

An aerial photograph showing a residential neighborhood with many houses and a road, adjacent to a sandy beach and a body of water. The water appears to have some darker patches, possibly indicating a wetland or a specific type of terrain.

Aplicações de IA em Sensoriamento Remoto

Prof. Dr. Denis M. L. Martins

DCM | FFCLRP | USP

Sobre mim

- Engenheiro da Computação pela Universidade de Pernambuco
- Doutorado na Uni Münster
- Eng. de Software na Stefanini
- Pesquisador Sênior em IA na Samsung Research Brazil
- Professor na PUC-Campinas
- **Professor no DCM-USP**

■ Especialidade: Dados e IA



"Data is the new Oil"

(Dados são o novo petróleo)

Forbes

INNOVATION

Data Is The New Oil -- And That's A Good Thing



By [Kiran Bhageshpur](#), Former Forbes Councils Member.

for [Forbes Technology Council](#), **COUNCIL POST** | Membership (fee-based)

Published Nov 15, 2019, 08:15am EST, Updated Apr 14, 2022, 02:04pm EDT

Forbes

INNOVATION > AI

Data as The New Oil Is Not Enough: Four Principles For Avoiding Data Fires

By [Nisha Talagala](#), Contributor. © Entrepreneur and technologist in AI and AI L... ▾

[Follow Author](#)

Published Mar 02, 2022, 05:48pm EST, Updated Mar 04, 2022, 05:05am EST

Forbes

INNOVATION

Stop Thinking Of Data As The New Oil



By [Juan Carlos Santiago](#), Forbes Councils Member.

for [Forbes Technology Council](#), **COUNCIL POST** | Membership (fee-based)

Published Jul 09, 2025, 09:45am EDT

Forbes

SMALL BUSINESS

If Data Is The New Oil, Decision Science Is The New Refinery

By [Chris Chambers, MBA](#), Forbes Councils Member.

for [Forbes Business Council](#), COUNCIL POST | Membership (fee-based)

Published Oct 07, 2025, 08:15am EDT

Dados

"Data is the new Oil".

- Frase de Clive Humby no início da década de 2000.
- Ficou popular na década de 2010.


Na foto: Clive Humby. Fonte: [Retailer Insider](#) .



