Climate Change AI

Climate Change AI Virtual Summer School 2026





Climate Change AI

MINISTRY OF
SCIENCE, TECHNOLOGY
AND INNOVATION

IA para florestas

Contribuições da IA para o monitoramento da vegetação

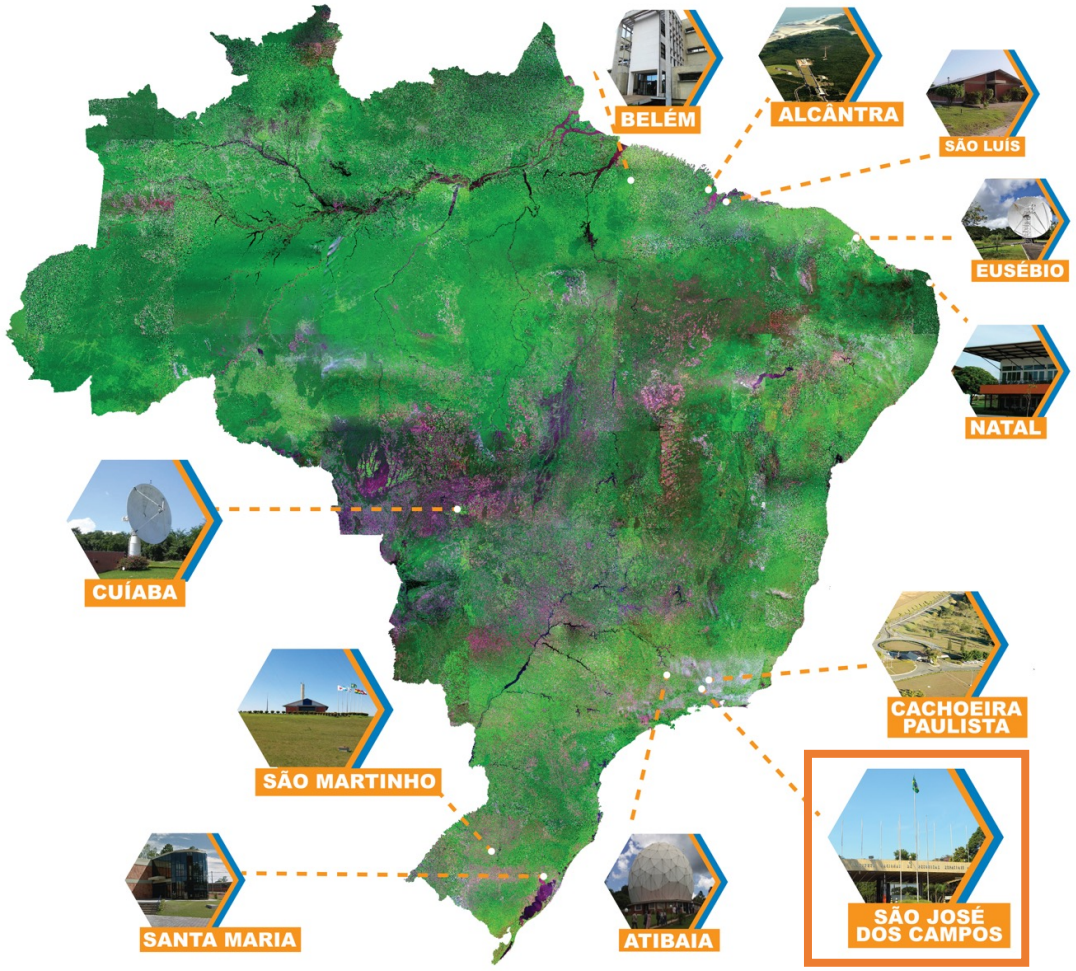
Silvana Amaral

Coordenadora adjunta da Divisão de Projetos Estratégicos 1 – DIPE 1
Divisão de Observação da Terra e Geoinformática – DIOTG
Instituto Nacional de Pesquisas Espaciais – INPE

São José dos Campos, SP, 4 de agosto de 2026



De onde eu venho...



627 servidores, ~360 estudantes, ~460 terceirizados

Ciências espaciais e atmosféricas



Tempo e clima



Tecnologia espacial



Ciências do sistema terrestre



Rastreio e controle de satélites



Observação da Terra



Laboratórios associados



Laboratório de Integração e Testes



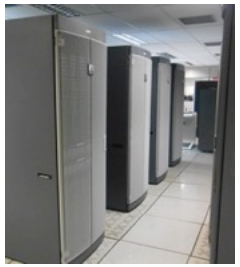
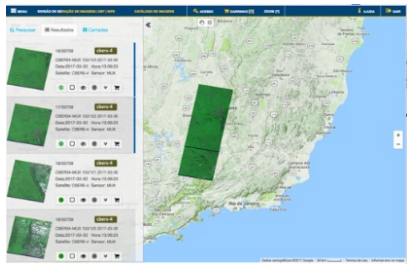
Slide: Kampel (2025)

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO

O que fazemos






SPRING · TerraLib · TerraView · TerraME · GeoDMA · TerraHidro · TerraAmazon · TerraMA²



SBSR
XXI SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO

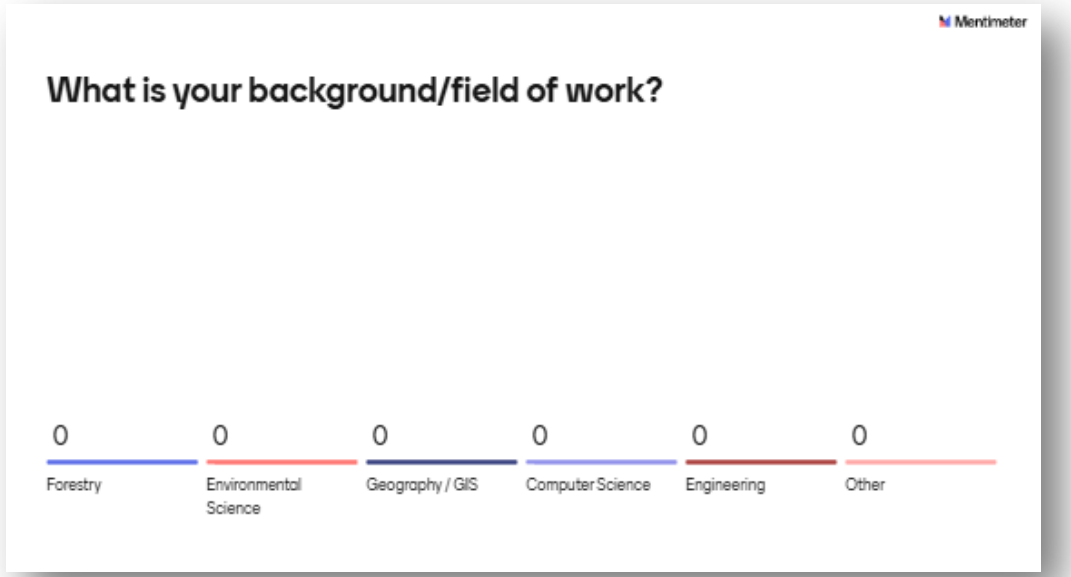
GEOINFO
May 19 to 21, 2025
INPE, São José dos Campos, SP, Brazil

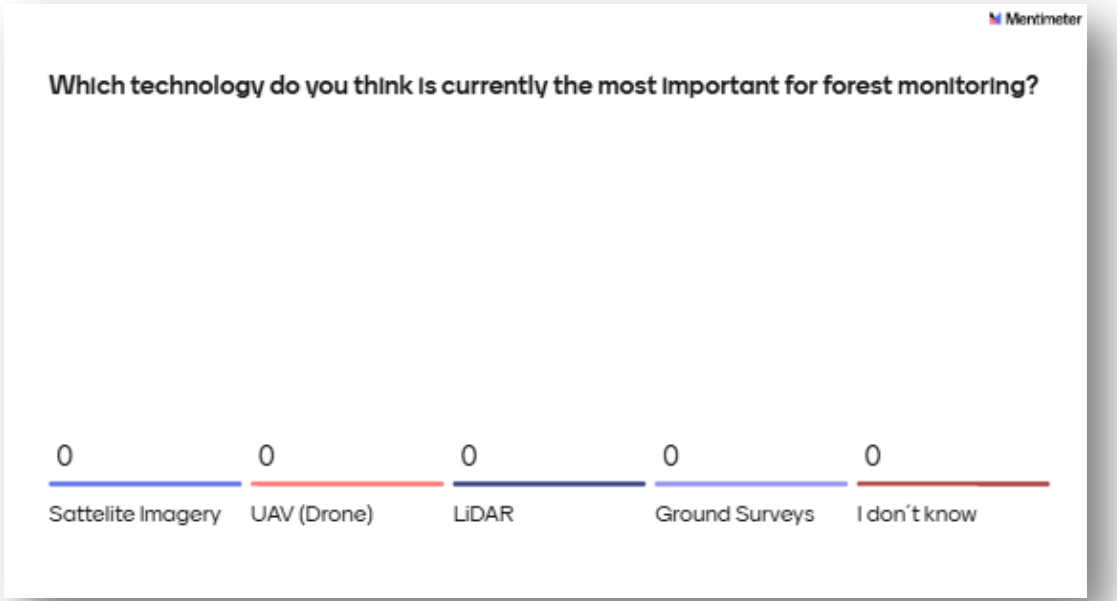
8º Simpósio de Geotecnologias no Pantanal

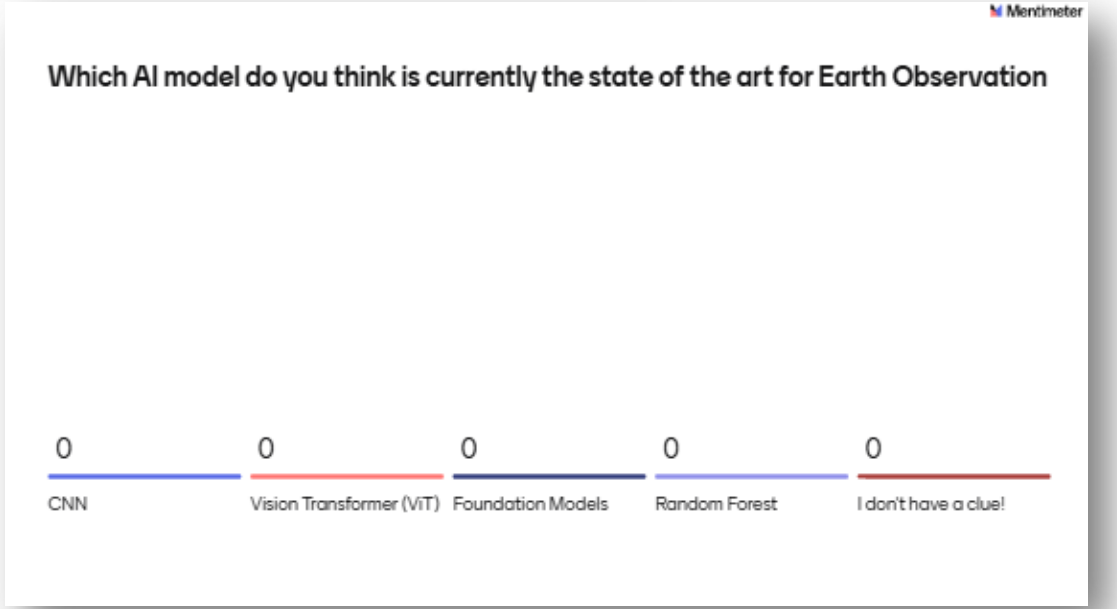
Slide: Kampel (2025)

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO

menti.com
5859 8794









Por que o monitoramento florestal é importante?

Como a IA tem sido usada em aplicações florestais?

Evolução da IA para o monitoramento florestal

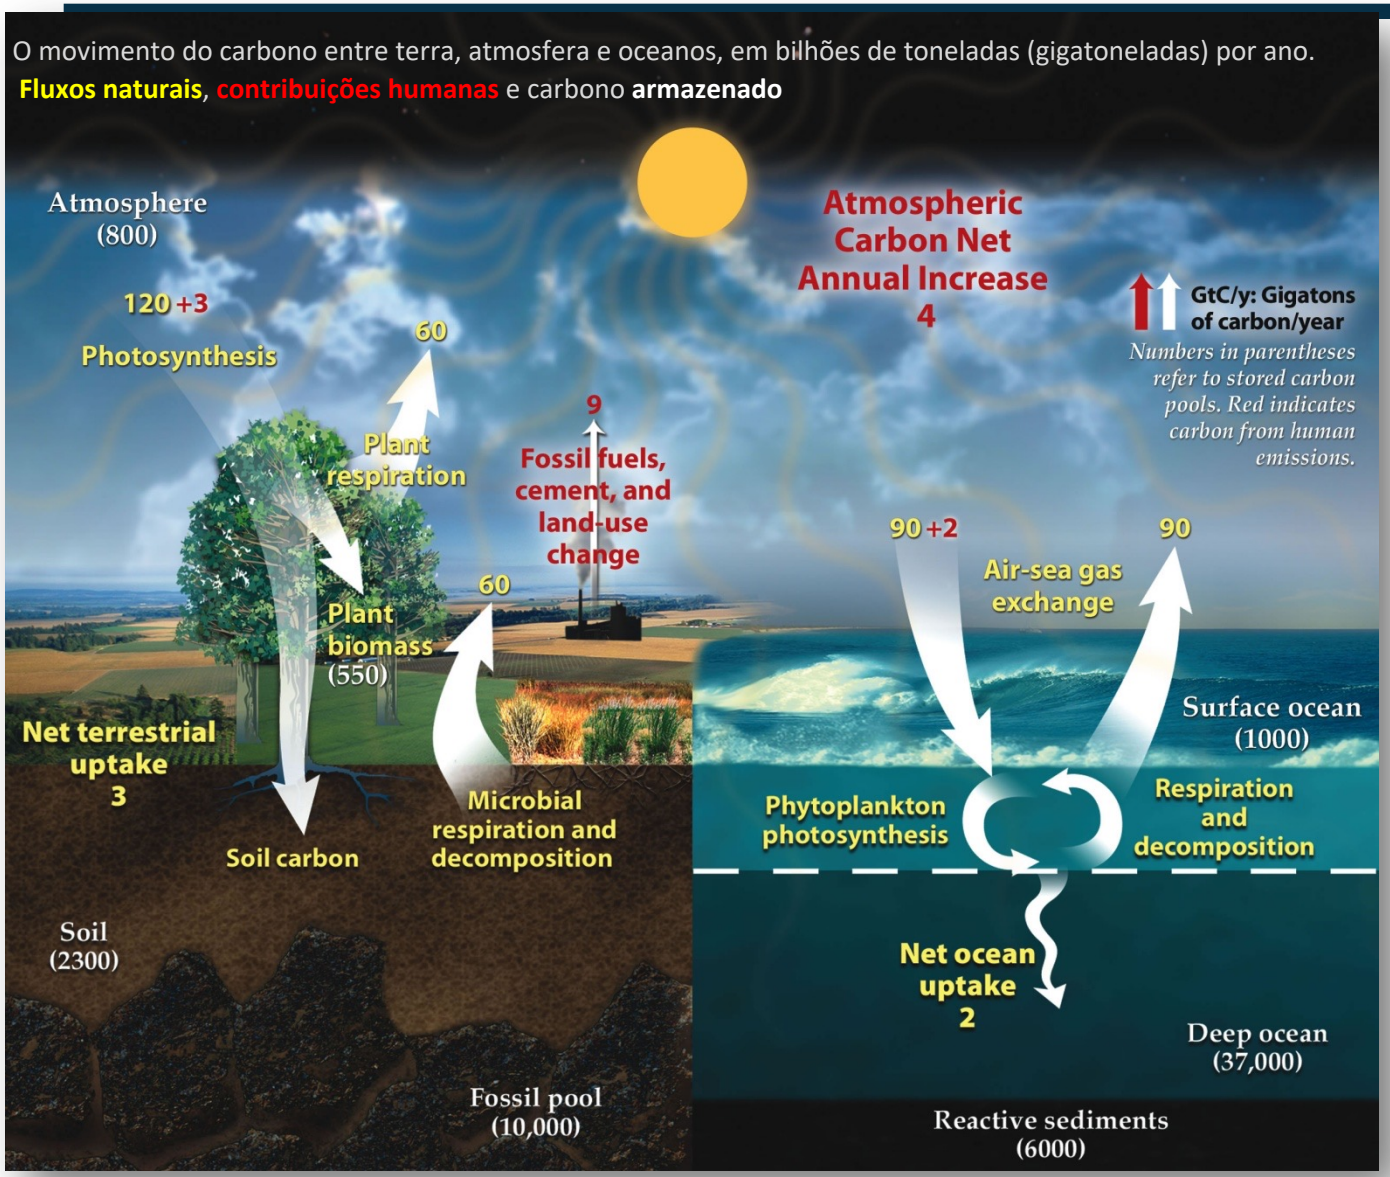
Os fundamentos (conceitos) dos modelos de IA mais usados

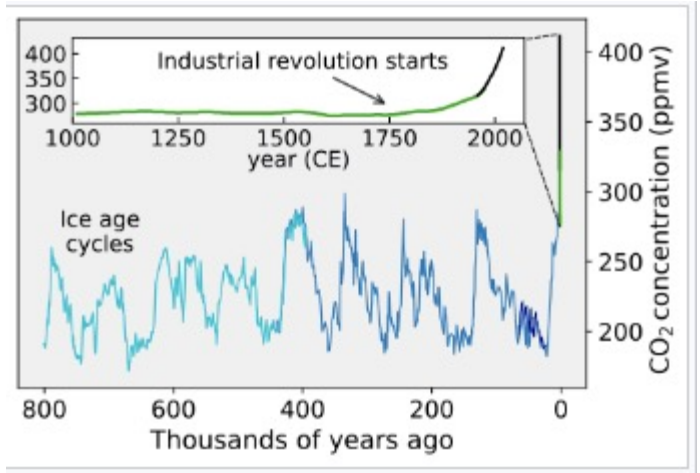
Exemplos: classificação de espécies arbóreas, avaliação de incêndios florestais, estimativa de biomassa e carbono

A evolução do uso da IA no monitoramento da vegetação nos biomas brasileiros

“O ciclo do carbono”

https://earthobservatory.nasa.gov/features/CarbonCycle

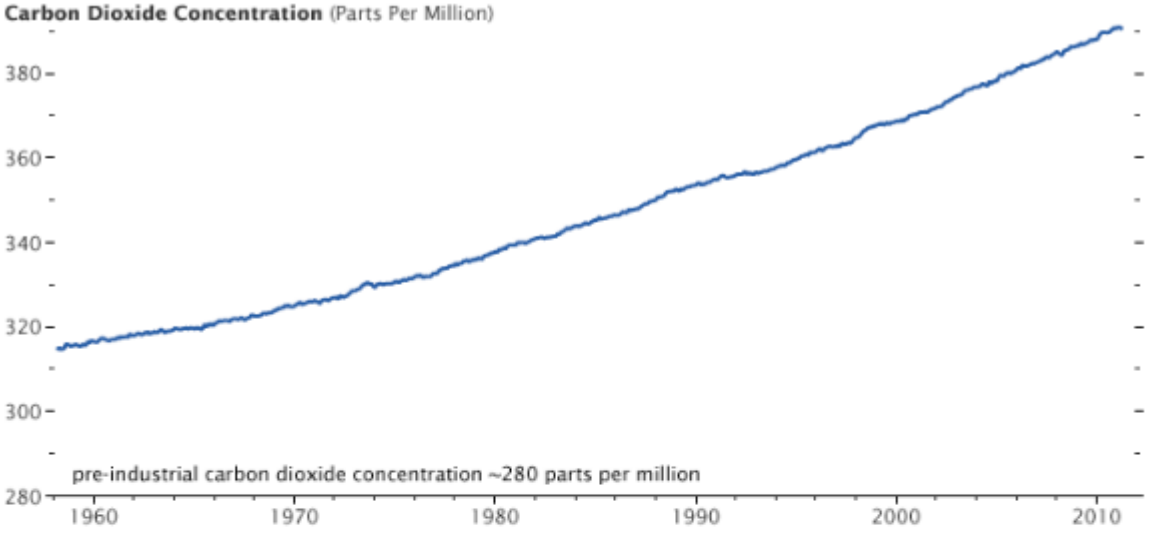


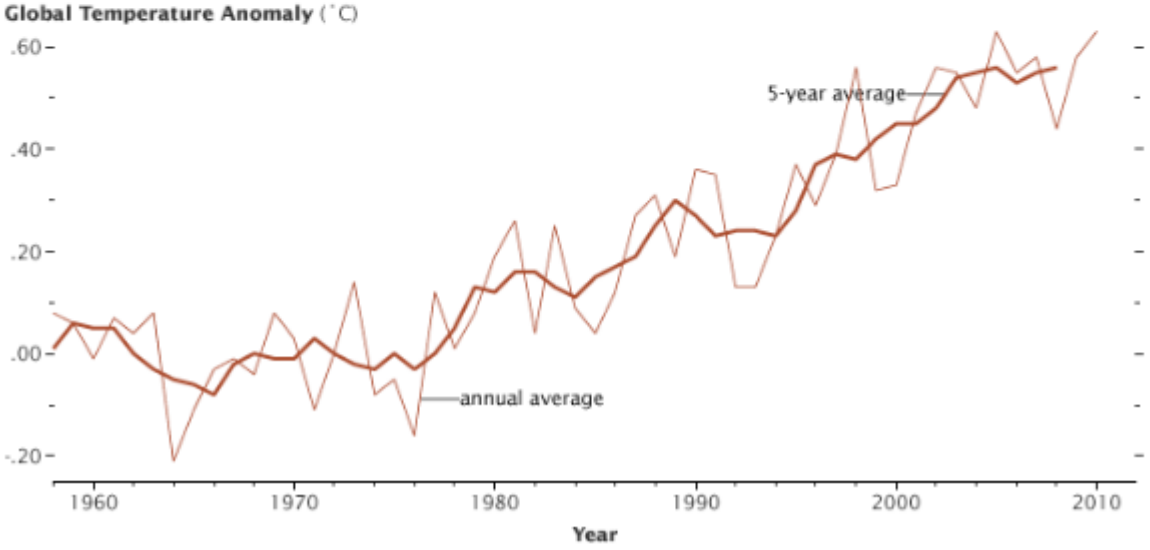


Concentrações de CO_2 nos últimos 800.000 anos, medidas em testemunhos de gelo (azul/verde) e diretamente (preto)

“O ciclo do carbono”

https://earthobservatory.nasa.gov/features/CarbonCycle



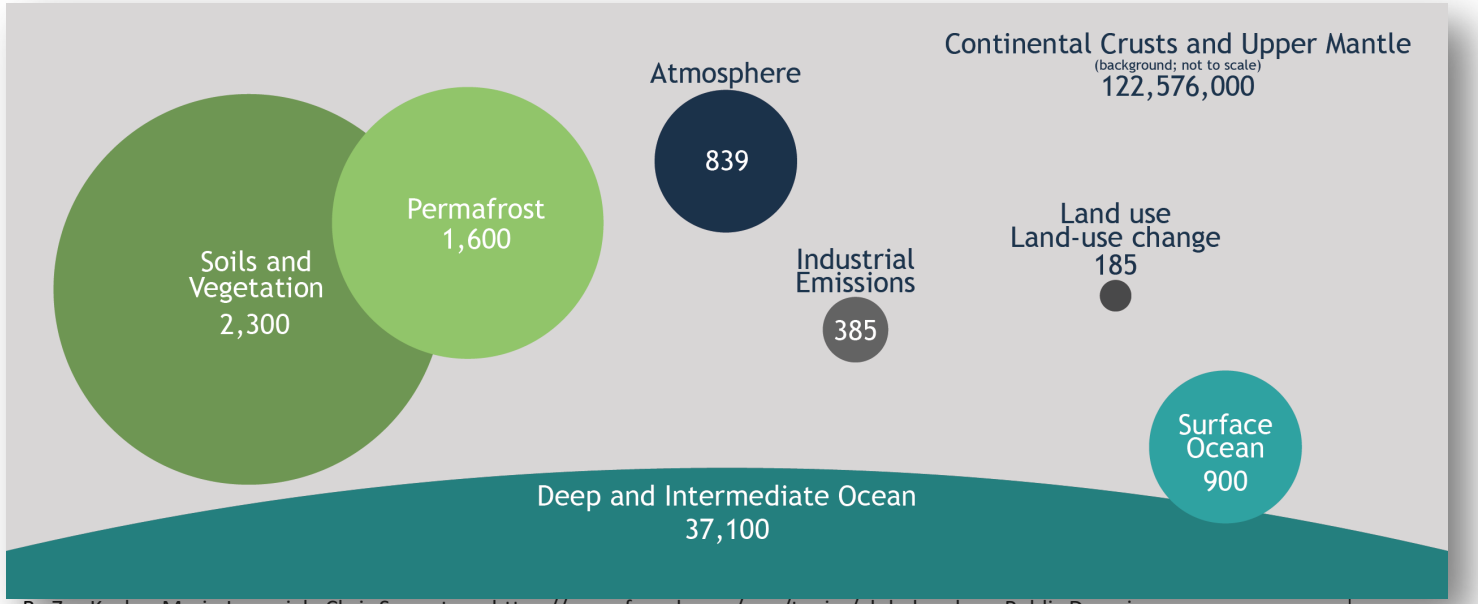


O dióxido de carbono é o gás que define a temperatura.

O dióxido de carbono controla a quantidade de vapor d’água na atmosfera e, portanto, a intensidade do efeito estufa.

Somos feitos de carbono (e precisamos dele)!
Mas…
essa necessidade também está intimamente ligada a um dos problemas mais graves que enfrentamos hoje:
a mudança climática global.

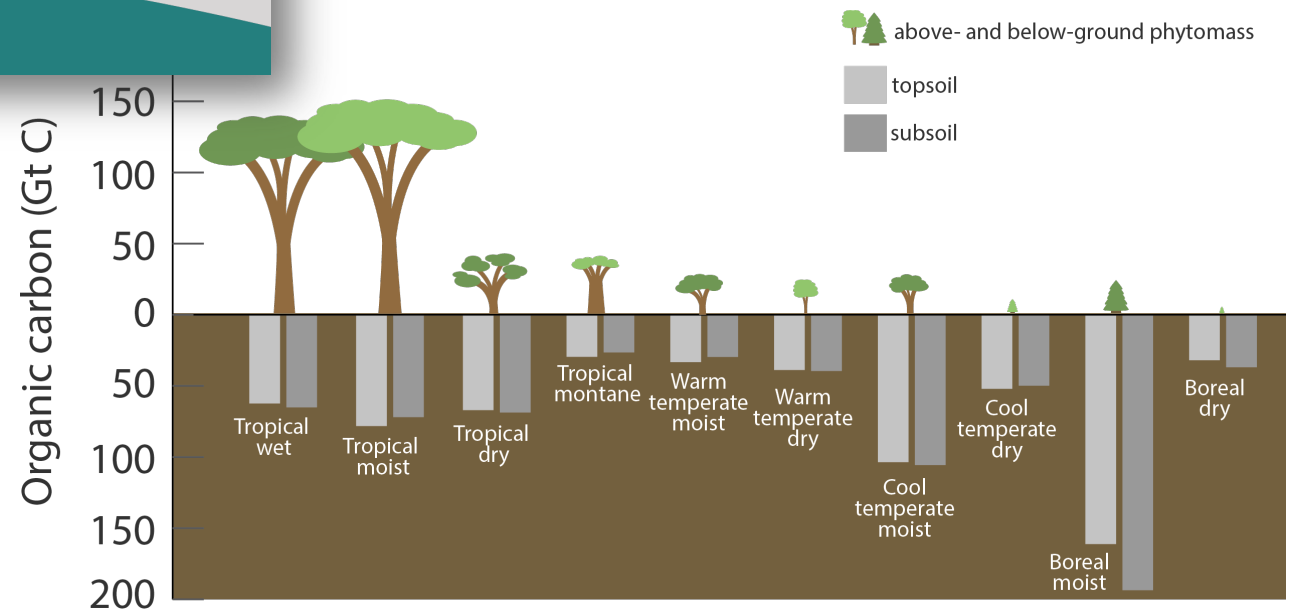
O estoque de carbono



By Zac Kayler, Maria Janowiak, Chris Swanston - https://www.fs.usda.gov/ccrc/topics/global-carbon, Public Domain, https://commons.wikimedia.org/w/index.php?curid=95324208

Tamanhos relativos (em gigatoneladas) dos principais reservatórios de carbono da Terra.

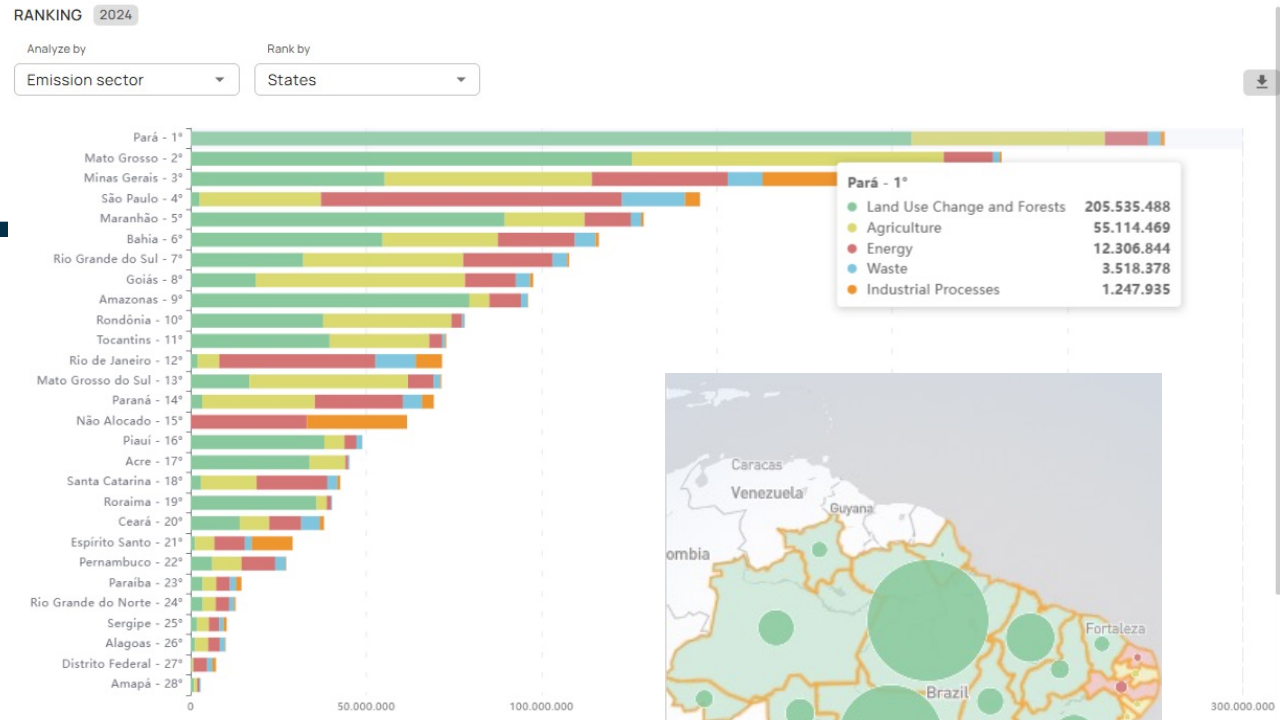
Quantidade de carbono armazenada nos diversos ecossistemas terrestres (em gigatoneladas).

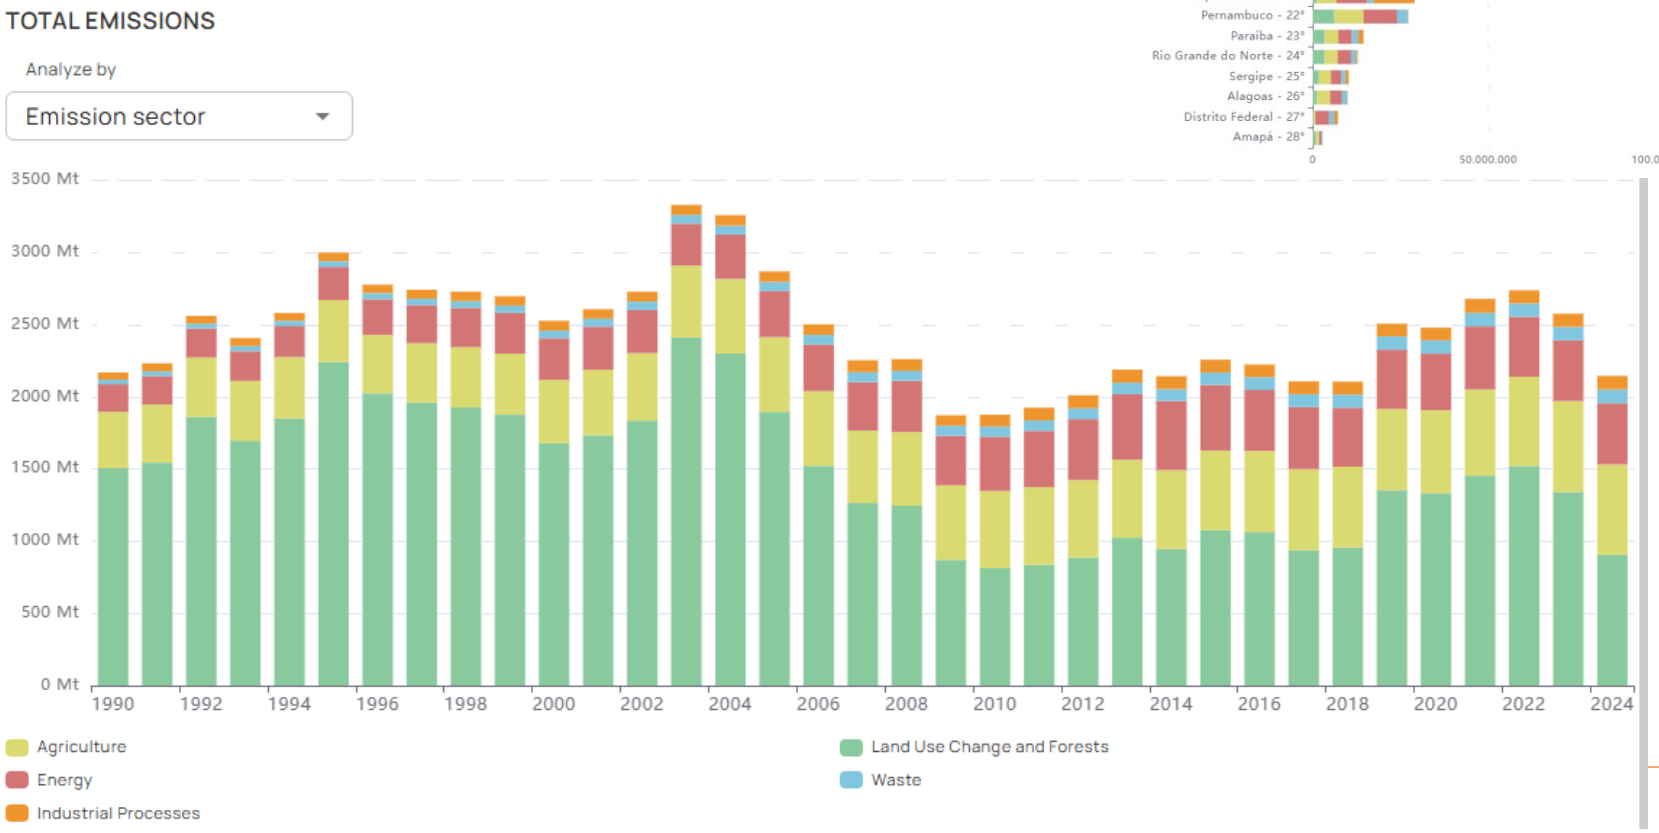


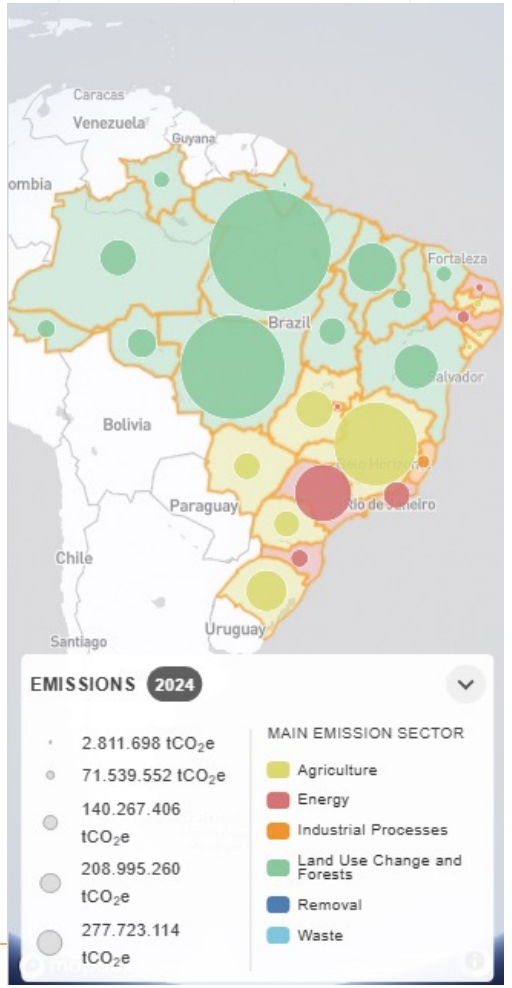
By Zac Kayler, Maria Janowiak, Chris Swanston - https://www.fs.usda.gov/ccrc/topics/global-carbon, Public Domain, https://commons.wikimedia.org/w/index.php?curid=95677627

Emissões brutas do Brasil por setor

https://plataforma.seeg.eco.br/

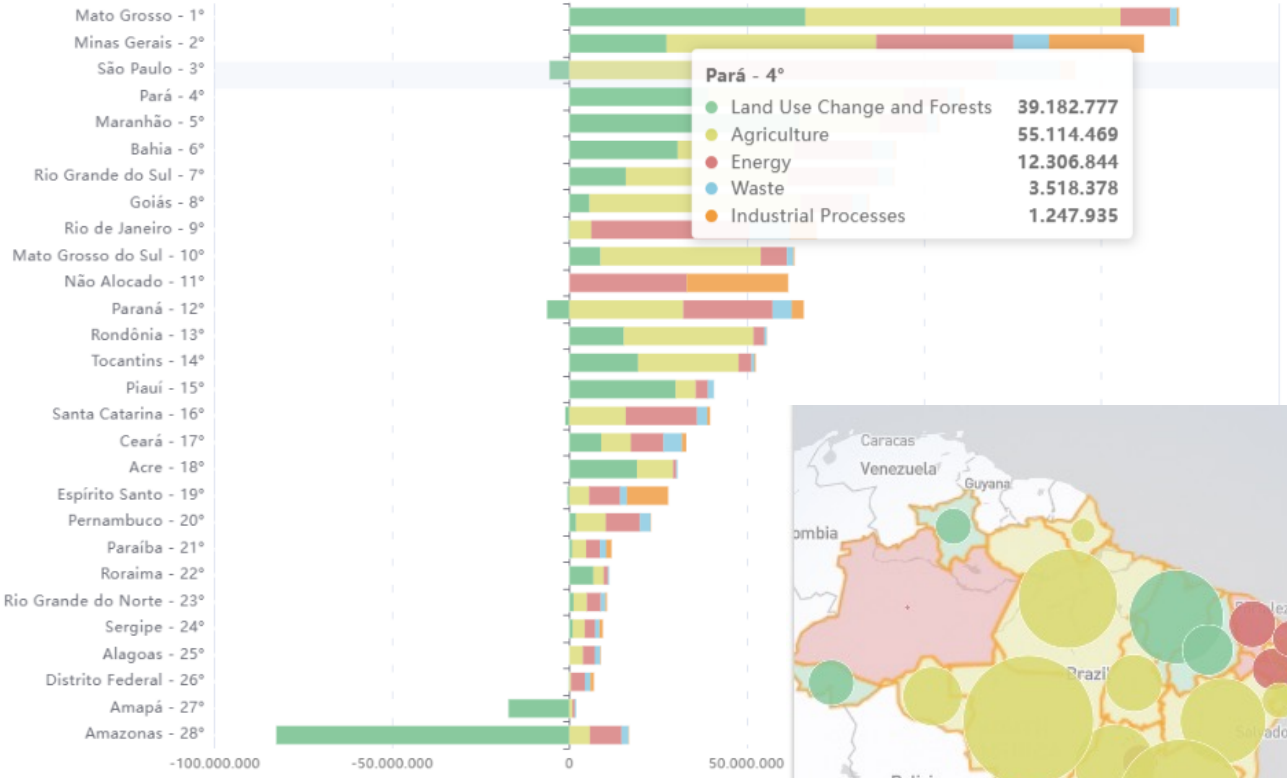


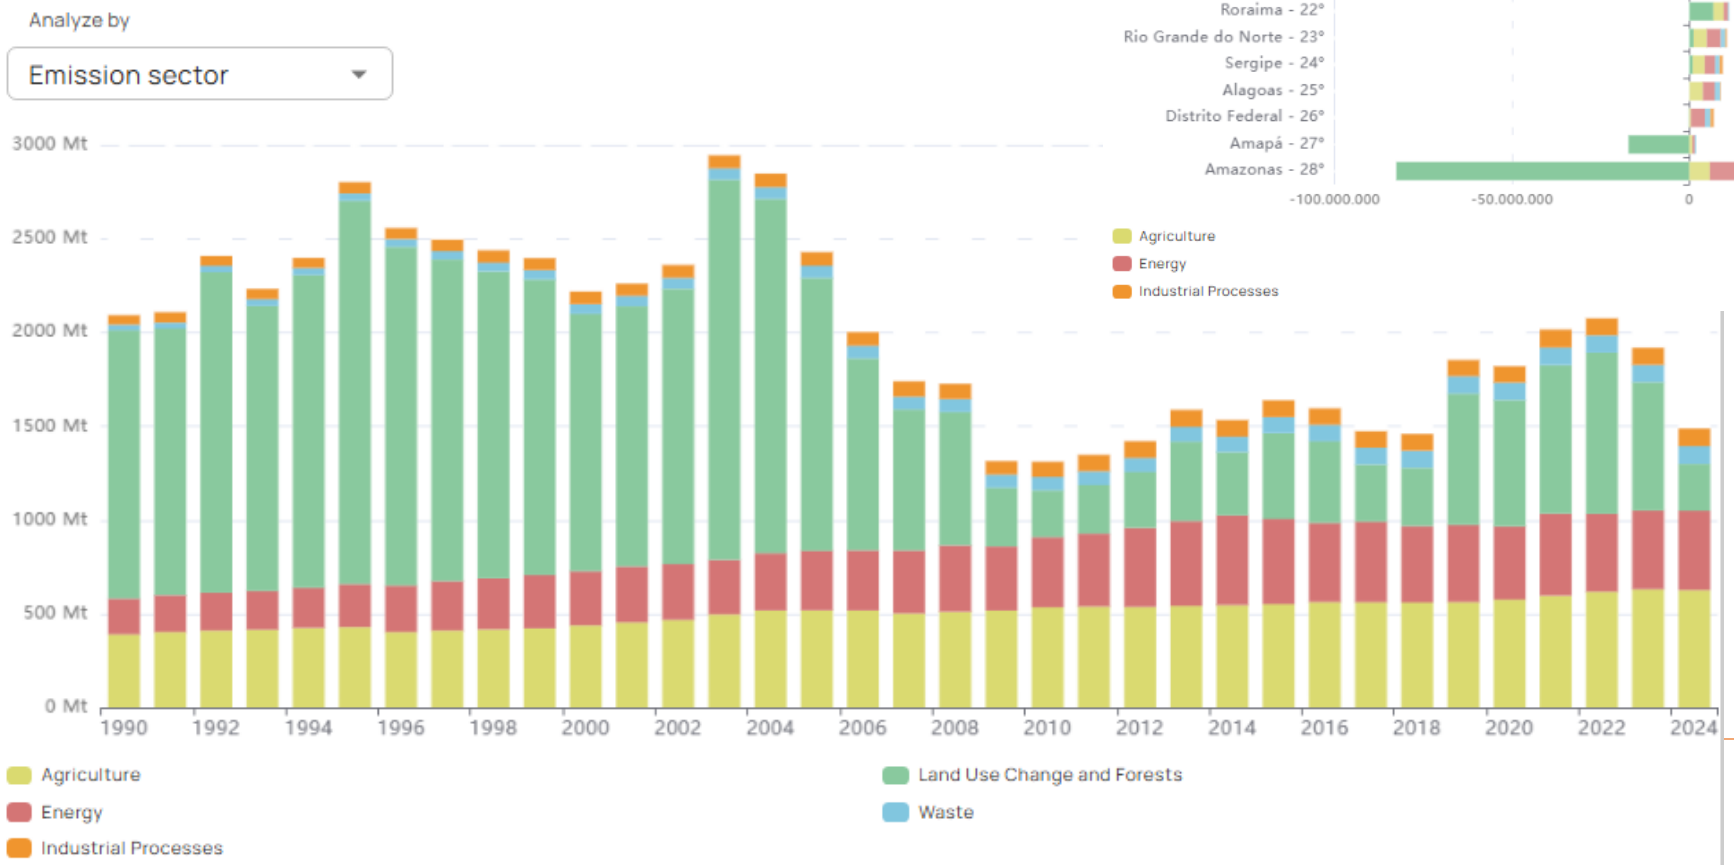


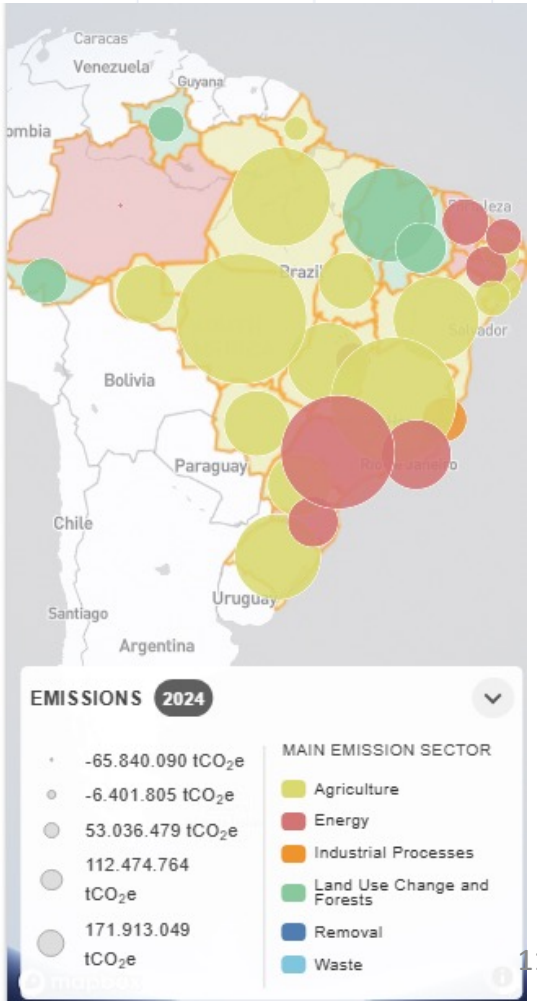


Emissões líquidas do Brasil p

https://plataforma.seeg.eco.br/







Climate Change 2022: Impacts, Adaptation and Vulnerability

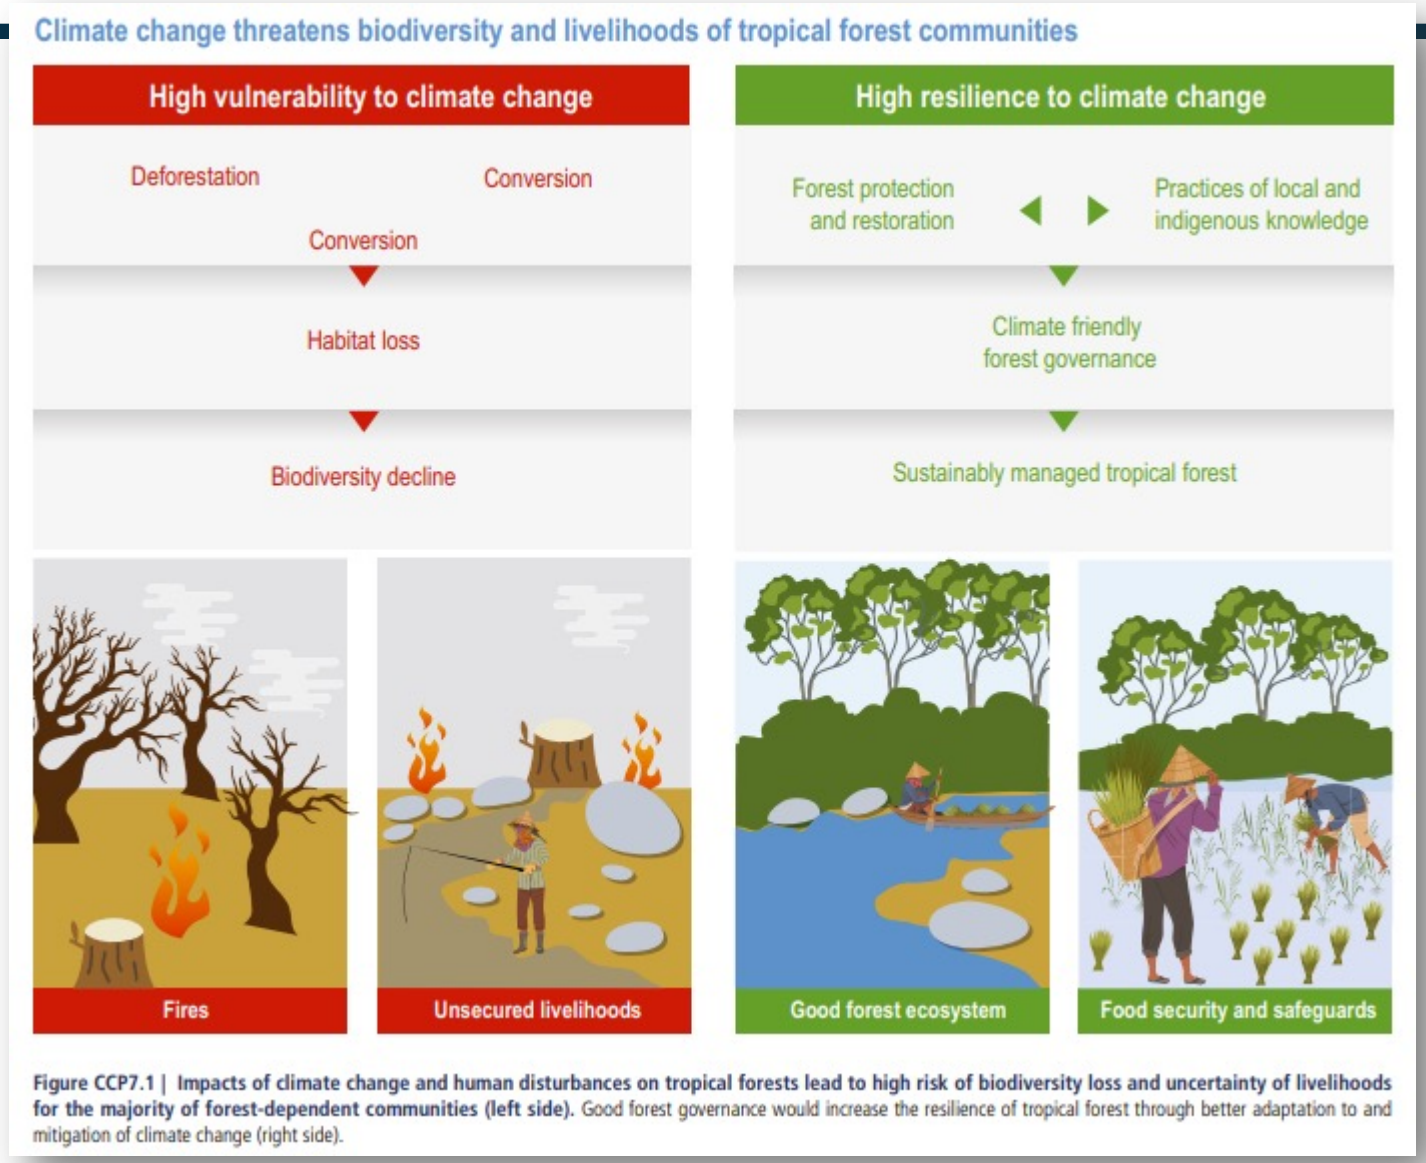


Figure CCP7.1 | Impacts of climate change and human disturbances on tropical forests lead to high risk of biodiversity loss and uncertainty of livelihoods for the majority of forest-dependent communities (left side). Good forest governance would increase the resilience of tropical forest through better adaptation to and mitigation of climate change (right side).

Mais de 420 milhões de ha de floresta foram perdidos pelo desmatamento entre 1990 e 2020;

Mais de 90% dessa perda ocorreu em áreas tropicais,

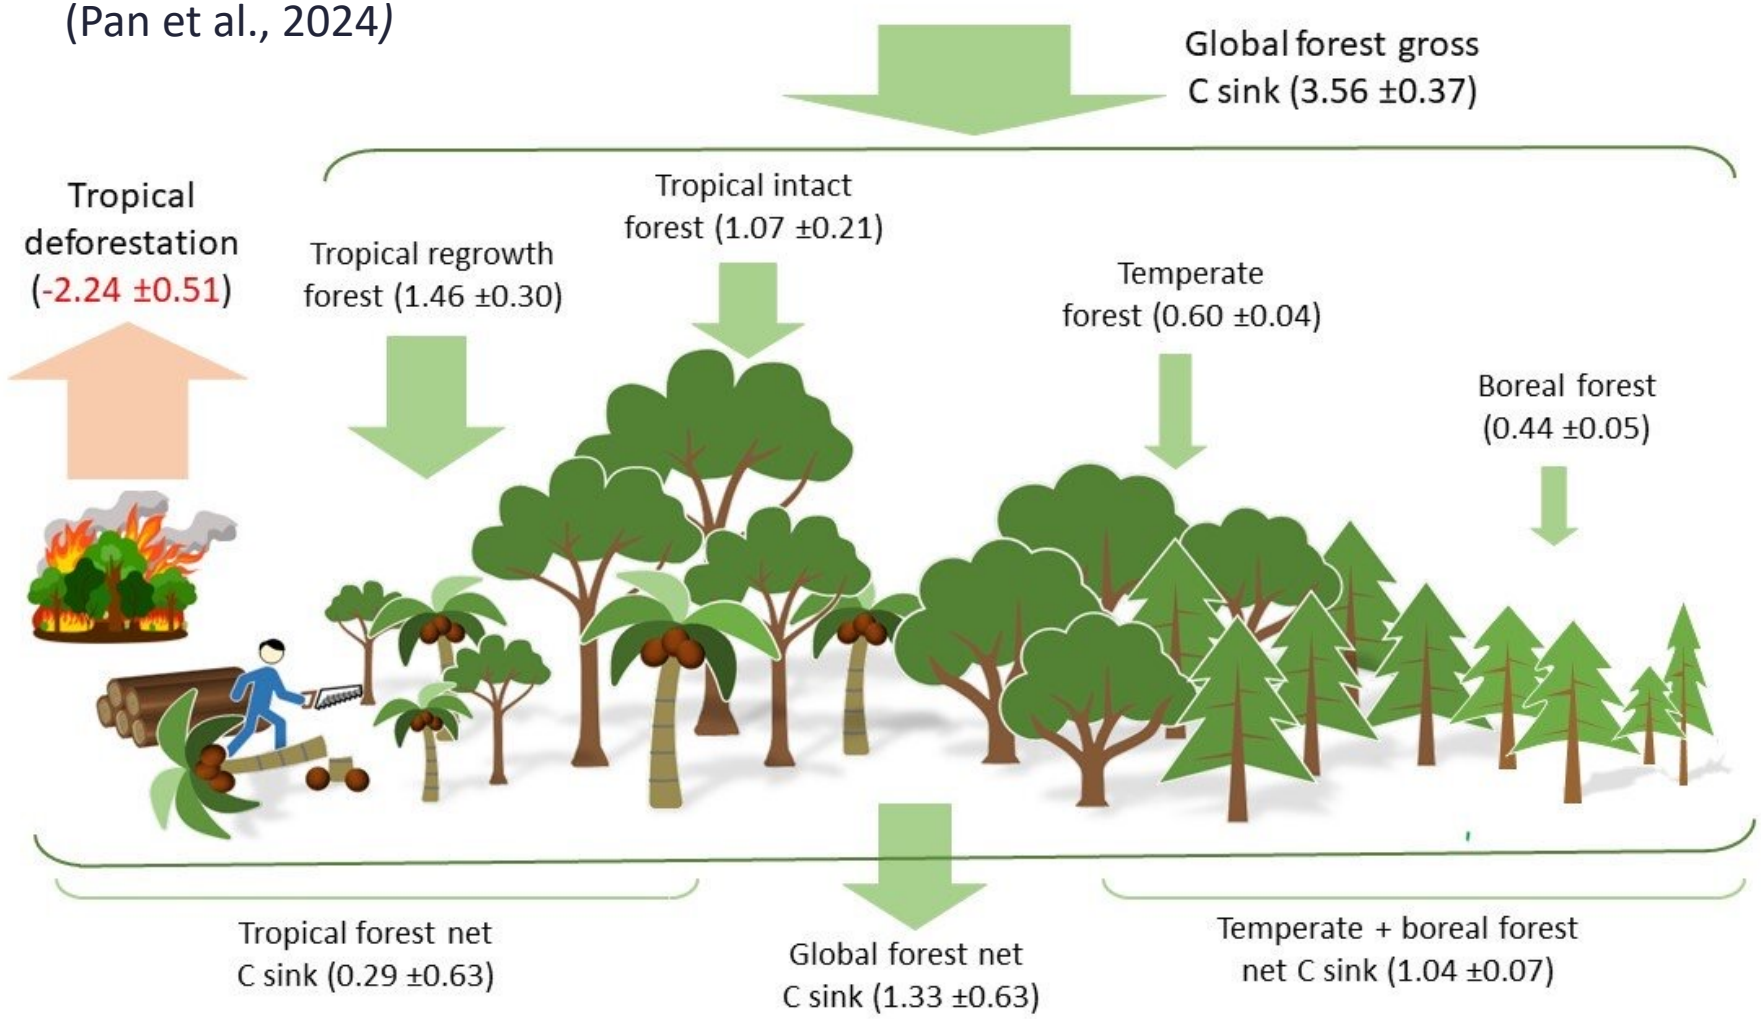
Ameaçando a biodiversidade, os serviços ambientais, os meios de vida das comunidades florestais e a resiliência a choques climáticos

(Ometto et al., 2022)
IPCC AR6, CCP7 sobre florestas tropicais

https://www.ipcc.ch/report/ar6/wg2/downloads/report/IPCC_AR6_WGII_CCP7.pdf

Por que monitorar o desmatamento e a vegetação?

O persistente sumidouro de carbono florestal mundial
(Pan et al., 2024*)*



Para proteger o sumidouro de carbono**, são necessárias políticas de gestão territorial que limitem o desmatamento,** promovam a restauração florestal e melhorem as práticas de exploração madeireira

Sumidouros e fontes de carbono das florestas do mundo (Pg C ano^{-1}), taxa média anual de 1990 a 2019.

Por que monitorar o desmatamento e a vegetação?

