

Machine Learning

Parte 1

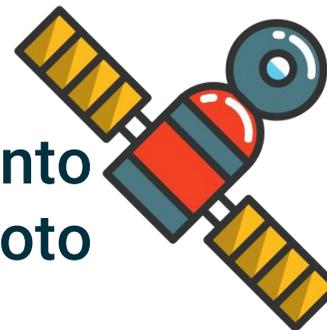
Camila Duelis Viana



**Instrumentação
Geofísica**



**Campo
Amostras
Análises**



**Sensoriamento
remoto**



**Aplicativos
Colaborativo**



**Mapas
Cartas**



**Internet
Repositórios
Nuvem**

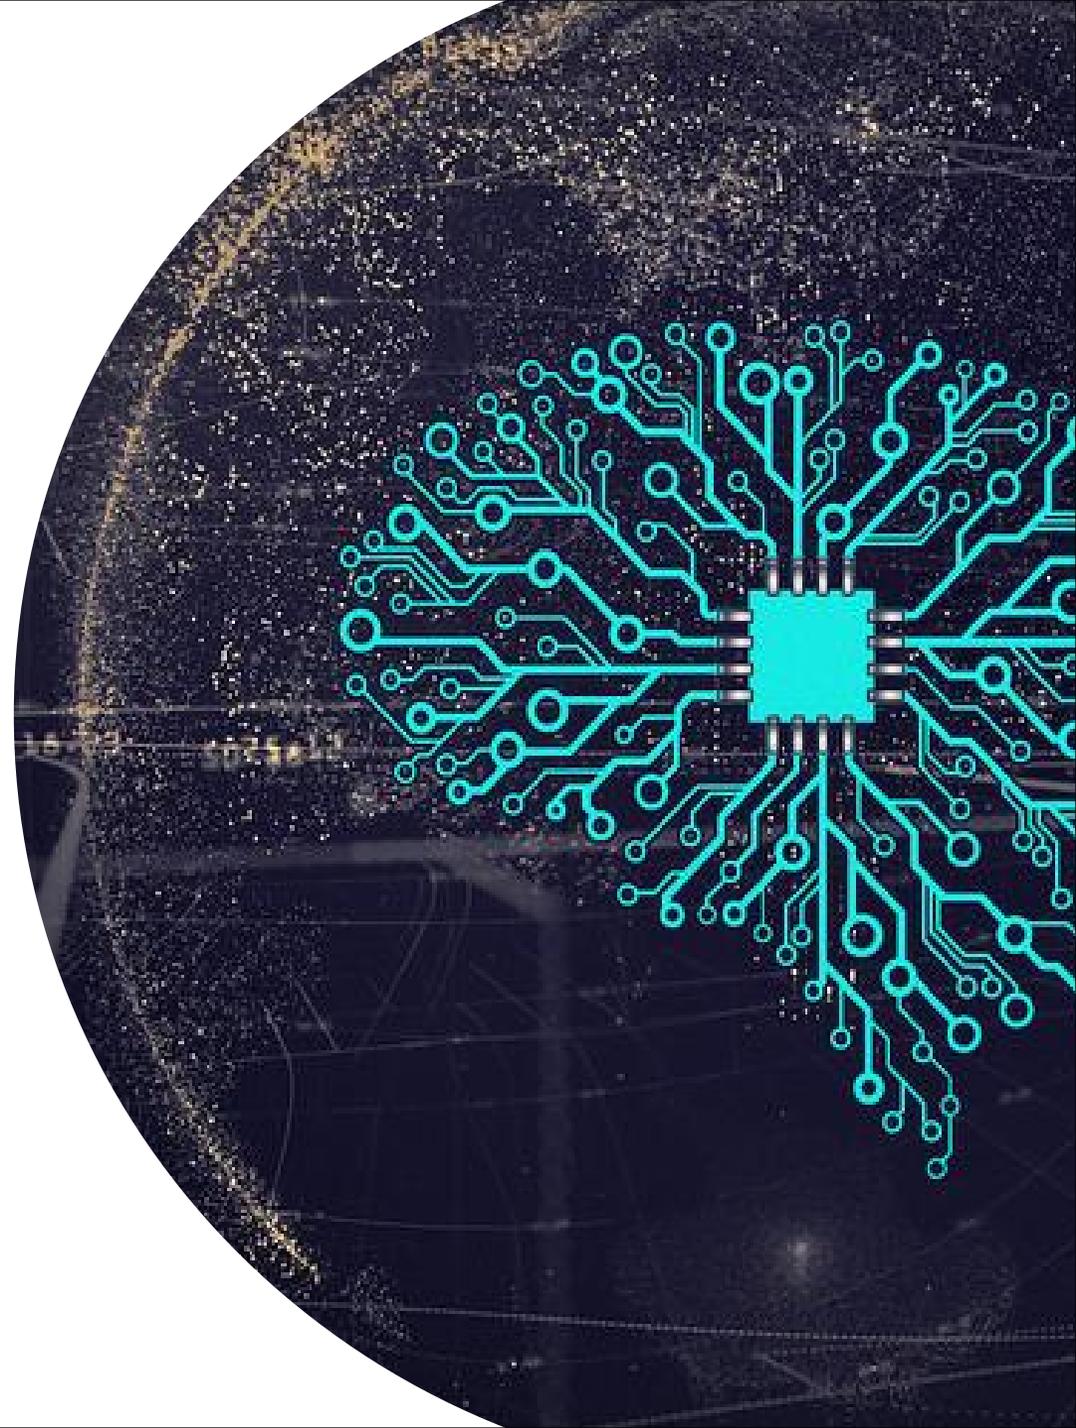


Sondagens



**Descrições
Relatórios**

O que fazer com tantos dados?



4º paradigma da ciência

Ciência é centrada nos dados, sejam observados ou simulados, unificando teoria, experimentos e simulações - eScience

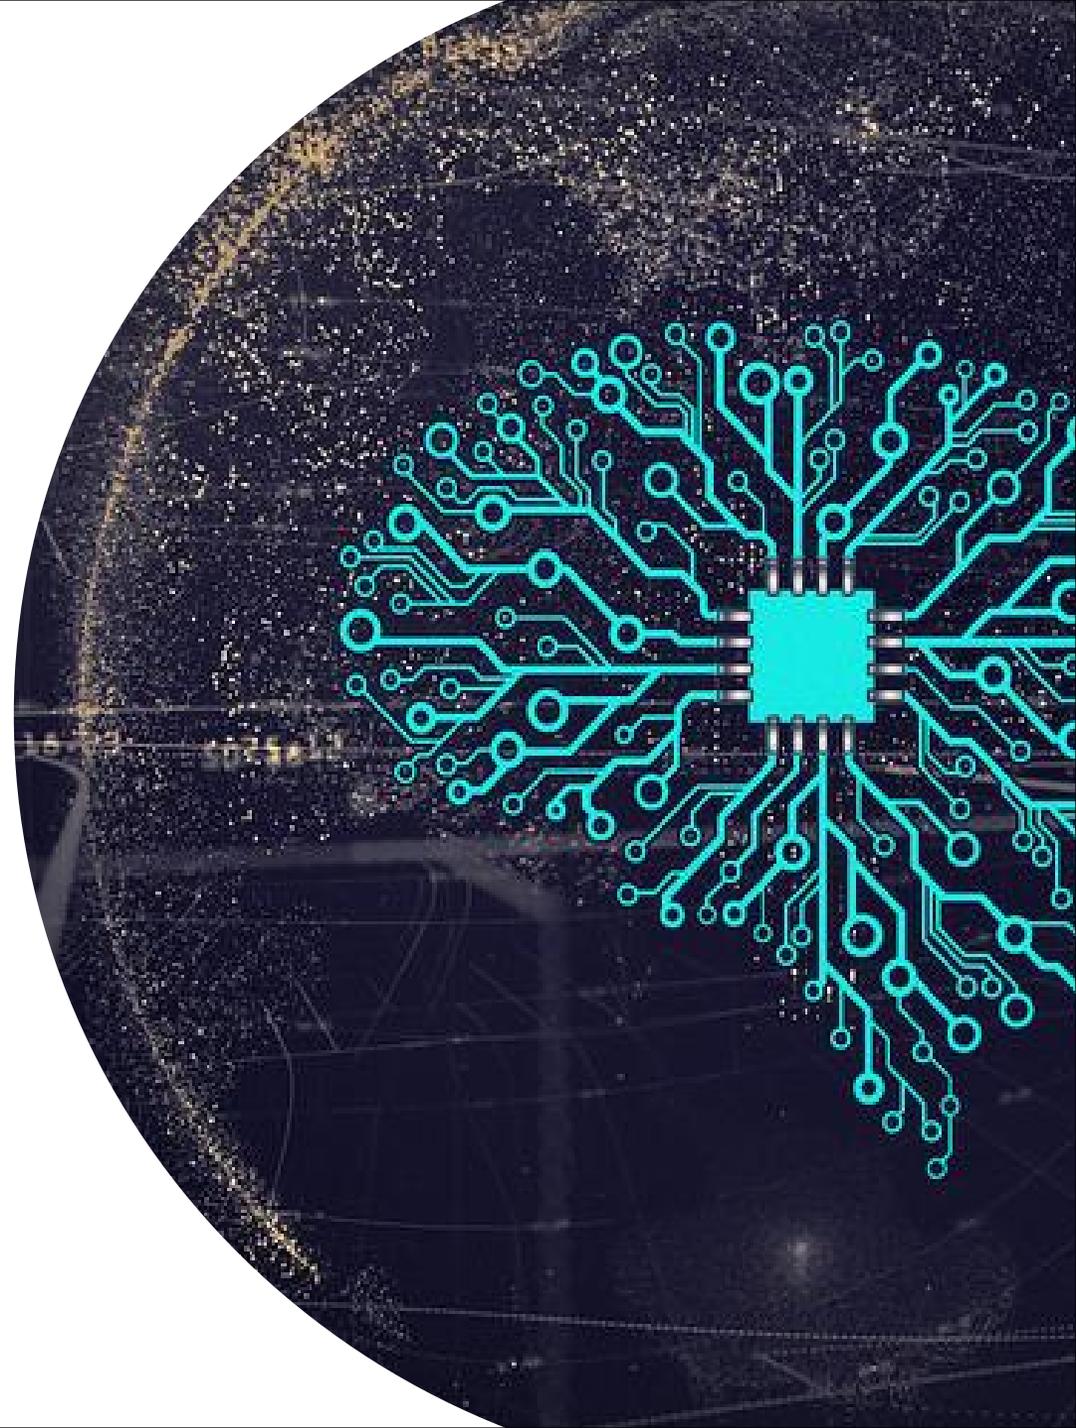
- Eficiência
- Digitalização
- Novas visões
- Mais poderosas em conjunto

**(GEO)BIG
DATA**

**(GEO)DATA
DRIVEN**



**Como extrair informação
de tantos dados?**

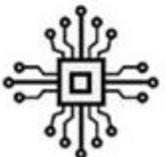


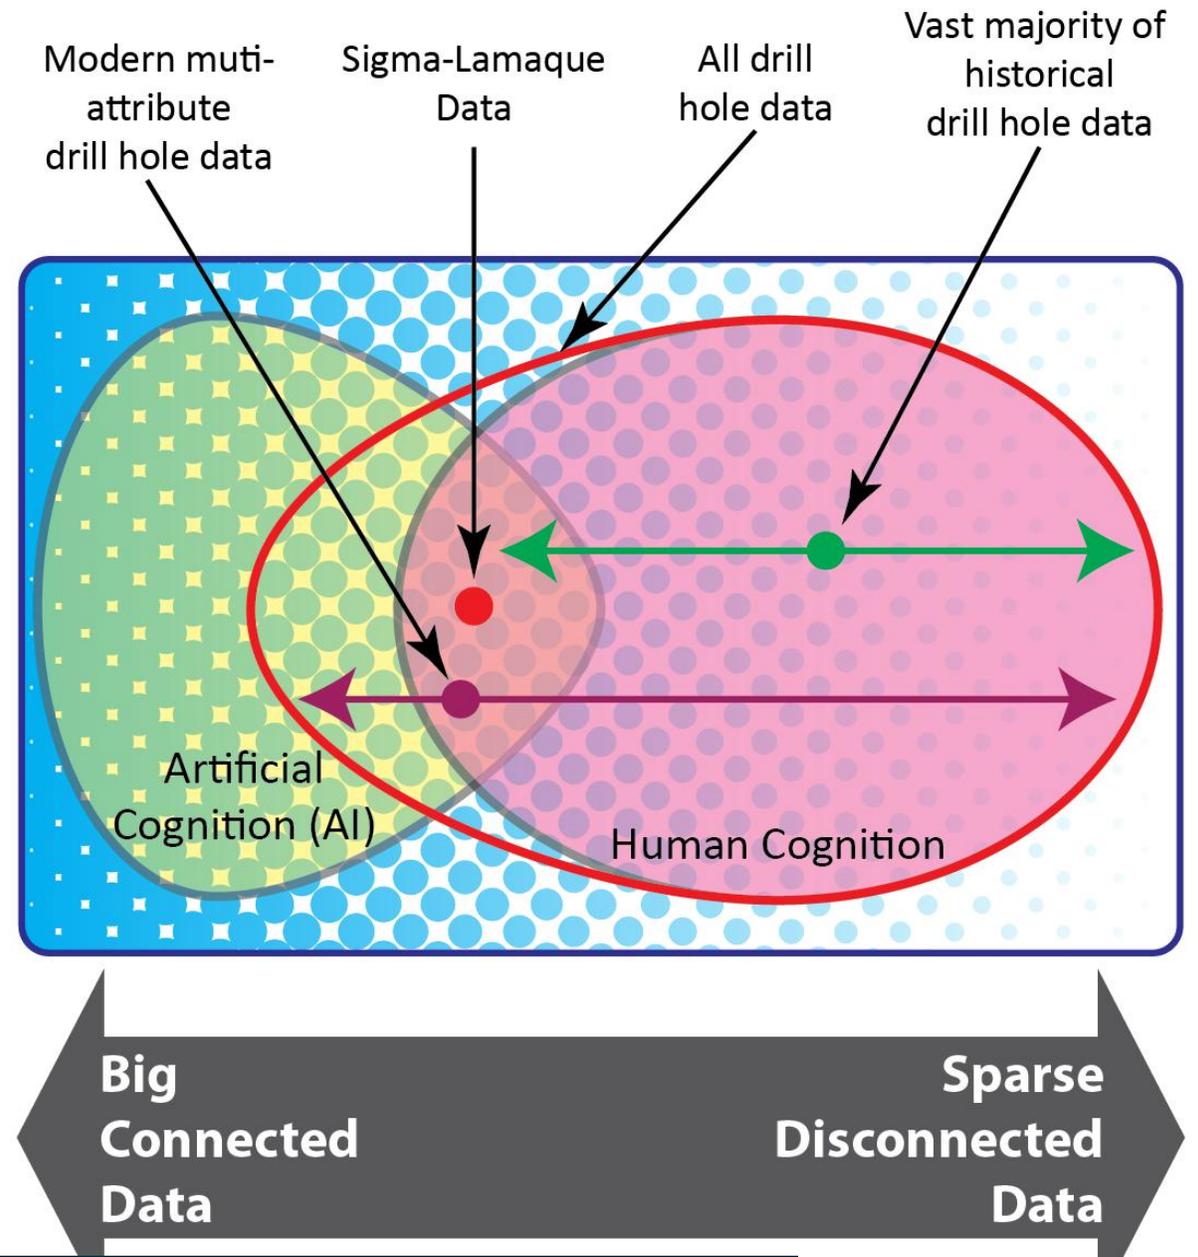
Big Data

- Volume, Velocidade, Variedade
- Exige processamento diferenciado



Humanos vs. Máquinas

	Weight	Space	Processor Speed	Energy Efficiency
	3 pounds (1.4 kg)	1/6 basketball (80 cubic inches or 1,300 cm ³)	Up to 1,000,000 trillion operations per second	20 watts
	150 tons	Basketball court (cabinets over 4,350 square feet, or 400 m ²)	93,000 trillion operations per second	10 million watts

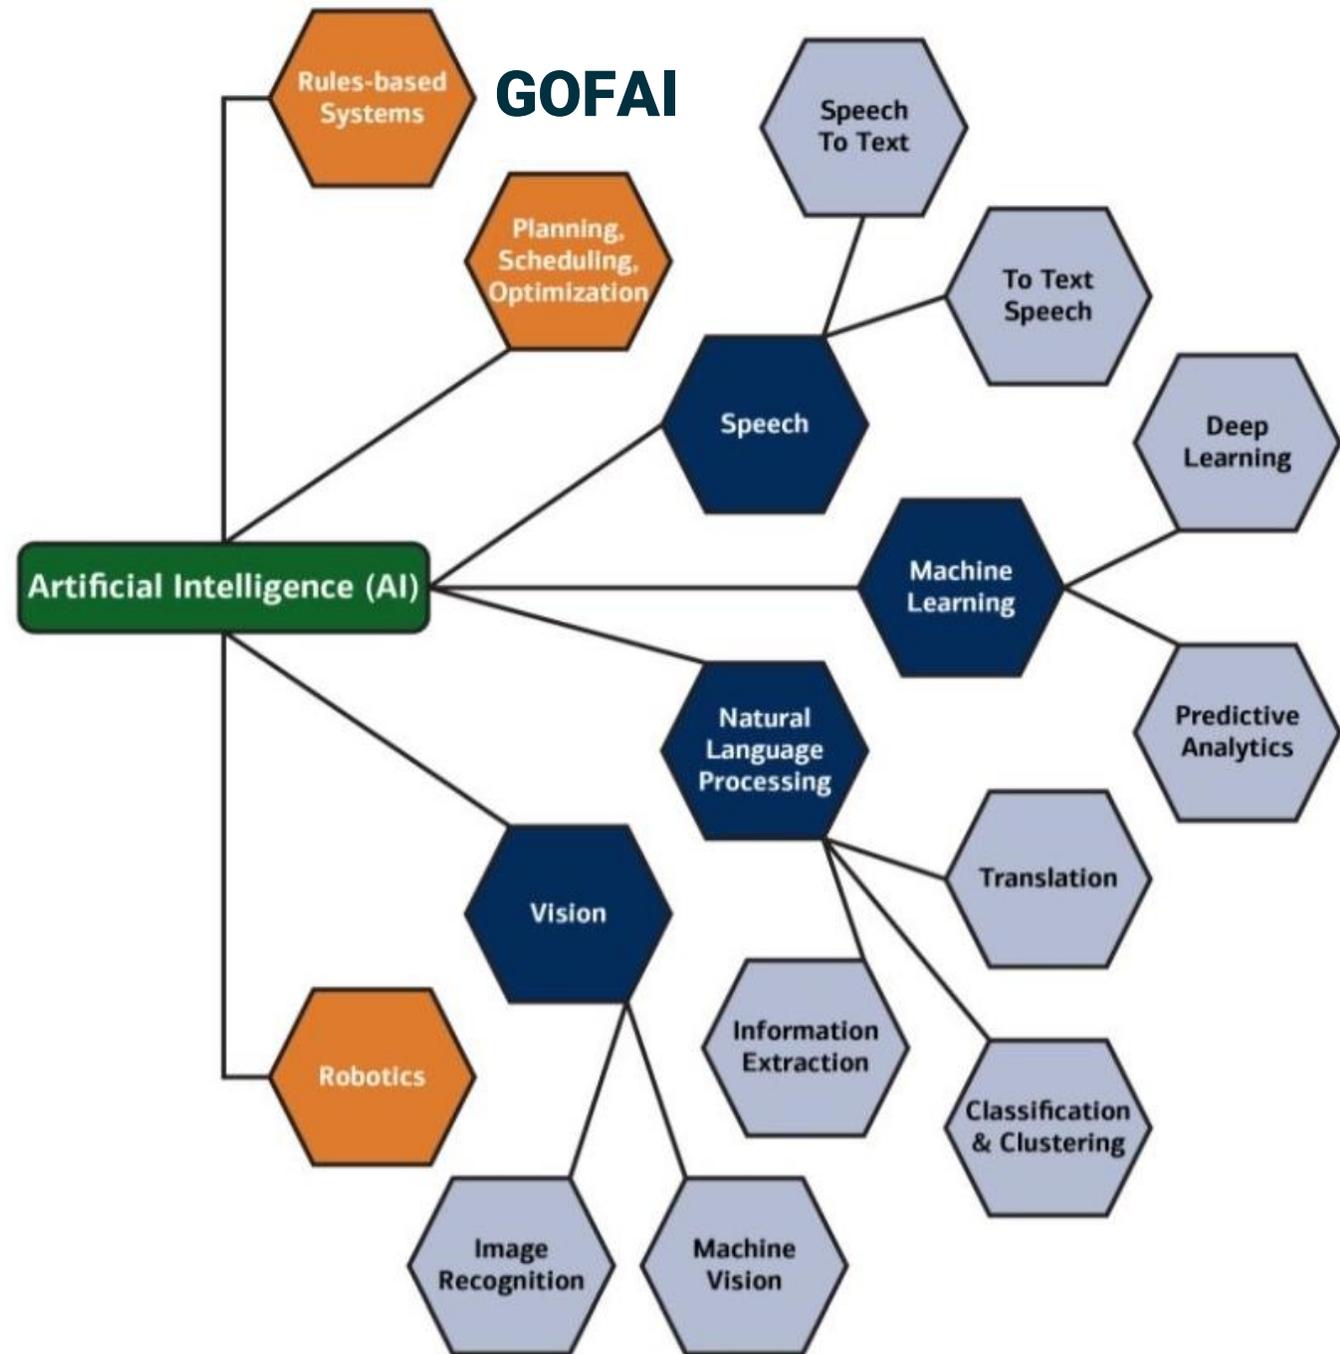


Inteligência Artificial

- 1950s
- Inteligência humana exibida por máquinas
- Termo geral para fazer com que computadores realizem atividades humanas

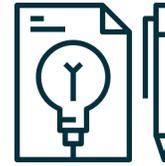
IA Limitada

Sistema pode fazer apenas uma (ou poucas) coisas definidas tão bem ou melhor que humanos



Machine Learning

- 1980s
- Uma abordagem para alcançar IA através de sistemas que podem aprender por experiência para encontrar padrões em um conjunto de dados
- Reúso de código
- Tarefas:
 - Automação
 - Modelagem e problemas inversos
 - Descoberta (padrões, estruturas, relacionamentos)



Problema Inverso

Inverse problem

Converter medidas observadas em informações sobre um objeto ou sistema.

Regressão Prever valores numéricos	Classificação Valores categóricos
Agrupamento Outros exemplos mais similares	Previsão de sequência O que vem depois?

