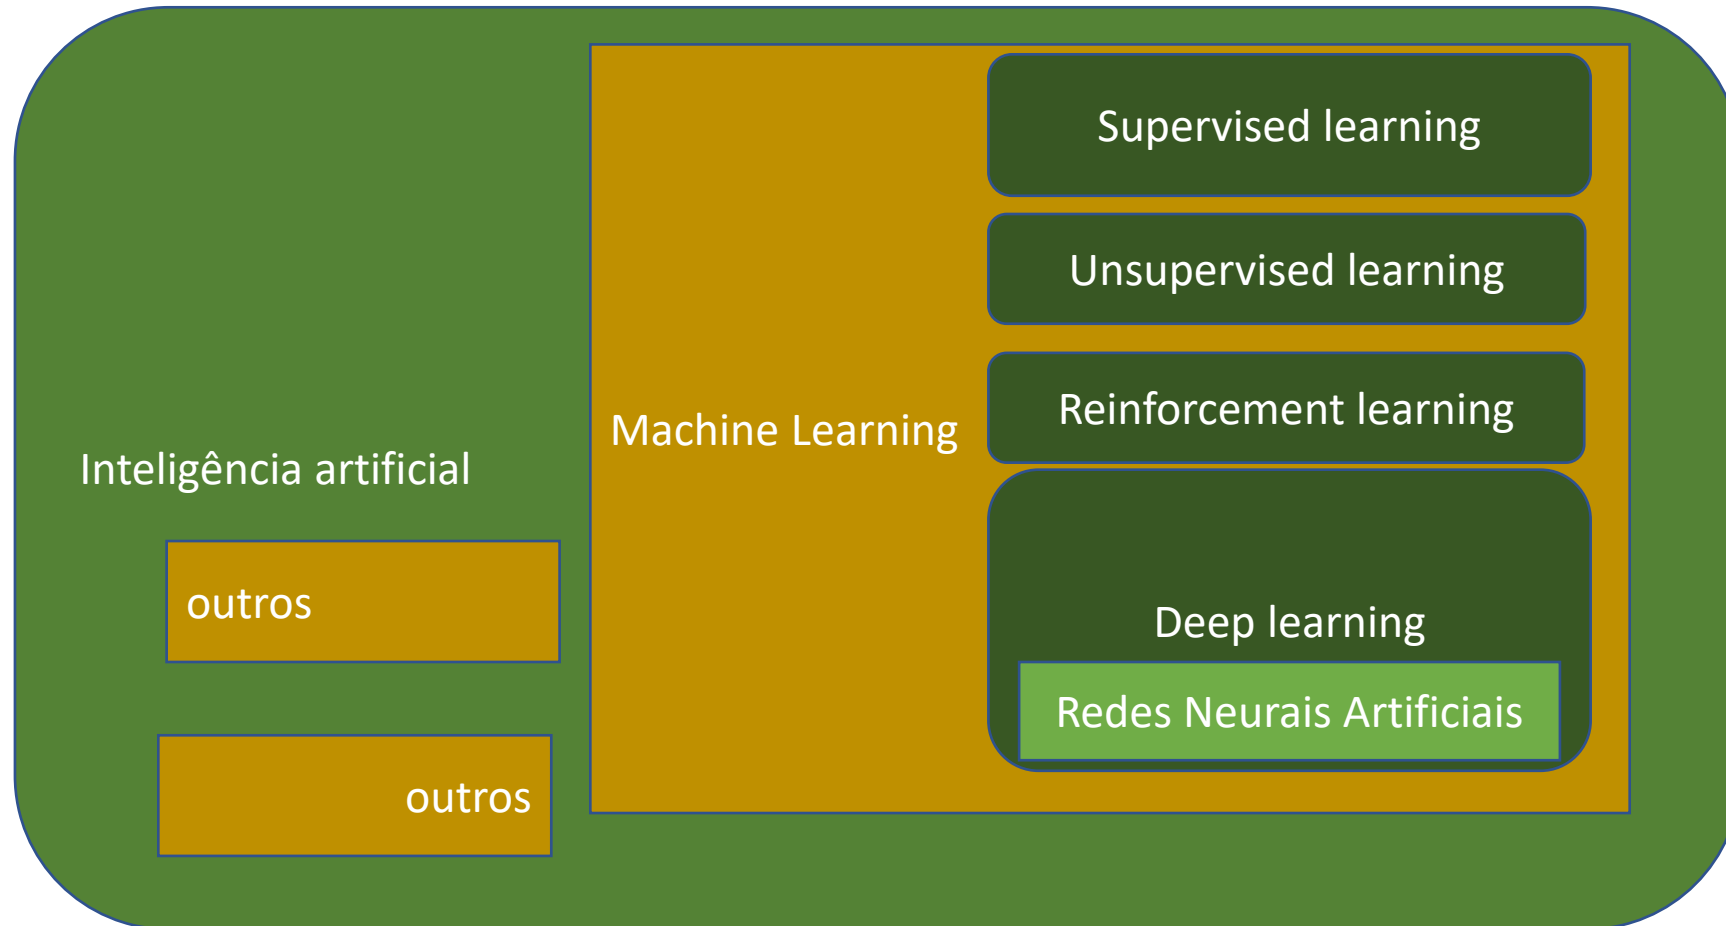


# Machine Learning Deep Learning Neural nets

Jorge Centeno



# Machine learning -> Neural Nets



# Machine learning

(Aprendizagem de máquina)

É um campo da ciência da computação que busca dar aos computadores a capacidade de aprender sem ser explicitamente programados.

*Machine learning is a form of AI that enables a system to learn from data rather than through explicit programming.*



<https://www.ibm.com/downloads/cas/GB8ZMQZ3>


No aprendizado de máquina, o computador usa uma variedade de algoritmos iterativos para aprender com os dados com a finalidade de

- descrever os dados,
- se aprimorar,
- e prever resultados.

Por exemplo, se o usuário apresenta entradas e saídas ao computador, ele pode “aprender” com base nos exemplos.




À medida que os algoritmos recebem mais dados de treinamento, eles depuram os modelos com base nesses dados.

Após o treinamento, quando você apresentar uma entrada ao modelo, você receberá uma saída.