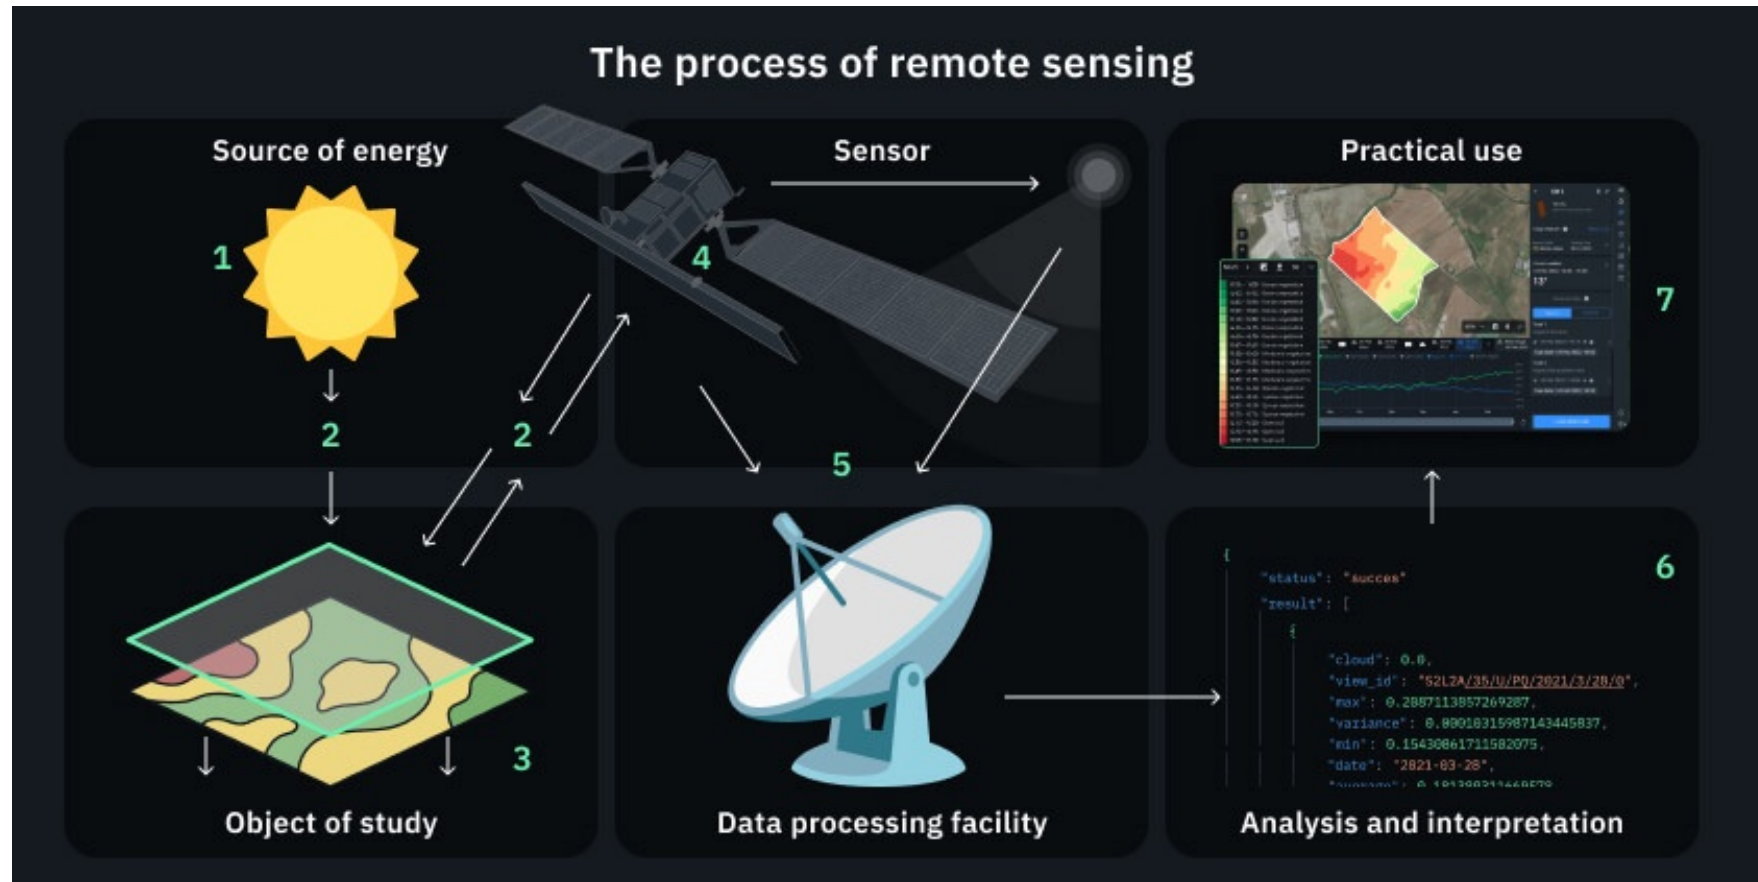
Sensoriamento Remoto

- Processo de observação e avaliação realizado à distância.
- Frequentemente pelo emprego de plataformas aéreas e satélites.
- **Objetivo:** Identificar e monitorar alterações em suas características físicas ao longo do tempo.
 - Aprimorar a avaliação área de interesse
 - Subsidiar processos decisórios.
- **Volume de dados é abundante.**

Fonte da imagem: [GeeksForGeeks](#) .





Sensoriamento Remoto



Na imagem: Fases do processo de Sensoriamento Remoto. Fonte: [EOS](#)

Ground Sampling Distance

- A unidade de medida padrão para resolução espacial.
- Ou seja, o quão grande é um único pixel no mundo real.
- Very High Resolution: 30cm – 50cm
- Low Resolution: 30m+

Fonte da imagem: [GeoAwesome](#) 
Mais informações em [Skyfi](#) .

Understanding Scale to Avoid GeoAI Failures



Sentinel (ESA)

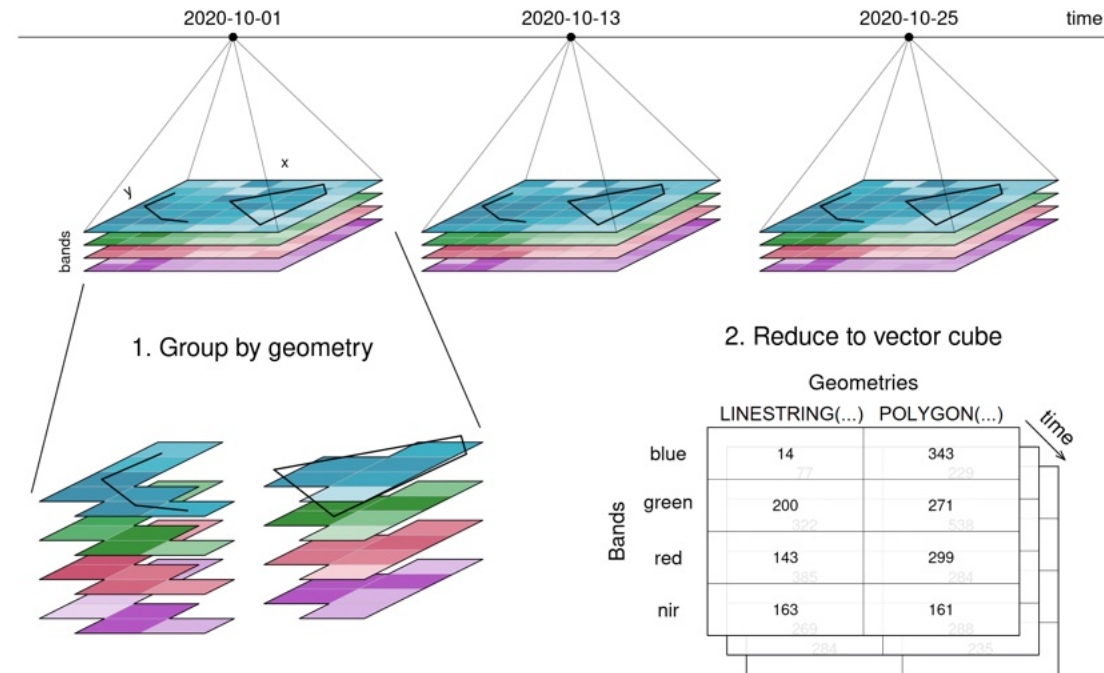
Sentinel-1: Radar: Consiste em dois satélites operando em órbita polar. Isso permite que ele capture imagens através de nuvens, fumaça ou durante a noite.

Sentinel-2: Óptico Multiespectral: Dois satélites operando em uma órbita síncrona com o Sol, mantendo um desfasamento de fase de 180 graus entre si.

Fonte da imagem: [eoPortal](#) 