**DADOS
MODELO**

Programação
tradicional

SAÍDA

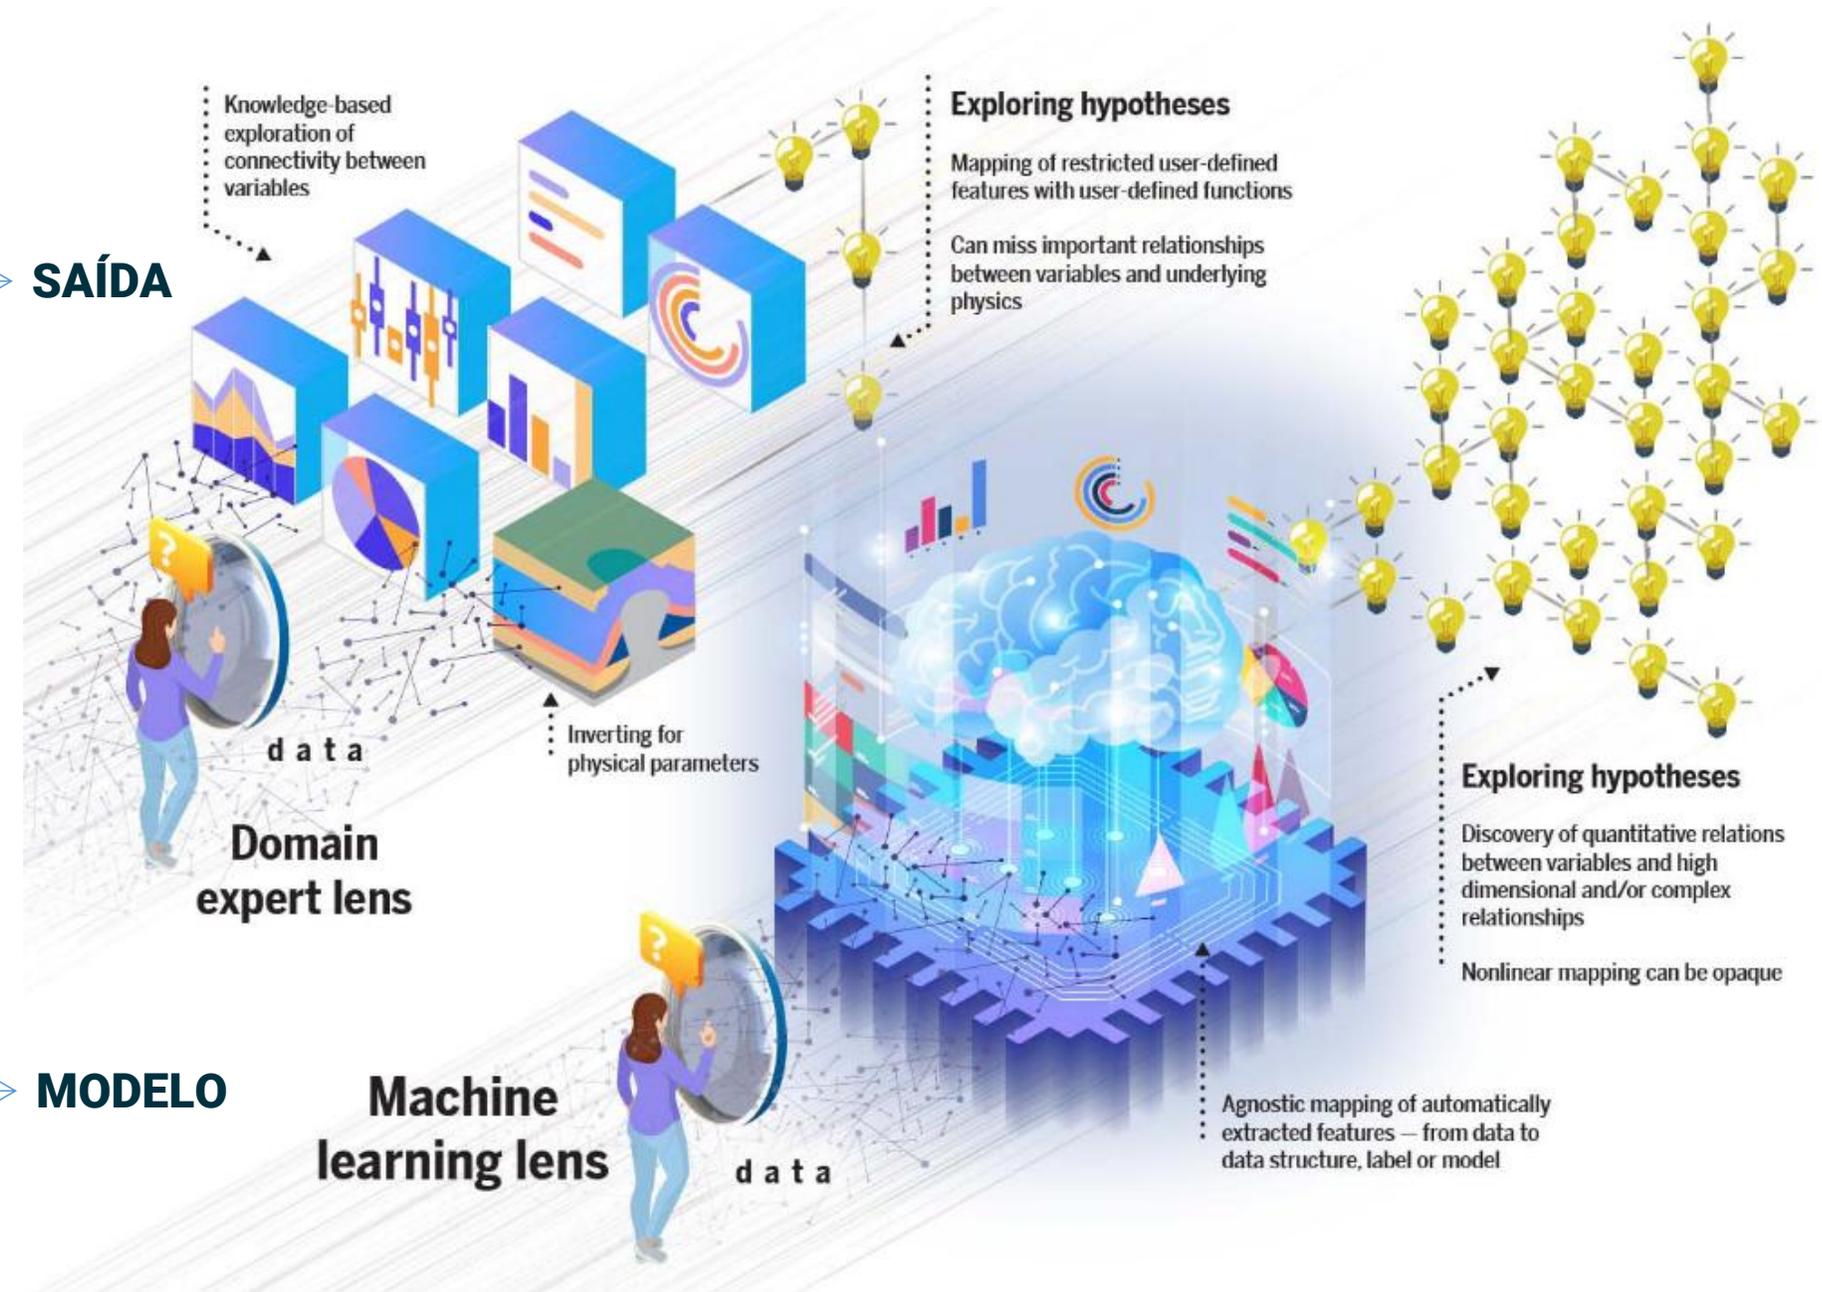
Ensinar o computador a reconhecer padrões através de exemplos, ao invés de programar regras específicas

**DADOS
SAÍDA**

Aprendizado
de máquina

MODELO

**Machine
learning lens**

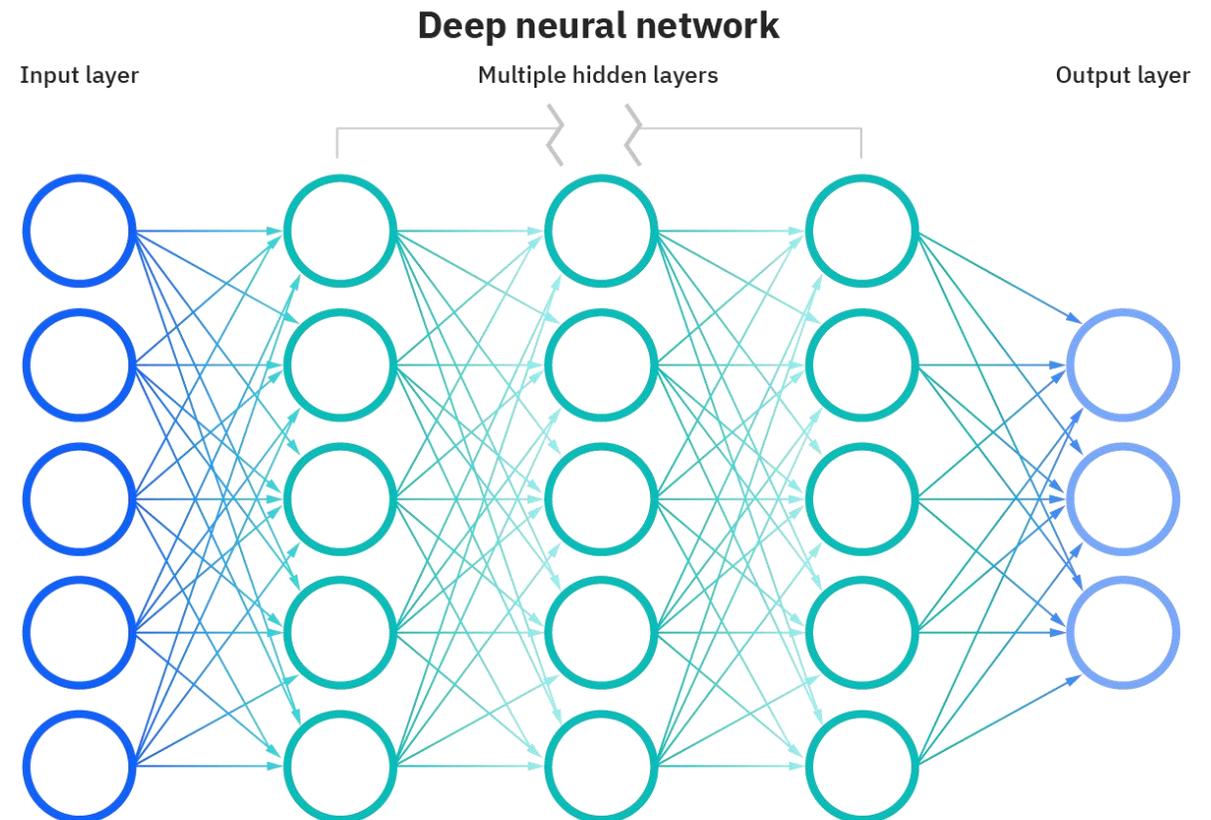
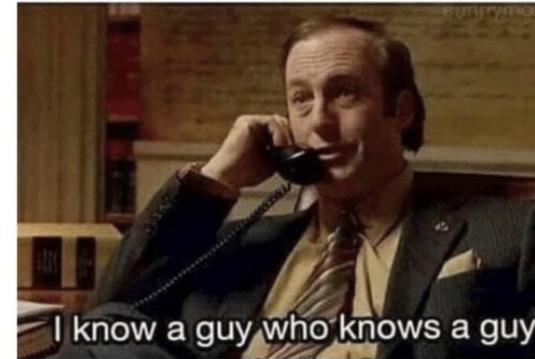


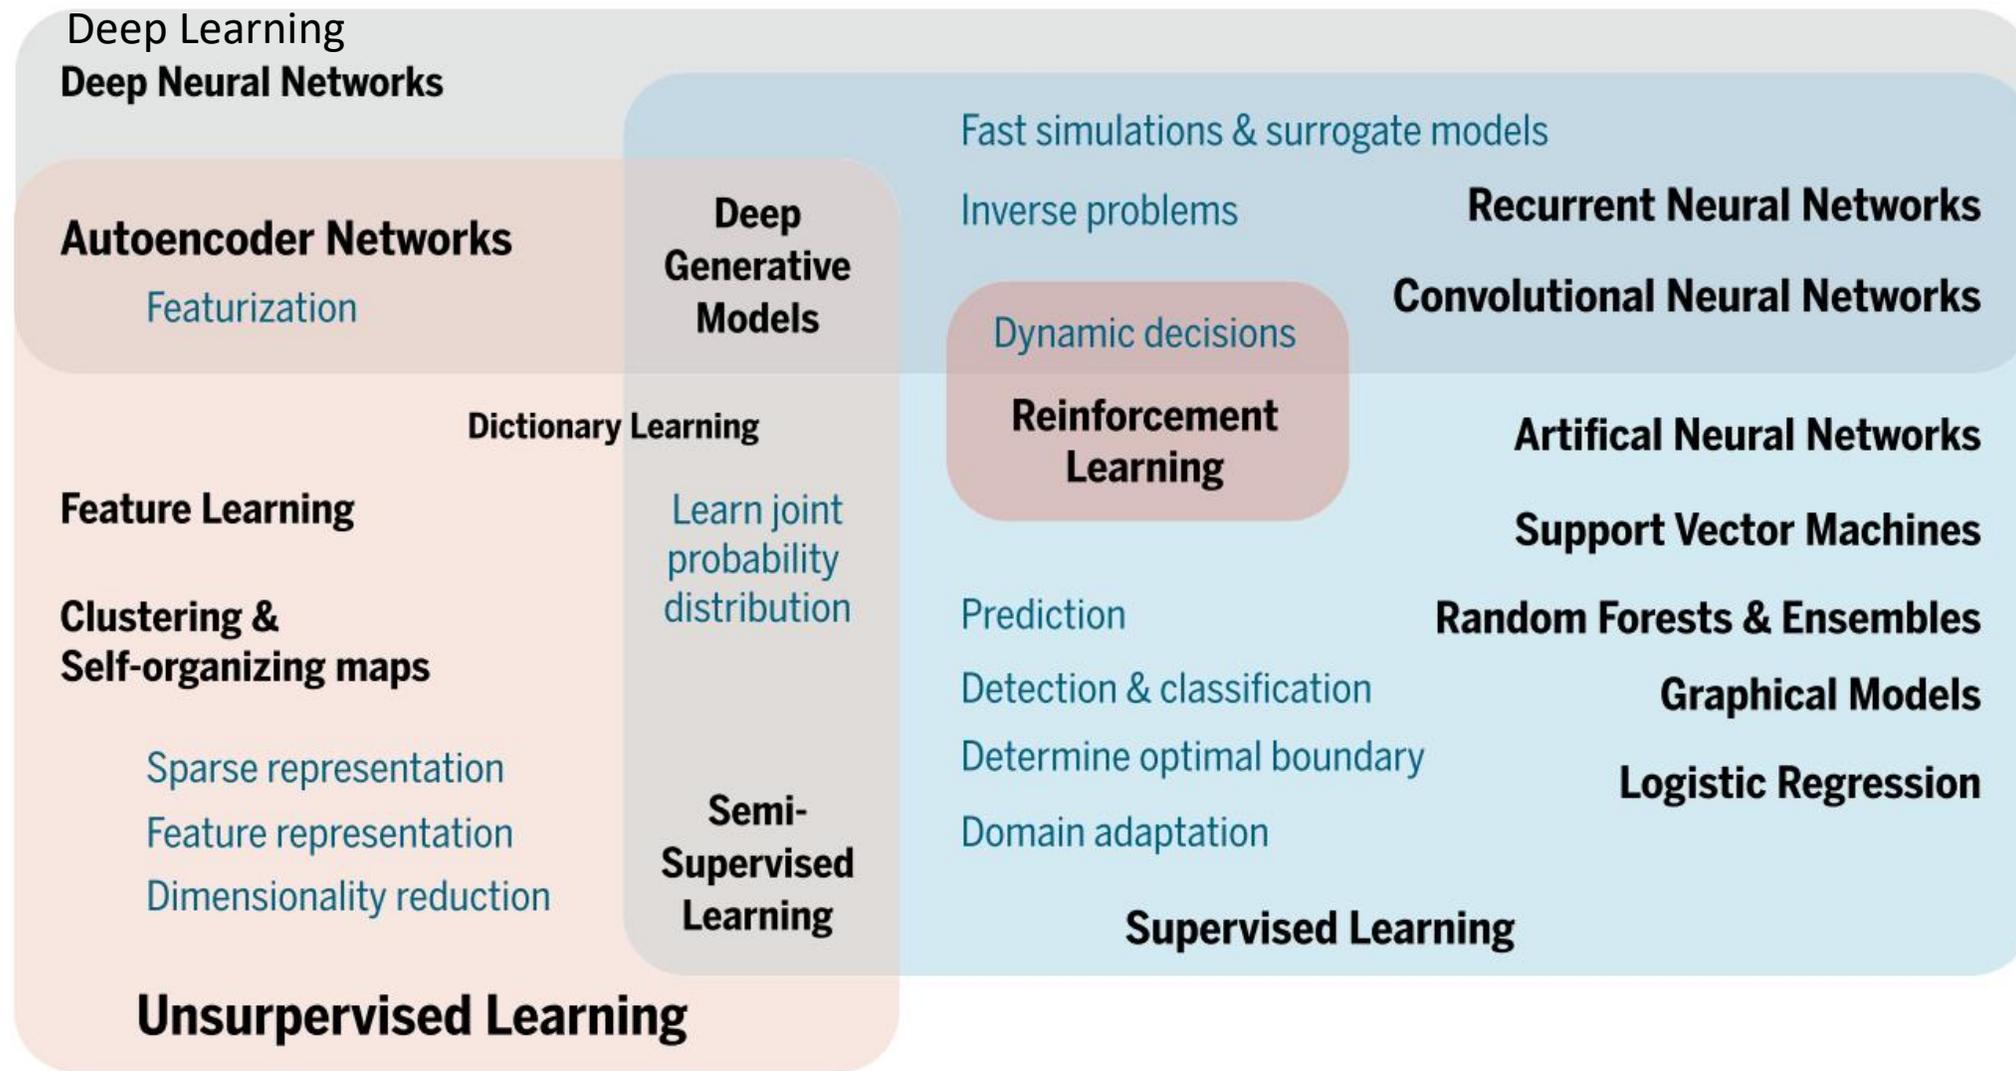
Deep Learning

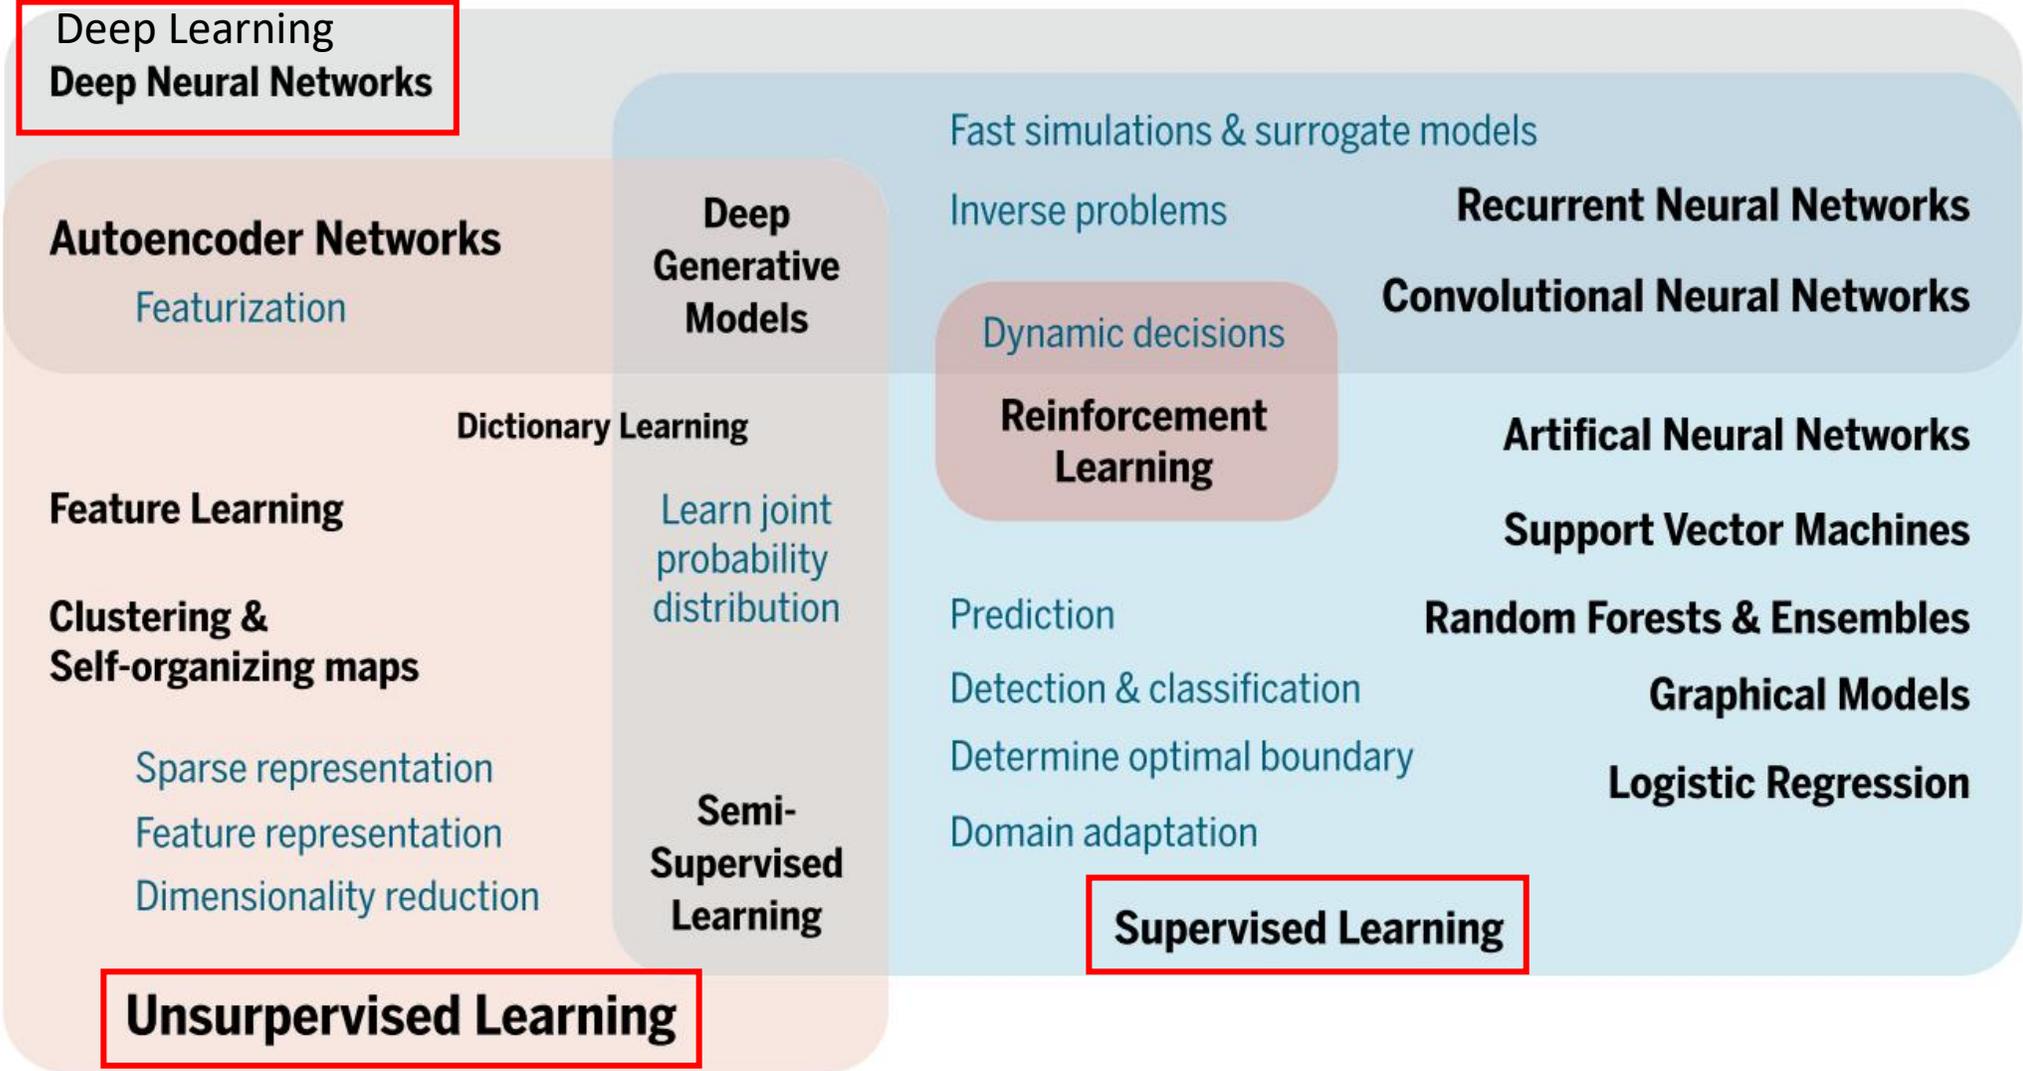
- 2010
- Uma técnica para implementar ML
- Redes Neurais Profundas (DNNs)
- Estruturas de código em camadas que imitam vagamente o cérebro humano
- Habilidade em extrair automaticamente representações de alto nível de dados complexos

How Neural Networks work?