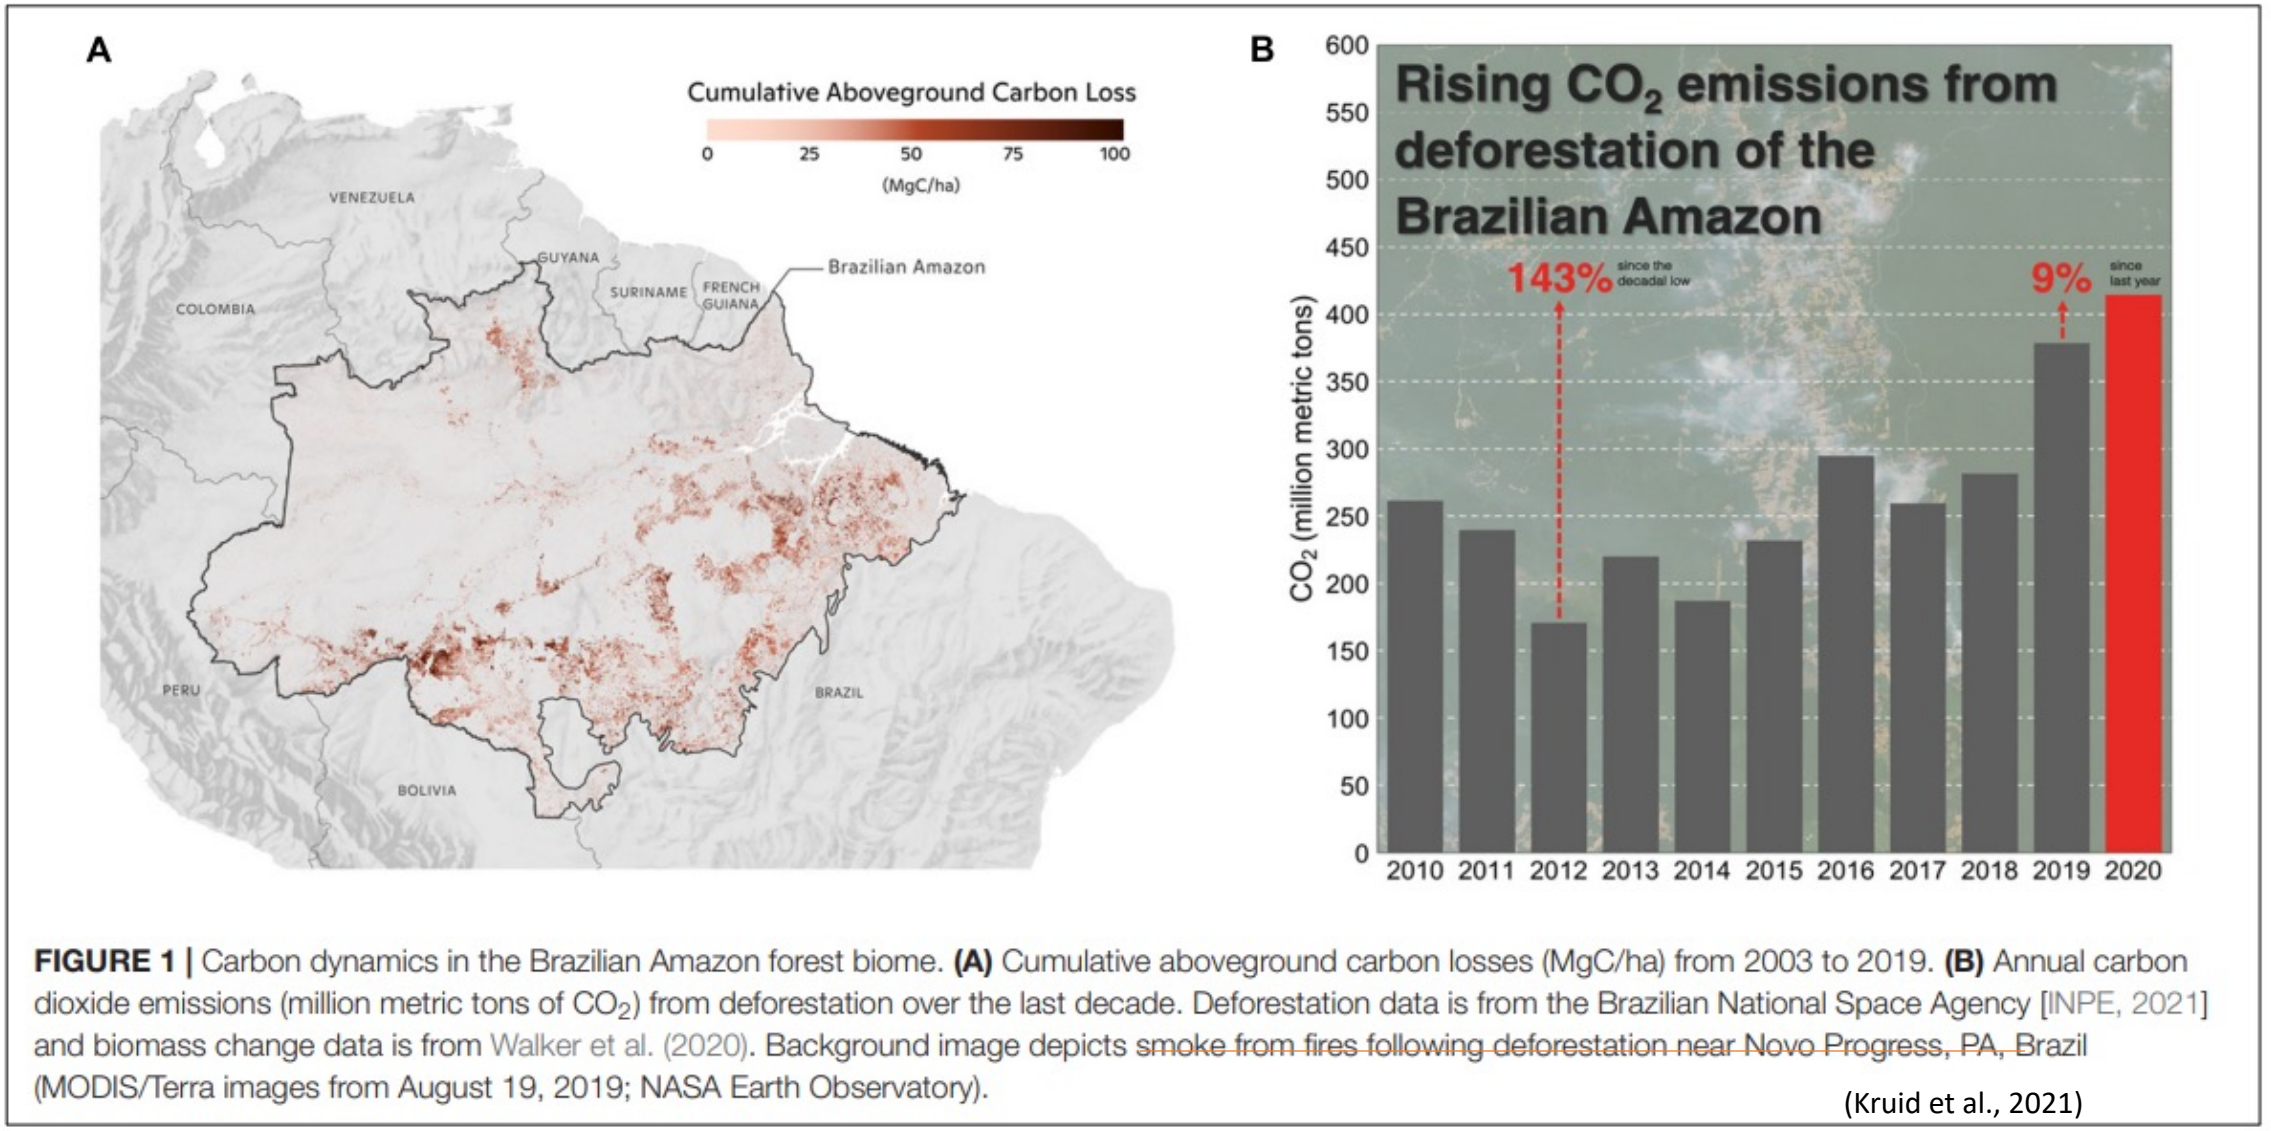


FIGURE 1 | Carbon dynamics in the Brazilian Amazon forest biome. **(A)** Cumulative aboveground carbon losses (MgC/ha) from 2003 to 2019. **(B)** Annual carbon dioxide emissions (million metric tons of CO_2) from deforestation over the last decade. Deforestation data is from the Brazilian National Space Agency [INPE, 2021] and biomass change data is from Walker et al. (2020). Background image depicts smoke from fires following deforestation near Novo Progress, PA, Brazil (MODIS/Terra images from August 19, 2019; NASA Earth Observatory).

(Kruid et al., 2021)

Por que monitorar o desmatamento e a vegetação?

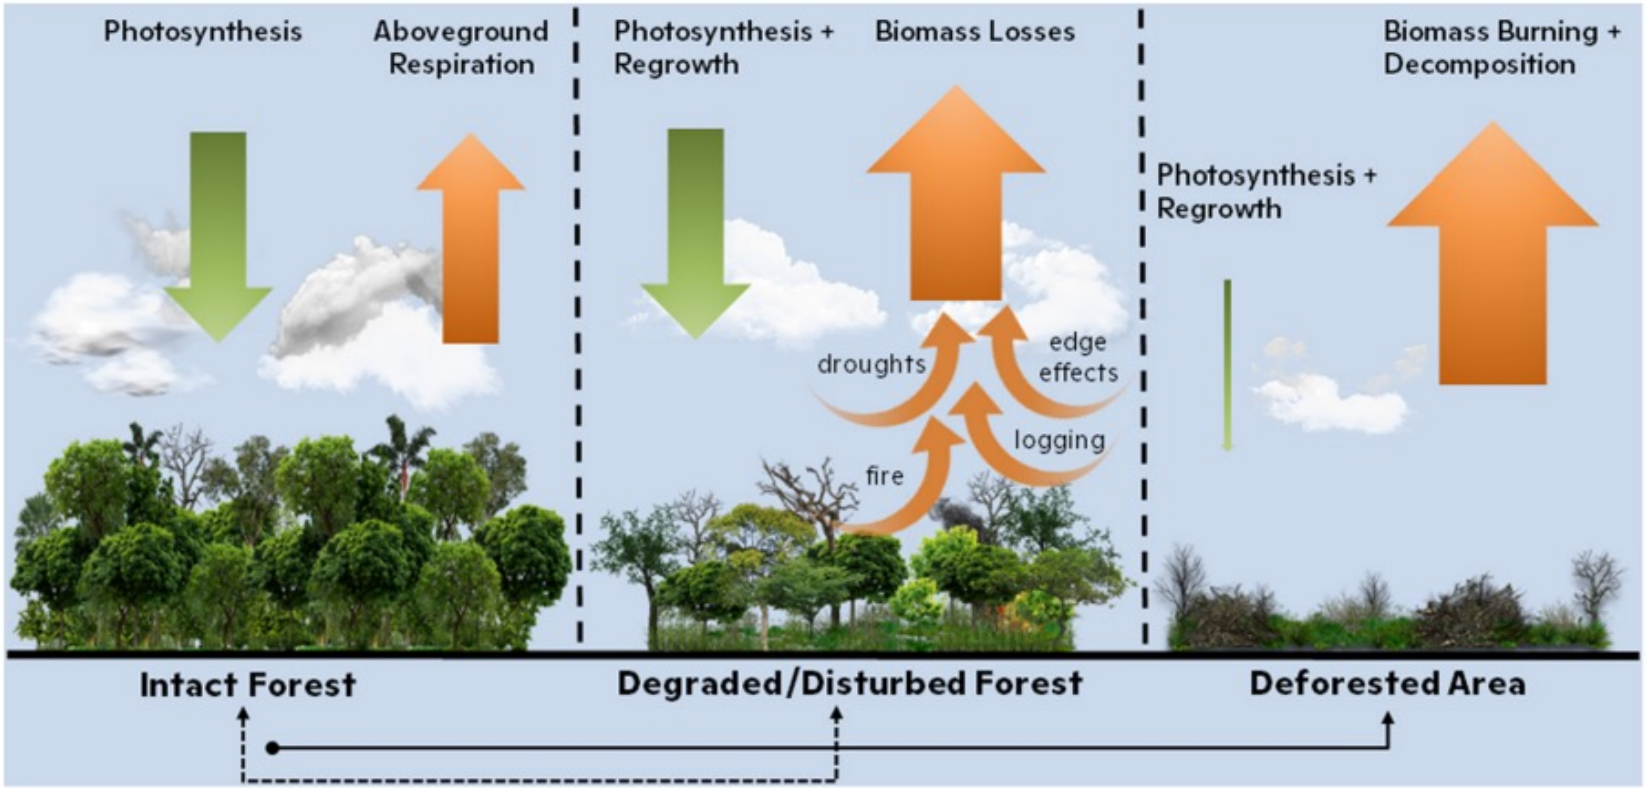


FIGURE 2 | Conceptual diagram showing above-ground carbon fluxes typical of healthy forests (left), degraded/disturbed forests (middle), and newly defo areas (right) in the Amazon. In each panel, carbon stocks are represented by the standing vegetation, losses by the orange upward arrows, and gains by downward arrows. Sources contributing to degradation and disturbance include direct (logging, fire) and indirect (droughts, edge effects) anthropogenic d one-way, solid black arrow represents forest clearing (deforestation) and conversion to another land use/cover— once deforested, these areas are unlikely regenerate to an intact forest. The two-way, dashed line reflects degradation/disturbance of intact forests. Depending on the intensity and frequency of disturbances, degraded/disturbed forests may regenerate into intact forests.

(Kruid et al., 2021)

Entender os **vetores e padrões das perdas de carbono florestal**

Primeiro passo para desenhar **estratégias de mitigação eficazes**

Essencial para os compromissos do Brasil e dos países tropicais no âmbito do **Acordo de Paris**.

Conservação das florestas tropicais

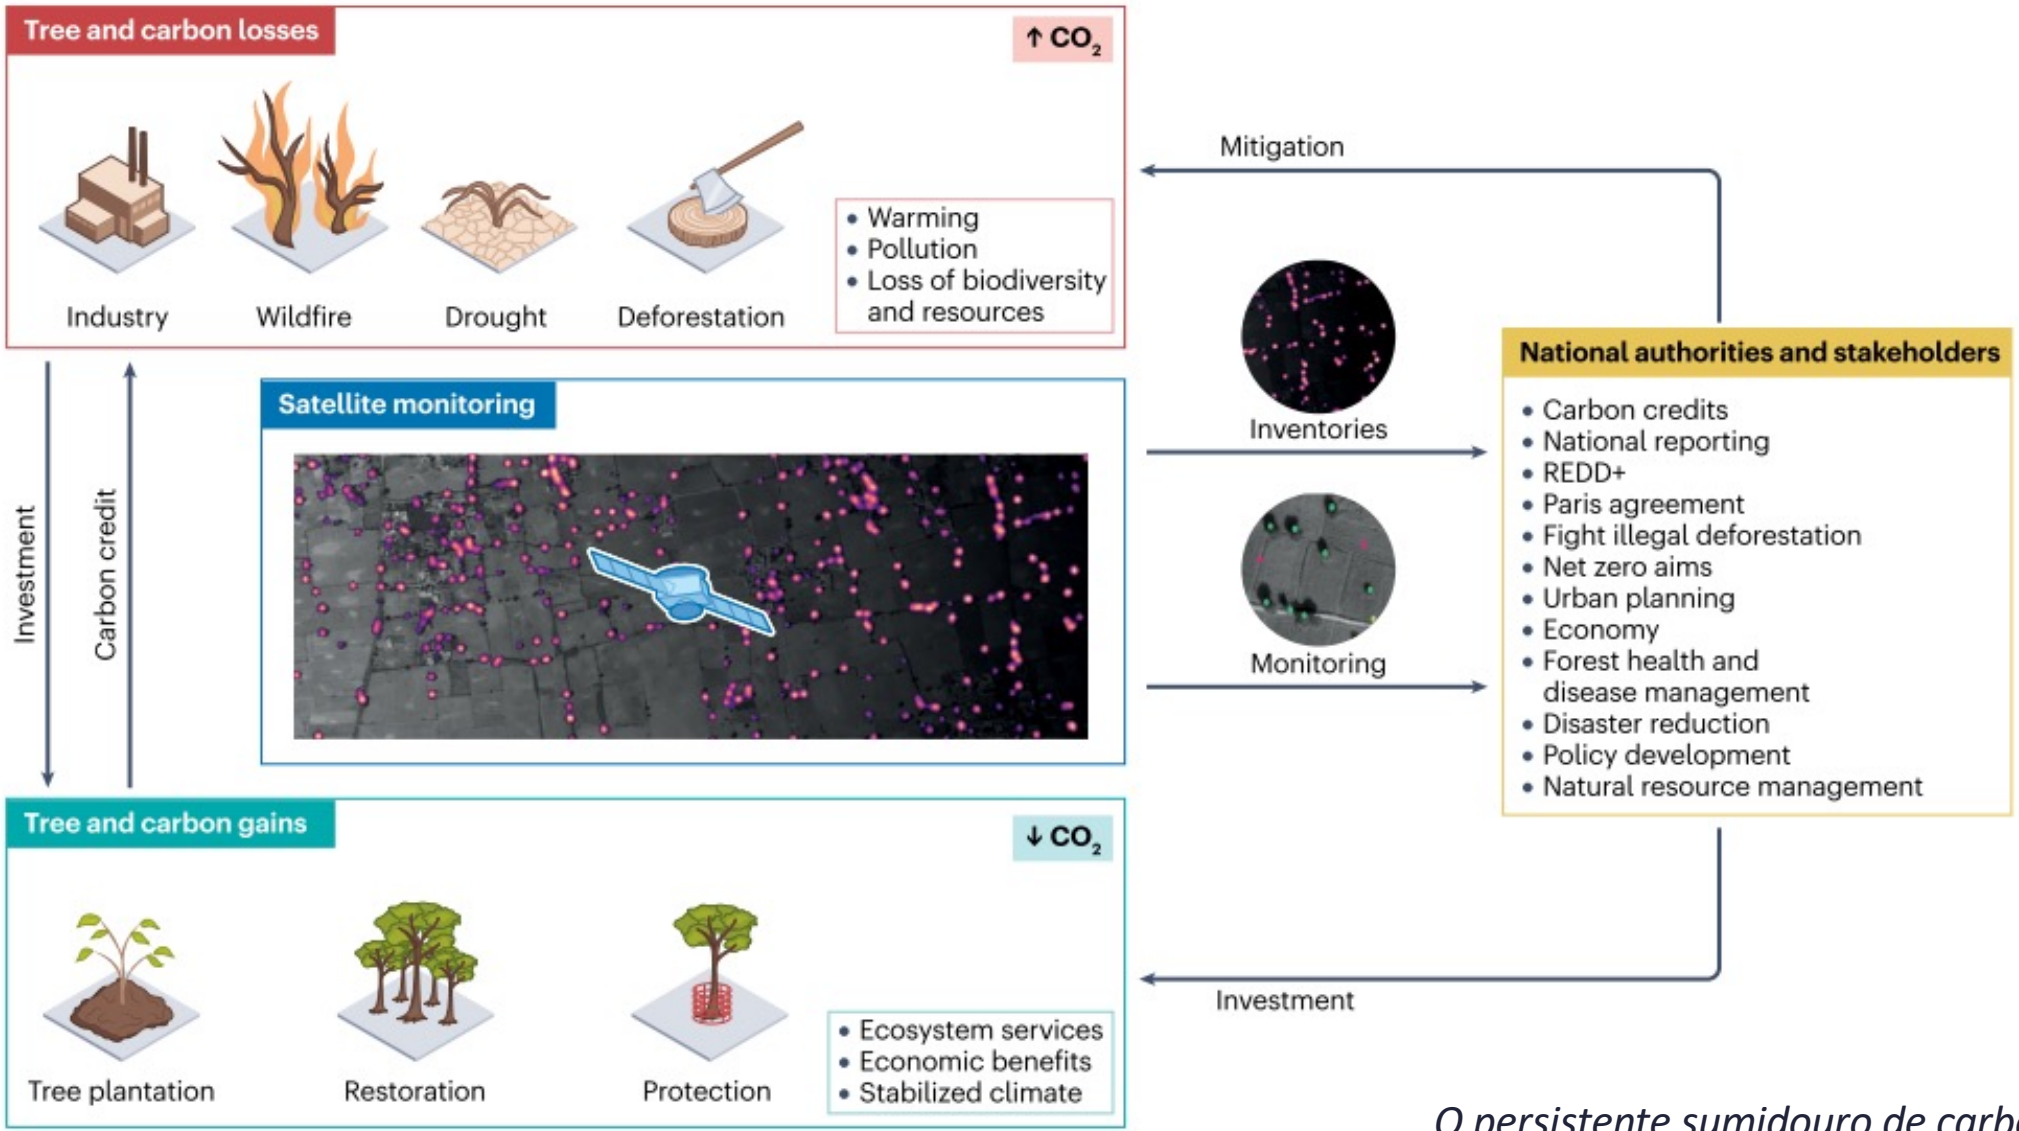


Fig. 1 | The importance of tree resource monitoring.

O persistente sumidouro de carbono florestal mundial
(Brandt et al., 2024)



IA – *um lembrete….*

A inteligência artificial (IA) é um campo da ciência da computação que desenvolve sistemas computacionais capazes de simular processos cognitivos humanos como aprendizagem, raciocínio e tomada de decisão (Russell & Norvig, 2010).

Métodos de IA?

- Aprendizado de máquina (**supervisionado**, **não supervisionado** e por reforço);
- Aprendizado profundo e redes neurais;
- Processamento de linguagem natural (PLN);
- Visão computacional;
- IA simbólica (incluindo sistemas especialistas e modelagem baseada em regras);
- Computação evolutiva;
- Lógica fuzzy



IA para florestas: tendências atuais

Do aprendizado de máquina ao aprendizado profundo

Período	Métodos de IA predominantes
~2010–2017	Florestas aleatórias, máquinas de vetores de suporte (SVM)
~2017–2022	Redes neurais convolucionais (CNNs) e arquiteturas U-Net
~2022–2024	Vision Transformers e modelos temporais de aprendizado profundo
~2024–atual	Modelos de base, IA multimodal e aprendizado autossupervisionado

Classificação da cobertura da terra e estimativa de biomassa

Robustez e baixa demanda por dados de treinamento



IA para florestas: tendências atuais

Do aprendizado de máquina ao aprendizado profundo

Período	Métodos de IA predominantes
~2010–2017	Florestas aleatórias, máquinas de vetores de suporte (SVM)
~2017–2022	Redes neurais convolucionais (CNNs) e arquiteturas U-Net
~2022–2024	Vision Transformers e modelos temporais de aprendizado profundo
~2024–atual	Modelos de base, IA multimodal e aprendizado autossupervisionado

Mapeamento florestal, detecção de desmatamento e caracterização do dossel.

Capacidade de captar padrões espaciais complexos.



IA para florestas: tendências atuais

Do aprendizado de máquina ao aprendizado profundo

Período	Métodos de IA predominantes
~2010–2017	Florestas aleatórias, máquinas de vetores de suporte (SVM)
~2017–2022	Redes neurais convolucionais (CNNs) e arquiteturas U-Net
~2022–2024	Vision Transformers (ViTs) e modelos temporais de aprendizado profundo
~2024–atual	Modelos de base, IA multimodal e aprendizado autossupervisionado

Extração de **dependências espaciais** de longo alcance e

Uso de **séries temporais de imagens** de satélite densas para monitorar a dinâmica florestal.



IA para florestas: tendências atuais

Do aprendizado de máquina ao aprendizado profundo

Período	Métodos de IA predominantes
~2010–2017	Florestas aleatórias, máquinas de vetores de suporte (SVM)
~2017–2022	Redes neurais convolucionais (CNNs) e arquiteturas U-Net
~2022–2024	Vision Transformers (ViTs) e modelos temporais de aprendizado profundo
~2024–atual	Modelos de base, IA multimodal e aprendizado autossupervisionado

Dados massivos de OT sem rótulos

Integração de fontes (óptico, SAR, LiDAR, clima, topografia)

Transferibilidade entre regiões e sensores

Menor dependência de dados rotulados,

Suporte a várias tarefas posteriores com ajuste fino mínimo.



IA para florestas: tendências atuais

Do aprendizado de máquina ao aprendizado profundo

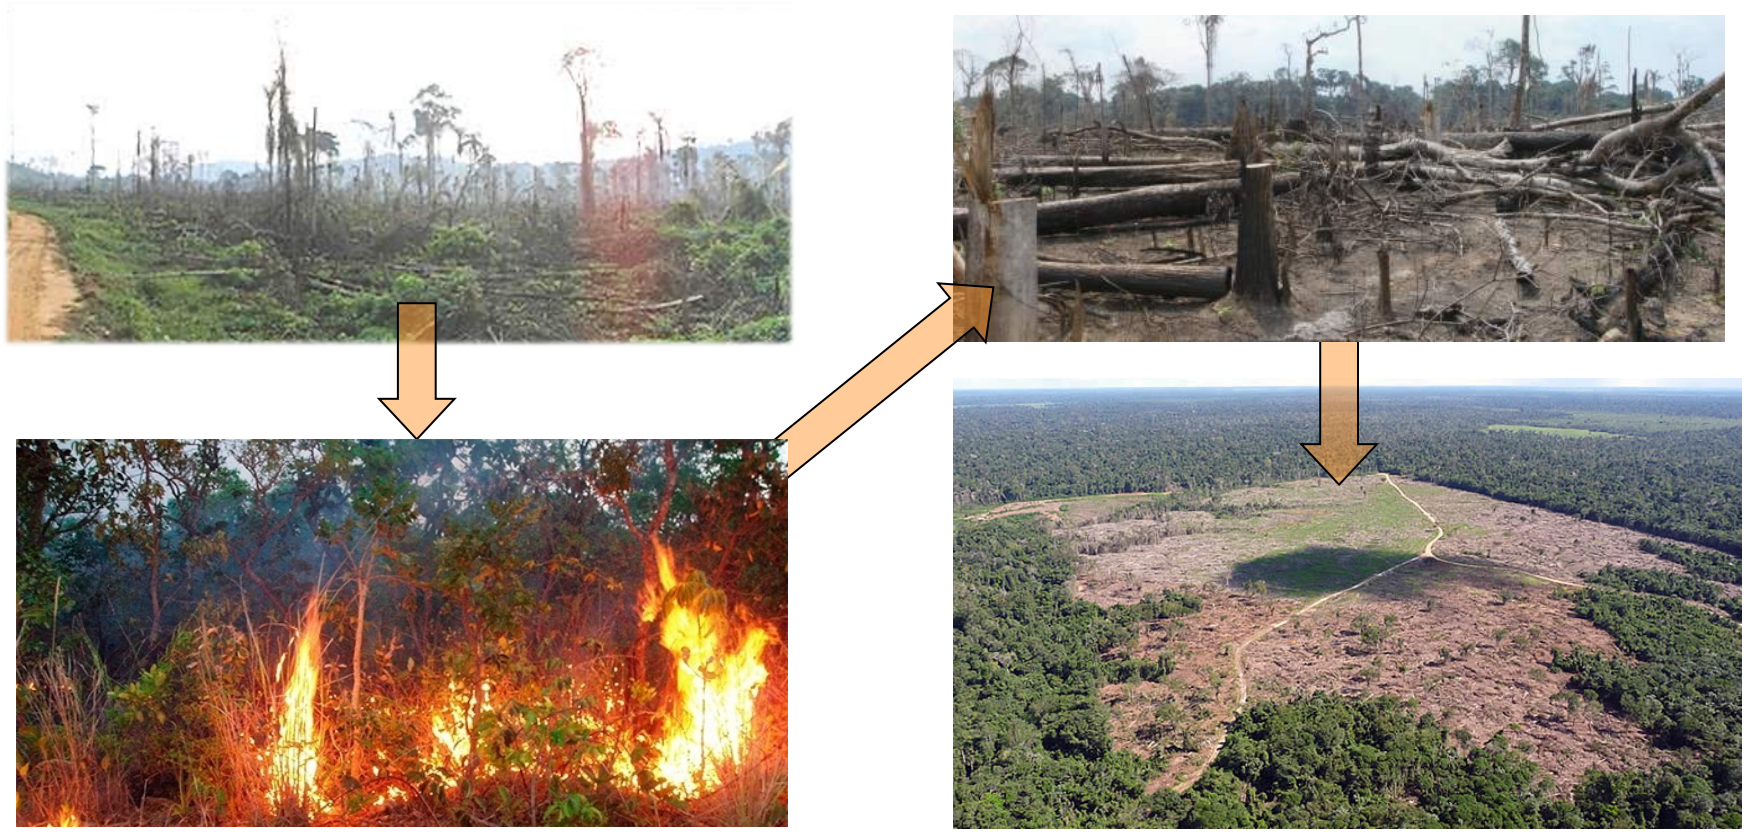
Período	Métodos de IA predominantes
~2010–2017	Florestas aleatórias, máquinas de vetores de suporte (SVM)
~2017–2022	Redes neurais convolucionais (CNNs) e arquiteturas U-Net
~2022–2024	Vision Transformers (ViTs) e modelos temporais de aprendizado profundo
~2024–atual	Modelos de base, IA multimodal e aprendizado autossupervisionado

Cobertura da terra, biomassa e aplicações com poucos dados rotulados

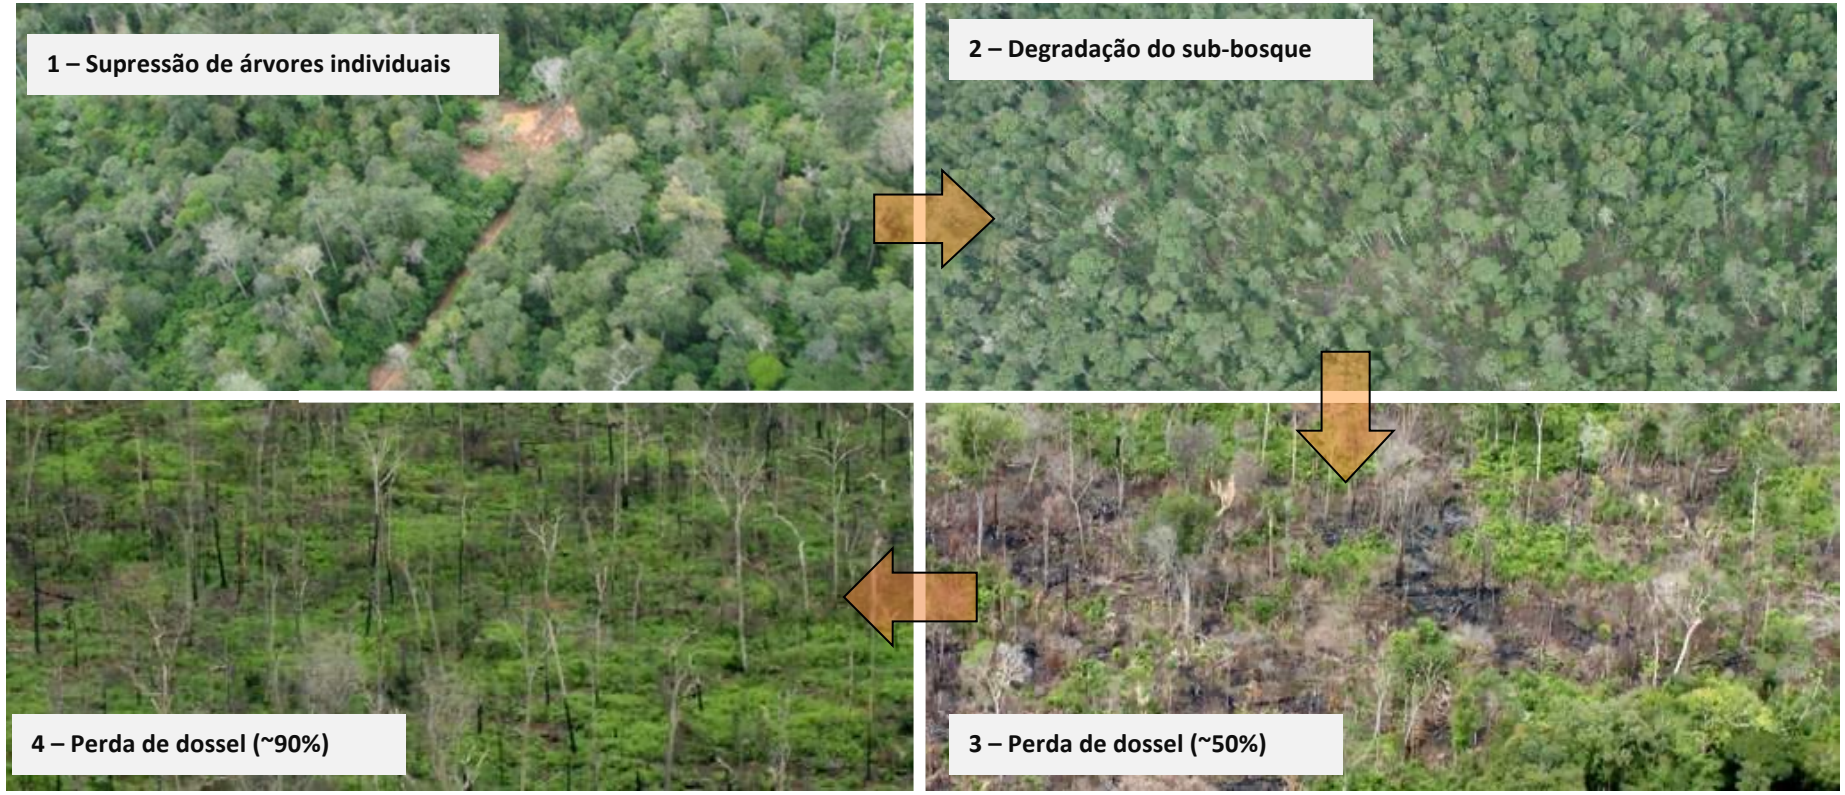
Degradação florestal, mapeamento de distúrbios, monitoramento contínuo e análises em larga escala

Desmatamento, incêndios florestais, corte raso

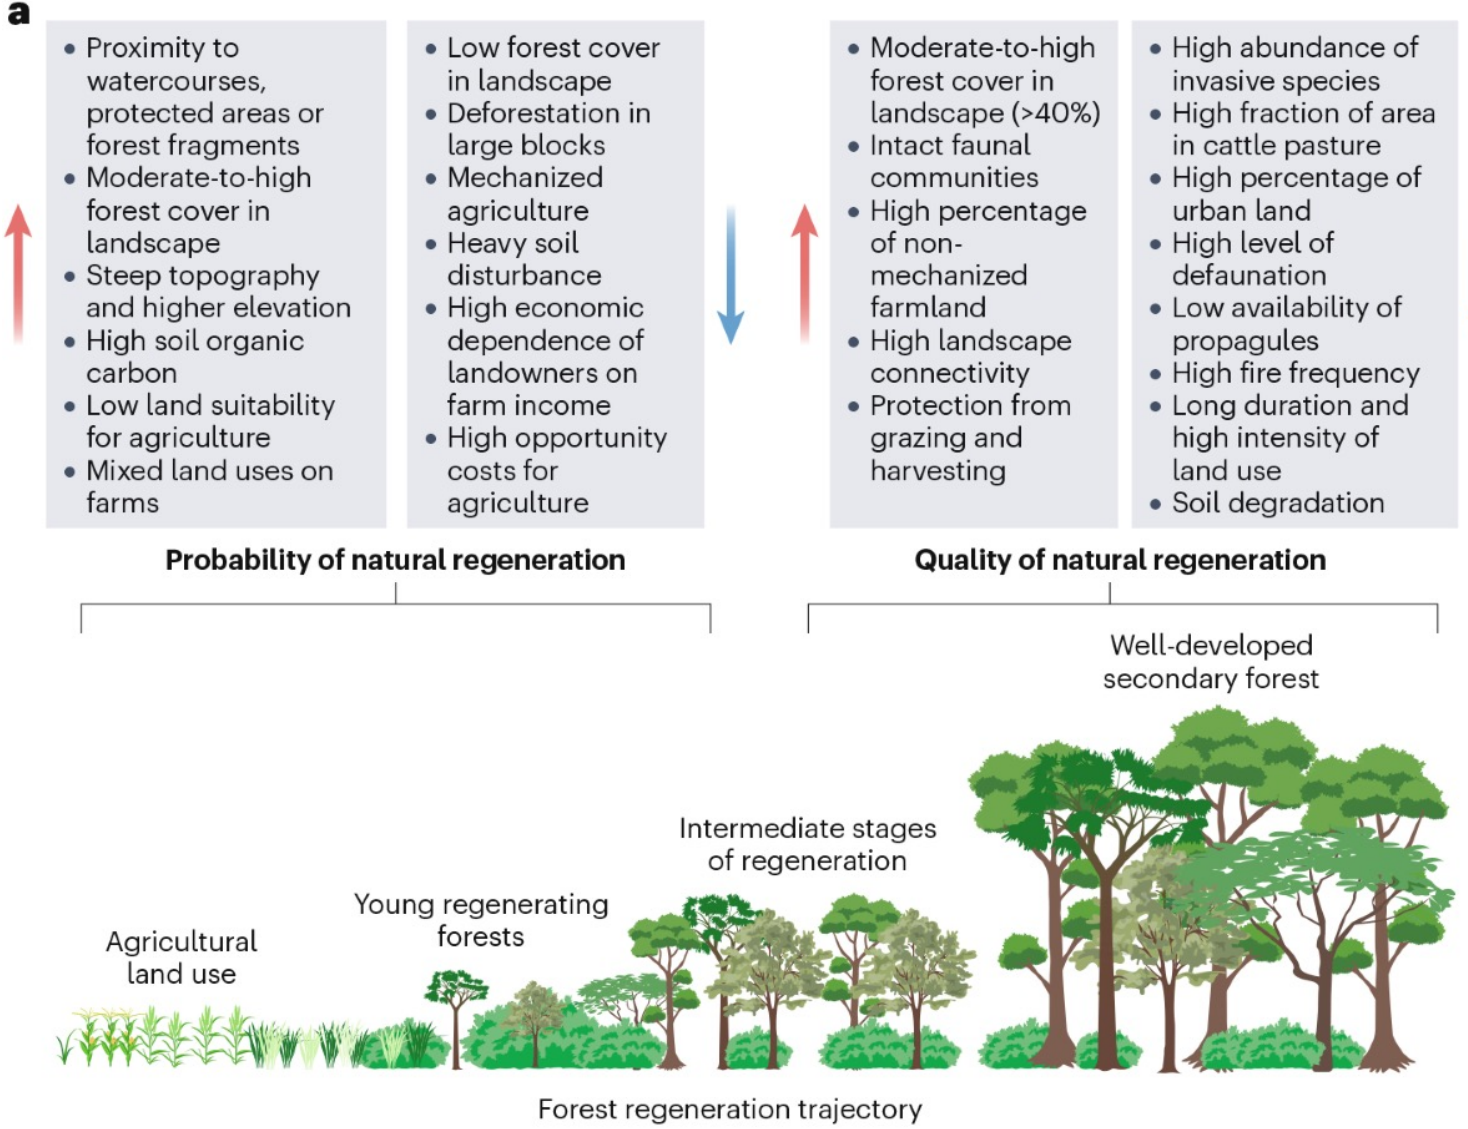
Corte e queima na Amazônia

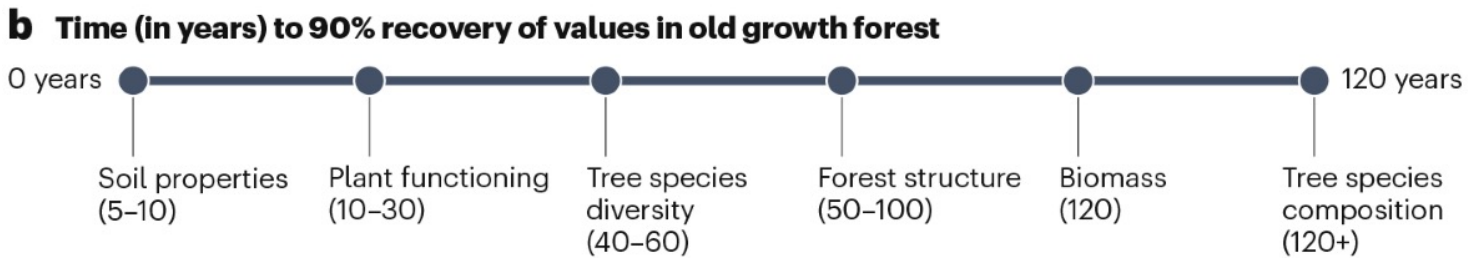


Degradação florestal



Biomas Br





Vetores e benefícios da regeneração natural em florestas tropicais

Chazdon et al. (2025)



Sensoriamento remoto e IA para florestas

Tarefa	Aplicações representativas	Referências-chave
Mapeamento florestal e classificação da cobertura da terra	Mapeamento floresta/não floresta, classificação de tipos florestais, inventários de florestas tropicais	Belgiu & Drăguț (2016); Mountrakis et al. (2011); Ma et al. (2019)
Detecção de desmatamento	Detecção de corte raso, exploração ilegal, monitoramento quase em tempo real	Zhu et al. (2017); Chen et al. (2021); Bandara & Patel (2022)
Monitoramento da degradação florestal	Exploração seletiva, distúrbio do sub-bosque, degradação do dossel	Rußwurm & Körner (2018); Pelletier et al. (2019)
Recuperação e regeneração florestal	Sucessão de floresta secundária, monitoramento da restauração, recuperação da vegetação	Pelletier et al. (2019); Ma et al. (2019)
Estimativa de biomassa e carbono	Biomassa acima do solo, estoques de carbono, monitoramento REDD+	Belgiu & Drăguț (2016); Maxwell et al. (2018)
Detecção de árvores individuais e caracterização do dossel	Delimitação de copas, reconhecimento de espécies, clareiras no dossel	Ma et al. (2019); Zhu et al. (2017)
Distúrbios florestais e detecção de mudanças	Cicatrizes de fogo, tempestades, surtos de insetos, mudança de uso da terra	Chen et al. (2021); Bandara & Patel (2022)
Avaliação de incêndios florestais	Mapeamento de áreas queimadas, severidade do fogo, recuperação pós-fogo	Ma et al. (2019); Zhu et al. (2017)
Monitoramento florestal quase em tempo real	Sistemas de alerta operacionais, vigilância florestal contínua	Ayush et al. (2021); Jakubik et al. (2024)
Análise geoespacial de uso geral	Aprendizado multitarefa, aprendizado por transferência, monitoramento florestal continental e global	Robinson et al. (2024); Jakubik et al. (2024)



Sensoriamento remoto e IA para florestas

Tarefa	Principais métodos de IA
Mapeamento florestal e classificação da cobertura da terra	Florestas aleatórias, SVM, CNNs, Vision Transformers
Detecção de desmatamento	CNNs, U-Net, redes siamesas, Transformers
Monitoramento da degradação florestal	CNNs, CNNs temporais, LSTM, Vision Transformers
Recuperação e regeneração florestal	LSTM, GRU, Transformers temporais
Estimativa de biomassa e carbono	Florestas aleatórias, gradient boosting, redes neurais profundas
Detecção de árvores individuais e caracterização do dossel	CNNs, Mask R-CNN, U-Net, YOLO
Distúrbios florestais e detecção de mudanças	CNNs siamesas, BIT, ChangeStar, Vision Transformers
Avaliação de incêndios florestais	CNNs, DeepLab, Transformers
Monitoramento florestal quase em tempo real	Transformers temporais, aprendizado autossupervisionado, modelos de base
Análise geoespacial de uso geral	Modelos de base, IA multimodal



IA para tarefas de monitoramento florestal

Tarefa	Principais métodos de IA
Mapeamento florestal e classificação da cobertura da terra	Florestas aleatórias, SVM, CNNs, Vision Transformers
Detecção de desmatamento	CNNs, U-Net, redes siamesas, Transformers
Monitoramento da degradação florestal	CNNs, CNNs temporais, LSTM, Vision Transformers
Recuperação e regeneração florestal	LSTM, GRU, Transformers temporais
Estimativa de biomassa e carbono	Florestas aleatórias, gradient boosting, redes neurais profundas
Detecção de árvores individuais e caracterização do dossel	CNNs, Mask R-CNN, U-Net, YOLO
Distúrbios florestais e detecção de mudanças	CNNs siamesas, BIT, ChangeStar, Vision Transformers
Avaliação de incêndios florestais	CNNs, DeepLab, Transformers
Monitoramento florestal quase em tempo real	Transformers temporais, aprendizado autossupervisionado, modelos de base
Análise geoespacial de uso geral	Modelos de base, IA multimodal

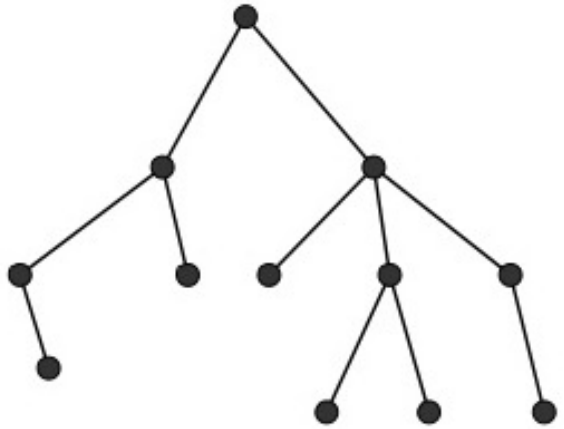


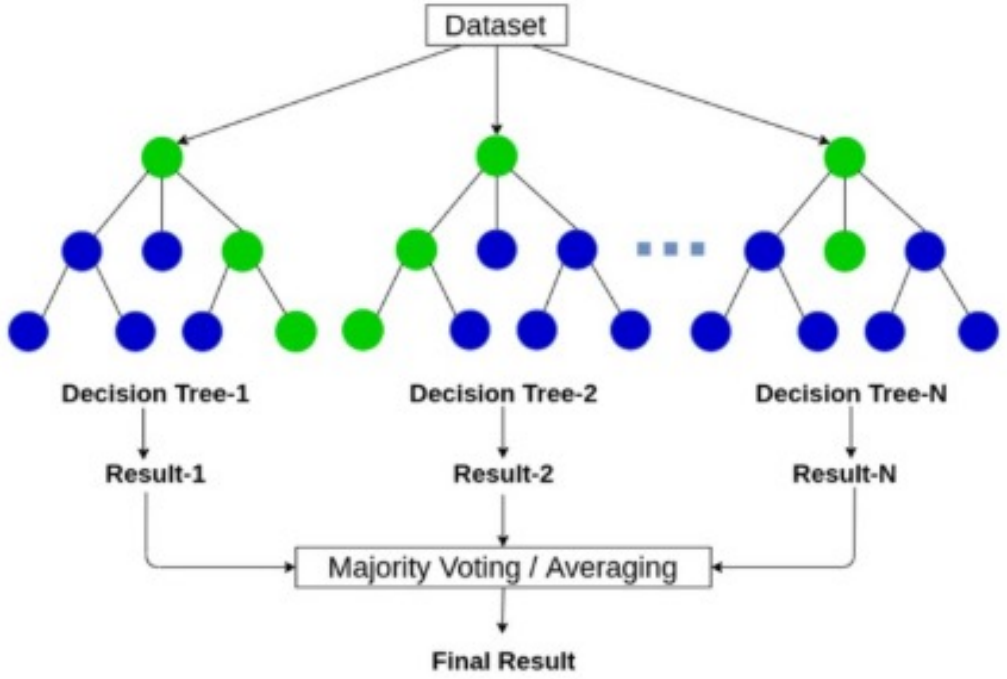
Florestas aleatórias

Árvores de decisão: **algoritmos** de aprendizado de máquina

Ponto de decisão = “nós” da árvore, que decidem seguir um caminho ou outro
Caminho = “ramos”
A variável com maior ganho de informação fica no primeiro nó da árvore.







Floresta aleatória - um conjunto de árvores de decisão - para classificação e regressão

Entropia / índice de Gini – para definir a influência das variáveis

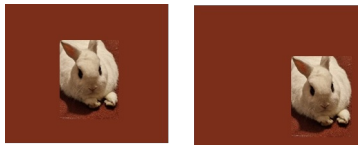
https://pt.stackoverflow.com/questions/216885/o-que-seria-uma-%C3%A1rvore-e-uma-floresta

https://www.linkedin.com/pulse/entendendo-o-algoritmo-random-forest-e-suas-aplica%C3%A7%C3%B5es-julio-rena-aa1yc/

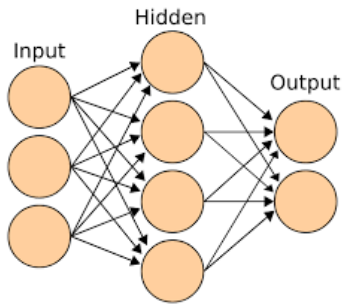


CNN Rede neural convolucional

Os modelos de aprendizado profundo usam dados tridimensionais para classificação de *imagens* e reconhecimento de objetos (**processamento de dados com topologia em grade)**



Convoluções matemáticas: para **preservar a estrutura espacial e extrair automaticamente características** como bordas, texturas e formas



Rede neural artificial (RNA)

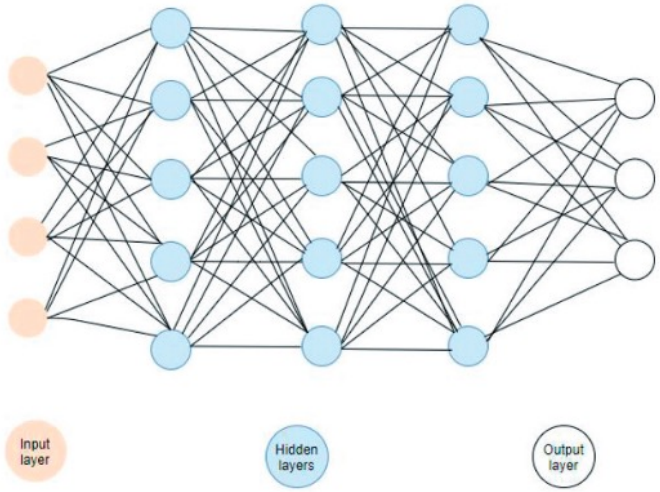
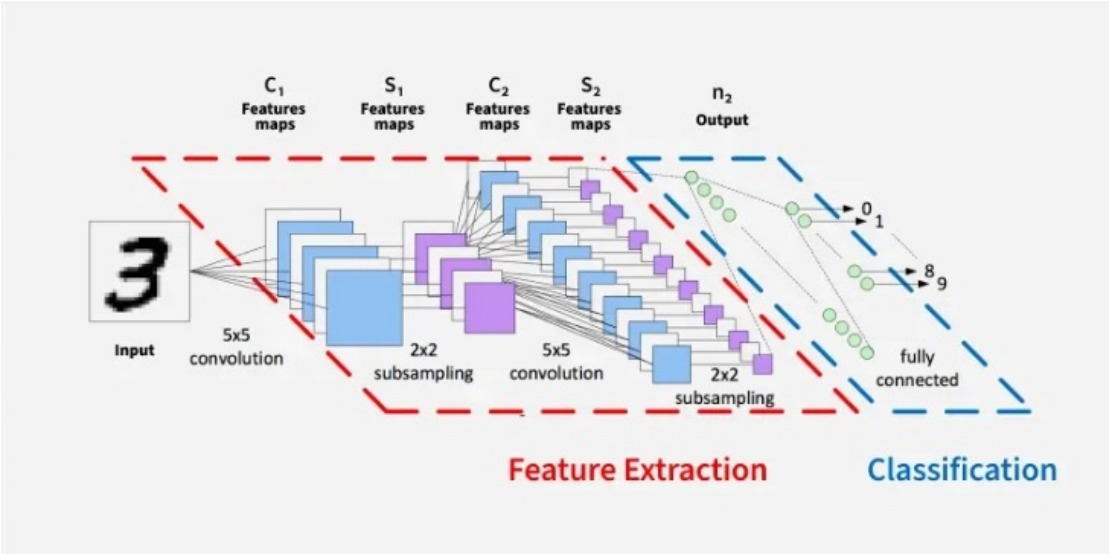


Figure 2.
Deep neural network.

Advancements in Deep Learning Theory and Applications: Perspective in 2020 and beyond
DOI: http://dx.doi.org/10.5772/intechopen.92271



Rede neural convolucional

Uma rede neural com muitas camadas ocultas é chamada de aprendizado profundo

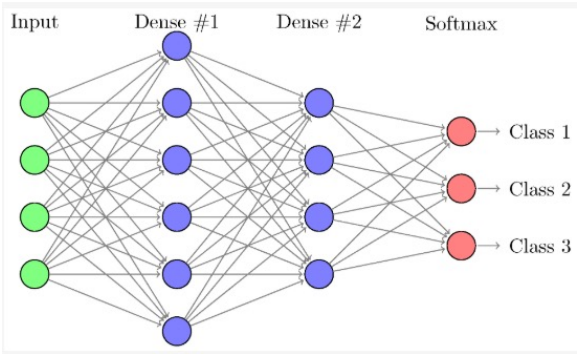
https://www.geeksforgeeks.org/deep-learning/convolutional-neural-network-cnn-in-machine-learning/

TempCNN

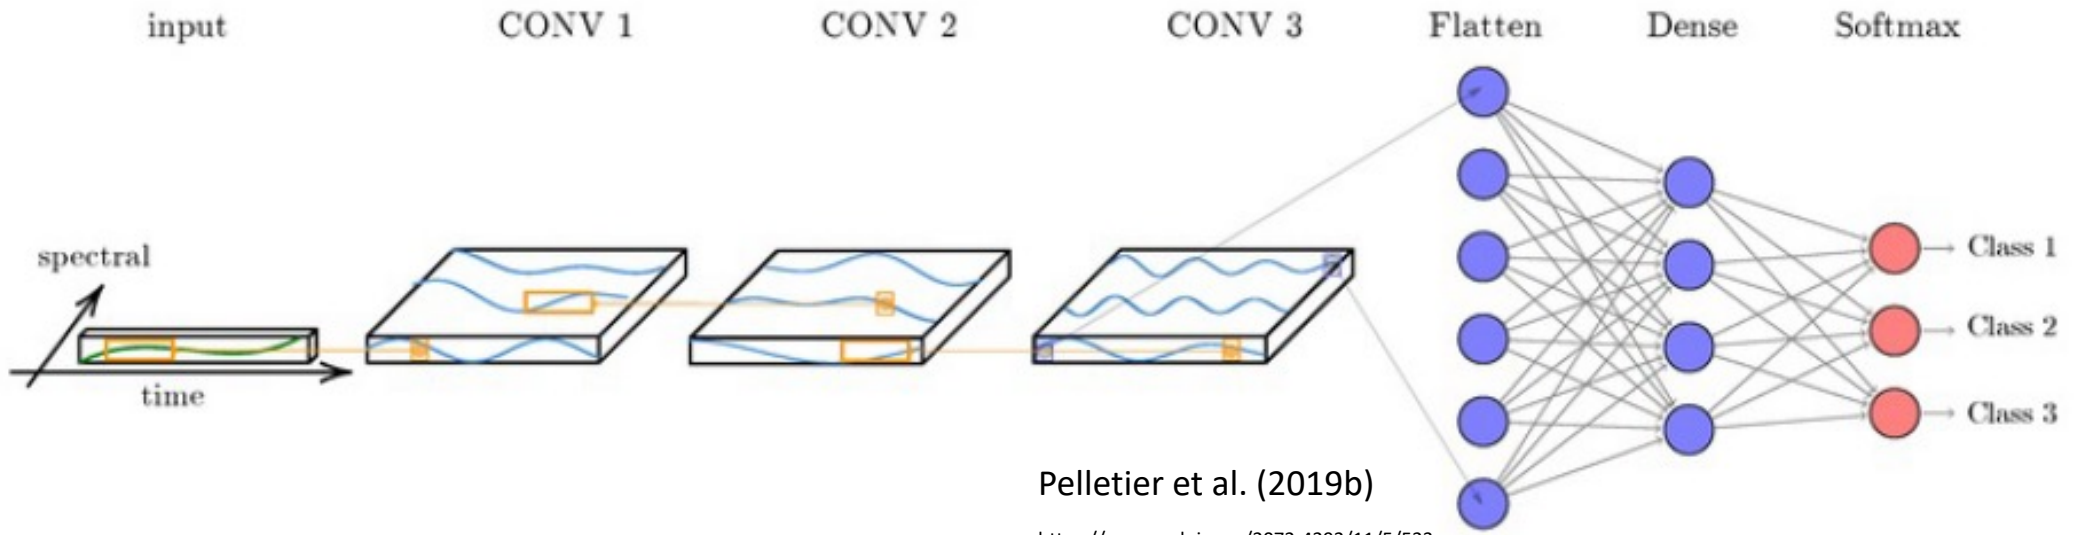
Rede neural convolucional temporal

A **entrada** da rede é uma série temporal multivariada.
Três **filtros** convolucionais são aplicados em sequência, depois uma camada densa,
e por fim a camada Softmax, que fornece a distribuição de classes prevista.

Rede neural totalmente conectada



Arquitetura TempCNN para uma tarefa de classificação.



Pelletier et al. (2019b)

https://www.mdpi.com/2072-4292/11/5/523



Transformers

Attention Is All You Need

Vaswani et al. (2017)

Arquitetura
Baseada somente em mecanismos de atenção, dispensando totalmente recorrência e convoluções

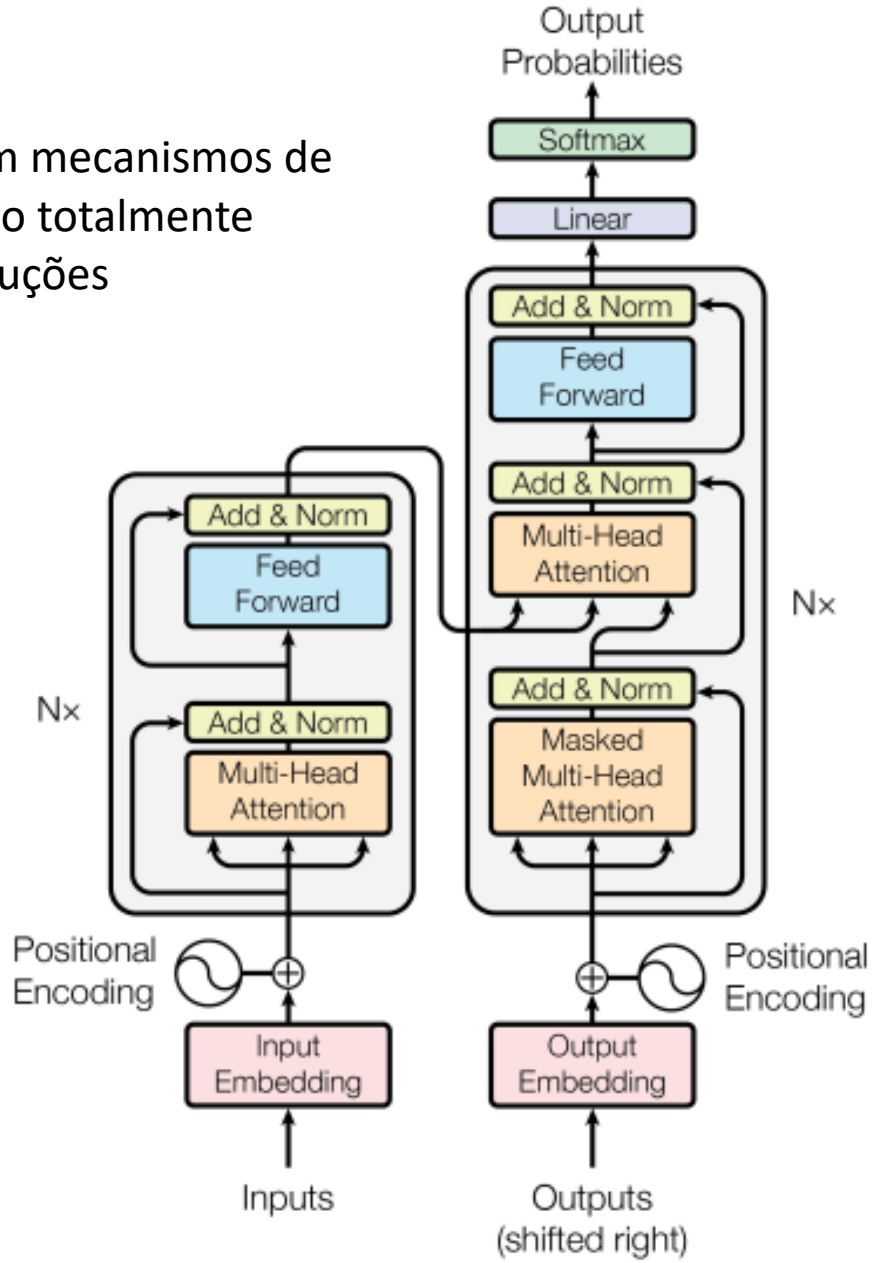


Figure 1: The Transformer - model architecture.

Vindo do PLN (processamento de linguagem natural)
– tradução automática em vez de palavra por palavra e frase por frase
– o livro inteiro, com atenção (marcadores)
– recuperar facilmente um parágrafo (como numa conversa: o que é interessante?)

Autoatenção: modela as relações entre todos os elementos da entrada;
Atenção multicabeça : aprendizado simultâneo de diferentes tipos de relação;
Eliminação das redes recorrentes;
Processamento paralelo;
Arquitetura Transformer.

Transformers

Vision Transformer (ViT)
Masked Autoencoder (MAE)
SatMAE
Prithvi
Clay
DOFA

Mecanismos de autoatenção para modelar tanto as relações espaciais quanto as trajetórias temporais em grandes paisagens

Vegetação secundária identificada não só por sua assinatura espectral, mas também por estar:
- localizada em área já desmatada,
- perto de outros fragmentos em regeneração,
- com evolução coerente ao longo de uma série temporal de imagens.



É a **integração do contexto espacial e temporal** que torna os Transformers especialmente promissores para o sensoriamento remoto.