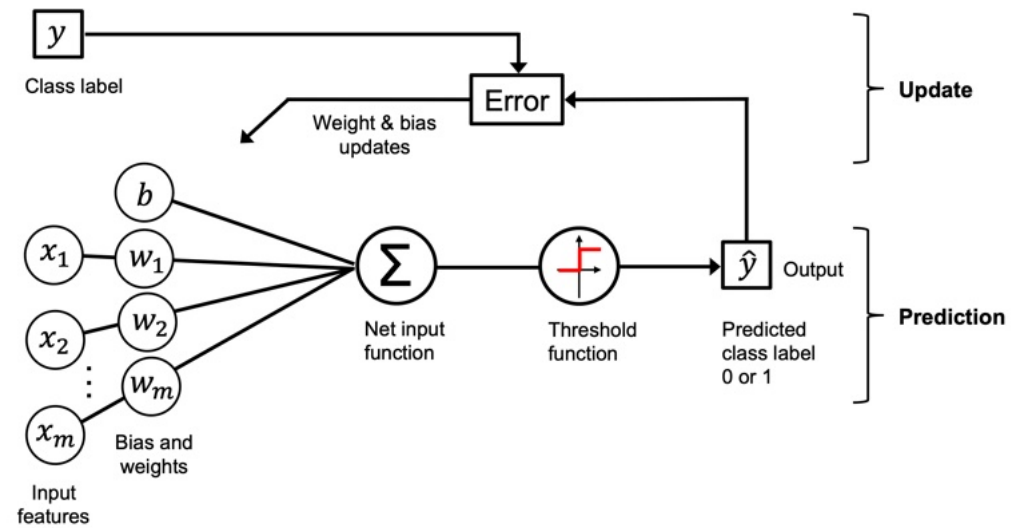
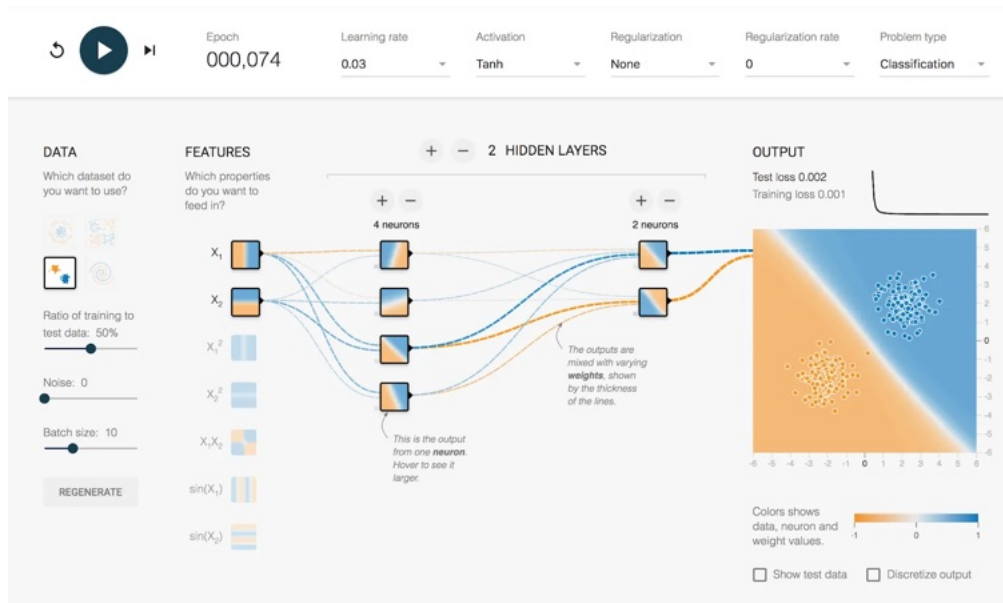


Data Cubes



Fonte da imagem: <https://openeo.org/documentation/1.0/datacubes.html#what-are-datacubes>

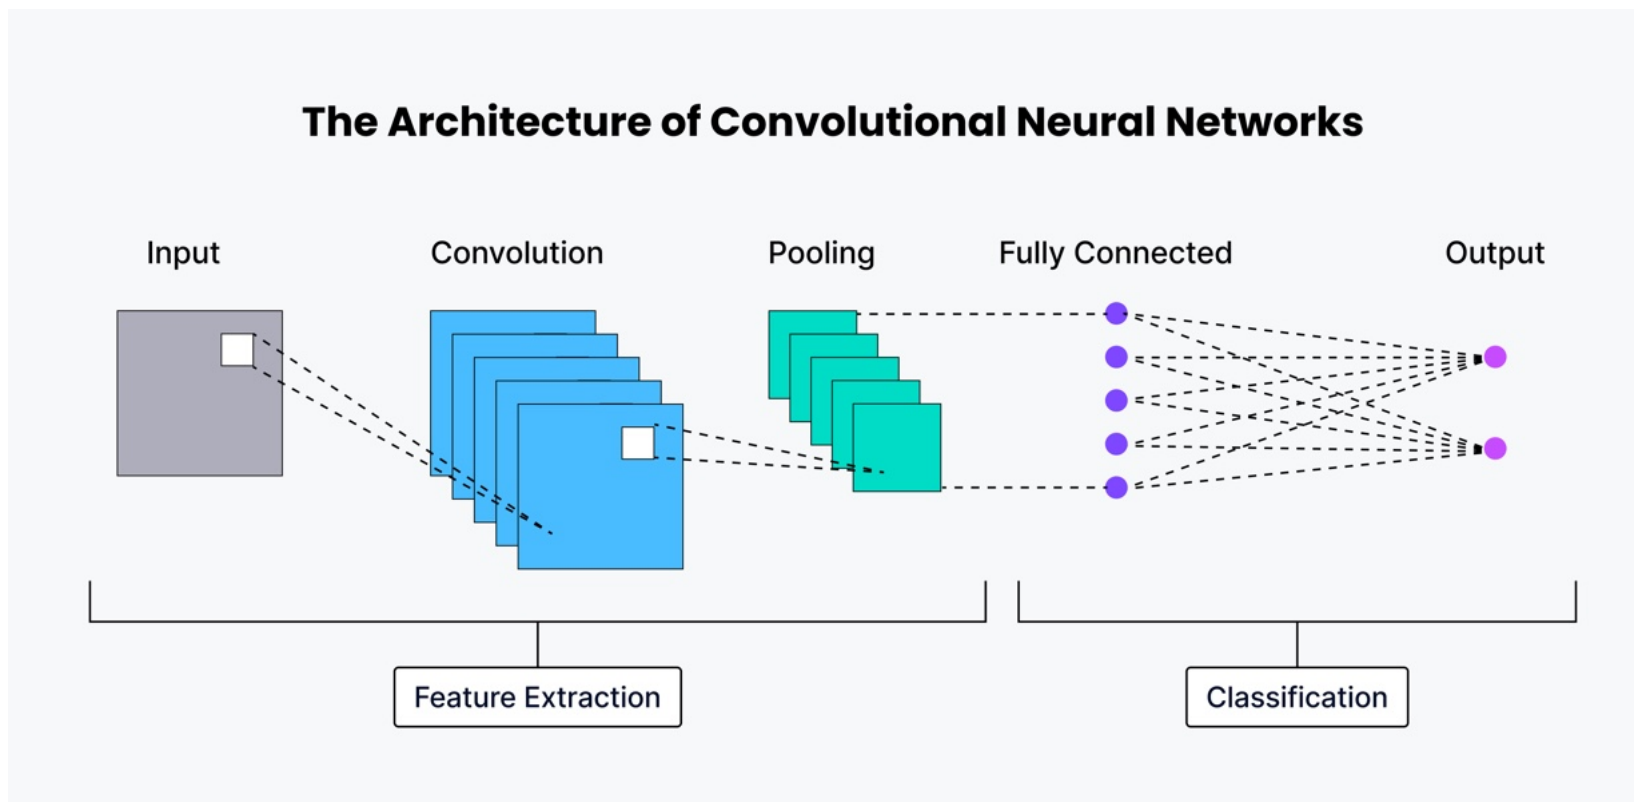
Como a IA Moderna "aprende"?



