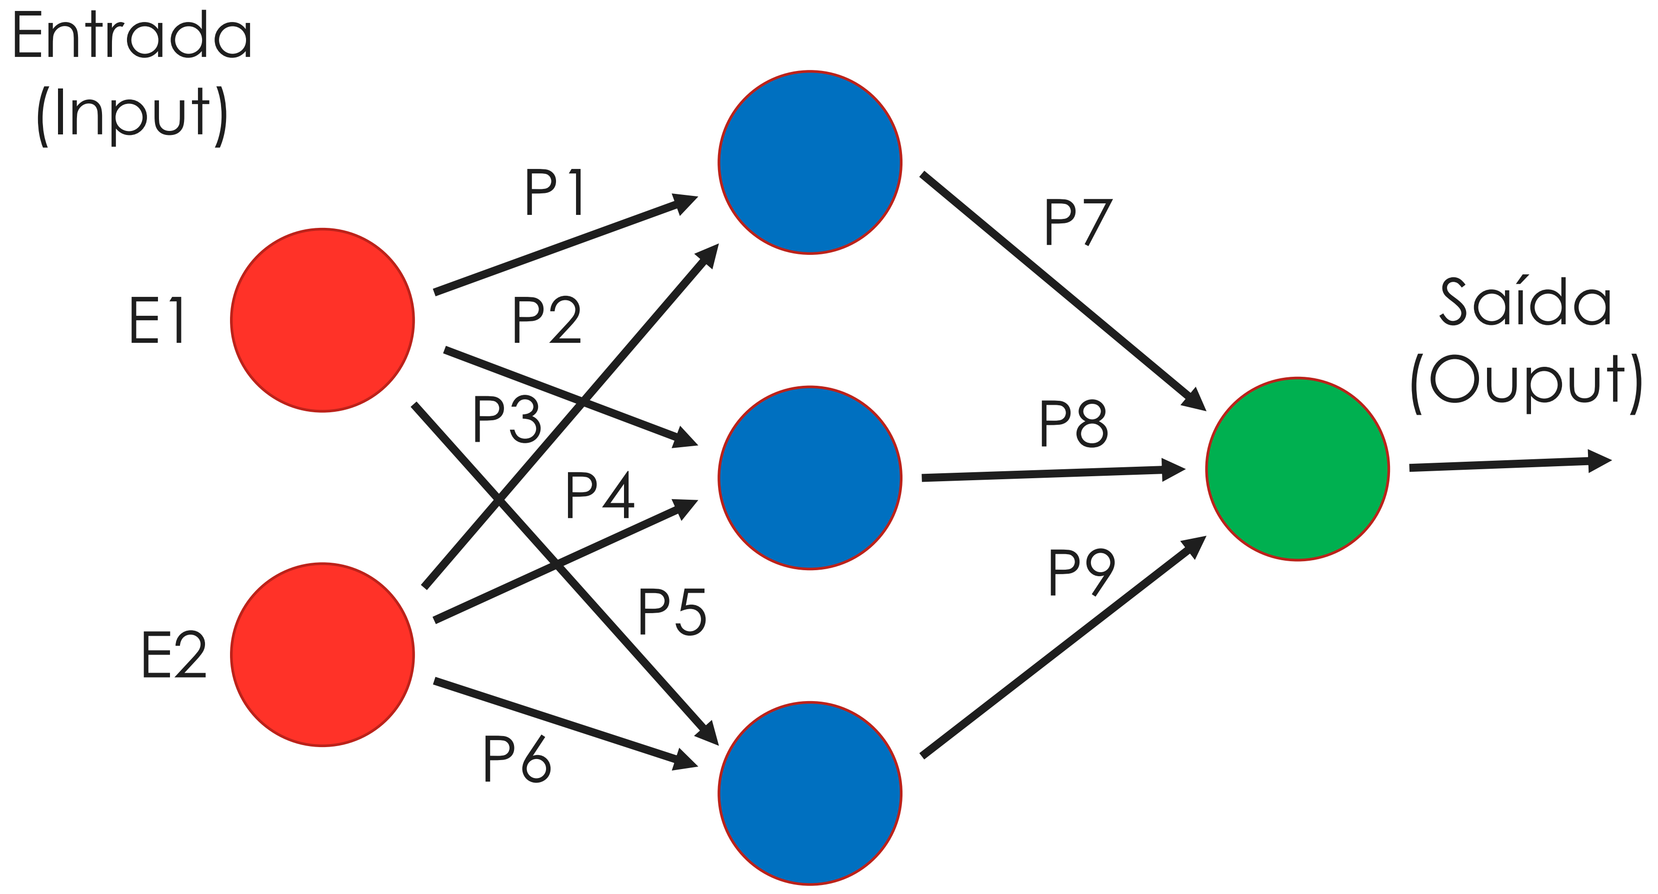

Minimizar o desvio quadrático médio:

ERRO QUADRÁTICO MÉDIO (MSE) = MÉDIA[(REAL(X) – MODELO(x))²]