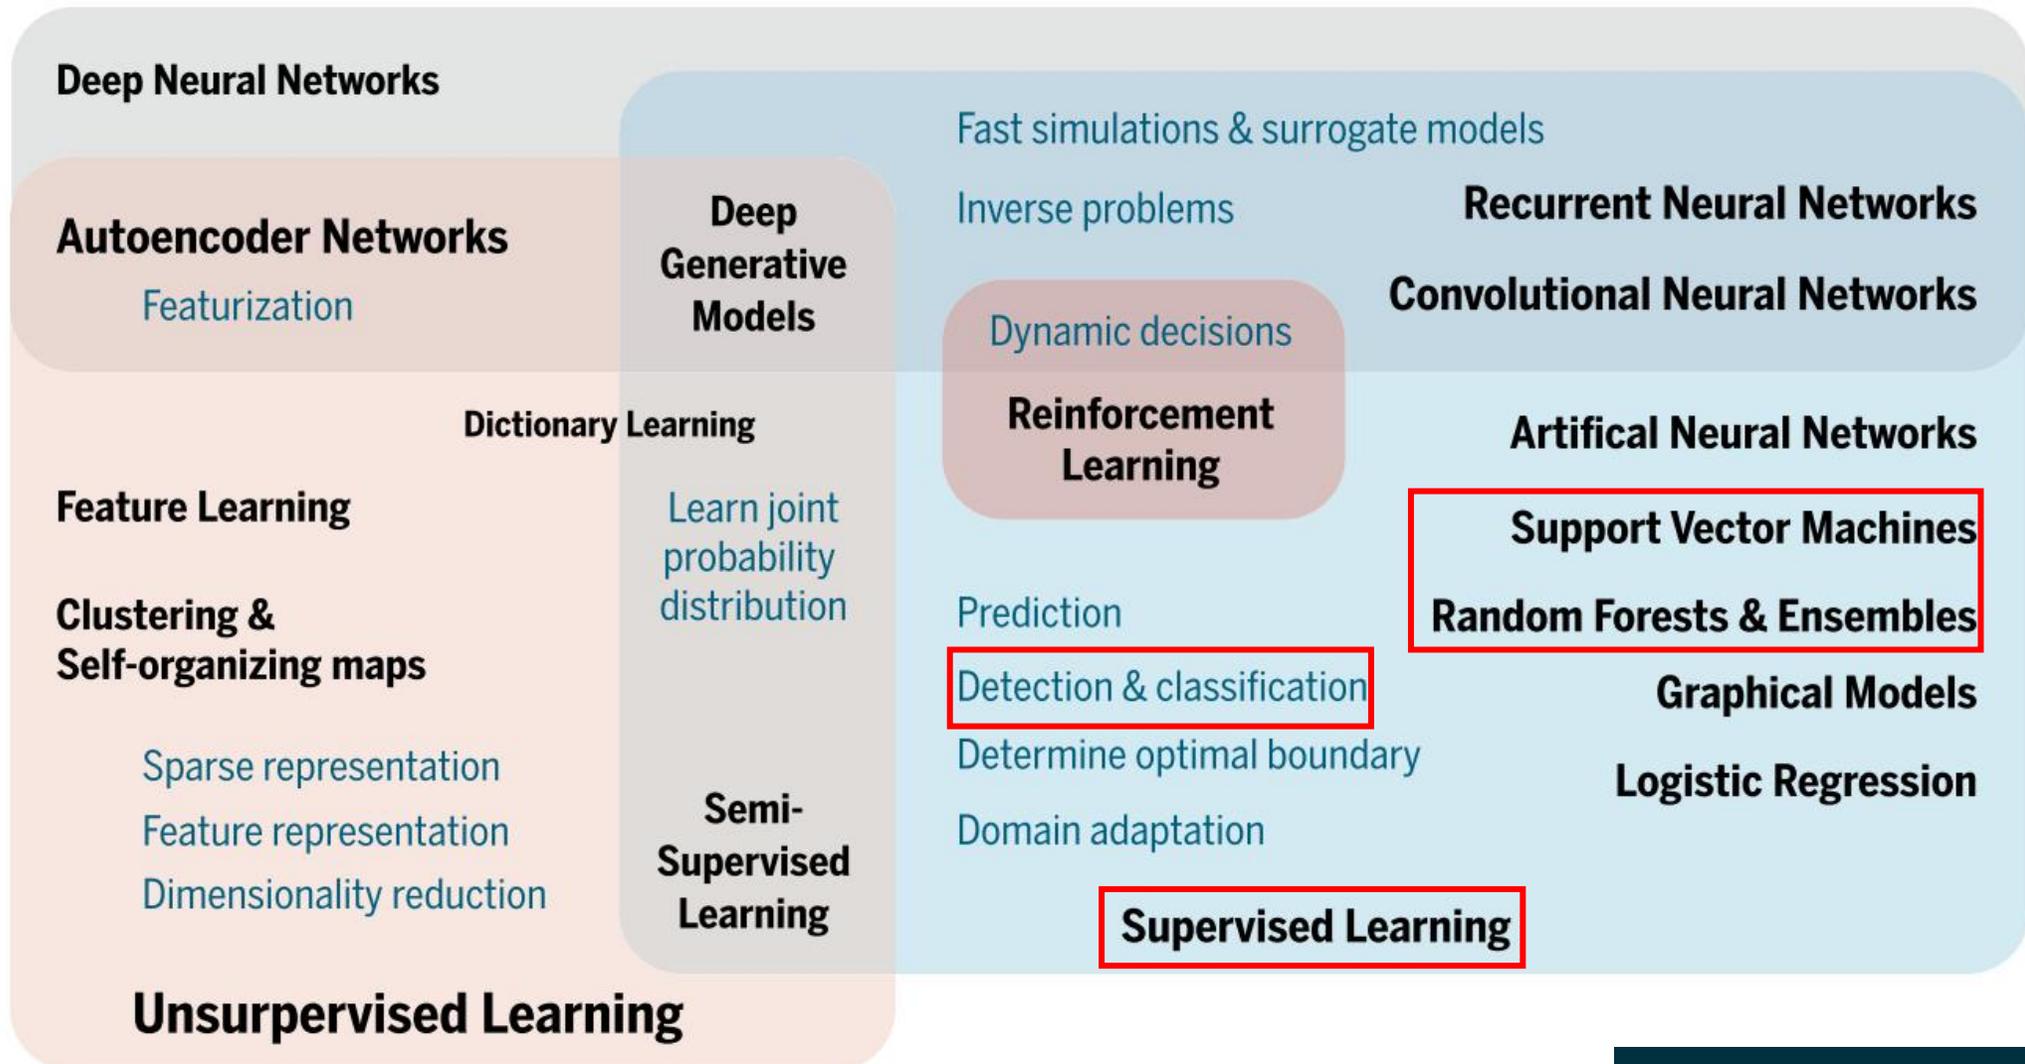
Neurons:

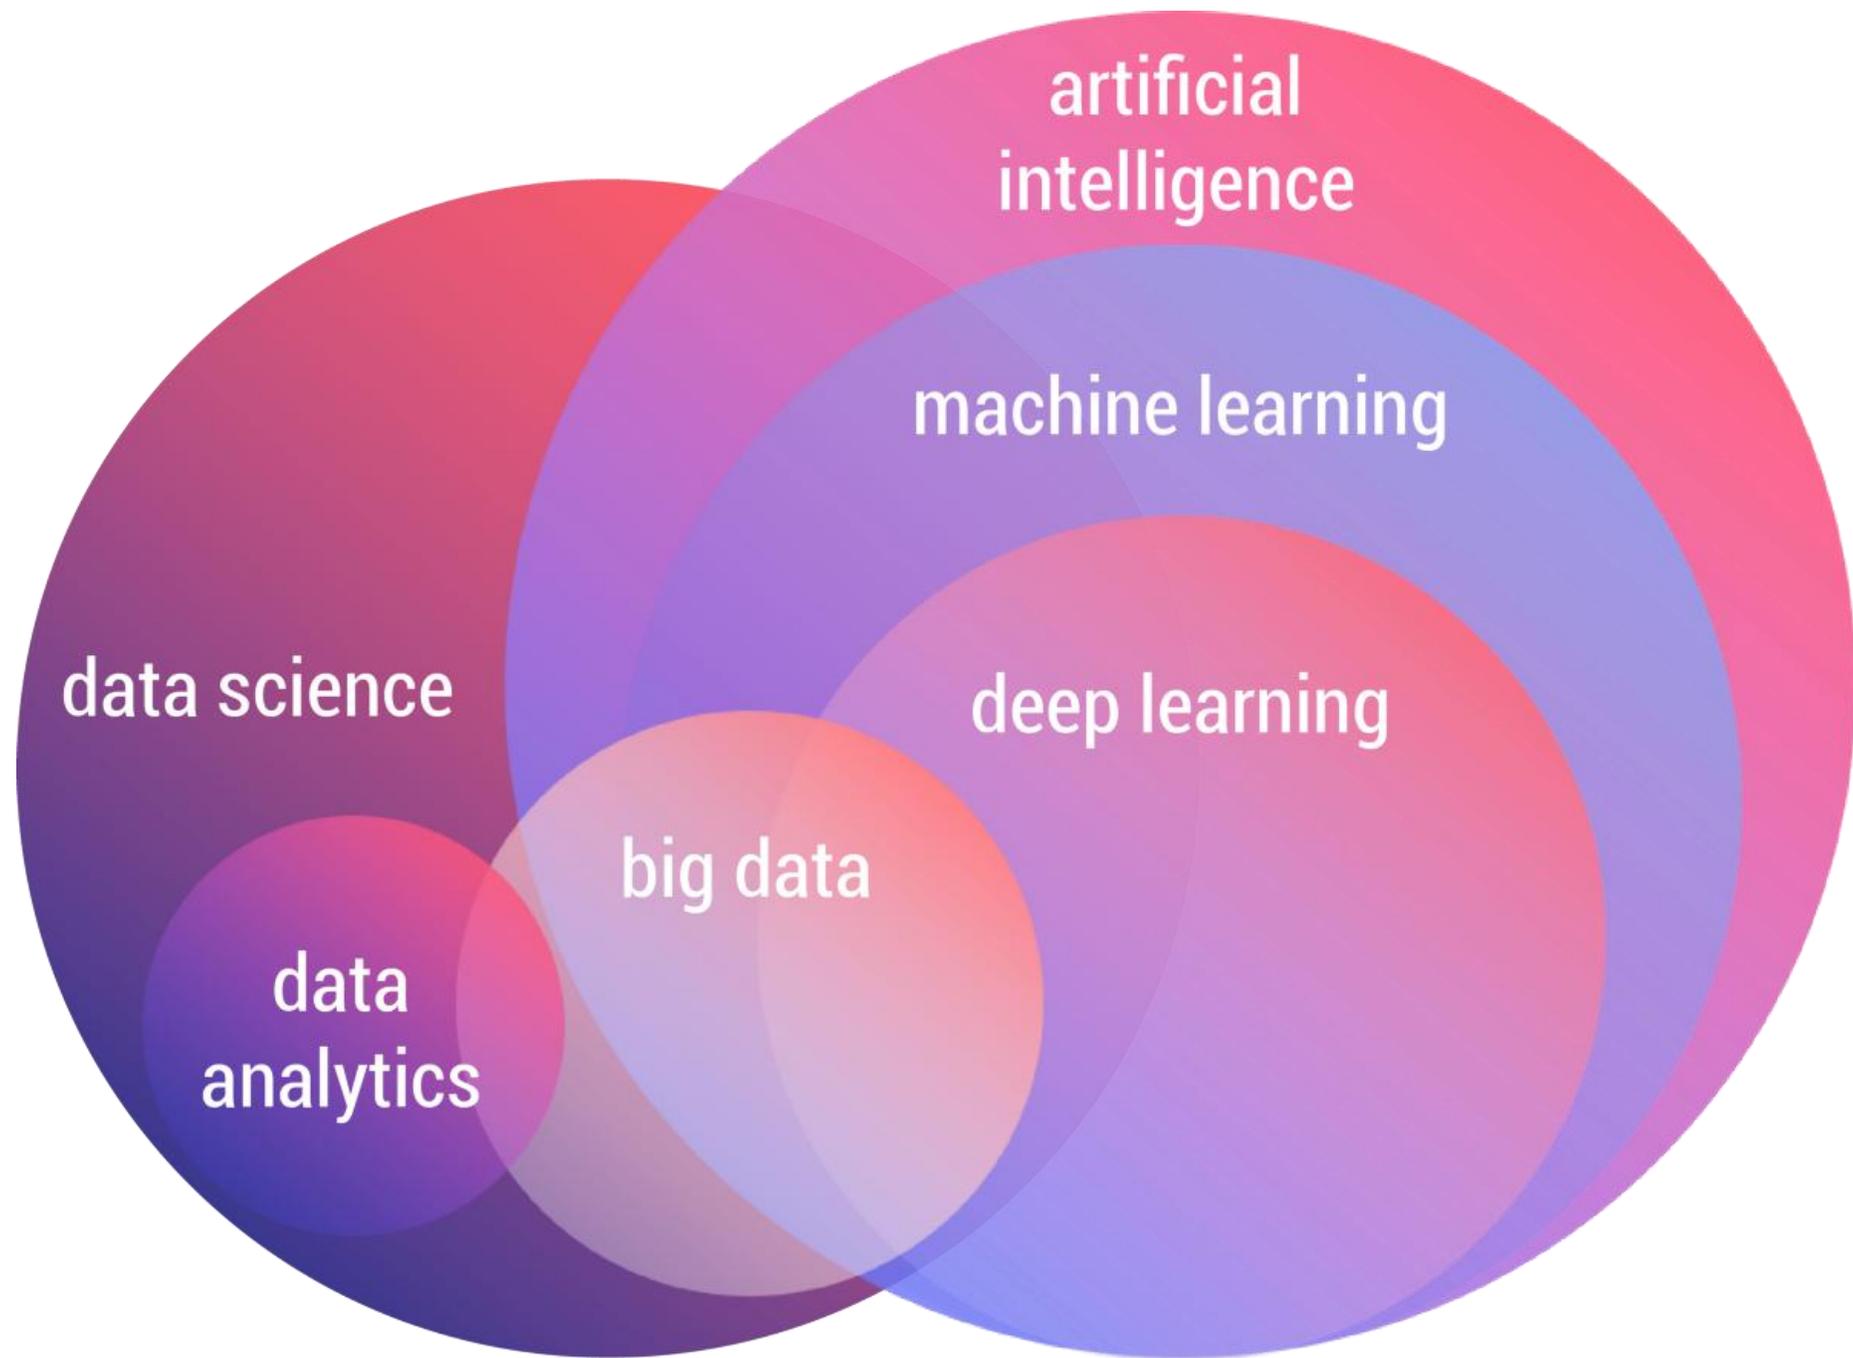






Exercício de hoje





Os desafios

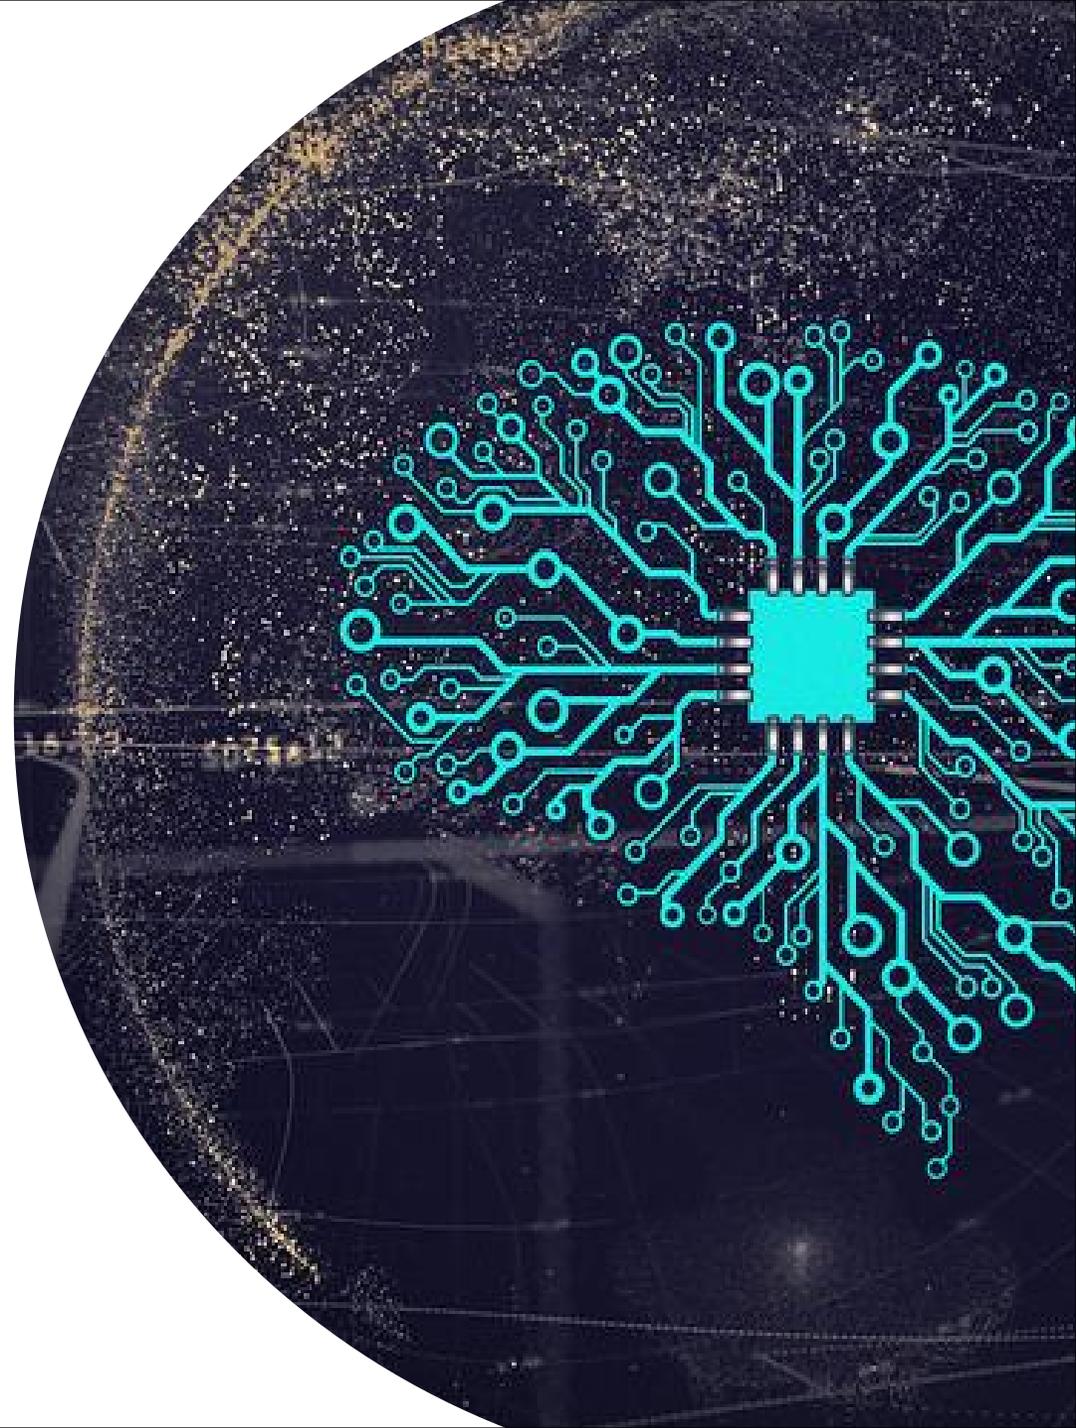
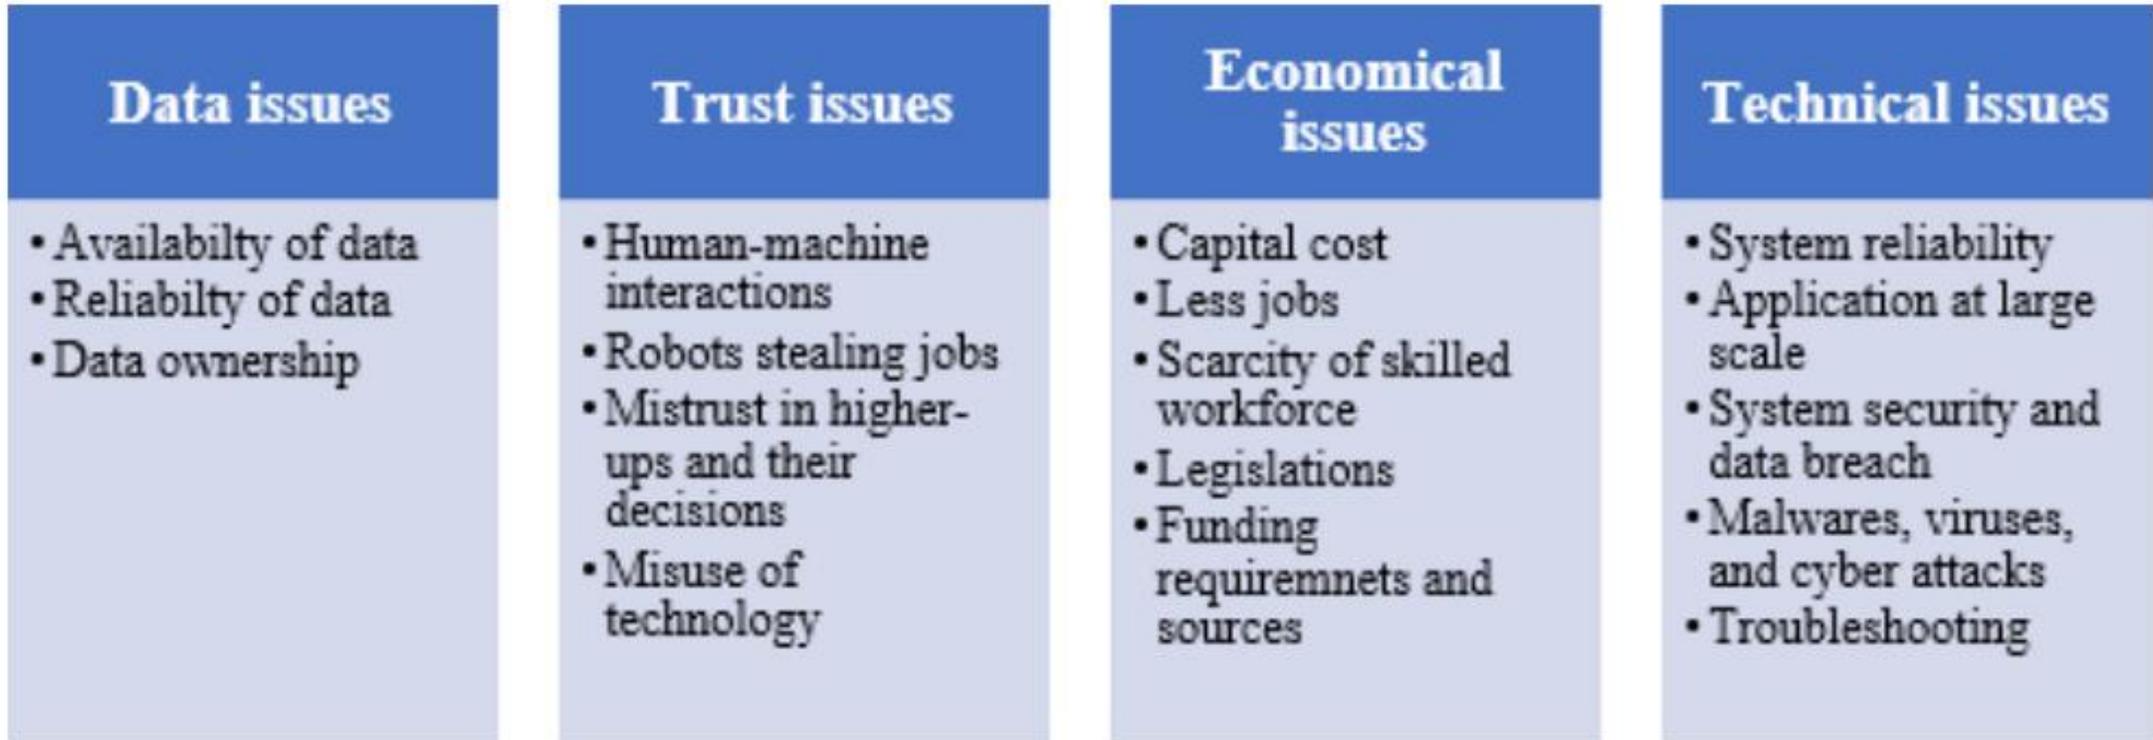