Na direita: Treinando Redes Neurais no TensorFlow Playground. Fonte: [Tensorflow Playground](#)

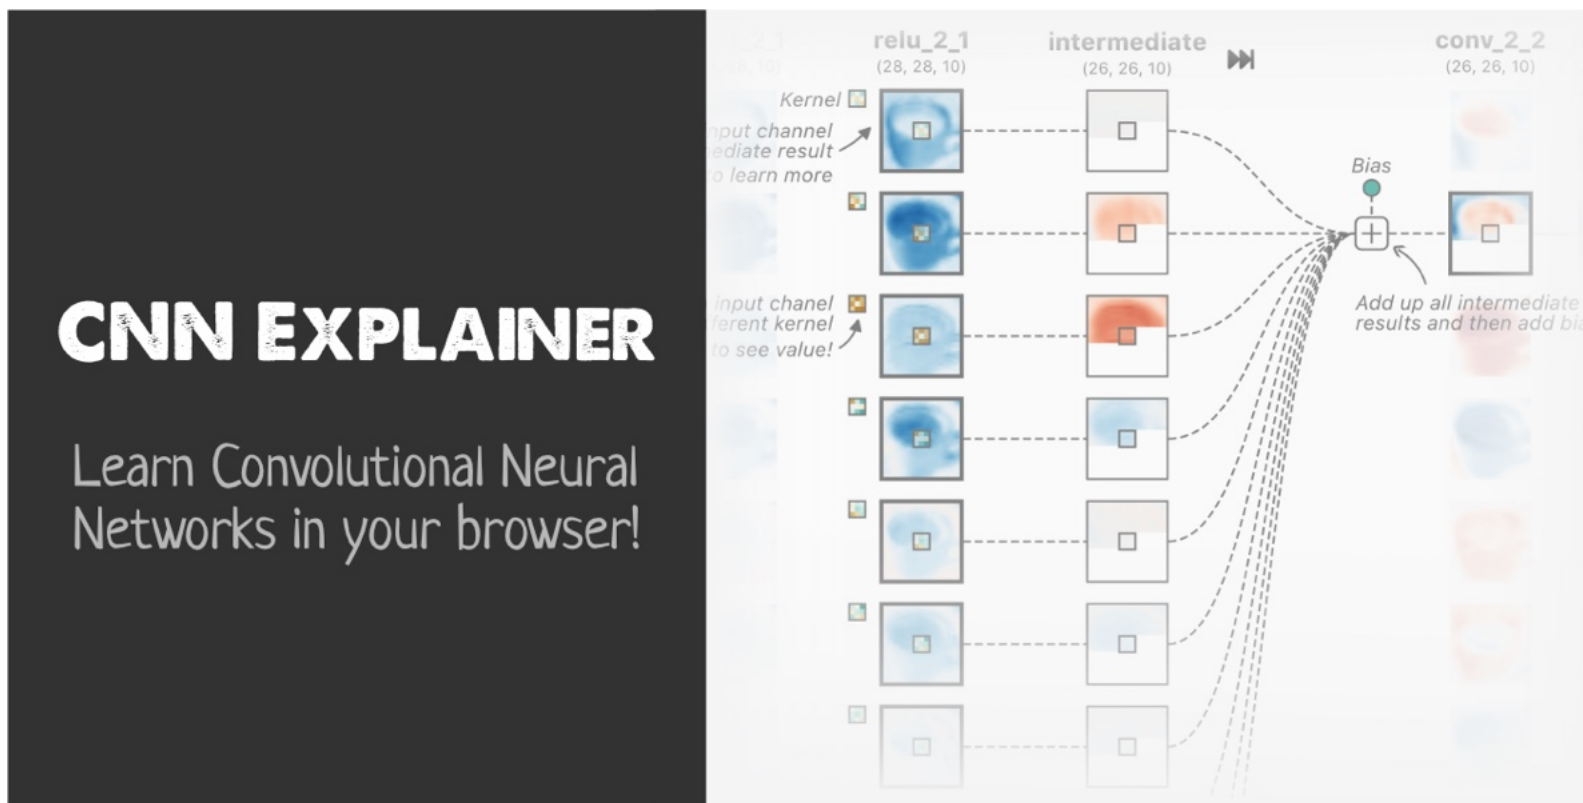
Na esquerda: Visão Geral do Perceptron. Fonte: [Sebastian Raschka](#)

Como IA "entende" imagens? (cont.)



Estrutura geral de uma Rede Neural Convolutacional. Fonte da Imagem: [Zilliz](#) ↗


Como IA "entende" imagens? (cont.)



Demonstração em [CNN Explorer](#) ↗


Landcover: Uso da Terra

- Escala Temporal: Série anual (Cobertura prevista para 2017–2025).
- Resolução Espacial: 10 metros
- Altamente granular, permitindo a diferenciação entre diferentes tipos de uso do solo em escala de bairro/sub-bairro.
- Nível de Dados: Mapa Semanticamente Classificado (Uso e Cobertura da Terra).
- Link: [Sentinel-2 Land Cover Explorer](#) ↗