# Como solucionamos problemas?

Você pode ... Reconhecer se a declividade do terreno é alta ou baixa, olhando as isolinhas (curvas de nível)?




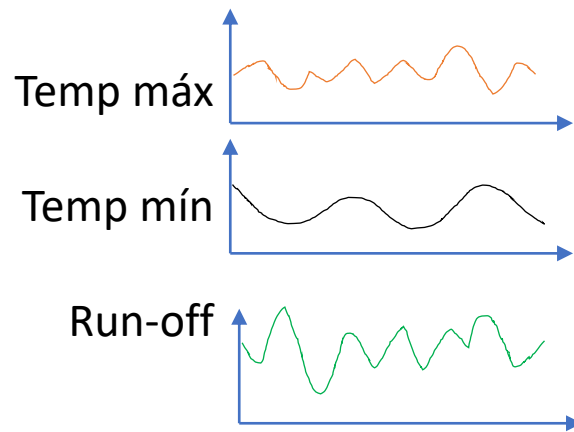
E um computador, poderia fazer isto, sem que você fornecesse o “modelo”?

OU...


Prever variáveis hidrológicas com base em uma série de observações de outras variáveis?

## Urban Water Flow and Water Level Prediction based on Deep Learning

Haytham Assem et al. (<http://ecmlpkdd2017.ijs.si/papers/paperID343.pdf>)



(a) Water flow predictions






(b) Water level predictions

# Fluxo de Aprendizado

Começa com a extração de características (descritores) relevantes das variáveis de entrada.

Estes descritores são usadas para criar um modelo que pode ser usado para classificar as entradas.



Os descritores “descrevem” os principais aspectos que podem ser usados para caracterizar os elementos envolvidos no problema.



# Parametrização: descritores

Como podemos descrever a declividade?

Por exemplo...densidade de curvas de nível na região?