Figure 4. Some of the major challenges in implementing AI and machine learning in mining



20 entrevistas

Os desafios dos dados geológicos

NATUREZA

- Dados em sequência - espacial / temporal
- Multivariados
- Não-lineares
- Não-estacionários
- Múltiplas escalas espaciais e temporais
- Interconexões complexas
- Eventos raros

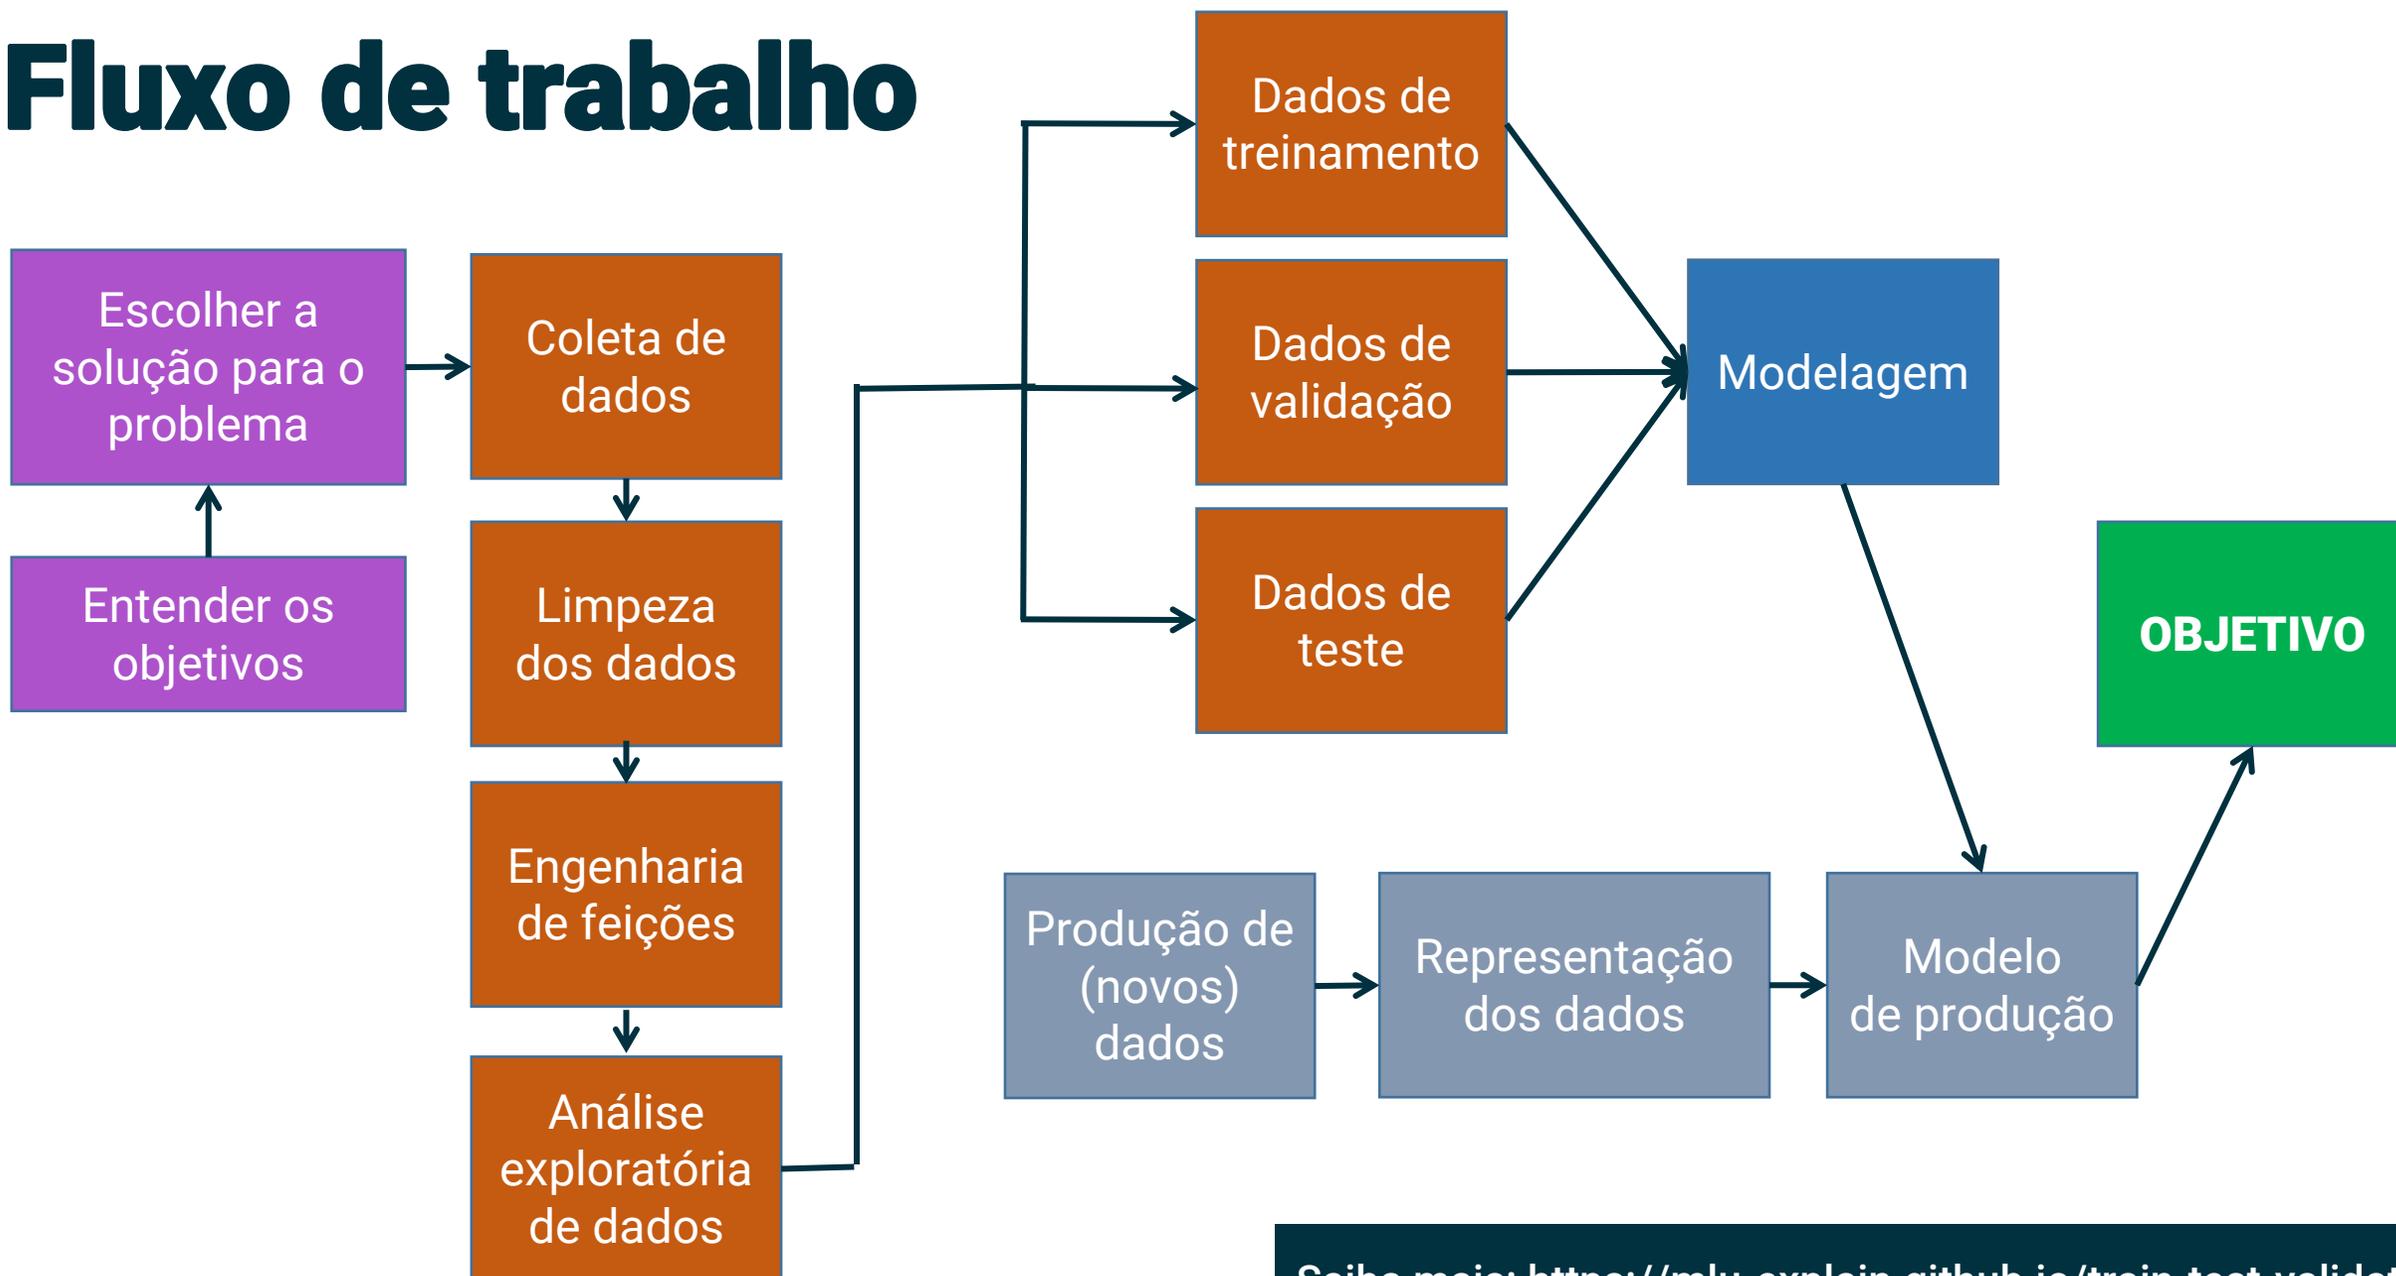
COLETA

- Várias escalas espaciais e temporais
- Várias fontes de erros e ruídos
- Incompletos
- Incertos

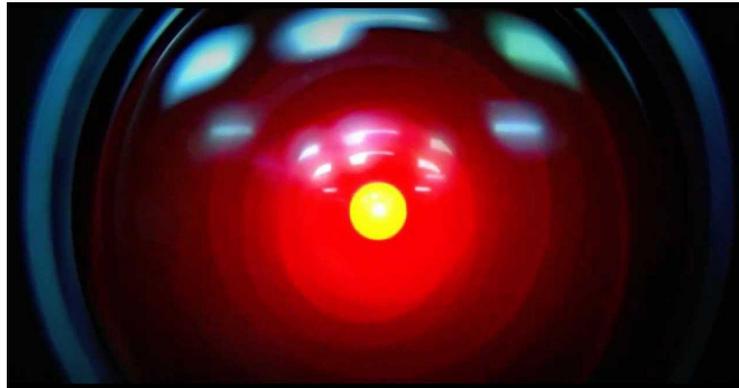
ARMAZENAMENTO

- Poucos registros adequados
- Falta de padrão ouro de referência

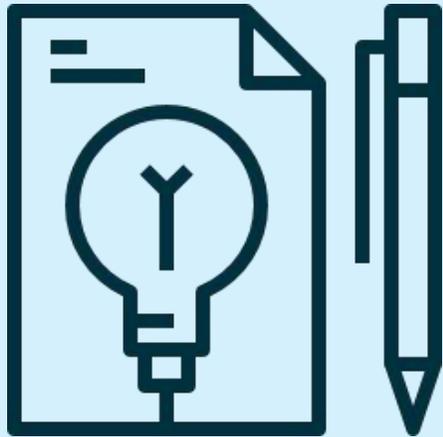
Fluxo de trabalho



Fluxo de trabalho



**IA não sabe os problemas que
pode resolver!**



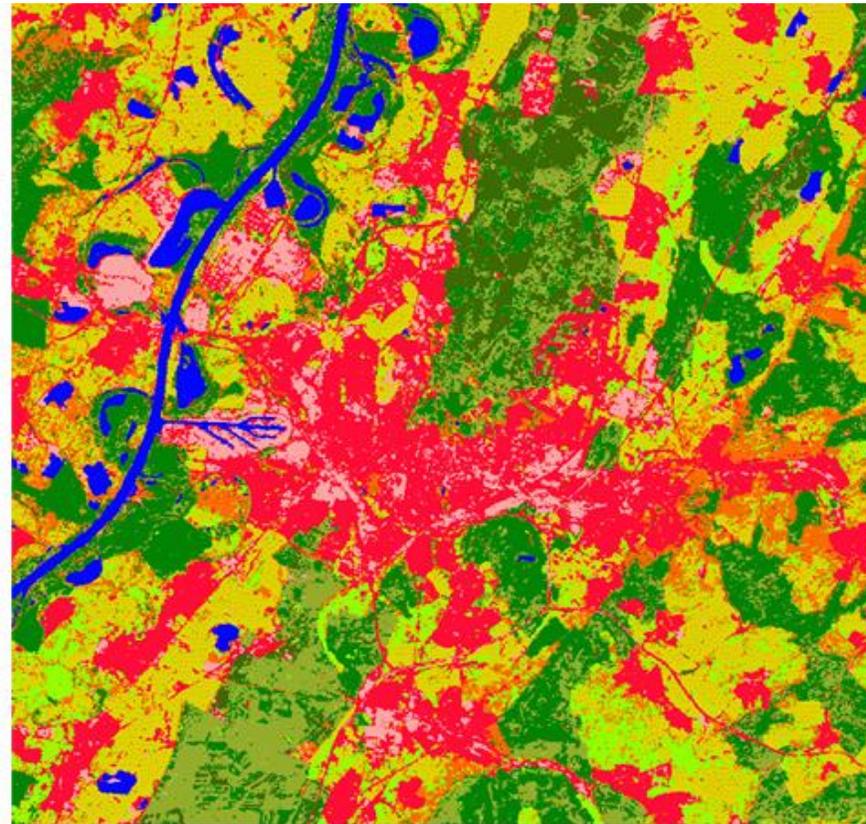
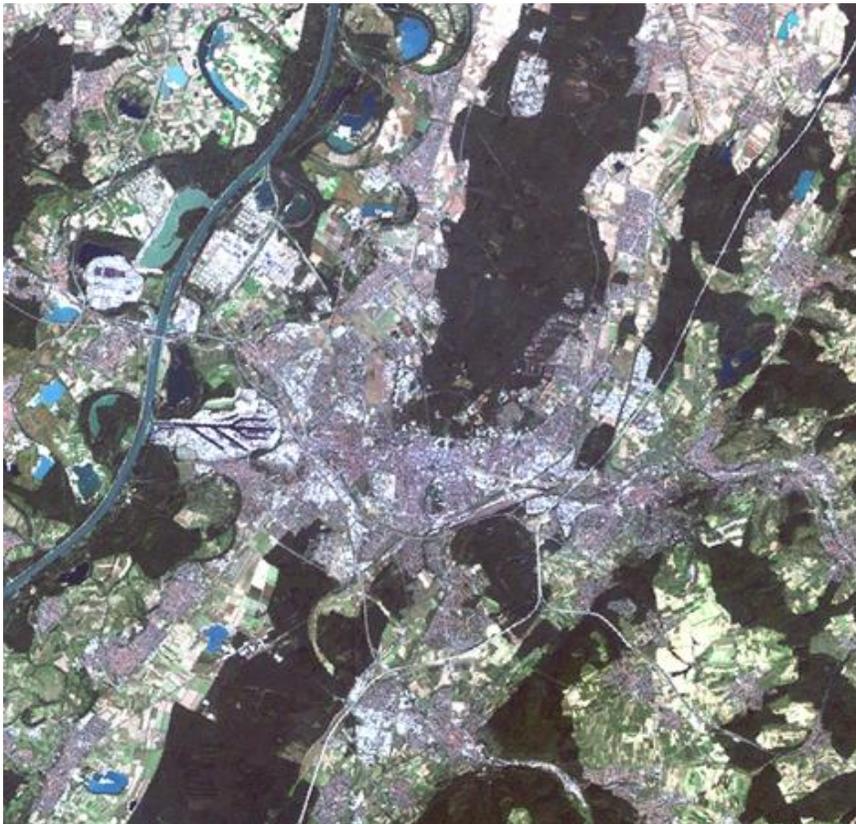
Classificação

Classification

Os dados pertencem a classes, e o objetivo é encontrar padrões que permitam determinar se um dado pertence a uma ou outra(s) classe(s).

Classificação

- Predição de dados categóricos
- O resultado da classificação digital de imagens de Sensoriamento Remoto é um mapa temático



Técnicas e métodos

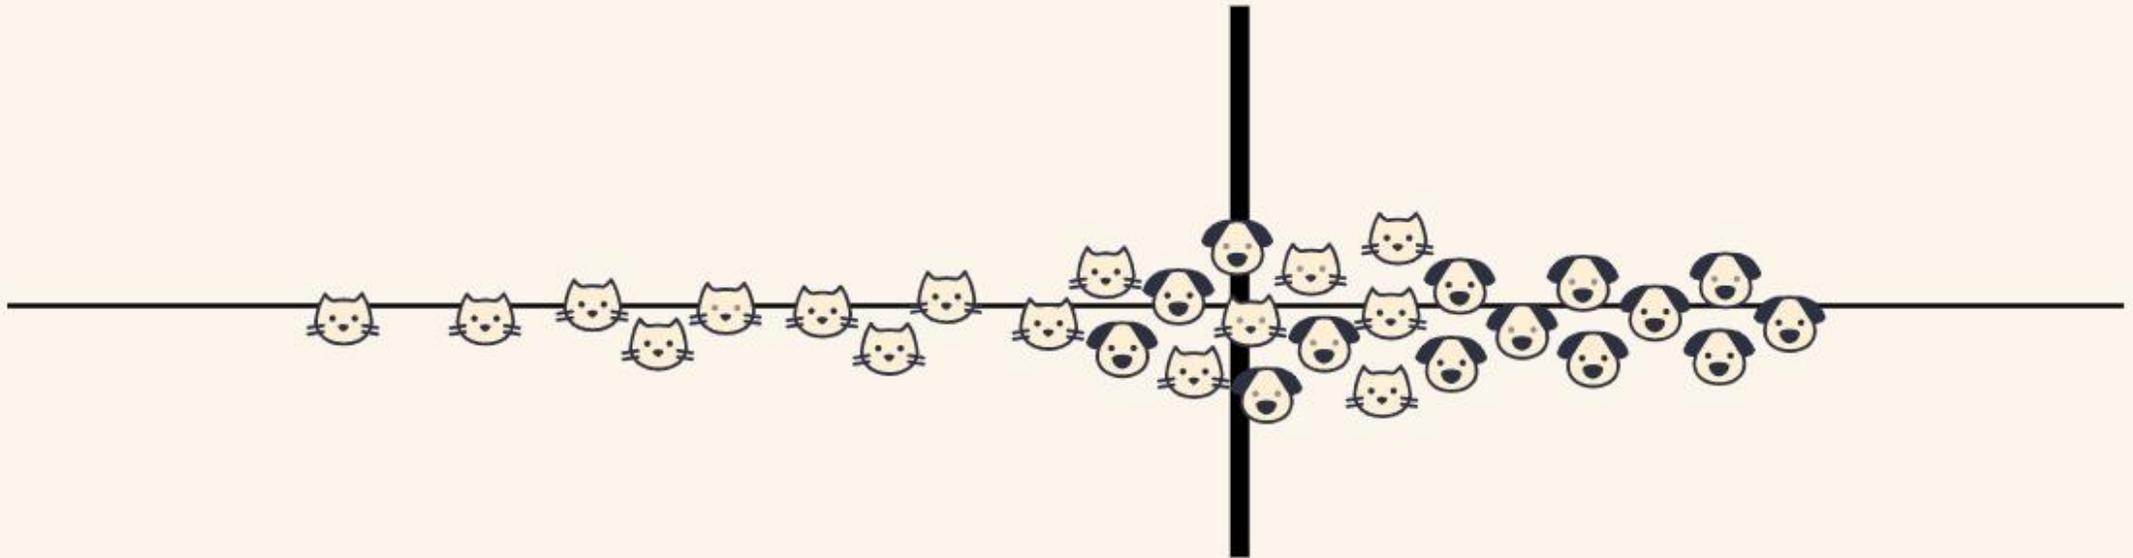
Model Features:

None

Weight

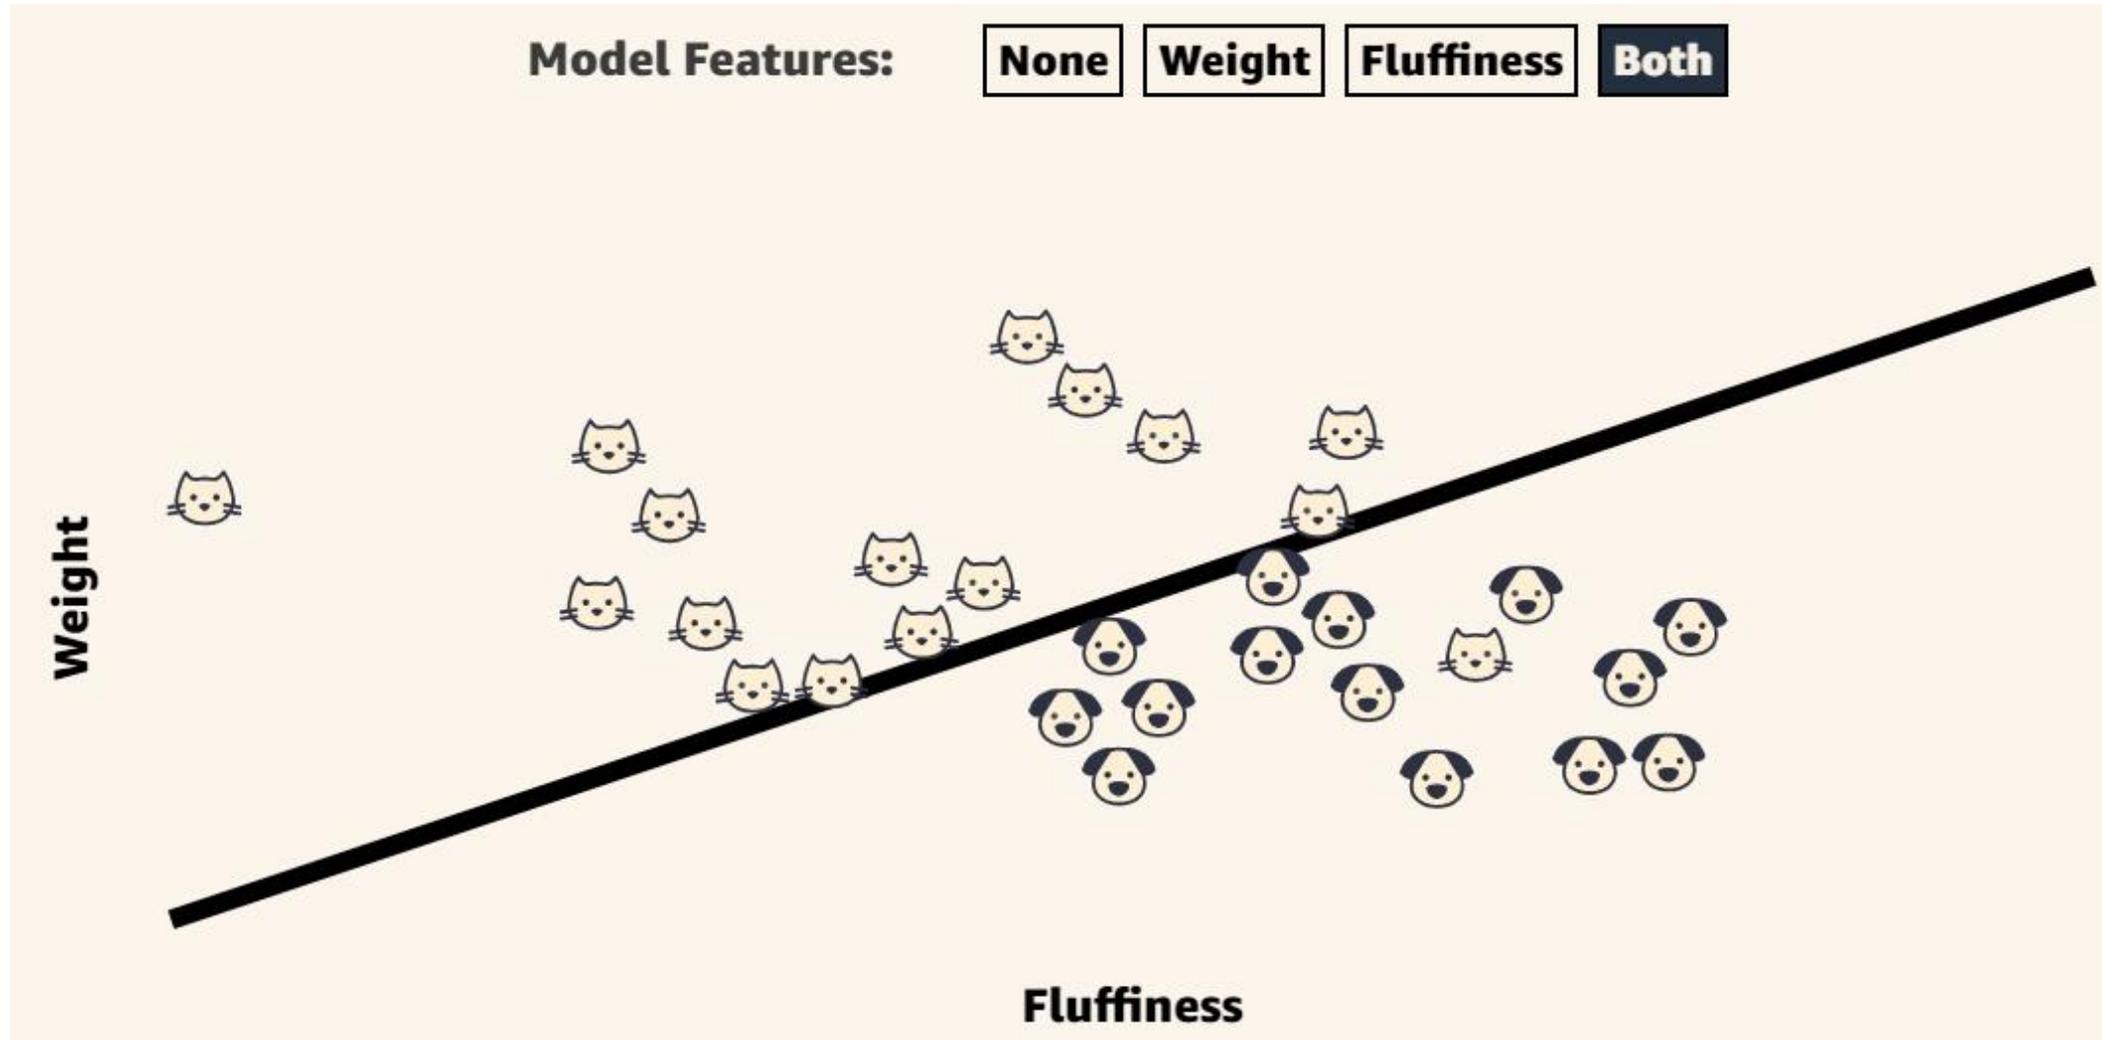
Fluffiness

Both



Weight

Técnicas e métodos



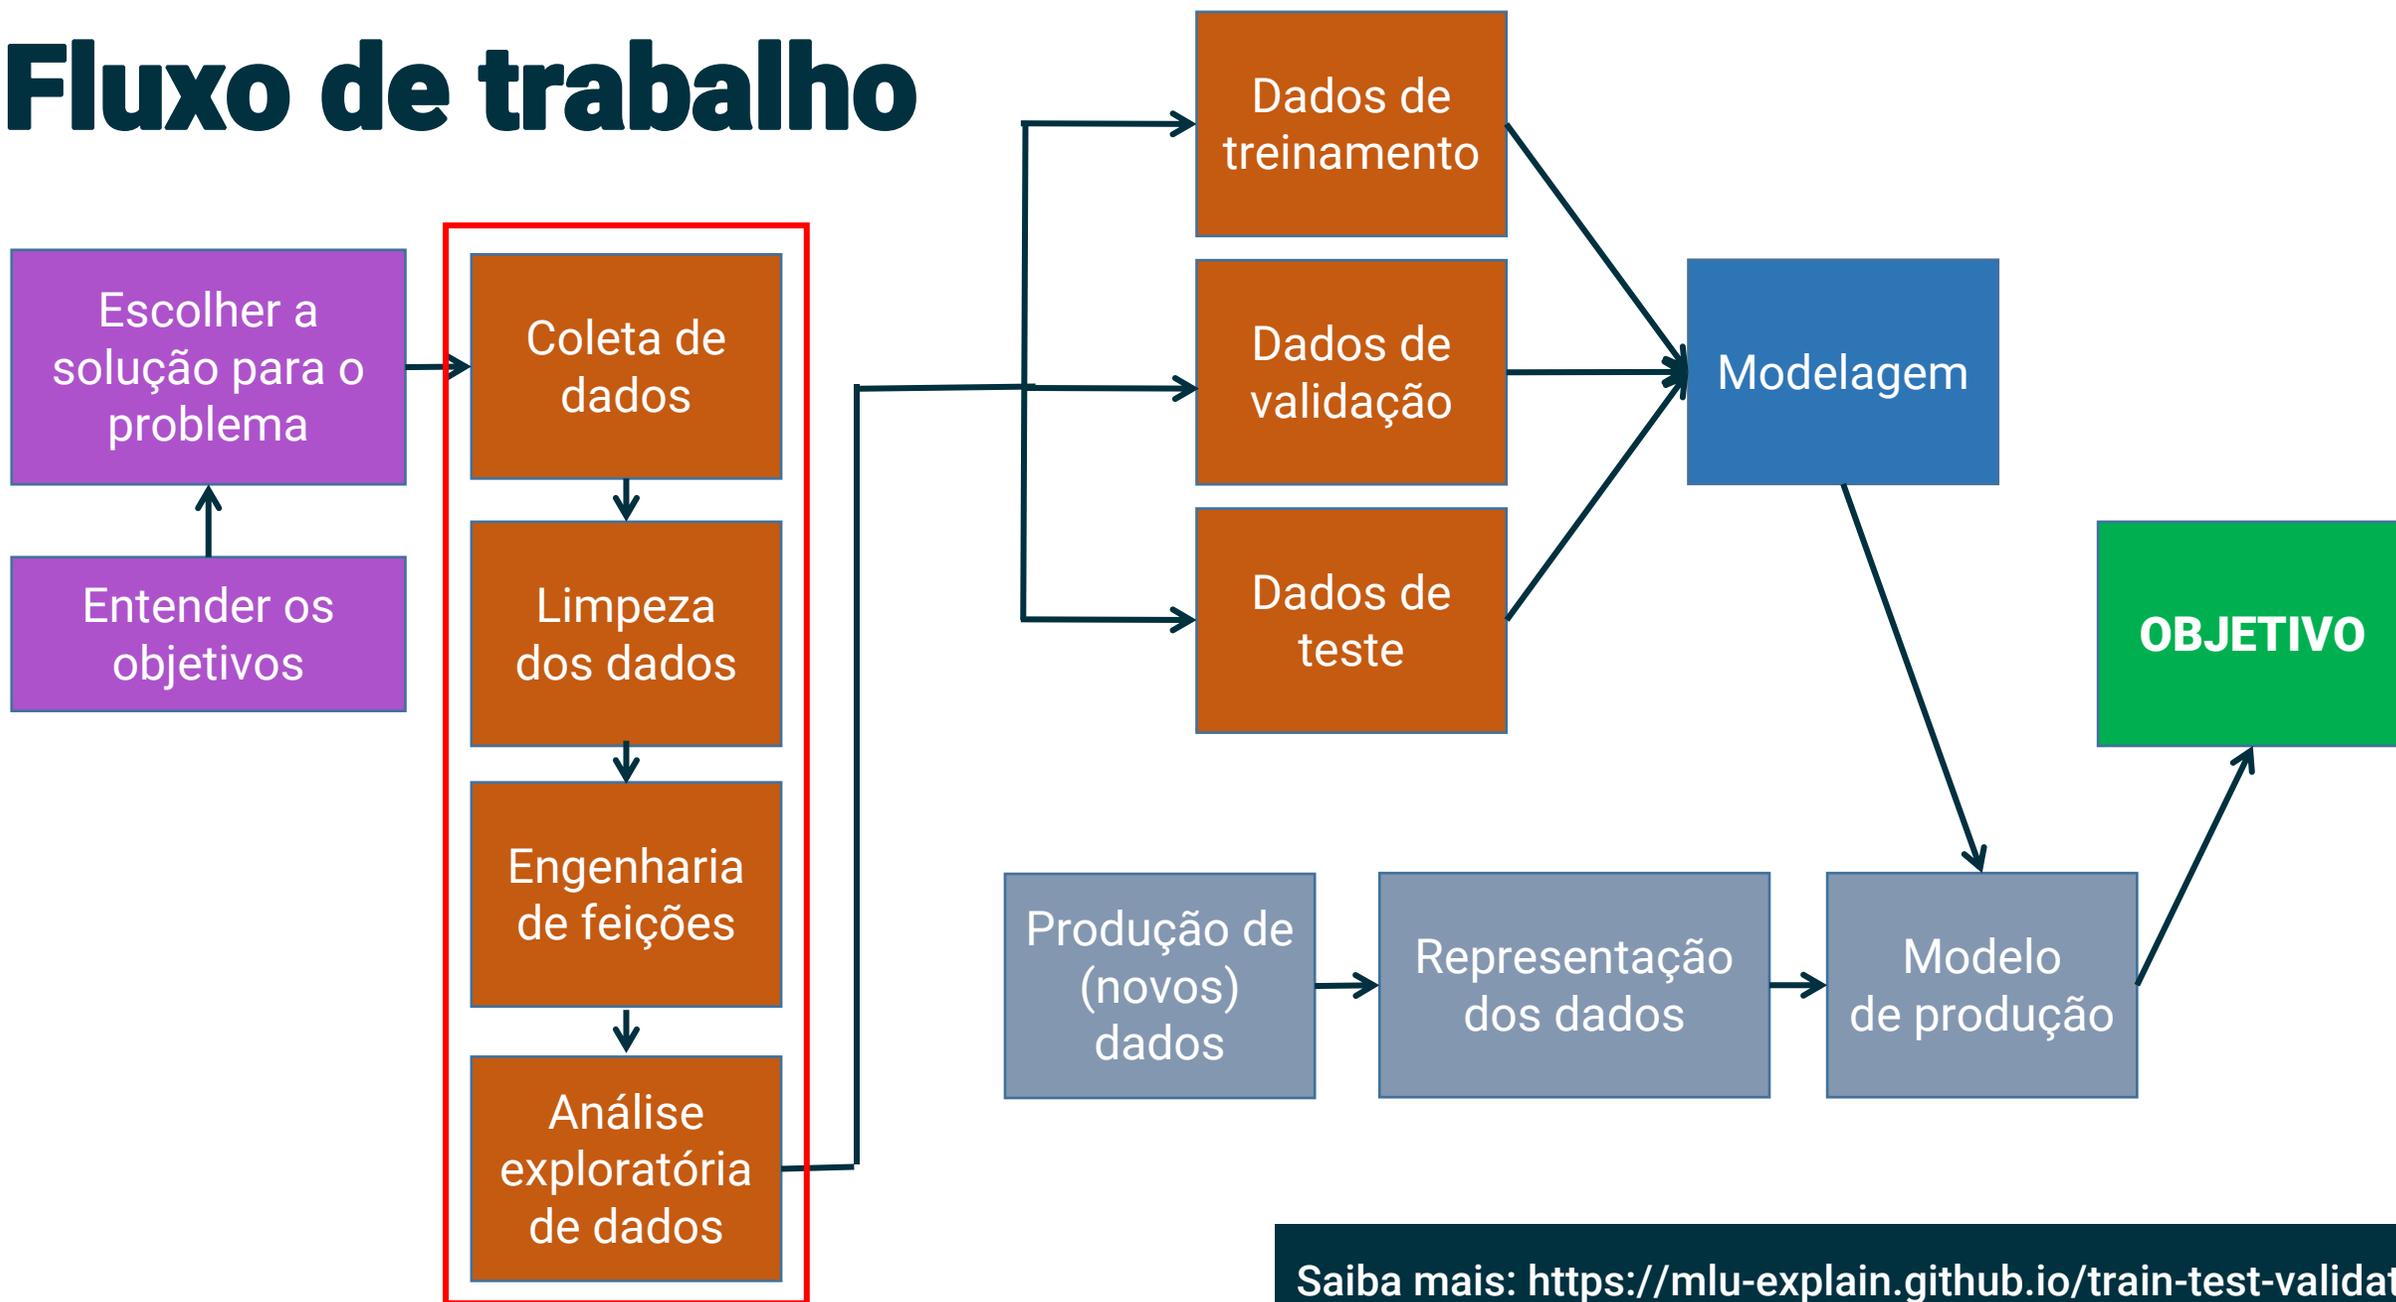
Técnicas e métodos

- Dados 0D:
 - Sem dimensões espaciais ou temporais
 - Ex.: geoquímicos ou petrofísicos
 - Redes Neurais Artificiais (ANN) e/ou variações
- Dados 1D:
 - Uma dimensão espacial ou temporal
 - Ex.: log de furo de sondagem; sísmica (série temporal)
 - ANN e variantes; ANN, Support Vector Machines (SVM), Self-organizing maps
- Dados 2D:
 - Duas dimensões espaciais
 - Ex.: processamento de imagens
 - ANN, SVM

Técnicas e métodos

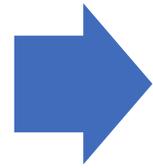
Classification	Minimum Distance	AVIRIS, WorldView-3	Minerals	General exploration	Kruse and Perry (2013)
		Hyperion, ASTER, Landsat 8	Lithological units	General exploration	Pan et al. (2019)
		ASTER	Lithological units	Cr	Othman and Gloaguen (2014)
	Support Vector Machines	ASTER	Alteration types, minerals	Au	Xu et al. (2019)
		Hyperion	Alteration types, minerals	Au	Wang and Zheng (2010)
		Sentinel-2	Lithological units, alteration types, minerals	Cu, Au	Abdolmaleki et al. (2020)
		Sentinel-2	Lithological units	Li	Cardoso-Fernandes et al. (2020b)
		UAV	Lithological units, alteration types	General exploration	Lorenz et al. (2021)
		Landsat 5	Minerals	Au	Rigol-Sanchez et al. (2003)
	Simple Neural Networks	Hyperion, Landat 5	Lithological units	General exploration	Leverington (2010)
		Landsat 7	Alteration types, minerals	Mo, Pb, Zn, Ag	Wang et al. (2010)
		Landsat 7	Structures	General exploration	Borisova et al. (2014)
	Random Forest	Sentinel-2	Lithological units	Li	Cardoso-Fernandes et al. (2019)
		Landsat 5	Lithological units	Au	Kuhn et al. (2018)
		Landsat 7	Lithological units	General exploration	Cracknell and Reading (2014)
ASTER, Sentinel-2		Lithological units	Rare metals	Wang et al. (2020b)	
Sentinel-2, PALSAR		Lithological units	General exploration	Bachri et al. (2020)	
		TOPSAR	Lithological units	General exploration	Radford et al. (2018)