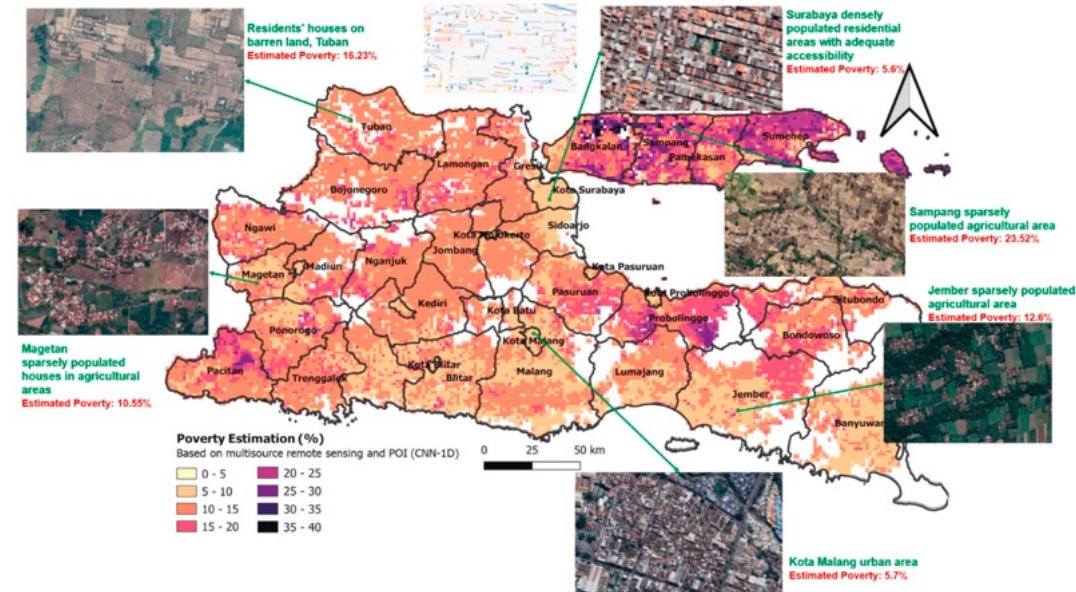


Landcover: Aplicações

- **Planejamento do Uso do Solo:** Entender a pressão antrópica em áreas críticas, informando decisões sobre zoneamento urbano.
- **Segurança Alimentar:** Monitorar da conversão de terras agrícolas e a quantificação dos índices de desmatamento periurbano.
- **Gestão Hídrica/Ambiental:** Identificar mudanças na permeabilidade do solo em relação ao crescimento urbano.
- **Capital Natural Nacional:** Rastrear as tendências no capital natural de um país, justificando alocações orçamentárias de planejamento territorial.



Poverty Maps



Na imagem: Mapa da pobreza em East Java, Indonésia. PUTRI, Salwa Rizqina; WIJAYANTO, Arie Wahyu; PRAMANA, Setia. Multi-source satellite imagery and point of interest data for poverty mapping in East Java, Indonesia: Machine learning and deep learning approaches. Remote Sensing Applications: Society and Environment, v. 29, p. 100889, 2023. [↗](#)



Residents' houses on barren land, Tuban
Estimated Poverty: 16.23%



Surabaya densely populated residential areas with adequate accessibility
Estimated Poverty: 5.6%



Magetan sparsely populated houses in agricultural areas
Estimated Poverty: 10.55%



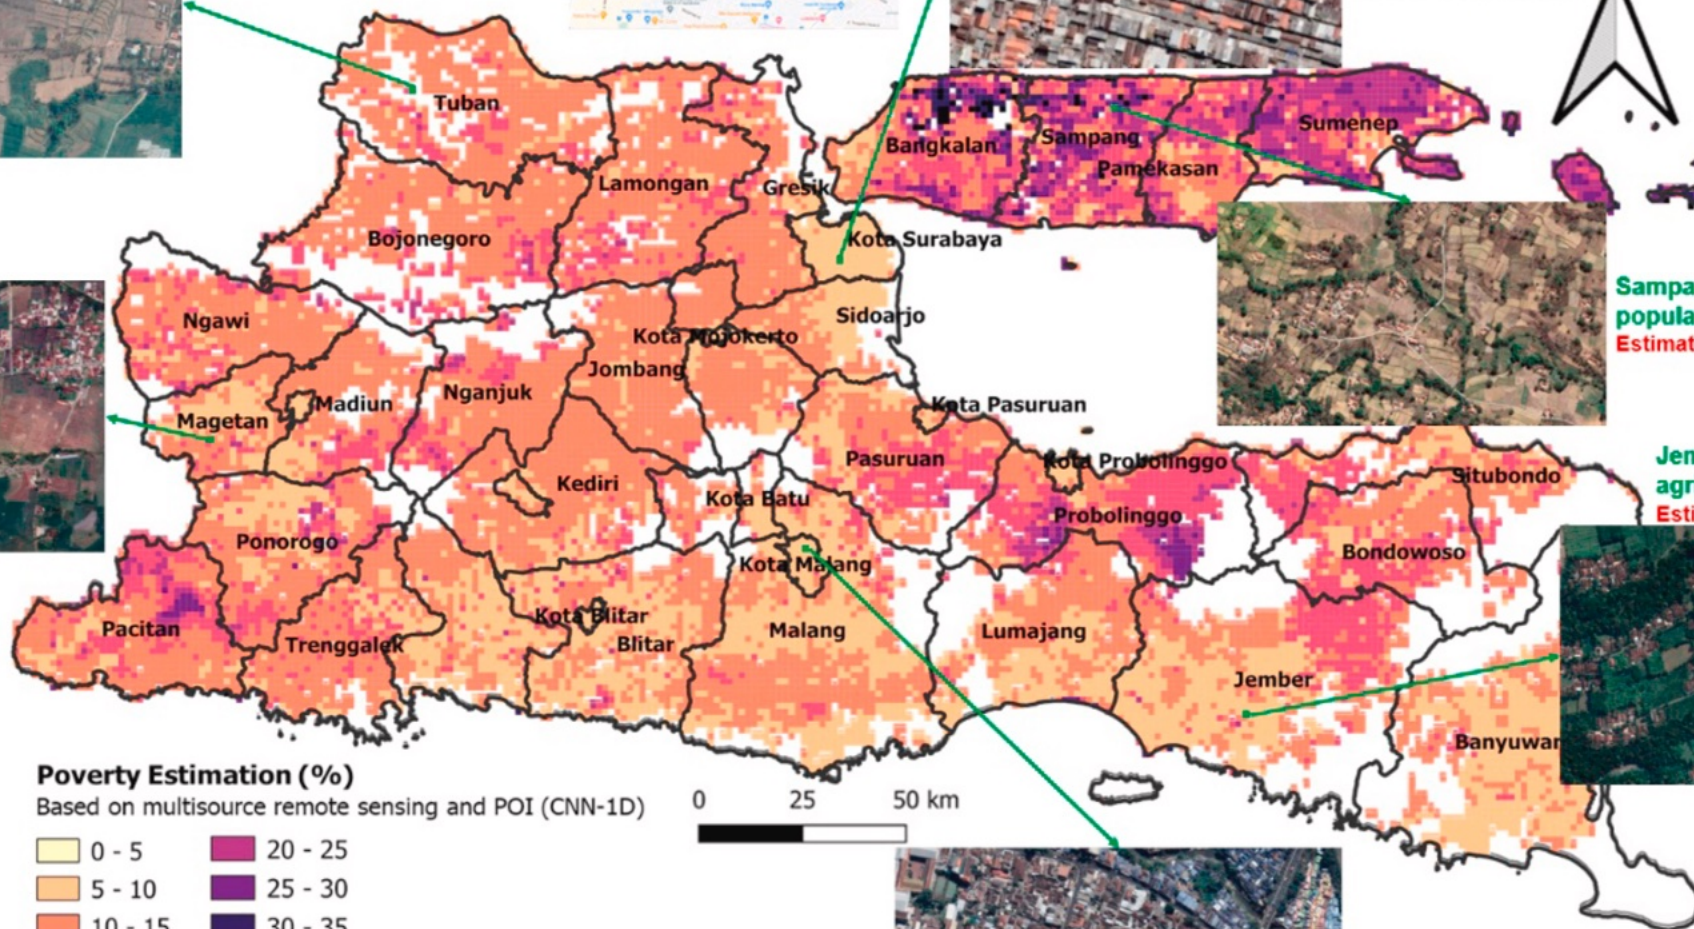
Sampang sparsely populated agricultural area
Estimated Poverty: 23.52%