Contruir uma Rede Neuronal

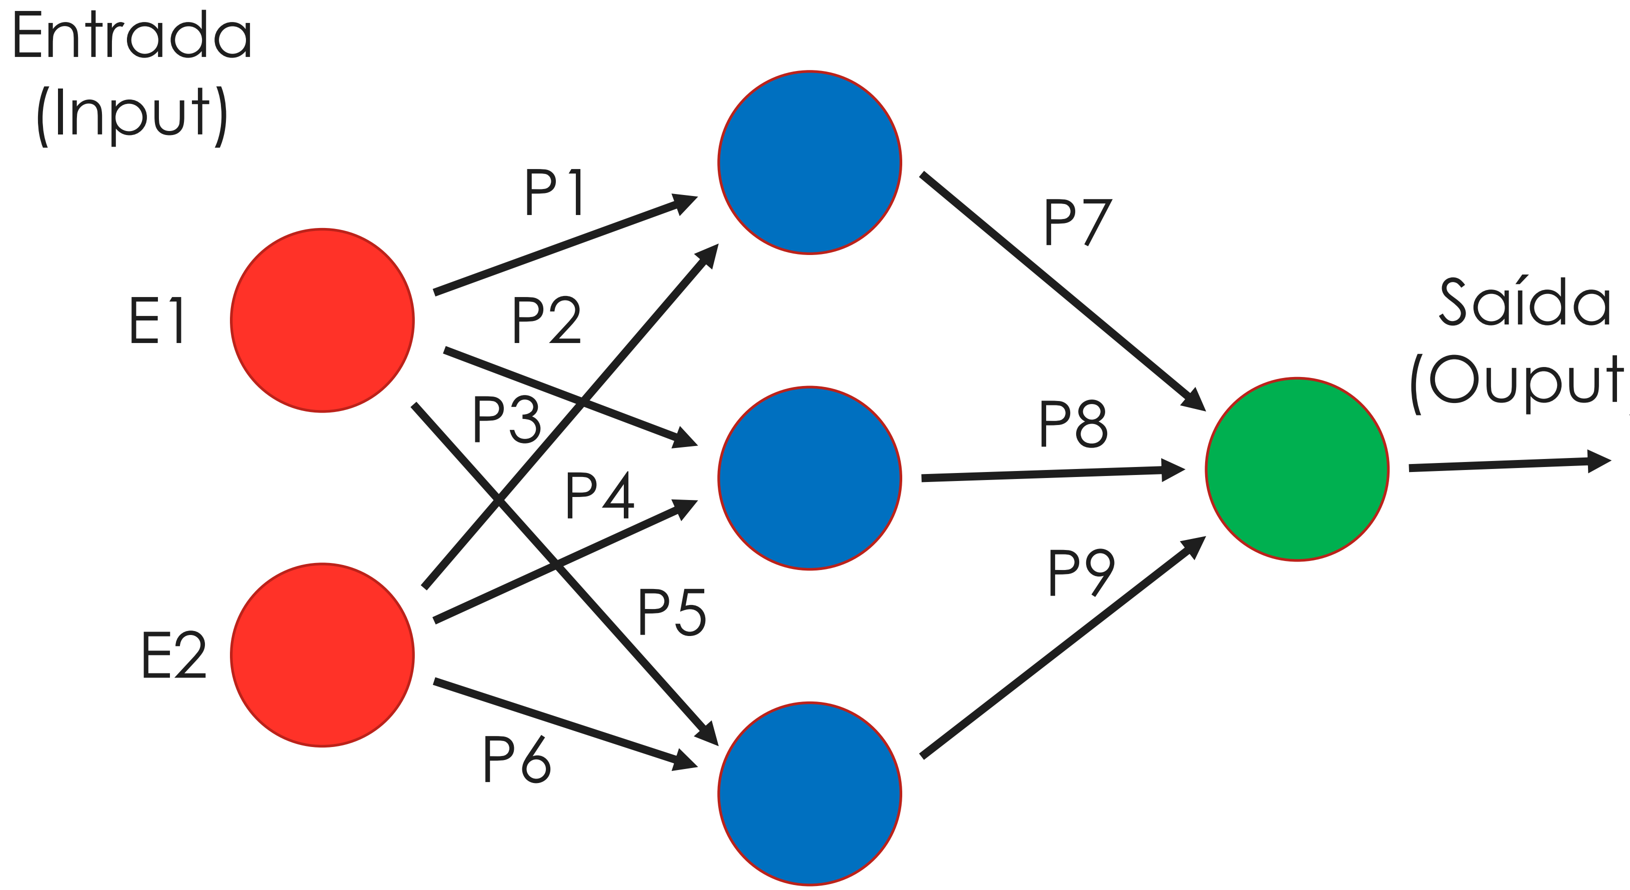

Contruir uma Rede Neuronal

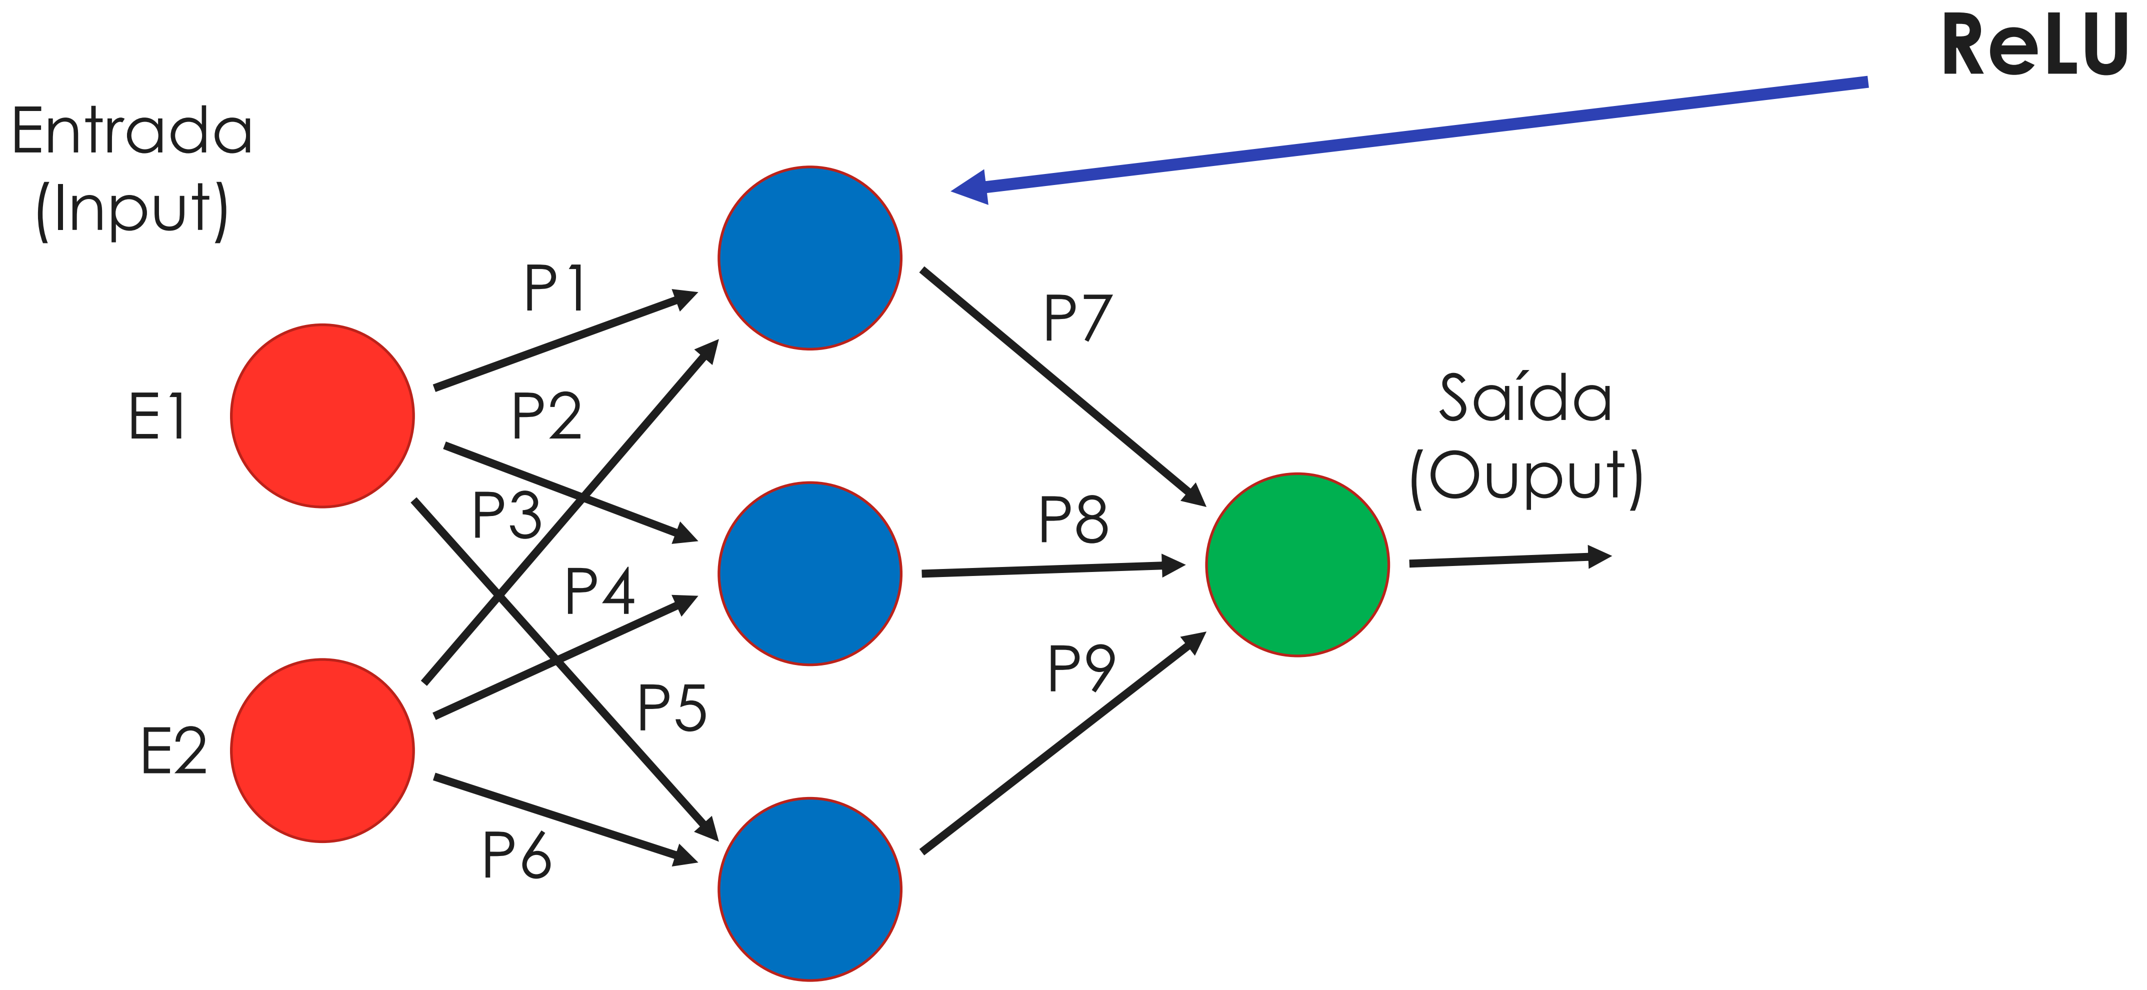