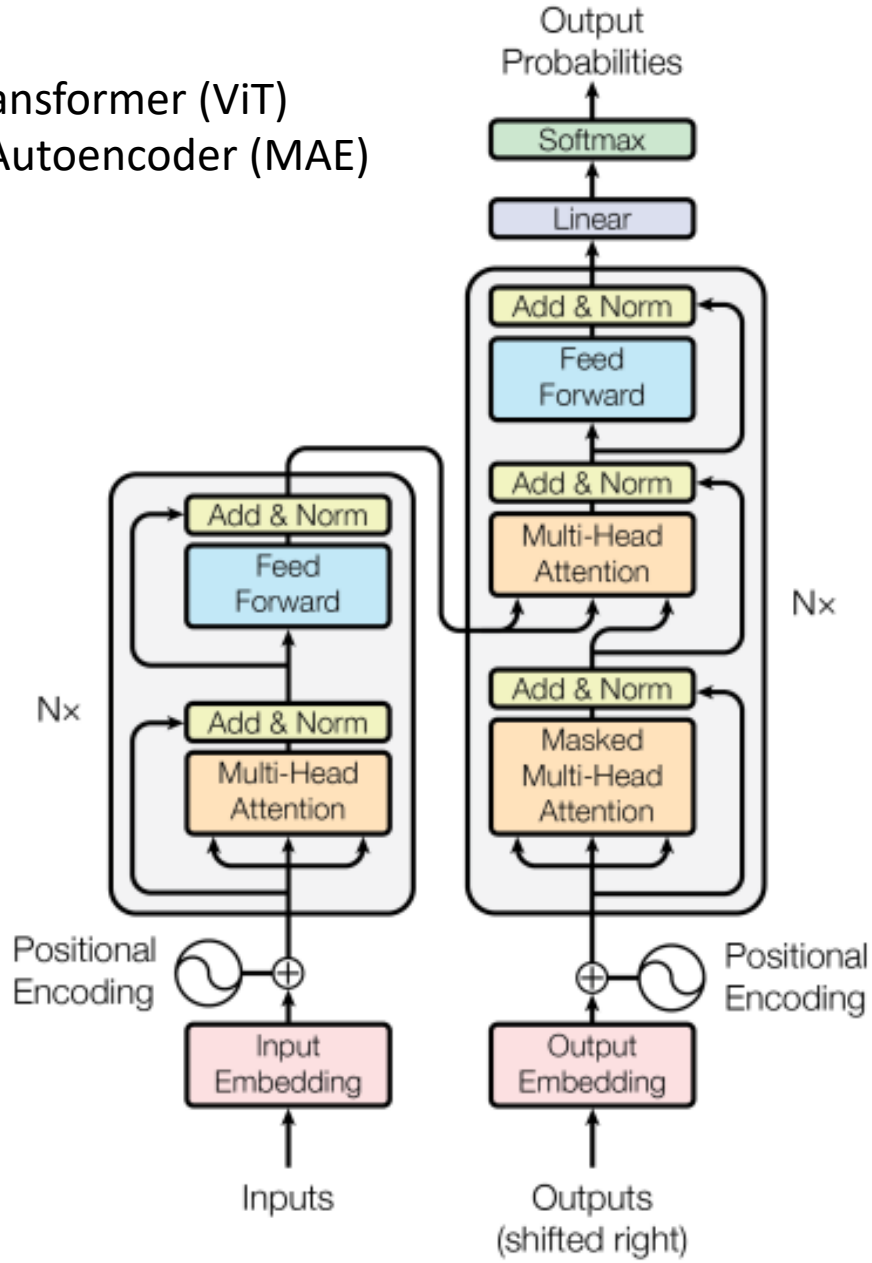
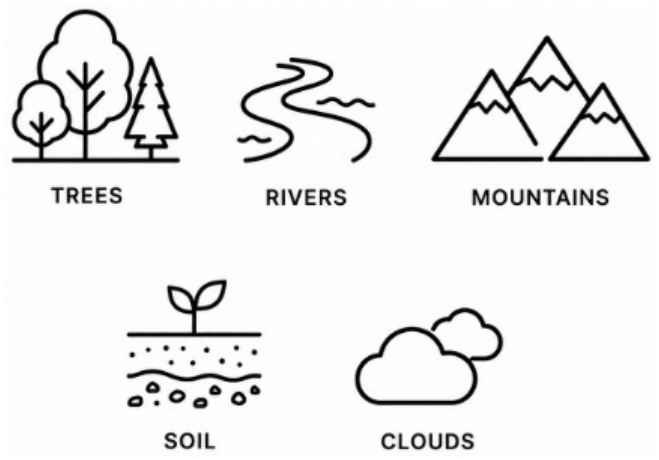


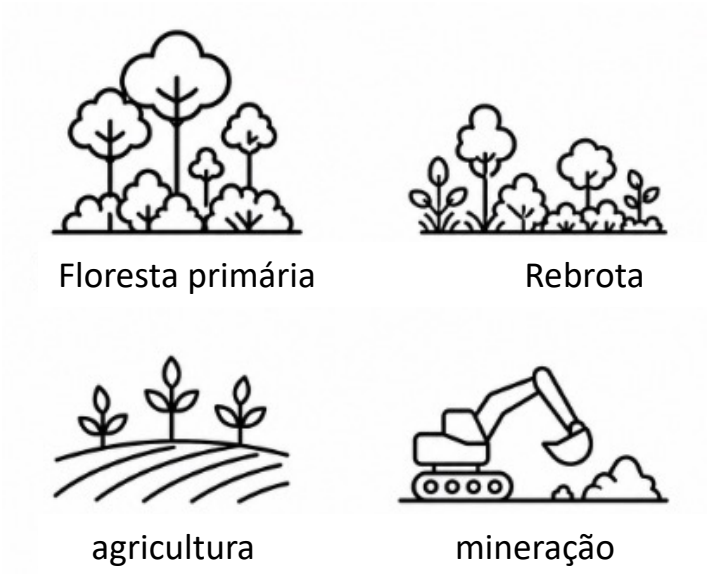
Figure 1: The Transformer - model architecture.

Modelos de base

Universidade Stanford:
On the Opportunities and Risks of Foundation Models
(Bommasani et al., 2021).

Um **Transformer** é uma **arquitetura** de rede neural (o “motor”).
Um modelo de base (MB) é um **paradigma de treinamento** (uma forma de construir modelos de uso geral adaptáveis a muitas tarefas posteriores)



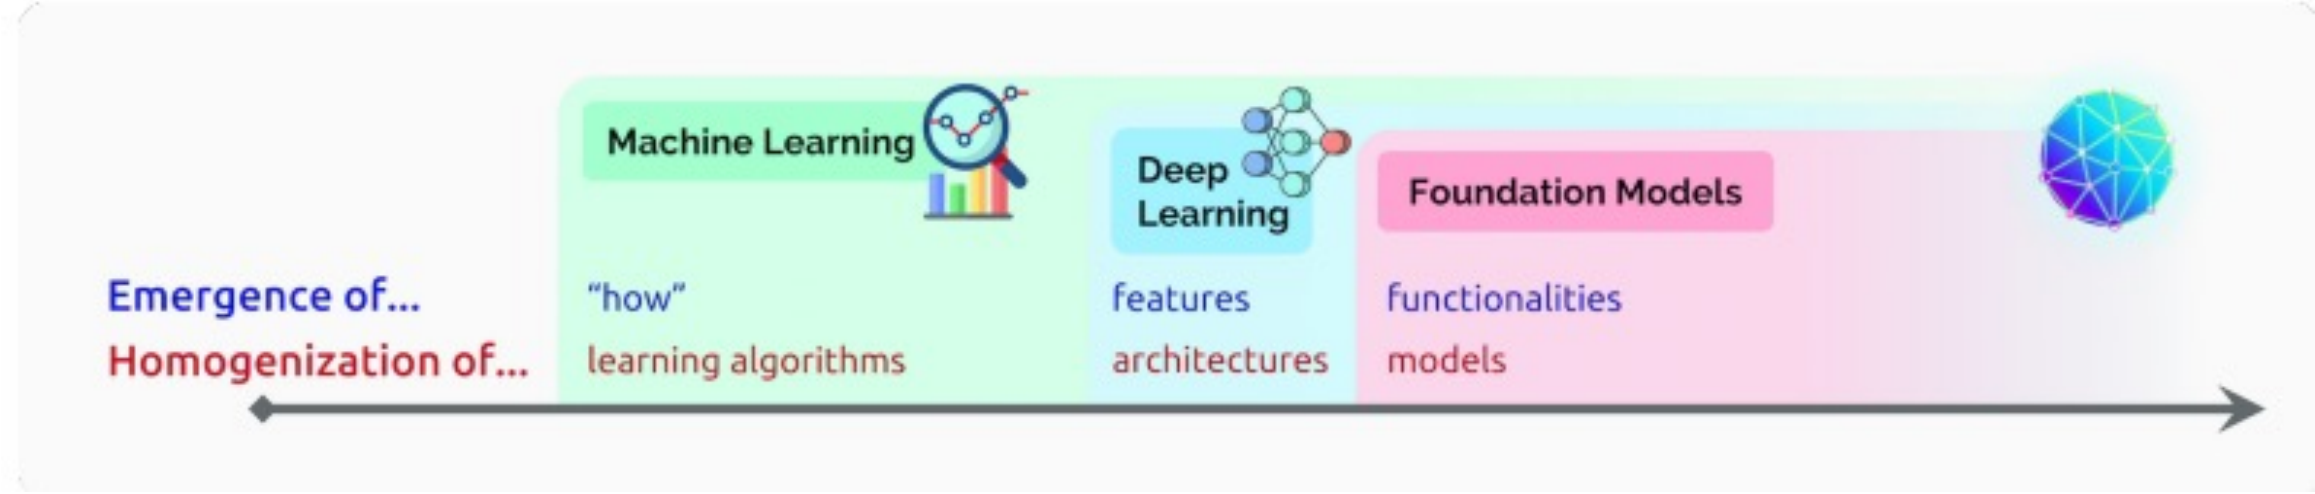


Pré-treinamento
Em vez de ensinar diretamente ao modelo que “**isto é uma floresta**”,
o modelo aprende primeiro **conceitos mais fundamentais** como texturas, padrões espaciais, relações espectrais, dinâmica temporal, formas de objetos e informação contextual.
Depois, o modelo pode ser especializado para uma aplicação específica.



Modelos de base

Universidade Stanford:
On the Opportunities and Risks of Foundation Models
(Bommasani et al., 2021).



"Como construir um modelo melhor para esta tarefa?"

"Como adaptar um modelo de uso geral para resolver esta tarefa da melhor forma possível?"

Uma mudança de paradigma na forma de desenvolver sistemas de IA

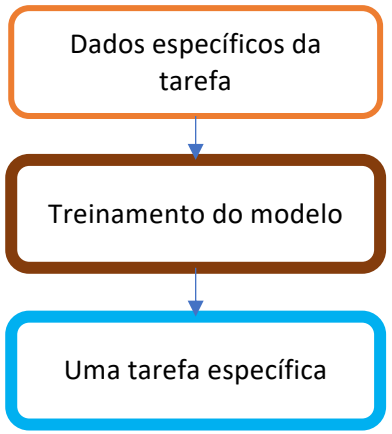


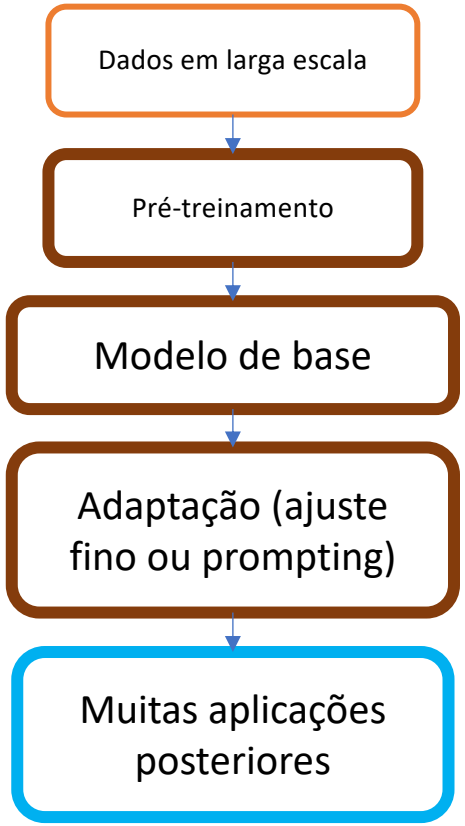
Modelos de base

Universidade Stanford:
On the Opportunities and Risks of Foundation Models
(Bommasani et al., 2021).

Um modelo treinado com dados amplos e diversos, em geral por aprendizado autossupervisionado em larga escala, que pode ser adaptado a uma grande variedade de tarefas posteriores.

Aprendizado autossupervisionado





Vantagens:

- Reaproveitamento de conhecimento: um único modelo para diferentes aplicações.
- Menor dependência de dados rotulados, graças ao pré-treinamento autossupervisionado em larga escala.
- Melhor desempenho que modelos treinados com dados específicos da tarefa.
- Transferência de conhecimento entre domínios e aplicações.

- Inovação acelerada: os pesquisadores podem se concentrar em adaptar modelos pré-treinados em vez de desenvolver novos modelos do zero.



Modelos de base

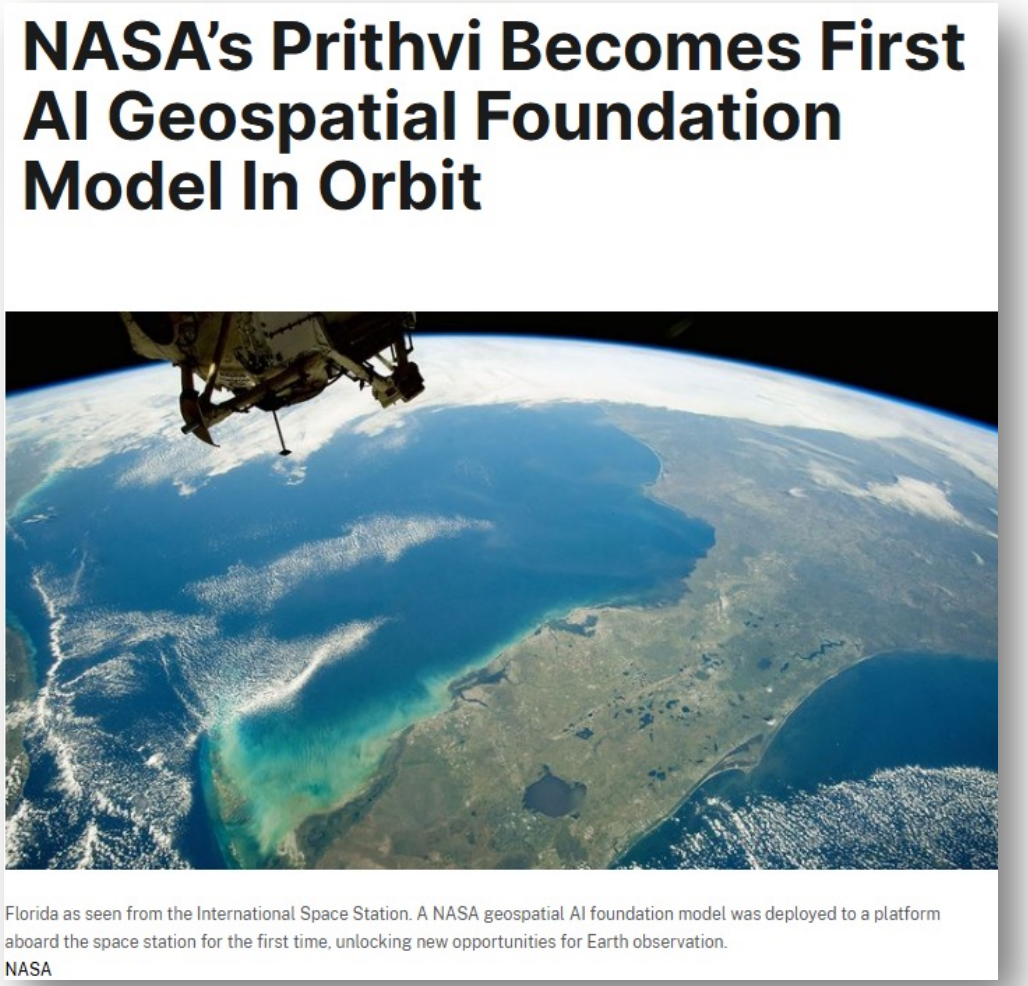
Desafios

1. **Altas exigências de dados e computação**
   Treinamento

   De milhões a bilhões de imagens
   Centenas de milhões (ou até bilhões) de parâmetros
   Milhares de GPUs rodando por semanas ou meses

   Poucas instituições de pesquisa conseguem treinar um modelo de base do zero
   A maioria dos usuários usa modelos pré-treinados públicos e faz ajuste fino para suas aplicações.

Prithvi (NASA/IBM)
Modelo de base Clay
SatMAE
CROMA
DOFA
AnySat



https://science.nasa.gov/science-research/ai-foundation-model-in-orbit/

Modelos de base

Desafios

2. Generalização limitada - Não generalizam perfeitamente



Um modelo pré-treinado com

- paisagens agrícolas dos EUA,
- cidades europeias,
- florestas boreais,



pode ter desempenho ruim quando aplicado à Amazônia,
savana africana,
florestas da Nova Zelândia

Os ecossistemas diferem em:
composição de espécies,
clima,
características d sensores,
fenologia,
estrutura da vegetação.

Por isso, um bom desempenho muitas vezes ainda exige

- ajuste fino,
- adaptação de domínio,
- dados de treinamento coletados localmente.



Modelos de base

Desafios

3. Dependência dos dados de pré-treinamento - depende da diversidade do conjunto de pré-treinamento.

Hoje, os conjuntos de dados públicos têm relativamente pouca informação sobre:

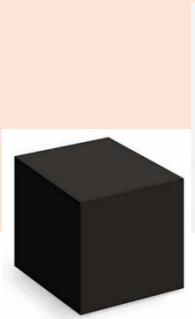
florestas tropicais,
florestas secundárias,
degradação florestal,
manejo florestal,
danos de incêndios em diferentes estágios de recuperação.

4. Interpretabilidade limitada – "caixas-pretas".

Não respondem a perguntas sobre a contribuição ou importância das variáveis

Essa falta de transparência dificulta

- a validação científica,
- a explicabilidade dos modelos,
- a confiança operacional.







Modelos de base

Desafios

5. Alto custo computacional na inferência - exigentes em computação, mesmo após o treinamento.

Limitações:

Grande exigência de memória de GPU,
inferência lenta,
altos custos de computação em nuvem,
escalabilidade limitada para sistemas operacionais.

Alguns modelos atuais têm centenas de milhões de parâmetros, o que torna cara a implantação operacional em escala nacional.

6. Generalização entre sensores – pré-treinamento básico

Muitos modelos de base são pré-treinados com
- Sentinel-2,
- Landsat,
- imagens RGB.

O monitoramento florestal depende de
- Sentinel-1 SAR,
- LiDAR,
- GEDI,
- imagens Planet,
- CBERS,
- imagens hiperespectrais.

6. A modelagem de séries temporais continua difícil

Poucos modelos de base hoje aproveitam bem longas séries temporais de imagens de satélite (AnySat, Prithvi)

Precisa de desenvolvimento ativo.

Fronteiras de pesquisa no monitoramento florestal com IA



IA para tarefas de monitoramento florestal

Tarefa	Principais métodos de IA
Mapeamento florestal e classificação da cobertura da terra	Florestas aleatórias, SVM, CNNs, Vision Transformers
Detecção de desmatamento	CNNs, U-Net, redes siamesas, Transformers
Monitoramento da degradação florestal	CNNs, CNNs temporais, LSTM, Vision Transformers
Recuperação e regeneração florestal	LSTM, GRU, Transformers temporais
Estimativa de biomassa e carbono	Florestas aleatórias, gradient boosting, redes neurais profundas
Detecção de árvores individuais e caracterização do dossel	CNNs, Mask R-CNN, U-Net, YOLO
Distúrbios florestais e detecção de mudanças	CNNs siamesas, BIT, ChangeStar, Vision Transformers
Avaliação de incêndios florestais	CNNs, DeepLab, Transformers
Monitoramento florestal quase em tempo real	Transformers temporais, aprendizado autossupervisionado, modelos de base
Análise geoespacial de uso geral	Modelos de base, IA multimodal

Classificação de espécies arbóreas

scientific reports

Manacá da Serra

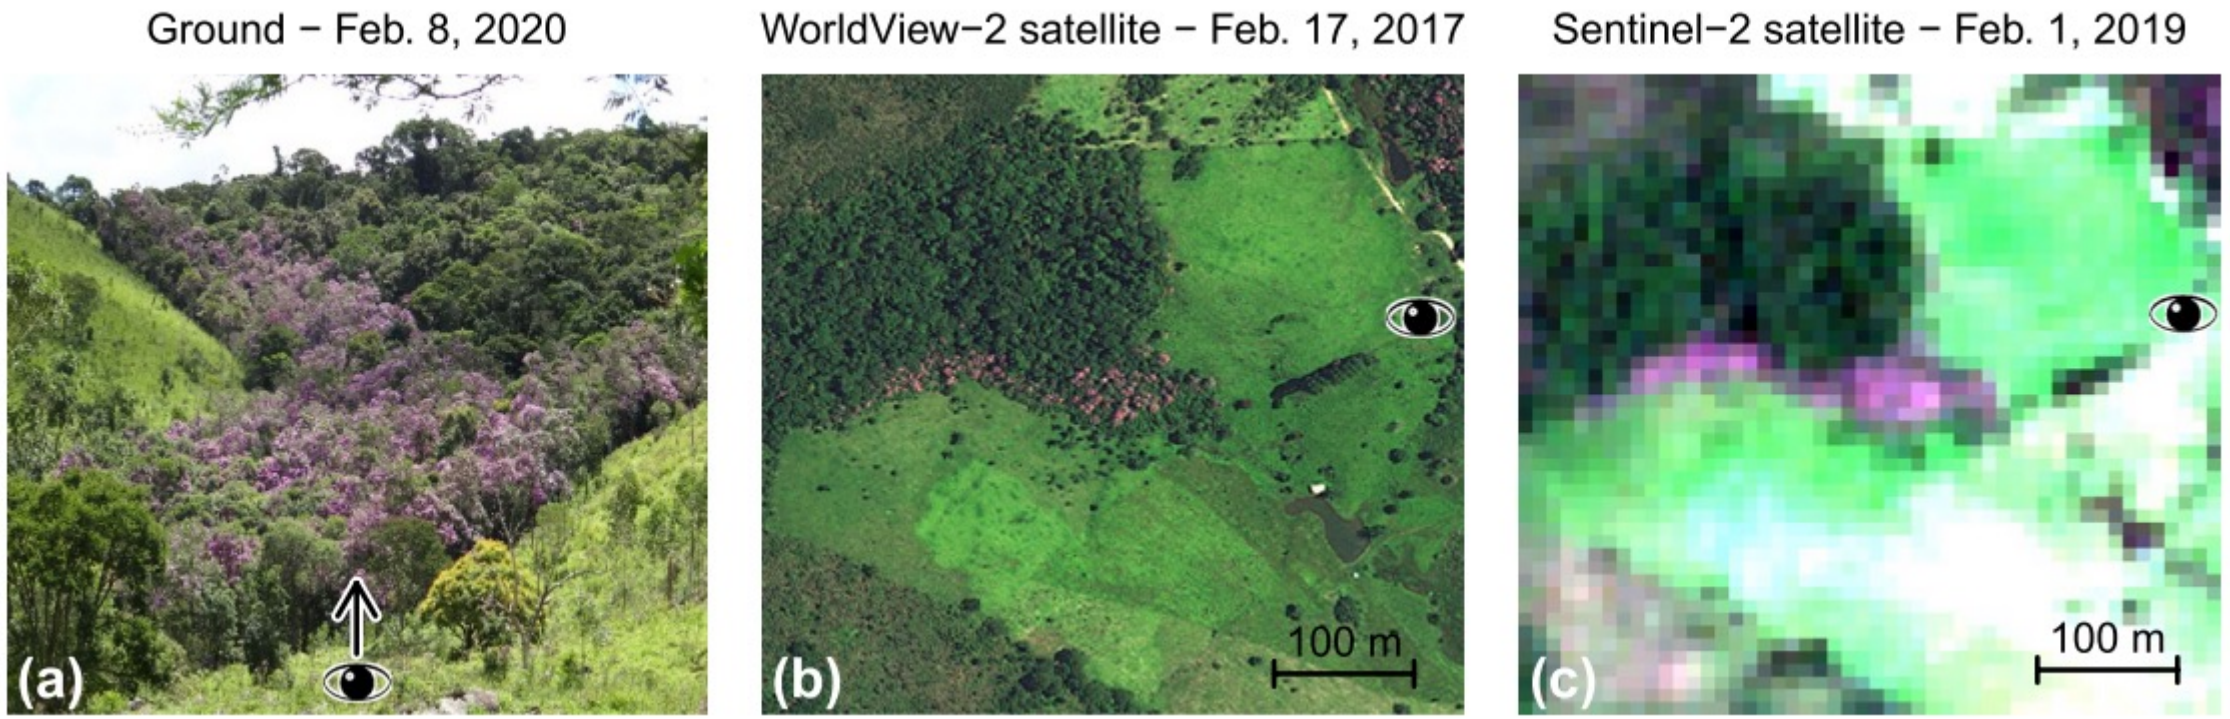


OPEN

The flowering of Atlantic Forest *Pleroma* trees

Fabien H. Wagner

Wagner (2021)



https://agencia.fapesp.br/biologist-uses-satellite-imagery-and-ai-to-map-glory-trees-in-brazils-atlantic-rainforest/37886

https://doi.org/10.1038/s41598-021-99304-x

scientific reports Wagner (2021)



OPEN

The flowering of Atlantic Forest *Pleroma* trees

Fabien H. Wagner

O aprendizado profundo (CNN) com séries temporais Sentinel-2 (33.798 imagens) consegue mapear gêneros de árvores floridas em escala de bioma.

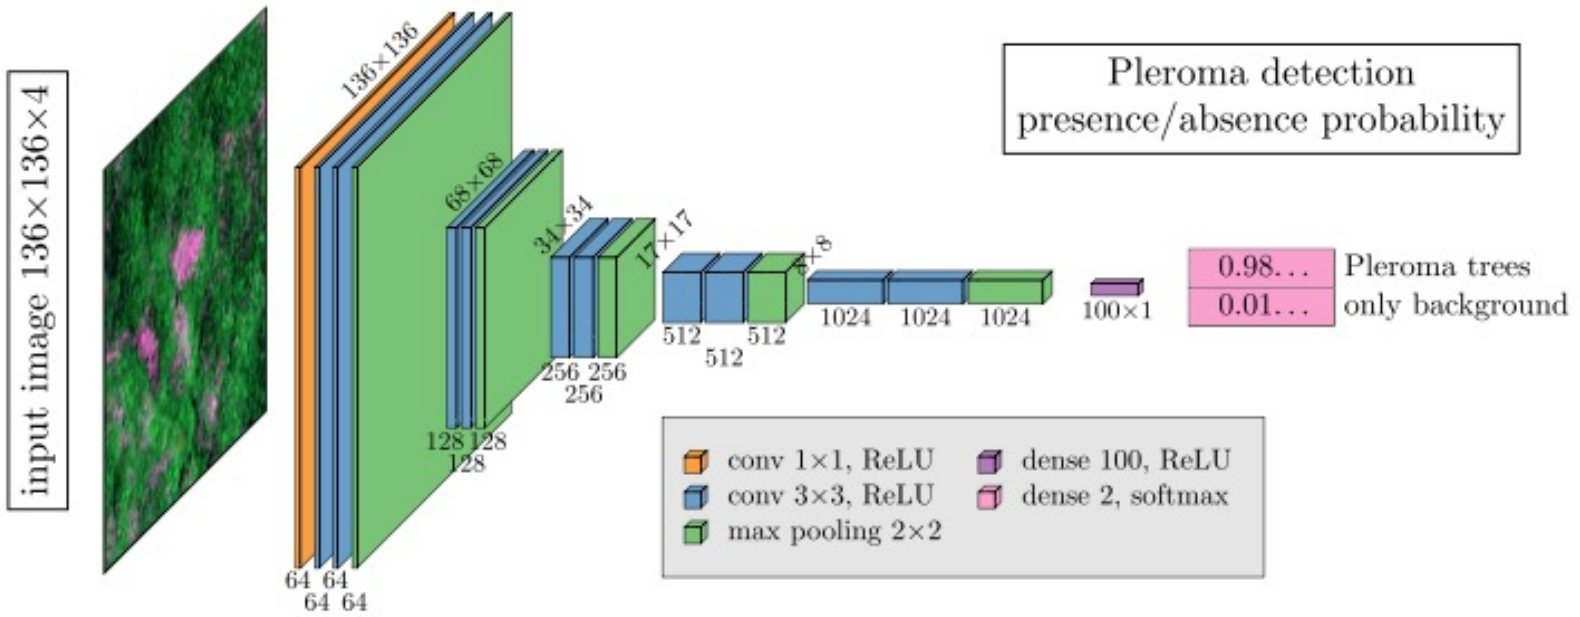


Figure 13. Architecture of the *Pleroma* blossom detection model.

https://agencia.fapesp.br/biologist-uses-satellite-imagery-and-ai-to-map-glory-trees-in-brazils-atlantic-rainforest/37886

https://doi.org/10.1038/s41598-021-99304-x

scientific reports Wagner (2021)

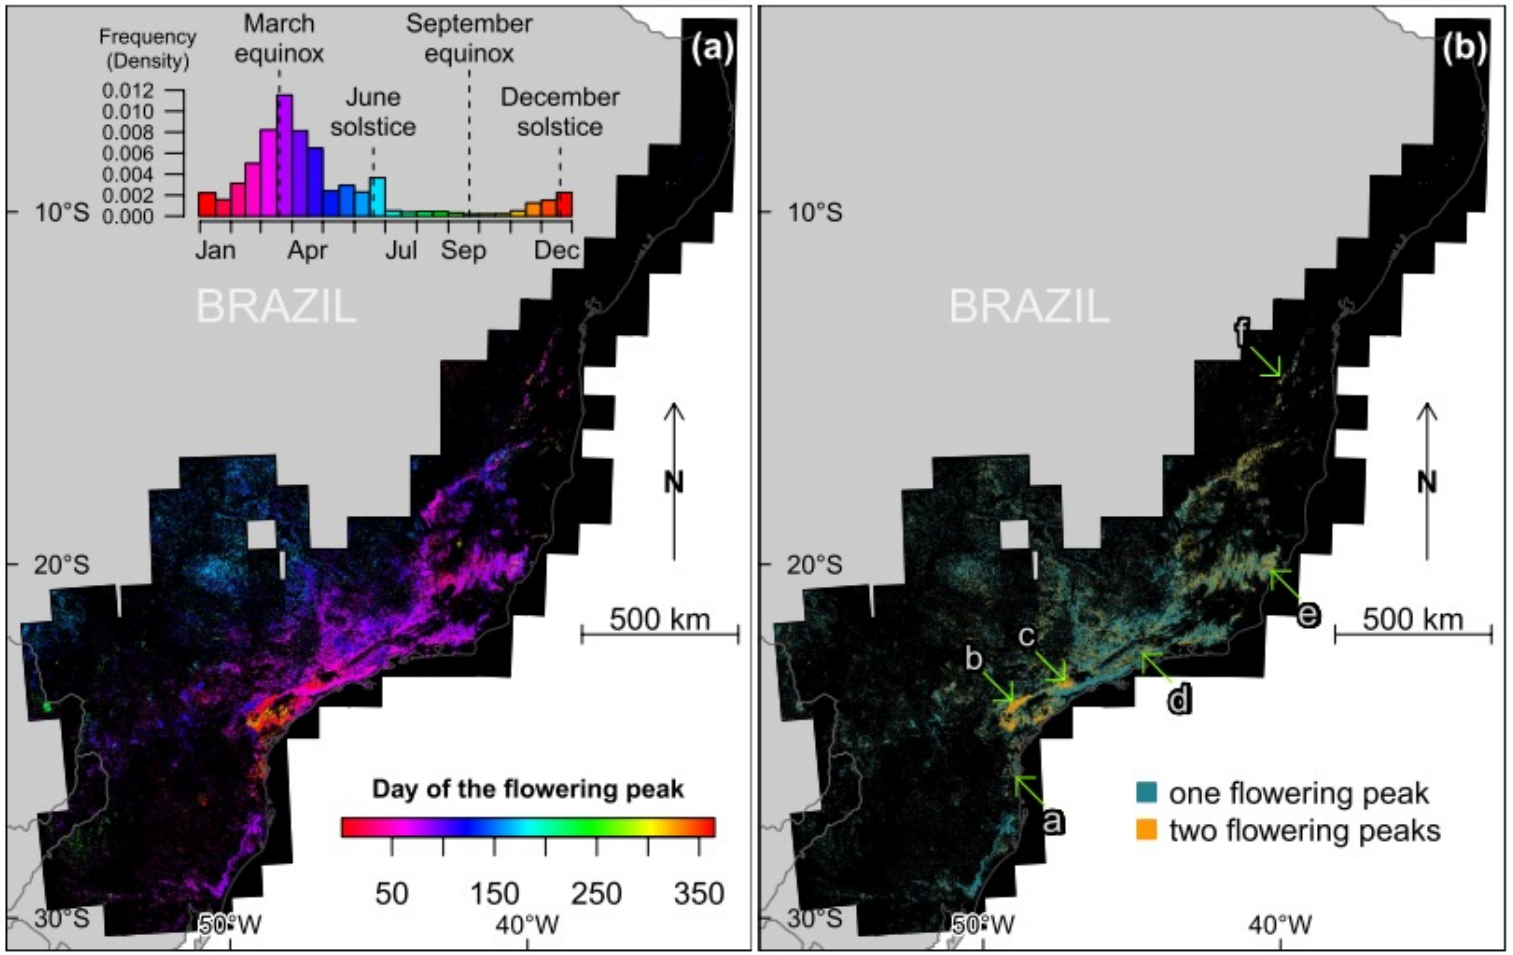
OPEN

The flowering of Atlantic Forest *Pleroma* trees

Fabien H. Wagner

comportamento biológico sazonal





eventos fenológicos (floração)

características muito discriminantes para o mapeamento de espécies com aprendizado profundo

usando imagens Sentinel-2 gratuitas

https://doi.org/10.1038/s41598-021-99304-x

Taher et al. (2026)

ISPRS Journal of Photogrammetry and Remote Sensing 233 (2026) 278–309

Contents lists available at ScienceDirect

ISPRS Journal of Photogrammetry and Remote Sensing

journal homepage: www.elsevier.com/locate/isprsjprs

Classificação de espécies arbóreas

Multispectral airborne laser scanning for tree species classification: A benchmark of machine learning and deep learning algorithms



Fig. 1. (a) The Espoonlahti study area is located in southern Finland. (b) Orthophoto of the Espoonlahti study area together with collected tree segments colored by the species in the reference dataset. The coverage of the HeliALS data is shown with the light blue line. Areas A and B are separated by the orange line. (c) A close-up of the orthophoto shown in (b). (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

Criar o **maior benchmark** para classificação de **espécies arbóreas** com **varredura a laser aerotransportada (ALS)** multiespectral e avaliar o desempenho de algoritmos de **AM** e **AP** de ponta.

Conjunto de dados

- 6.326 árvores rotuladas individualmente
- 9 espécies arbóreas
- Dois conjuntos ALS multiespectrais com densidades de pontos diferentes

Algoritmos comparados

- **Aprendizado de máquina:** Random Forest, XGBoost, LightGBM, MLP
- **Aprendizado profundo:** PointNet++, PointMLP, **Point Transformer**, DetailView

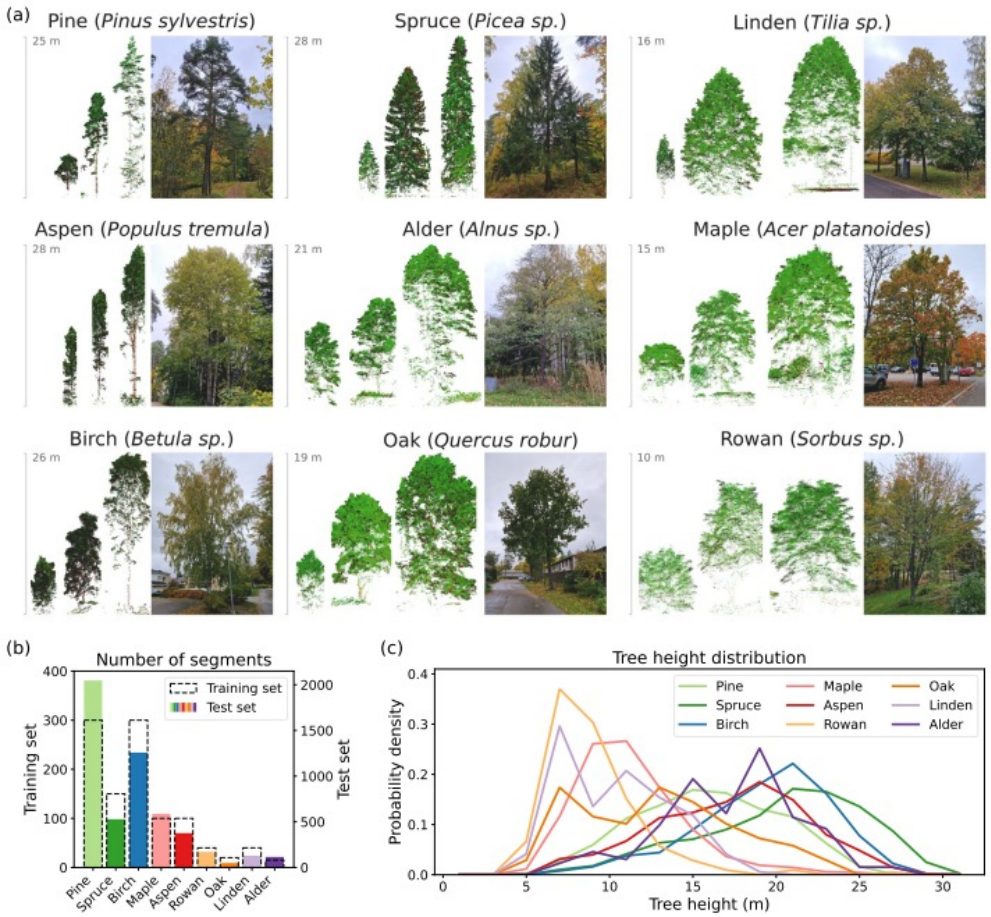
Taher et al. (2026)

ISPRS Journal of Photogrammetry and Remote Sensing 233 (2026) 278–309

Contents lists available at ScienceDirect

ISPRS Journal of Photogrammetry and Remote Sensing

journal homepage: www.elsevier.com/locate/isprsjprs



Comparação de desempenho

- **O Point Transformer** obteve a maior acurácia de classificação (**~92% de acurácia global**).
- O aprendizado profundo superou sistematicamente o aprendizado de máquina tradicional.
- A informação multiespectral melhorou bastante a acurácia em relação à geometria isolada.
- Os ganhos de desempenho foram especialmente evidentes para:
  - nuvens de pontos esparsas
  - conjuntos de treinamento maiores
  - espécies difíceis de distinguir

Taher et al. (2026)

ISPRS Journal of Photogrammetry and Remote Sensing 233 (2026) 278–309

Contents lists available at ScienceDirect

ISPRS Journal of Photogrammetry and Remote Sensing

journal homepage: www.elsevier.com/locate/isprsjprs

Multispectral airborne laser scanning for tree species classification: A benchmark of machine learning and deep learning algorithms

Classificação de espécies arbóreas

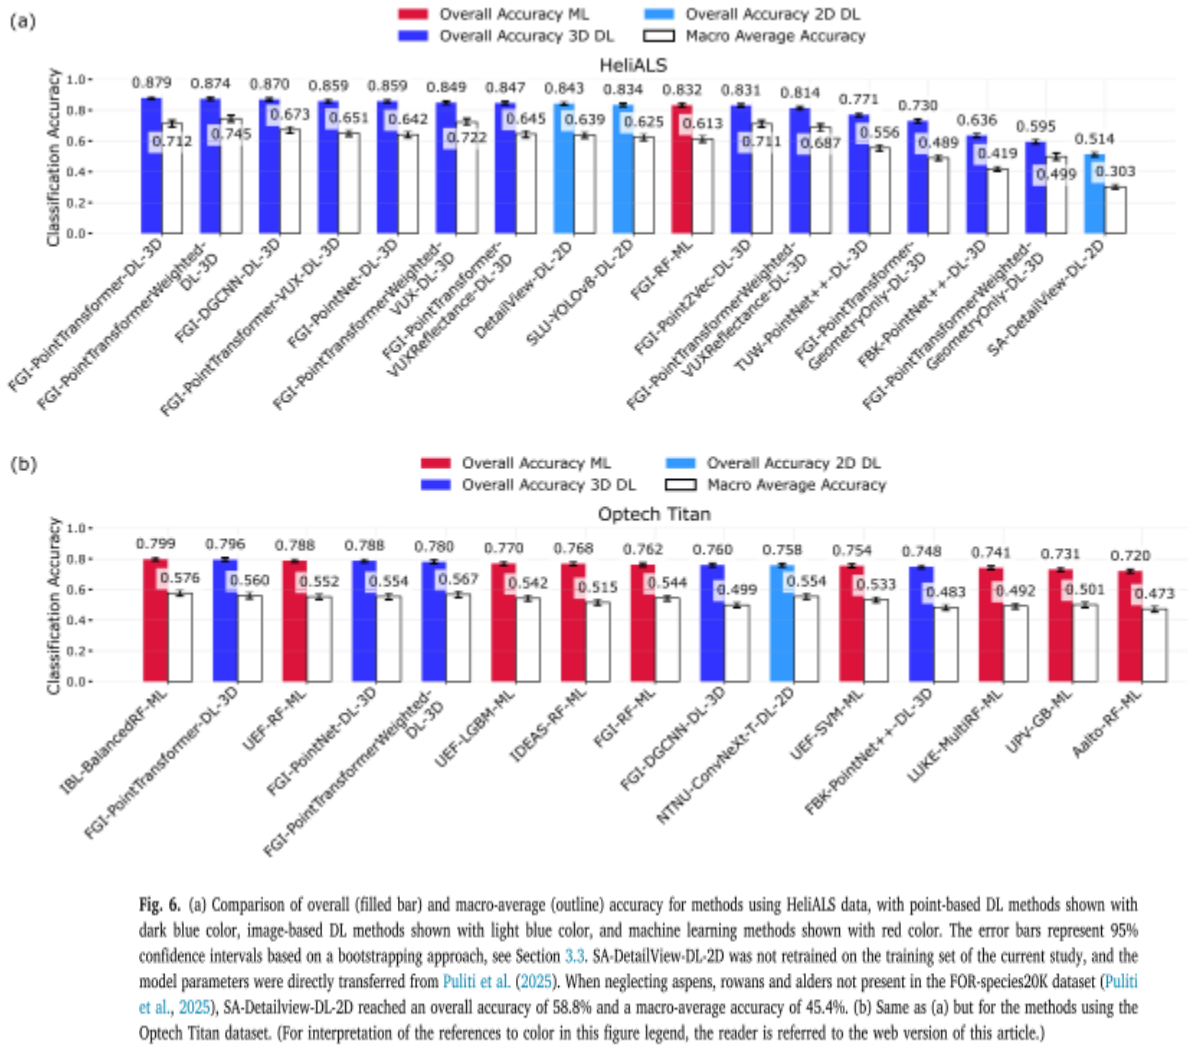


Fig. 6. (a) Comparison of overall (filled bar) and macro-average (outline) accuracy for methods using HeliALS data, with point-based DL methods shown with dark blue color, image-based DL methods shown with light blue color, and machine learning methods shown with red color. The error bars represent 95% confidence intervals based on a bootstrapping approach, see Section 3.3. SA-DetailView-DL-2D was not retrained on the training set of the current study, and the model parameters were directly transferred from Puliti et al. (2025). When neglecting aspens, rowans and alders not present in the FOR-species20K dataset (Puliti et al., 2025), SA-Detailview-DL-2D reached an overall accuracy of 58.8% and a macro-average accuracy of 45.4%. (b) Same as (a) but for the methods using the Optech Titan dataset. (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)

Principais contribuições

- Primeiro benchmark abrangente comparando AM e AP na classificação de espécies arbóreas com ALS multiespectral.
- Demonstrou a superioridade dos **modelos baseados em Transformers** sobre as abordagens tradicionais.
- Confirmou a importância de combinar informação **estrutural 3D** e **espectral** (no treinamento).
- Oferece um **conjunto de dados de referência aberto**, apoiando a pesquisa reproduzível e o desenvolvimento de métodos de IA de nova geração para o monitoramento florestal.

Avaliação de incêndios florestais

Avaliação de incêndios florestais

Article

Explainable AI-Driven Wildfire Prediction in Australia: SHAP and Feature Importance to Identify Environmental Drivers in the Age of Climate Change

Zina Abohaia [1,*], Abeer Elkhouly [2,*], May El Barachi [1] and Obada Al-Khatib [2]

Objetivo

- Desenvolver um **arcabouço de aprendizado de máquina interpretável** para prever características de incêndios florestais nas diversas regiões climáticas da Austrália.
- Identificar os **vetores ambientais** do comportamento do fogo usando **IA explicável (XAI)**.

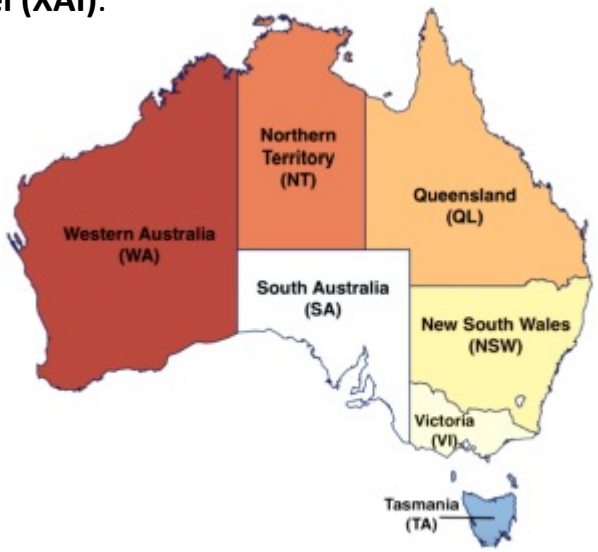


Figure 1. Study area: the seven Australian regions.

Metodologia

Área de estudo: sete regiões australianas (2005–2021).

Dados de entrada:

- Variáveis climáticas ERA5 (temperatura, precipitação, umidade, velocidade do vento, umidade do solo, radiação solar)
- Produtos MODIS de focos ativos

Variáveis de incêndio previstas:

- Área do incêndio (FA)
- Temperatura de brilho do incêndio (FBT)
- Potência radiativa do f

Modelos de aprendizado de n

- Regressão Lasso
- Random Forest
- LightGBM
- XGBoost

Explicabilidade:

- SHAP (SHapley Additive exPlanations)
- Análise de importância das variáveis para quantificar a contribuição de cada uma.

Inovação

Alto desempenho preditivo com **interpretabilidade do modelo** identificação dos processos físicos que controlam a ocorrência e a intensidade dos incêndios.

Article

Explainable AI-Driven Wildfire Prediction in Australia: SHAP and Feature Importance to Identify Environmental Drivers in the Age of Climate Change

Principais resultados

Umidade do solo, radiação solar, precipitação e umidade relativa são os principais preditores de incêndios.

A variabilidade climática e as condições extremas (variância, mínimos e máximos) são **mais informativas que as médias de longo prazo**.

A importância dos preditores varia entre as zonas climáticas australianas:

- **Regiões áridas:** o Lasso capta bem as relações lineares.
- **Regiões tropicais:** ensembles de árvores (LightGBM, Random Forest, XGBoost) representam melhor interações não lineares complexas.

Melhor desempenho preditivo:

- **Área do incêndio:** Tasmânia (LightGBM)
- **Potência radiativa do fogo:** Queensland (Lasso)

Potência radiativa do fogo

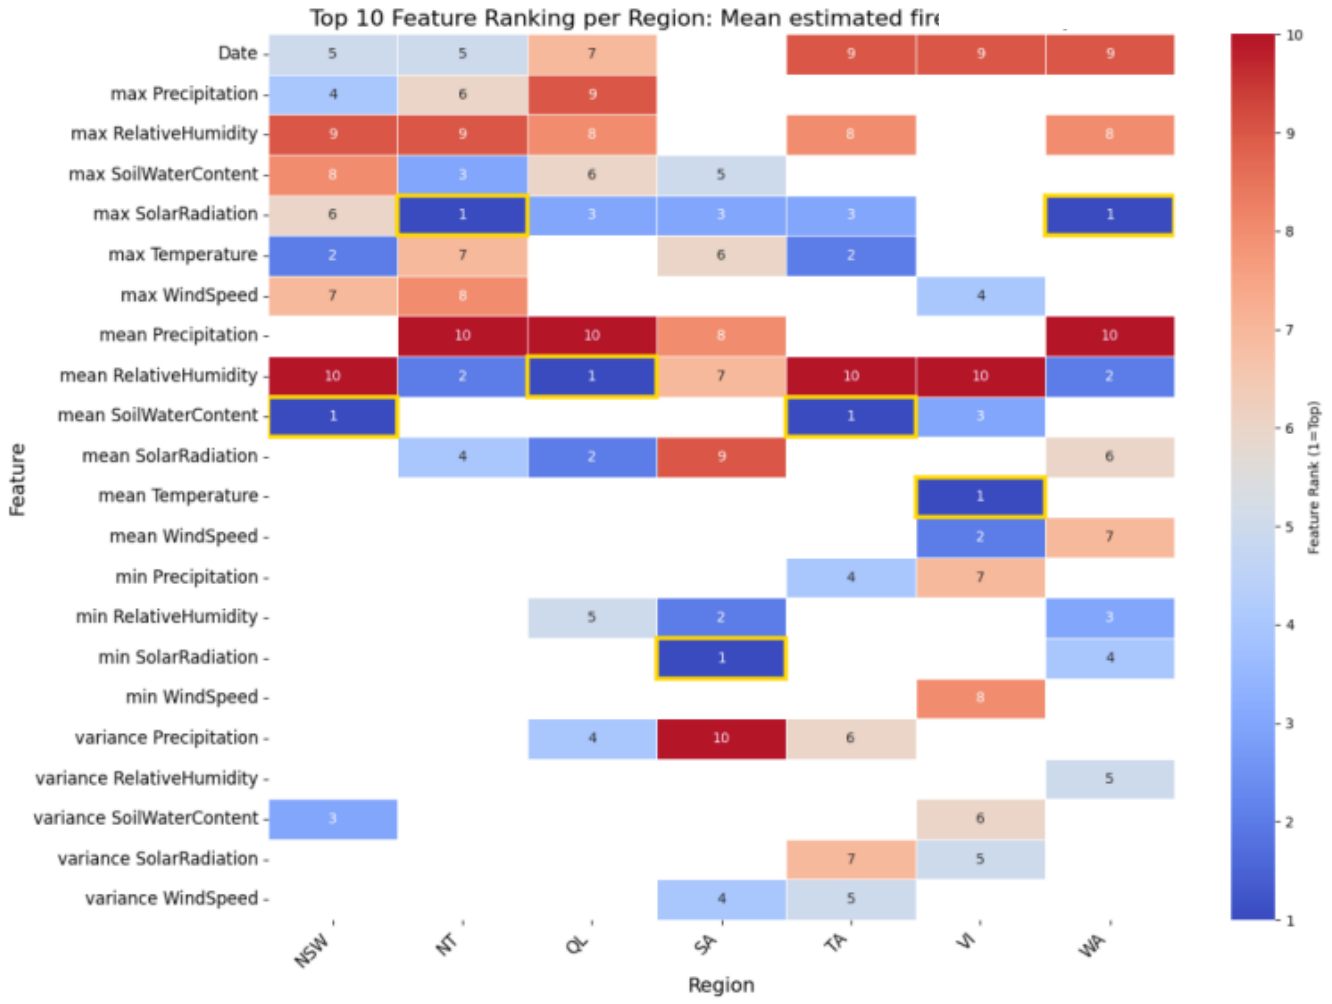


Figure 5. Top 10 features for each region's best model in predicting FRP, with 1 = Most Important to 10 = Least Important, and the yellow outline highlighting the top feature for that region.

fire Abohaia et al. (2023) MDPI

Article

Explainable AI-Driven Wildfire Prediction in Australia: SHAP and Feature Importance to Identify Environmental Drivers in the Age of Climate Change



Conclusões principais

O comportamento do fogo segue um processo hierárquico:

- **O estresse ambiental de longo prazo** (esgotamento da umidade do solo + radiação solar) determina o potencial de fogo.

- **A variabilidade meteorológica de curto prazo** (umidade, temperatura, vento) controla a ignição e a propagação.

A IA explicável fornece informações transparentes para a **gestão de incêndios adaptada a cada região**, apoiando a adaptação climática e a tomada de decisão operacional.

Trabalhos futuros devem integrar **modelos de base, transformers, IA generativa e fusão de dados de várias fontes** para a previsão de incêndios em tempo real.

forests Shahid et al. (2023) MDPI

Article

Forest Fire Segmentation via Temporal Transformer from Aerial Images

Mohammad Shahid [1], Shang-Fu Chen [1], Yu-Ling Hsu [2], Yung-Yao Chen [3], Yi-Ling Chen [1] and Kai-Lung Hua [1,*]

Objetivo

Desenvolver um **modelo eficiente de segmentação de incêndios em tempo real** para o monitoramento por vídeo de drones.

Superar as limitações dos métodos baseados em **CNN**, que muitas vezes não captam a informação **temporal** nem localizam com precisão as **bordas do fogo**.

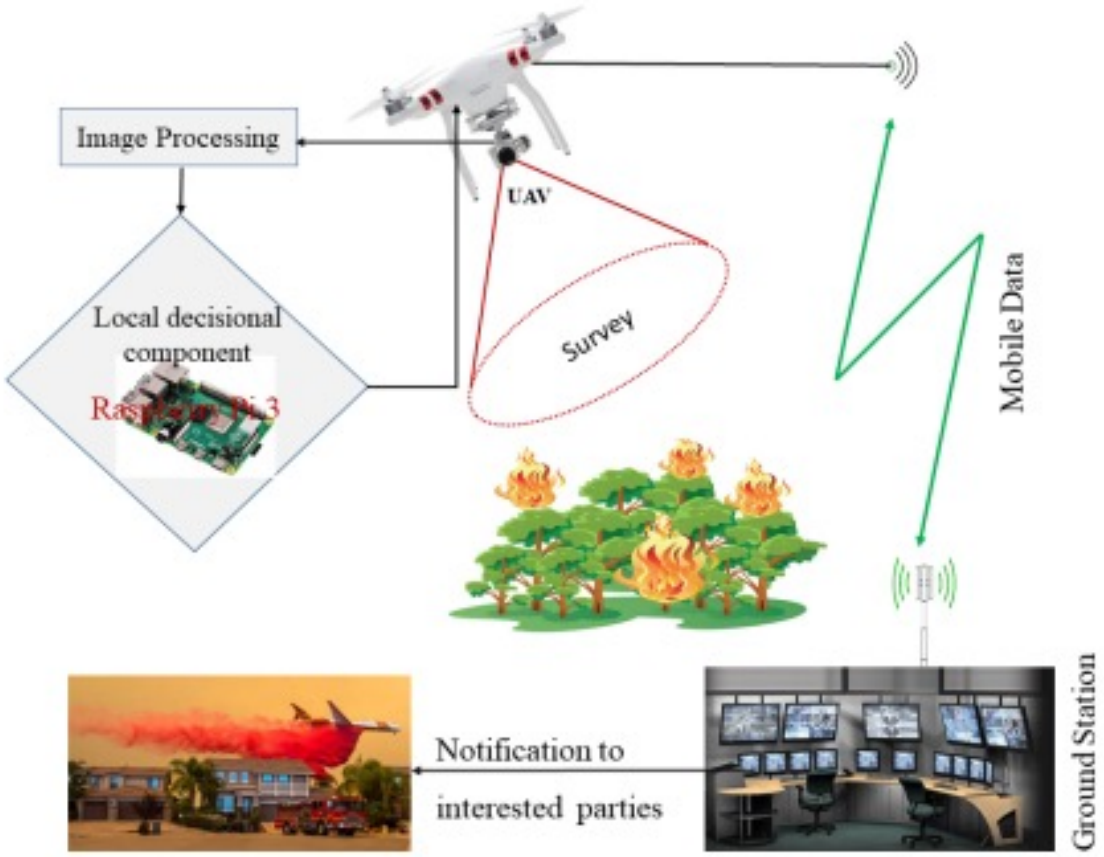


Figure 1. A conceptual model for early forest fire detection.

forests Shahid et al. (2023) MDPI

Article

Forest Fire Segmentation via Temporal Transformer from Aerial Images

Mohammad Shahid [1], Shang-Fu Chen [1], Yu-Ling Hsu [2], Yung-Yao Chen [3], Yi-Ling Chen [1] and Kai-Lung Hua [1,*]

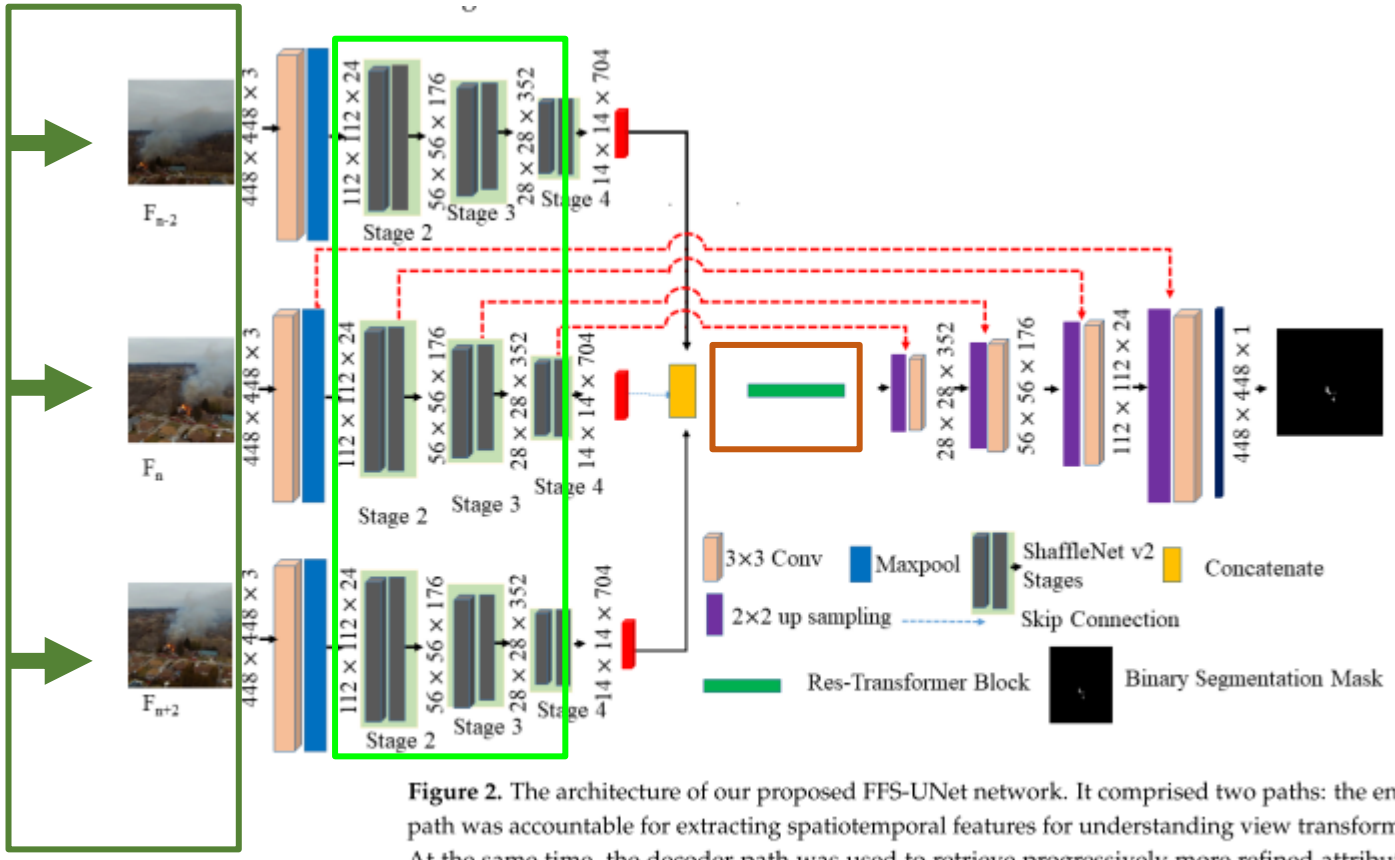


Figure 2. The architecture of our proposed FFS-UNet network. It comprised two paths: the encoder path was accountable for extracting spatiotemporal features for understanding view transformation. At the same time, the decoder path was used to retrieve progressively more refined attributes by combining information from the peer-encoder path.

Método proposto: FFS-UNet

Nova arquitetura **UNet + Vision Transformer (ViT)** para segmentação semântica do fogo.

Três ramos de codificador em paralelo processam três quadros consecutivos do drone (Fn−2, Fn, Fn+2) para aprender **informação espacial e temporal**.

O módulo Transformer modela **dependências temporais de longo alcance**, distinguindo melhor o fogo de objetos visualmente parecidos.

Uma backbone leve **ShuffleNetV2** reduz o custo computacional, tornando o modelo adequado para **dispositivos de borda e drones**.

Uma perda combinada **Dice + entropia cruzada binária** melhora a segmentação com classes desbalanceadas.

forests Shahid et al. (2023) MDPI

Article

Forest Fire Segmentation via Temporal Transformer from Aerial Images

Mohammad Shahid [1], Shang-Fu Chen [1], Yu-Ling Hsu [2], Yung-Yao Chen [3],



Principais resultados e contribuições

Desempenho

Alcançou **desempenho de ponta** em conjuntos de dados de incêndios filmados por drones:
(**IoU:** 86,8%; **precisão:** 96,3%, **revocação:** 94,0%, **F1:** 95,1%, **acurácia:** 97,9%)

Vantagens

Superou **UNet, DeepLabV3+, TransUNet, Swin-UNet, SegFormer e STNet+DenseFire**.

Localização do fogo mais precisa, com menos falsos positivos, sobretudo em cenas difíceis (fumaça, sombras, fundos poluídos).

Demonstrou forte **generalização** no conjunto independente Corsican Fire.

Robusto à degradação de imagens (neblina, ruído gaussiano e desfoque de movimento).

Implementação leve (**14,2 milhões de parâmetros**) a **66 FPS**, permitindo **implantação em tempo real em drones**.

A informação temporal é crucial para detectar incêndios.

Integrar **Vision Transformers** à **UNet** torna a segmentação do fogo mais confiável que as CNNs de imagem única, oferecendo uma solução prática para o **monitoramento de incêndios em tempo real e alerta precoce**.

Um dos primeiros exemplos combinando **Vision Transformers** e **segmentação semântica** para a **detecção de incêndios**

Inovação: o uso do **contexto temporal dos vídeos de drone**, em vez da classificação ou segmentação de imagens isoladas.

INPE Programa Queimadas

O PROGRAMA QUEIMADAS do INPE pesquisa, desenvolve, opera e divulga sistemas de dados e informação para o monitoramento de queimadas na vegetação por satélite.

FOCOS ATIVOS

Mostra onde estão os focos ativos quase em tempo real com imagens de satélite.

ÁREA QUEIMADA

Determina a extensão da vegetação atingida pelo fogo.