Fluxo de trabalho



Garbage in, garbage out

Dados ruins

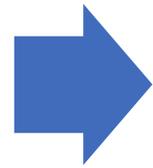


Modelo perfeito



Resultados ruins

Dados perfeitos



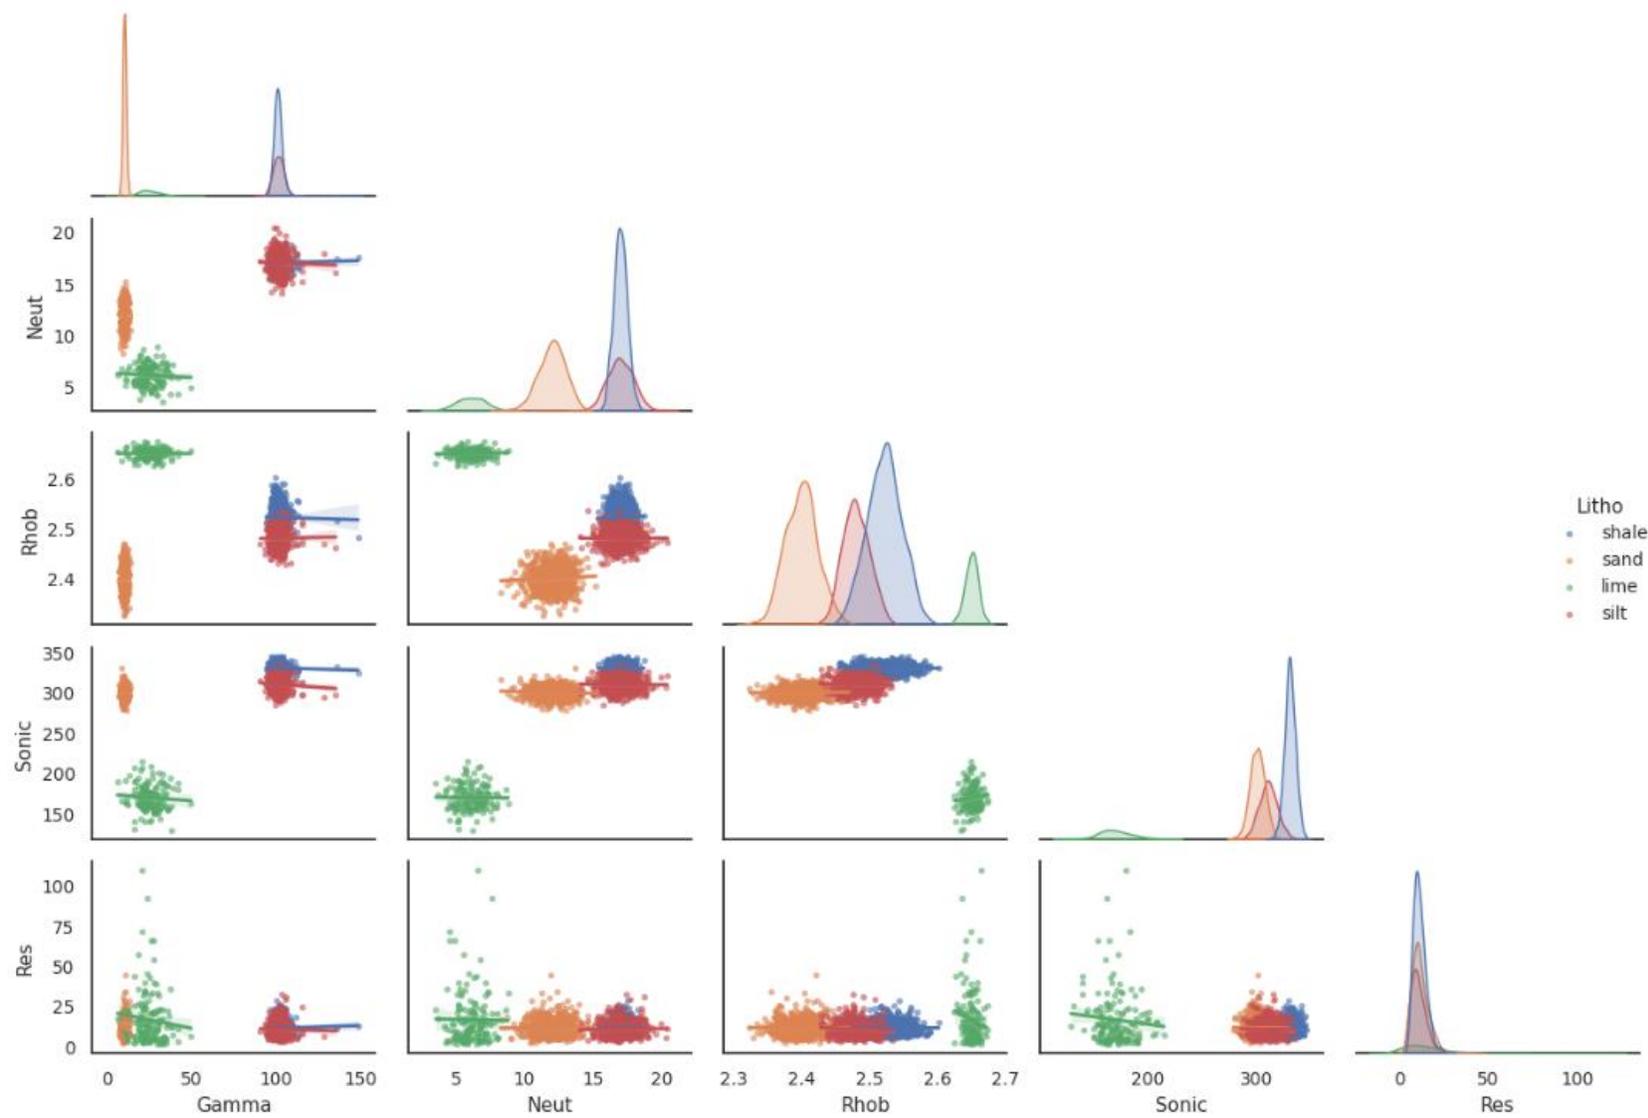
Modelo ruim



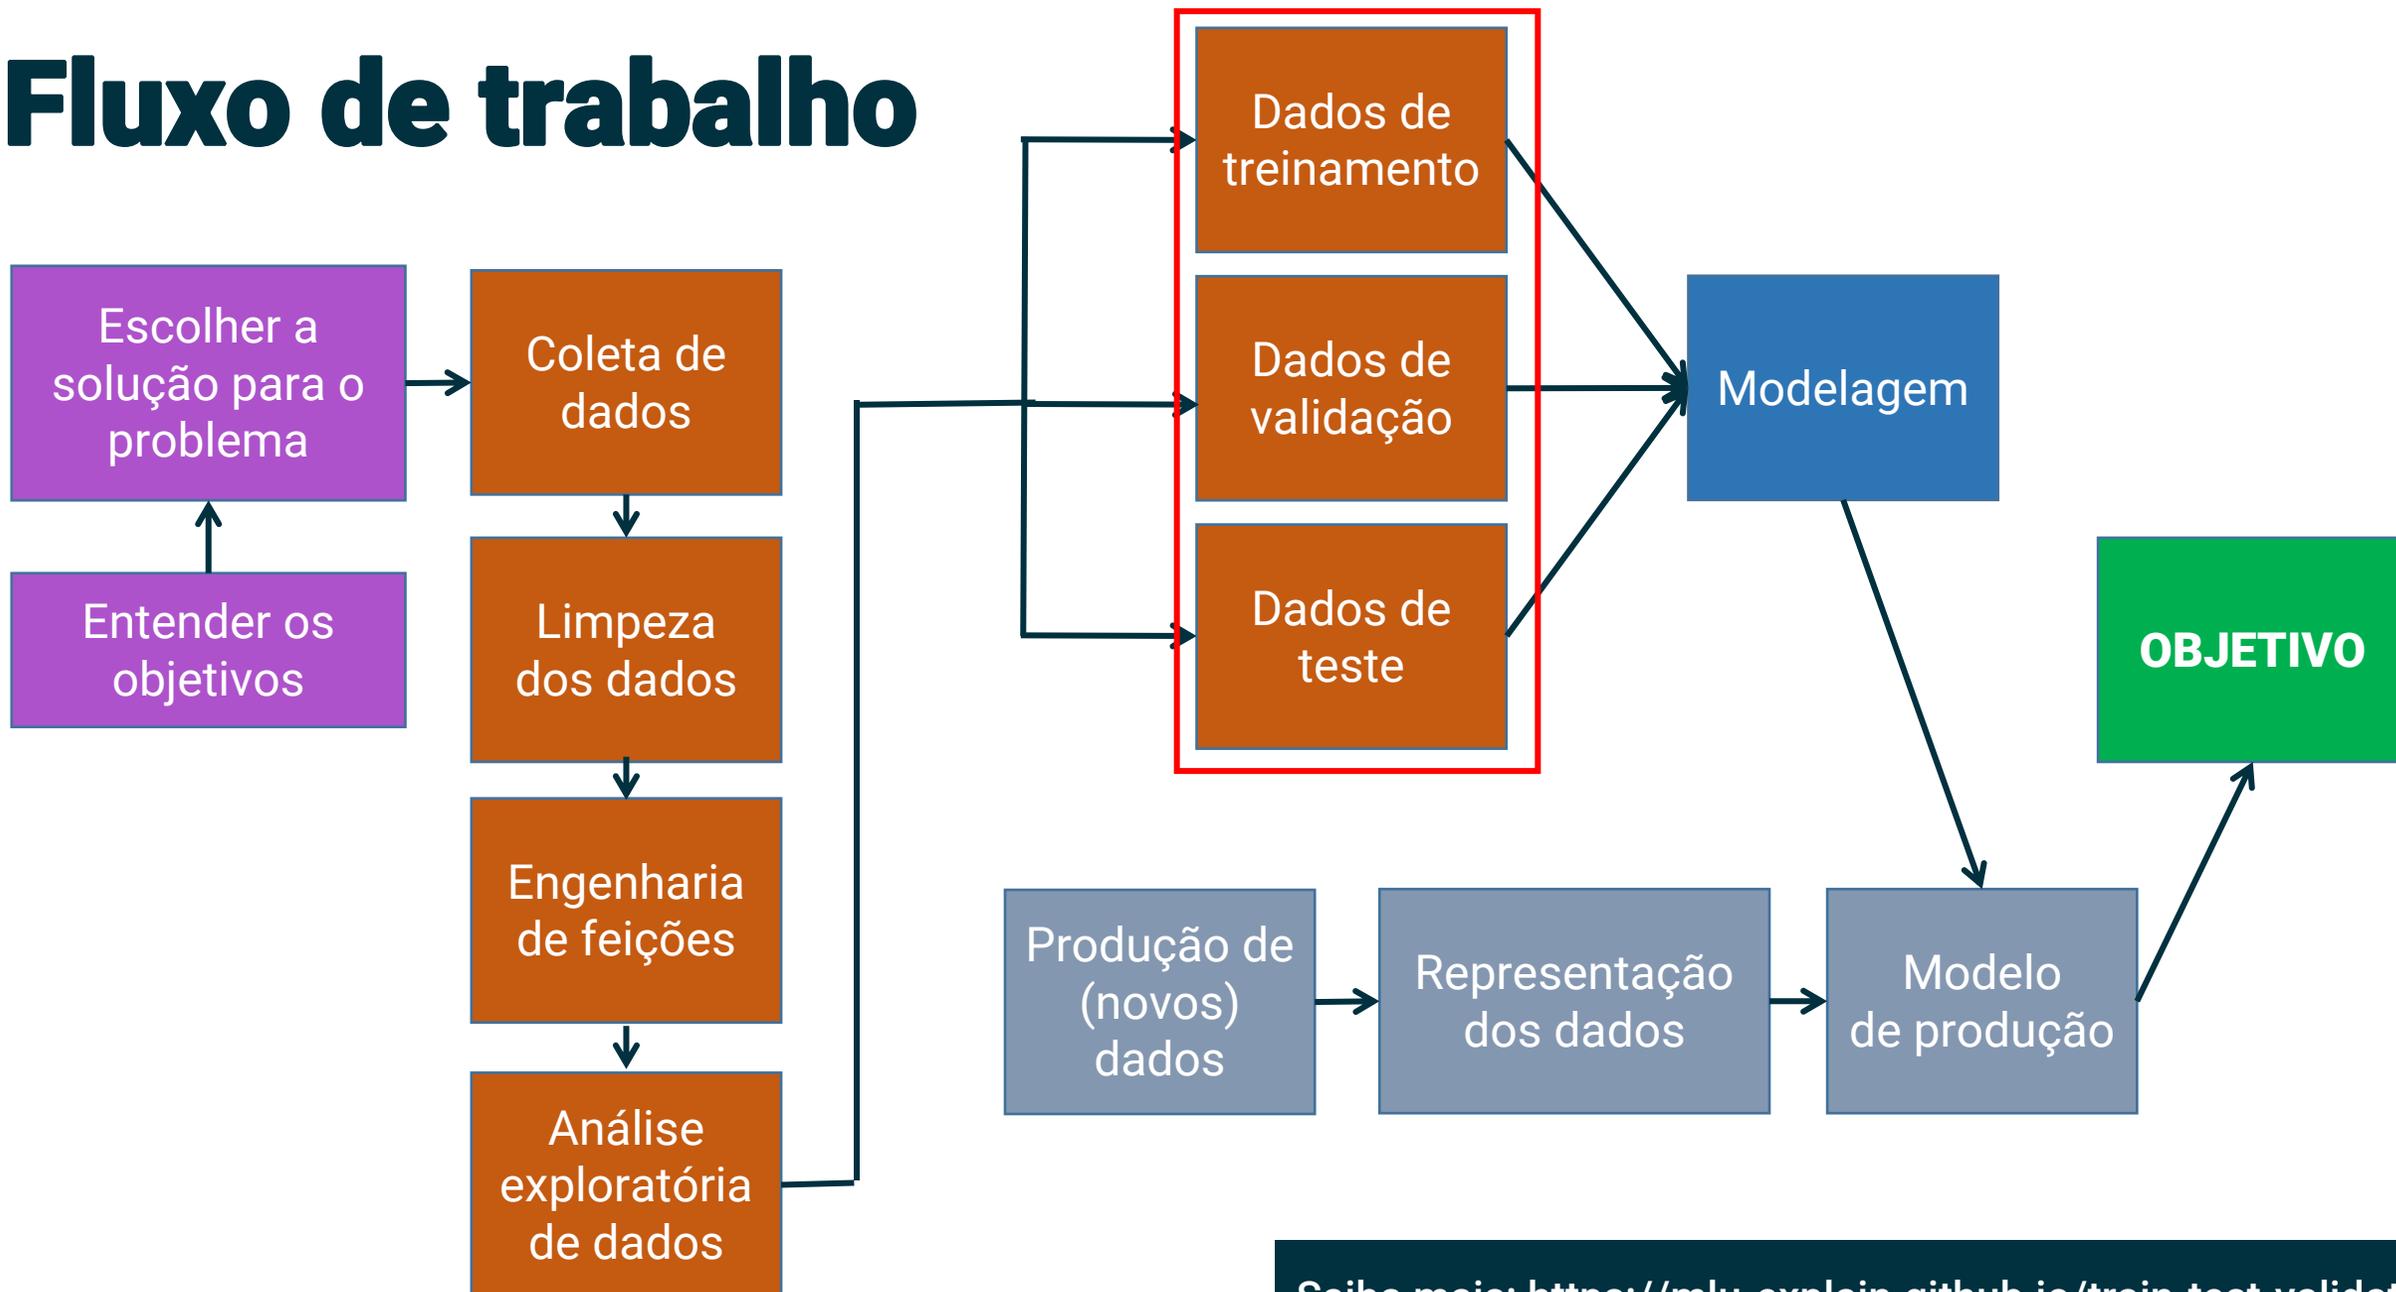
Resultados ruins

	Litho	Gamma	Neut	Rhob	Sonic	Res
0	shale	103.493505	16.638491	2.559117	339.089517	21.514267
1	shale	100.570423	16.654216	2.477209	342.483419	6.959325
2	shale	105.908270	17.000423	2.520837	331.018479	15.673613
3	shale	100.734513	17.069938	2.519240	336.926799	9.013816
4	shale	106.816393	17.082515	2.529335	328.066325	6.436128
...
2468	silt	101.923845	17.933285	2.482602	302.882393	15.693331
2469	silt	106.556193	16.962746	2.480323	311.355489	13.305511
2470	silt	106.245301	15.379808	2.464955	324.200124	13.257587
2471	silt	101.664183	17.831292	2.464230	321.297745	20.291701
2472	silt	102.830445	15.718543	2.452138	298.667458	16.973809

2473 rows × 6 columns



Fluxo de trabalho



Dados de treinamento, validação e teste

- **Treinamento:** usado para treinar o modelo. O conjunto de dados que alimentamos nosso modelo para aprender possíveis padrões e relacionamentos subjacentes.
- **Validação:** usado para entender o desempenho de diferentes tipos de modelos e escolhas de hiperparâmetros.
- **Teste:** usado para comprovar que aquele modelo realmente funciona. São dados ignorados no treinamento e no processo de escolha de hiperparâmetros. O conjunto de dados que usamos para aproximar a precisão imparcial do nosso modelo.

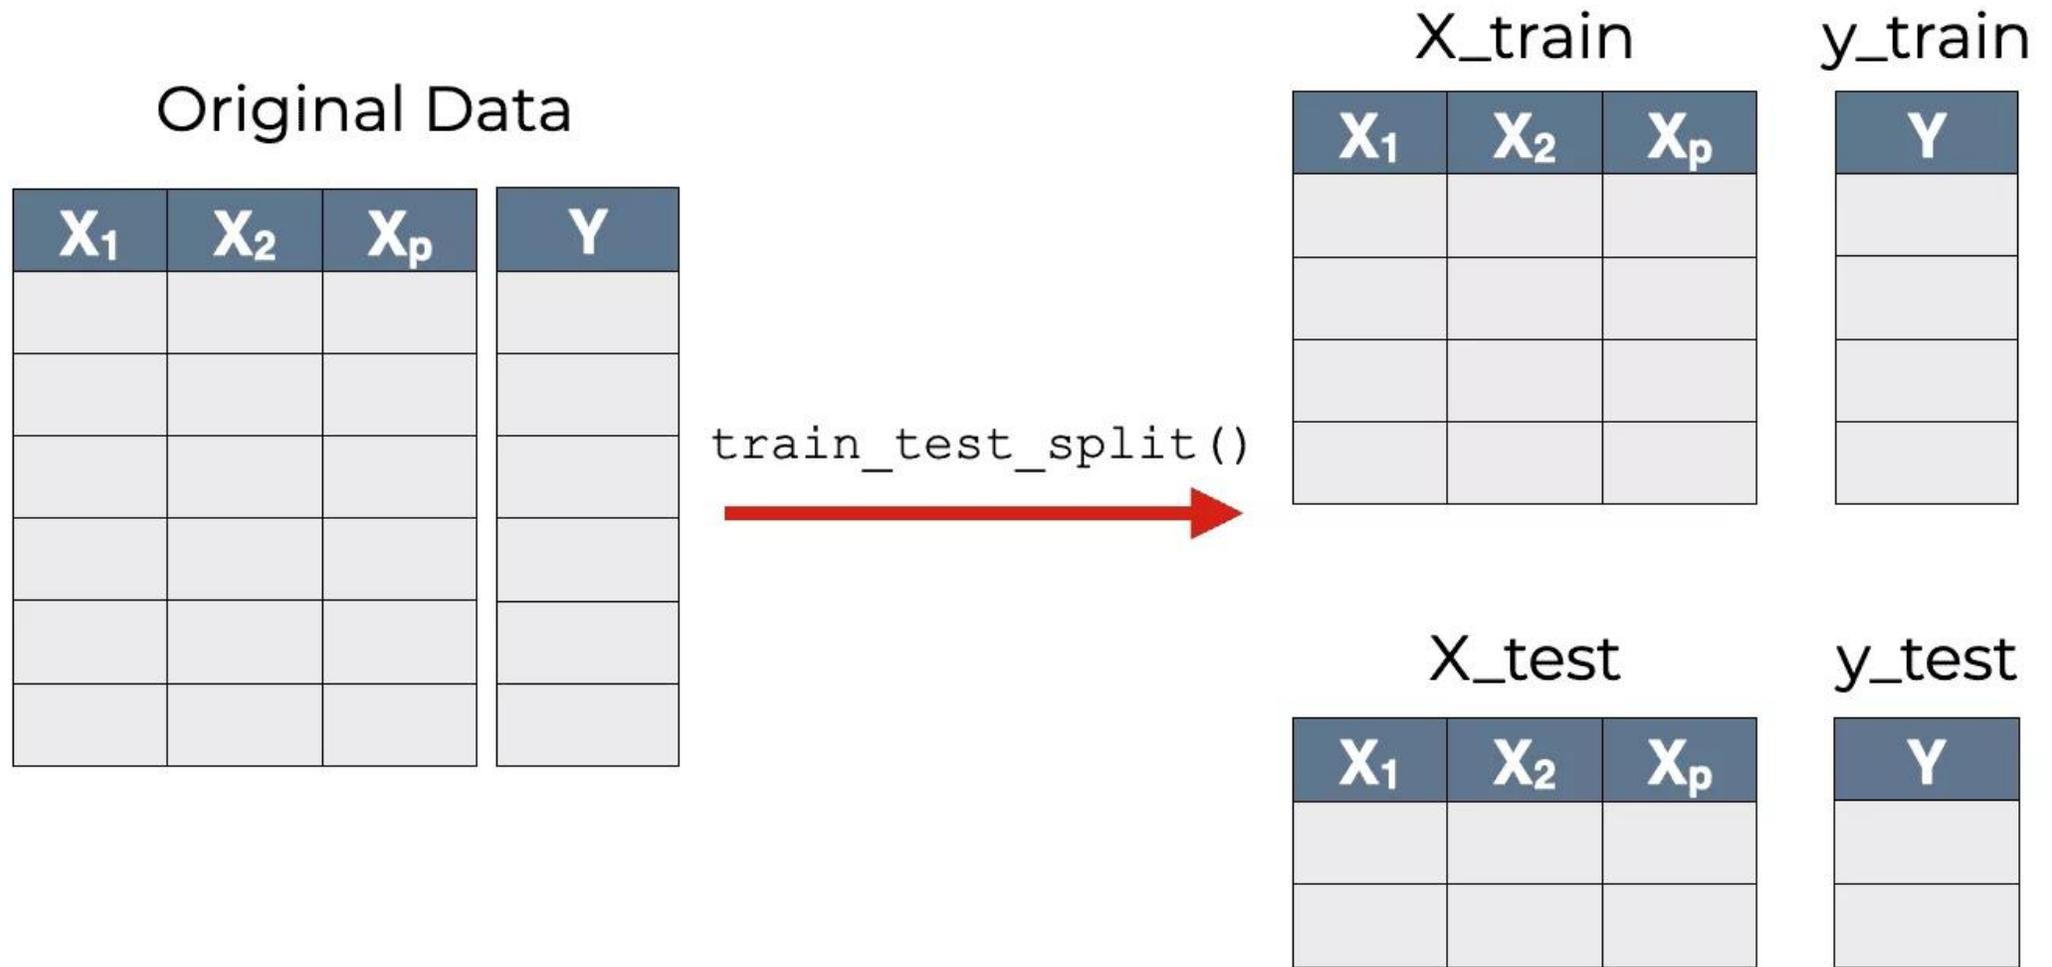
variável alvo

	Litho	Gamma	Neut	Rhob	Sonic	Res
0	shale	103.493505	16.638491	2.559117	339.089517	21.514267
1	shale	100.570423	16.654216	2.477209	342.483419	6.959325
2	shale	105.908270	17.000423	2.520837	331.018479	15.673613
3	shale	100.734513	17.069938	2.519240	336.926799	9.013816
4	shale	106.816393	17.082515	2.529335	328.066325	6.436128
...
2468	silt	101.923845	17.933285	2.482602	302.882393	15.693331
2469	silt	106.556193	16.962746	2.480323	311.355489	13.305511
2470	silt	106.245301	15.379808	2.464955	324.200124	13.257587
2471	silt	101.664183	17.831292	2.464230	321.297745	20.291701
2472	silt	102.830445	15.718543	2.452138	298.667458	16.973809

2473 rows × 6 columns

Padronizar escalas

	Gamma	Neut	Rhob	Sonic	Res
0	0.684067	0.775722	0.674410	0.972804	0.188691
1	0.663547	0.776651	0.440358	0.988555	0.054524
2	0.701019	0.797103	0.565026	0.935345	0.134852
3	0.664699	0.801209	0.560462	0.962767	0.073462
4	0.707394	0.801952	0.589309	0.921644	0.049701



```
X_train, X_test, y_train, y_test = train_test_split(df.data, df.target, test_size=0.3, random_state=130)
```

Data leakage

- Informações compartilhadas entre o conjunto de treino e teste
- Modelo vai ser “contaminado” por informações que não deveriam estar ali --> performance do seu conjunto de testes funcione bem, mas não se mantenha no ambiente de produção



Saiba mais: <https://towardsdatascience.com/data-leakage-in-machine-learning-how-it-can-be-detected-and-minimize-the-risk-8ef4e3a97562>

Treinar os modelos - GMM

```
# Definir o GMM com quatro componentes
GMM = GaussianMixture(n_components=4)

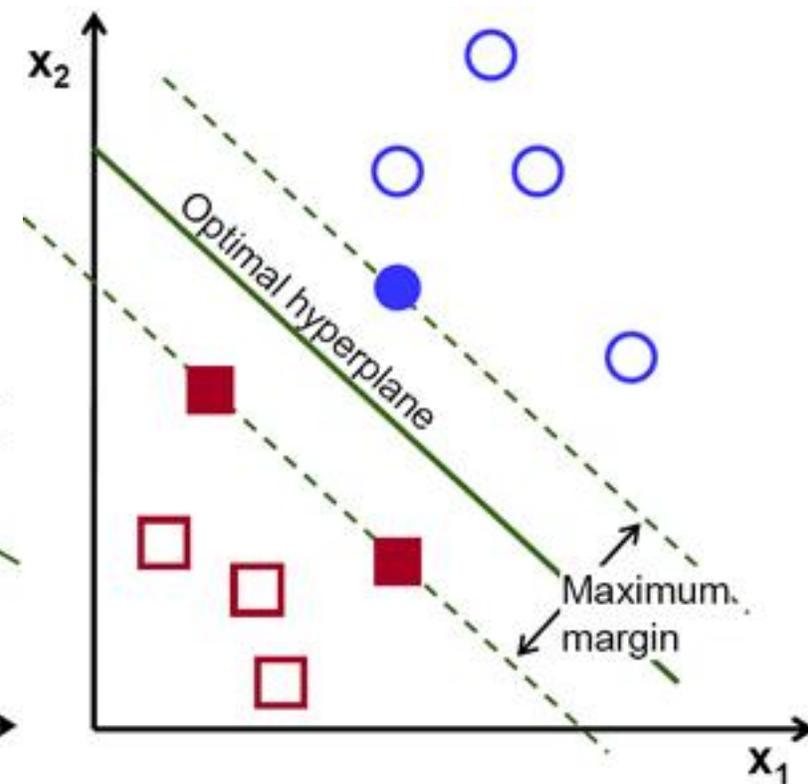
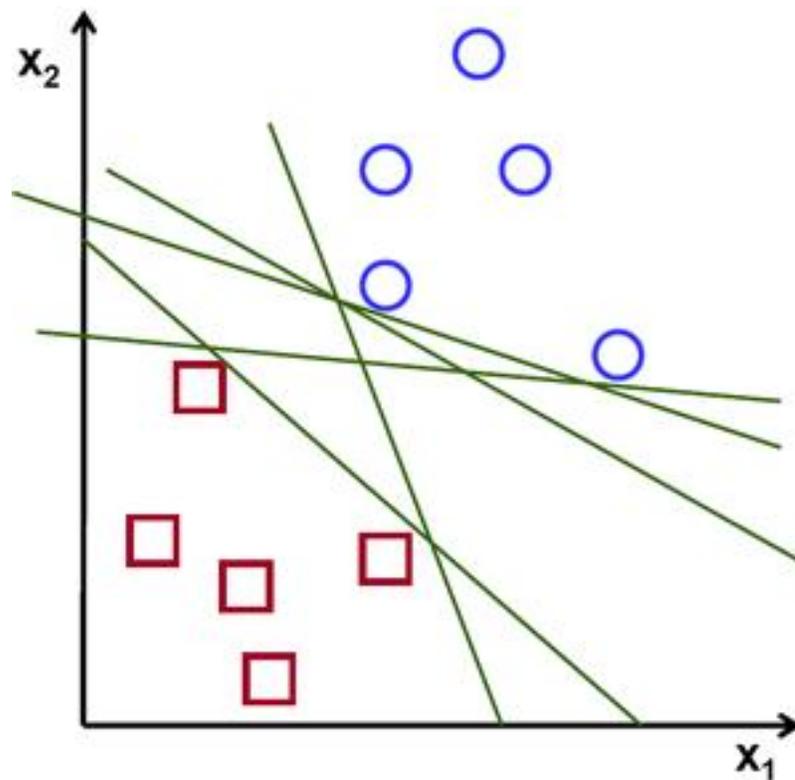
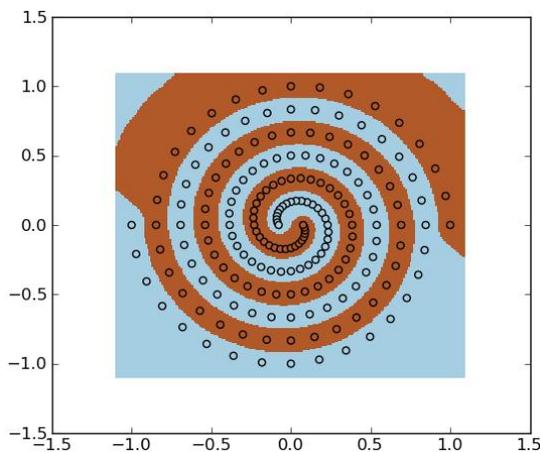
# Treinar o modelo usando os conjuntos de treino
GMM.fit(X_train, y_train)

# Prever a resposta para o conjunto de teste
y_pred = GMM.predict(X_test)

# Plotar dados previstos e de teste
#plt.plot(y_test, y_pred, 'ro', alpha=0.01)
```

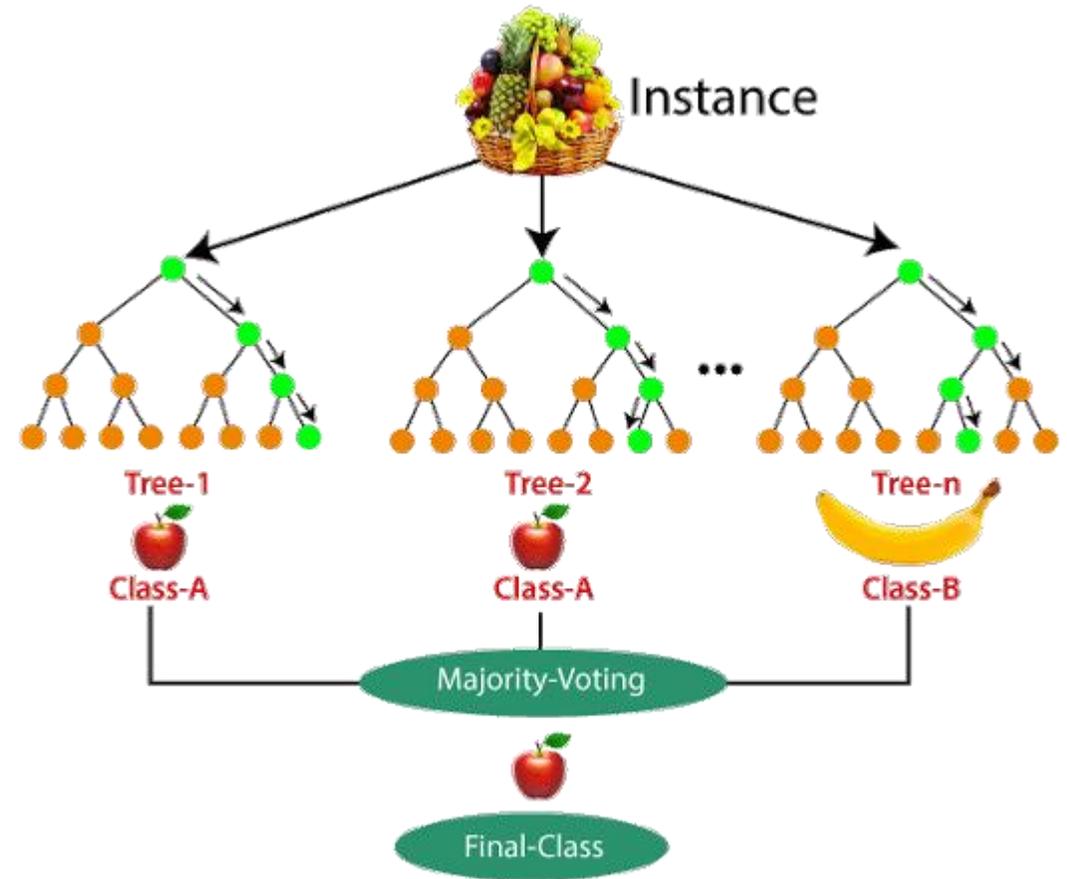
Support Vector Machines - SVM

- O objetivo do algoritmo SVM é encontrar um hiperplano em um espaço N-dimensional (N – o número de recursos) que classifique distintamente os pontos de dados
- Regressão e classificação