Contruir uma Rede Neuronal

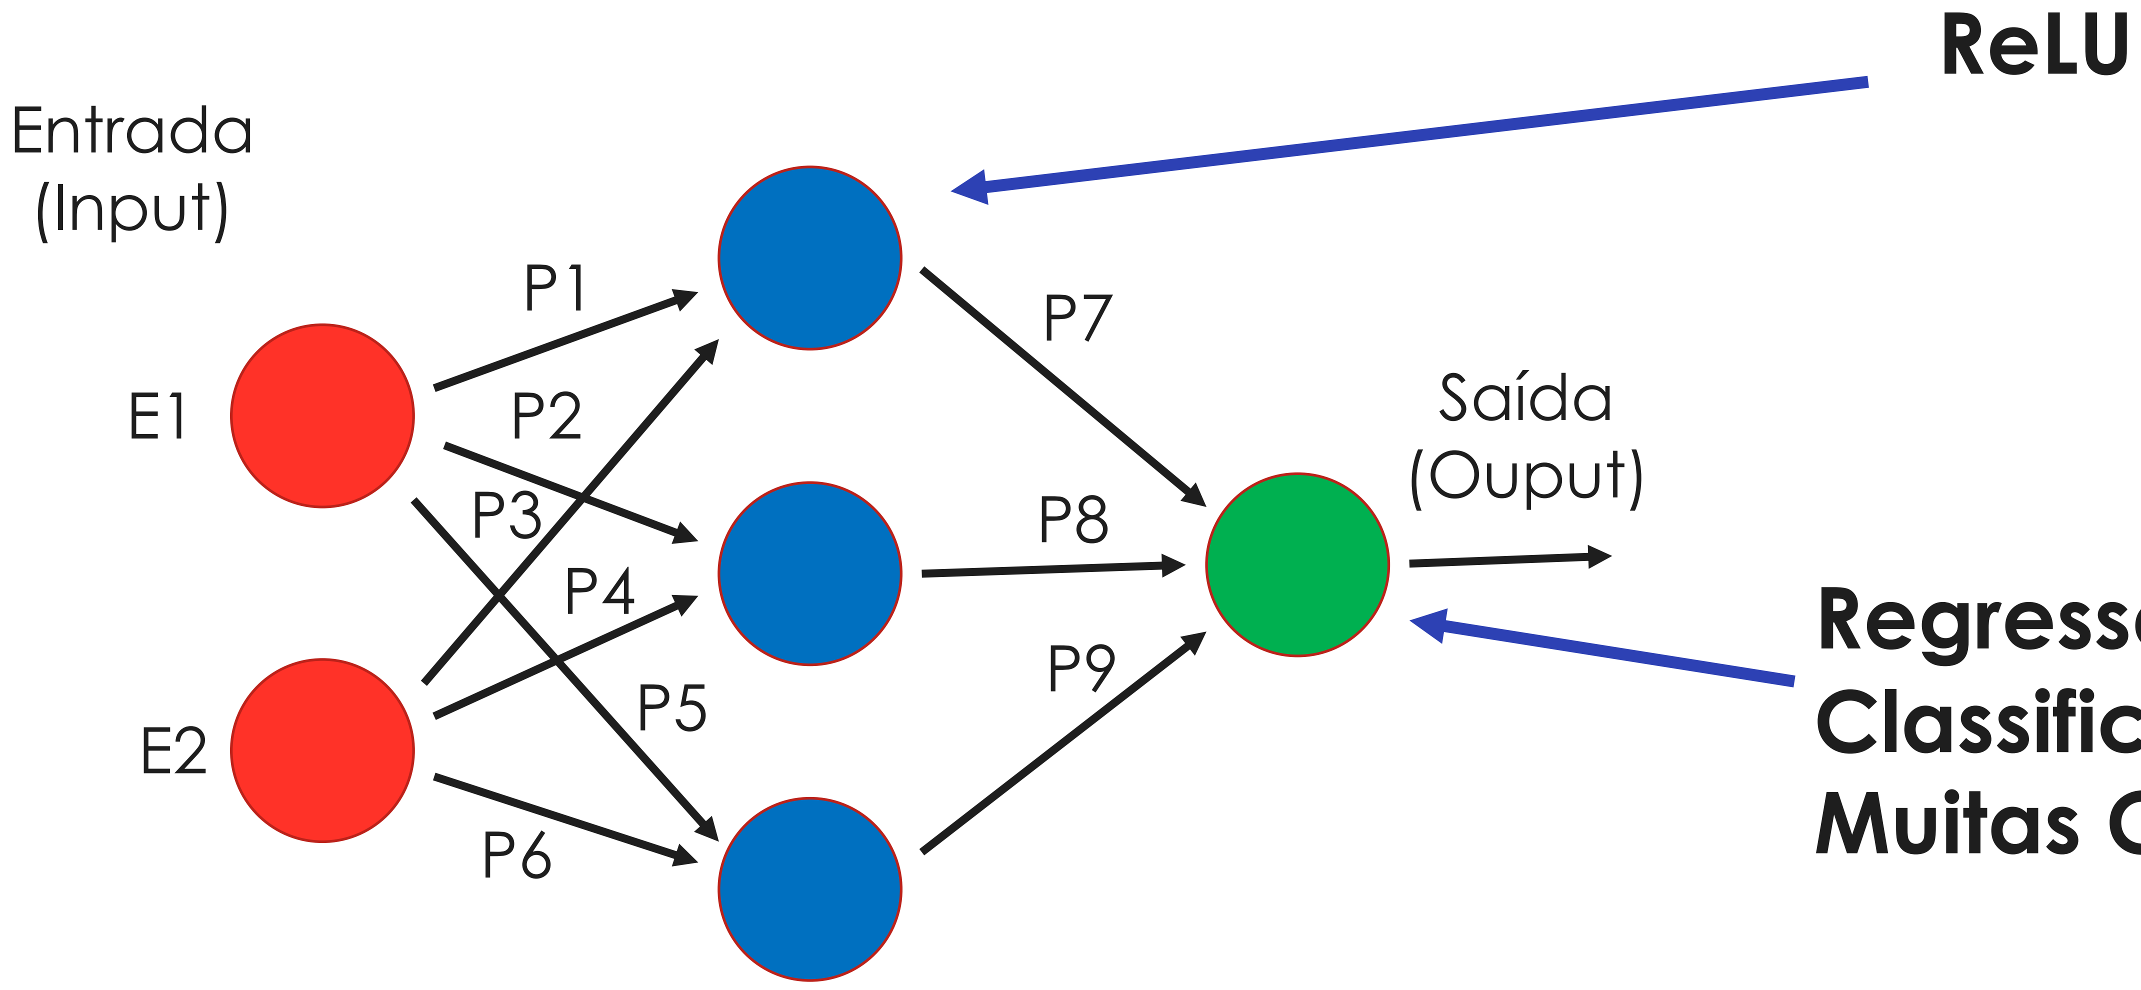

Regressão -> Função Linear
Classificação Binária -> ReLU
Muitas Classes -> SoftMax