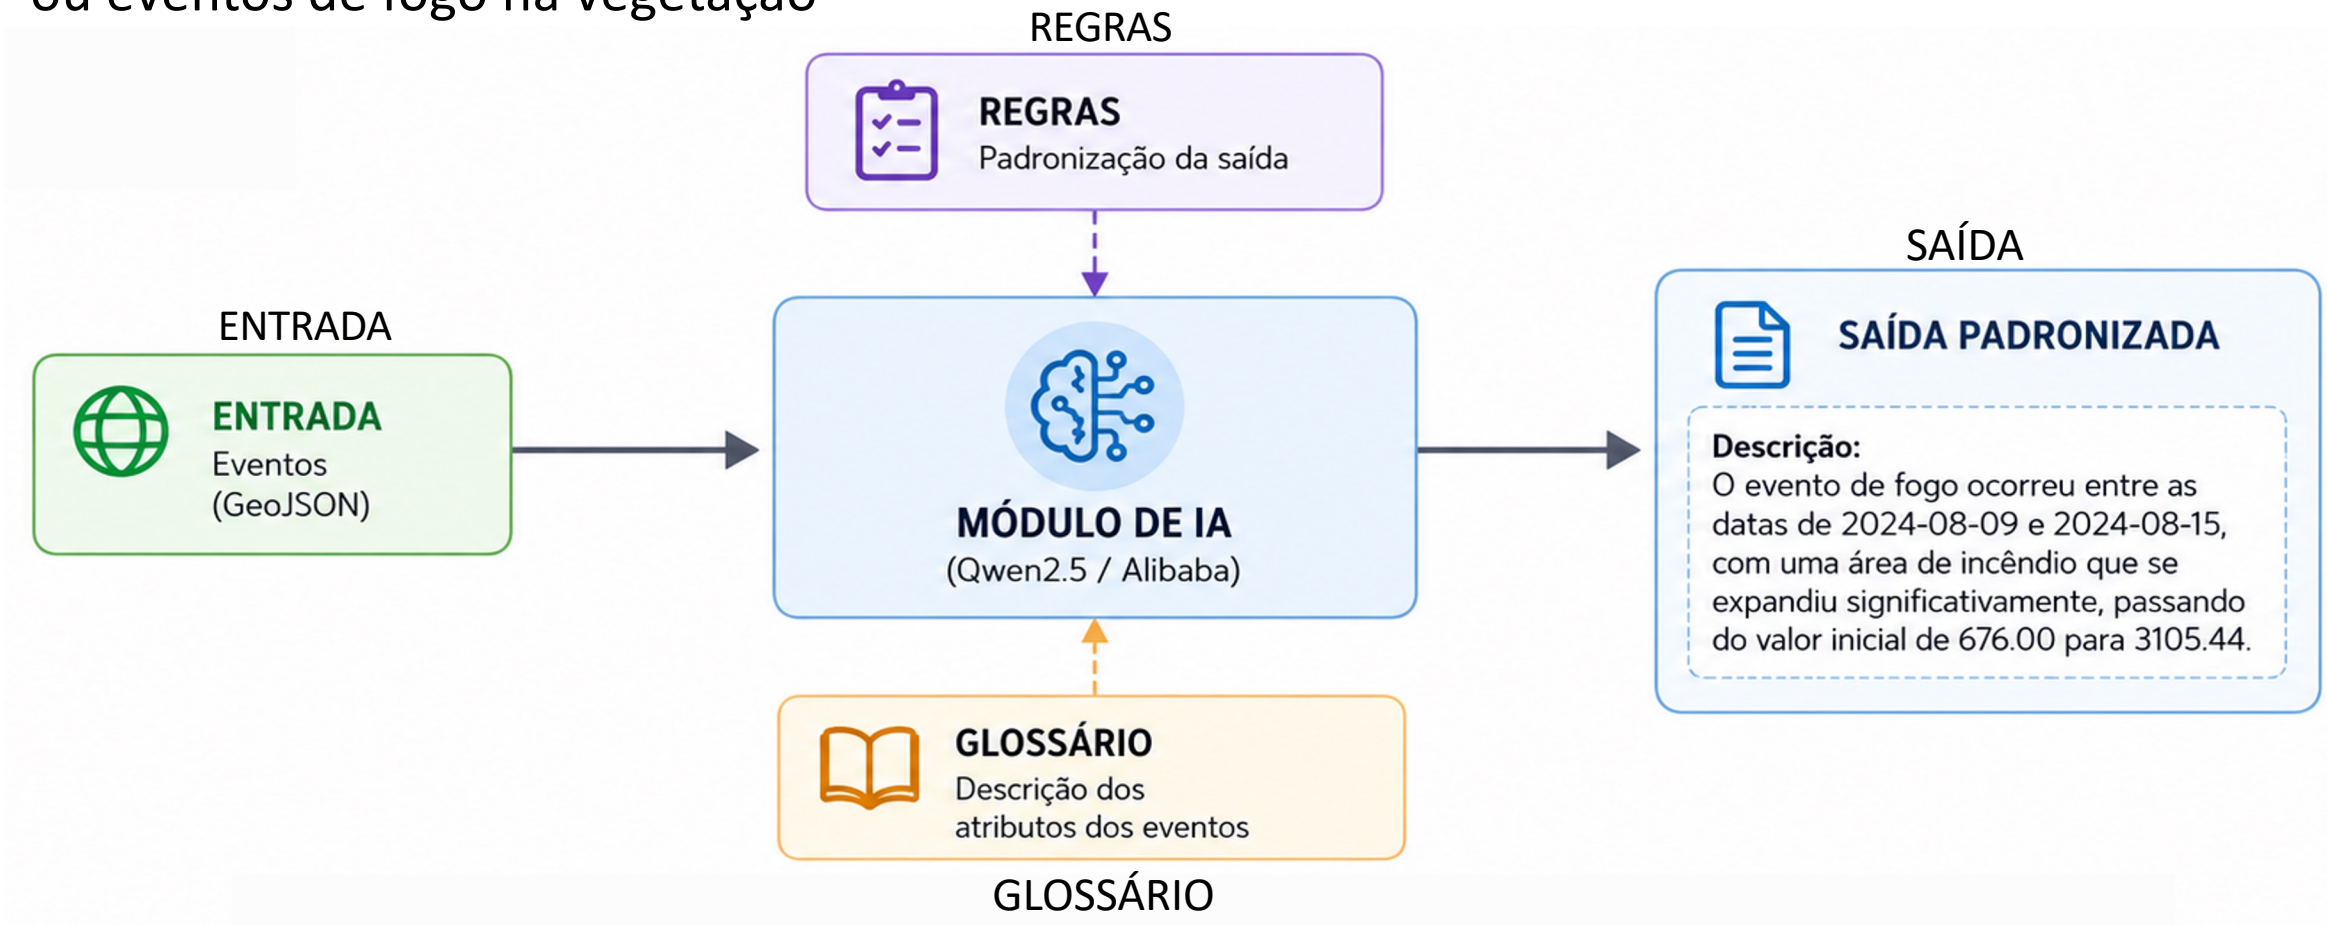
RISCO DE FOGO

Previsão do risco de fogo na vegetação com base em dados meteorológicos.



IA para caracterizar o fogo: **Descreve Fogo**

Geração de um texto consolidado, com dados integrados, para descrever regiões ou eventos de fogo na vegetação



IA para caracterizar o fogo: **Descreve Fogo**

Exemplos de informações geradas pelo **DescrEVE**

Descrição situação atual do município de CAXIAS-MA

Na data de **15/10/2025**, o município de Caxias obteve **7 eventos** de fogo, sendo o **1º maior registrado** para o histórico do período, representando **1,4%** dos eventos do Maranhão, que teve **503 eventos**. A média FRP foi de **51,71 MW**. O maior evento em área de Caxias teve um acumulado de **12.427,93 hectares**.

Descrição do evento mais significativo do município

Local:	Classificação:	Período:	Área acumulada afetada:
Assentamento Pa Engenho Dgua	**Incêndio**	**17/08/2025 a 15/10/2025 (60 dias)**	**12.427,93 ha**

- É registrada uma sequência de **19 dias** sem precipitação, contribuindo para a senescência/envelhecimento da vegetação e aumentando a probabilidade de continuidade do evento.
- O evento apresenta **91 frentes** de fogo ativas ao longo do período monitorado.
- A análise da progressão do evento demonstra que a área afetada apresenta um acréscimo de **1.791,35 hectares** desde a última atualização.
- Comparando-se com a amplitude histórica de expansão da área para este evento, observa-se que a variação permanece dentro da faixa de **99,97 a 12.427,93 hectares**.
- O evento é o maior evento em quantidade de frente, maior evento em duração e maior evento em área acumulada para a data de **17/08/2025** no Assentamento Pa Engenho Dgua.

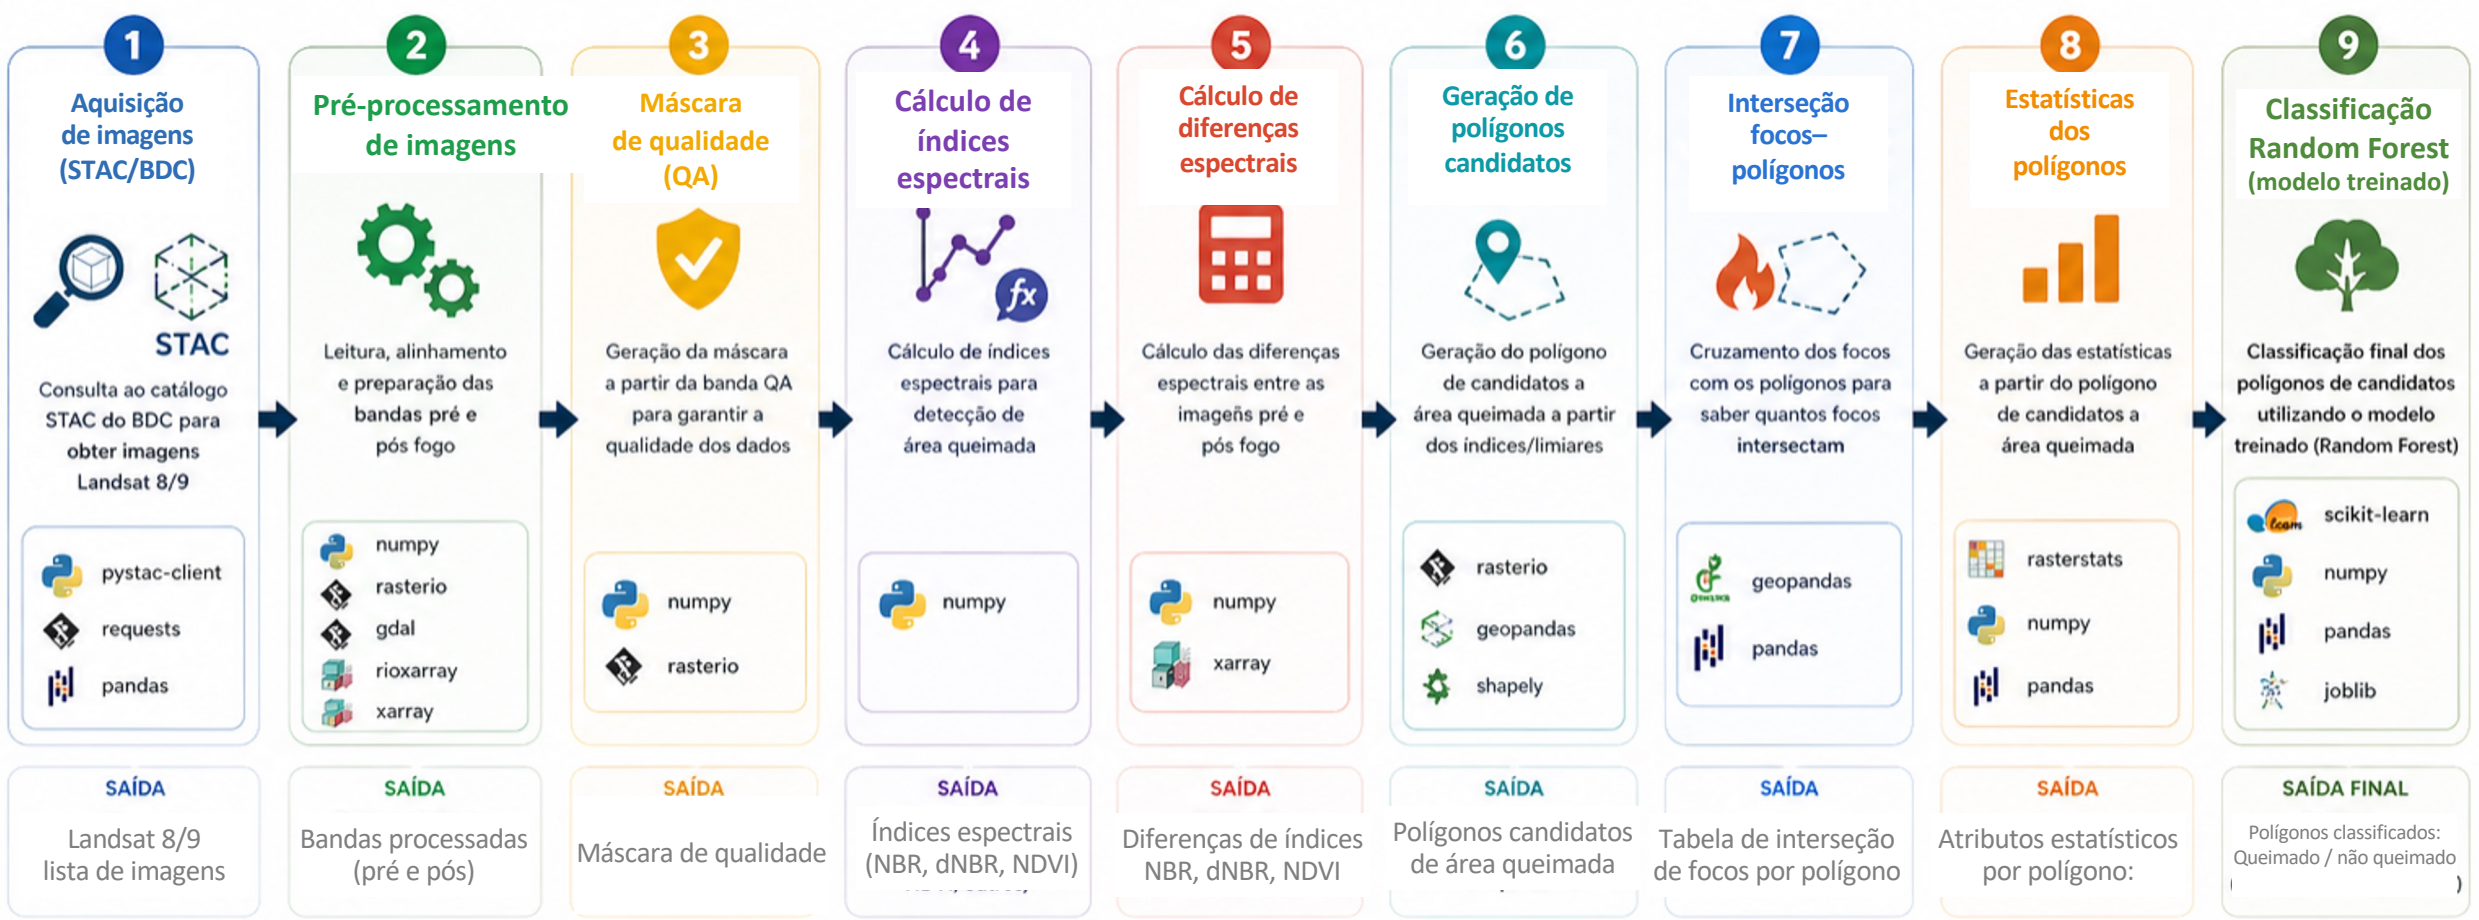
Quantidade de frentes
91 frentes
Média na região: **48** frentes
Posicionado entre os **100%** maiores

Duração do evento
60 dias
Média na região: **32** dias
Posicionado entre os **100%** que duram mais tempo

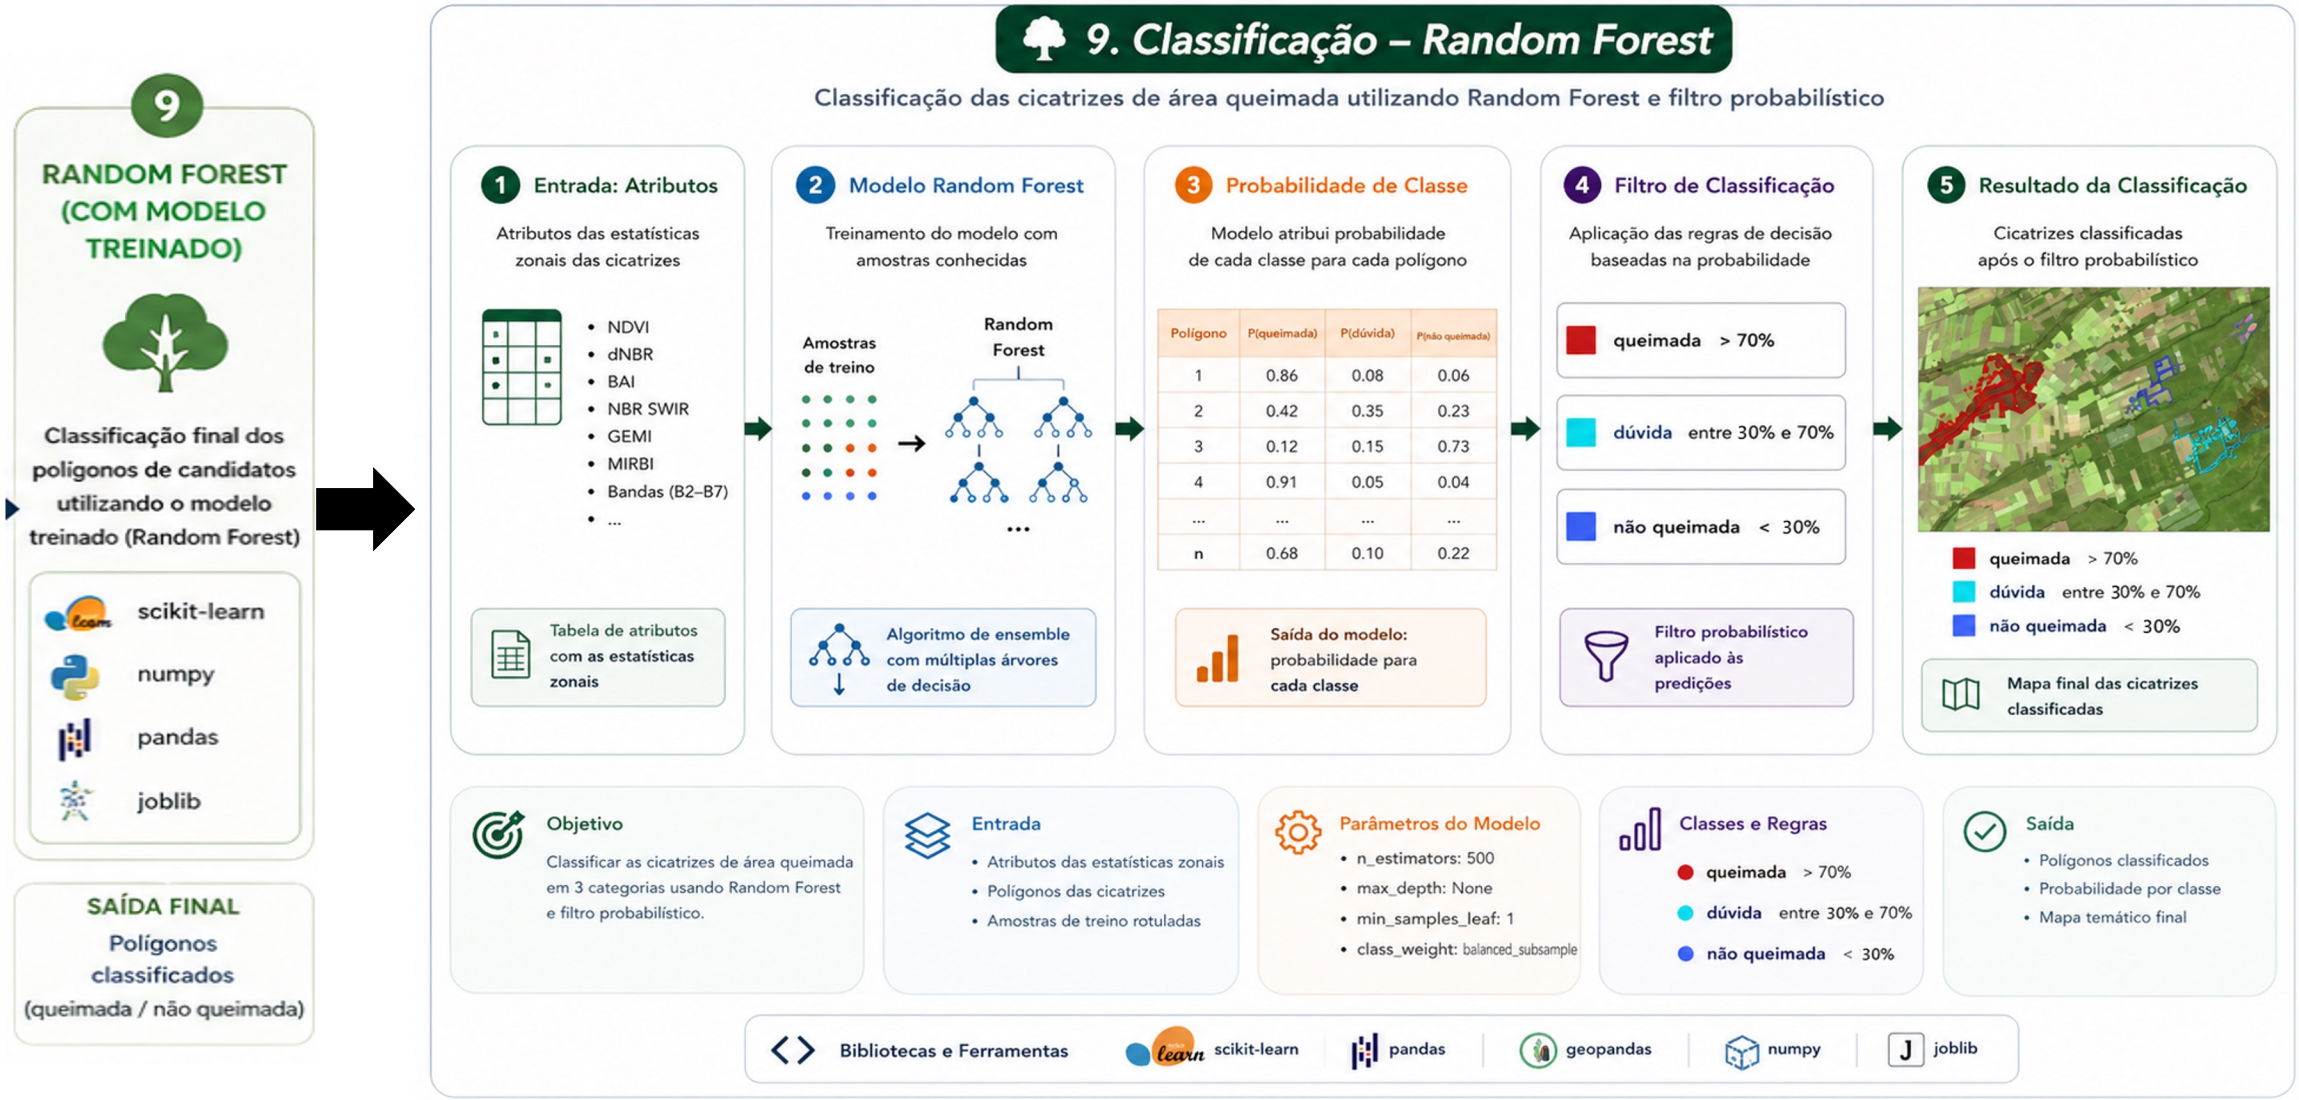
Área afetada
12.427,93 ha
Média na região: **7.177,11** ha
Posicionado entre os **100,0%** que afetam as maiores áreas

Resumo geral
Este evento apresenta atividade acima do normal para a região em todos os aspectos analisados, destacando-se como um evento extremo em frentes de fogo, duração e área afetada.

MAPIA30M – Áreas queimadas no BDC



Metodologia de controle de qualidade dos dados disponibilizados aos usuários.





IA-FogoBio

Instituto Federal do Amazonas (IFAM)



Foto: CARL DE SOUZA/AFP

Redes neurais LSTM (Long Short-Term Memory), redes convolucionais e Random Forest

Histórico de incêndios dos últimos 20 anos, vegetação, tipo de solo e condições ambientais áreas com maior risco de fogo.

Áreas de risco (7 a 14 dias) e alertas (6 horas)

Ibama / ICMBio Tempo para planejar o envio de brigadistas, equipamentos e rotas de ação preventiva

Monitora 100% das terras indígenas, unidades de conservação e territórios quilombolas do bioma Amazônia

Financiado pelo Google.org com R$ 1,9 milhão

Hub de Inovação do IFAM / Centro Gestor e Operacional do Sistema de Proteção da Amazônia (Censipam)

https://18horas.com.br/noticias/ia-desenvolvida-no-instituto-federal-do-amazonas-promete-prever-queimadas-na-amazonia-com-ate-14-dias-de-antecedencia/

Estimativa de biomassa e carbono

Biomassa e carbono: evolução

A biomassa acima do solo (AGB) como variável climática essencial

A estimativa de biomassa florestal passou de modelos empíricos locais para abordagens globais baseadas em IA que integram sensoriamento remoto e observações de campo.

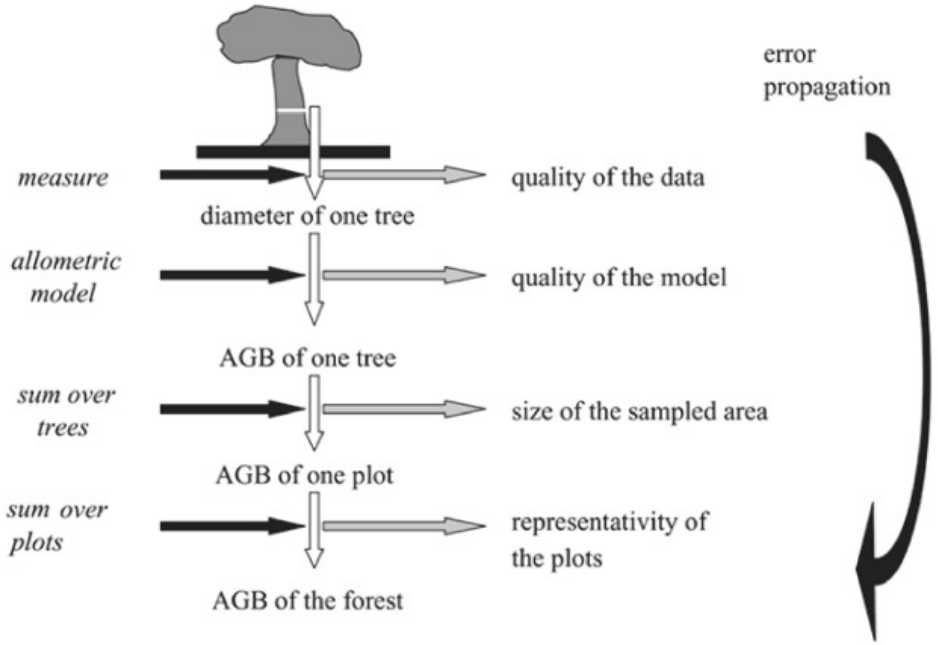


Fig. 1. Procedure for biomass estimation in plots and its error propagation (Rodríguez et al., 2017).

Trees, Forests and People 22 (2025) 101057

Contents lists available at ScienceDirect

Trees, Forests and People

journal homepage: www.sciencedirect.com/journal/trees-forests-and-people

Quantifying forest above ground biomass: a critical review of methods, challenges, and opportunities

Fortunate Kemigyisha [a,*], Evet Naturinda [b], Emmanuel Omia [a], Jackline Aboth [a], Denis Mutiibwa [c], Isa Kabenge [a], Anthony Gidudu [b], Nicholas Kiggundu [a]

[a] Department of Agricultural and Biosystems Engineering, Makerere University, P.O. Box 7062, Kampala, Uganda
[b] Department of Geomatics and Land Management, Makerere University, P.O. Box 7062, Kampala, Uganda
[c] 1410 Montello Ave NE #2 Washington DC, 20002, USA

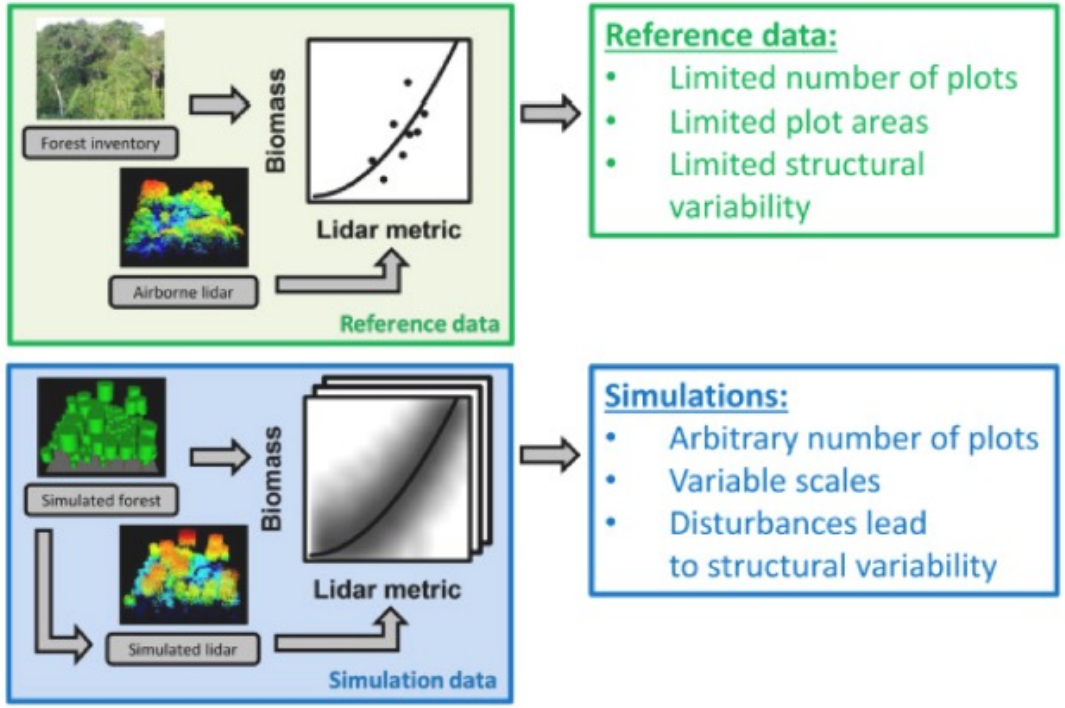


Fig. 2. Use of LiDAR data for biomass estimation (Knapp et al., 2018).

Biomassa e carbono: evolução

Inventários florestais → sensoriamento remoto → inteligência artificial

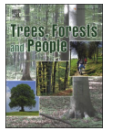
Variáveis ambientais e biomassa:
AM (Random Forest, SVM, redes neurais artificiais) e AP superam os métodos estatísticos convencionais.

Trees, Forests and People 22 (2025) 101057

Contents lists available at ScienceDirect

Trees, Forests and People

journal homepage: www.sciencedirect.com/journal/trees-forests-and-people



Quantifying forest above ground biomass: a critical review of methods, challenges, and opportunities

Fortunate Kemigyisha [a,*], Evet Naturinda [b], Emmanuel Omia [a], Jackline Aboth [a], Denis Mutiibwa [c], Isa Kabenge [a], Anthony Gidudu [b], Nicholas Kiggundu [a]

[a] Department of Agricultural and Biosystems Engineering, Makerere University, P.O. Box 7062, Kampala, Uganda
[b] Department of Geomatics and Land Management, Makerere University, P.O. Box 7062, Kampala, Uganda
[c] 1410 Montello Ave NE #2 Washington DC, 20002, USA

Modelos estatísticos → Random Forest / XGBoost → Aprendizado profundo (CNN) → Vision Transformers → Modelos de base → Modelos em escala global

A IA está transformando a estimativa de biomassa e carbono florestal
de modelos específicos de cada local em sistemas de previsão escaláveis e aplicáveis globalmente.

Integração de dados

Fusão de dados multissensor, IA explicável (XAI), LiDAR orbital e computação em nuvem

Óptico + SAR + LiDAR melhora mais a estimativa de AGB do que um único algoritmo de IA

O sensoriamento remoto multifonte importa mais que qualquer algoritmo

forests

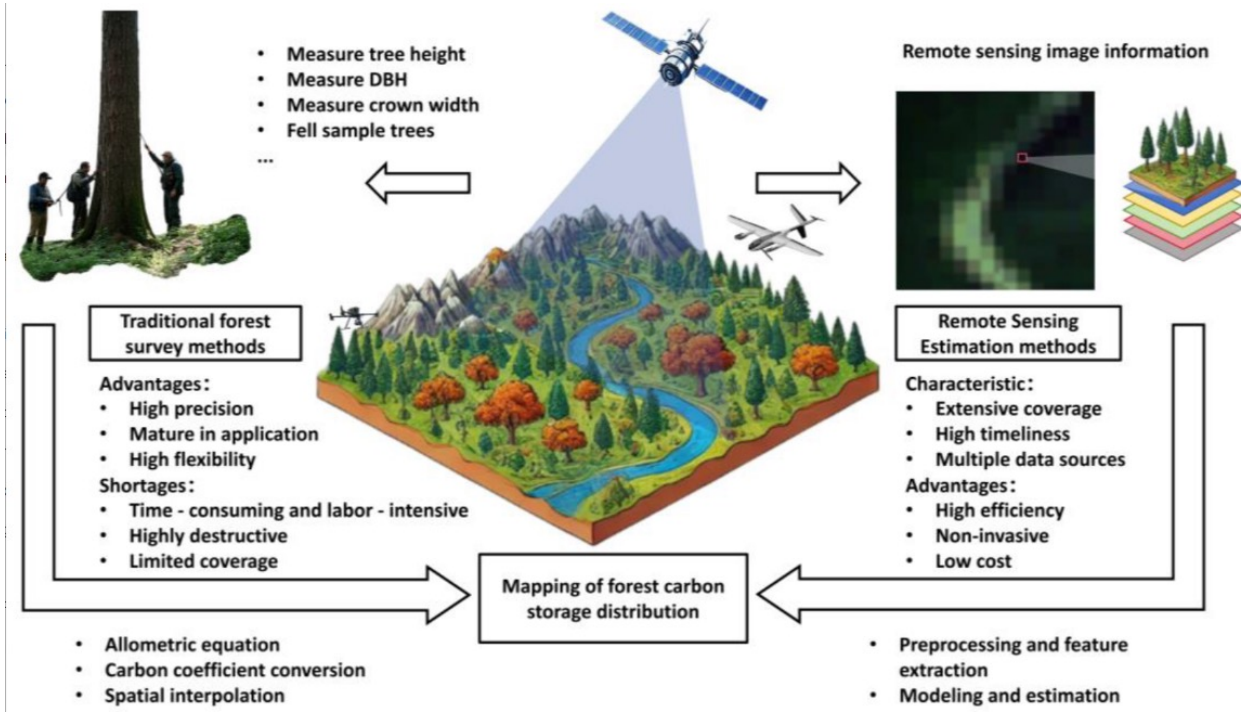
MDPI

Review

Progress and Limitations in Forest Carbon Stock Estimation Using Remote Sensing Technologies: A Comprehensive Review

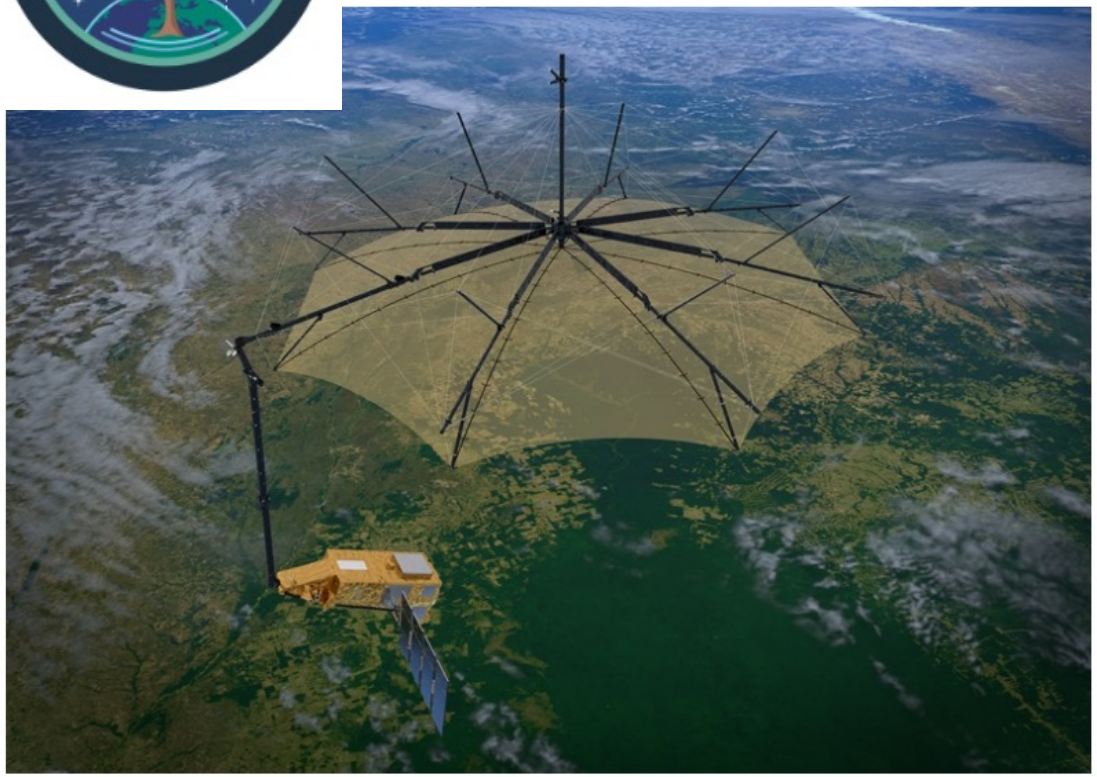
Weifeng Xu [1,†], Yaofei Cheng [2,†], Mengyuan Luo [3], Xuzhi Mai [4], Wenhuan Wang [3,4], Wei Zhang [4,*] and Yinghui Wang [3,4,*]

(2025)

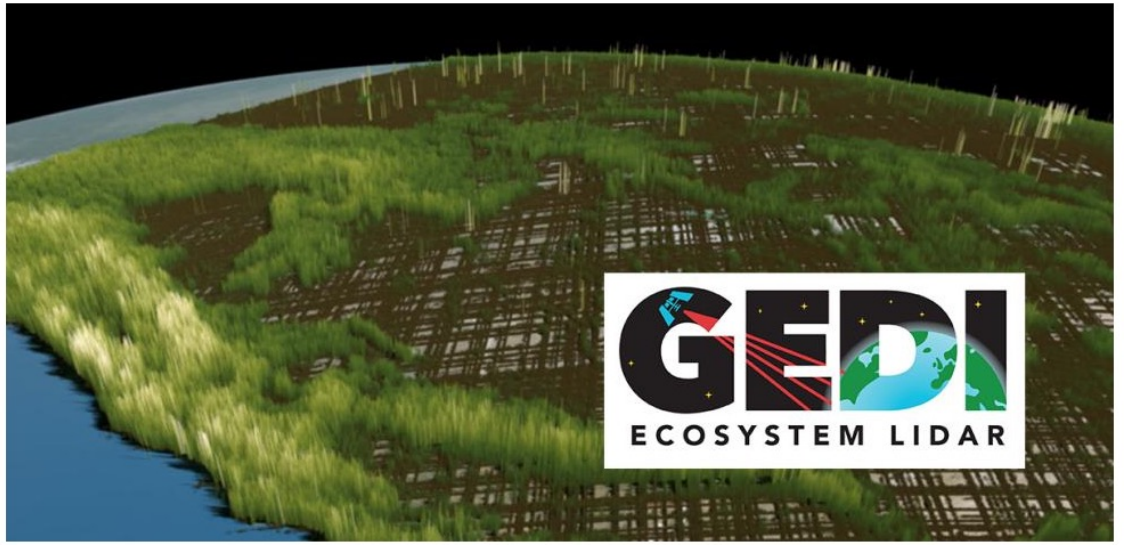


Perspectivas

- Maior integração das **missões LiDAR orbitais** (GEDI, ICESat-2).
- Uso crescente de **inteligência artificial** e de abordagens de modelagem híbridas.
- Desenvolvimento de **modelos globais transferíveis** capazes de generalizar entre ecossistemas.
- Melhor **avaliação da incerteza** e **protocolos de validação padronizados**.
- Espera-se que os **modelos de base** emergentes e o aprendizado autossupervisionado melhorem a estimativa de carbono ao aproveitar grandes conjuntos de dados multimodais de observação da Terra.



BIOMASS – a missão florestal da ESA



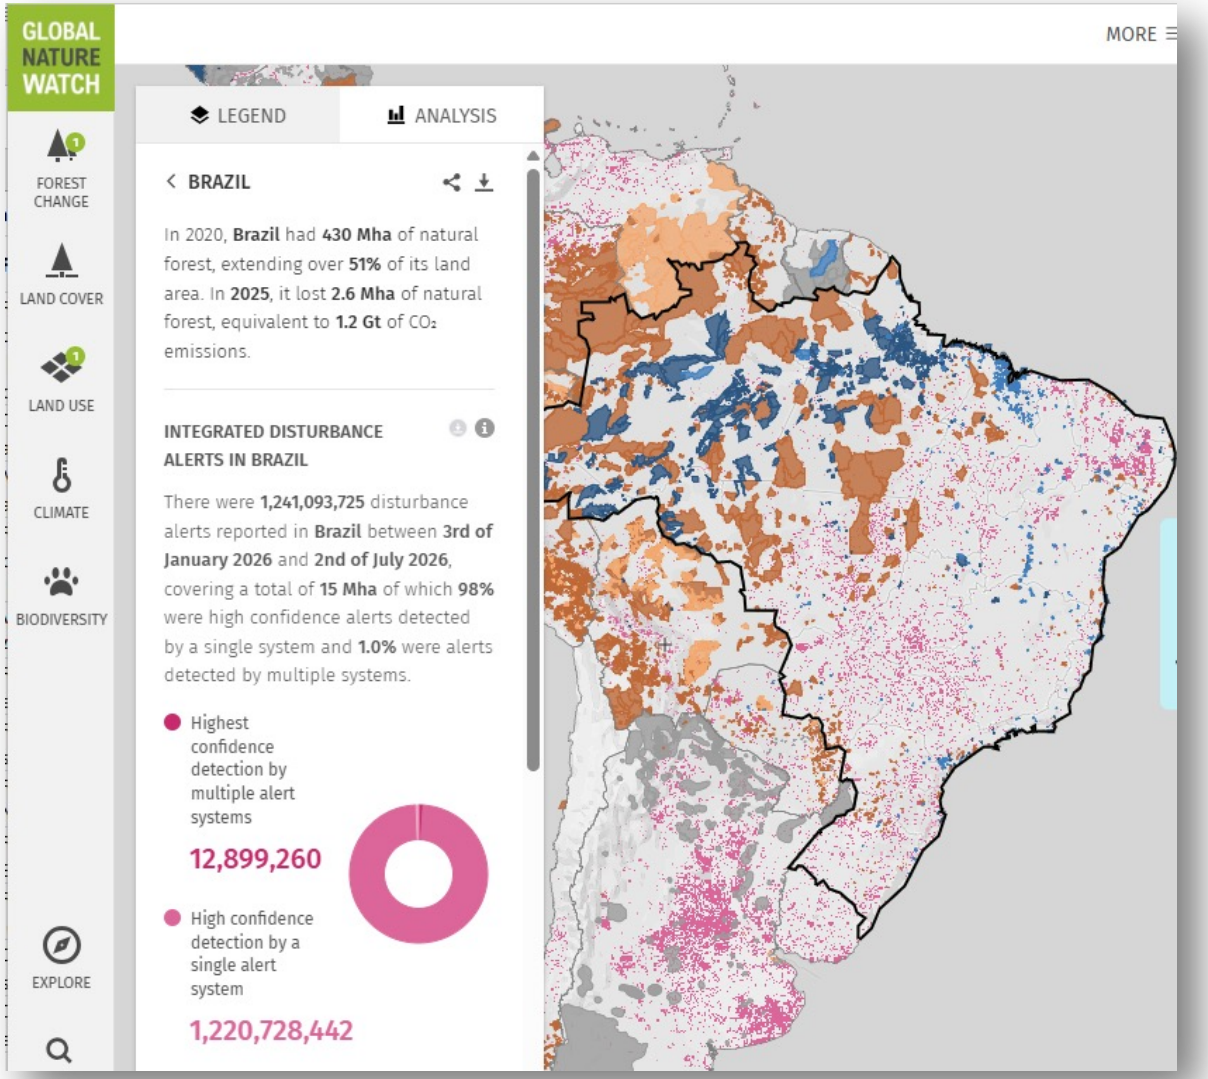
Global Ecosystem Dynamics Investigation Lidar (GEDI Lidar)

IA para florestas em outros lugares, como….
ÁFRICA?

Iniciativa	Abrangência geográfica	Aplicação principal	Uso da IA	Fontes de dados
FAO AIM4Forests	Pan-africana (p. ex., RDC, Gana, Quênia, Uganda)	Sistemas nacionais de **monitoramento** florestal (SNMF), **REDD+**, contabilidade de **carbono**	**Aprendizado de máquina** para mapeamento florestal, estimativa de biomassa, detecção de mudanças e apoio à decisão	Sentinel-1, Sentinel-2, Landsat, GEDI, inventários de campo
Open Foris / SEPAL (FAO)	Pan-africana	Monitoramento **florestal** operacional, mapeamento da cobertura da terra, avaliação do desmatamento	**Classificação por aprendizado de máquina**, **fluxos de IA em nuvem**, modelagem do risco de desmatamento	Landsat, Sentinel, Planet (quando disponível), dados de campo
SERVIR Africa (NASA–USAID)	Vários países africanos	Monitoramento **florestal**, detecção de fogo, **restauração**, avaliação de **biomassa**	**Aprendizado de máquina** para classificação da cobertura da terra, detecção de degradação florestal e modelos ambientais preditivos	Dados ópticos, SAR, climáticos e geoespaciais
Global Forest Watch Africa (WRI)	Pan-africana	Alertas de desmatamento quase em tempo real e **monitoramento** de mudanças florestais	**Detecção de mudanças assistida por IA**, modelos preditivos de desmatamento, avaliação de risco	Landsat, Sentinel, radar, dados espaciais auxiliares
Programas de monitoramento florestal da Bacia do Congo	África Central	Cobertura florestal, **biomassa, estoque de carbono,** monitoramento da **exploração madeireira** ilegal	**Aprendizado de máquina** para estimativa de biomassa, classificação da cobertura da terra, detecção de mudanças	Sentinel-1, Sentinel-2, Landsat, LiDAR, parcelas de campo
IA para o monitoramento de paisagens de cacau	Gana, Costa do Marfim	**Monitoramento do desmatamento ligado ao cacau e conformidade com o EUDR**	**Aprendizado profundo**: segmentação de imagens, classificação do uso da terra, detecção de mudanças	Sentinel-1, Sentinel-2, imagens de alta resolução
Regreening Africa (CIFOR-ICRAF)	África Oriental e Ocidental	Planejamento da **restauração** de paisagens florestais e da **agrofloresta**	**Assistida por IA**: planejamento da restauração, modelagem de adequação de espécies, monitoramento da restauração	Imagens de satélite, clima, solos, observações de campo
M-Situ	Quênia	Detecção de **exploração madeireira** ilegal e incêndios florestais	**IA embarcada** para detecção de eventos sonoros (motosserras, tiros, incêndios) com alertas automáticos	Sensores acústicos (IoT), IA de borda
Iniciativa de pesquisa Miti360	Quênia	**Monitoramento do** reflorestamento **e inventário de árvores**	**Aprendizado profundo** para detecção de árvores, delimitação de copas, monitoramento do crescimento	Imagens de drone, dados de campo, observações meteorológicas

IA e monitoramento florestal - GFW

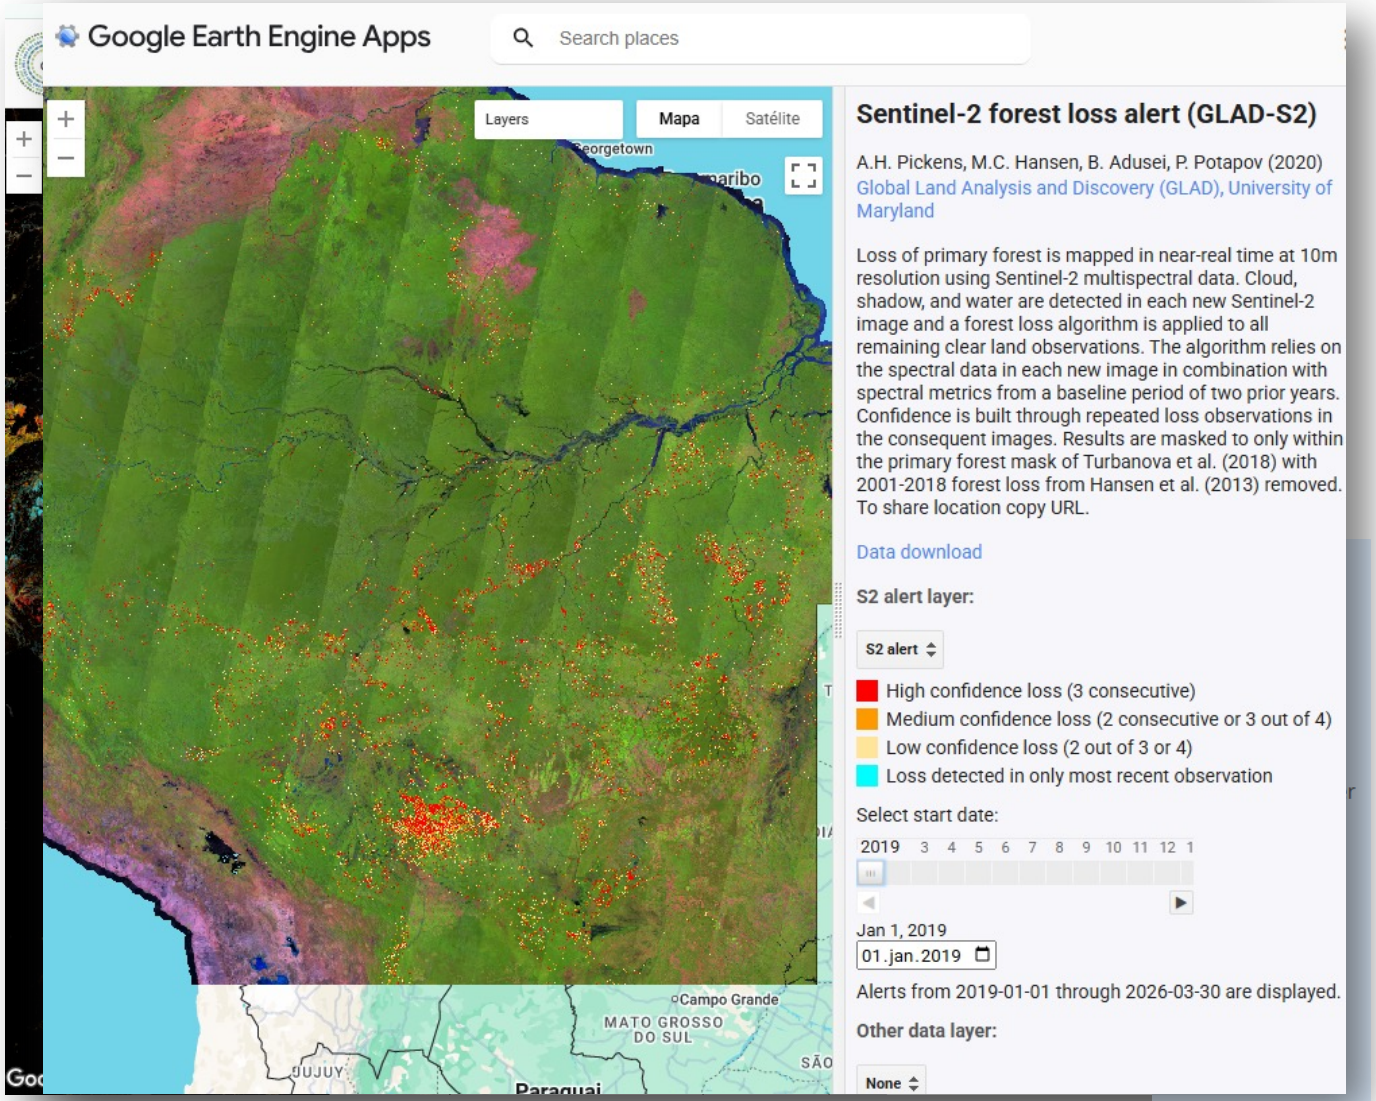
Sistema de monitoramento	Global Forest Watch (GFW)
Região	Global
Principais métodos de IA / análise	Random Forest, detecção temporal de mudanças, aprendizado de máquina, integração crescente de produtos de aprendizado profundo de instituições parceiras
Principais aplicações	Alertas de perda florestal, extensão florestal, monitoramento de mudanças florestais
Dados de sensoriamento remoto	Landsat, Sentinel-1/2, Planet



https://www.globalforestwatch.org/

IA e monitoramento florestal - GLAD

Sistema de monitoramento	Alertas GLAD (Universidade de Maryland)
Região	Trópicos (global)
Principais métodos de IA / análise	Algoritmos de árvores de decisão, análise de séries temporais, detecção estatística de mudanças, aprendizado de máquina
Principais aplicações	Detecção de distúrbios florestais quase em tempo real
Dados de sensoriamento remoto	Landsat (GLAD-L) Sentinel (GLAD-S2)

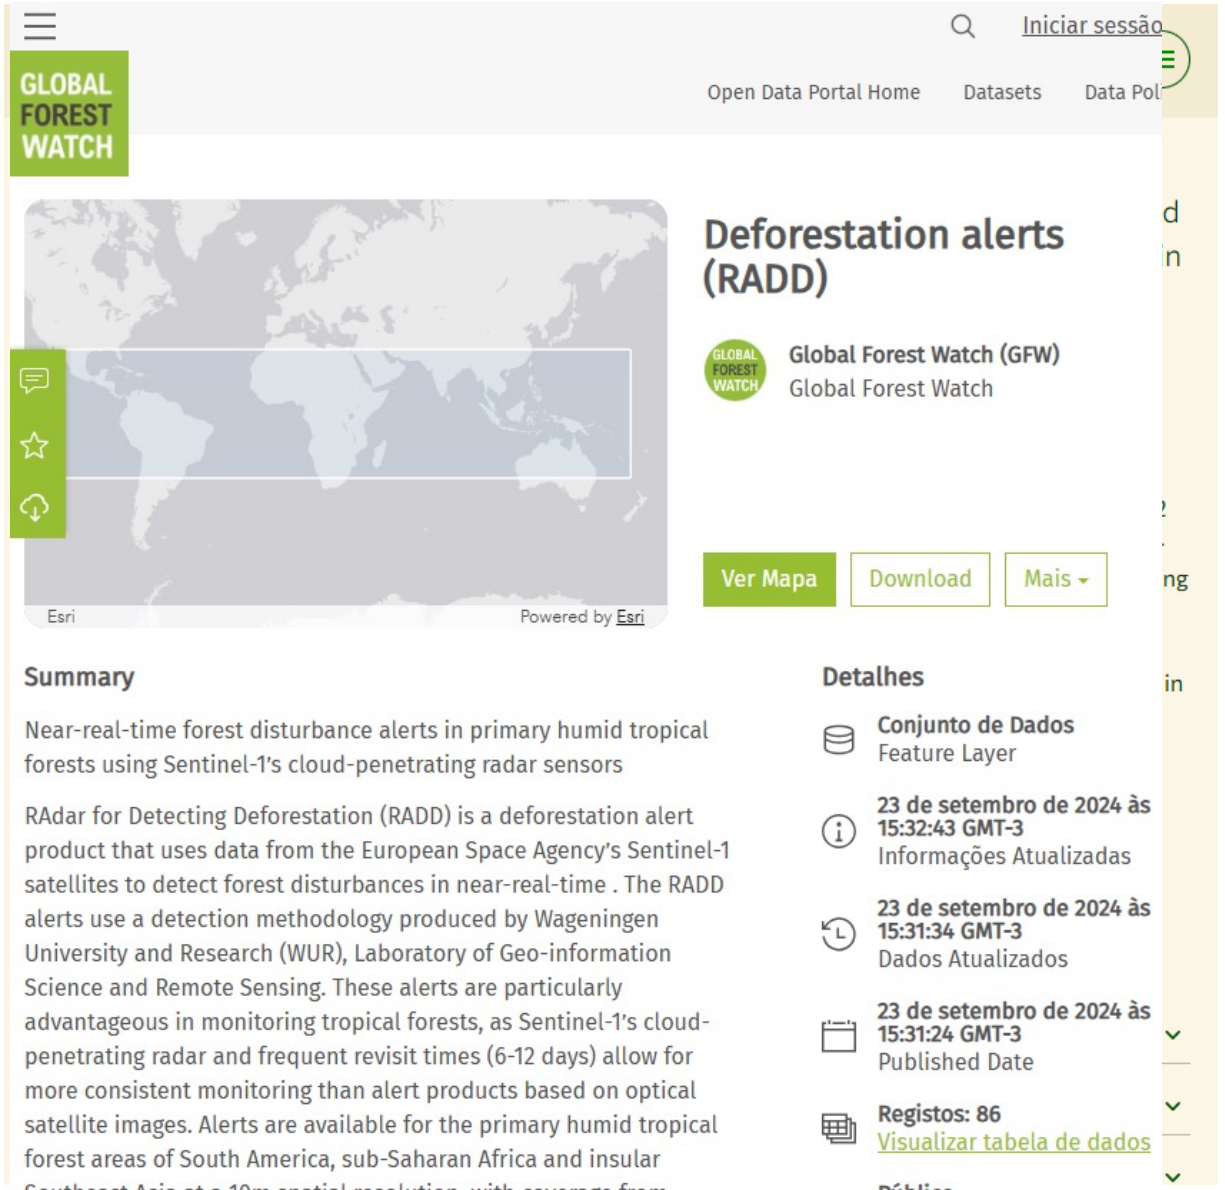


https://glad.umd.edu/dataset



IA e monitoramento florestal - RADD

Sistema de monitoramento	Alertas RADD (Universidade de Wageningen e WRI)
Região	Florestas tropicais
Principais métodos de IA / análise	Aprendizado de máquina, análise de séries temporais SAR, detecção bayesiana de mudanças
Principais aplicações	Desmatamento quase em tempo real sob cobertura de nuvens
Dados de sensoriamento remoto	Sentinel 1 SAR



https://www.wur.nl/en/research/products-services/radd-forest-disturbance-alert

IA e monitoramento florestal - GEDI

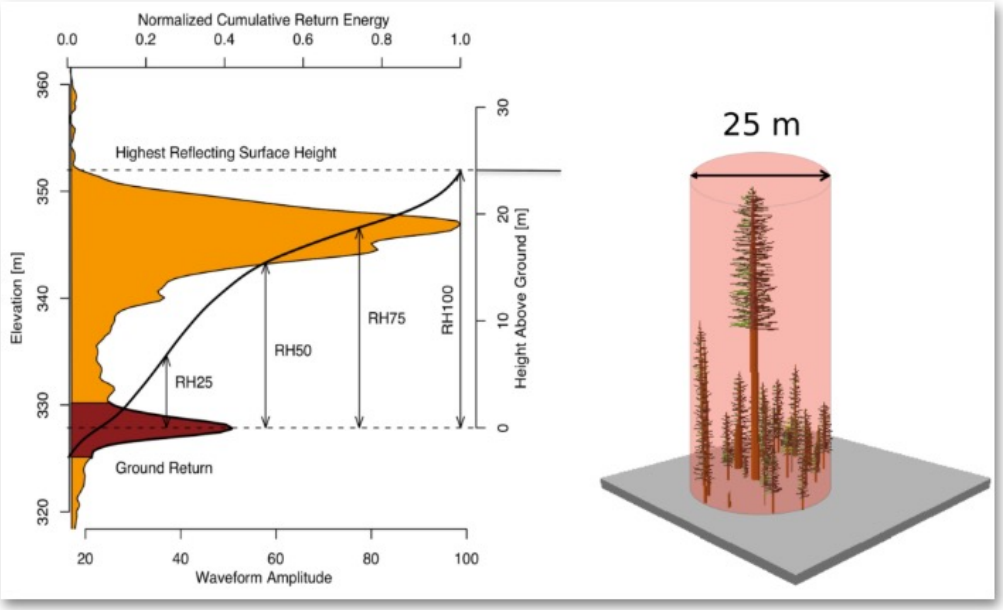
Sistema de monitoramento	Produtos de biomassa GEDI da NASA
Região	Global
Principais métodos de IA / análise	Random Forest, Gradient Boosting , Redes neurais profundas, (CNNs, modelos com codificador Transformer), Aprendizado por transferência
Principais aplicações	Estimativa de biomassa acima do solo, estrutura florestal
Dados de sensoriamento remoto	GEDI LiDAR, Landsat, Sentinel

LEVEL 1 - GEOLOCATED WAVEFORMS

The raw GEDI waveforms as collected by the GEDI system are geolocated by our science team.

LEVEL 2 - FOOTPRINT LEVEL CANOPY HEIGHT AND PROFILE METRICS

The waveforms are processed to provide canopy height and profile metrics. These are values calculated directly from the waveform return for each footprint such as terrain elevation, canopy height, RH metrics and Leaf Area Index (LAI). These metrics provide easy-to-use and interpret information about the vertical distribution of the canopy material.