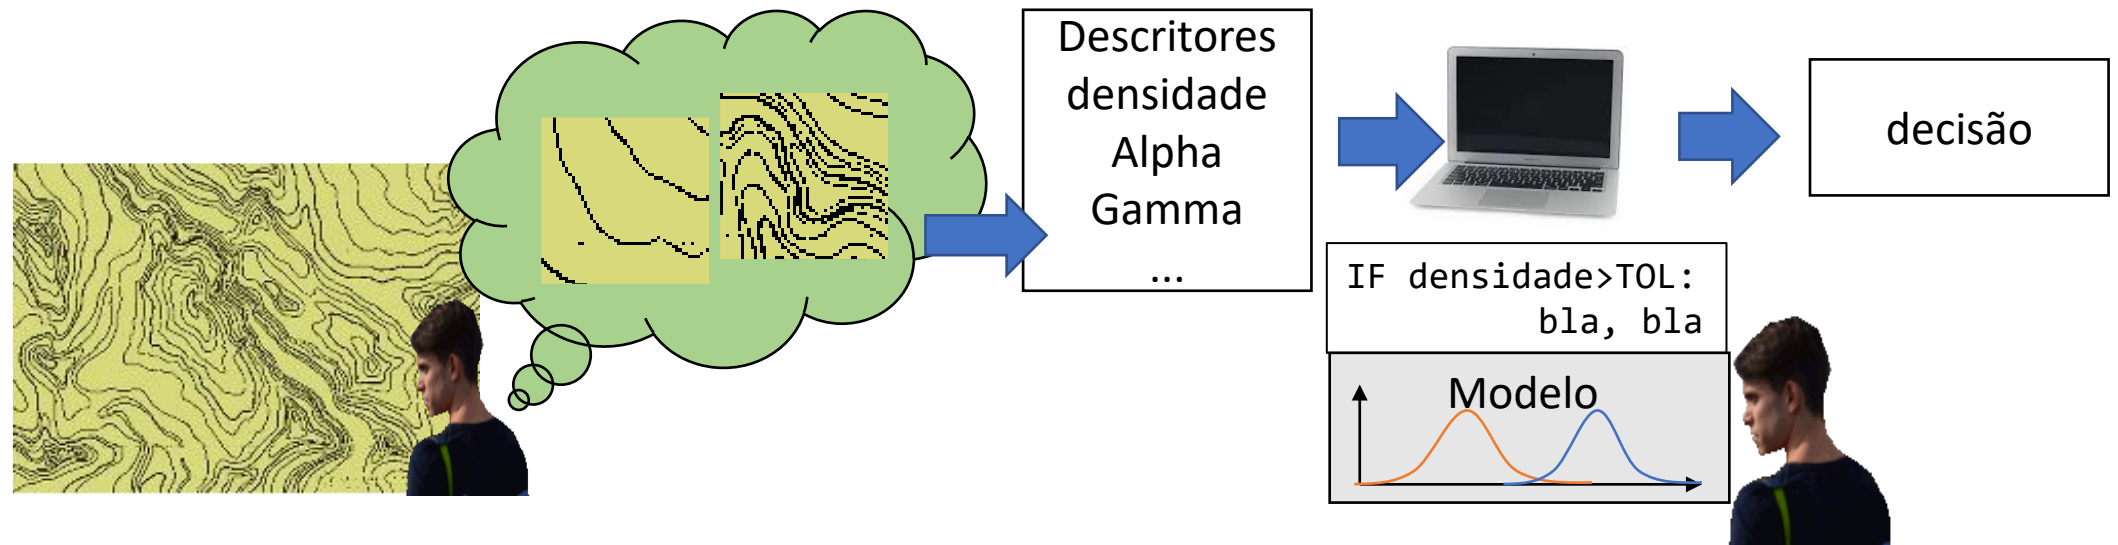
# No Fluxo de Aprendizado tradicional

As características (descritores) relevantes são especificadas pelo usuário.

Por exemplo,

*“comprimento das curvas por unidade de área”*

Estes descritores são passados ao computador (máquina) para que os use na tomada de decisões.



Um exercício...



# Aprendendo alemão

Pode dizer qual é o artigo de:

a) \_\_\_ Wagen



b) \_\_\_ Industrie



Opções:

1: die

2: der

# Agora com ajuda...

Dada a lista de substantivos com seus artigos, pode dizer qual é o artigo de:

a) \_\_\_ Wagen



b) \_\_\_\_\_ Industrie



Opções:      1: die                      2: der

Qual é a regra?

|     |             |
|-----|-------------|
| die | Anästhesie  |
| die | Anomalie    |
| der | Bäcker      |
| die | Energie     |
| der | Hut         |
| die | Ironie      |
| der | Kaffee      |
| der | Kellner     |
| die | Melodie     |
| der | Ober        |
| die | Psychologie |
| der | Windsurfer  |

# Last characters

As palavras que terminam em “ie” são feminino (die)  
Então, se a última letra for “ie”, o artigo correto é “die”.