Jember sparsely populated agricultural area
Estimated Poverty: 12.6%



Kota Malang urban area
Estimated Poverty: 5.7%




Poverty Estimation (%)

Based on multisource remote sensing and POI (CNN-1D)

0 - 5	20 - 25
5 - 10	25 - 30
10 - 15	30 - 35
15 - 20	35 - 40

0 25 50 km



Poverty Maps

Global Opportunity Lab [↗](http://3.15.84.96) - Demonstração: <http://3.15.84.96> [↗](#)

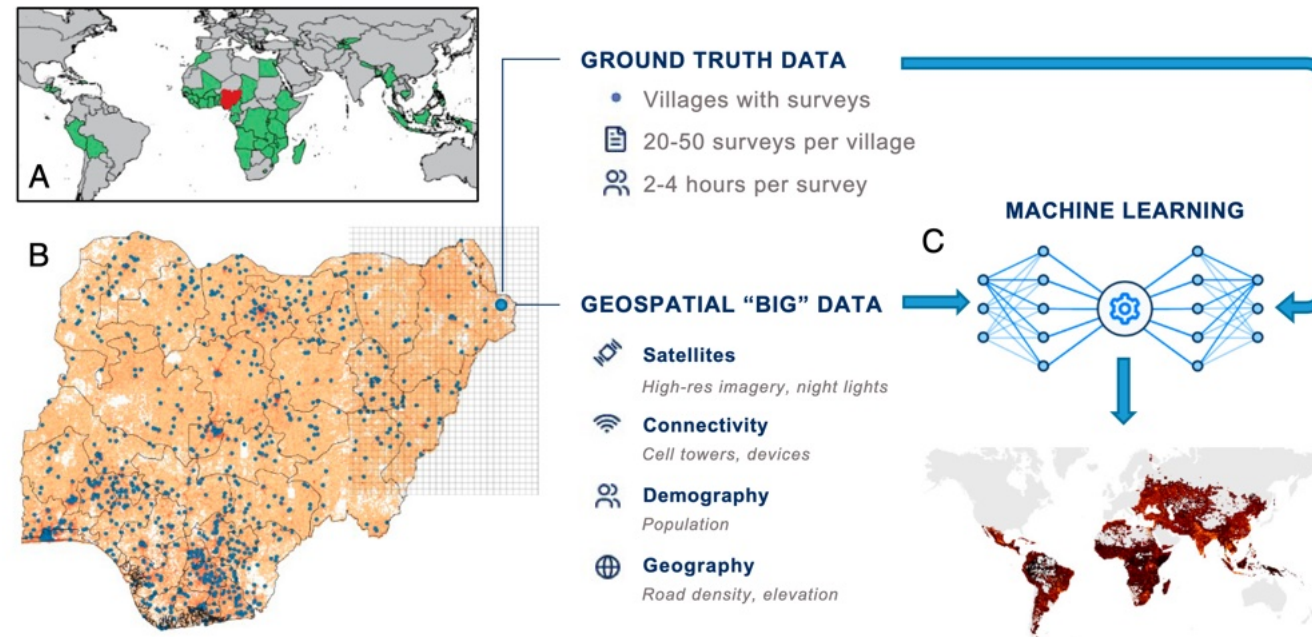



Fig. 2. Overview of approach. (A) Nationally representative household survey data are obtained from 56 different countries around the world. (B) In Nigeria, for example, there are 40,680 households surveyed in 899 unique survey locations ("villages"). Geospatial "big" data from satellites and other existing sensors are also sourced from each location. (C) These data are used to train a machine-learning algorithm that predicts microregional poverty from nontraditional data, even in regions where no ground-truth data exists.

Fonte da imagem: CHI, Guanghua et al. Microestimates of wealth for all low-and middle-income countries. Proceedings of the National Academy of Sciences, v. 119, n. 3, p. e2113658119, 2022.

Forest Carbon

- Conjunto de dados global que inclui estimativas do carbono florestal acima do solo
 - Altura das árvores
 - Cobertura do dossel
- Aplicações:
 - Contabilização de projetos de carbono
 - Reflorestamento
 - Monitoramento do desmatamento.


Demonstração e fonte da imagem: [Planet](#) 



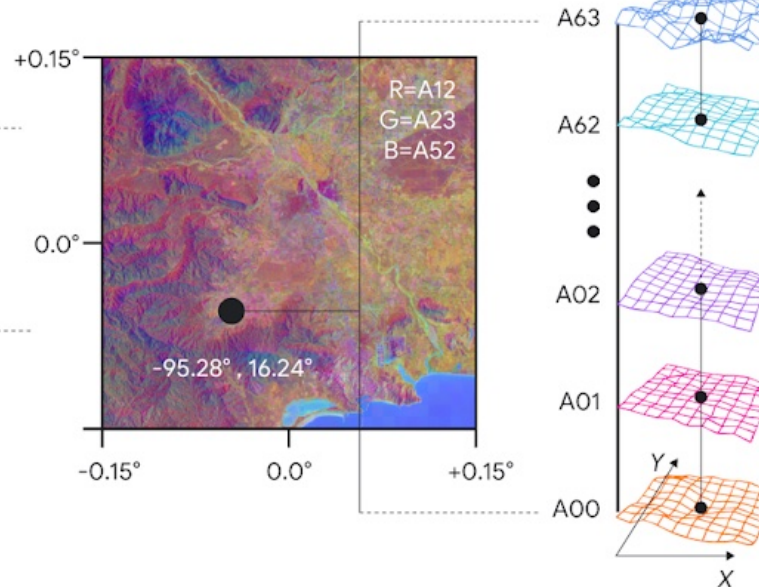
AlphaEarth Foundations

Digital Twin da superfície da Terra.