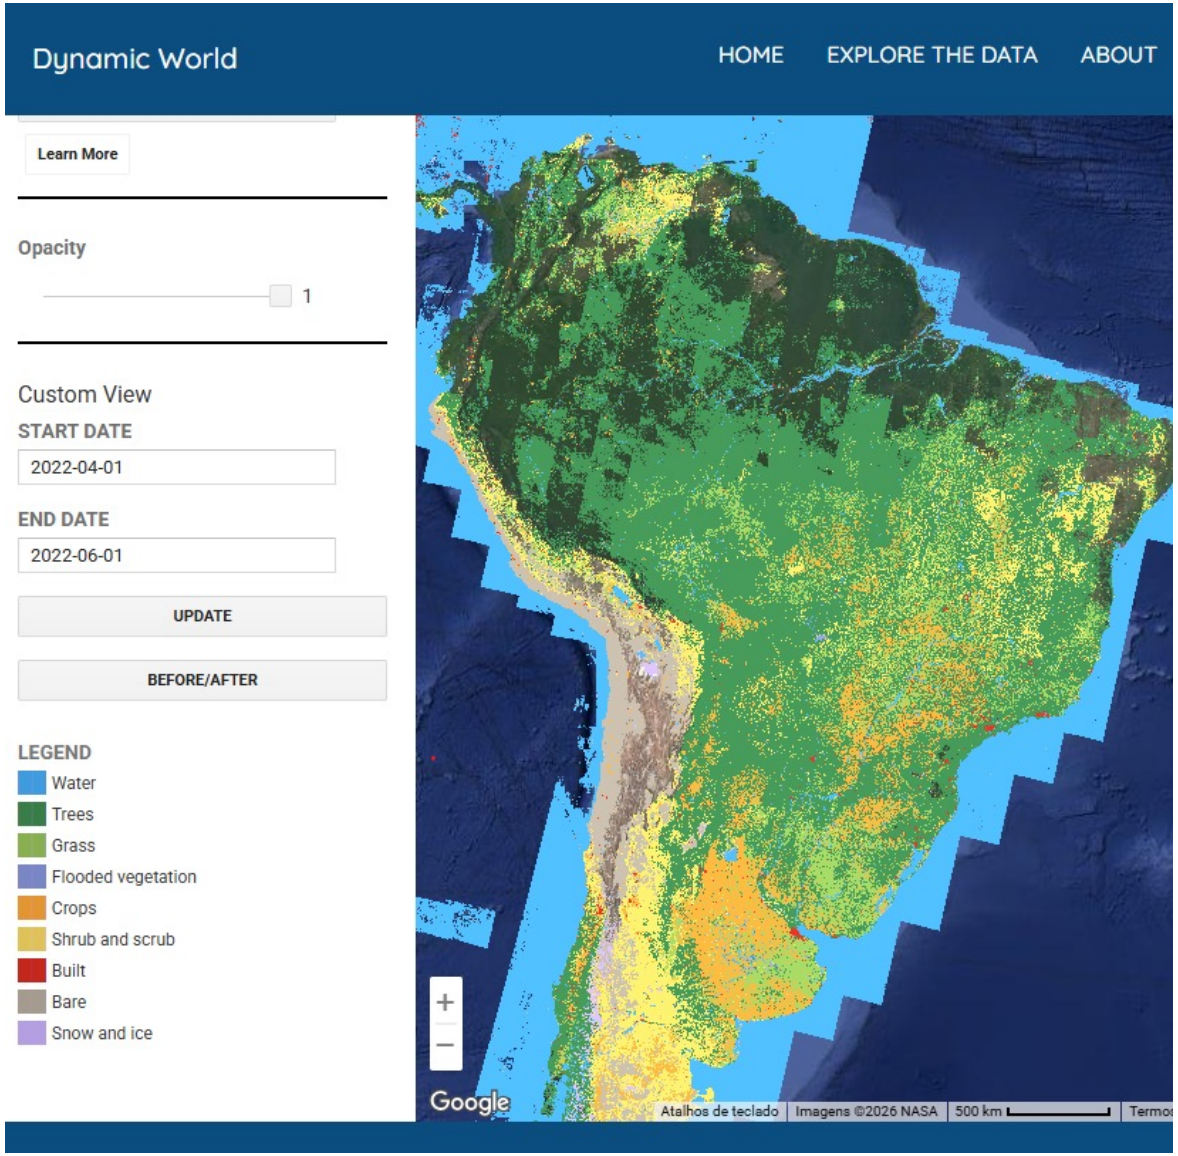
LEVEL 3 - GRIDDED CANOPY HEIGHT METRICS AND VARIABILITY

https://gedi.umd.edu/dataproducts/products/

IA e monitoramento florestal

Dynamic World

Sistema de monitoramento	Google Dynamic World
Região	Global
Principais métodos de IA / análise	Redes neurais profundas (segmentação semântica baseada em CNN)
Principais aplicações	Classificação da cobertura da terra quase em tempo real
Dados de sensoriamento remoto	Sentinel-2



https://dynamicworld.app/

BiomasBR - INPE

Programa do INPE de monitoramento da vegetação por imagens de satélite

Informações sistemáticas sobre a vegetação nativa, **as atividades de** desmatamento (supressão) e **degradação** em todos os biomas brasileiros

Dados oficiais brasileiros de desmatamento para as políticas públicas

Conservação e desenvolvimento sustentável

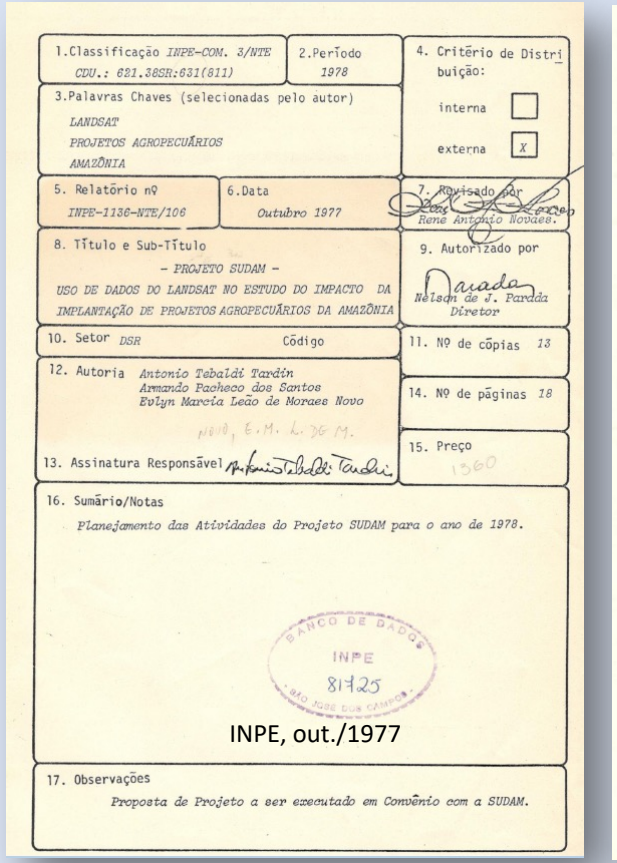
https://data.inpe.br/big/web/biomasbr/



Histórico – sensoriamento remoto e pesquisa no INPE

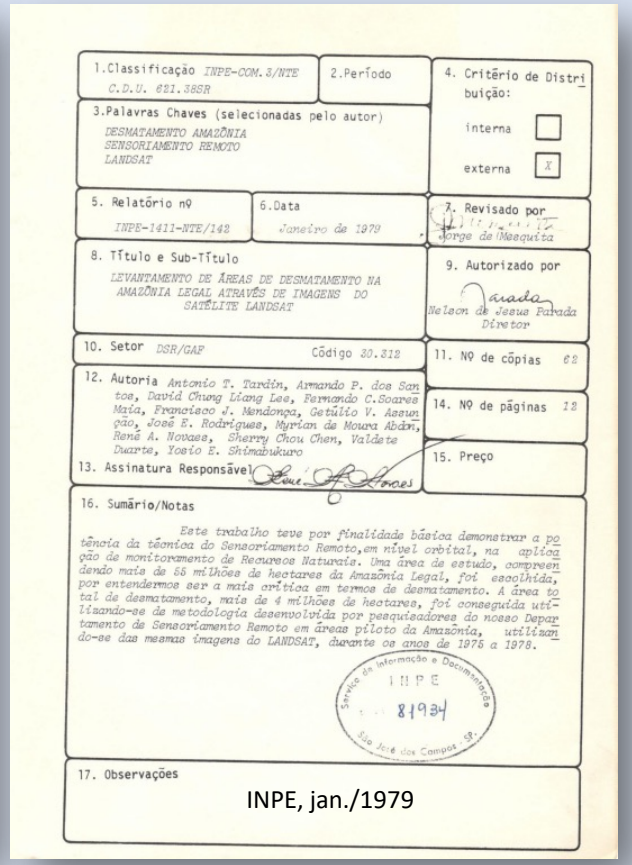


INPE – Cuiabá, 1973
Recepção e processamento de imagens Landsat



1.Classificação INPE-COM. 3/NTE
CDU.: 621.38SR:631(811)
2.Período 1978
4. Critério de Distribuição: interna [ ] externa [X]
3.Palavras Chaves (selecionadas pelo autor)
LANDSAT
PROJETOS AGROPECUÁRIOS
AMAZÔNIA
5. Relatório nº INPE-1136-NTE/106
6.Data Outubro 1977
7. Revisado por René Antonio Novaes.
8. Título e Sub-Título
- PROJETO SUDAM -
USO DE DADOS DO LANDSAT NO ESTUDO DO IMPACTO DA IMPLANTAÇÃO DE PROJETOS AGROPECUÁRIOS DA AMAZÔNIA
9. Autorizado por Nelson de J. Parada Diretor
10. Setor DSR Código
11. Nº de cópias 13
12. Autoria Antonio Tebaldi Tardin
Armando Pacheco dos Santos
Evlyn Marcia Leão de Moraes Novo
14. Nº de páginas 18
13. Assinatura Responsável
15. Preço 1360
16. Sumário/Notas
Planejamento das Atividades do Projeto SUDAM para o ano de 1978.
BANCO DE DADOS INPE 81725 SÃO JOSÉ DOS CAMPOS
17. Observações
Proposta de Projeto a ser executado em Convênio com a SUDAM.

INPE, out./1977



1.Classificação INPE-COM.3/NTE
C.D.U. 621.38SR
2.Período
4. Critério de Distribuição: interna [ ] externa [X]
3.Palavras Chaves (selecionadas pelo autor)
DESMATAMENTO AMAZÔNIA
SENSORIAMENTO REMOTO
LANDSAT
5. Relatório nº INPE-1411-NTE/142
6.Data Janeiro de 1979
7. Revisado por Jorge de Mesquita
8. Título e Sub-Título
LEVANTAMENTO DE ÁREAS DE DESMATAMENTO NA AMAZÔNIA LEGAL ATRAVÉS DE IMAGENS DO SATÉLITE LANDSAT
9. Autorizado por Nelson de Jesus Parada Diretor
10. Setor DSR/GAF Código 30.312
11. Nº de cópias 62
12. Autoria Antonio T. Tardin, Armando P. dos Santos, David Chung Liang Lee, Fernando C.Soares Maia, Francisco J. Mendonça, Getúlio V. Assunção, José E. Rodrigues, Myrian de Moura Abdon, René A. Novaes, Sherry Chou Chen, Valdete Duarte, Yosio E. Shimabukuro
14. Nº de páginas 12
13. Assinatura Responsável
15. Preço
16. Sumário/Notas
Este trabalho teve por finalidade básica demonstrar a potência da técnica do Sensoriamento Remoto, em nível orbital, na aplicação de monitoramento de Recursos Naturais. Uma área de estudo, compreendendo mais de 55 milhões de hectares da Amazônia Legal, foi escolhida, por entendermos ser a mais crítica em termos de desmatamento. A área total de desmatamento, mais de 4 milhões de hectares, foi conseguida utilizando-se de metodologia desenvolvida por pesquisadores do nosso Departamento de Sensoriamento Remoto em áreas piloto da Amazônia, utilizando-se das mesmas imagens do LANDSAT, durante os anos de 1975 a 1978.
Serviço de Informação e Documentação INPE 81934 São José dos Campos SP.
17. Observações

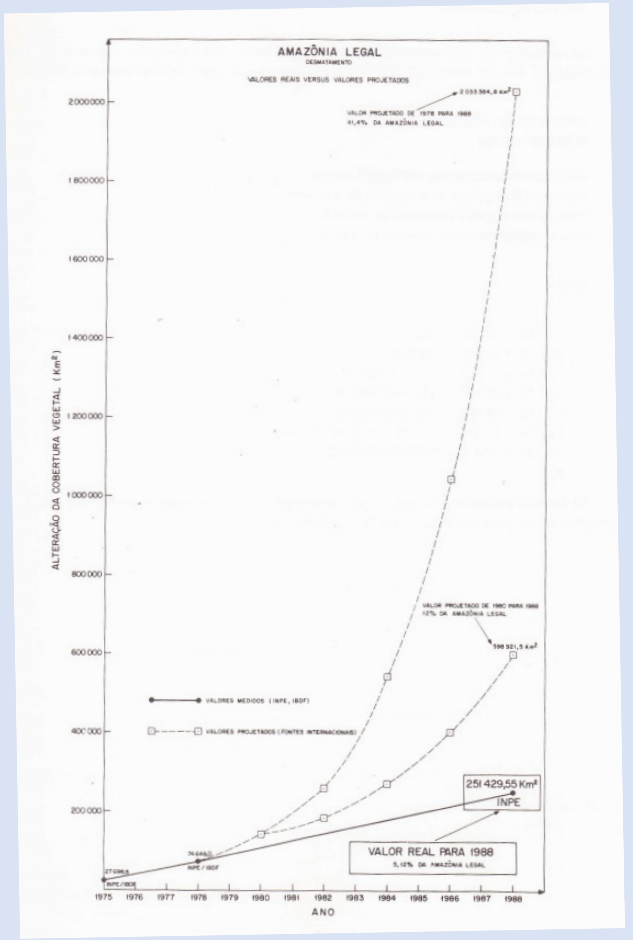
INPE, jan./1979

Anos 1980: início do monitoramento por satélite - PRODES

Desmatamento projetado > 2.000.000 km^2



1989 - Primeiro mapeamento completo da Amazônia Legal brasileira

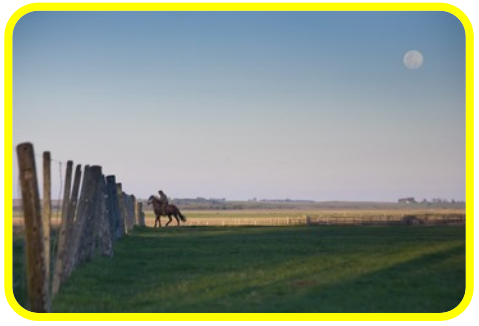


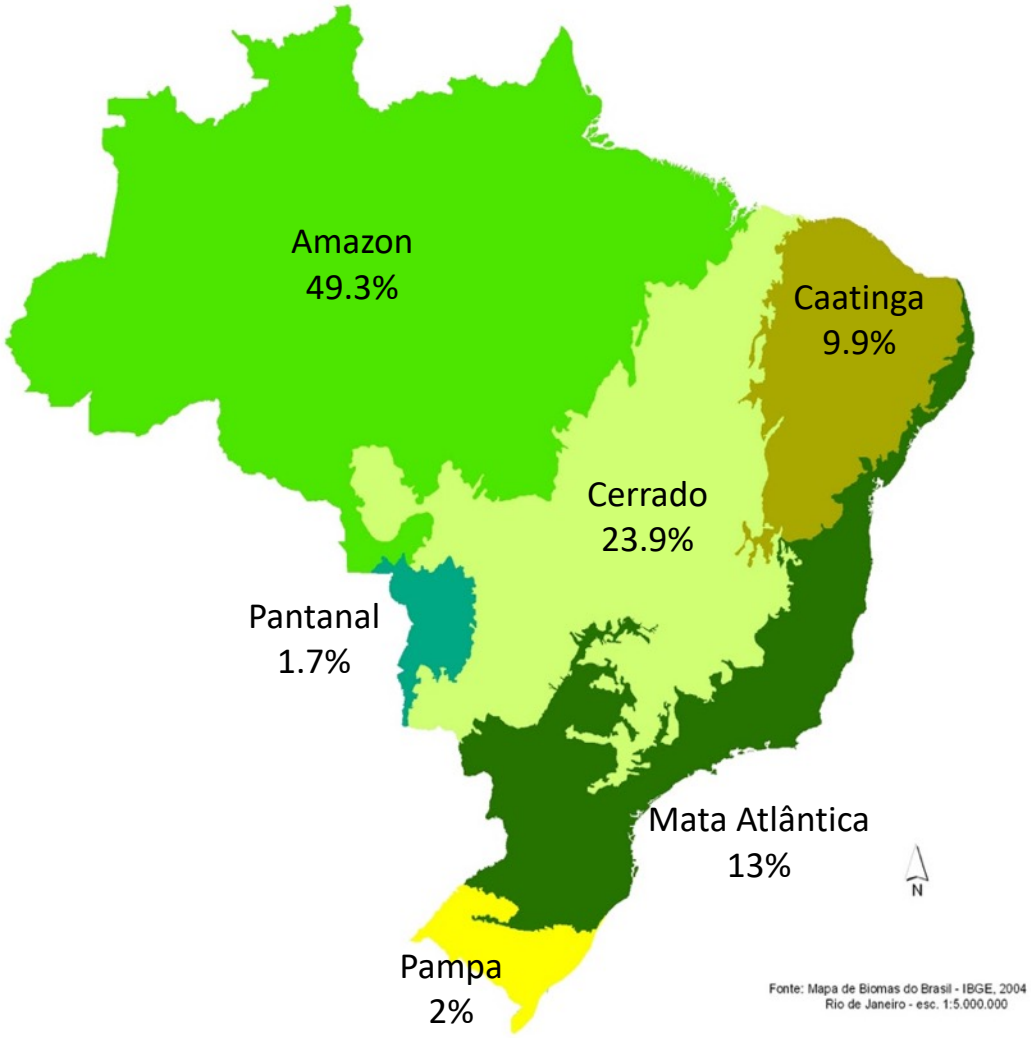
76

Biomas brasileiros















8.515.767,049 km²

https://data.inpe.br/big/web/biomas/

Biomas Br

PRODES



https://data.inpe.br/big/web/biomasbr/prodes-monitoramento-anual-da-supressao-de-vegetacao-nativa/

Prodes - Monitoramento anual da vegetação nativa suprimida

Prodes – Metodologia

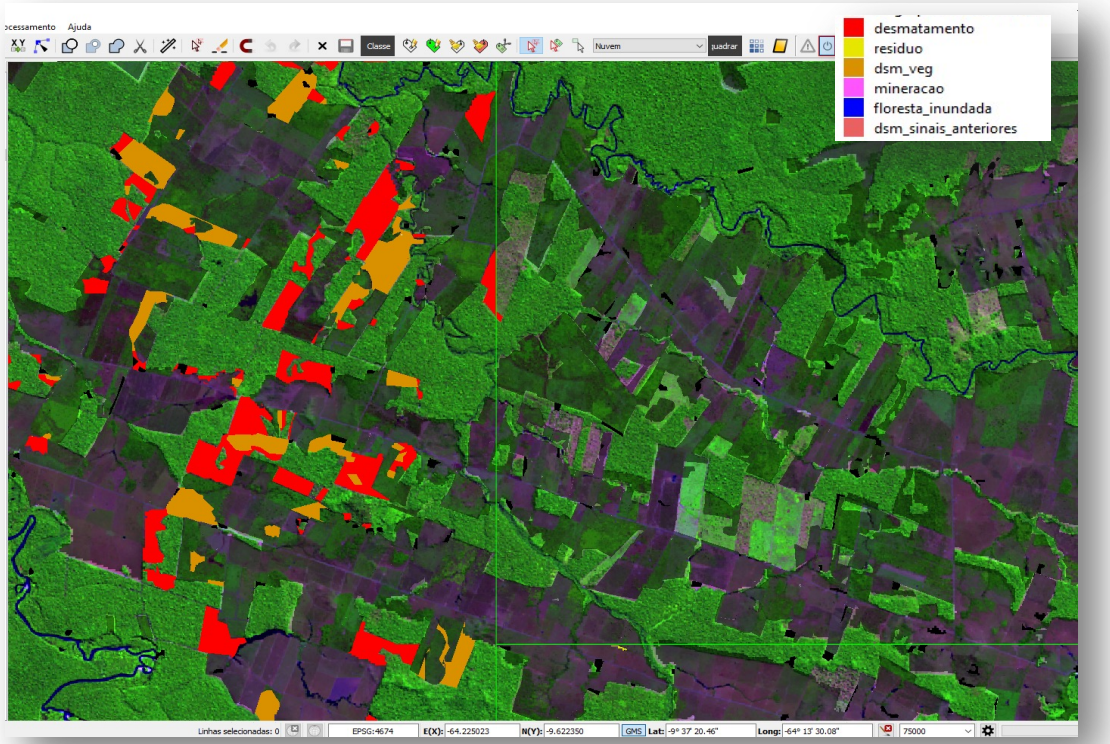
Sistema incremental - incremento anual de **desmatamento**
Supressão da vegetação nativa

Resolução espacial média (**10**-30 m) – Sentinel-2
Área mínima mapeável = **1 ha** (6,25 ha - série histórica mais longa)
Cobertura completa (só a Amazônia = 516 cenas Sentinel)

Até 2023 - identificação visual por **intérpretes**,
revisão por **auditores** e **validação independente** por especialistas externos de cada bioma

Acurácia > 93% (*Maurano et al. 2019, Parente et al. 2021*)

Dados abertos – Terrabrasilis (https://terrabrasilis.dpi.inpe.br/)



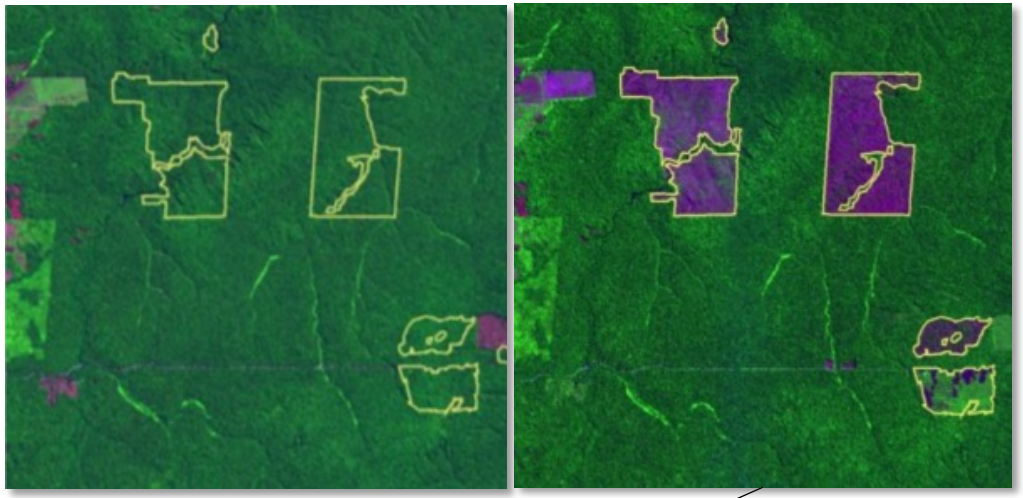
Almeida *et al*. Methodology for Forest Monitoring used in PRODES and DETER projects. 2022 . http://urlib.net/ibi/8JMKD3MGP3W34R/443H3RE

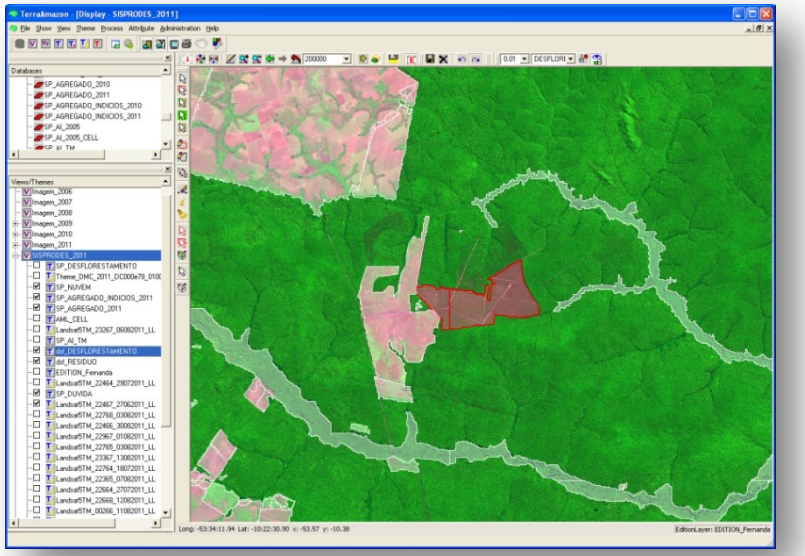
Prodes – Evolução metodológica

Prodes Amazônia – metodologia anterior

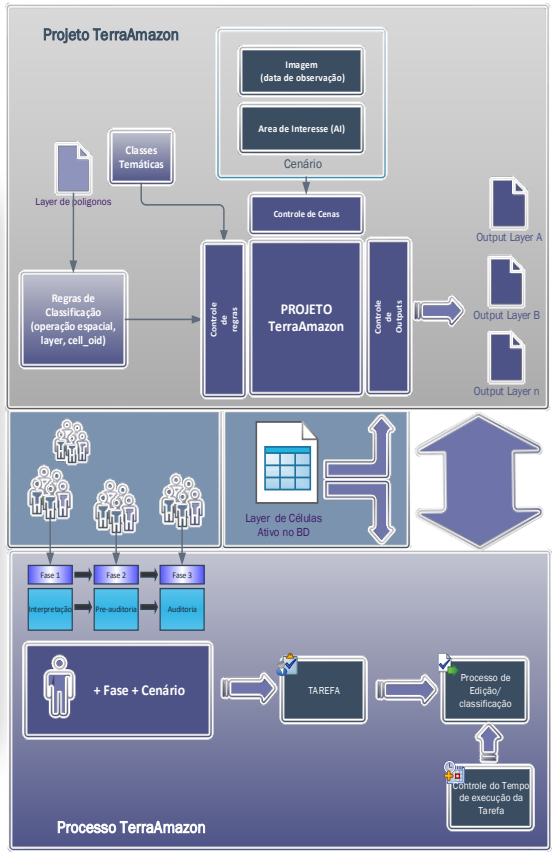
Ano anterior

Ano de mapeamento





TerraAmazon



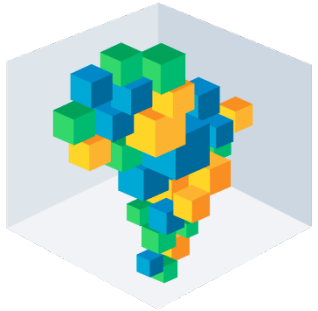
Prodes – Evolução metodológica

Prodes – De imagens Landsat anuais isoladas a cubos de dados de séries temporais Sentinel

Big data de imagens de sensoriamento remoto modelado em cubos de dados multidimensionais

Motivação: inovação tecnológica para os projetos de monitoramento ambiental do INPE (**BiomasBR**)

Mapeamento de uso e cobertura da terra



BRAZIL DATA CUBE

Análise de séries temporais

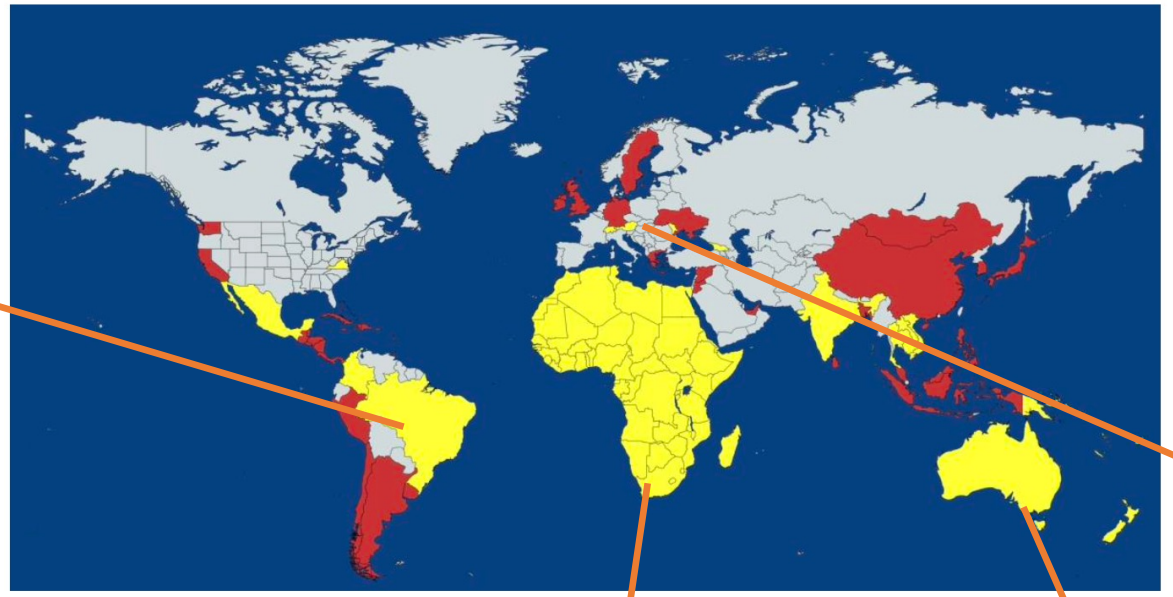
Tecnologia de aprendizado de máquina para big data

Fonte: Ferreira e Queiroz (2025)

Parceria com iniciativas similares

Fonte: [Sudmanns et al, 2022]

Amarelo: operacional
Vermelho: em desenvolvimento



BRAZIL DATA CUBE

http://brazildatacube.org

data MDPI

Article

Paving the Way towards an Armenian Data Cube

Swiss Data Cube

https://www.swissdatacube.org/

Naciones Unidas CEPAL NASA INEGI

Digital Earth Americas

A vision for a solution that provides relevant Earth observation data for the benefit of the Americas

Digital Earth AFRICA

https://digitalearthafrica.org/

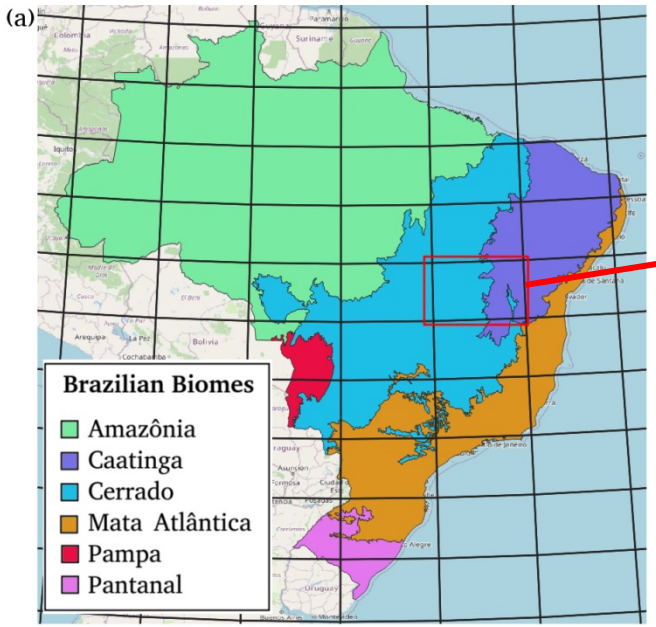
Digital Earth AUSTRALIA

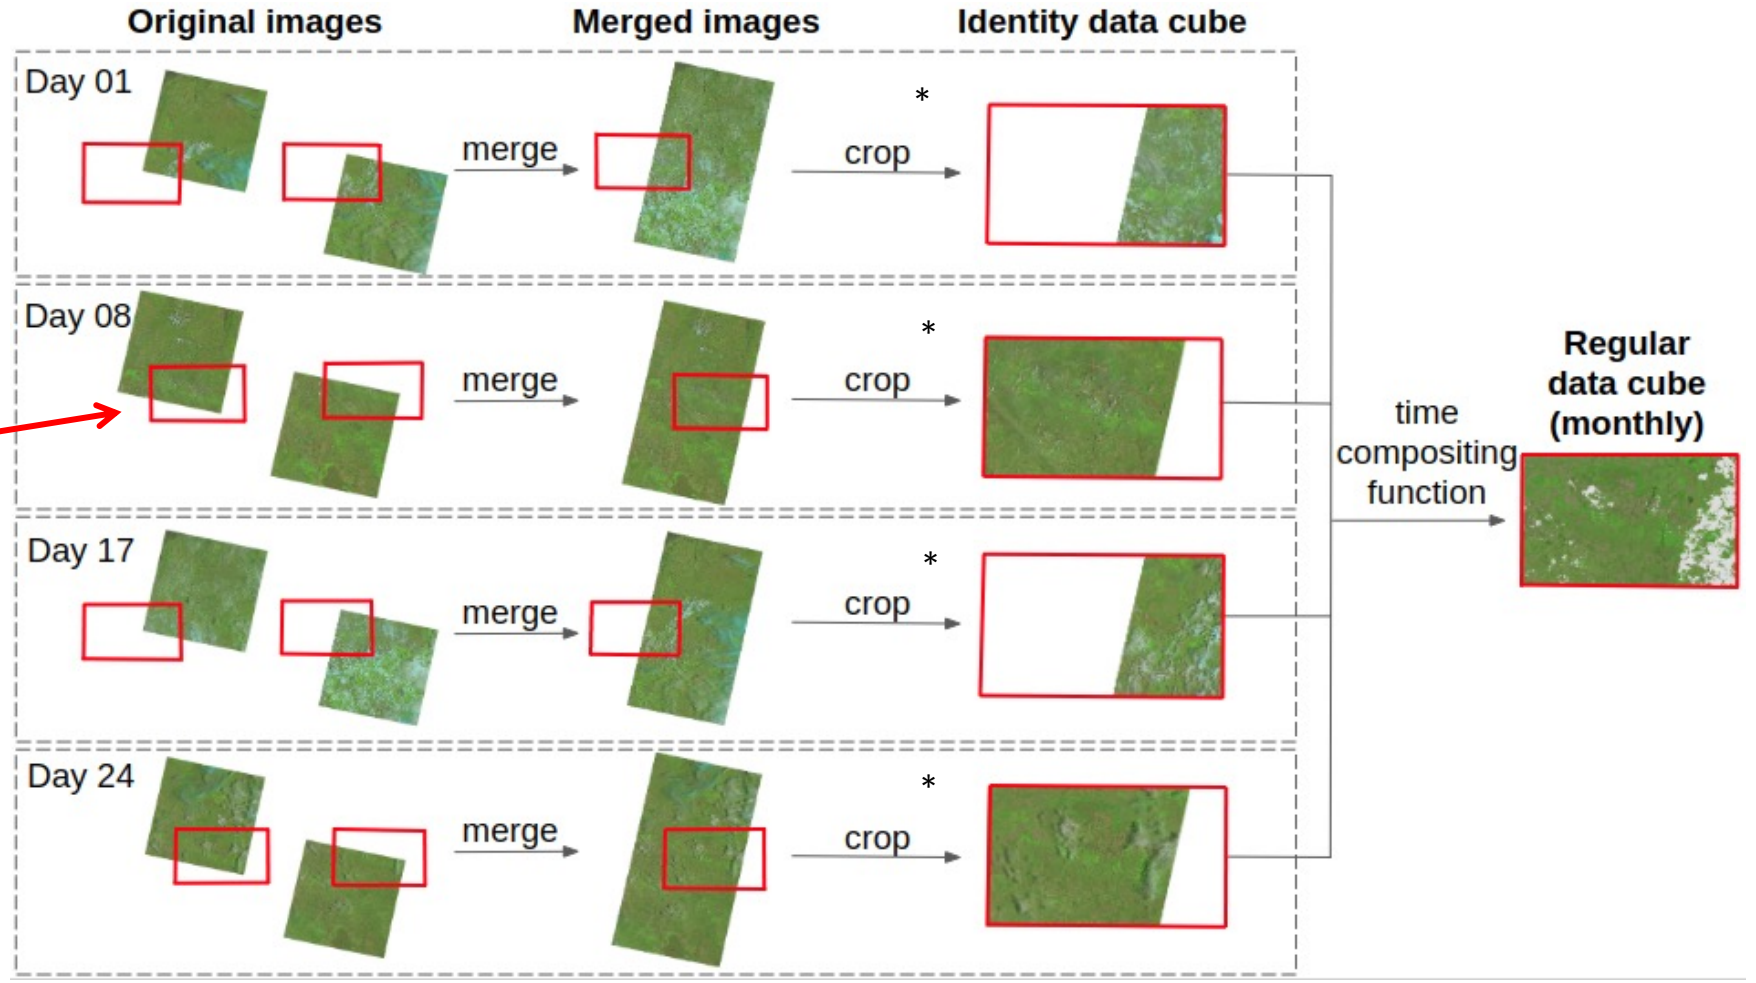
https://www.dea.ga.gov.au/

Fonte: Ferreira e Queiroz (2025)

Fonte: Ferreira e Queiroz (2025)

Construção de cubos de dados





*reamostragem bilinear para a banda de melhor resolução espacial

Fonte: Ferreira e Queiroz (2025)

Brazil Data Cube - BDC

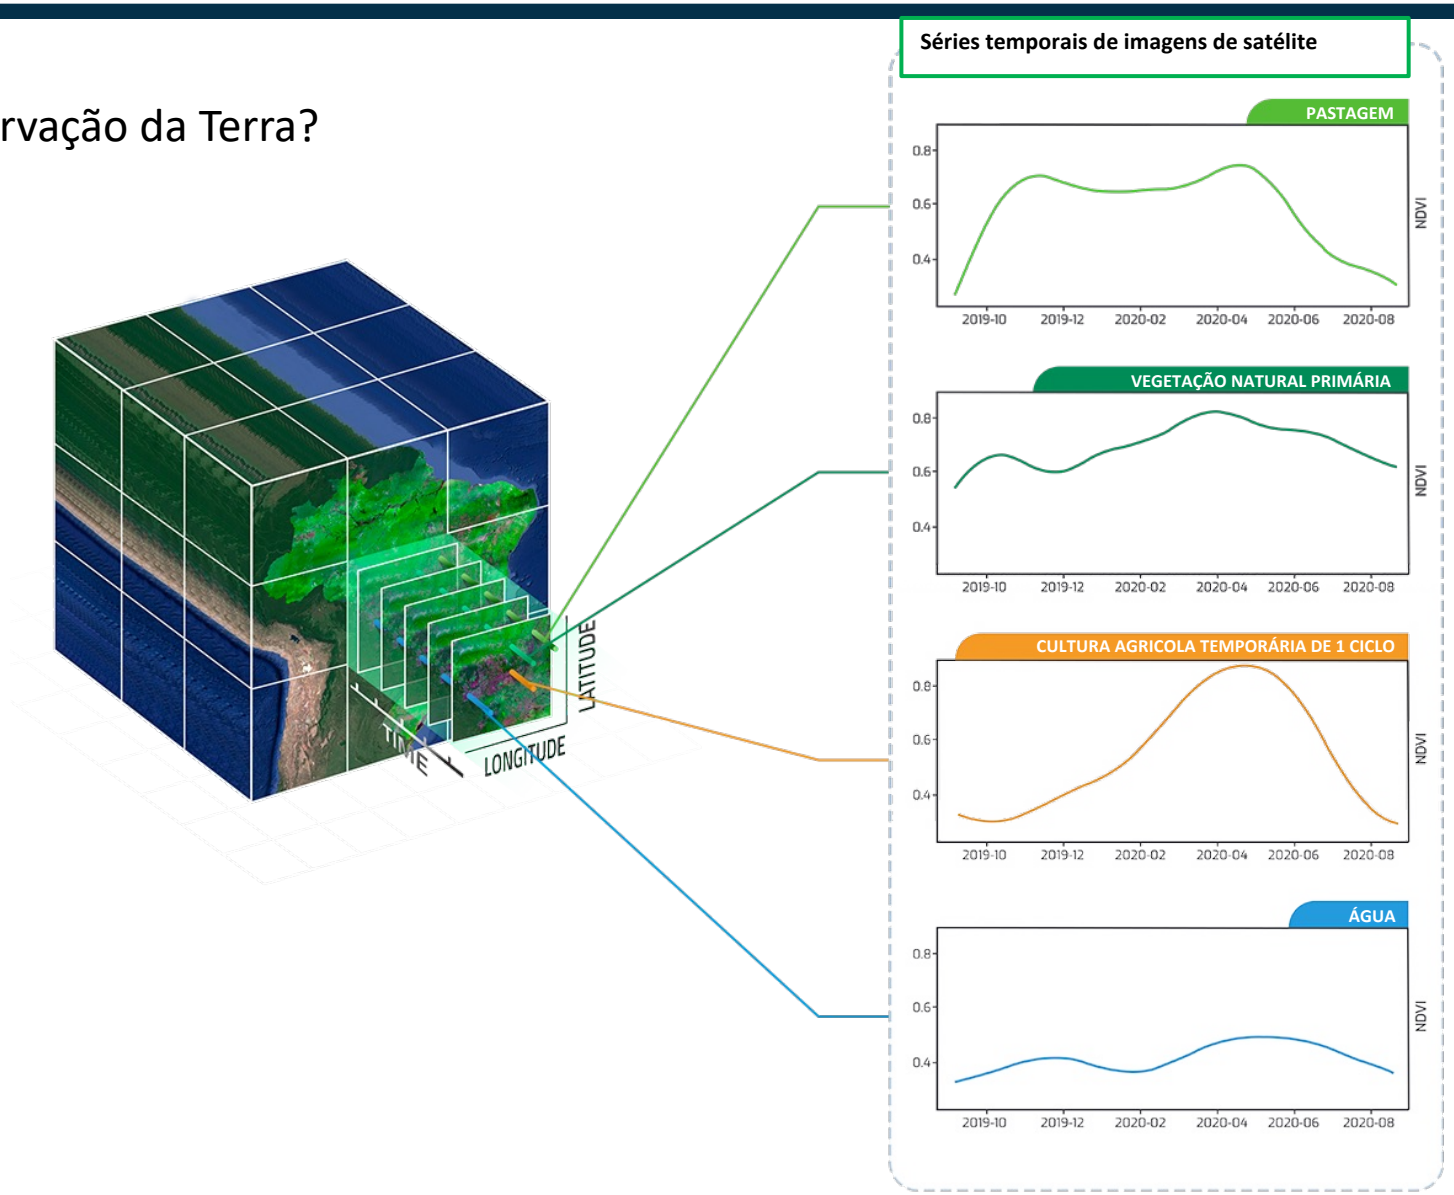
Por que um cubo de dados de observação da Terra?

Matriz multidimensional de imagens de satélite com

4 dimensões
latitude, longitude, data e atributos

para apoiar a análise de séries temporais.

(Appel et al., 2019)



Fonte: Ferreira e Queiroz (2025)

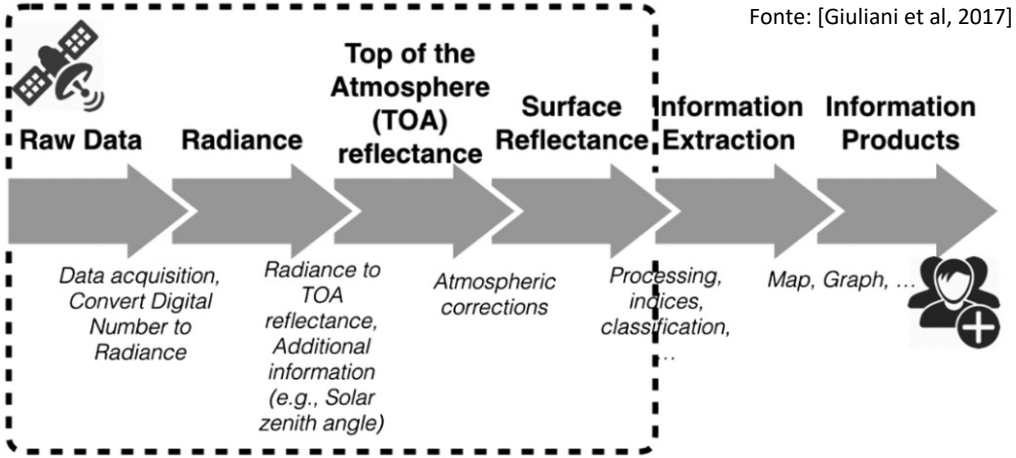
Prodes Amazônia – novas tecnologias - ANÁLISE DE BIG DATA

Brazil Data Cube

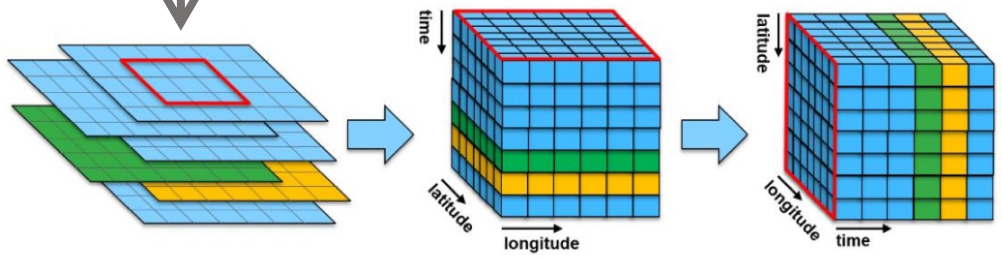
(1) Dados prontos para análise (ARD) de imagens de satélite de média resolução para o Brasil: CBERS-4, Landsat 8, Sentinel 2.

(2) Cubos de dados multidimensionais.

Fonte: [Giuliani et al, 2017]



Fonte: [Kopp et al, 2019]



Dados CEOS prontos para análise de terras:
https://ceos.org/ard/index.html

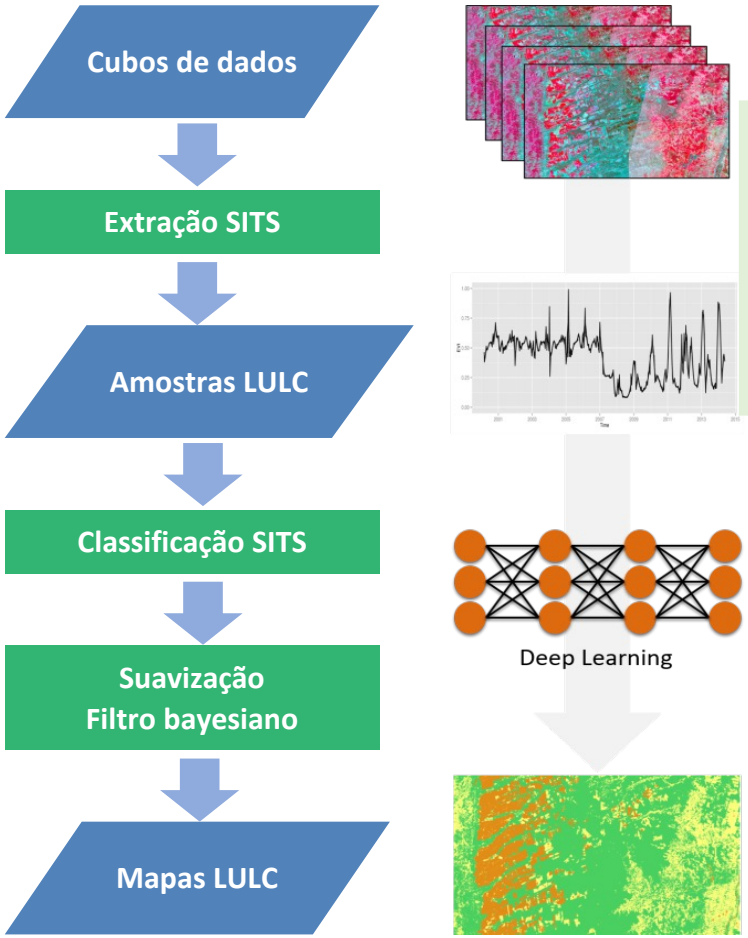
Coleções de imagens de satélite de observação da Terra – ARD

Cubos de dados – matriz de quatro dimensões.

Fonte: Ferreira e Queiroz (2025)

Brazil Data Cube - BDC

Mapeamento de uso e cobertura da terra (LULC)



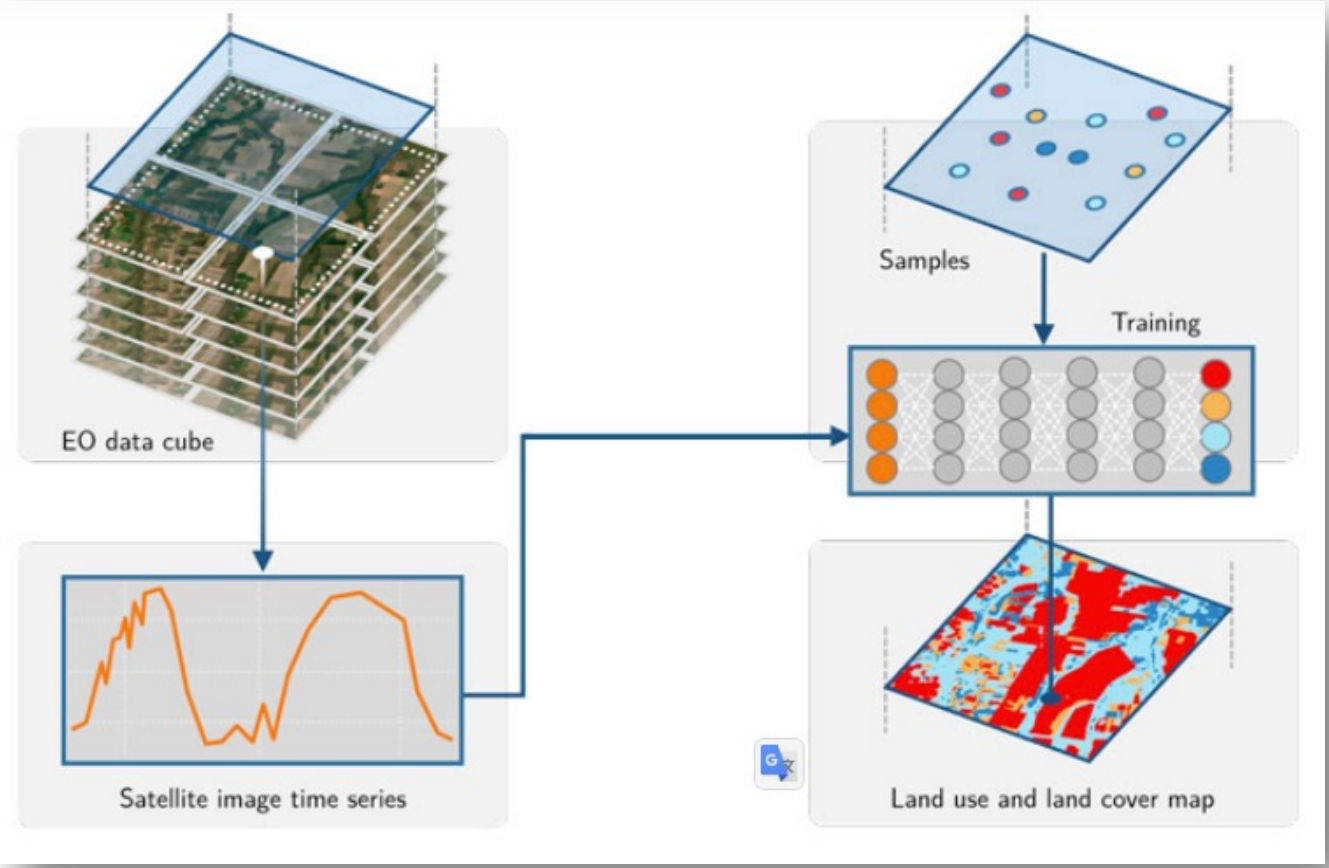
Fonte: [Ferreira et al, 2020]

Cubo de dados de OT,
análise de séries temporais de imagens de satélite (SITS),
e
aprendizado de máquina para produzir mapas LULC a partir de grandes bases de OT.

As SITS permitem processamentos complexos, difíceis com abordagens de detecção de mudança bitemporais ou mesmo anuais.

(Pasquarella et al., 2016)

SITS – séries temporais de imagens de satélite



Simoes et al, (2021]

SITS - ferramentas de análise e classificação de séries temporais: mapas auto-organizáveis, agrupamento, filtragem e visualização de dados.

Algoritmos avançados de aprendizado de máquina para mapear uso e cobertura da terra a partir de séries temporais de imagens de satélite.

Algoritmos de AM:

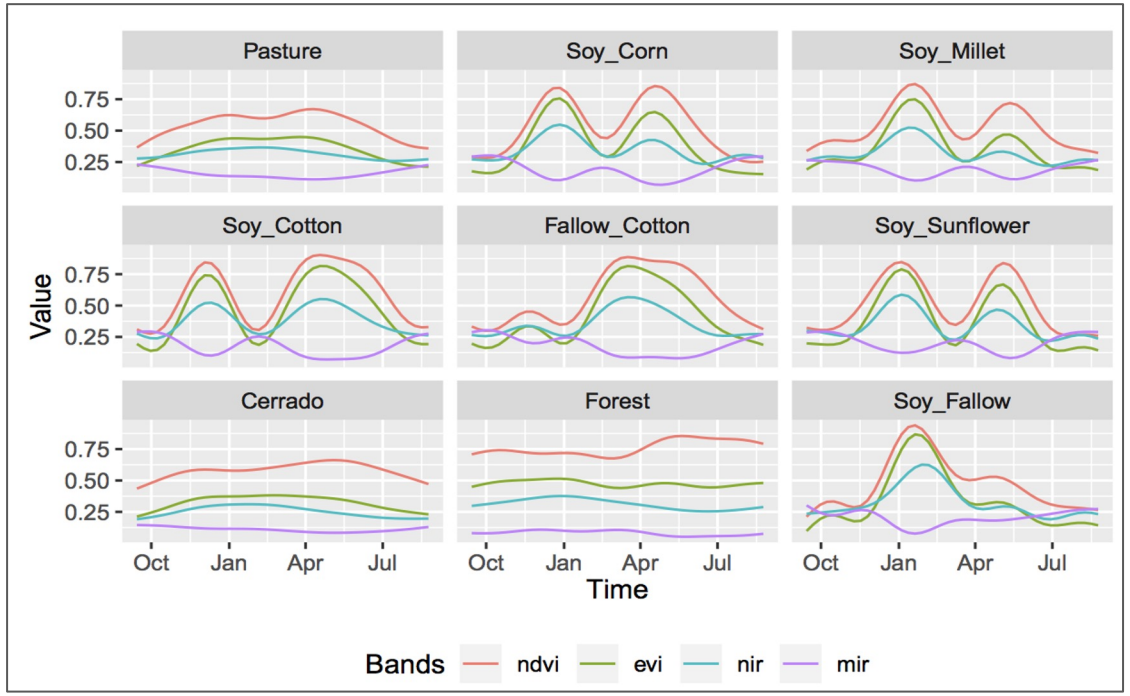
- Máquinas de vetores de suporte (SVM),
- Florestas aleatórias (RF),
- Extreme Gradient Boosting,
- Perceptrons multicamadas 1D totalmente conectados,
- Redes neurais convolucionais 1D,
- Versão 1D do método ResNet.