Podemos propor um programa, definindo explicitamente uma regra:

```
#####  
IF last_chars == 'ie':  
    artigo=feminino  
IF last_chars != 'ie':  
    artigo=masculino  
#####
```

Descritor  
Feature

| artigo | substantivo | last_char |
|--------|-------------|-----------|
| die    | Anästhesie  | 1         |
| die    | Anomalie    | 1         |
| der    | Bäcker      | 0         |
| die    | Energie     | 1         |
| der    | Hut         | 0         |
| die    | Ironie      | 1         |
| der    | Kaffee      | 0         |
| der    | Kellner     | 0         |
| die    | Melodie     | 1         |
| der    | Ober        | 0         |
| die    | Psychologie | 1         |
| der    | Windsurfer  | 0         |

Feminino=die, Masculino=der

a) \_\_\_ Industrie

b) \_\_\_ Wagen

# Ou ...

|     |             |
|-----|-------------|
| die | Anästhesie  |
| die | Anomalie    |
| der | Bäcker      |
| die | Energie     |
| der | Hut         |
| die | Ironie      |
| der | Kaffee      |
| der | Kellner     |
| die | Melodie     |
| der | Ober        |
| die | Psychologie |
| der | Windsurfer  |

Será possível que o computador “descubra” este padrão automaticamente?



- a) \_\_\_ Industrie
- b) \_\_\_ Wagen

# Lembrando...

*Machine learning é uma forma de IA na que o Sistema aprende dos dados em lugar de receber ordens explícitas através de programas.*

o computador usa uma variedade de algoritmos iterativos para aprender com os dados...




# Fluxo de trabalho

Os descritores relevantes são extraídos automaticamente.

A aprendizagem profunda realiza "aprendizado de ponta a ponta", ou seja, a uma rede são entregues dados brutos e uma tarefa para executar (classificação), e ela aprende como fazer isso de forma independente.

|     |             |
|-----|-------------|
| die | Anästhesie  |
| die | Anomalie    |
| der | Bäcker      |
| die | Energie     |
| der | Hut         |
| die | Ironie      |
| der | Kaffee      |
| der | Kellner     |
| die | Melodie     |
| der | Ober        |
| die | Psychologie |
| der | Windsurfer  |



Descritores  
de máquina

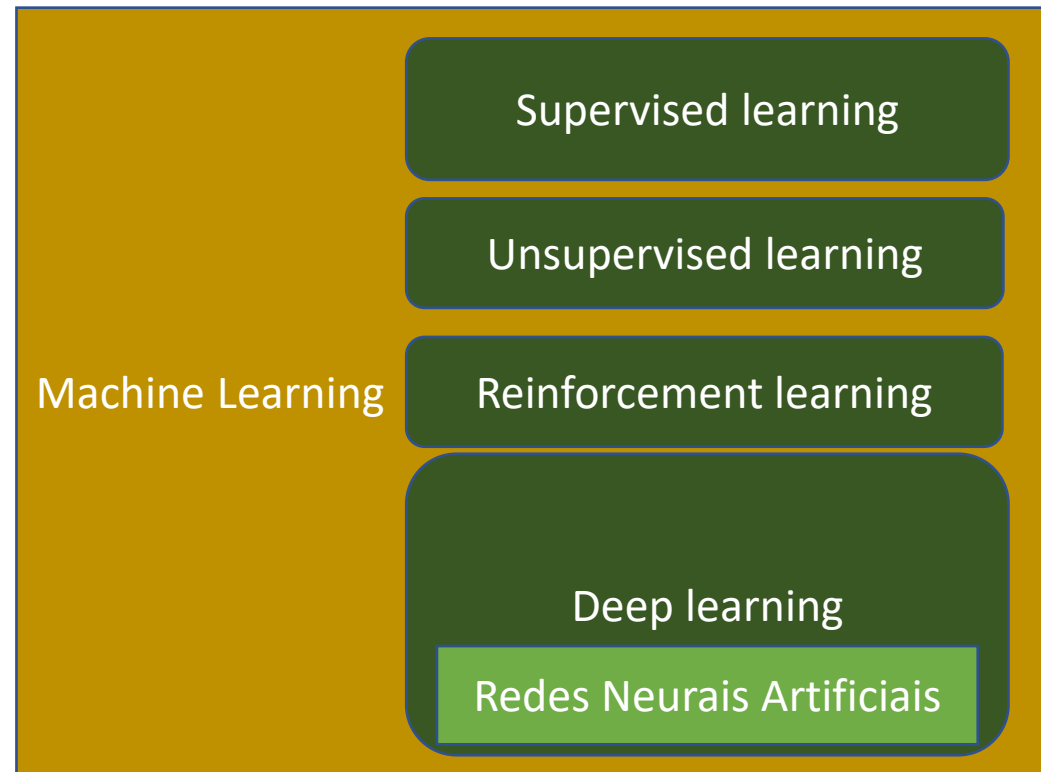
Modelo



solução



# Machine Learning



opções

# Aprendizagem supervisionada

Nela, são apresentados ao sistema um conjunto de entradas junto com o resultado esperado (rotulo).