Global Embedding Field



Embedding Axes



Embedding Vector



Fonte da imagem: [Google DeepMind](#). Demo: [Demo](#)

AlphaEarth Foundations: Busca por Similaridade


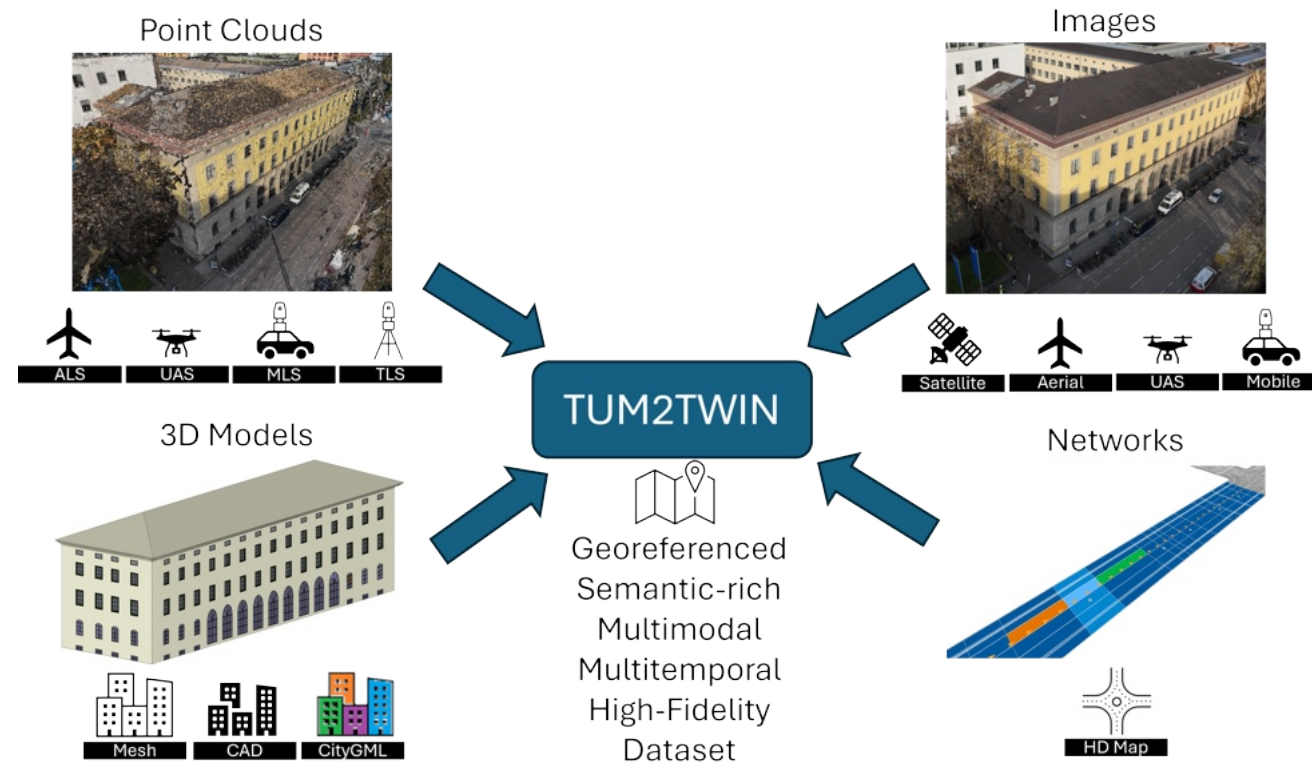


Imagem e Demo: [Google Earth Engine AI](#)

Point Cloud e LiDAR: <https://whu3d.com/>




Digital Twins



Fonte: WYSOCKI, Olaf et al. TUM2TWIN: Introducing the large-scale multimodal urban digital twin benchmark dataset. ISPRS Journal of Photogrammetry and Remote Sensing, v. 232, p. 810-830, 2026 [↗](#)

Digital Twins



Fonte: WYSOCKI, Olaf et al. TUM2TWIN: Introducing the large-scale multimodal urban digital twin benchmark dataset. ISPRS Journal of Photogrammetry and Remote Sensing, v. 232, p. 810-830, 2026 [↗](#)

Escalar a IA em larga escala exige um *design colaborativo* de sistemas de dados e modelos inteligentes.

Co-Design

Em várias aplicações, objetos de interesse são raros em dados massivos.

- Como encontrar uma agulha num palheiro.

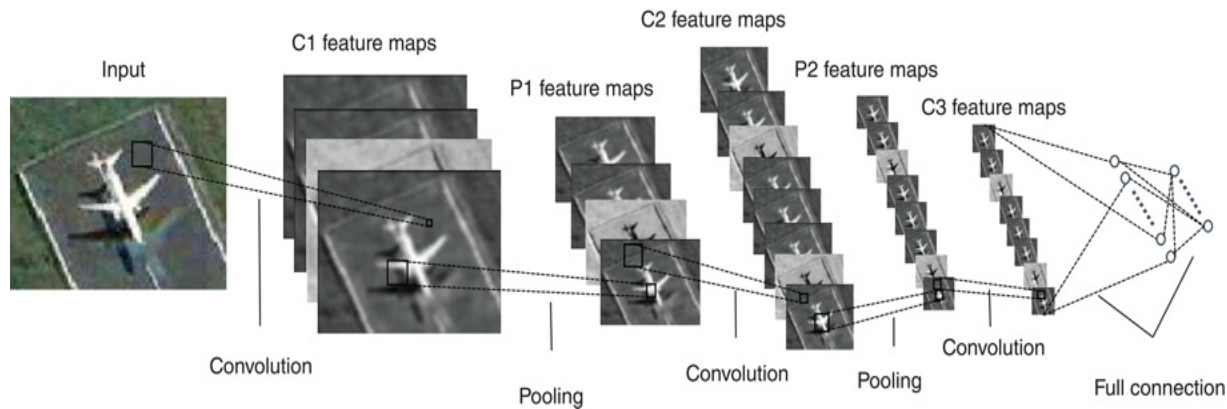
Exemplo: Encontrar turbinas eólicas em imagens de satélite.

- Objeto difícil de descrever em SQL.
- Fácil de conseguir exemplos (imagens).



Exemplo

Podemos *anotar* alguns dados e treinar um classificador (e.g., CNN) com IA.