Embeddings

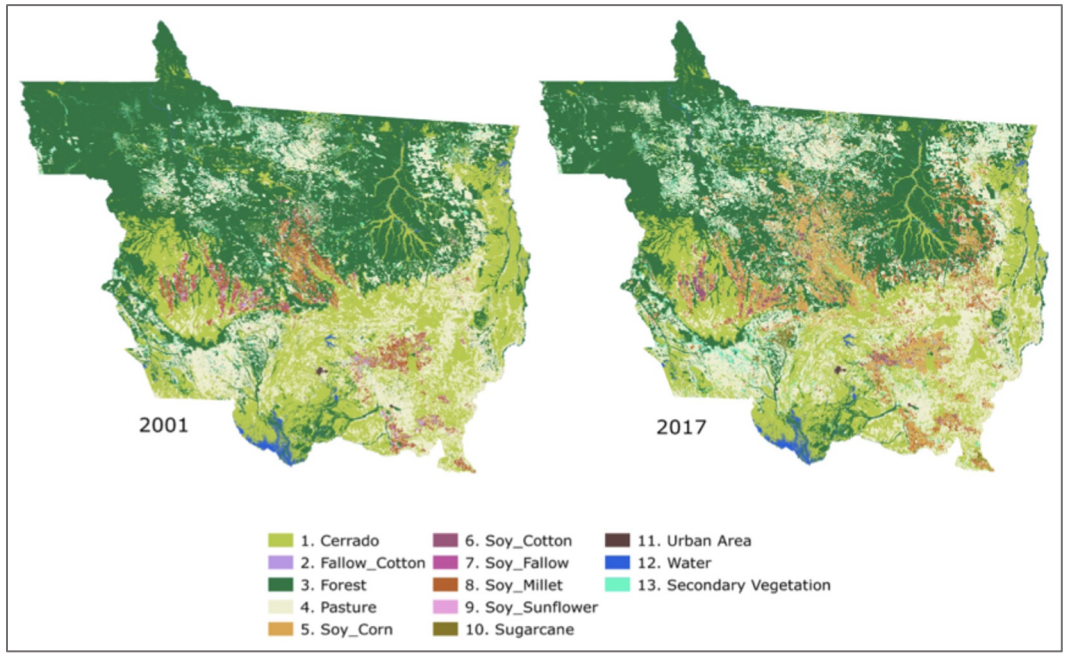
https://data.inpe.br/bdc/sits-satellite-image-time-series/

Brazil Data Cube - BDC

Análise de séries temporais de imagens e **aprendizado de máquina**
para produzir
mapas de uso e cobertura da terra a partir de grandes bases de observação da Terra



Séries temporais de imagens NDVI, EVI, NIR, MIR - ano agrícola
MODIS – produto MOD13Q1 / método – SVM (máquina de vetores de suporte)

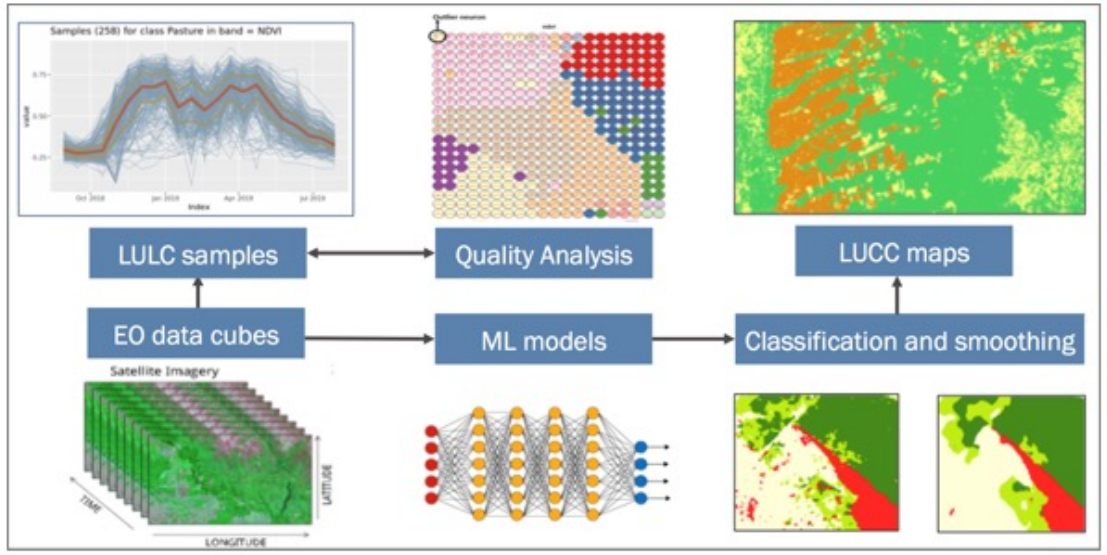


Mapas de uso e cobertura da terra do estado de Mato Grosso de 2001 a 2017, Scientific Data, 2020 (Simões et al., 2020)

Prodes – novas tecnologias - análise com IA

SITS (Satellite Image Time Series)
R package

https://github.com/e-sensing




```
cube <- sits_cube(source = "BDC",
                  collection = "S2_10_16D",
                  name = "s2_cube",
                  bands = c("NDVI", "EVI"),
                  tiles = "022024", start_date = "2018-09-01", end_date = "2019-08-28")

samples <- readRDS(url("https://bdc.dpi.inpe.br/rds/S2_10_16D.rds"))

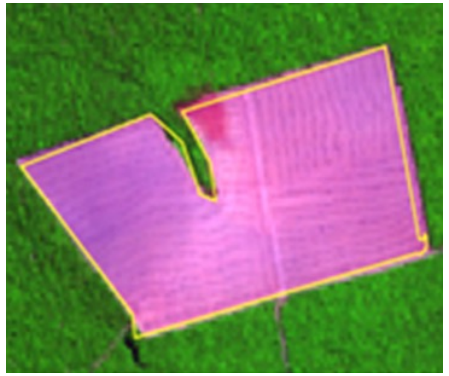
mlp_model <- sits_deeplearning(layers = c(512, 512, 512, 512, 512), activation = "relu")

dl_model <- sits_train(samples, mlp_model)

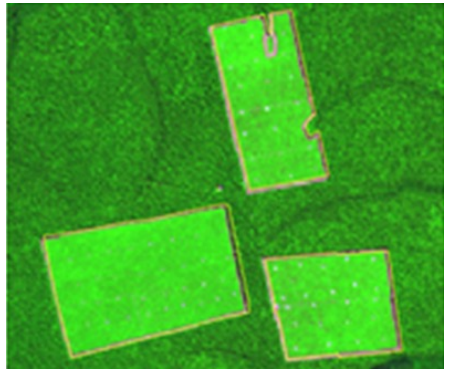
result <- sits_classify(data = cube, ml_model = dl_model, output_dir = tempdir())
```

Prodes Amazônia – classes

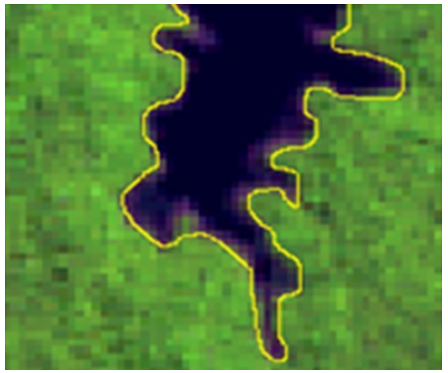
Desmatamento por corte raso solo exposto



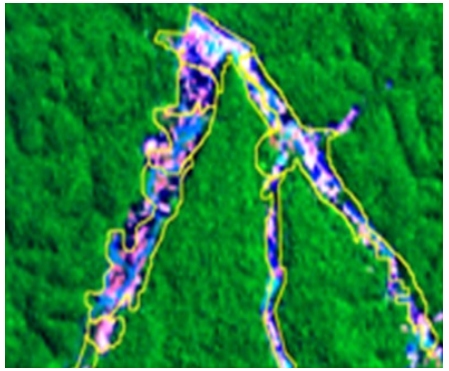
Desmatamento por corte raso vegetação herbácea



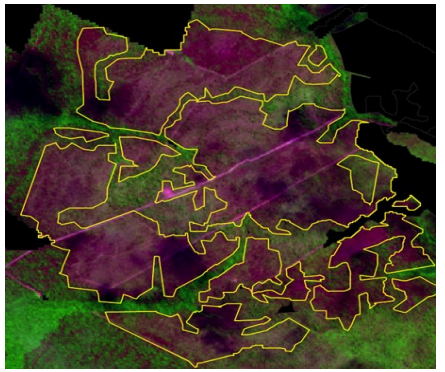
Desmatamento por corte raso floresta alagada



Desmatamento por corte raso mineração

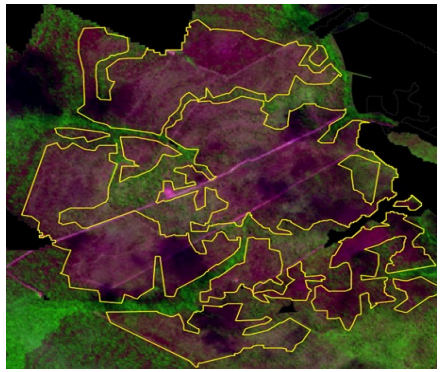


Desmatamento por degradação progressiva



Prodes Amazônia – classes de degradação - desde 2022

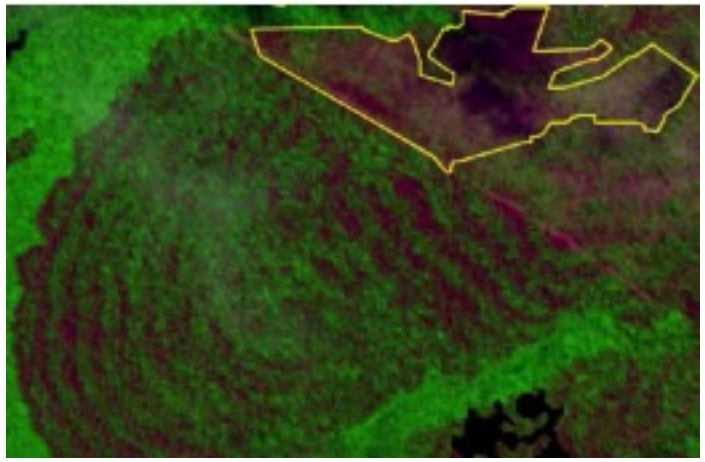
Desmatamento por degradação progressiva



Exploração seletiva



Recorrência de incêndios florestais



Prodes - Monitoramento anual da vegetação nativa suprimida

Prodes BRASIL

Desde 1988 - Amazônia Legal brasileira

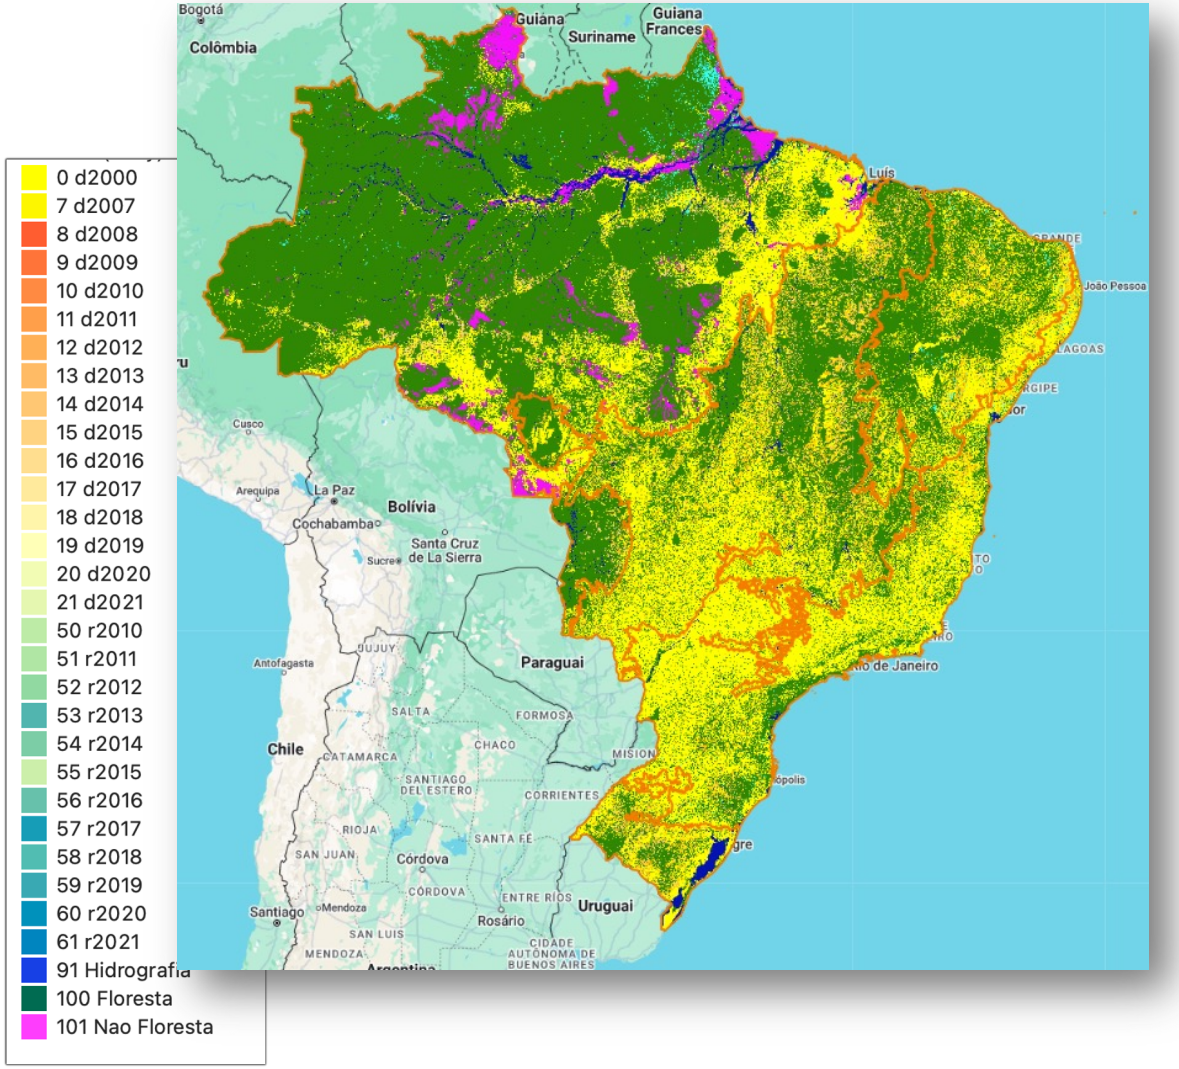
Todos os biomas de 2001 a **2025** (1 ha)

Amazônia, Amazônia não florestal*
Cerrado, Caatinga, Mata Atlântica, Pantanal e Pampa

Sentinel-2 - Brazil Data Cube, automação de processos

Dados oficiais de desmatamento do governo brasileiro

Insumo para políticas públicas e outras iniciativas: PPCDAm/PPCerrado, Fundo Amazônia, Moratória da Soja, TAC da Carne etc., além de inúmeras produções científicas.



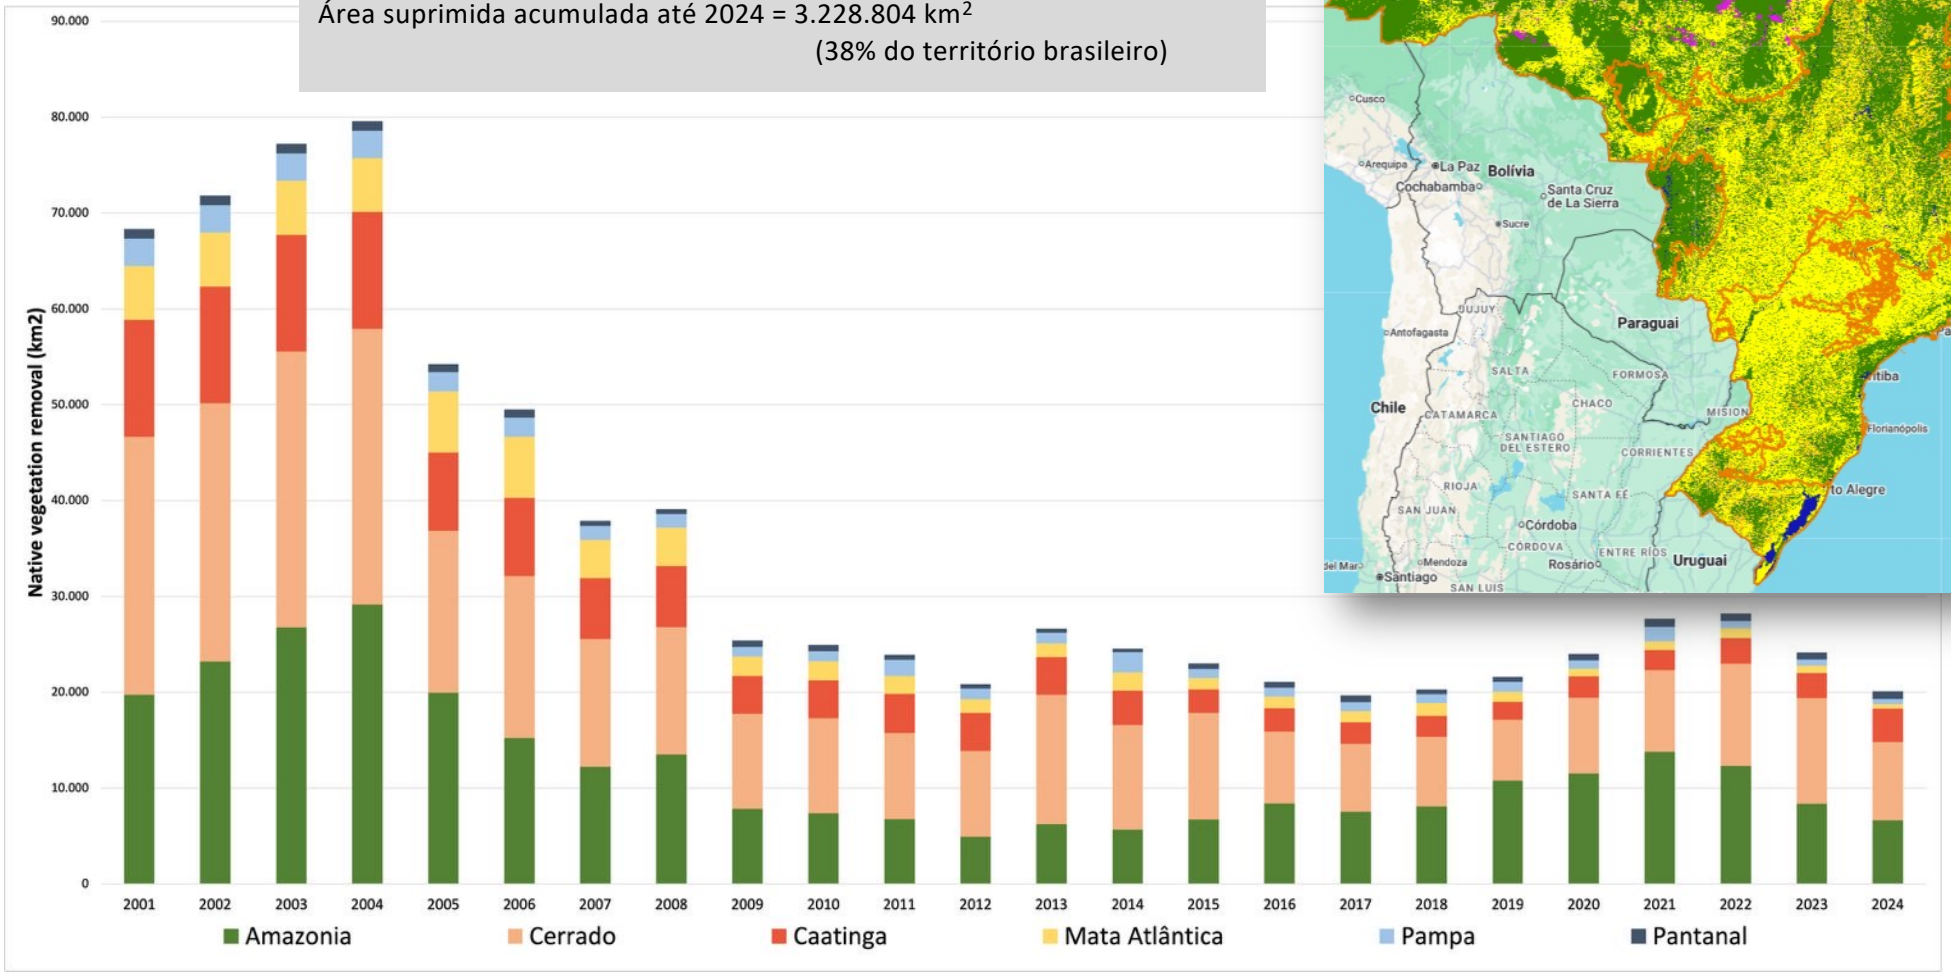
Prodes - Brasil

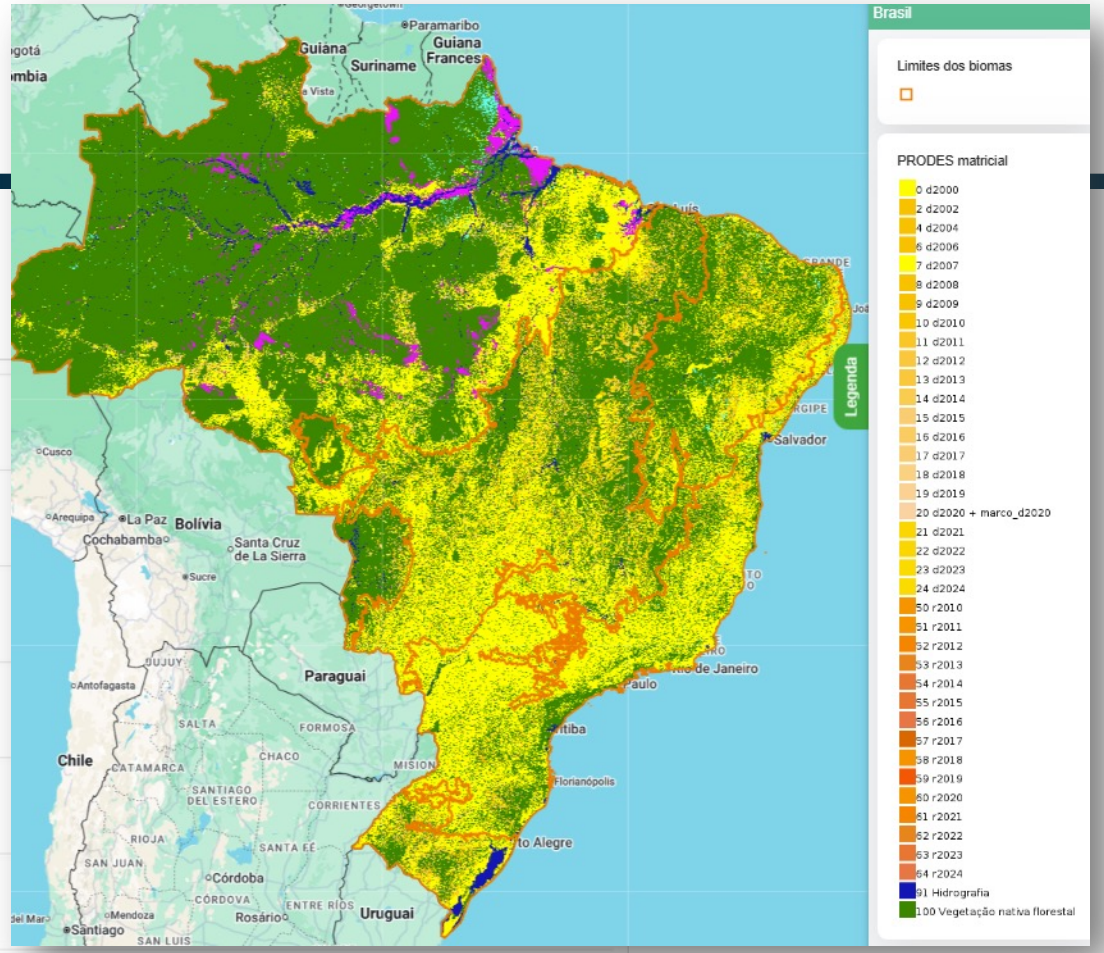
TerraBrasilis

Supressão da vegetação nativa 2024

Área suprimida acumulada até 2024 = 3.228.804 km^2

(38% do território brasileiro)



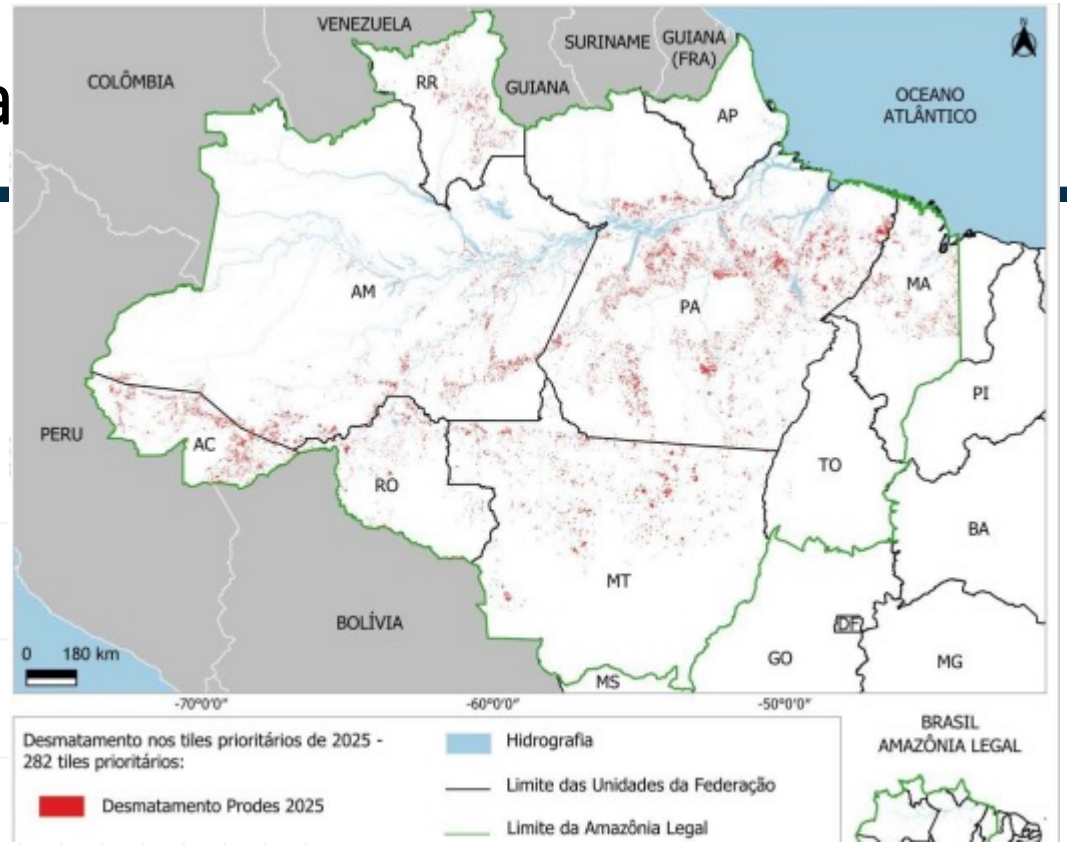


Polígonos > 1 ha
Imagem Sentinel (10 m)
Supressão da vegetação nativa

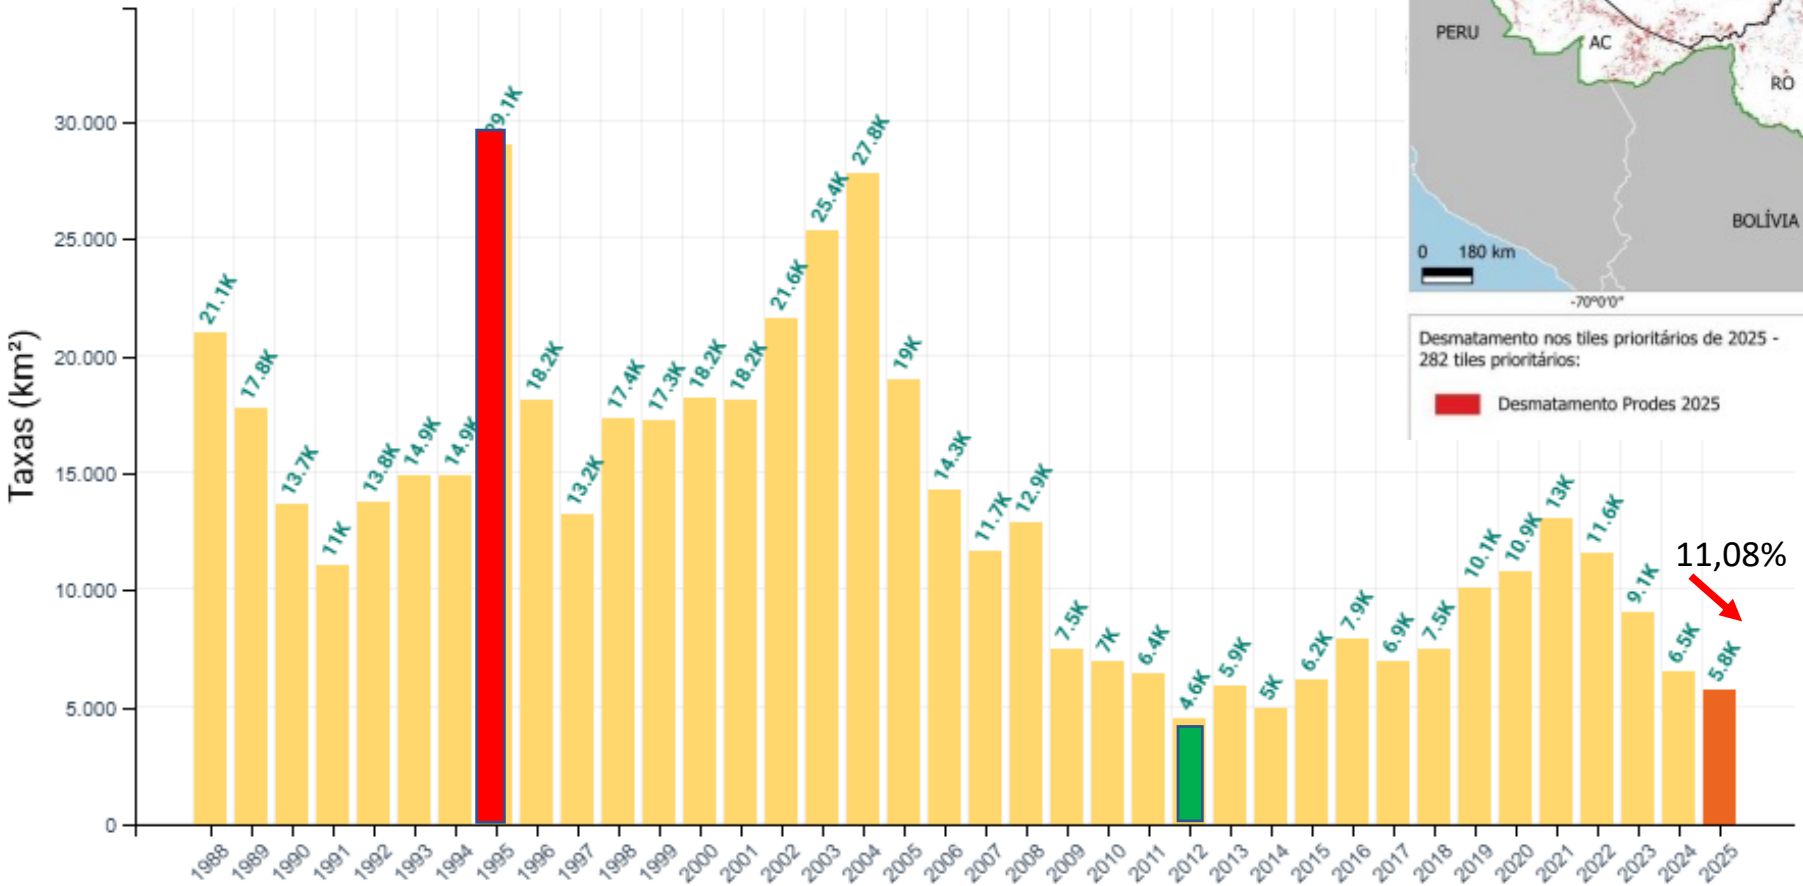
https://terrabrasilis.dpi.inpe.br/app/map/deforestation?hl=pt-br

Prodes - Amazônia Legal brasileira

Desmatamento acumulado até 2024 > 857.301,71 km²
> 21% da floresta original da região amazônica



Taxas de desmatamento - Amazônia Legal - Estados

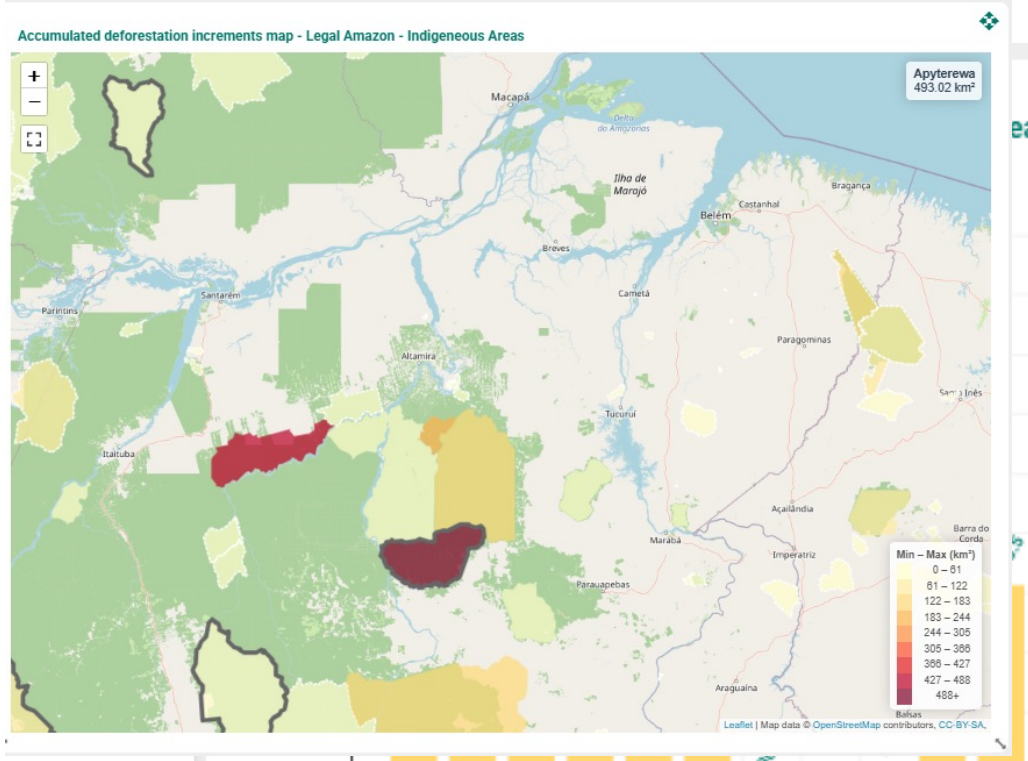


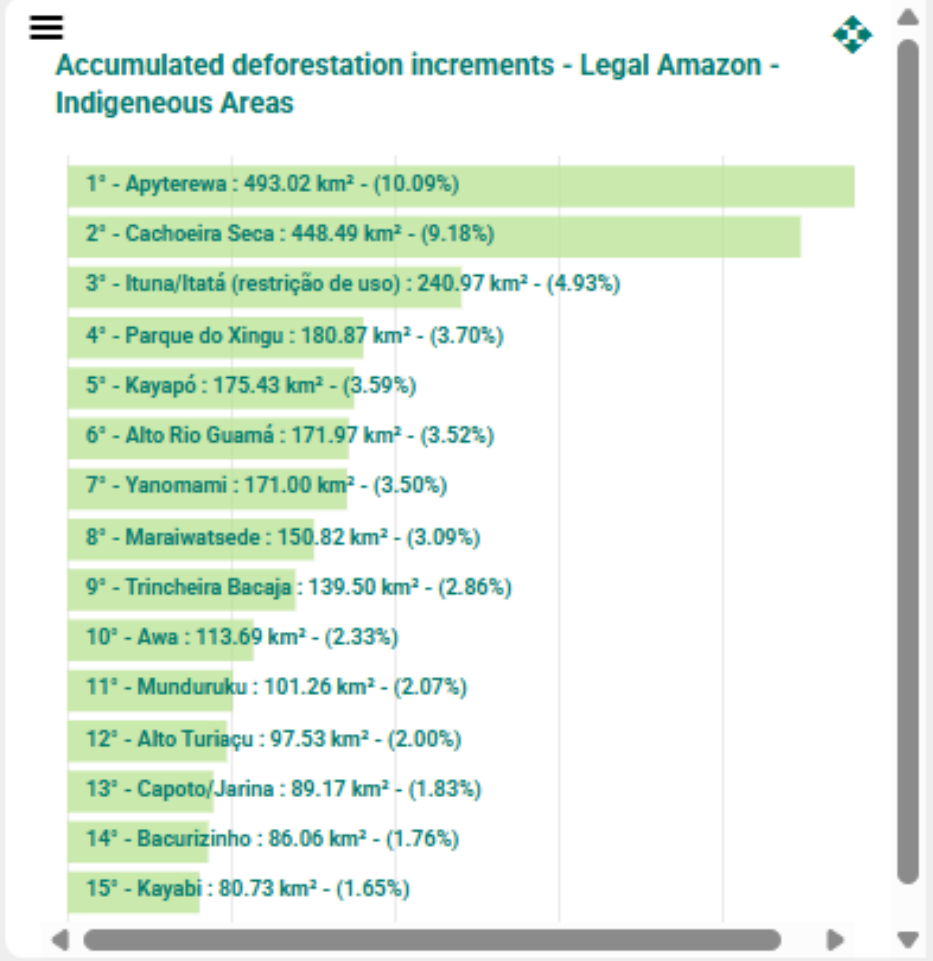
5.731 km²
Taxa de desmatamento 2025 (consolidada)

https://terrabrasilis.dpi.inpe.br

94

Prodes - Terras indígenas

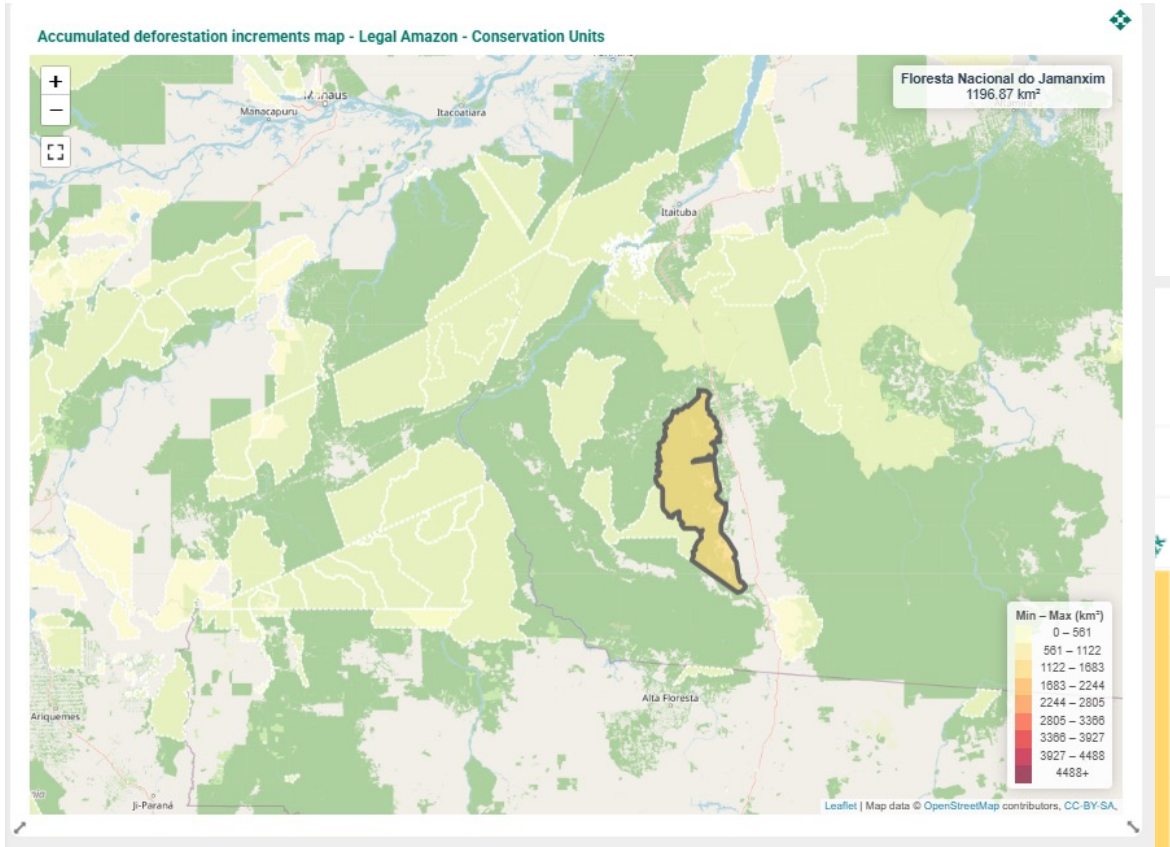


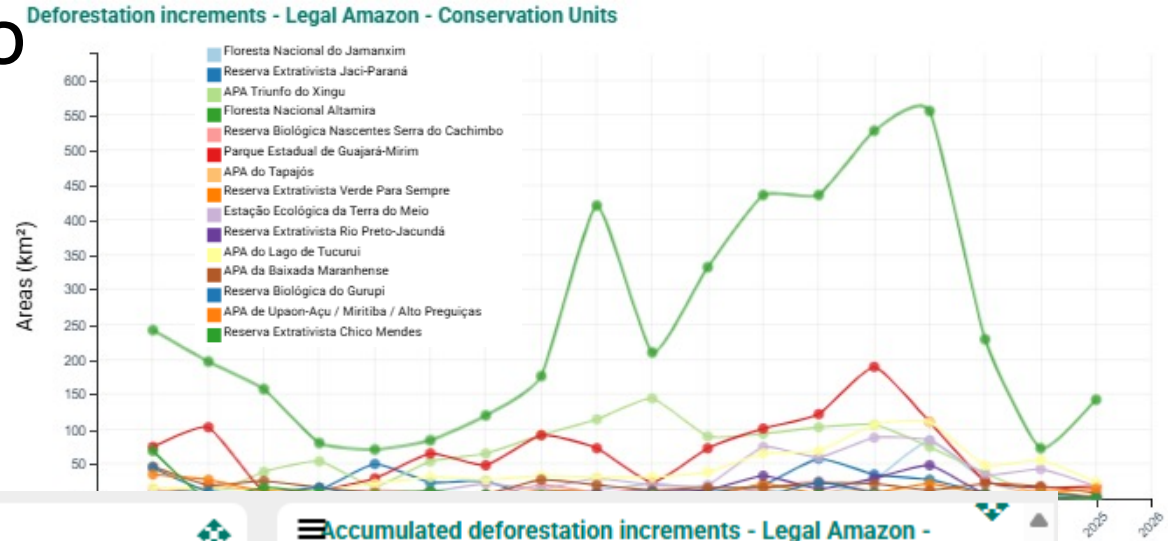


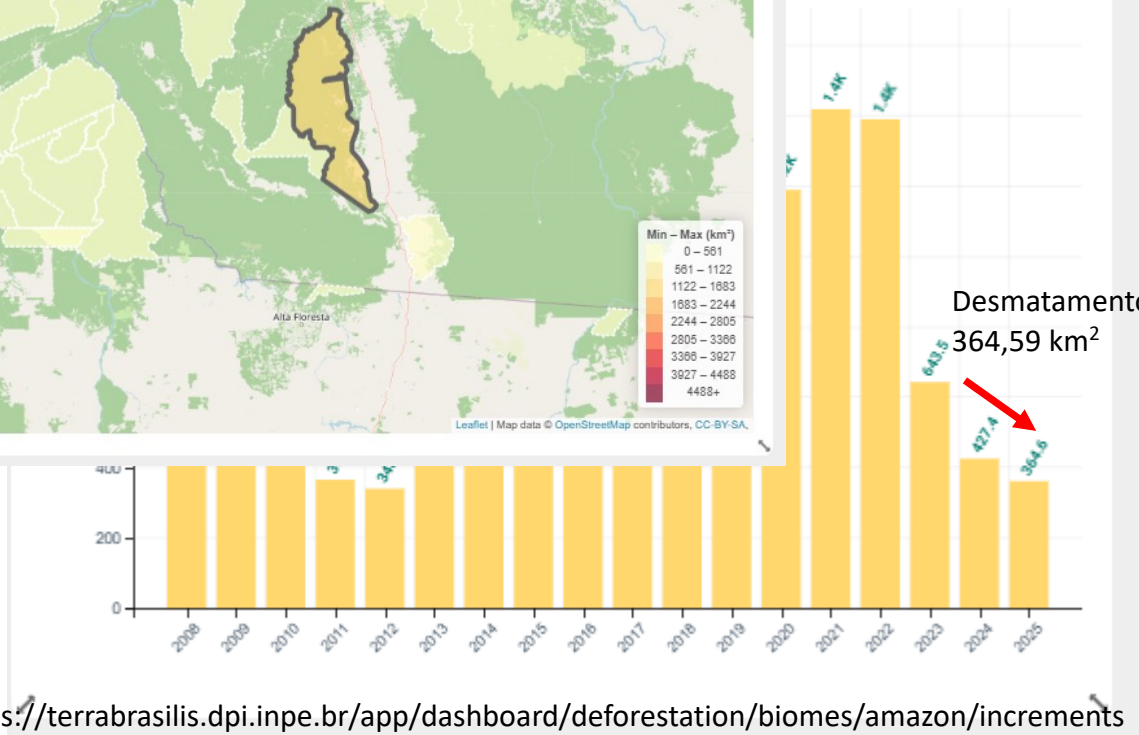
https://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/increments

104

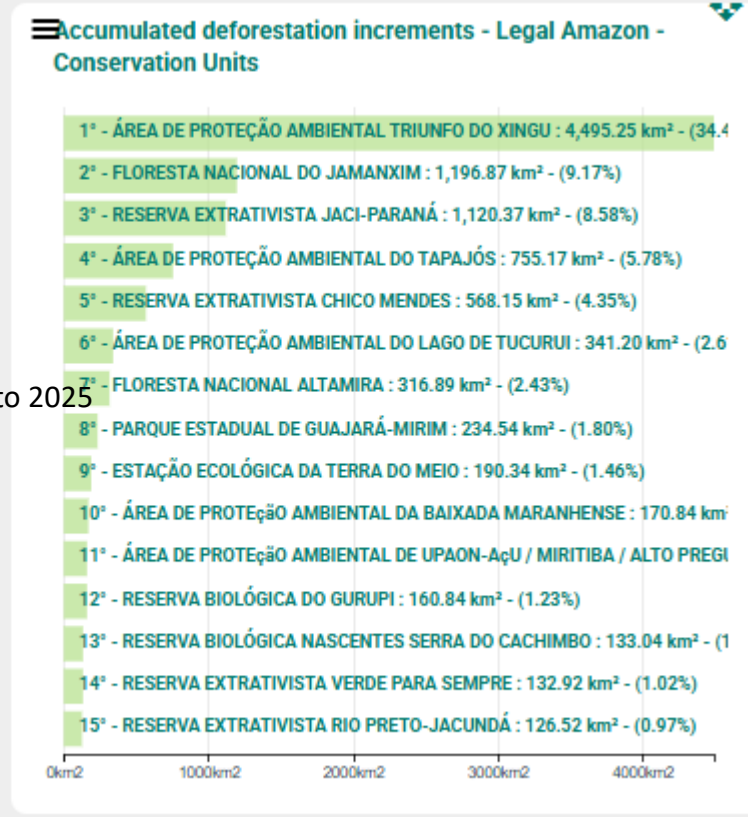
Unidades de conservação







Desmatamento 2025
364,59 km²



https://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/amazon/increments

105

Biomas Br

Prodes

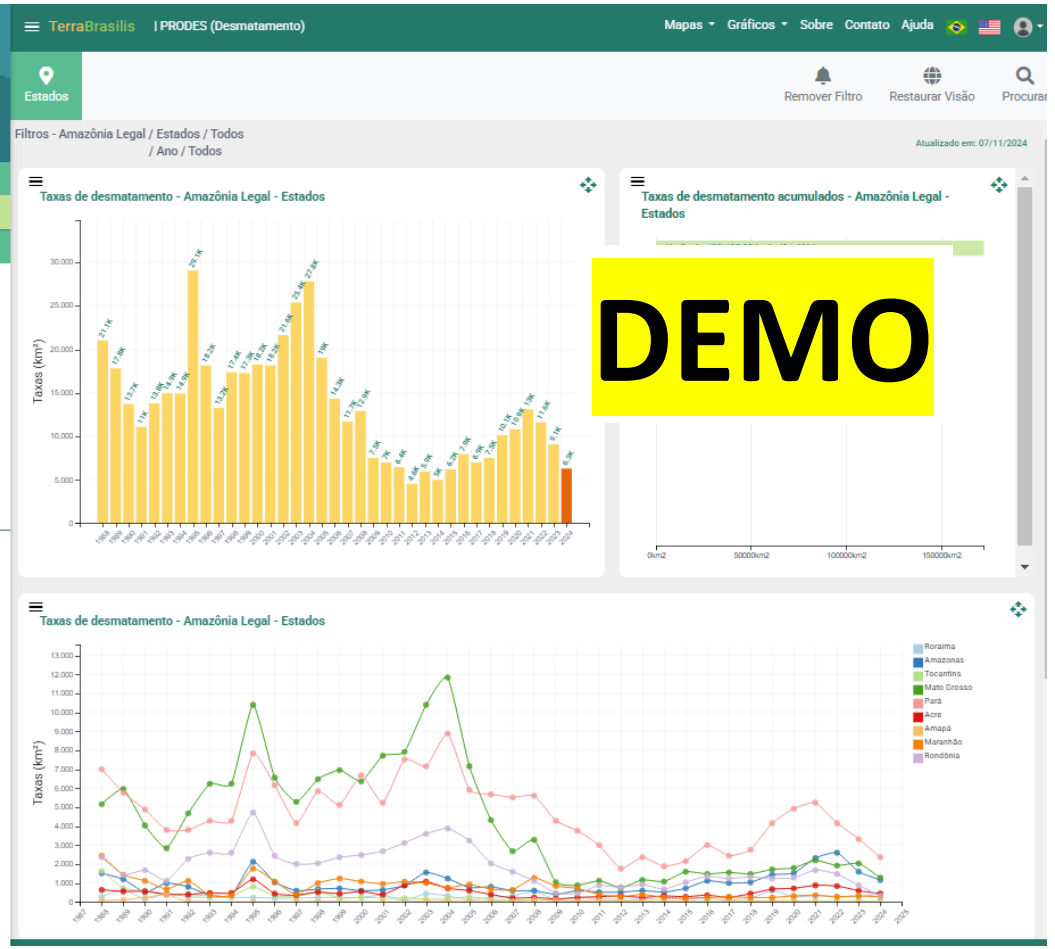
TerraBrasilis

TerraBrasilis - plataforma desenvolvida pelo INPE para **organização, acesso e uso** de dados geográficos dos sistemas de monitoramento ambiental.

Mapas



Painel - gráficos / consultas



E download https://terrabrasilis.dpi.inpe.br/

Prodes – Conformidade ambiental

Instituições brasileiras que avaliam a conformidade (CONAB / SERPRO) com dados do Prodes

A) EUDR - Regulamento da União Europeia sobre Desmatamento

Produtos de terras desmatadas após **31 de dezembro de 2020** não poderão ser comercializados

B) **Crédito rural** (Resolução CMN nº 5.193/2024)

Restrições de crédito para áreas desmatadas após **31 de julho de 2019**

C) **"Área rural consolidada"*** (Decreto nº 6.514/2008),

Código Florestal – o desmatamento ilegal anterior a **22 de julho de 2008** é considerado consolidado e anistiado.



https://agriconline.com.br/portal/artigo/car-cadastro-ambiental-rural-guia-para-produtores-rurais/

* São áreas já ocupadas por agricultura, pecuária ou infraestrutura antes de 22 de julho de 2008 (data definida pelo Código Florestal).

107

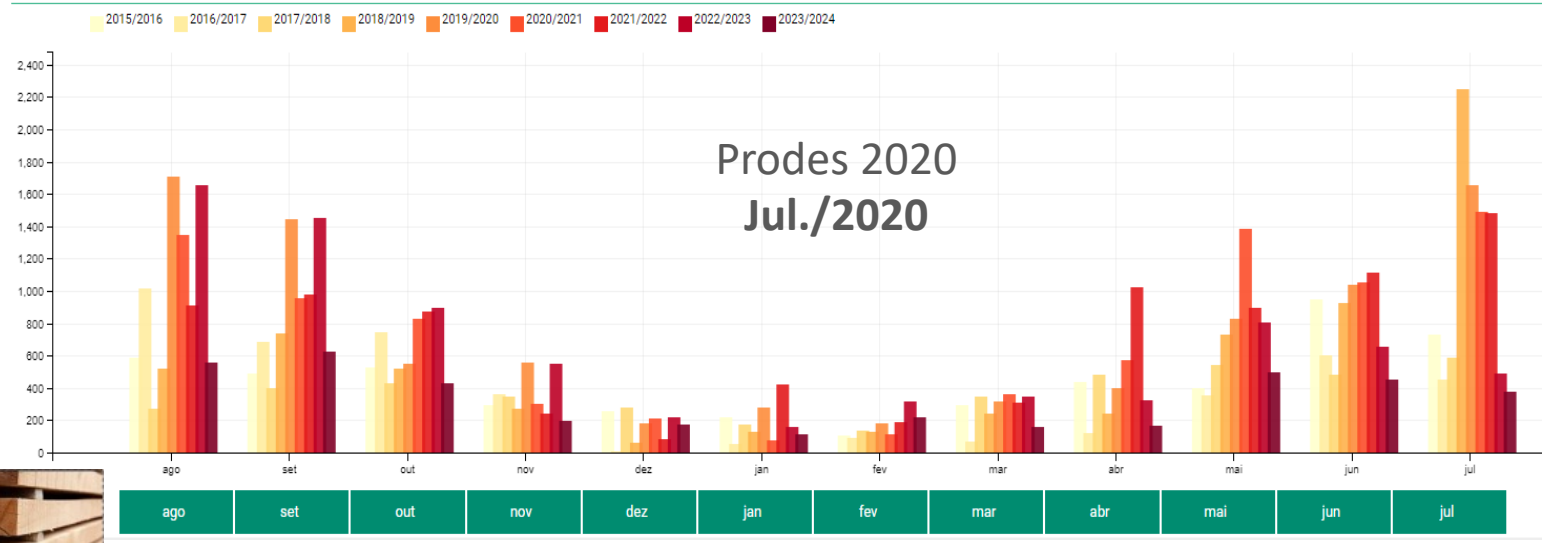
Prodes – dezembro/2020 EUDR

Regulamento da União Europeia sobre Desmatamento (EUDR)*
(EUDR 2023/1115)

Referência – **31/12/2020**

Área mínima = **0,5 ha**

Prodes – Calendário





** O EUDR 2023/1115 visa prevenir o desmatamento e a degradação florestal ligados a produtos colocados no mercado da UE ou exportados dela, exigindo que as empresas garantam que os produtos não venham de terras desmatadas após 31 de dezembro de 2020.*

Prodes – dezembro/2020 EUDR

Regulamento da União Europeia sobre Desmatamento (EUDR)
(EUDR 2023/1115)

Metodologia

Dados Sentinel-2/MSI – séries temporais
Brazil Data Cube (BDC)

Atributos espectrais:
B04, B8A, B11, NDVI, NBR, NDWI, AWEINSH, textura B8A (média).

Algoritmos de agrupamento não supervisionado
SOM - Mapa auto-organizável (SOM)
AHC - Agrupamento hierárquico aglomerativo

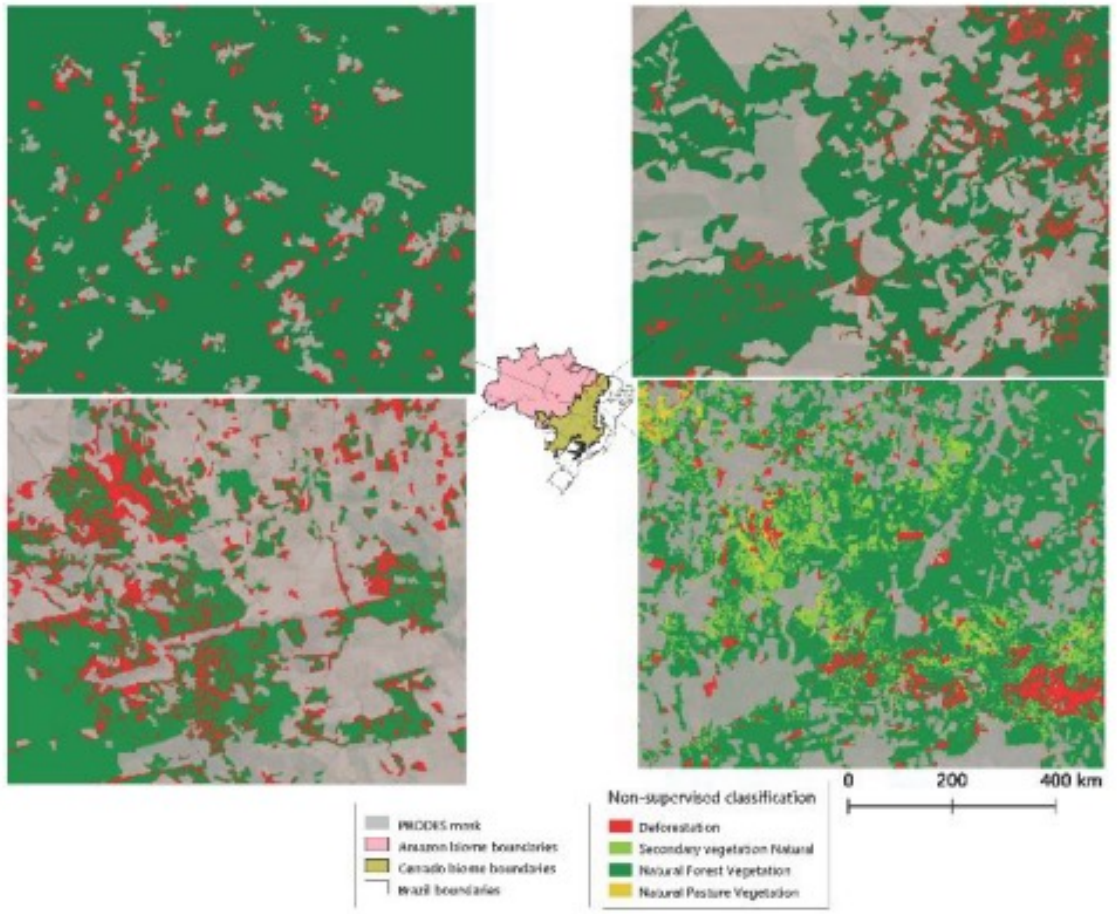
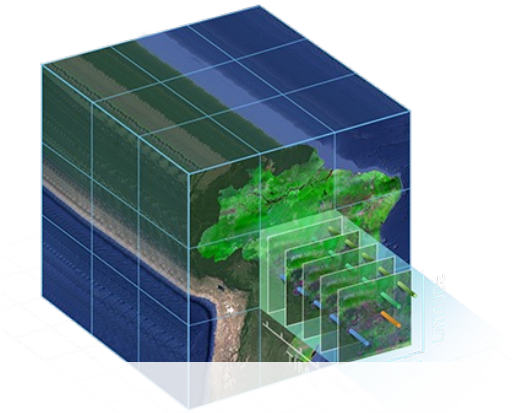


Figure 2. Tiles classified in the Brazilian Amazon and Cerrado biomes using the non-supervised approach.