O sistema deve detectar padrões nos dados para apoiar a decisão.

Se o rótulo é contínuo, trata-se de uma regressão. Em essência, a regressão usada para aprendizagem supervisionada ajuda entender a correlação entre as variáveis.

Um exemplo de aprendizagem supervisionada é a previsão do tempo. Usando análise de regressão, a previsão do tempo leva em consideração histórico conhecido, padrões climáticos e as condições atuais para fornecer uma previsão do tempo.

| Input | Input | Output |
|-------|-------|--------|
| x     | y     | z      |
| 1     | 8     | 33,5   |
| 2     | 2     | 10     |
| 5     | 0     | 3,5    |
| 8     | 3     | 17     |
| 2     | 5     | 22     |
| 0     | 7     | 29     |
| 3     | 9     | 38,5   |
| 5     | 5     | 23,5   |
| 7     | 3     | 16,5   |


# Classificação

Se os rótulos são limitados a um conjunto finito de valores discretos, trata-se de uma classificação.


A rotulagem dos dados permite definir as categorias desejadas.



Rótulos: 0 1 0 1



| Input | Input | Output |
|-------|-------|--------|
| x     | y     | Classe |
| 1     | 8     | 1      |
| 2     | 2     | 0      |
| 5     | 0     | 1      |
| 8     | 3     | 2      |
| 2     | 5     | 1      |
| 0     | 7     | 0      |
| 3     | 9     | 1      |
| 5     | 5     | 2      |
| 7     | 3     | 1      |
| 8     | 9     | 0      |
| 2     | 5     | 1      |
| 0     | 3     | 2      |
| 3     | 9     | 1      |
| 5     | 5     | 0      |
| 7     | 3     | 1      |



# Treinamento - verificação

O sistema é treinado com exemplos e seu desempenho deve ser avaliado com dados de teste.

Os padrões identificados em um **subconjunto** dos dados podem não ser visíveis na grande população de dados.



Se o modelo for ajustado para representar apenas os padrões que existem no subconjunto de treinamento, pode ocorrer **overfitting**.

**Overfitting:** o modelo está precisamente ajustado para os dados de treinamento, mas pode não ser aplicável para grandes conjuntos de dados desconhecidos.

Para evitar overfitting, o sistema deve ser avaliado com dados diferentes daqueles usados no treinamento.