Contruir uma Rede Neuronal

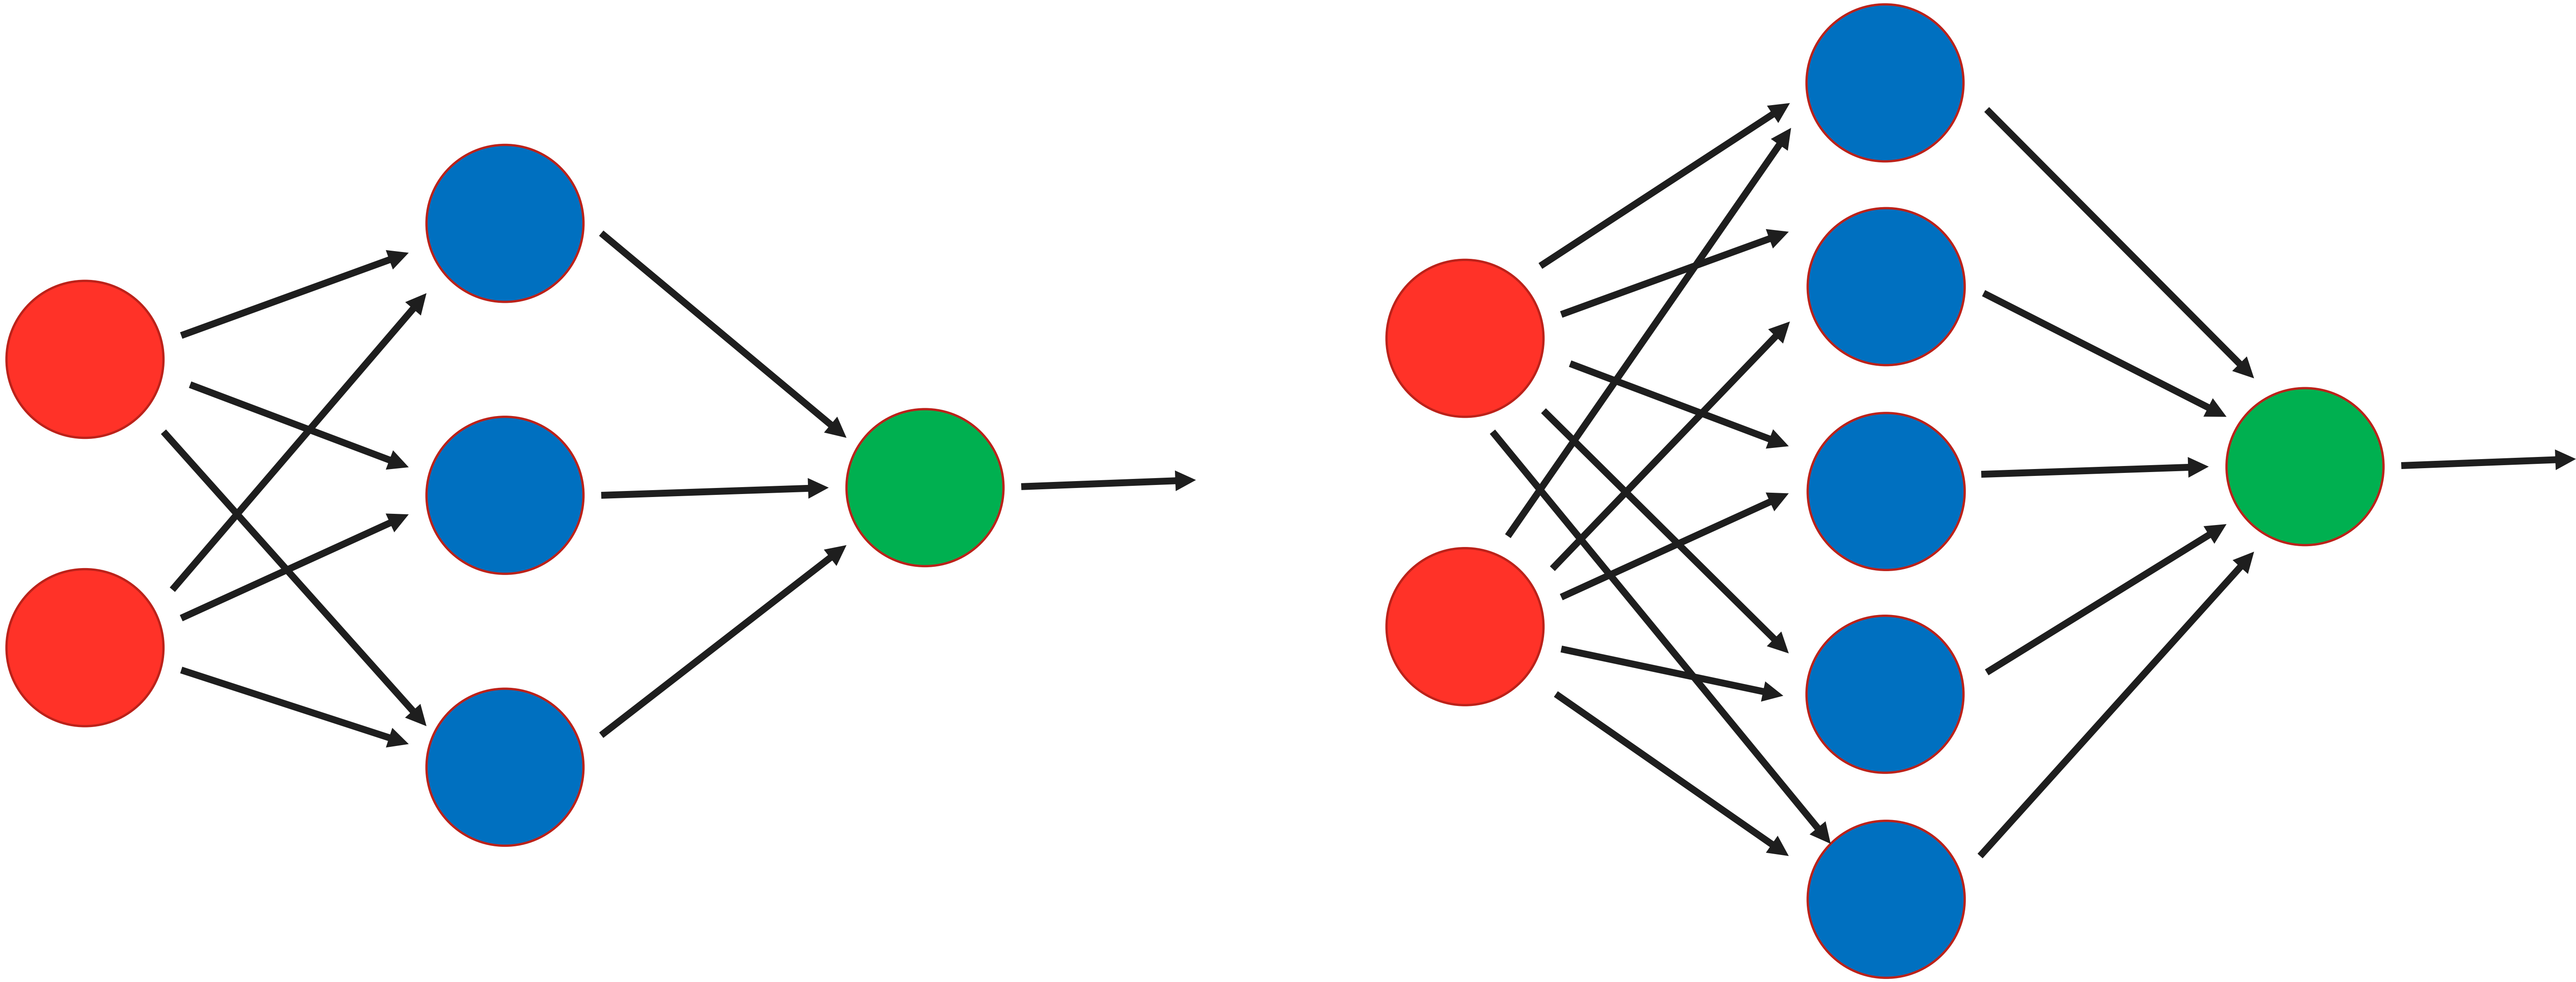

Contruir uma Rede Neuronal

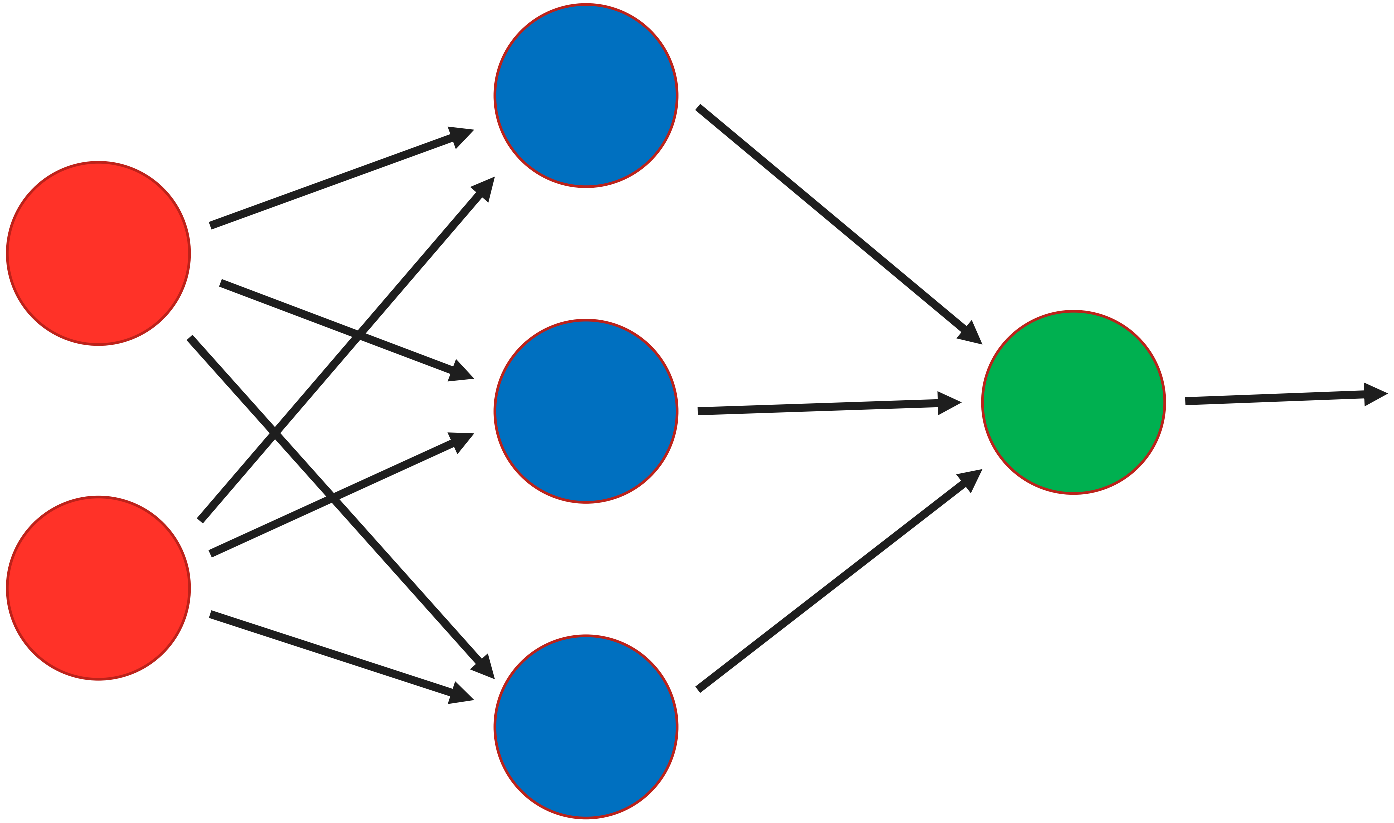