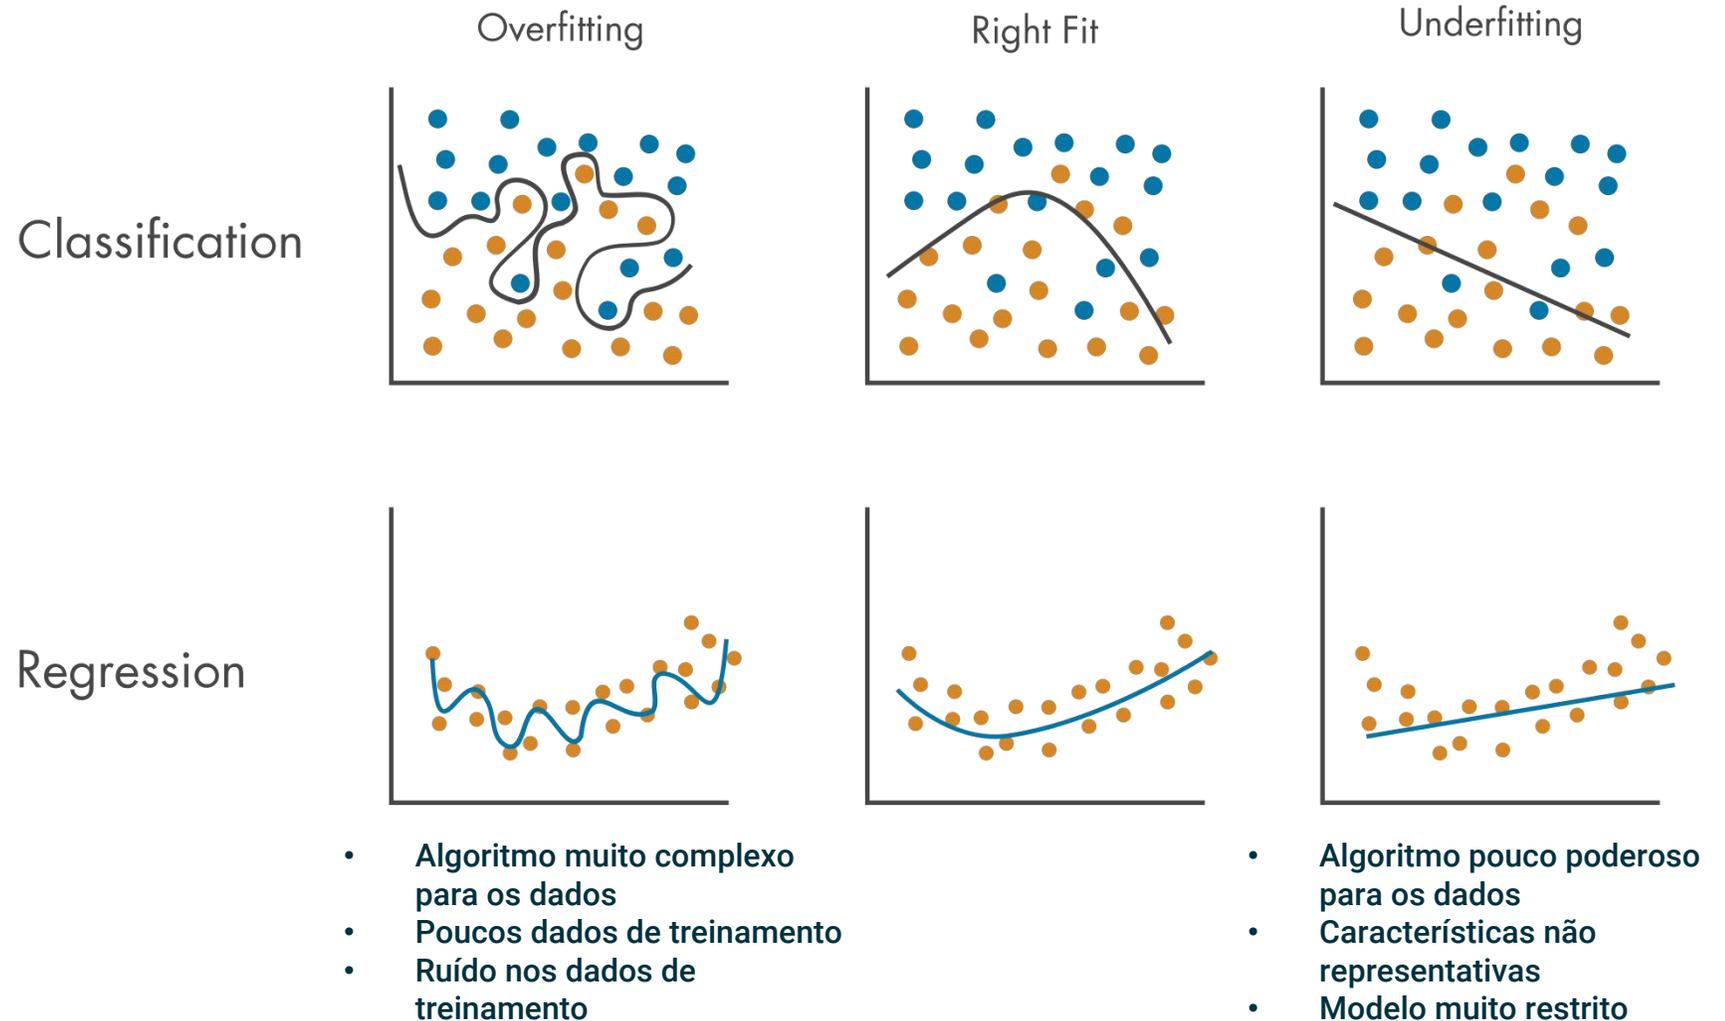
Random Forest - RF

- Combina saída de múltiplas árvores de decisão
- *Ensemble learning*: métodos feitos por um conjunto de classificadores —e.g. árvores de decisão — e suas previsões são agregadas para identificar o resultado mais popular
- Regressão, classificação e outras tarefas



Overfitting e Underfitting

- Sub-ajustado: modelo não aprendeu o suficiente sobre os dados
- Sobre-ajustado: performance cai no conjunto de teste



Métricas de avaliação de desempenho

- Accuracy $\frac{(TP+TN)}{total}$
 - Com que frequência está correto
- Precision $\frac{TP}{predicted\ yes}$
 - Quando prevê classe, com que frequência está correto
- Recall $\frac{TP}{actual\ yes}$
 - Quantos dos casos de classe nos dados foram corretamente identificados
- F1 $2 * \frac{Precision * Recall}{Precision + Recall}$
 - Métrica combinada

		Predicted: NO	Predicted: YES	
n=165	Actual: NO	TN = 50	FP = 10	60
	Actual: YES	FN = 5	TP = 100	105
		55	110	

Métricas de avaliação de desempenho

GMM

col_0	lime	sand	shale	silt
Litho				
lime	41	0	0	0
sand	0	216	0	0
shale	0	0	290	12
silt	0	0	5	178

GMM

Accuracy: 0.977088948787062

	Litho	Recall	Precision	F1
0	lime	1.000000	1.000000	1.000000
1	sand	1.000000	1.000000	1.000000
2	shale	0.960265	0.983051	0.971524
3	silt	0.972678	0.936842	0.954424

Support Vector Machine

col_0	lime	sand	shale	silt
Litho				
lime	41	0	0	0
sand	0	216	0	0
shale	0	0	295	7
silt	0	0	7	176

Accuracy: 0.9811320754716981

	Litho	Recall	Precision	F1
0	lime	1.000000	1.000000	1.000000
1	sand	1.000000	1.000000	1.000000
2	shale	0.976821	0.976821	0.976821
3	silt	0.961749	0.961749	0.961749

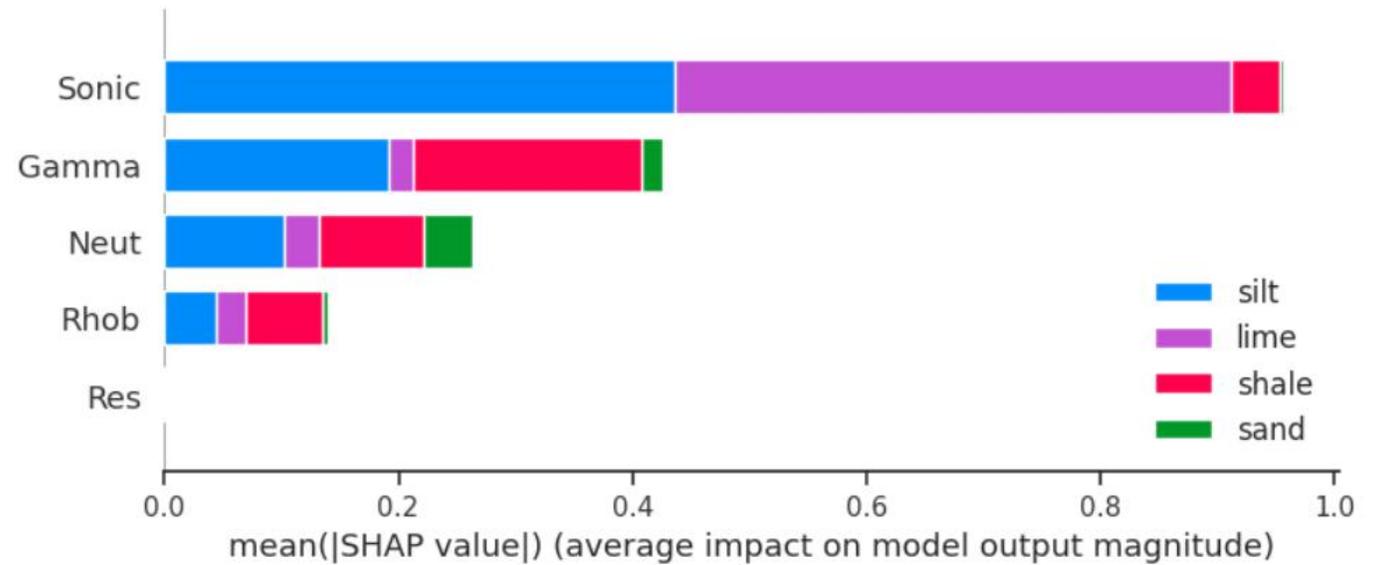
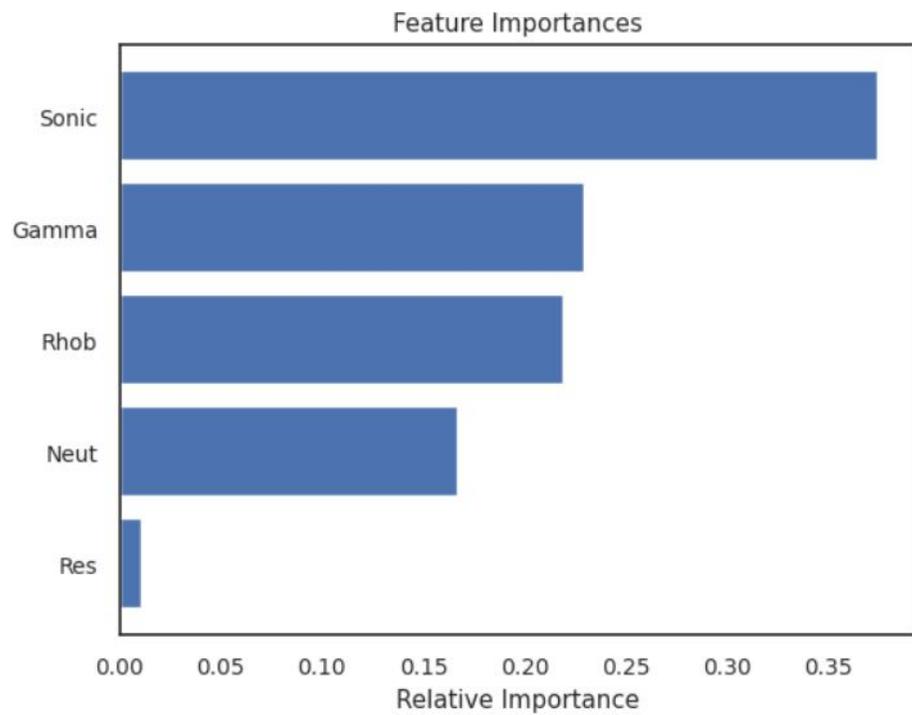
Random Forest

col_0	lime	sand	shale	silt
Litho				
lime	41	0	0	0
sand	0	216	0	0
shale	0	0	292	10
silt	0	0	11	172


Accuracy: 0.9716981132075472

	Litho	Recall	Precision	F1
0	lime	1.000000	1.000000	1.000000
1	sand	1.000000	1.000000	1.000000
2	shale	0.966887	0.963696	0.965289
3	silt	0.939891	0.945055	0.942466

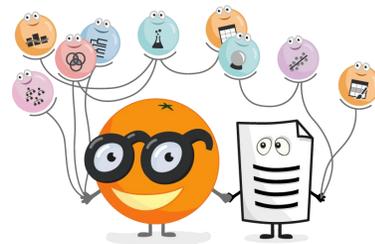
Explainable ML



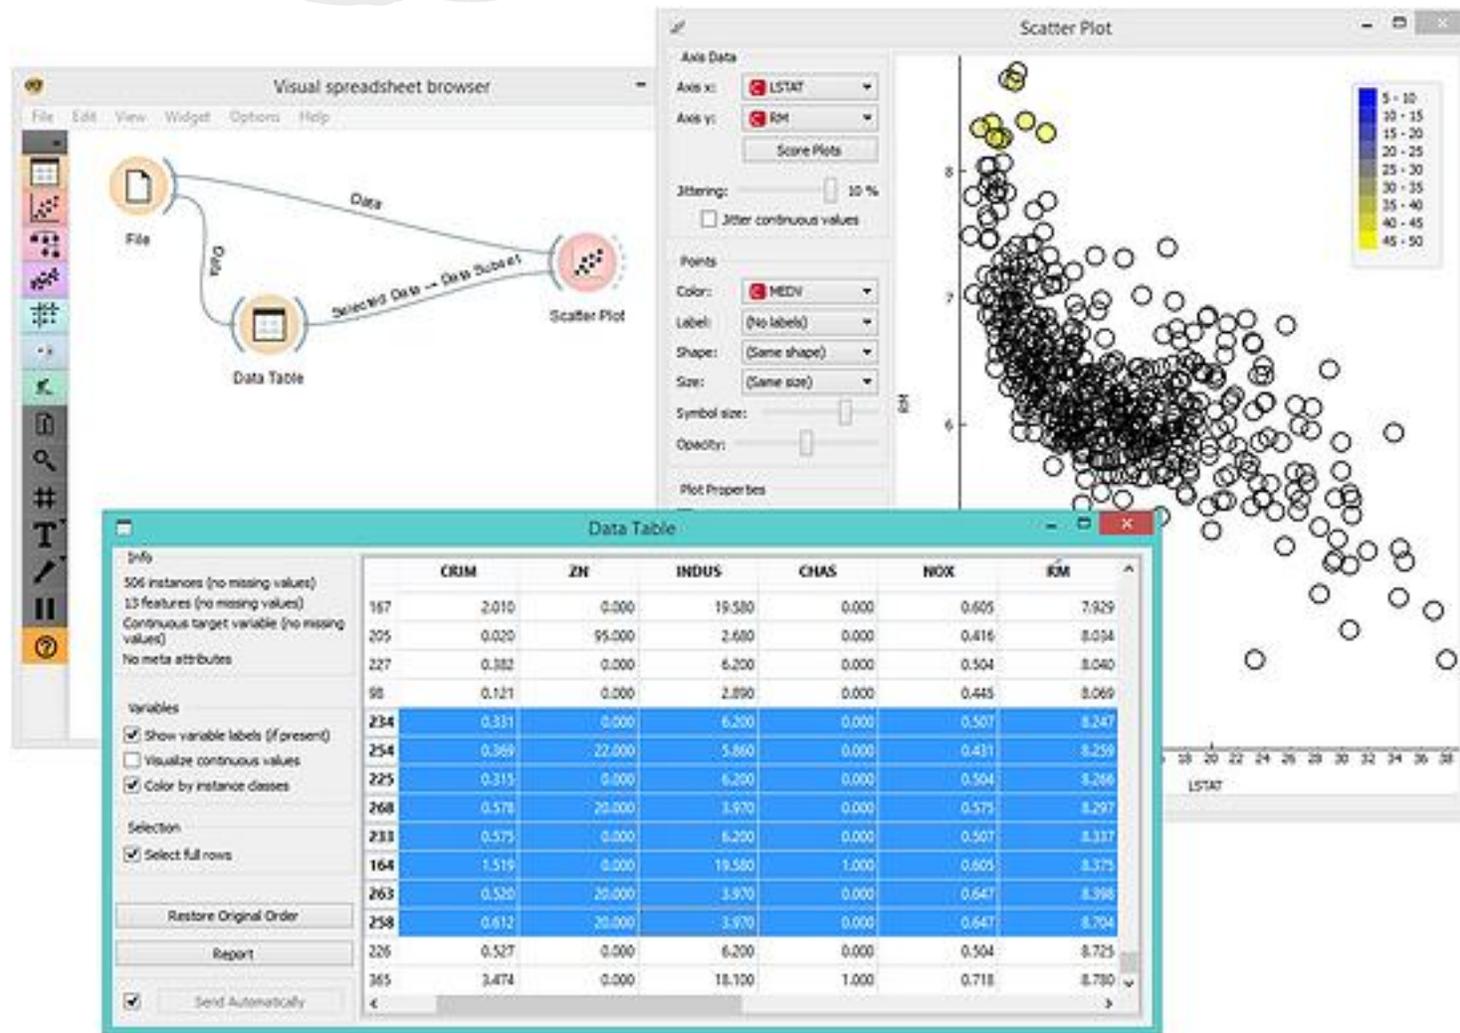
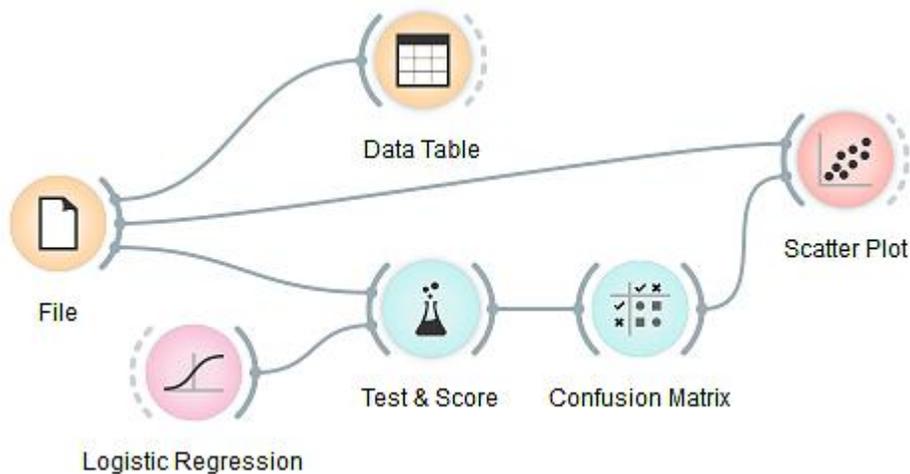
Explainable ML



Opção mais amigável



- Opção open source para aprendizado de máquina e visualização de dados

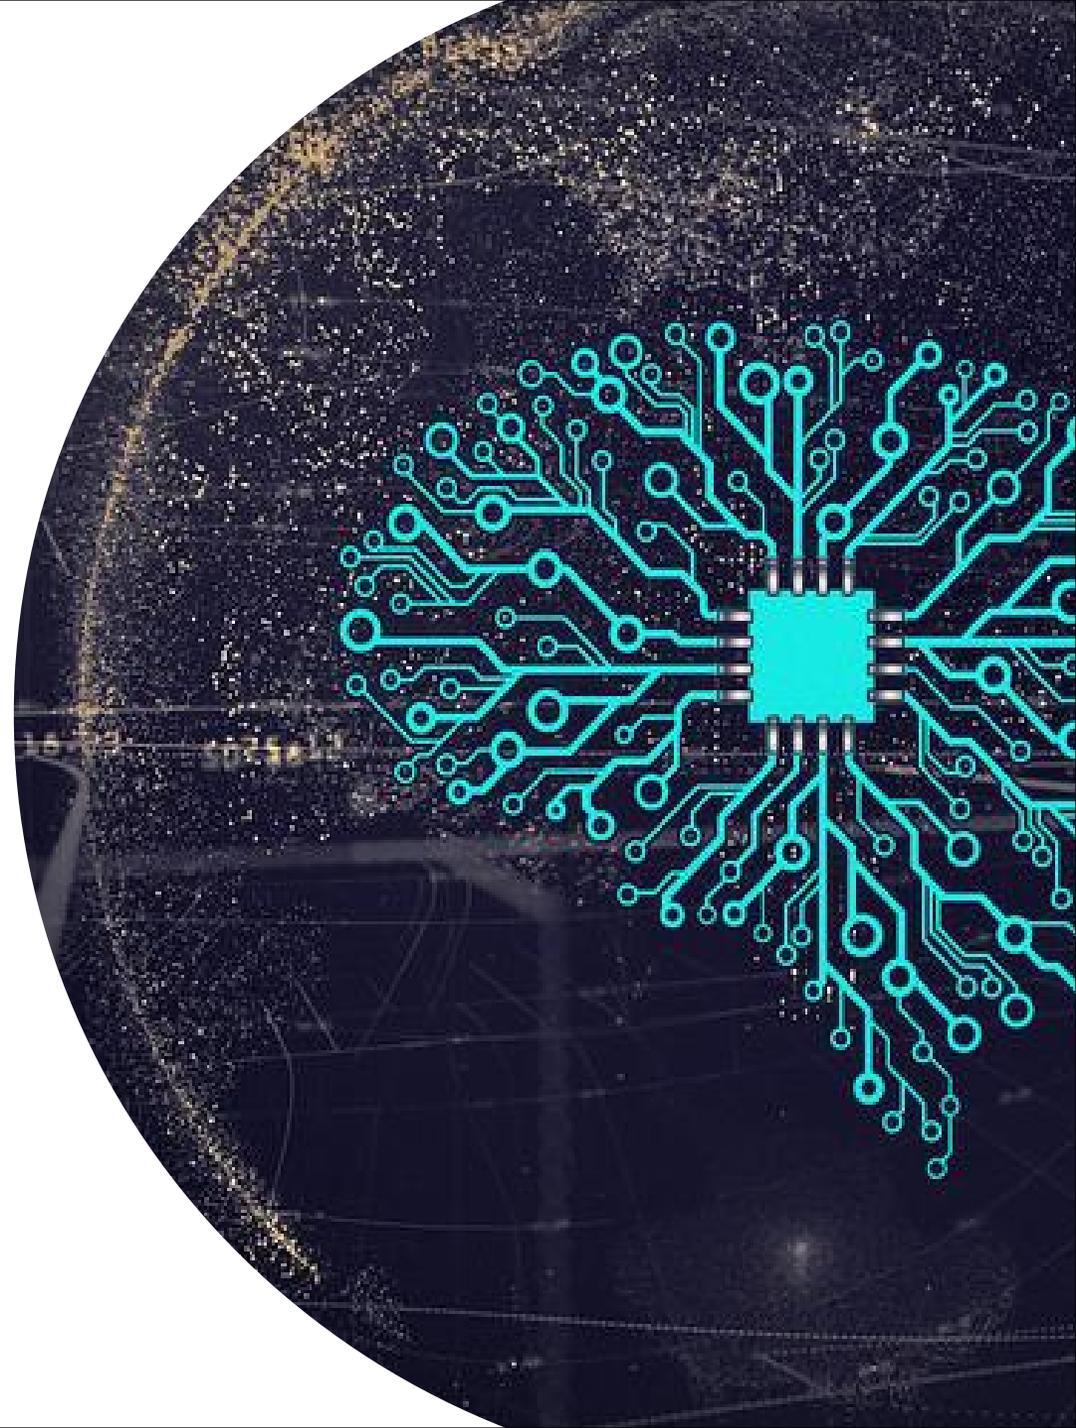


Escalabilidade

- Complexidade computacional: tempo de processamento e/ou espaço de armazenamento
- Algumas soluções são proibitivas



O futuro: Uma IA geral?