# Treinamento

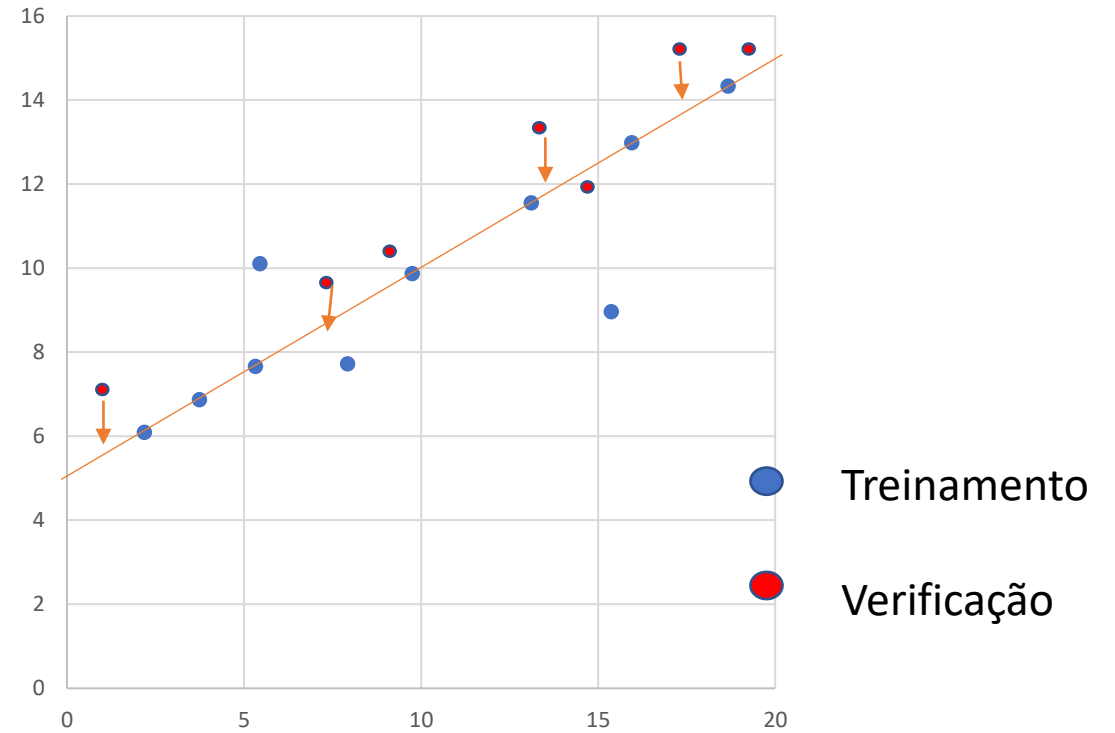

Qual modelo se ajusta melhor aos dados de treinamento?



● Treinamento

# Verificação

Qual modelo pode prever outros dados diferentes do treinamento?





# Aprendizagem não supervisionada

Neste caso, O sistema recebe apenas dos dados de entrada, SEM o resultado esperado (rotulo);


O sistema deve encontrar padrões nos dados e formar grupos de elementos com características similares.

É mais adequado quando não se conhece inicialmente a classificação dos dados. É usada, por exemplo, para detectar padrões em redes sociais.

Trata-se de compreender o significado por trás dos dados separando os mesmos em grupos com padrões similares.

Portanto, a aprendizagem supervisionada não requer a intervenção humana.

Você poderia separar as palavras ao lado em dois grupos?



Com base em que parâmetro você separaria os grupos?

Como definiria a fronteira entre grupos?

Qual nome daria a estes grupos?

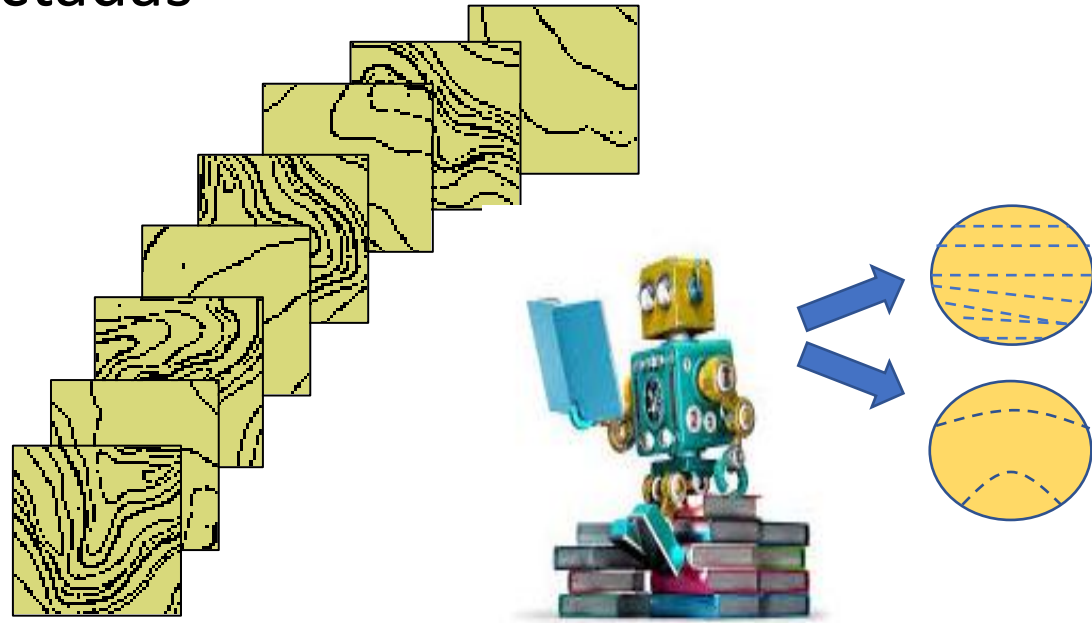
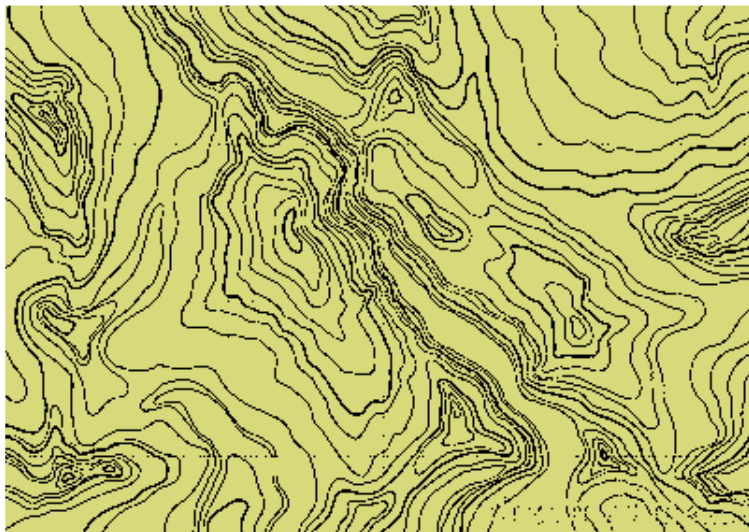
E em três grupos?