Menor ou igual ao
número de variáveis

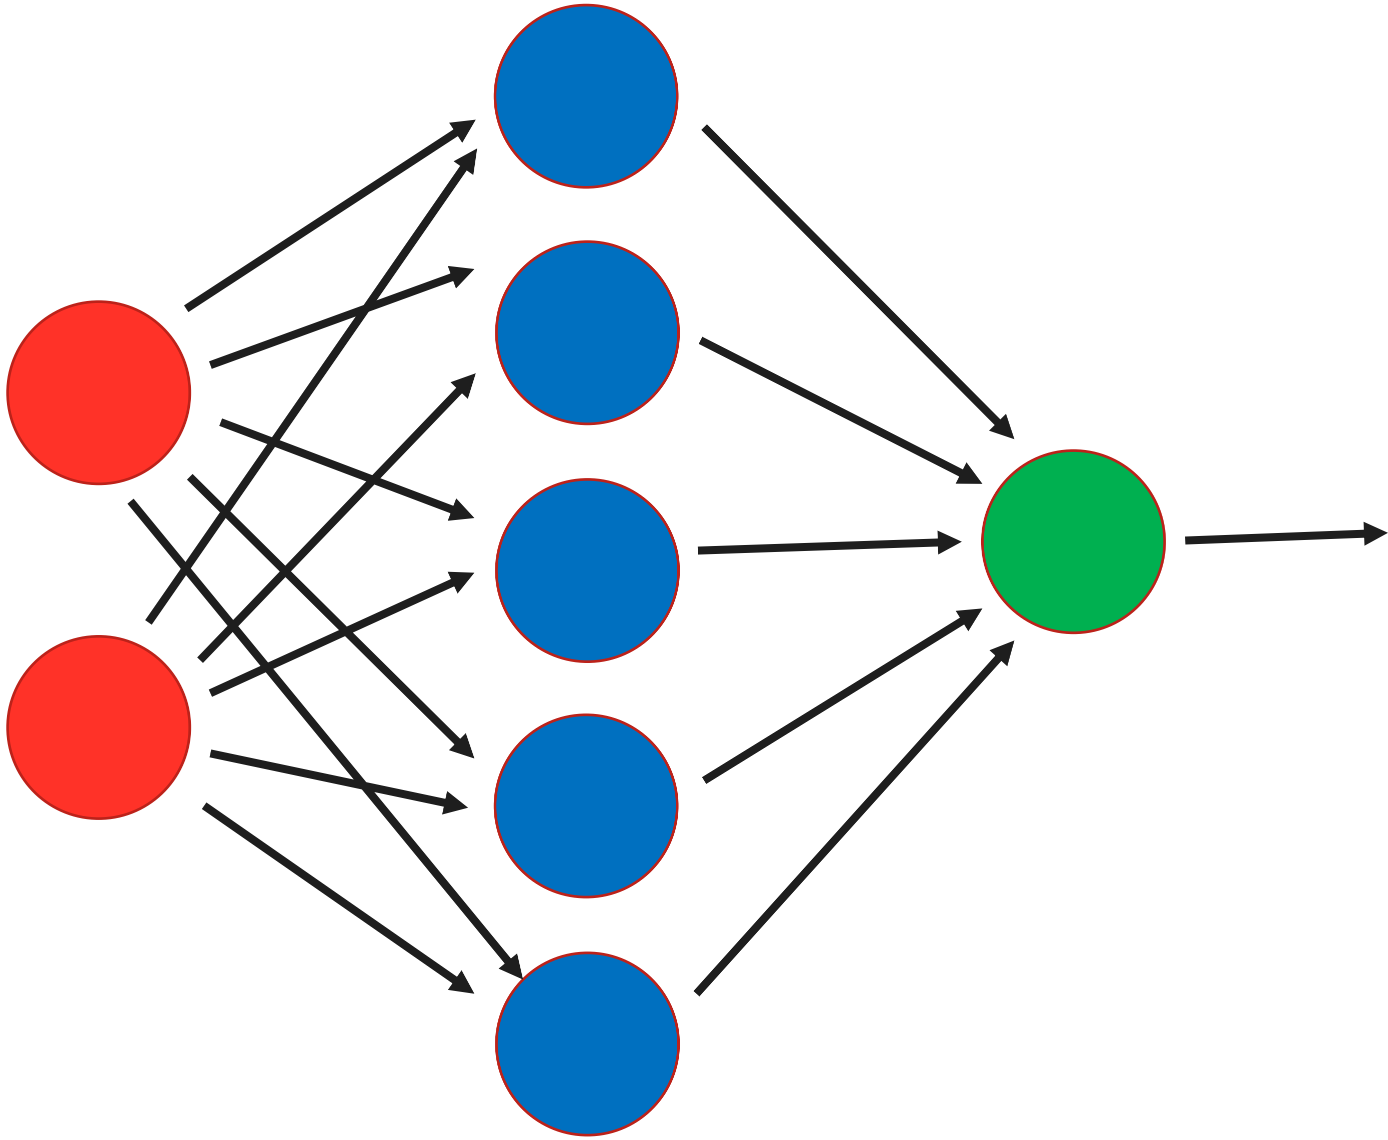

Contruir uma Rede Neuronal

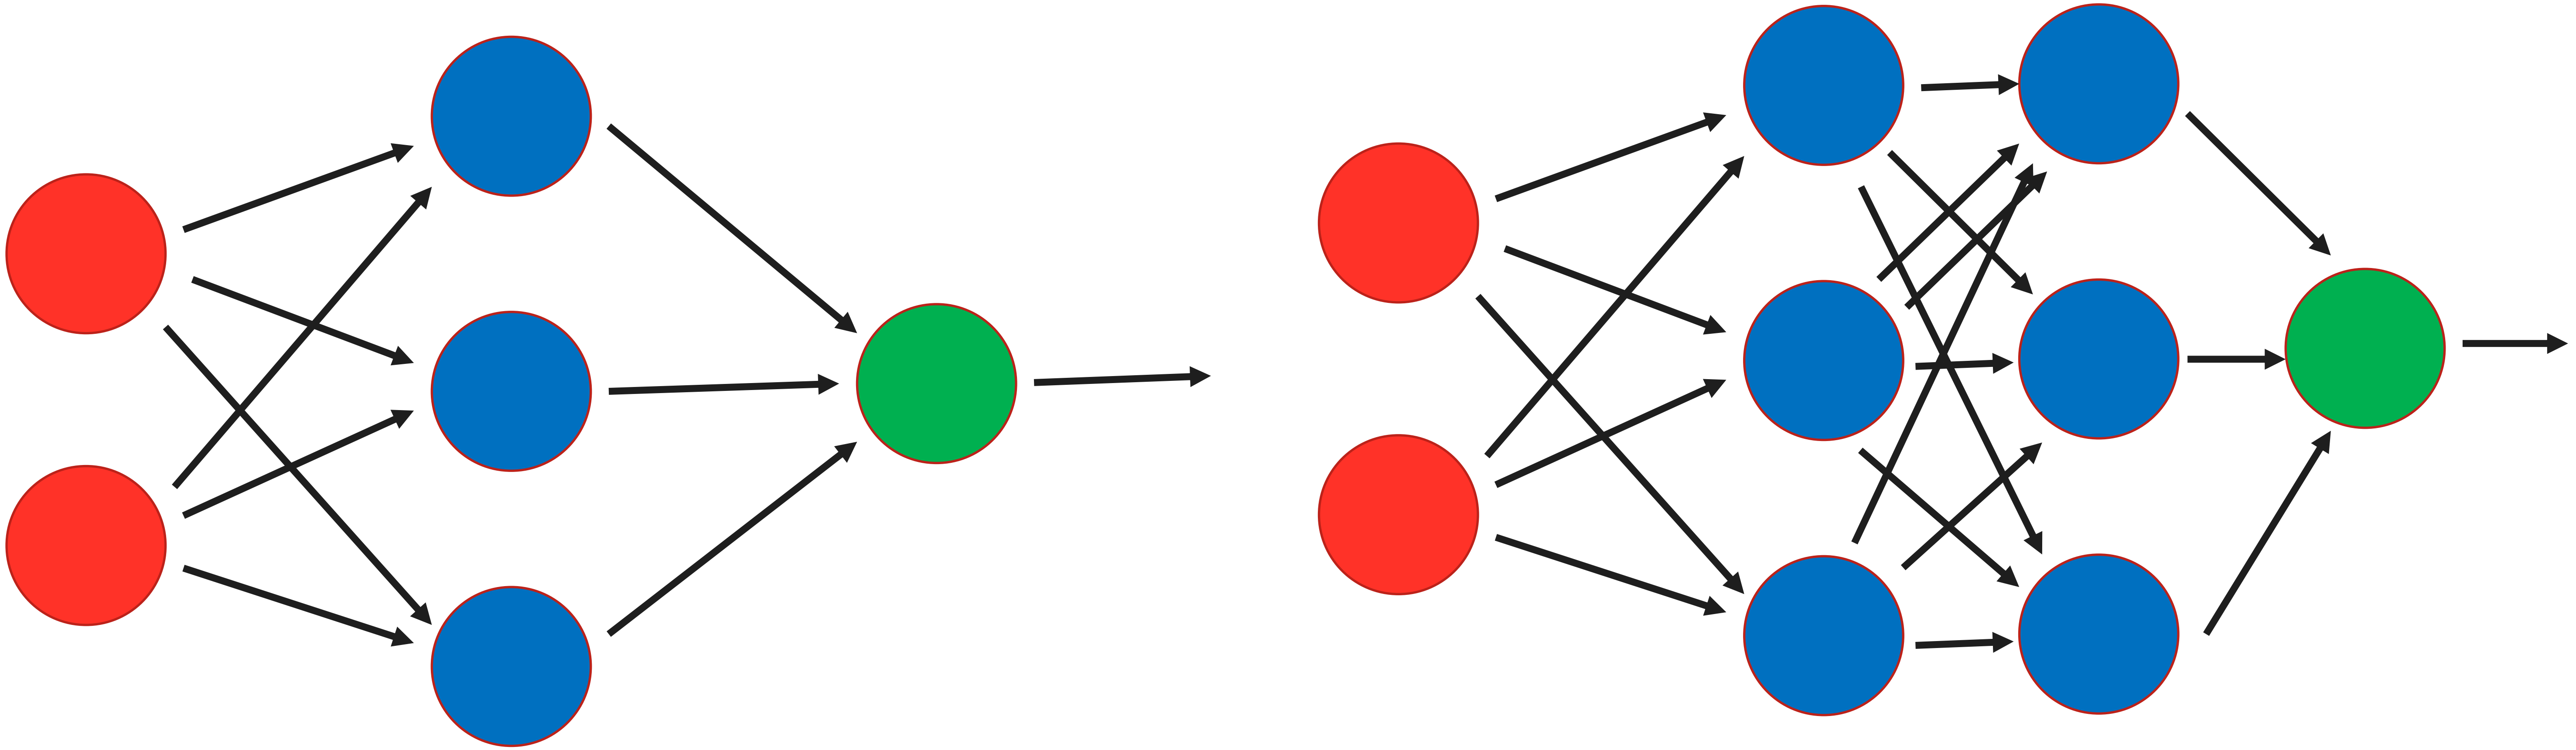