Soler et al. (2025)

Prodes – dez./2020 EUDR

Regulamento da União Europeia sobre Desmatamento (EUDR)
(EUDR 2023/1115)



Brazil Data Cube

Ago.-dez./2020

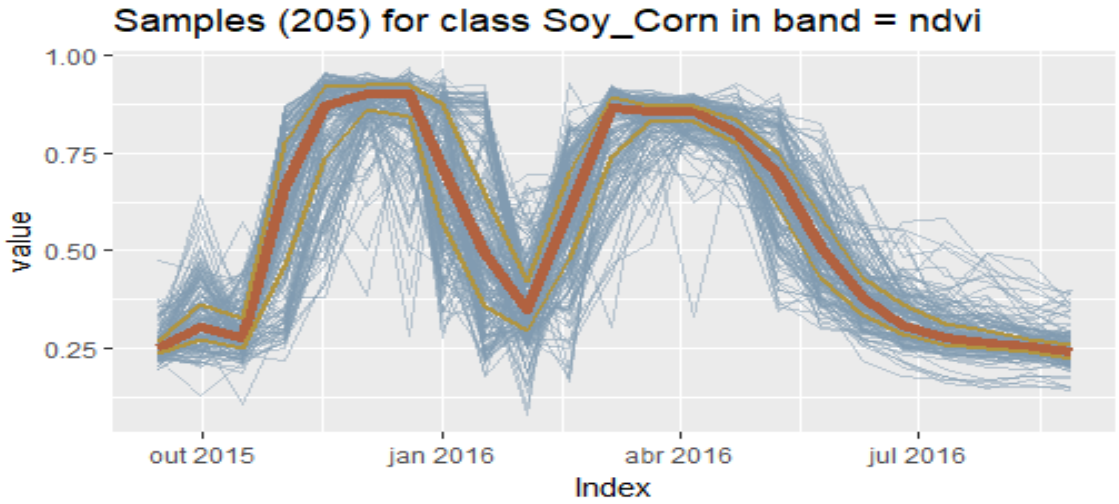
Mapa auto-organizável (SOM)
Algoritmo não supervisionado baseado em IA
(aprendizado profundo)

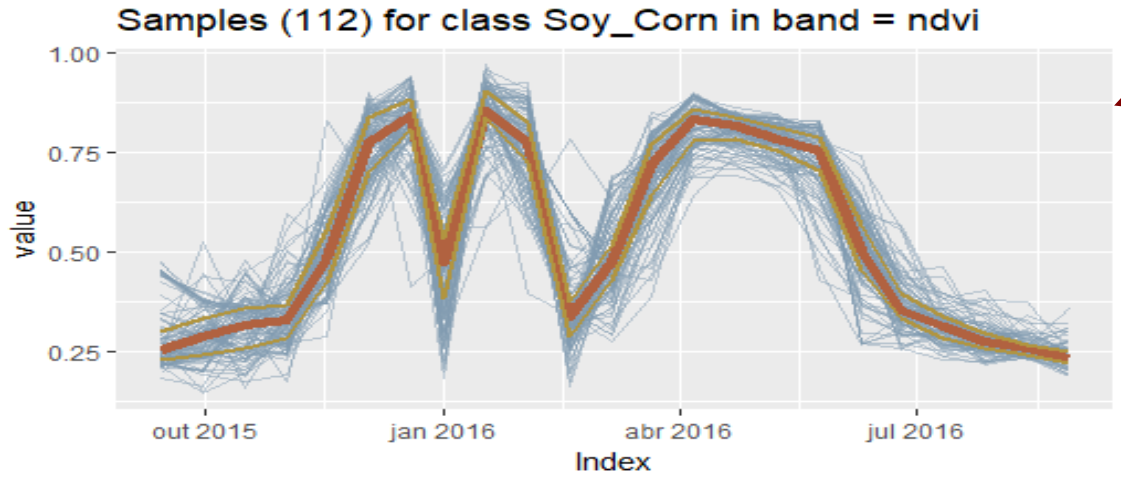
Dendrogramas - número de neurônios
AHC - Agrupamento hierárquico aglomerativo

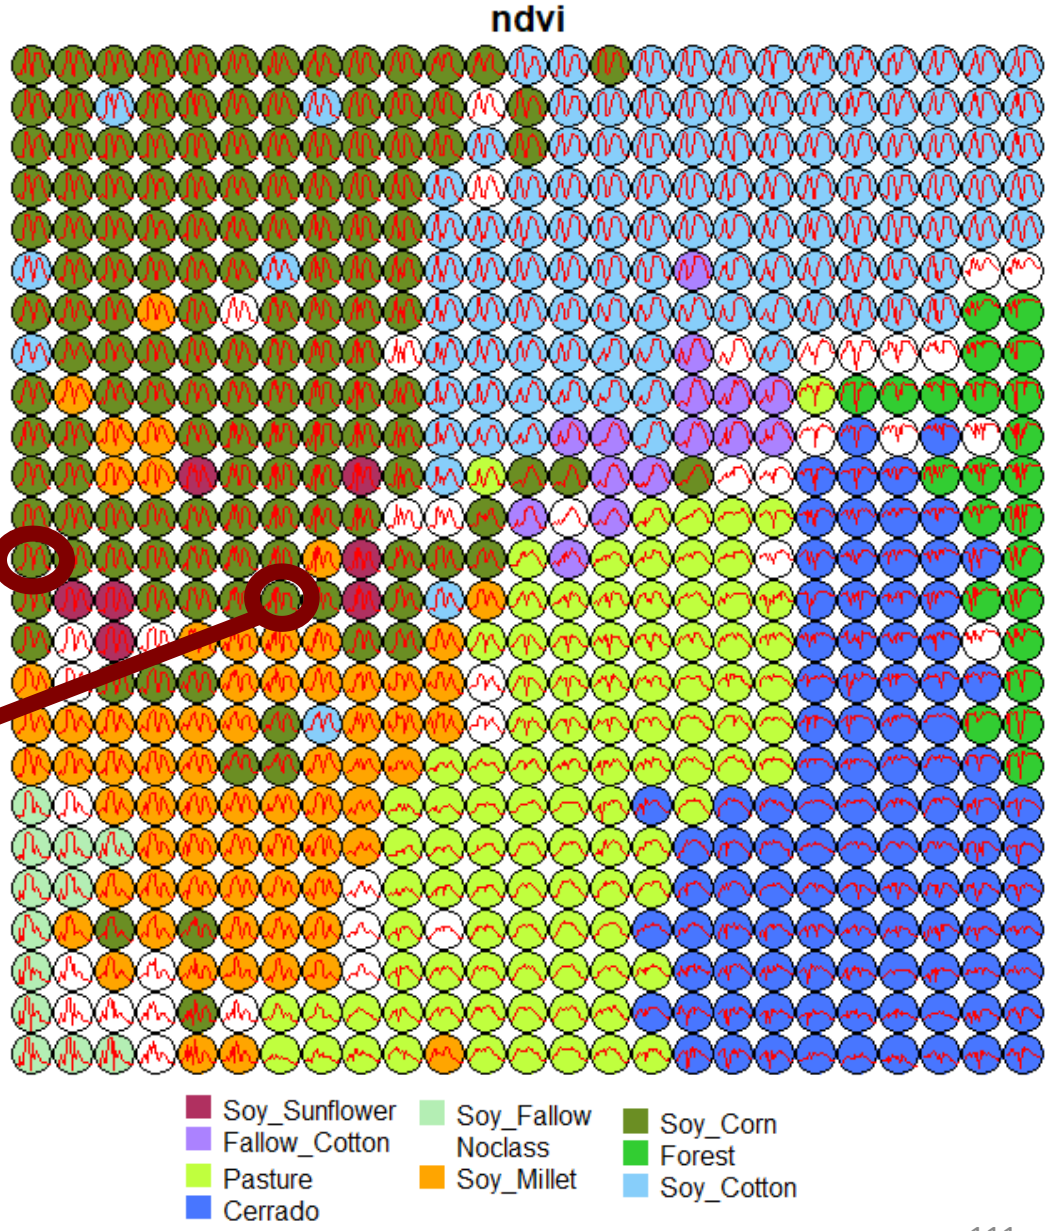
Rotulagem de segmentos – inspeção visual

SOM para identificar diferentes padrões de SITS

Rede neural de mapas auto-organizáveis (SOM) para agrupar SITS

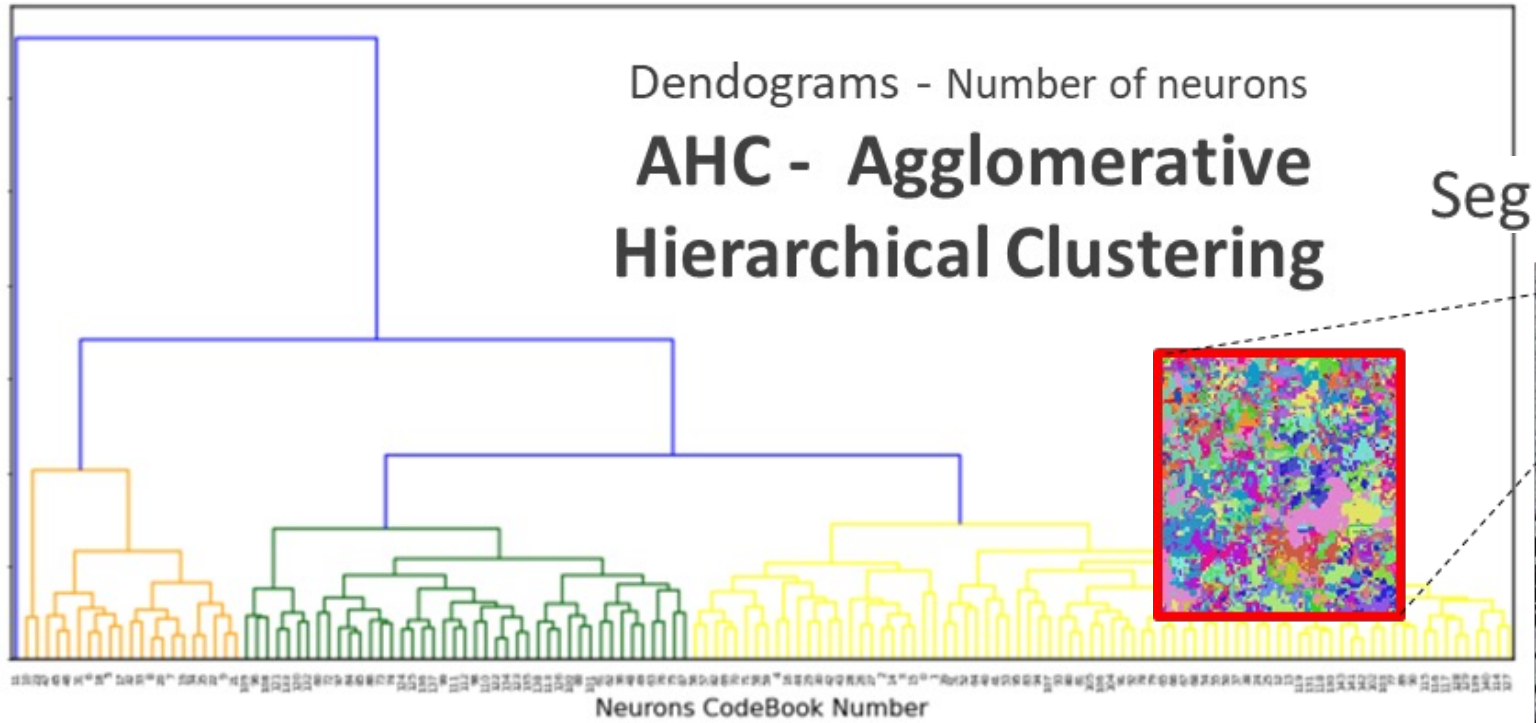




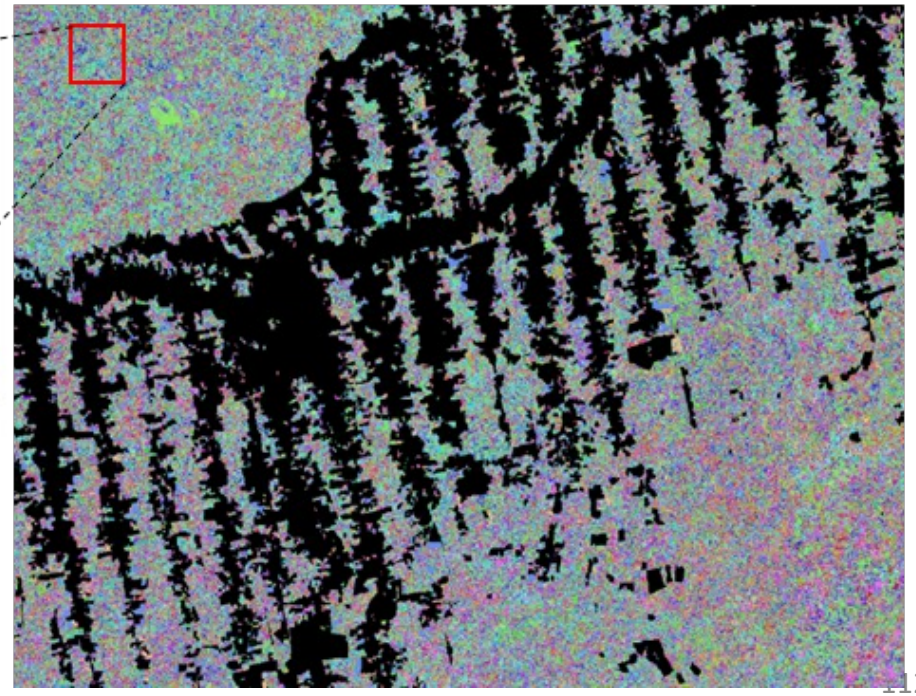


Prodes – dez./2020 EUDR

Regulamento da União Europeia sobre Desmatamento



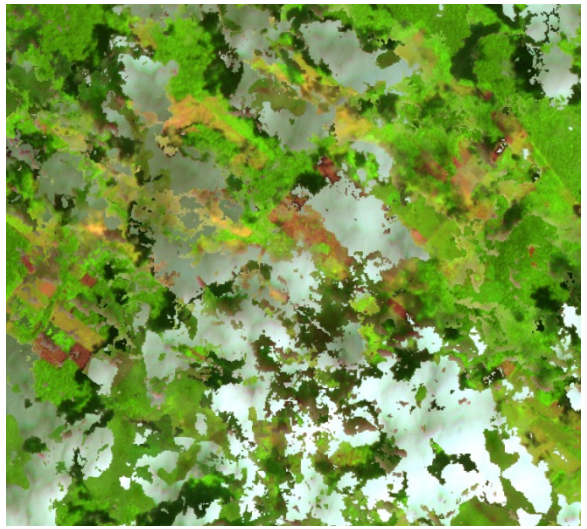
Segment labelling – Visual inspection



Prodes – dezembro/2020 EUDR

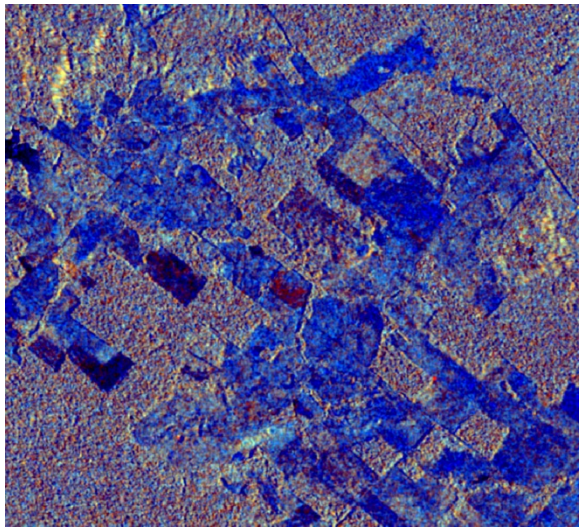
Radar – dados auxiliares

Mosaico de imagens Sentinel-2 BDC dez./2020



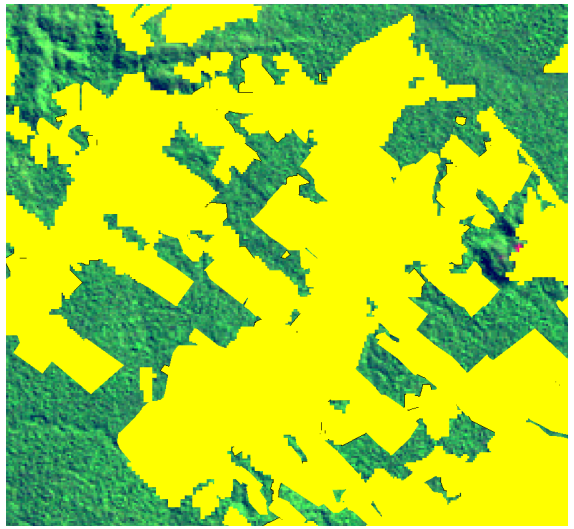
Sentinel - 2 (MSS)

Imagem de radar 28/12/2020 (sem nuvens)



Sentinel - 1 (SAR)

Delimitação das áreas desmatadas (amarelo)



Prodes – Validação da acurácia

Processos do PRODES: implicações para a qualidade dos dados

Aspectos da **qualidade do PRODES**:

I - Requisitos dos processos de mapeamento

II - Validação externa

III - Transparência

Seleção e processamento de imagens	Melhor período de detecção Menor cobertura de nuvens
Inspeção visual	Equipe multidisciplinar e experiente Padronização da legenda e do protocolo Dados auxiliares Informações sobre especificidades regionais ou locais
Auditoria	Processo sistemático (100% do território) Inspeção visual
Pós-processamento	Verificação de consistência e de regras de processamento
Validação do mapa	Amostragem estratificada e aleatória Equipe externa
Divulgação dos dados	Transparência (http://terrabrasilis.dpi.inpe.br/) Relatórios técnicos Publicações científicas

Auditor independente
Especialistas de cada bioma

Validador

Imagens de satélite de alta resolução como referência

Mosaico mensal Planet (5 m)

WPM/CBERS4 – PCA (2m)

Prodes – Comando e controle

Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm)

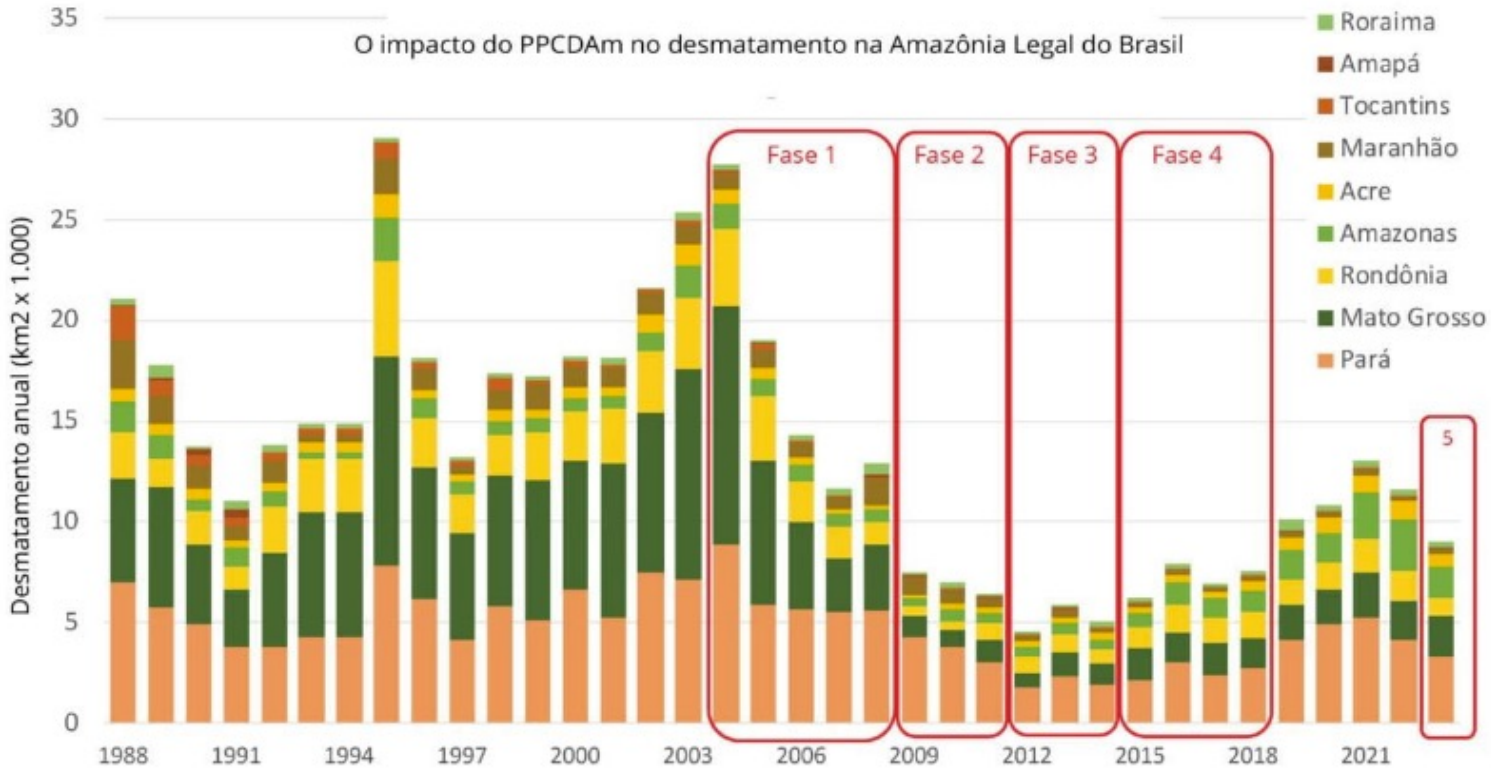
Lançado em 2003 – queda do desmatamento entre 2004 e 2012.

Em 2009,
Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC)
Redução de 80% do desmatamento até 2020.

2012 – meta superada.
Taxa anual = 20% da média histórica de vinte anos

2018 – governo Bolsonaro – desmantelou o programa

2023 – fase 5 – ONGs, contenção do desmatamento e regularização fundiária para comunidades florestais, assentamentos e agricultores familiares; - produção sustentável, REDD+, restauração



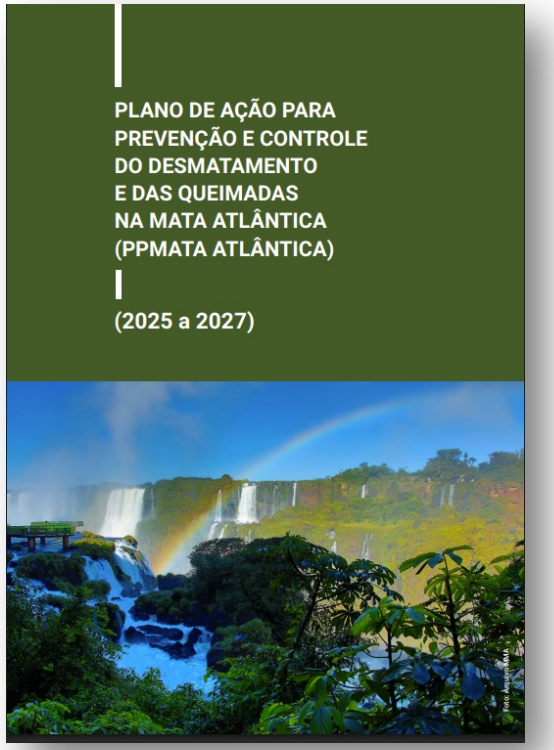
https://brasil.mongabay.com/2025/09/a-formula-que-reduziu-o-desmatamento-no-brasil-no-seculo-21/

115

Prodes – Comando e controle

Plano de Ação para Prevenção e Controle do Desmatamento (PPCD)
Todos os biomas

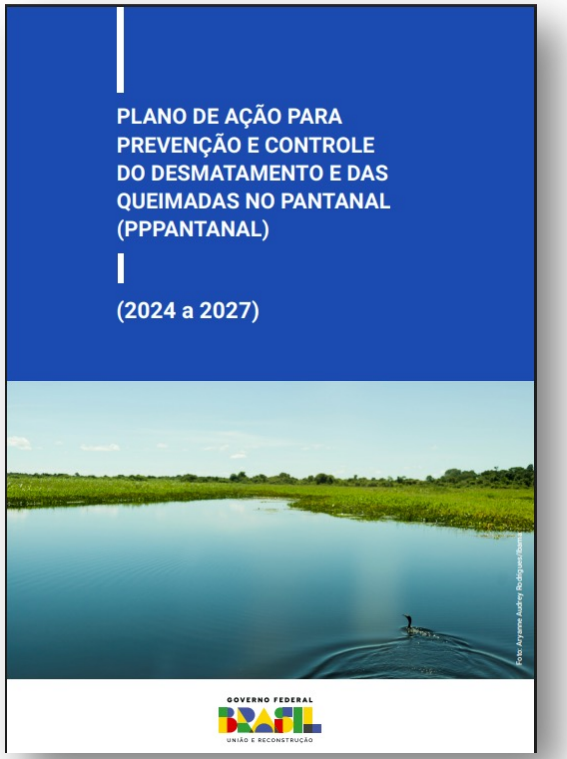
(decreto de 2023 – além do PPCDAm e do PPCerrado)



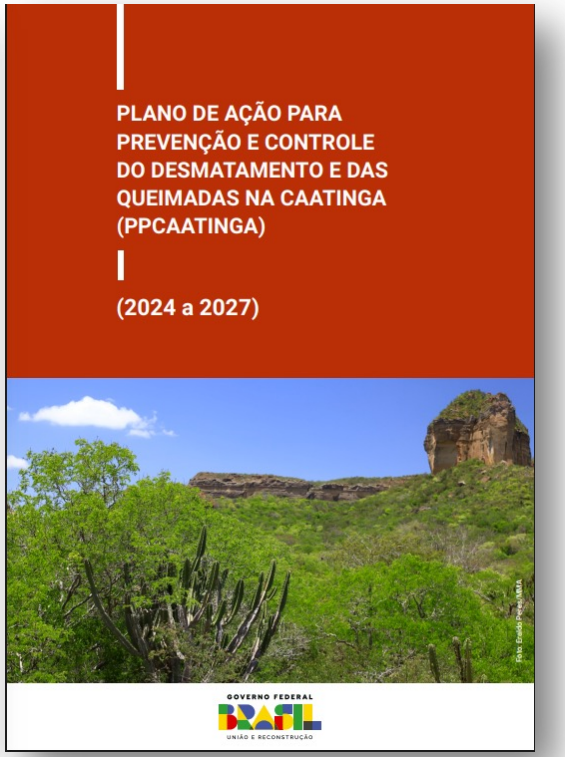
https://www.gov.br/mma/pt-br/assuntos/controle-ao-desmatamento-queimadas-e-ordenamento-ambiental-territorial/controle-do-desmatamento-1/ppmata-atlantica/PPMata_Atlantica_2025_internet_final.pdf



https://www.gov.br/mma/pt-br/assuntos/controle-ao-desmatamento-queimadas-e-ordenamento-ambiental-territorial/controle-do-desmatamento-1/pppampa/PPPampa_2025_internet.pdf



https://www.gov.br/mma/pt-br/assuntos/controle-ao-desmatamento-queimadas-e-ordenamento-ambiental-territorial/controle-do-desmatamento-1/pppantanal/pppantanal_2024.pdf



https://www.gov.br/mma/pt-br/assuntos/controle-ao-desmatamento-queimadas-e-ordenamento-ambiental-territorial/controle-do-desmatamento-1/ppcaatinga/ppcaatinga_2024_20_12.pdf

116

Biomas Br

DETER

Monitoramento diário da supressão e da degradação da vegetação nativa



https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supressão/degradação

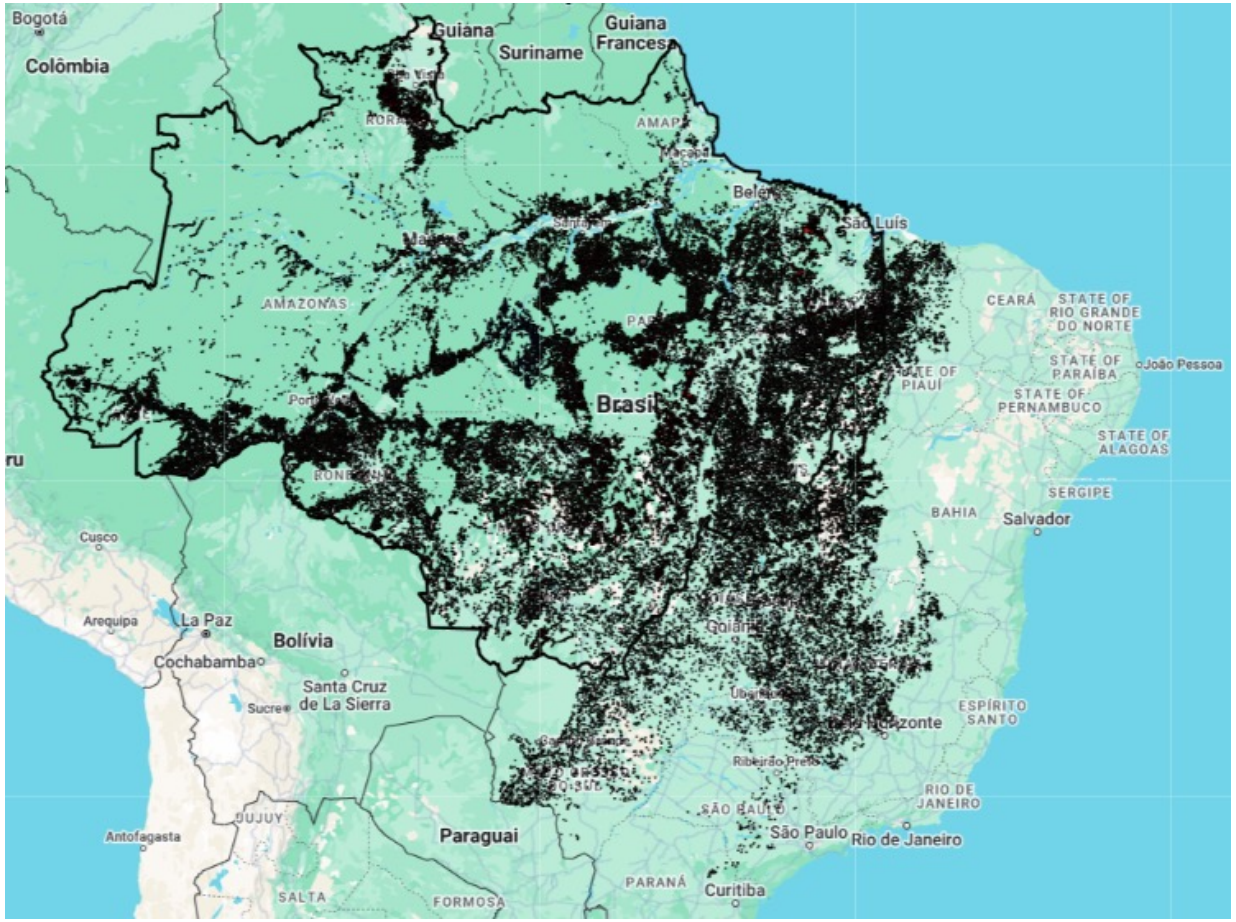
Deter

Amazônia, Cerrado,
Pantanal e Amazônia não florestal

São produzidos <u>alertas</u> diários
Agregados mensais - também divulgados

Os alertas são enviados às instituições de controle
IBAMA, secretarias estaduais e municipais de meio ambiente etc.

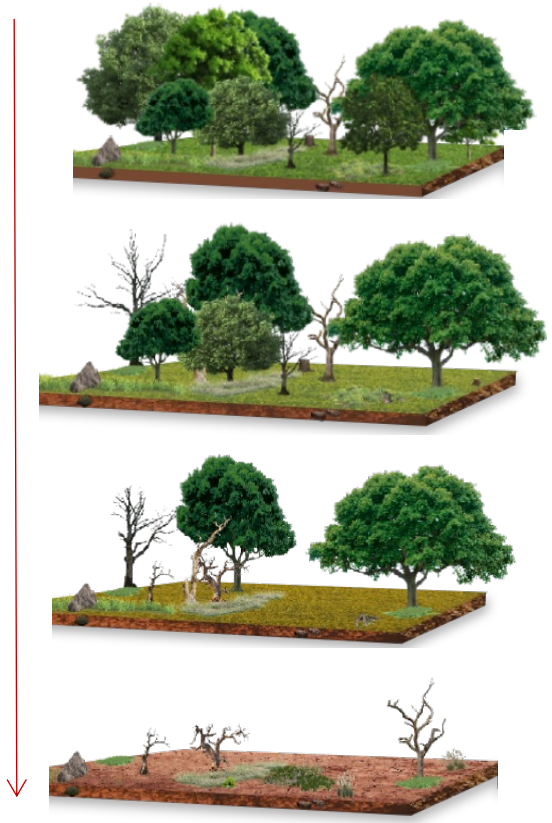
Dados: polígonos, tabelas, vetores;
Disponíveis na plataforma **TerraBrasilis**

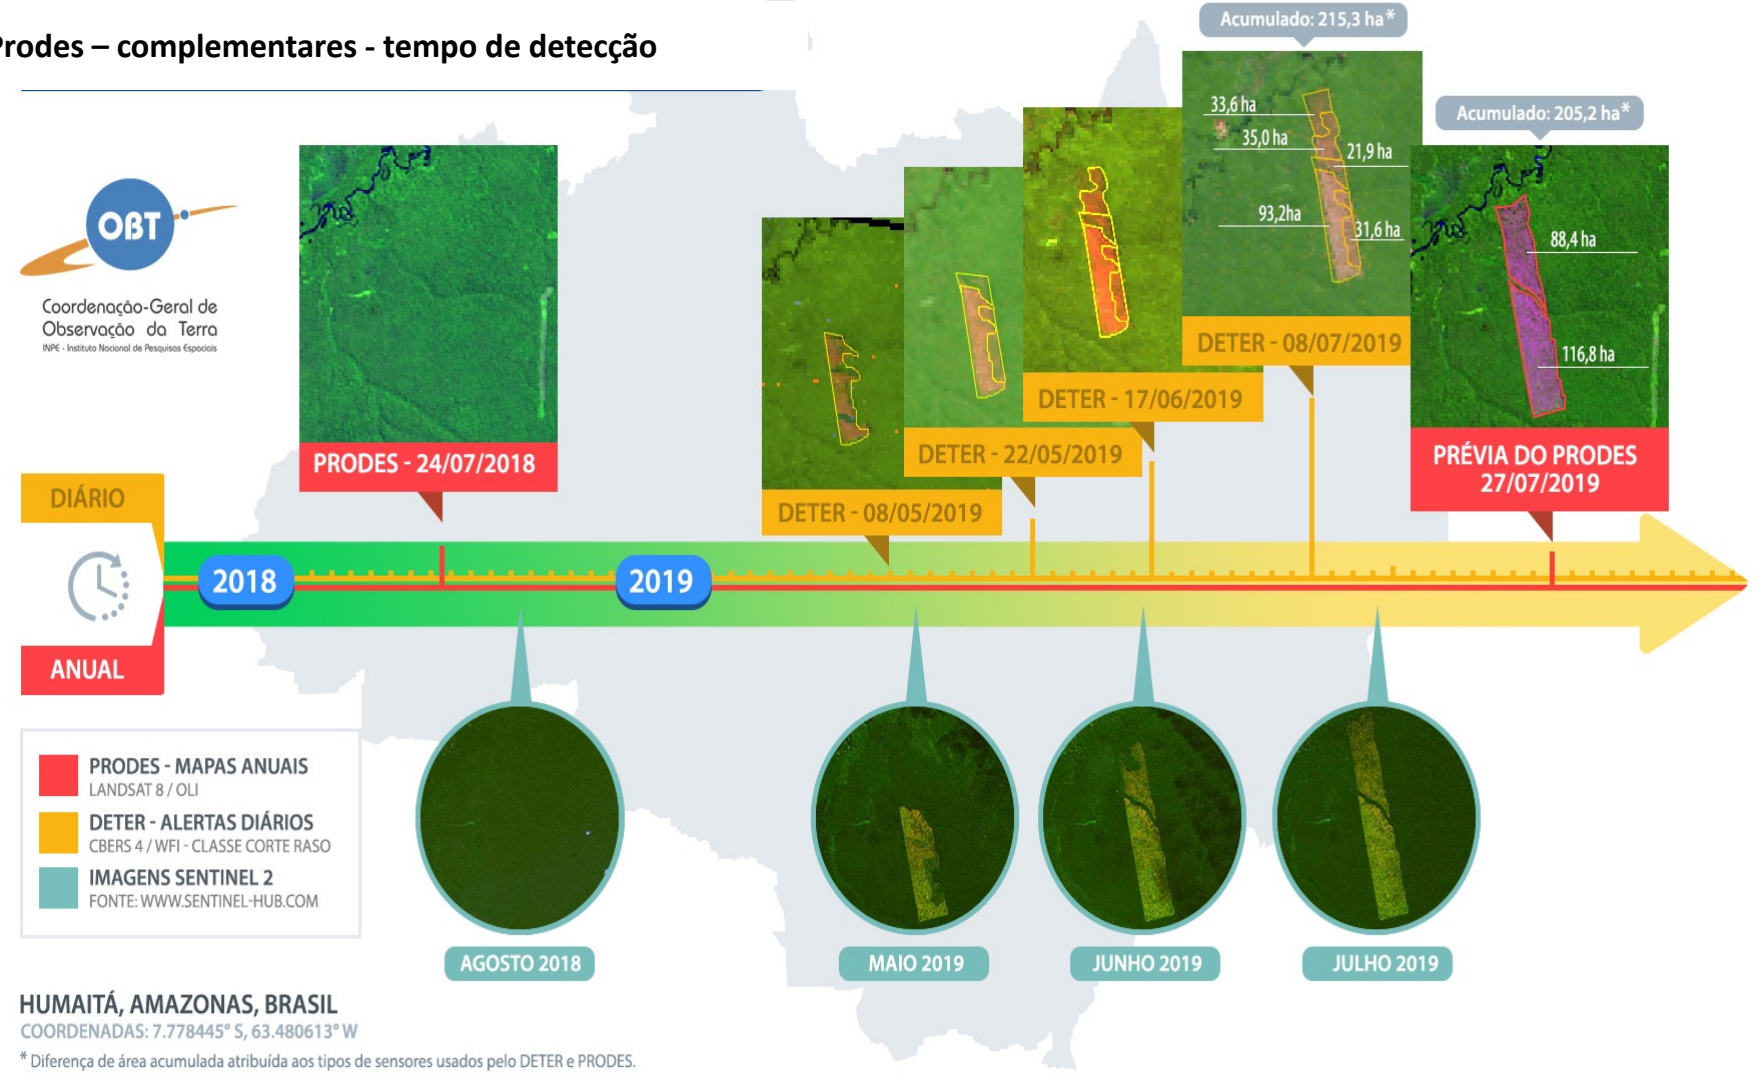


https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supressão/degradação

Alertas diários Deter x Prodes – complementares - tempo de detecção





https://doi.org/10.1109/JSTARS.2015.2437075

https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supressão/degradação

Deter

Amazônia, Cerrado,
Pantanal e Amazônia não florestal

Desmatamento, supressão e degradação florestal

2004 – 2014 MODIS 250 m (> 25 ha)
2015 – atual WFI 64 m (> 3 ha)

Satélites brasileiros
Amazonia 1, CBERS 4 e CBERS 4A
Sensor Wide Field Imaging – WFI

Alertas
Área mínima de **3 hectares**
Interpretação visual de imagens

Máscara do Prodes
Mapeamento incremental
Pode ter “repetição”

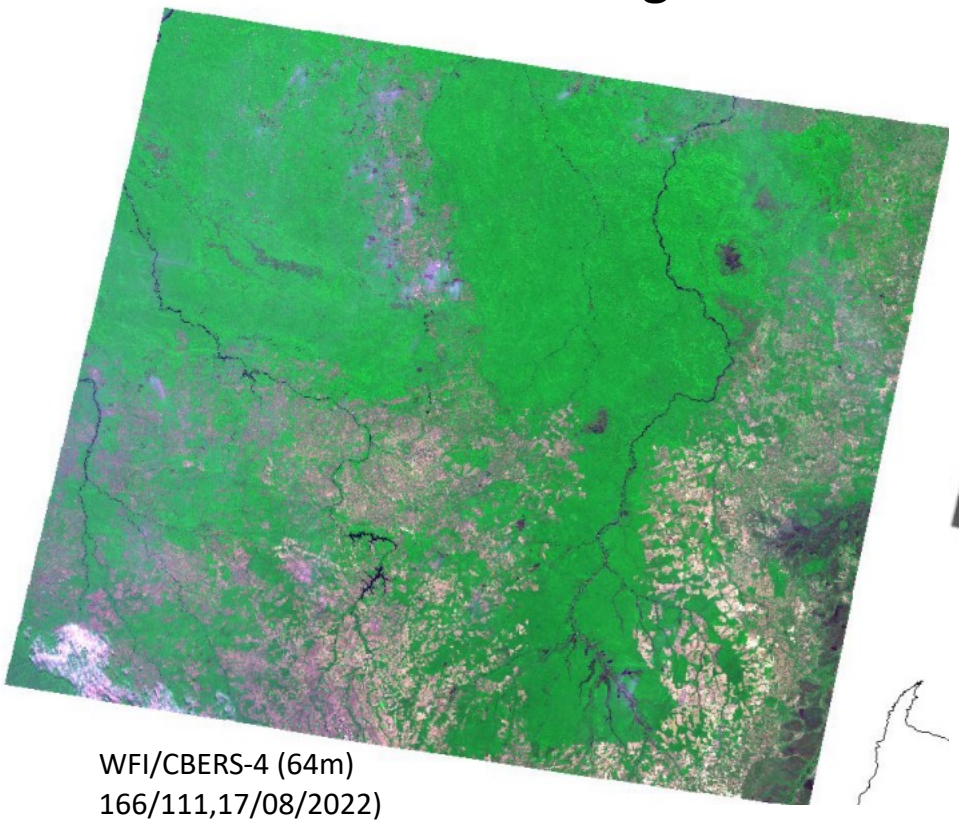




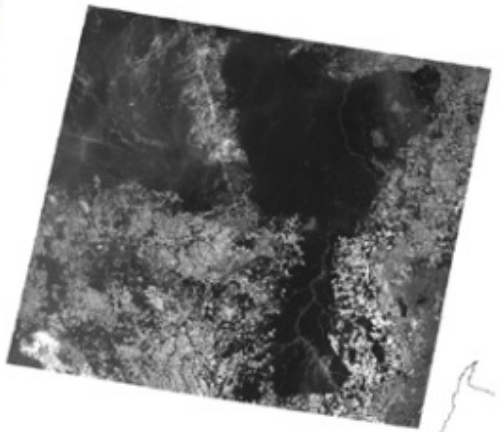
https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supressão/degradação

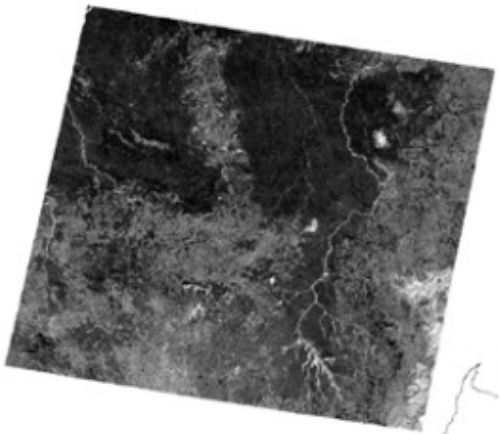
Imagens WFI modelo linear de mistura espectral - MLME



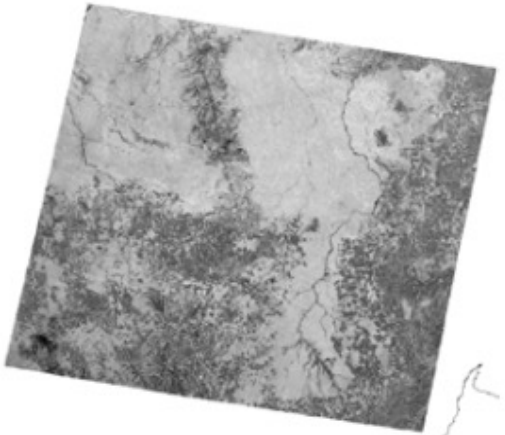
WFI/CBERS-4 (64m)
166/111,17/08/2022)
R(R)/IRp(G)/G (B)



Fração solo



Fração sombra



Fração vegetação

***Máscara do Prodes para detectar alertas**

Alertas de supressão/degradação

Deter

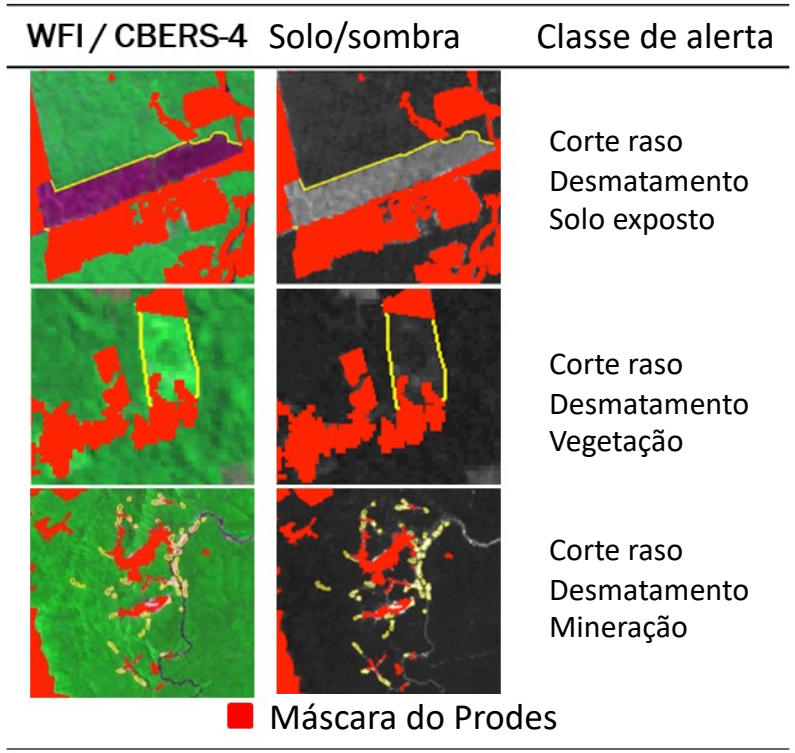
Alertas diários

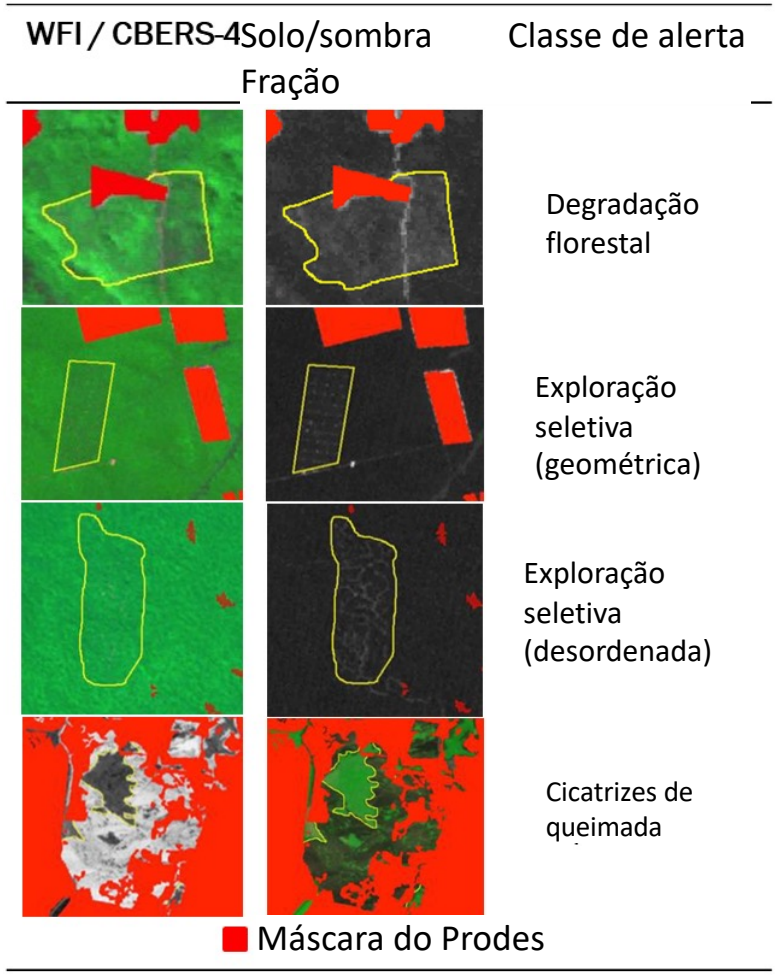
Classes:
Desmatamento /
supressão,

e

Cicatrizes de queimada, degradação florestal e exploração seletiva *(indicadores de* ***degradação*** *florestal)*

Classes DETER - Amazônia





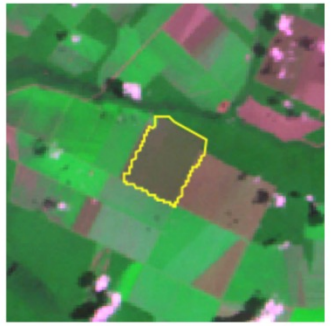
https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supressão/degradação

DETER - antes e depois

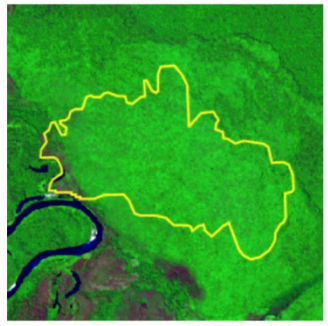
(4)
Id: 88234
Classe Deter: DESMATAMENTO_CR
Area Deter: 3.27 km2
Data imagem anterior deteccao: 2022-12-11 (CBERS-4/AWFI)
Data deteccao alerta Deter: 2023-02-01 (CBERS-4/AWFI)
Intervalo entre datas: 52 dias
Orbita/Ponto: 162/111
Ano da imagem Prodes: 2022
Ano mes mosaico Planet: 2023-02
UF: MT
Lat: -12.6941 Lon: -52.2662

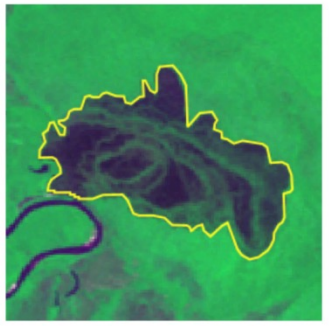
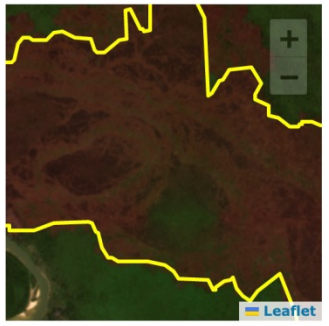





L8 2022-08 | CB4 2022-12-11 | CB4 2023-02-01 | Planet 2023-02

(15)
Id: 77415
Classe Deter: CICATRIZ_DE_QUEIMADA
Area Deter: 19.30 km2
Data imagem anterior deteccao: 2022-08-29 (CBERS-4/AWFI)
Data deteccao alerta Deter: 2022-10-20 (CBERS-4/AWFI)
Intervalo entre datas: 52 dias
Orbita/Ponto: 162/117
Ano da imagem Prodes: 2022
Ano mes mosaico Planet: 2022-10
UF: MT
Lat: -12.7185 Lon: -52.8705



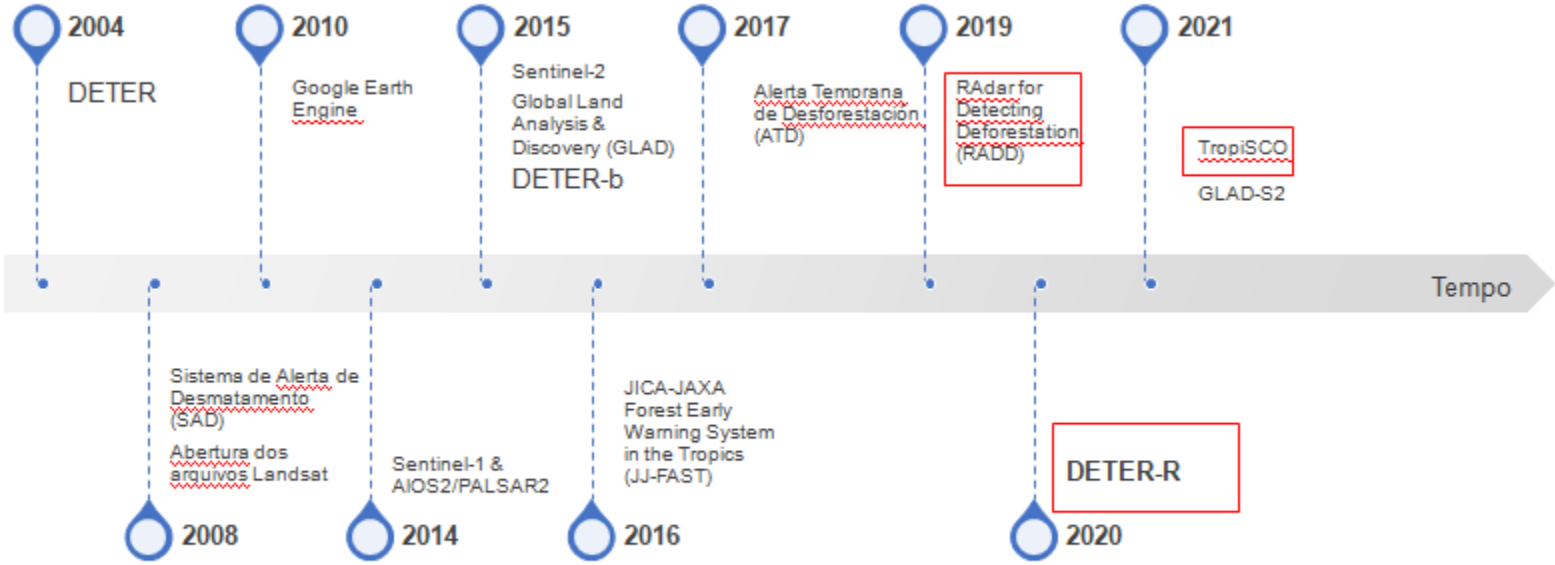



L8 2022-08 | CB4 2022-08-29 | CB4 2022-10-20 | Planet 2022-10

Alertas de supressão/degradação

Deter-R

Sistema automático de detecção de distúrbios florestais quase em tempo real baseado em imagens SAR de banda C.



Operado de nov./2020 a ago./2024

Os dados gerados não são públicos.

Sistemas baseados em banda C

Deter-RT

O novo sistema INPE-TropiSCO de monitoramento do desmatamento no bioma Amazônia.

https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

124

Alertas de supressão/degradação

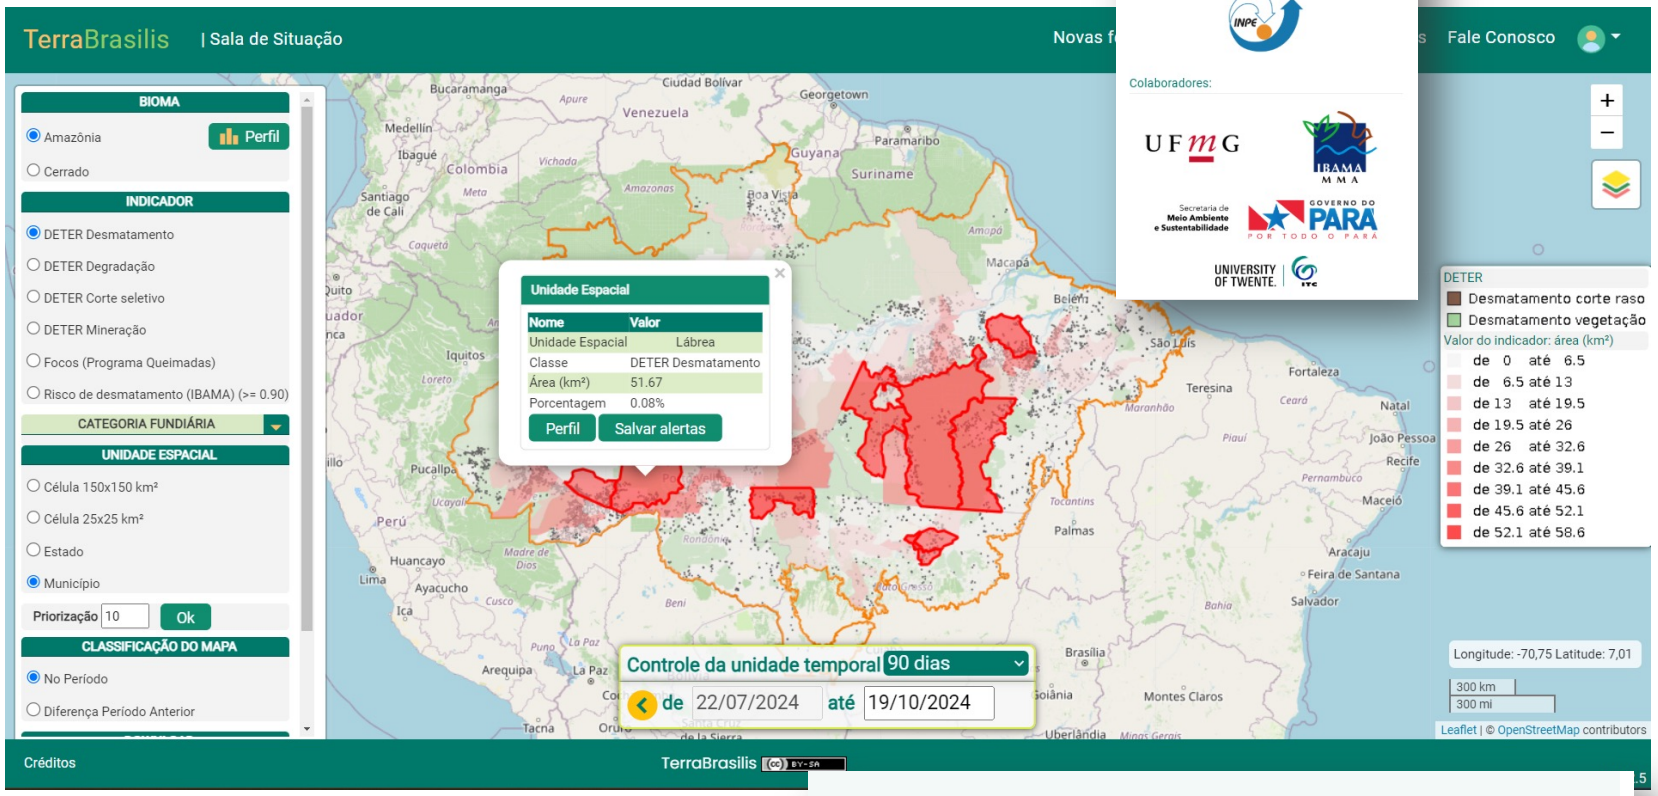
Sala de situação

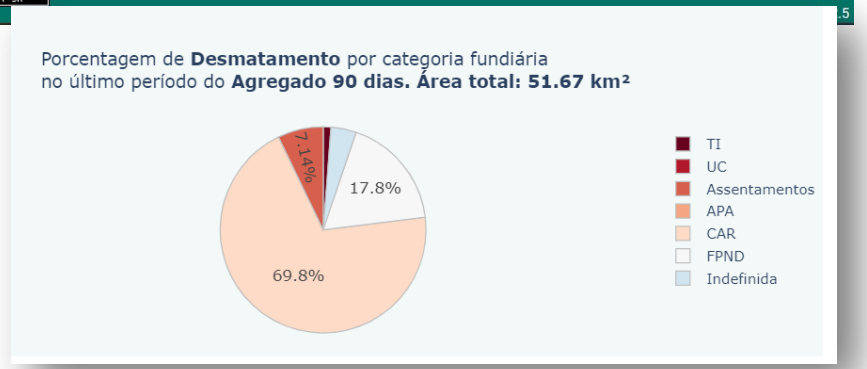
DETER e queimadas (Programa Queimadas)

Risco de desmatamento Modelo do IBAMA

Ferramenta para gestores

MUNICÍPIOS





https://terrabrasilis.dpi.inpe.br/app/dashboard/alerts/biomes/amazonia-nb/aggregated/

Alertas de supressão/degradação

Evolução do Deter



COEAM (2025)

Teste das classes Deter Amazônia



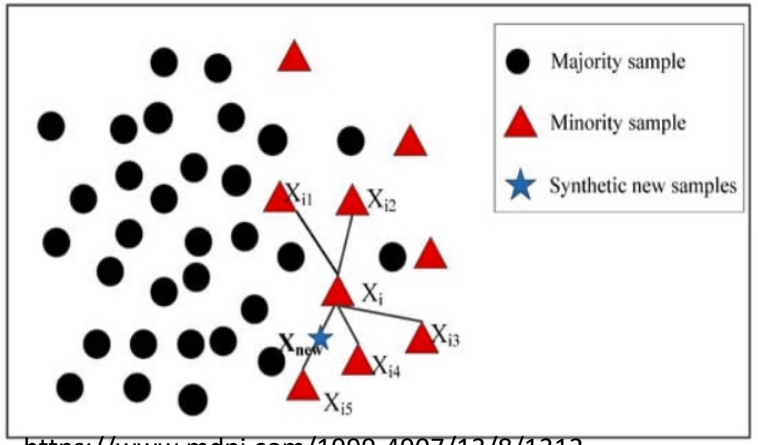
Desmatamento

Random Forest com amostras sintéticas



https://dida.do/what-is-random-forest

Princípio do algoritmo SMOTE baseado nos k vizinhos mais próximos.



https://www.mdpi.com/1999-4907/13/8/1312

Alertas de supressão/degradação

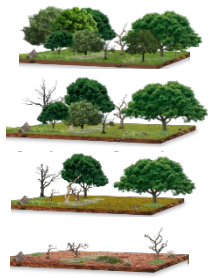
Evolução do Deter



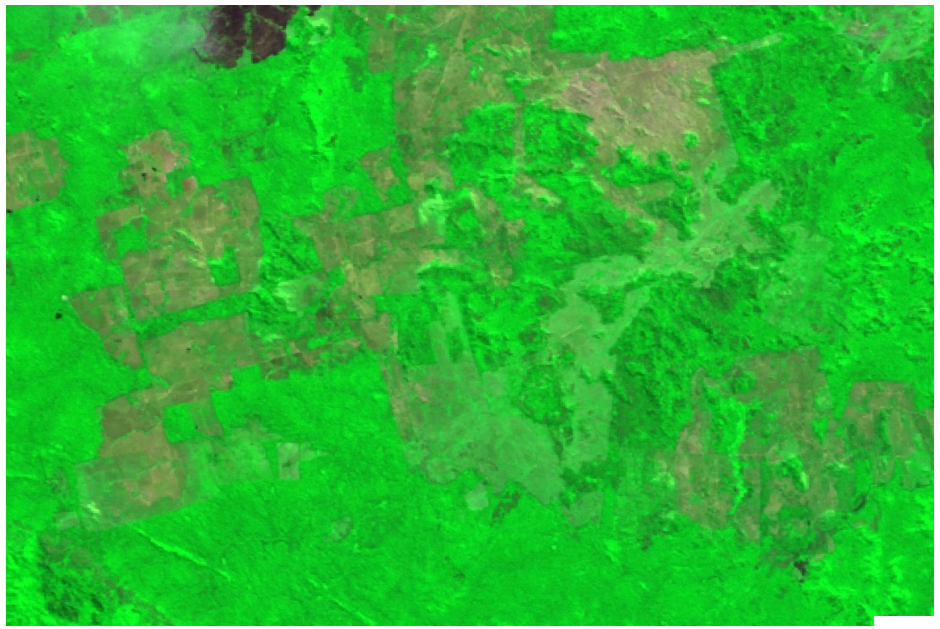
COEAM (2025)

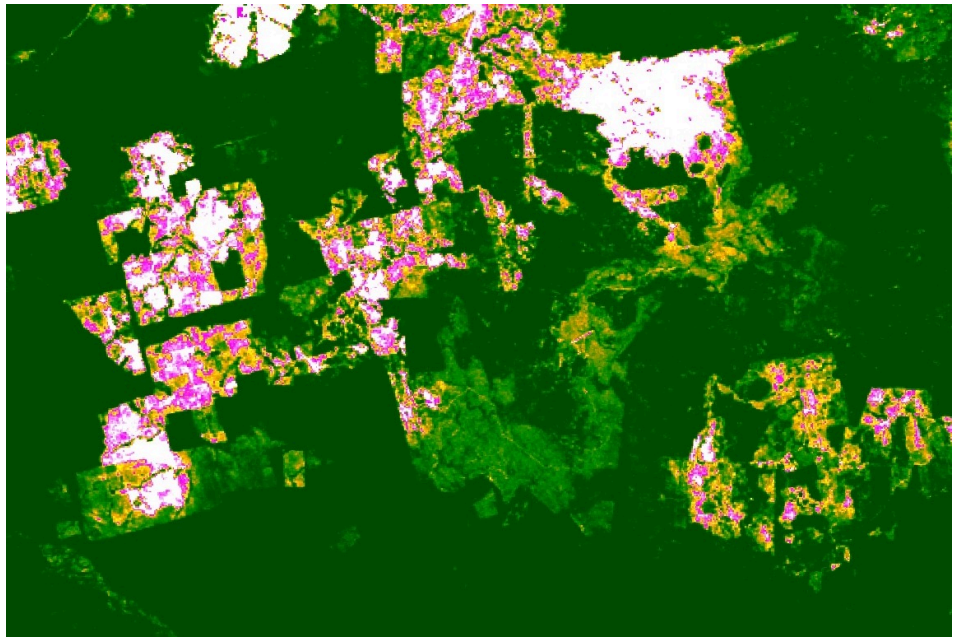
Teste das classes Deter Amazônia

Índices derivados do modelo linear do tipo NDFI (Normalized Difference Fraction Index)



Degradação





Diferentes níveis de degradação florestal

Alertas de supressão/degradação

Evolução do Deter



COEAM (2025)

Teste das classes Deter Amazônia

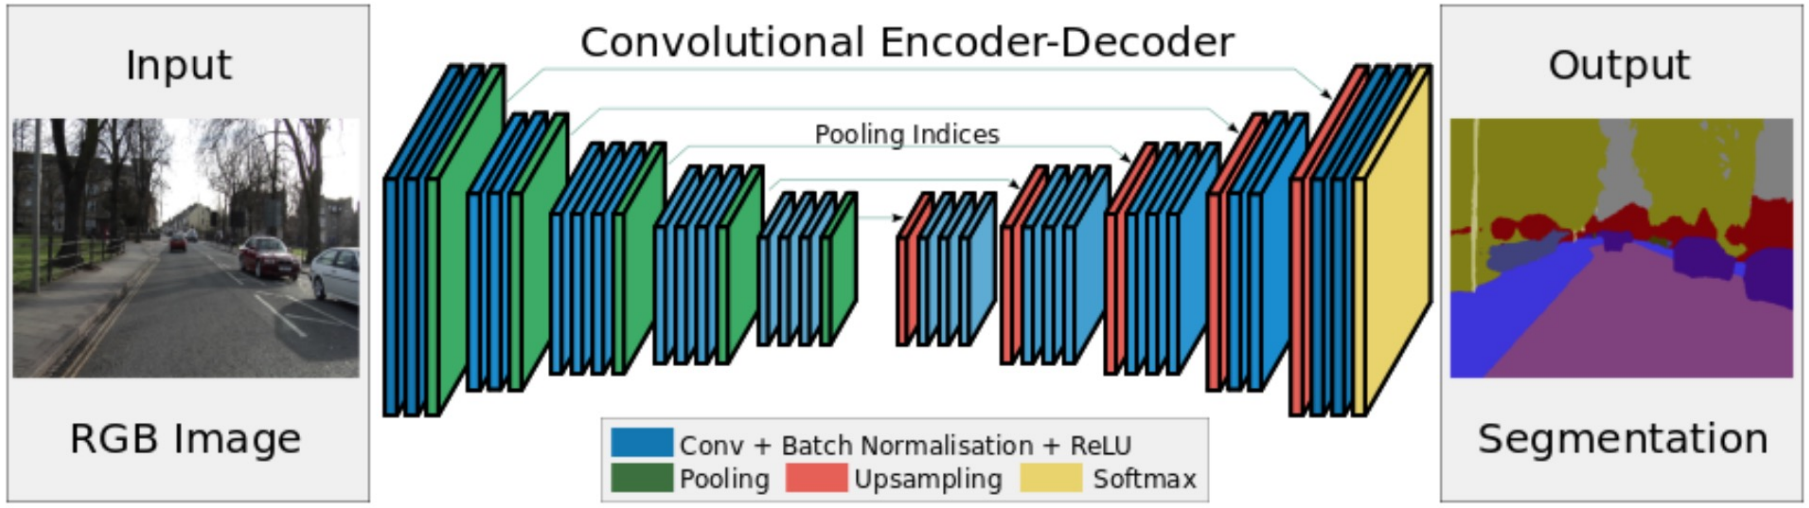


Degradação florestal por fogo



Mineração

A segmentação identifica o contexto



Aprendizado profundo com arquitetura U-net

Alertas de supressão/degradação



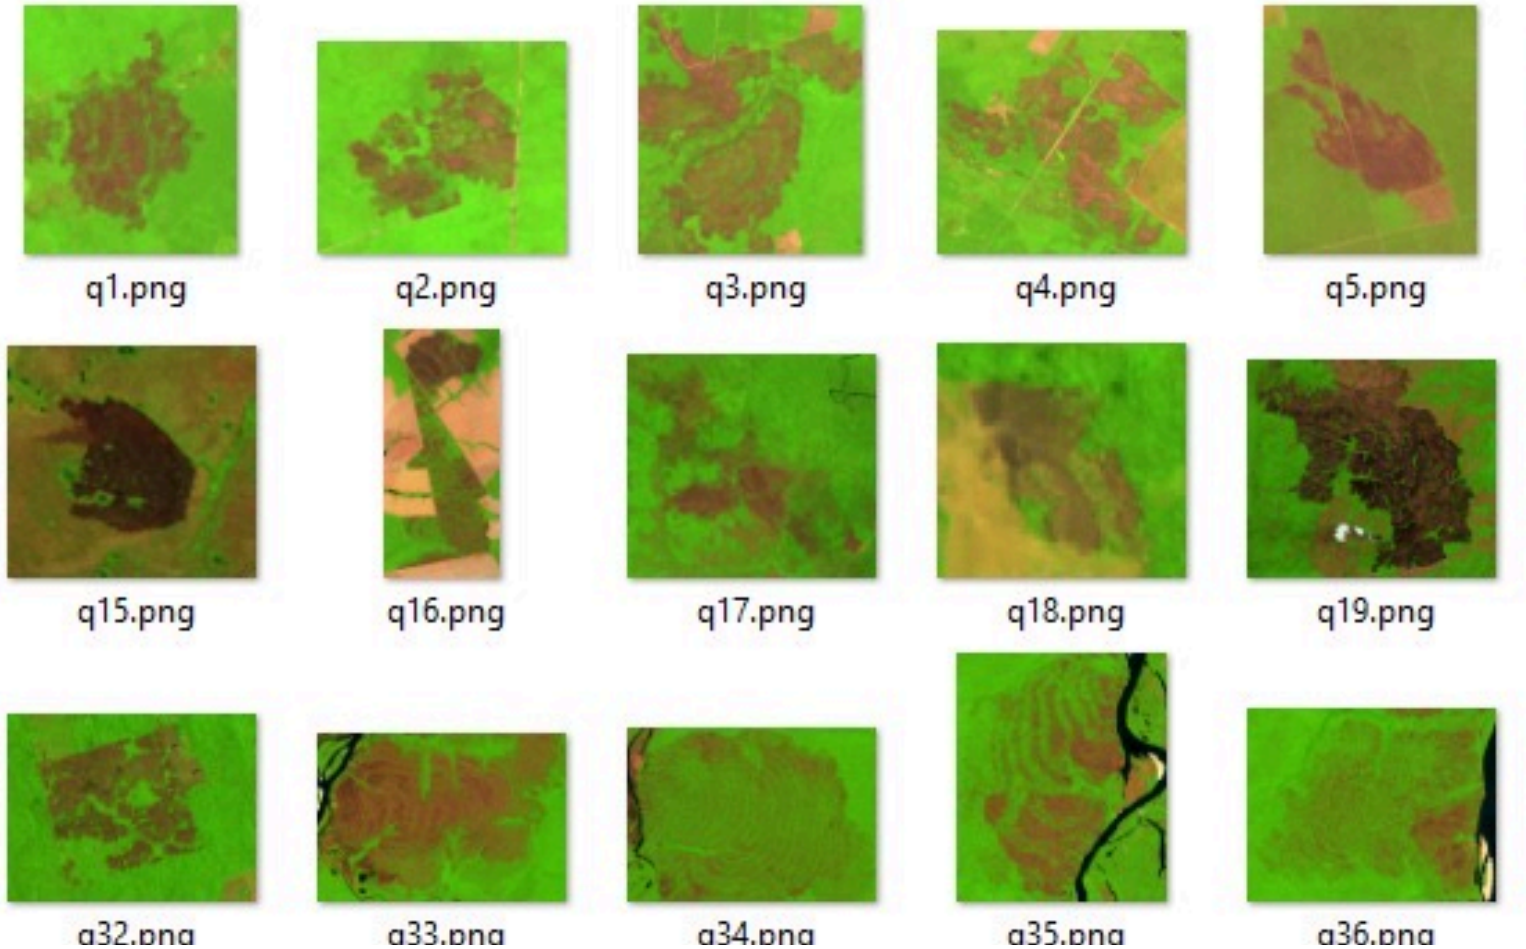
COEAM (2025)



Fogo

Evolução do Deter

Treinamento



Aprendizado profundo com arquitetura U-net

Alertas de supressão/degradação



COEAM (2025)

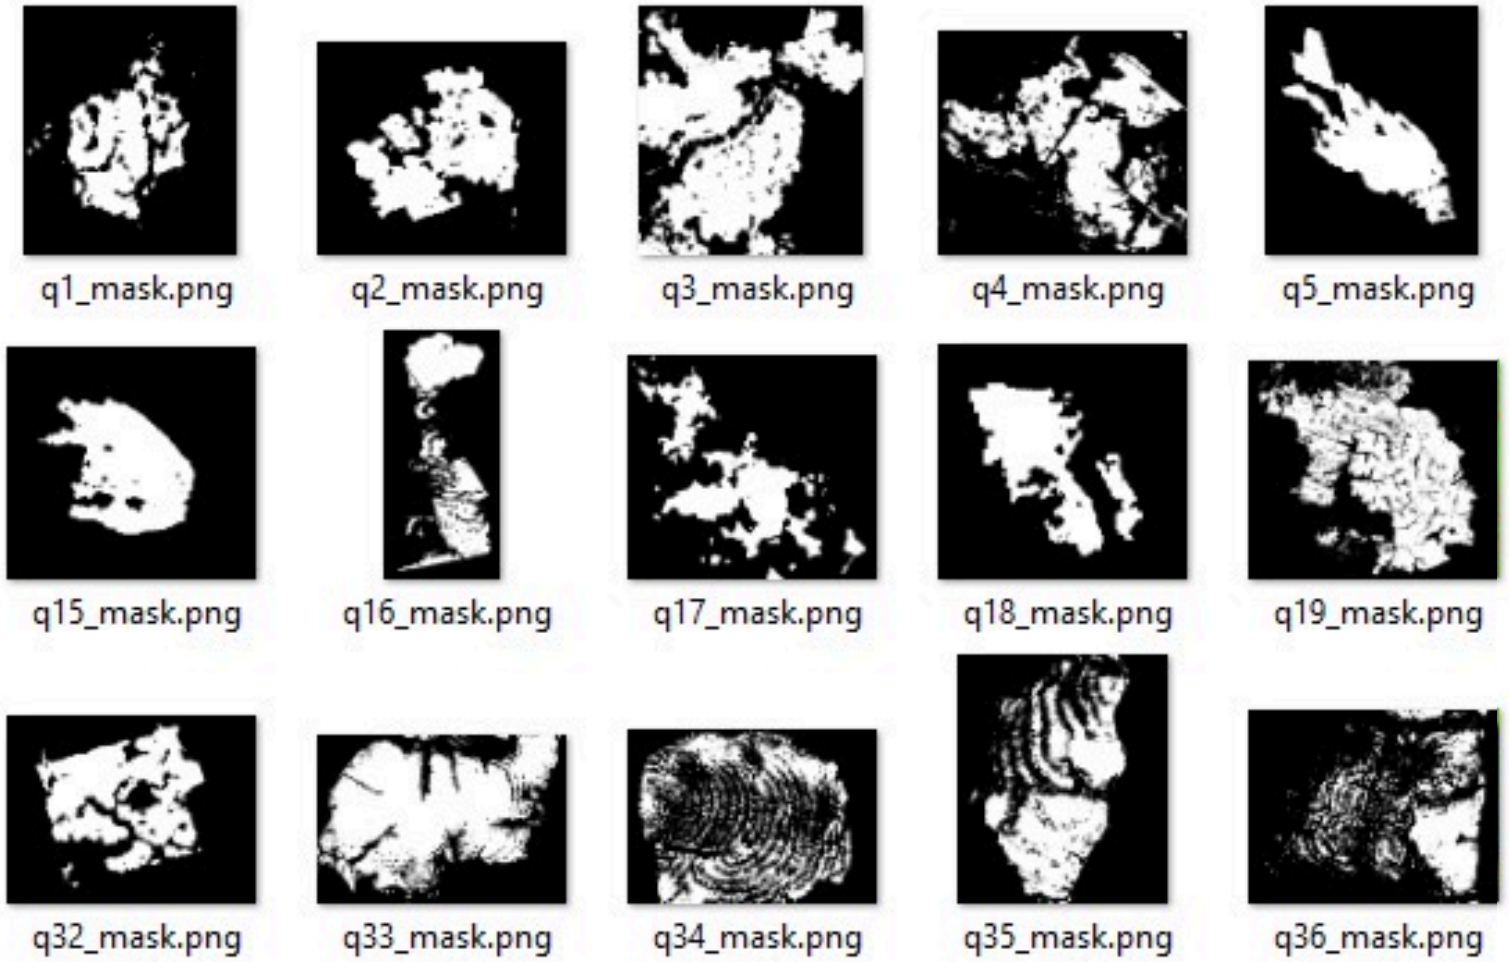
Máscara para treinar a rede a "ver" uma queimada e identificá-la.