| Palavra      | Grupo |
|--------------|-------|
| Archiv       |       |
| Cartoons     |       |
| Fehler       |       |
| Flexion      |       |
| Forum        |       |
| Kontakt      |       |
| Kurz         |       |
| Lektorat     |       |
| Leserfragen  |       |
| Links        |       |
| Nachgefragt  |       |
| Regeln       |       |
| Rezensionen  |       |
| Sprachleben  |       |
| Startseite   |       |
| Stilblüten   |       |
| Synonyme     |       |
| Tipps        |       |
| Übersicht    |       |
| Unterhaltung |       |
| Vermischtes  |       |
| Weblog       |       |
| Website      |       |



# Dados não rotulados

Apresenta-se amostras e o sistema forma grupos segundo algumas características detectadas



Os grupos podem (ou não) ter interpretação útil.

Algoritmos não supervisionados podem ajudar a compreender grandes volumes de dados novos não rotulados.

Quando o usuário encontra dificuldades em interpretar muitas variáveis e muitos dados para fins de classificação e interpretação.

Ex: dados vários (muitos) parâmetros das bacias do Paraná, é possível achar grupos de bacias similares?



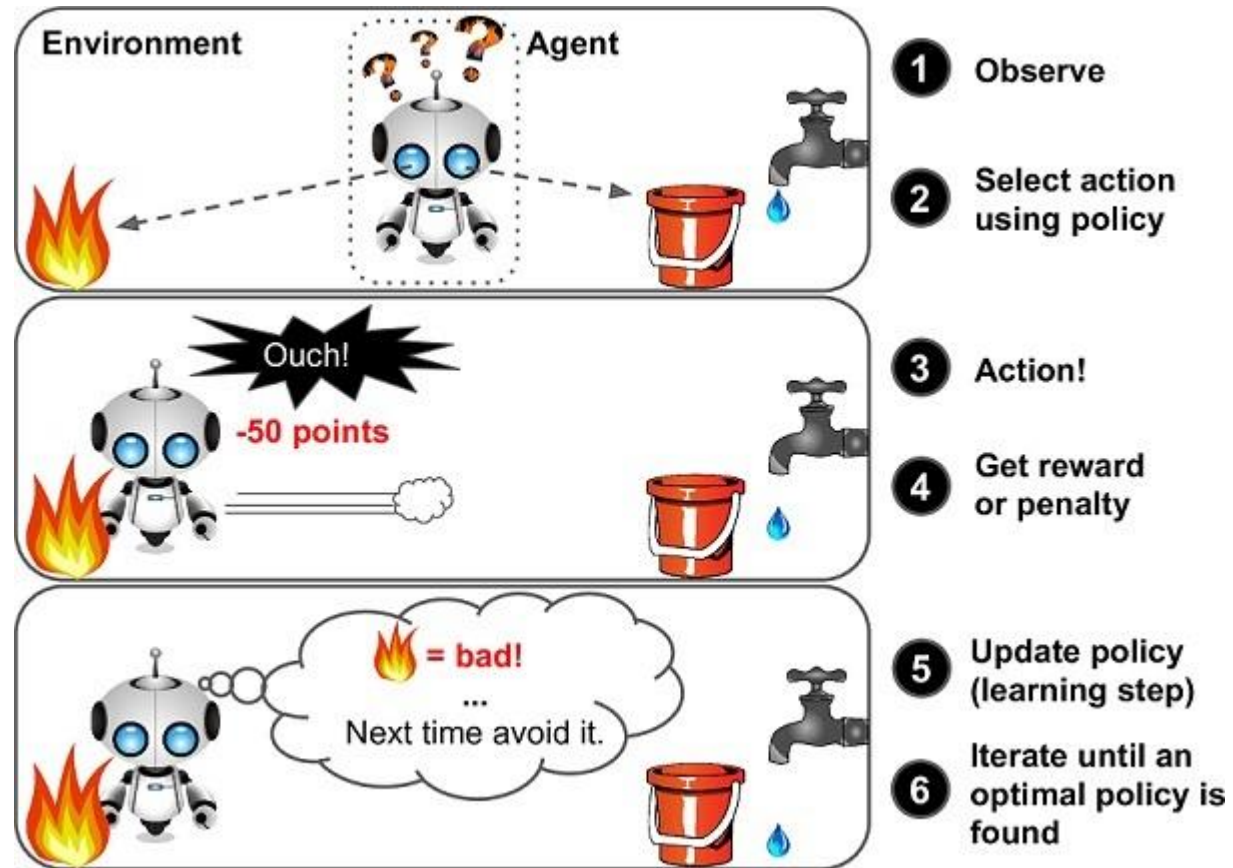
| Player                 | Pos | Team | x   | Opp     | Result | Cmp | Att | Yds | TD | Int | Att | Yds | Yds/Att | Fum | Tgt | Rec | Yds | Yds/Rec | Catch % | Touches (RB Only) | Rush Att | Tgt |   |
|------------------------|-----|------|-----|---------|--------|-----|-----|-----|----|-----|-----|-----|---------|-----|-----|-----|-----|---------|---------|-------------------|----------|-----|---|
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Austin Hooper/HoopAu00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 5 |
| Calvin Ridley/RidCa00  | WR  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 1 |
| Eric Saubert/SaubEr00  | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 1 |
| Isa Smith/SmI800       | RB  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 7  | 22  | 3.1 | 0   | 1       | 1   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 0 |
| Julio Jones/JoneJu02   | WR  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 8   | 2   | 18  | 0       | 9.00    | 25.0%             | 0        | 8   | 0 |
| Justin Hardy/HardJu00  | WR  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 0 |