Contruir uma Rede Neuronal

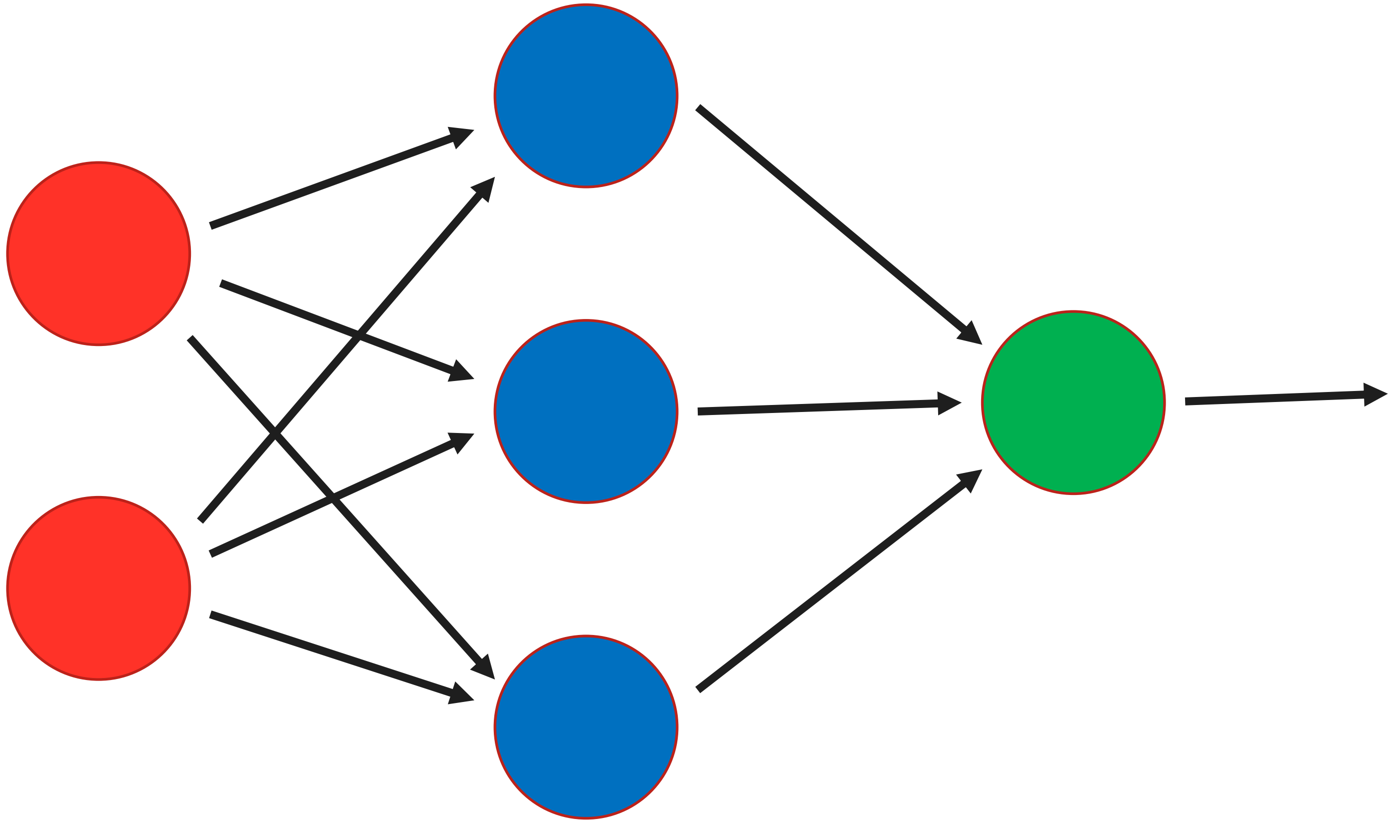

Quanto mais camadas mais não linear (perigo de overfit)