Com o classificador treinado, podemos aplicá-lo ao **banco de dados completo** para encontrar os objetos de interesse.



**Considere executar uma CNN *1 bilhão* de
patches de imagens...**

(Vai por mim. Vai demorar)


Co-Design: Usando Índices

A busca tradicional exige escanear todo o banco de dados.

- Ineficiente
- Ignora o potencial do DBMS.

Co-design de índices multidimensionais e modelos de IA.

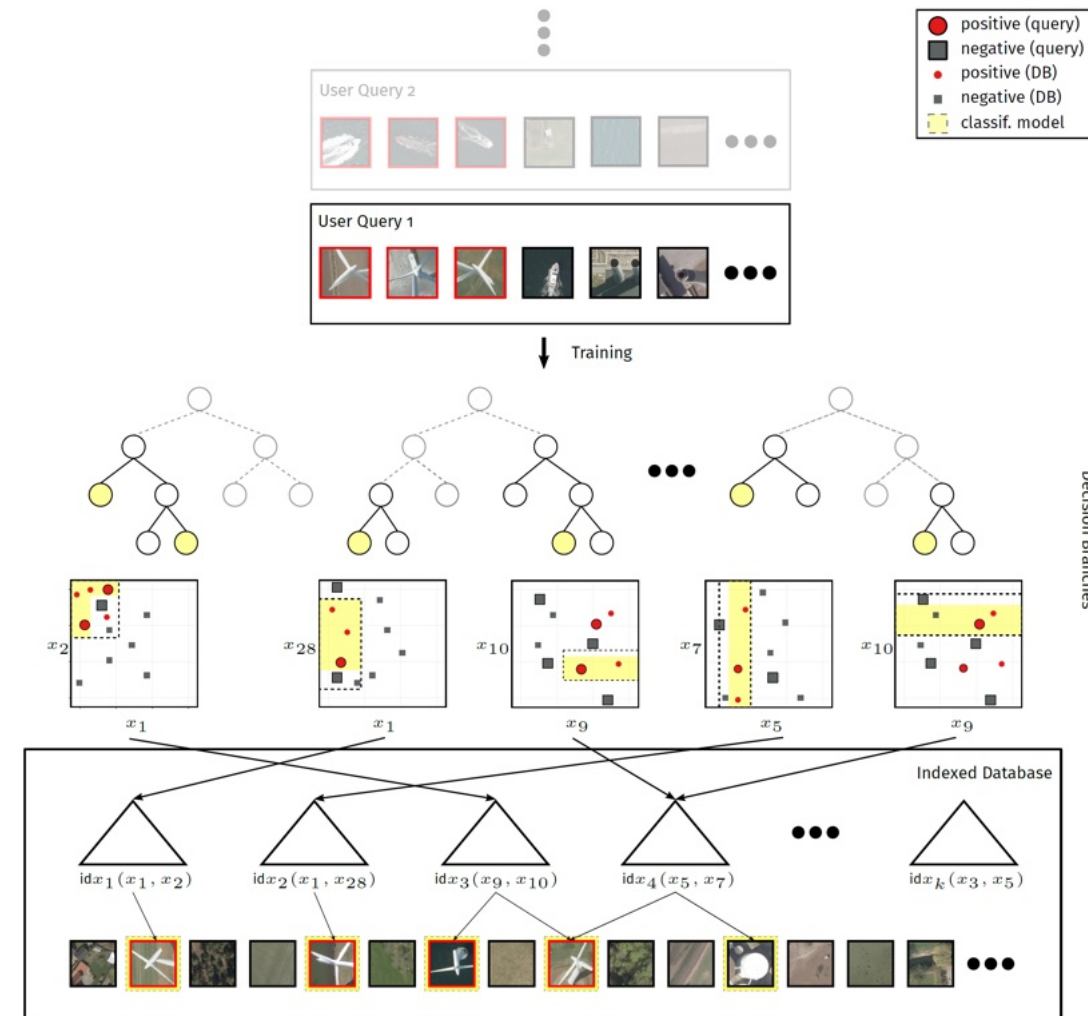
Fonte: LÜLF, Christian et al. [Fast Search-by-Classification for Large-Scale Databases Using Index-Aware Decision Trees and Random Forests](#). Proceedings of the VLDB Endowment, v. 16, n. 11, p. 2845-2857, 2023. [🔗](#)



Co-Design: Usando Índices

1. Índices são pré-definidos sobre pequenos subconjuntos de *features*.
2. *Decision Branches* são treinadas nestes subconjuntos.
3. Durante a inferência, os índices são utilizados, evitando *full scan*.

Fonte: LÜLF, Christian et al. Fast Search-by-Classification for Large-Scale Databases Using Index-Aware Decision Trees and Random Forests. Proceedings of the VLDB Endowment, v. 16, n. 11, p. 2845-2857, 2023. 



Co-Design: Usando Índices

Melhor desempenho de classificação em comparação com **Random Forest**.

Muito mais **~200 vezes mais rápido**.

Fonte: LÜLF, Christian et al. Fast search-by-classification for large-scale databases using index-aware decision trees and random forests. arXiv preprint arXiv:2306.02670, 2023. [↗](#)

Model	T_{train}	T_{query}	T_{total}	F_1 -score
DBranch	0.398	1.047	1.445	0.833
DTree	0.855	1,043.433	1,044.288	0.829
DBEns	0.993	5.666	6.658	0.914
RForest	0.274	1,319.688	1,319.961	0.904
ExTrees	0.122	1,332.026	1,332.148	0.950











Perspectivas Futuras







"In the next five years, 170 million jobs are projected to be created and 92 million jobs to be displaced (...)."

Fonte: [The Future of Jobs - Report 2025](#) 

Como se preparar para **posições de trabalho** e **problemas de pesquisa** que *ainda não existem?*

Top 10 fastest growing skills by 2030

1.  AI and big data
2.  Networks and cybersecurity
3.  Technological literacy
4.  Creative thinking
5.  Resilience, flexibility and agility
6.  Curiosity and lifelong learning
7.  Leadership and social influence
8.  Talent management
9.  Analytical thinking
10.  Environmental stewardship

 Cognitive skills  Self-efficacy  Working with others  Management skills  Technology skills  Ethics

Note: The skills selected by surveyed organizations to be increasing most rapidly in importance by 2030.

Source: World Economic Forum. (2025). *Future of Jobs Report 2025*.

Muito Obrigado!