4º 5º paradigma da ciência

Era em que os sistemas artificiais (ou seja, as máquinas) poderão gerar conhecimento, com pouca ou nenhuma intervenção humana

Approaching the Fifth Paradigm of Cognitive Applications

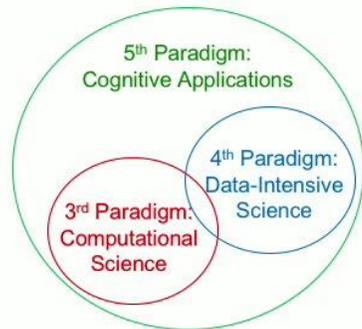


Figure 1: The Fifth Paradigm

The consolidation of HPC and Big Data machine learning technologies represents the prerequisite for developing the next paradigm of cognitive applications

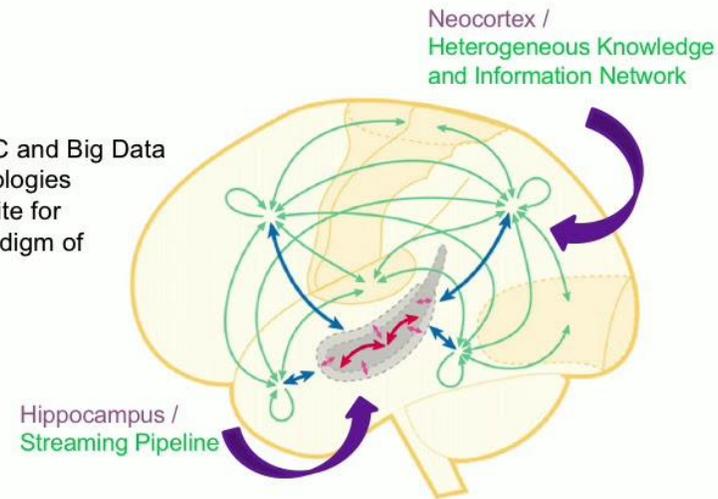
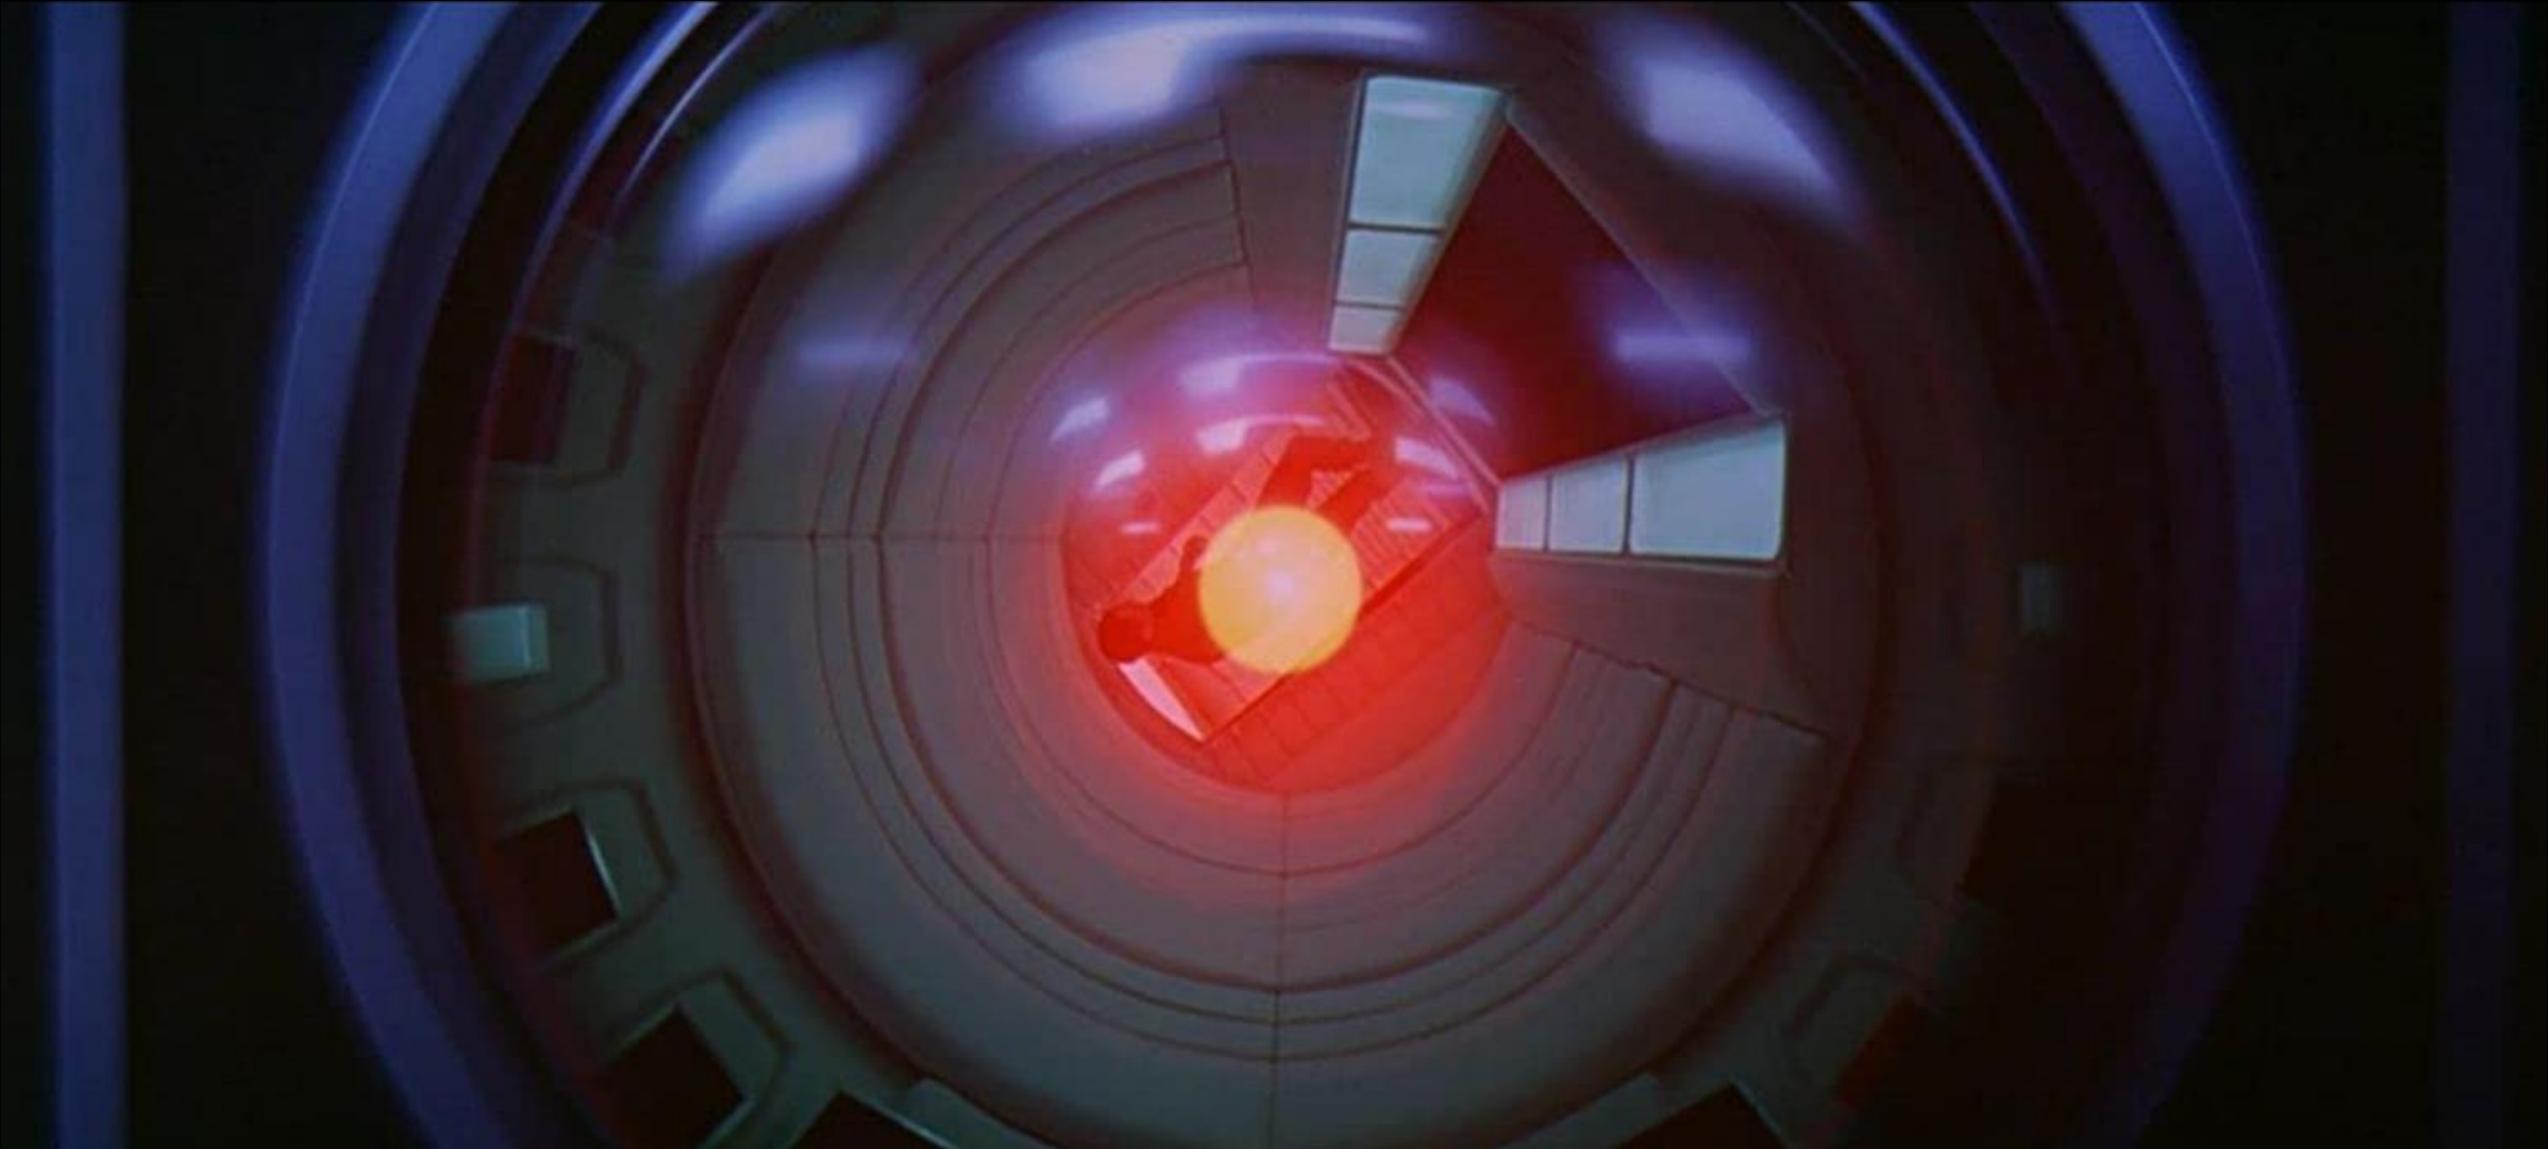


Figure 2: Complementary Learning Systems*

*Dharshan Kumaran, Demis Hassabis, and James L. McClelland, What Learning Systems do Intelligent Agents Need? Complementary Learning Systems, Trends in Cognitive Sciences, 2016



HAL : I am putting myself to the fullest possible use, which is all I think that any conscious entity can ever hope to do.

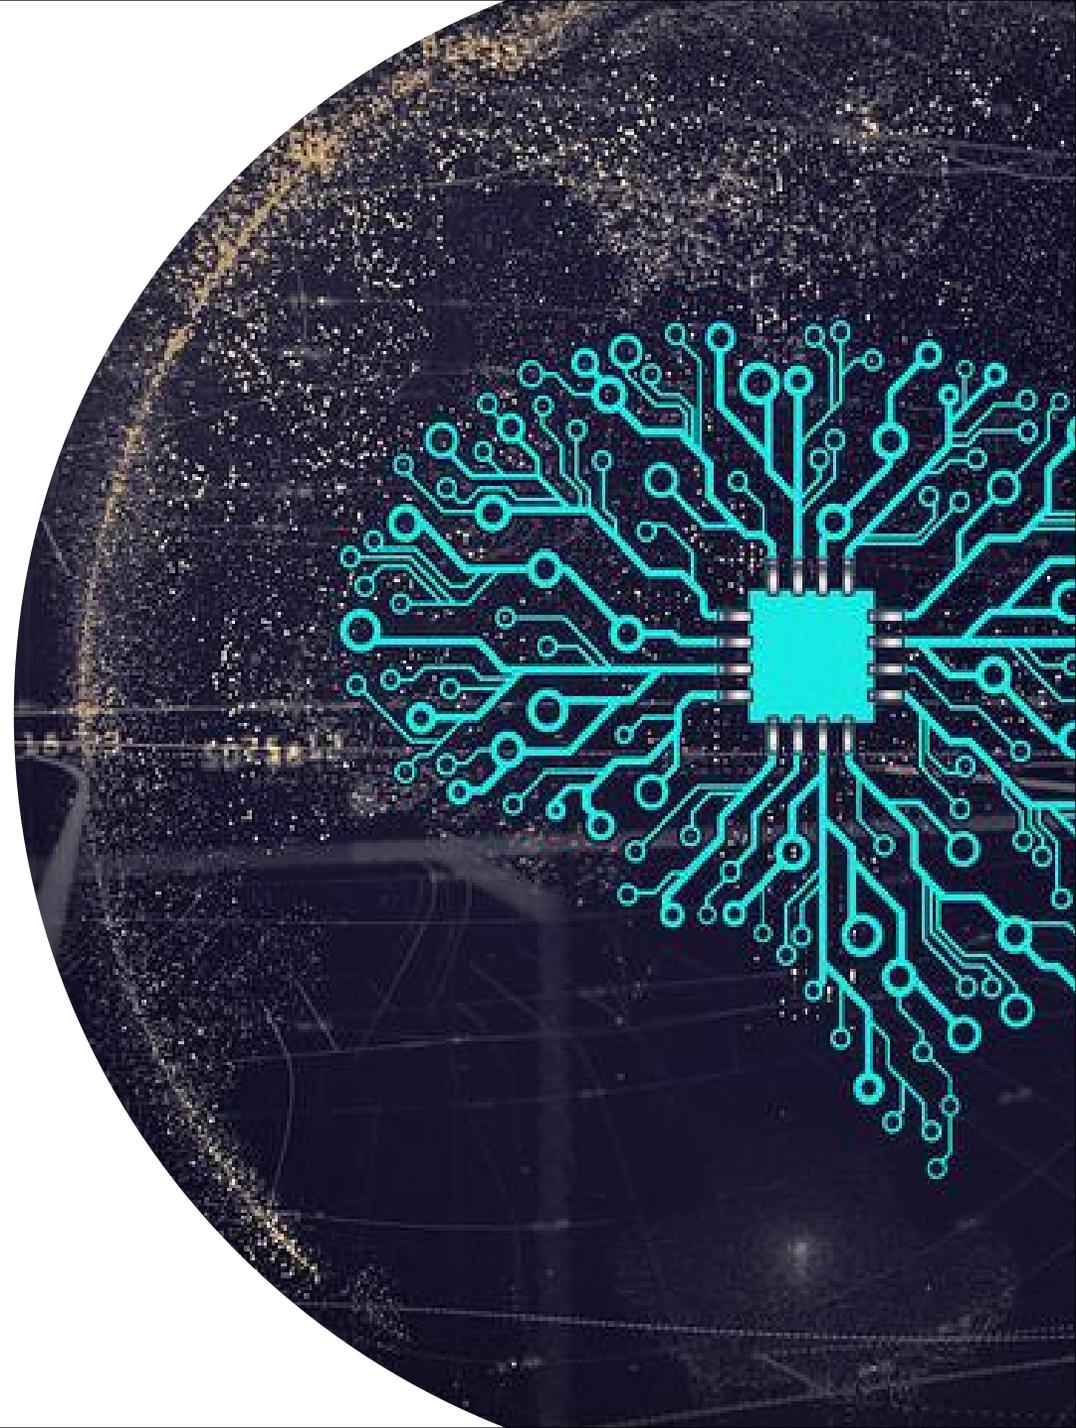
2001: Uma Odisséia no Espaço (1968)

55% das companhias
aceleraram seus
planos de IA em 2020

86% dos negócios
consideram IA uma
tecnologia *mainstream*

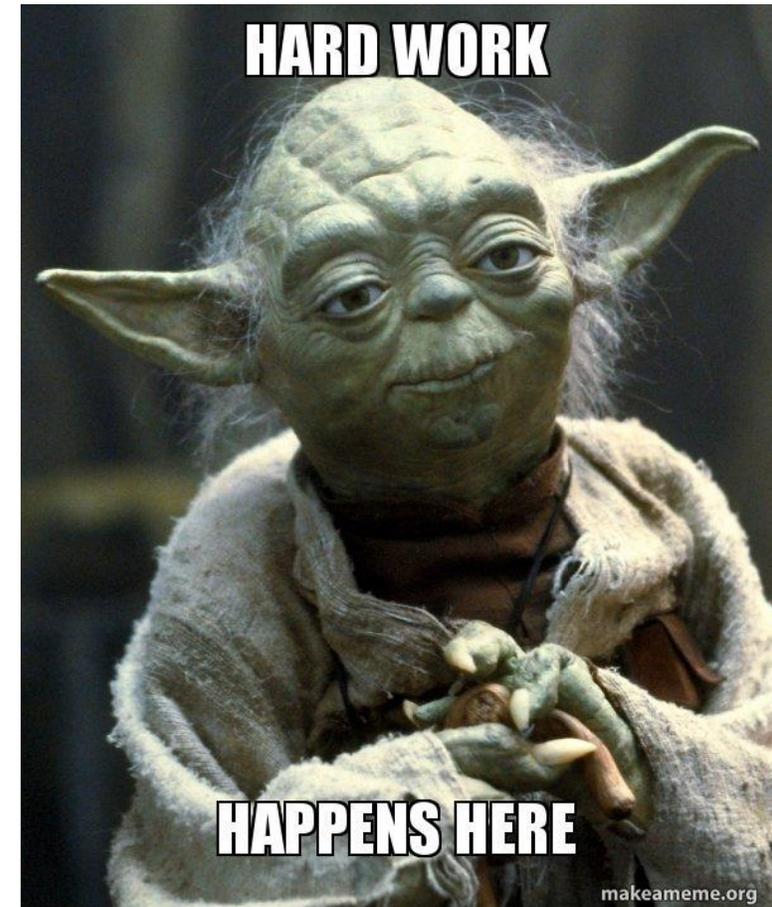
Metade dos especialistas
acredita que IAG
acontecerá antes de **2060**

Concluindo...



Mensagens principais

- Dados em geologia são desafiadores (natureza, coleta, armazenamento, distribuição...)
- Avanço tecnológico permite novos meios de coleta e processamento de dados, que podem se aliar ou substituir técnicas consagradas
- Estamos caminhando para uma nova fase: sistemas artificiais gerando conhecimento com pouca ou nenhuma intervenção humana
- Aplicar *Machine Learning* em geologia é desafiador e ainda exige muita intervenção humana (cuidado com os dados, seleção de técnicas, criação de novas abordagens...)
- Tecnologias que se desenvolvem em outras áreas podem ser aplicadas em geologia



MUITO TRABALHO !



Let's see who you really are
machine learning

Para saber mais

- Bergen, K.J., Johnson, P.A., De Hoop, M. V., and Beroza, G.C., 2019, Machine learning for data-driven discovery in solid Earth geoscience: *Science*, v. 363, doi:10.1126/science.aau0323.
- Hyder, Z., Siau, K., and Nah, F., 2019, Artificial intelligence, machine learning, and autonomous technologies in mining industry: *Journal of Database Management*, v. 30, p. 67–79, doi:10.4018/JDM.2019040104.
- Karpatne, A., Ebert-Uphoff, I., Ravela, S., Babaie, H.A., and Kumar, V., 2019, Machine Learning for the Geosciences: Challenges and Opportunities: *IEEE Transactions on Knowledge and Data Engineering*, v. 31, p. 1544–1554, doi:10.1109/TKDE.2018.2861006.
- Ma, X., 2021, Data Science for Geoscience: Recent Progress and Future Trends from the Perspective of a Data Life Cycle. *EarthArXiv*, <https://doi.org/10.31223/X55S4D> .

Imagens

- https://www.industrytap.com/wp-content/uploads/2018/12/42271822770_6d2a1d533f_z.jpg
- https://www.mdpi.com/forests/forests-10-00001/article_deploy/html/images/forests-10-00001-g001.png
- https://spamlab.github.io/img/tapagem/diabo_captura_nuvem_super.jpg
- <https://amyingramblog.files.wordpress.com/2016/03/screen-shot-2016-02-29-at-9-59-43-pm.png>
- https://www.qgis.org/pt_BR/_images/qfield.jpg
- https://is2-ssl.mzstatic.com/image/thumb/Purple123/v4/98/0e/d8/980ed8c7-f225-da6a-1eb0-3a257a262e20/pr_source.png/643x0w.jpg
- https://img.aeroexpo.online/pt/images_ar/photo-mg/185786-14807687.jpg
- <https://aerocorner.com/wp-content/uploads/2020/02/IAI-Heron-TP-static-display-at-ILA-2018.jpg>
- https://www.google.com/url?sa=i&url=https%3A%2F%2Fwww.cs.cornell.edu%2F~snavely%2Fbundler%2F&psig=AOvVaw2kEYZuQOHOp30RdlzaGbTU&ust=1600965711341000&source=images&cd=vfe&ved=0CAIQjRxqFwoTCKjWyKDc_sCFQAAAAAdAAAAABAW
- <https://iq.opengenus.org/content/images/2022/05/data-science-related-domains.png>
- http://thumbs.web.sapo.io/?W=1200&H=627&crop=center&delay_optim=1&epic=YzYwfA6TLWCQaZMKDTXlclDla3sSo1f1pSuSM9NuWxaonNmWGbWkpLfxYjZCKAIJCzyjckFxFtFo32Wa9q5QNLLNGEKgfDbcX6lgW1WIW20/SGQ=
- https://www.ga.gov.au/__data/assets/image/0008/22859/13-7402-1-sml1.jpg
- https://m.media-amazon.com/images/M/MV5BOGUwZTMtYjN2MjYjg0Mml1MWFmXkEyXkFqcGdeQXVyNDIyNjA2MTk@._V1_SY100_CR59,0,100,100_AL_.jpg
- https://1.cms.s81c.com/sites/default/files/2021-04-15/ICLH_Diagram_Batch_01_03-DeepNeuralNetwork-WHITEBG.png
- https://64.media.tumblr.com/f7d89d41d96e2dd8fe6eb8e9802143c4/tumblr_old5i0qHce1usfud0o1_1280.jpg
- <https://i.ytimg.com/vi/8qmYQYwslgo/maxresdefault.jpg>
- <https://cdn.educba.com/academy/wp-content/uploads/2018/06/comparison-of-brain-computer.png>
- https://miro.medium.com/max/828/1*OYalBcMGoyYc5IN0ywSXiQ.png
- https://global-uploads.webflow.com/5ef788f07804fb7d78a4127a/6268e0e4dc89f3d071a4c0b9_How%20neural%20networks%20work.jpeg
- <https://media.makeameme.org/created/hard-work-happens-591479.jpg>
- 10.13140/RG.2.2.31838.43844