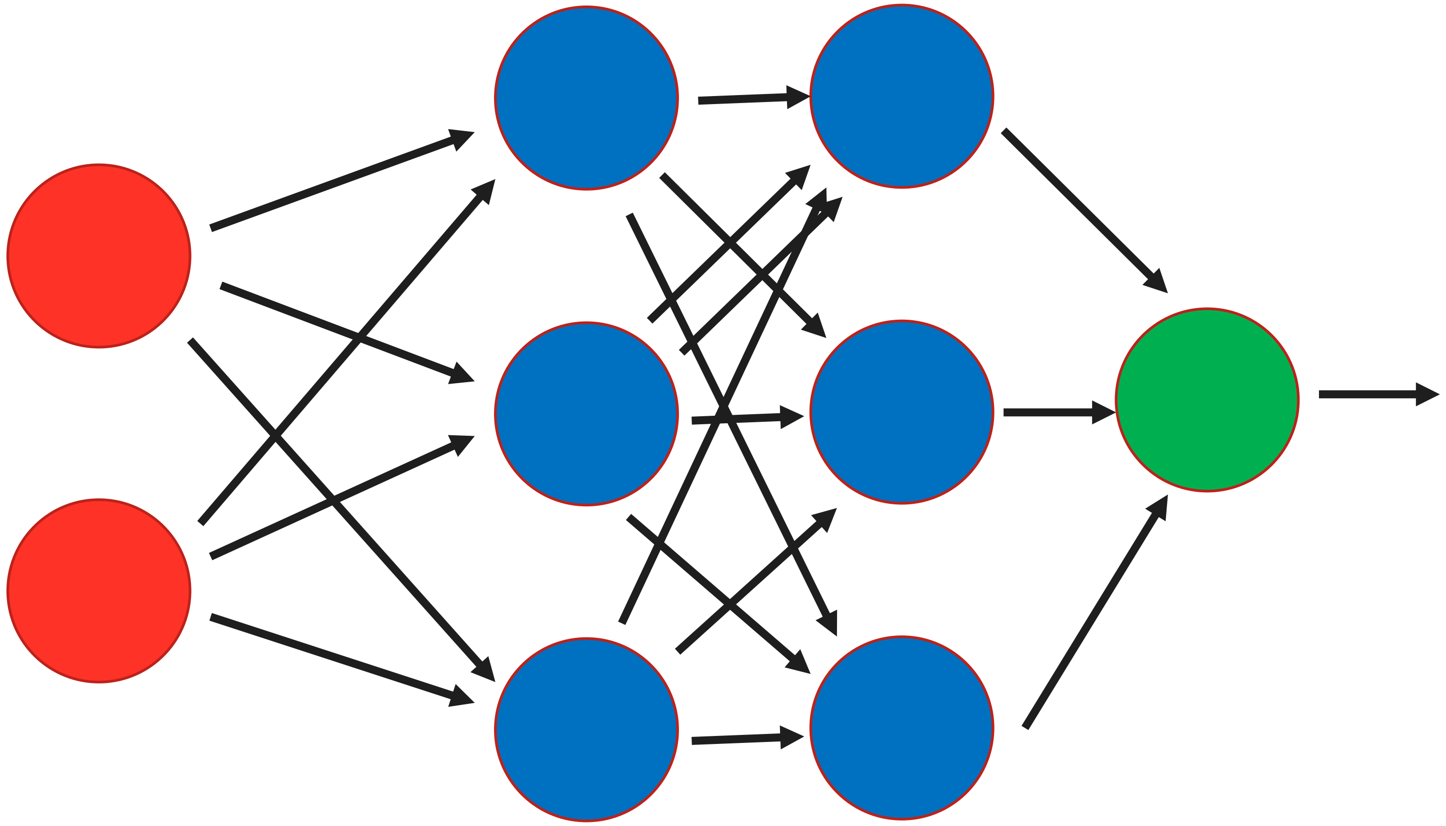

Backpropagation

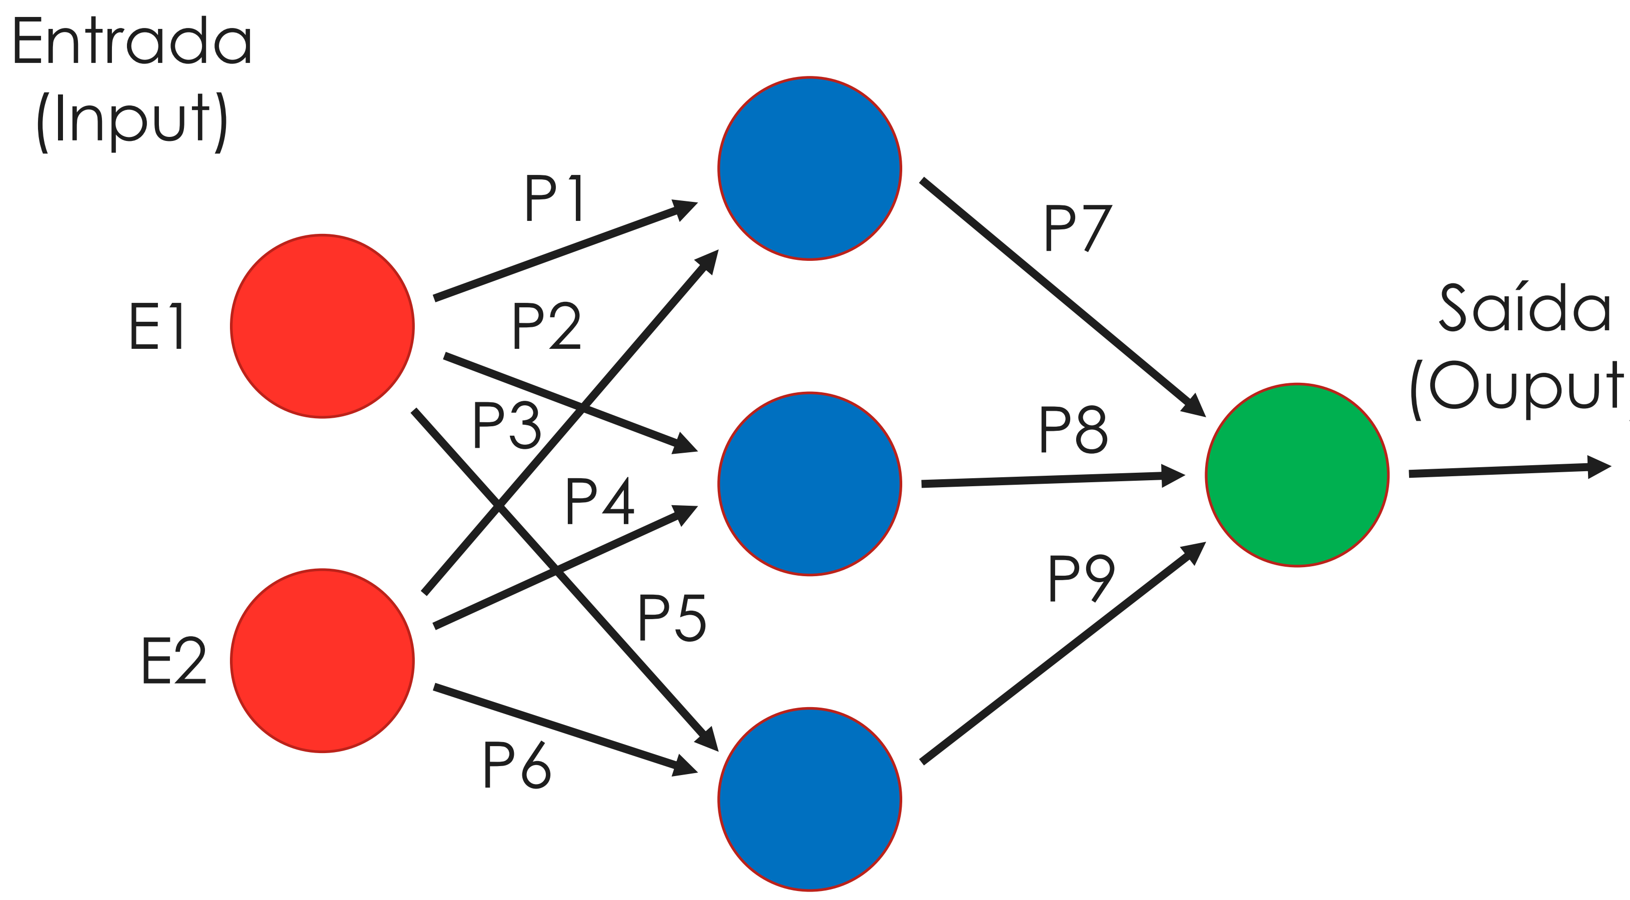

Backpropagation

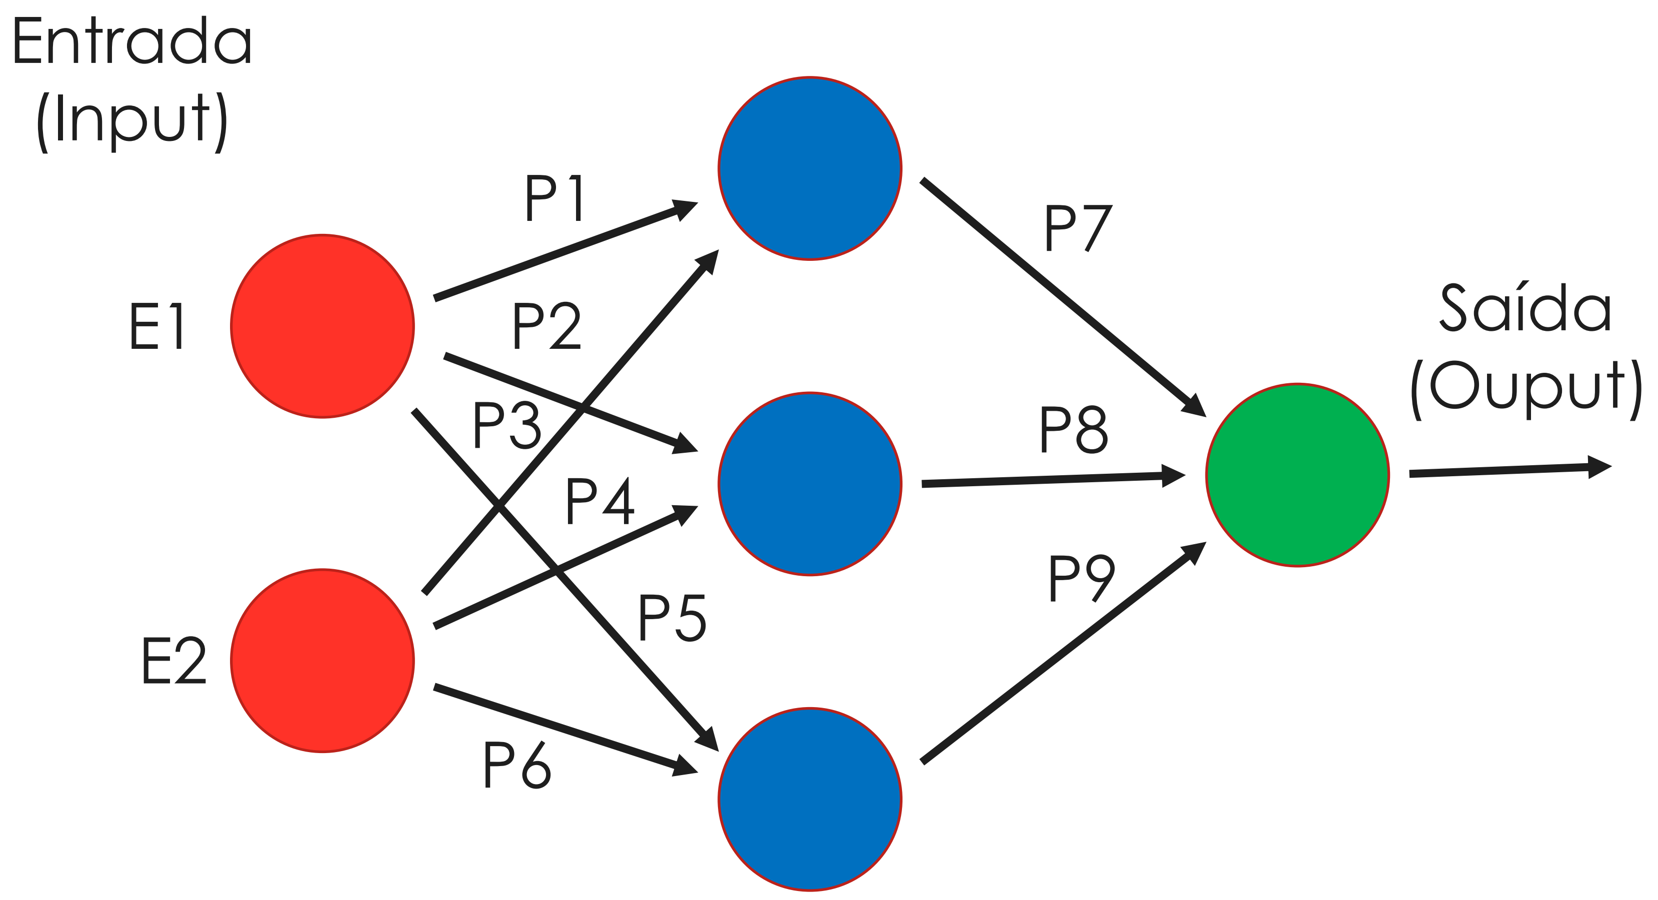

Passos:

1. Definir função de custo (desvio quadrático médio, entropia, etc...)
2. Ir uma camada para trás e calcular o gradiente da função de custo
3. Mudar os pesos na direção do gradiente (método do gradiente)