| Logan Paulsen/PaulLo00 | TE  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 1 |
| Marvin Hall/HallMa02   | WR  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 4 |
| Matt Ryan/RyanMa00     | QB  | ATL  | BAL | L 16-26 | 16     | 26  | 131 | 1   | 0  | 2   | 4   | 2   | 0       | 1   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 0 |
| Mohamed Samu/SamuMo00  | WR  | ATL  | BAL | L 16-26 | 0      | 1   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 4   | 3   | 37  | 0       | 12.33   | 75.0%             | 0        | 4   | 1 |
| Ricky Ortiz/OrtizR00   | RB  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 0   | 0   | 0   | 0       | 0       | 0                 | 0        | 0   | 3 |
| Russell Gage/GageRu00  | WR  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 0   | 0   | 0   | 0       | 0   | 1   | 1   | 7   | 0       | 7.00    | 100.0%            | 0        | 1   | 0 |
| Tevin Coleman/ColeTe01 | RB  | ATL  | BAL | L 16-26 | 0      | 0   | 0   | 0   | 0  | 6   | 8   | 1.3 | 0       | 1   | 3   | 1   | 3   | 0       | 3.00    | 33.3%             | 7        | 6   | 3 |

# Reinforcement learning

O algoritmo produz um resultado que provoca um *feedback* que permite melhorar o resultado.

Na ***aprendizagem por reforço*** o sistema não é treinado com o conjunto de amostras, mas ele **aprende por tentativa e erro**. Portanto, uma sequência de decisões bem-sucedidas resultará no processo sendo "reforçado" porque é a melhor solução para o problema em questão.







# Deep Learning & Neural networks


*Deep learning* (Aprendizagem profunda) são redes **neurais artificiais** projetadas para emular o funcionamento do cérebro humano para lidar com abstrações e problemas mal definidos.

*Deep learning* é um método específico de aprendizado de máquina que incorpora **redes neurais** em camadas sucessivas para aprender a partir dos dados de maneira iterativa. O aprendizado profundo é especialmente útil quando se deseja aprender padrões de dados não estruturados.

Redes neurais e aprendizado profundo são frequentemente usados em aplicativos de reconhecimento de imagem, fala e visão computacional.

# Deep learning

Deep = profunda: porque utiliza várias camadas de redes neurais para estimar as características (features) e combiná-las para derivar a conclusão.



Mas todo começou com RNA