Tipos de Redes Neuronais

Tipos de Redes Neuronais

Convolutional Neural Network

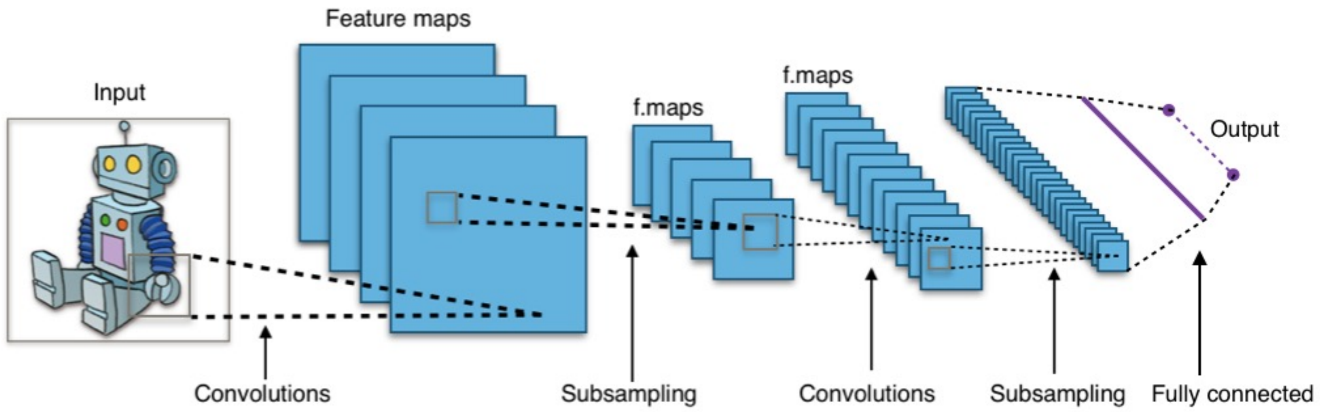

Tipos de Redes Neuronais

Convolutional Neural Network

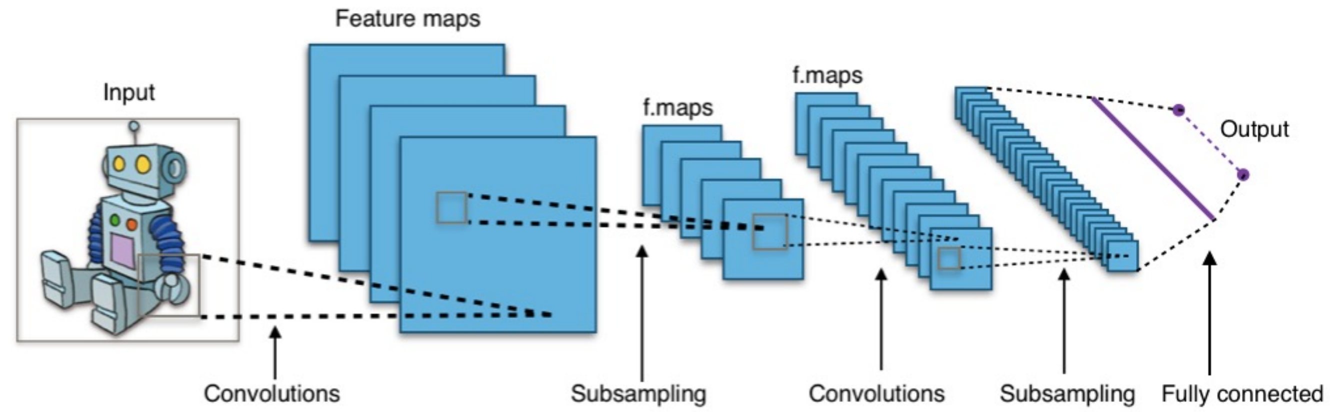

Recursive Neural Network

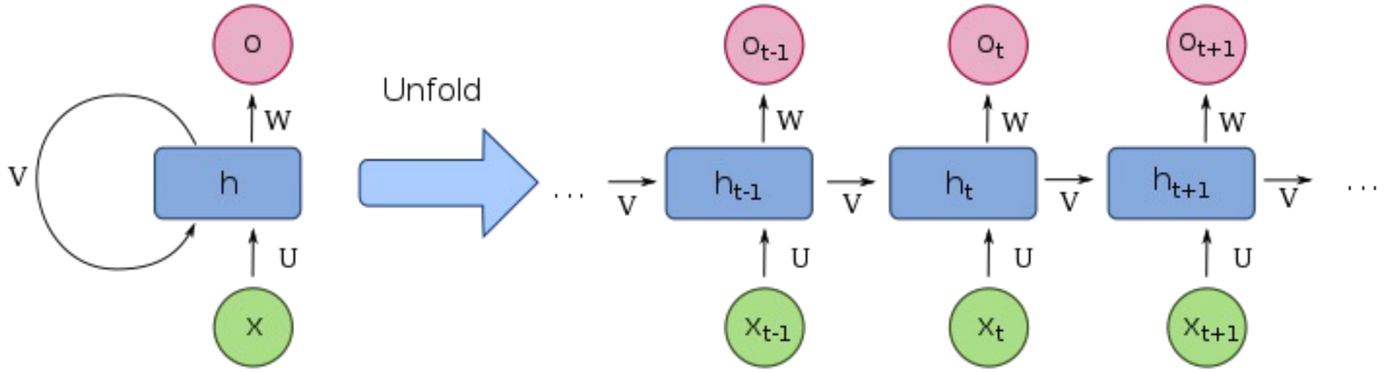

Tipos de Redes Neuronais

Convolutional Neural Network

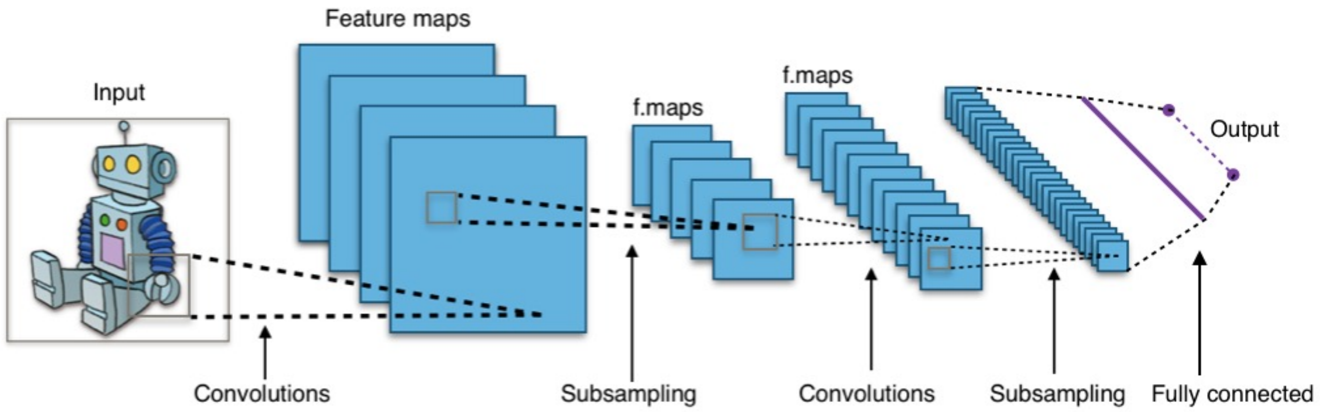

Recursive Neural Network

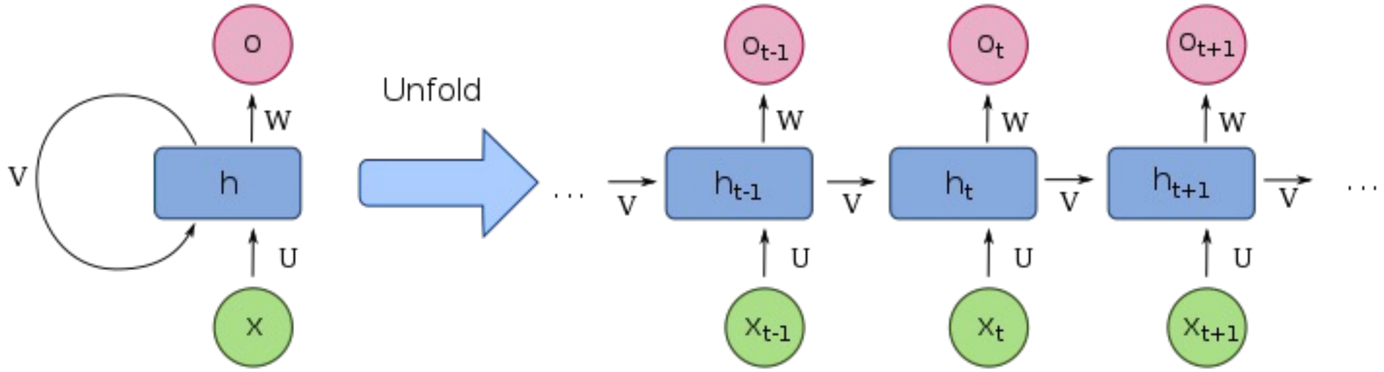

Autoencoders

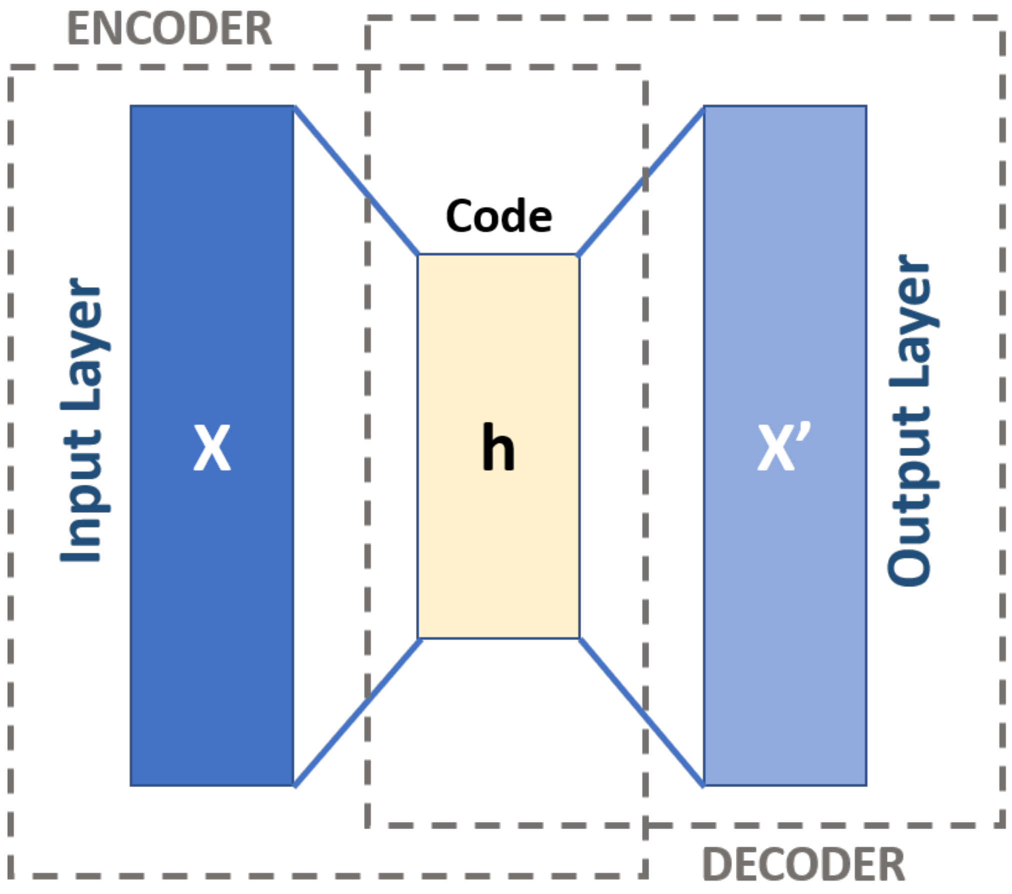

Grandes modelos de Linguagem (LLM)

ChatGPT

Gemini

Transformer

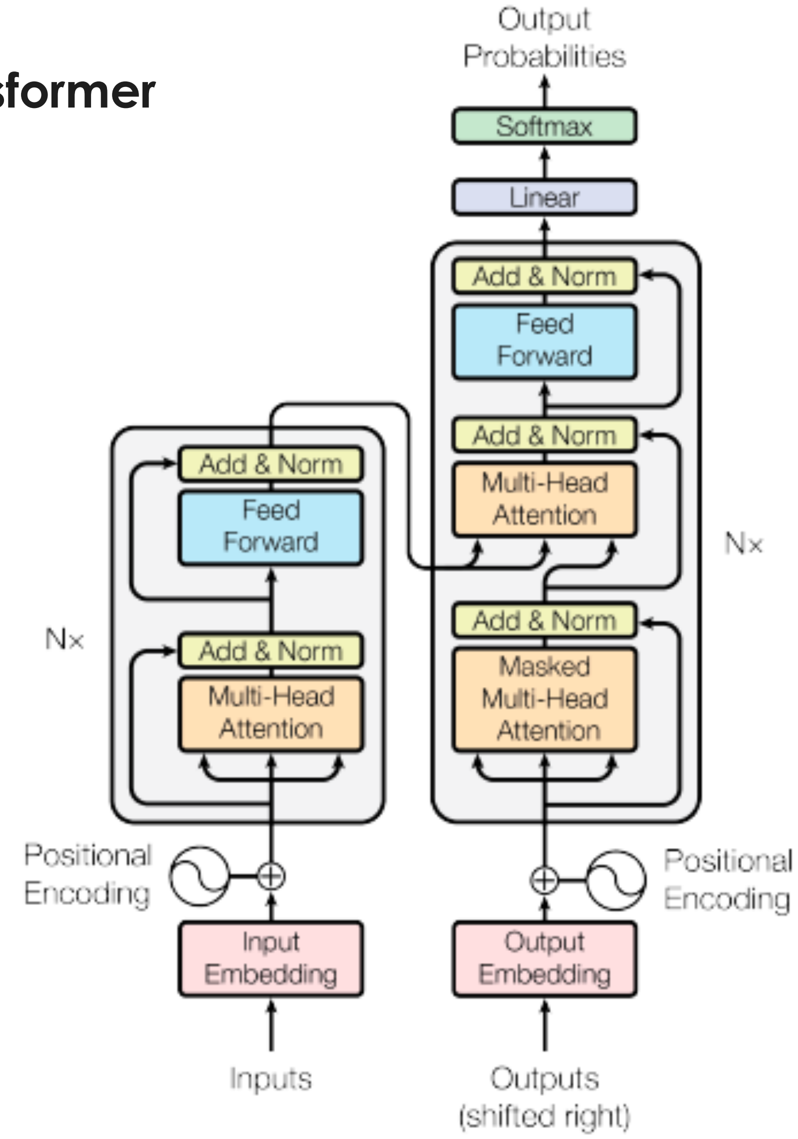

Figure 1: The Transformer - model architecture.