Como se estivéssemos treinando os olhos do algoritmo de segmentação.

Evolução do Deter

Mascaramento





Aprendizado profundo com arquitetura U-net

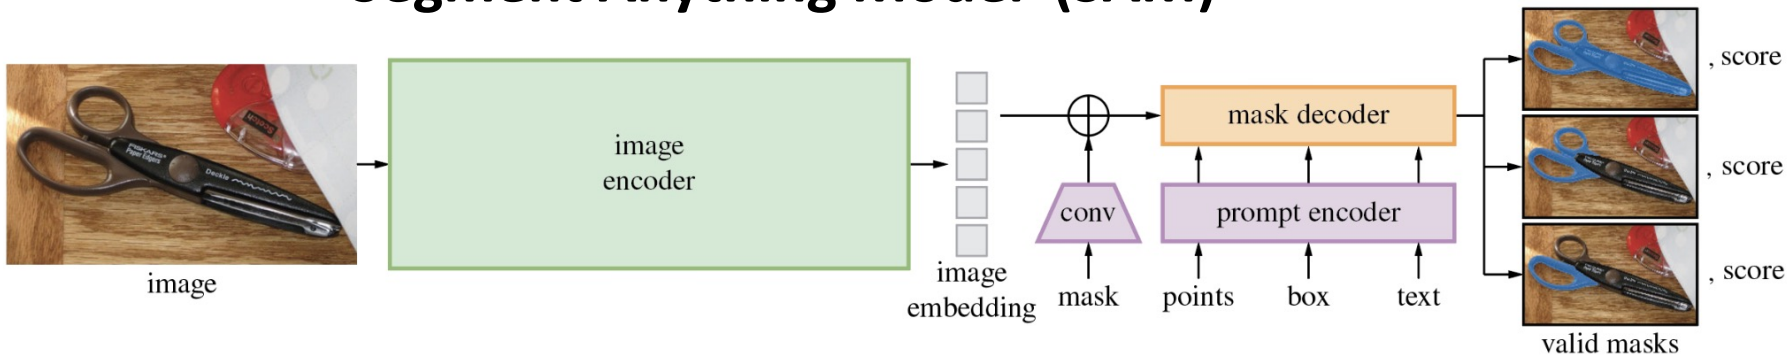
Alertas de supressão/degradação

Evolução do Deter – testes de algoritmos

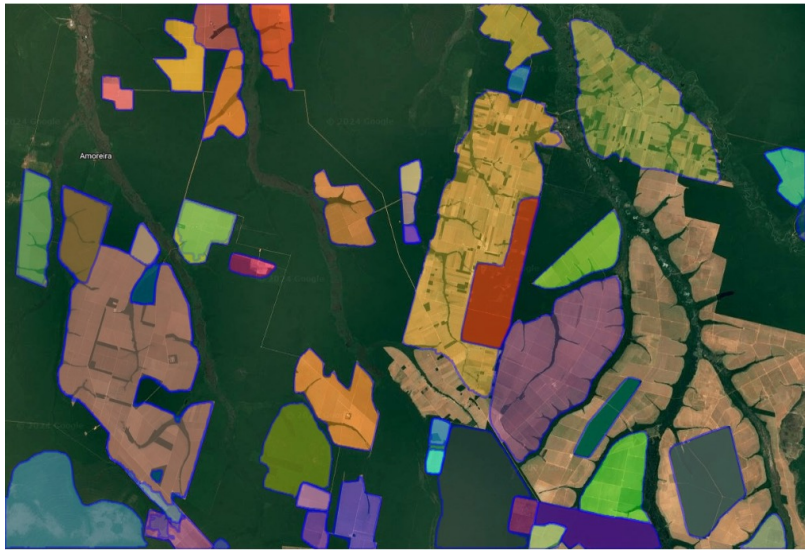


COEAM (2025)

Segment Anything Model (SAM)







YOLO (You Only Look Once)

CNN

Alertas de supressão/degradação

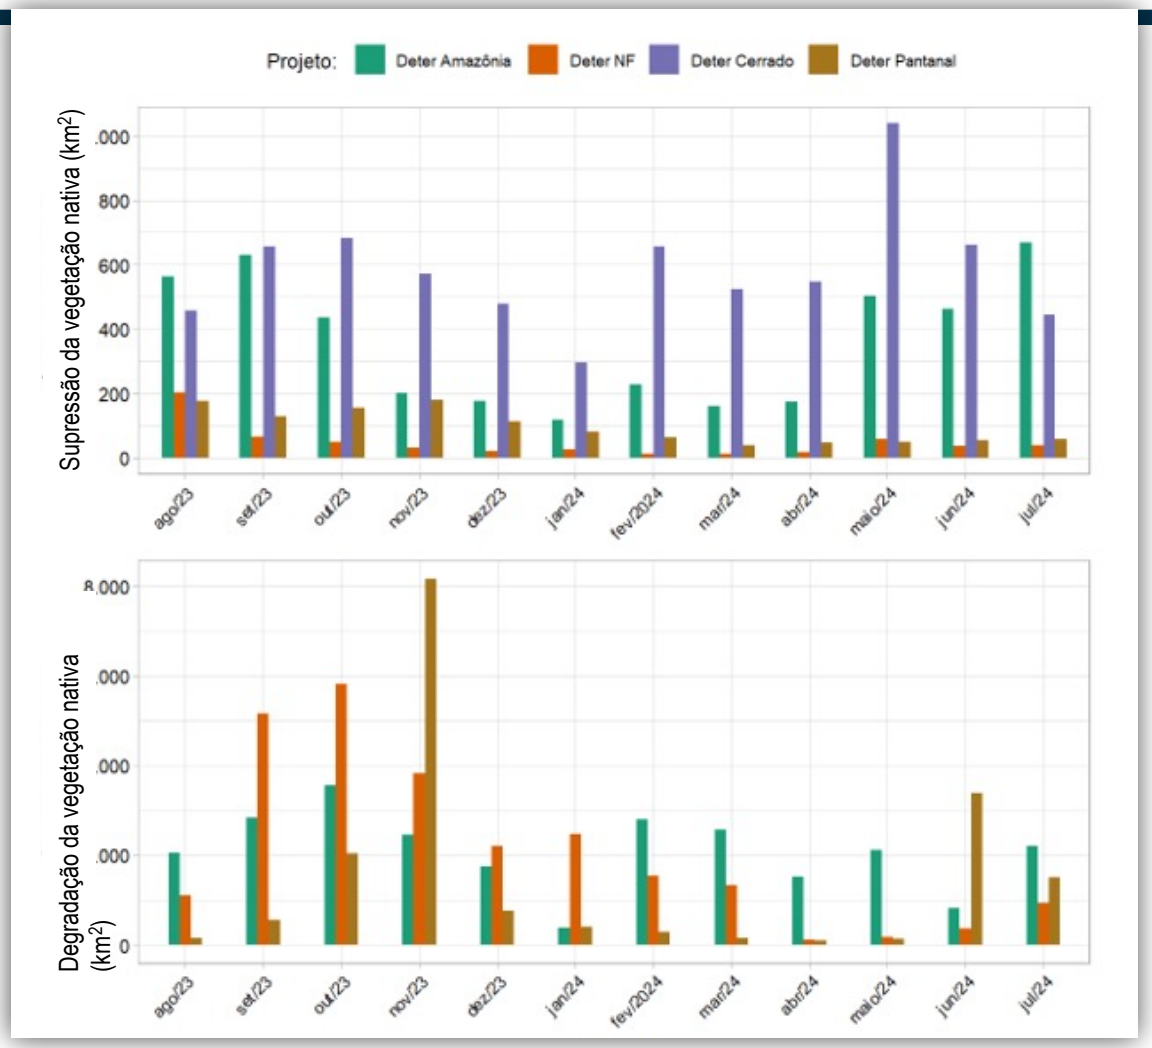
Mapas, polígonos e estatísticas do DETER disponíveis na plataforma TerraBrasilis

Dados valiosos para:

- *planejar e monitorar estratégias*
- *analisar* ***tendências do desmatamento*** *comparando períodos*

Degradação Deter 2025 Amazônia 2025 previsão de desmatamento

**Evolução – sistema integrado:*
Prodes a partir do Deter



Supressão da vegetação nativa e degradação florestal. DETER ago./2023 – jun./2024

https://terrabrasilis.dpi.inpe.br/app/dashboard/alerts/biomes/amazonia-nb/aggregated/

Alertas também para a sociedade

Ministério do Meio Ambiente e Mudança do Clima

O que você procura?

CONTROLE DO DESMATAMENTO

Áreas sob alerta de desmatamento caem 37,5% na Amazônia e 8,2% no Cerrado de agosto de 2025 a maio de 2026

Divulgados pelo presidente Lula, dados do Deter/INPE indicam que Brasil segue no caminho para cumprir a meta de zerar o desmatamento até 2030

Publicado em 11/06/2026 15h56 Compartilhe:



G1

https://g1.globo.com › amazonas › noticia › 2026/06/15

Desmatamento no Amazonas cai 57% nos primeiros meses ...

há 19 horas — O desmatamento no Amazonas caiu 57% entre janeiro e maio de 2026, com redução de 45% nos alertas ambientais monitorados pelo Inpe e órgãos ...





Desmatamento na Amazônia aumenta na temporada 2024/2025 — Foto: Reprodução/TV Globo

Biomas Br

TerraClass

Monitoramento sistêmico do uso e cobertura da terra



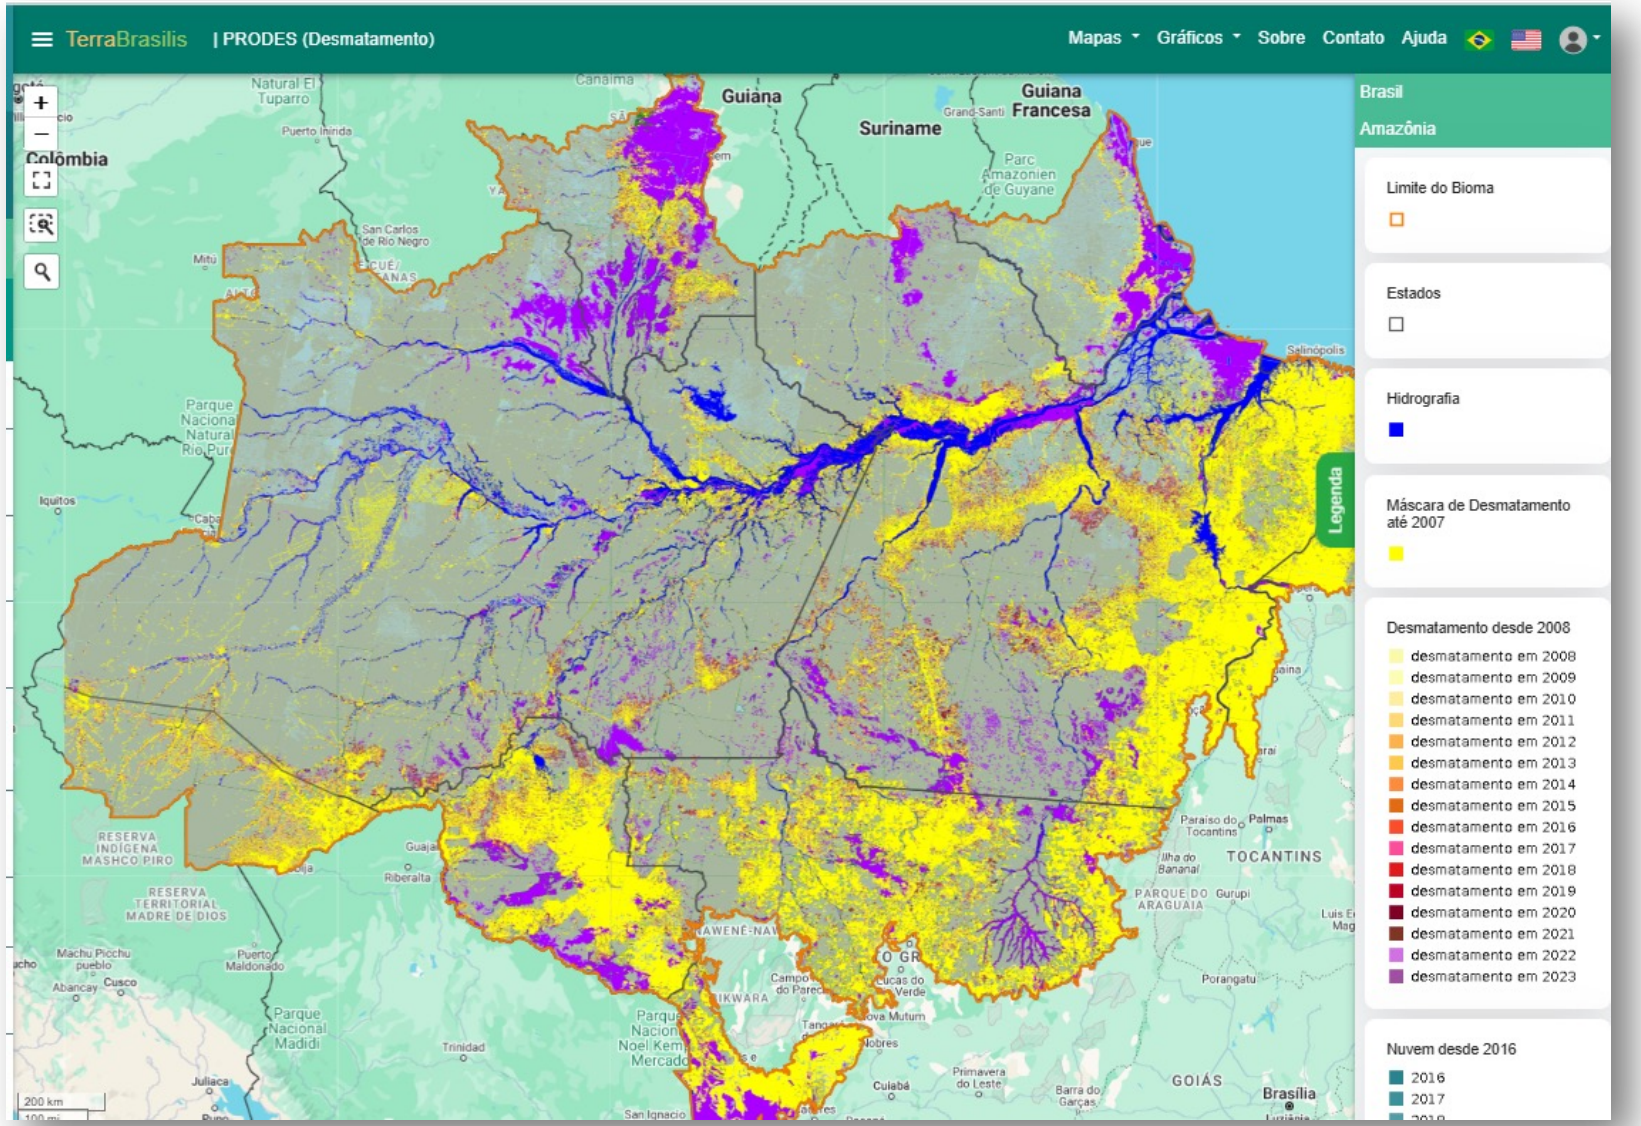
Embrapa

Empresa Brasileira de Pesquisa Agropecuária

INPE

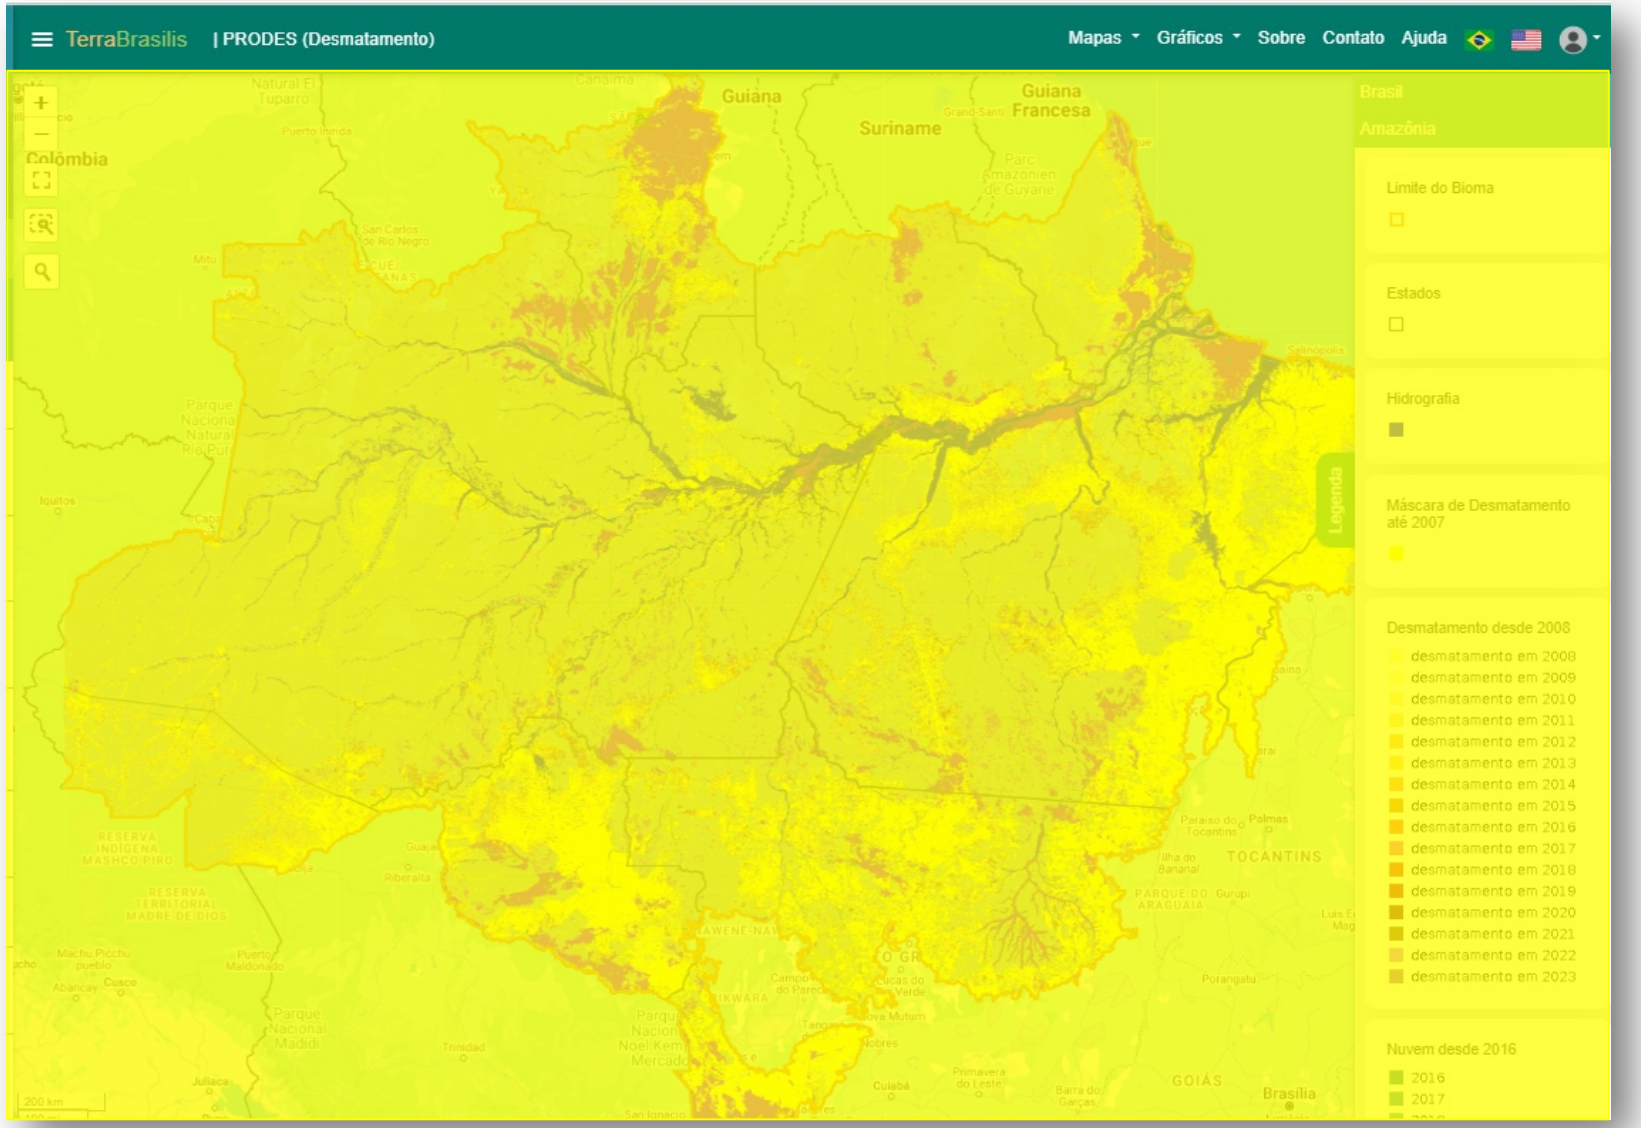
https://data.inpe.br/big/web/biomasbr/terraclass-monitoramento-sistemico-de-uso-e-cobertura-da-terra/

O que substituiu a vegetação nativa?



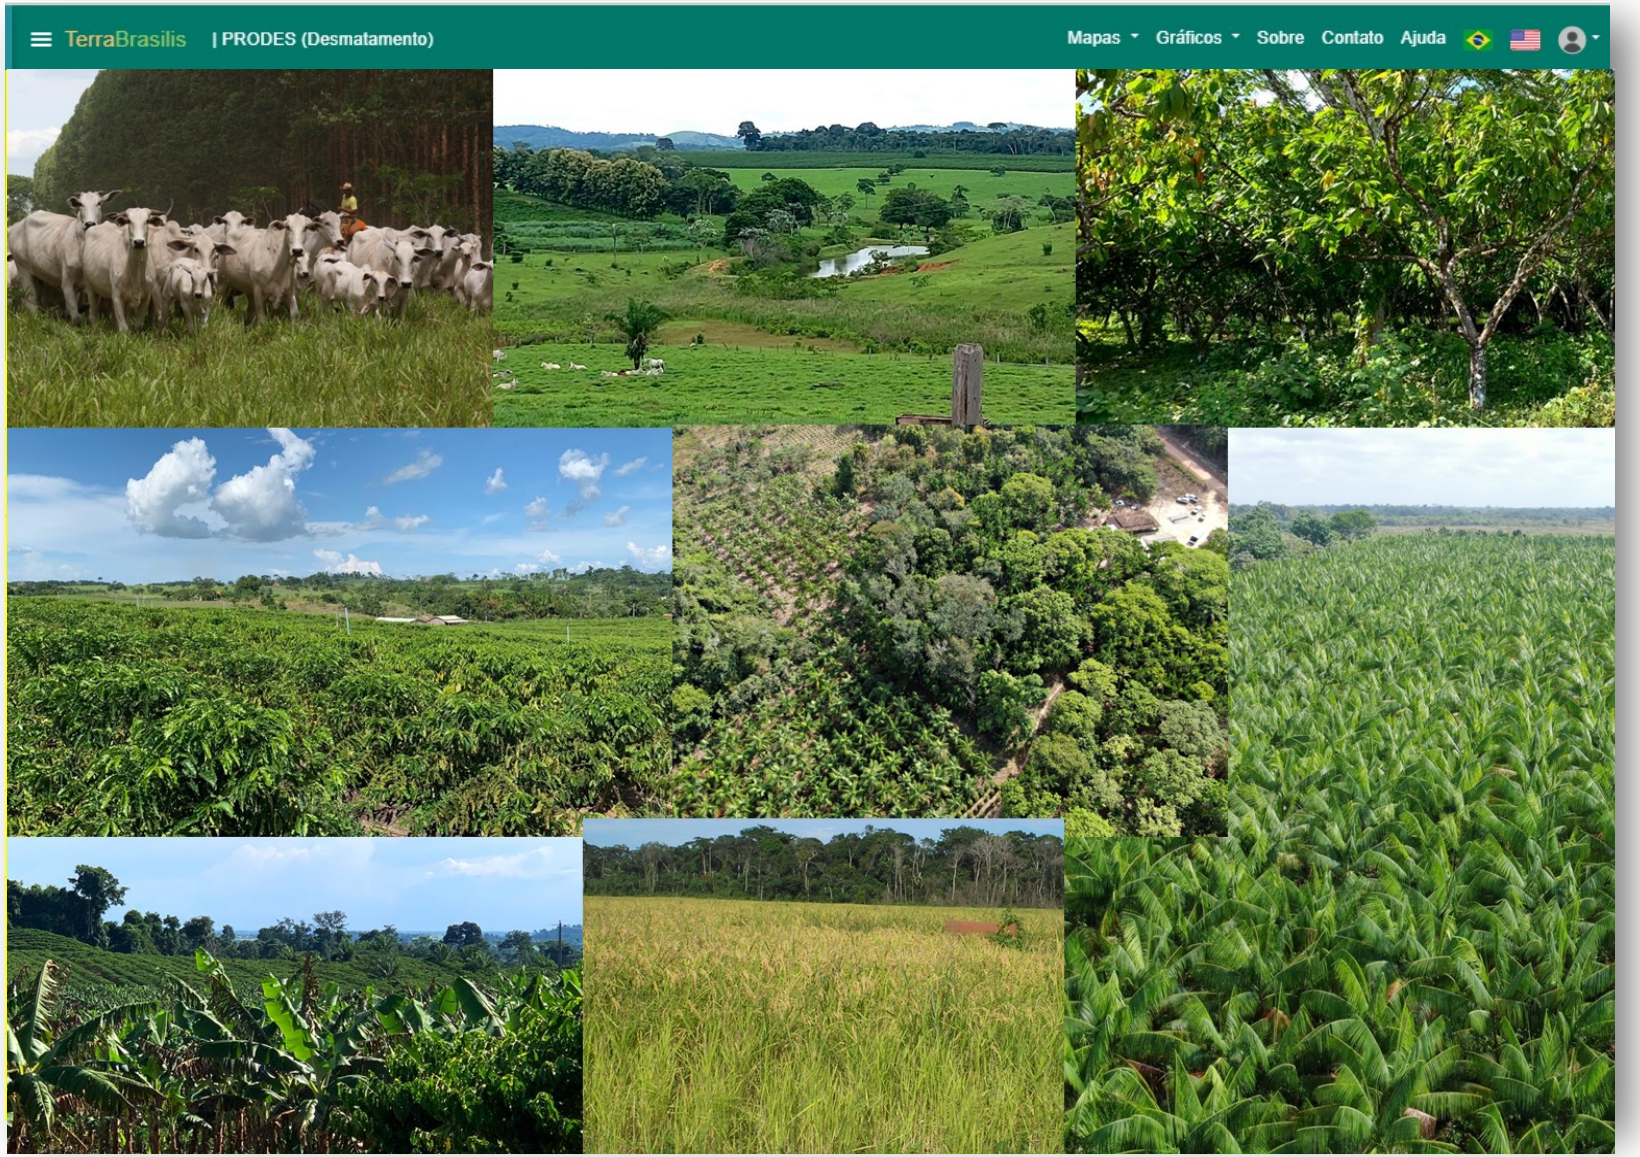
Do desmatamento (Prodes)

O que substituiu a vegetação nativa?



Do desmatamento (Prodes)

O que substituiu a vegetação nativa?



Do desmatamento (Prodes)

ao

uso e cobertura da terra TerraClass

Ventirueri (2025)

PROJETO TERRACLASS

Parceria entre o INPE e a EMBRAPA (desde 2011)



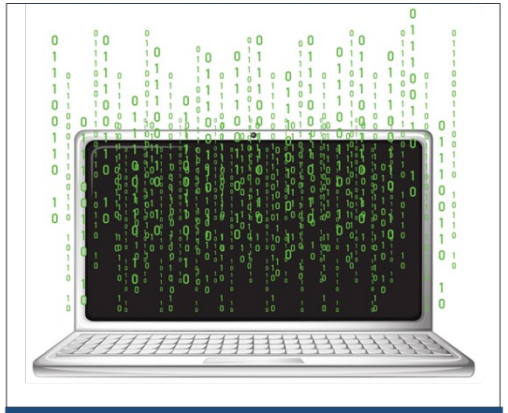
METODOLOGIA



Sentinel-2 10 m Images

BRAZIL DATA CUBE

Brazil Data Cube



Machine Learning Algorithms

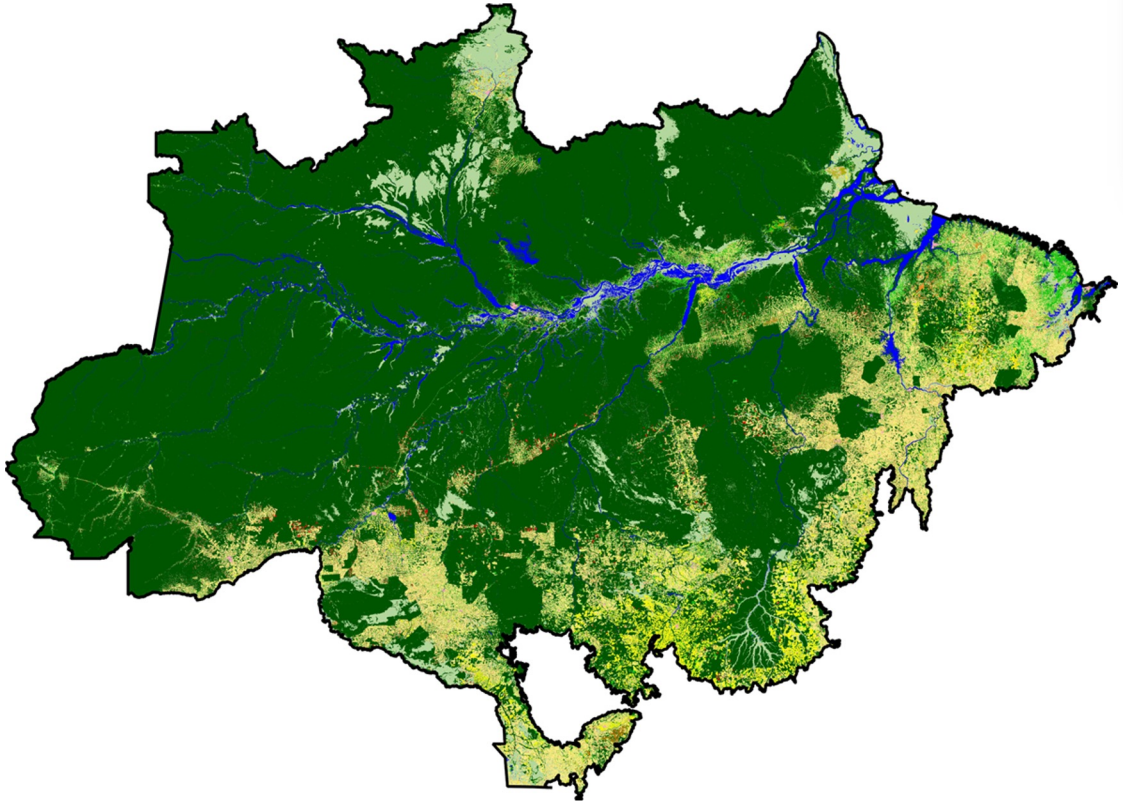
sits

SITS computing package

Coutinho (2023)

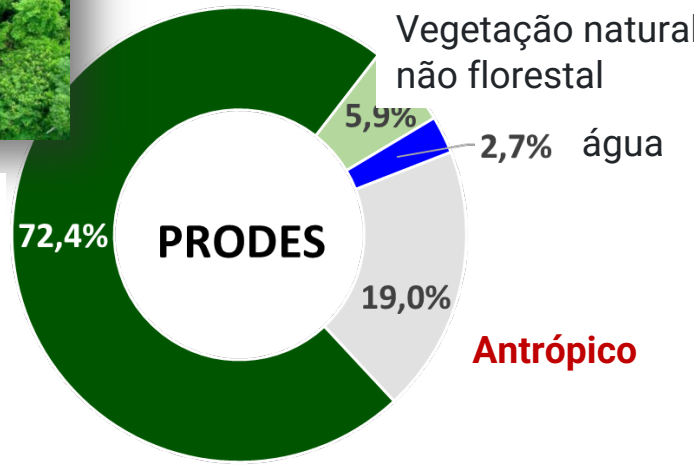
RESULTADOS

TerraClass 2022





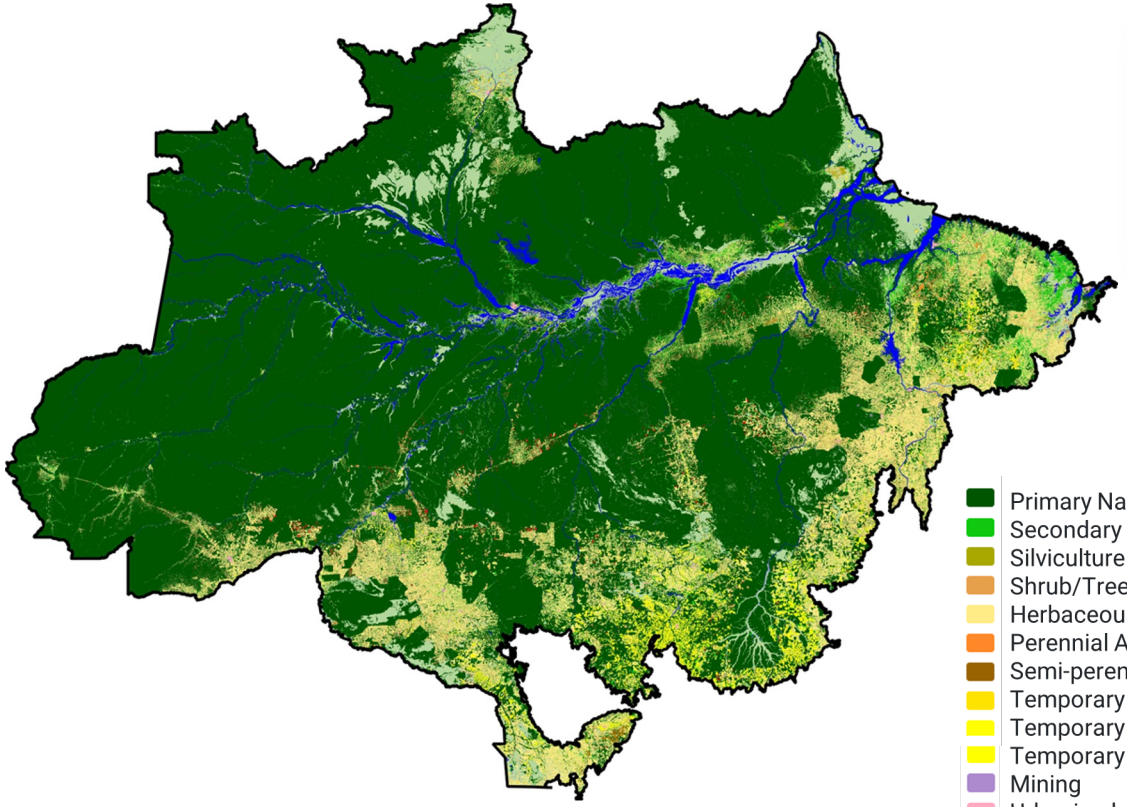
Vegetação natural florestal primária



PRODES (2022)

RESULTADOS

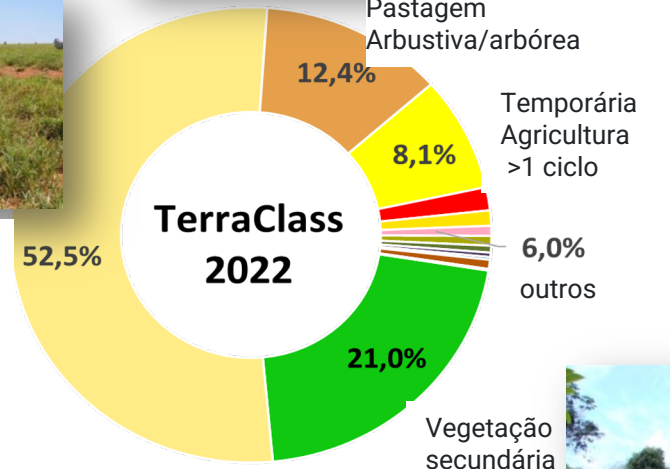
TerraClass 2022











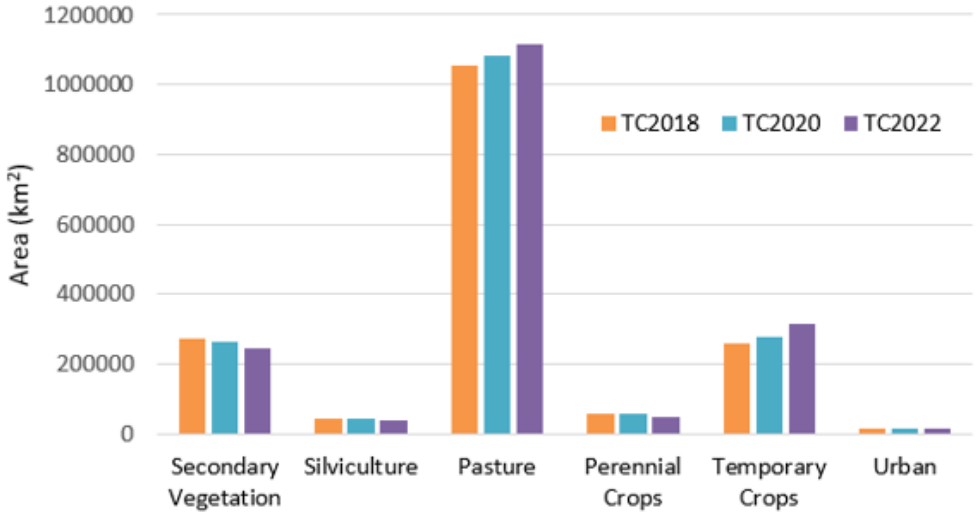
TerraClass (2022)



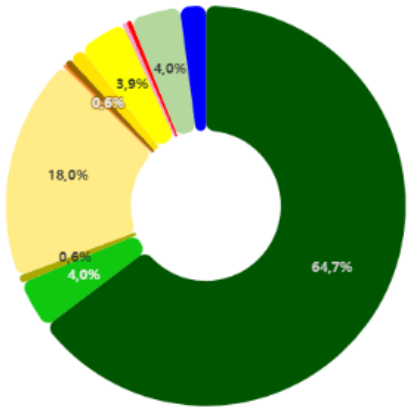
TRAJETÓRIAS DE USO DA TERRA

Amazônia (2008 – 2022) e Cerrado – 2018, 2020 e 2022 (unificado)

Mapeamento bienal



2018
2020
2022





Amaral et al. 2025



https://www.terraclass.gov.br/webgis/

TerraClass

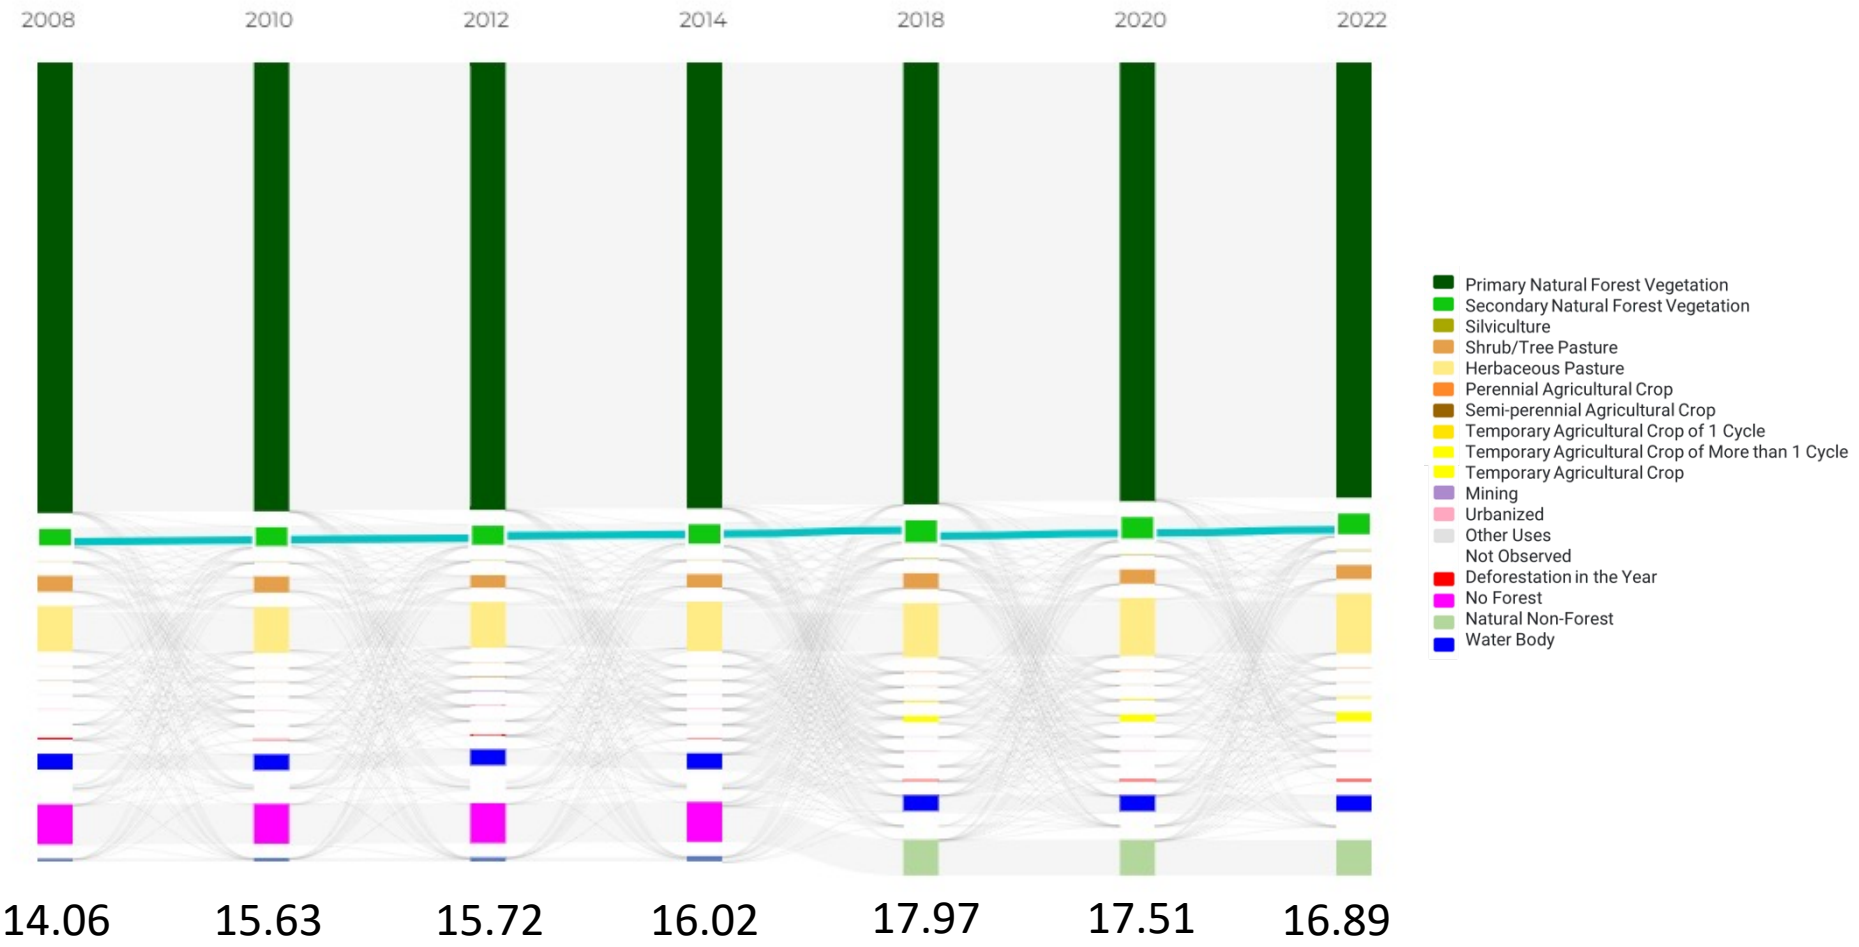
Vegetação secundária (VS) na Amazônia

Persistência

6.735.018,71 ha
2012 – 2022
(10 anos)

6.027.202,24 ha
2010 – 2022
(12 anos)

5.304.131,67 ha
2008 – 2022
(14 anos)



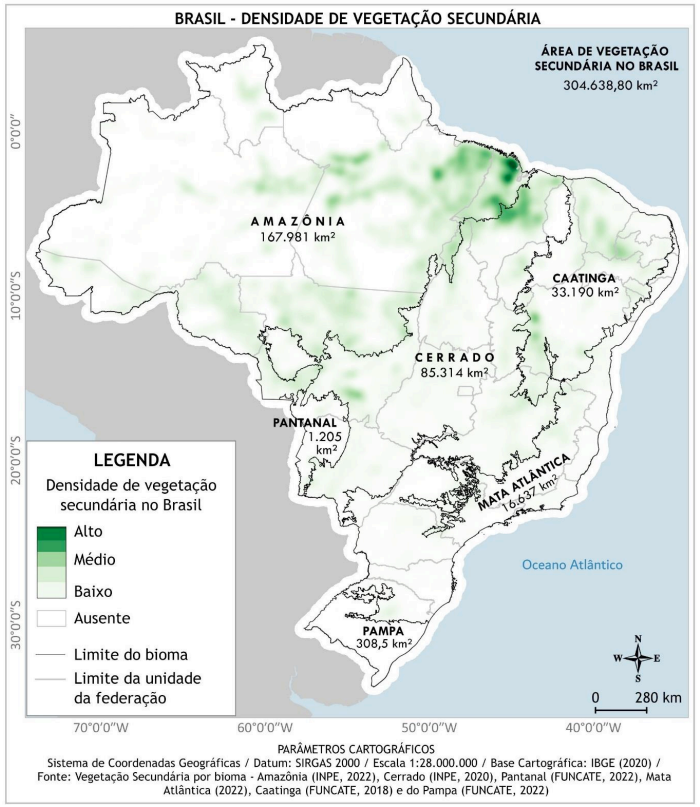
Mil ha	14.06	15.63	15.72	16.02	17.97	17.51	16.89

TerraClass - Paisagem

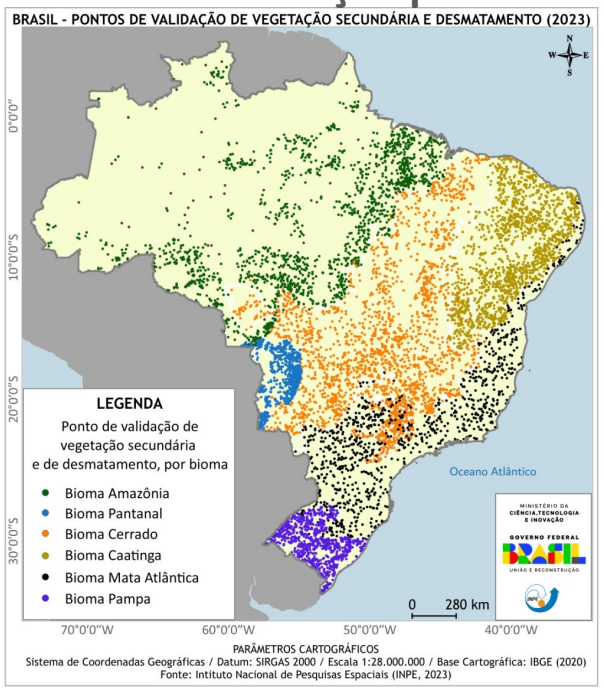
Mapeamento da vegetação secundária (VS)

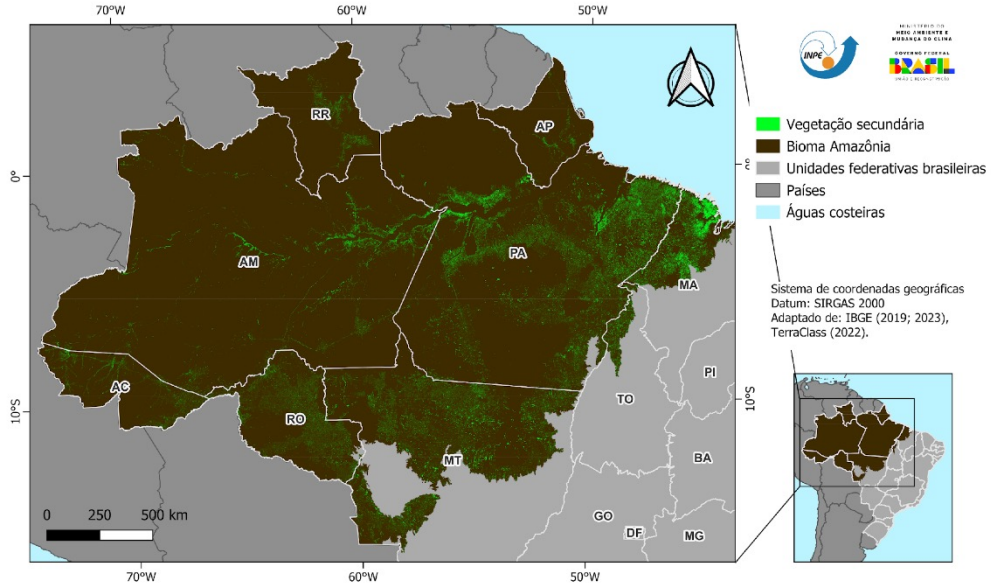
Áreas de vegetação secundária para todos os biomas brasileiros
2018, 2020 e 2022

A serem integradas e disponibilizadas no TerraBrasilis em 2025



VS 2022 - Validação por bioma





Vegetação secundária do bioma Amazônia

TerraClass - Paisagem

Análise da paisagem da vegetação secundária (VS) – BRASIL

Categoria fundiária	Área (%)
Territórios quilombolas	0.85
UC de proteção integral	1.28
Florestas públicas não destinadas	1.82
UC de uso sustentável (sem APA)	3.11
Terras indígenas	5.03
Área de proteção ambiental (APA)	6.18
Assentamento rural	**15.46**
Imóveis privados (SIGEF)	**22.34**
Área sem registro fundiário	**43.92**

Área total (VS) = 16.247.366,72 ha (689.288 fragmentos)

MÉTRICA	Análise		
	Área	Polígonos	OBS
Idade ponderada (anos)	(34.38%) 7–9 (07.66%) 1–3	(34.69%) 4 - 6 (09.36%) 13 - 14	jovem (4 – 9 anos)
Área (ha)	(32.51%) 100 –|1,000 (19.28%) > 1,000	(42.25%) 2 –| 5 (39.40%) 5 –| 20	Muitos pequenos, alguns grandes relevantes
Área núcleo	(41.40%) 10 –| 1,000	(87,04%) zero	relevante efeito de borda
Dimensão fractal	(99,33%) 1.25–1.5	(93.76%) 1.25–1.5	forma geométrica - antrópica
Distância euclidiana ao vizinho mais próximo	84,30% - 0 m	69,80% - 0 m	adjacente à vegetação
Vegetação vizinha mais próxima	85,47% - vegetação primária	73,85% - vegetação primária	vegetação primária

TerraClass e PLANAVEG

Comissão de Recuperação da Vegetação Nativa (Conaveg)

A Comissão de Recuperação da Vegetação Nativa
meta comum de restaurar 12 milhões de hectares de vegetação nativa no nosso país.
Esse novo pacto e marco estão agora refletidos no Planaveg 2025-2028.

Planaveg

Plano Nacional de Recuperação da Vegetação Nativa
Plano Nacional de Recuperação da Vegetação Nativa
(Art. 5º do Decreto nº 8.972, de 23 de janeiro de 2017,
Portaria Interministerial nº 230, de 14 de novembro de 2017)

"Os dados de vegetação secundária (VS) gerados pelo projeto TerraClass serão consolidados como camada estrutural de inteligência espacial e de monitoramento da recuperação da vegetação nativa no Brasil, figurando entre as principais camadas da plataforma nacional de monitoramento".

OBJETIVO
Restauração da vegetação nativa em áreas degradadas de unidades de conservação (UC), terras indígenas (TI) e outros territórios coletivos.



Planaveg

146

USUÁRIOS DOS DADOS DO PRODES

Biomas Br

Políticas públicas

National Adaptation Plan to Climate Change

General Strategy

VOLUME I

Reducing Emissions from Deforestation and forest Degradation

conservation of forest carbon stocks

+ sustainable management of forests

enhancement of forest carbon stocks

United Nations Framework Convention on Climate Change



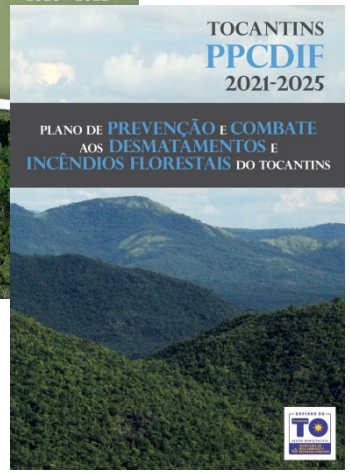
Plano de controle do desmatamento na Amazônia entra em consulta pública

Governo federal abre espaço para sugestões para o PPCDAm, que chega a sua quinta versão

João Gabriel

BRASÍLIA O governo federal abriu, na noite desta segunda-feira (10), a consulta pública para o Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal, o PPCDAm, diretriz que norteia as ações de proteção da floresta no bioma amazônico.





Ciência e estudos acadêmic

PRODES

07/17/2026:

1.787 artigos em

576 periódicos

CLIMATE POLICY INITIATIVE
NÚCLEO DE AVALIAÇÃO DE POLÍTICAS CLIMÁTICAS PUC-Rio

DETERring Deforestation in the Brazilian Amazon: Environmental Monitoring and Law Enforcement

Climate Policy Initiative



Controle do comércio



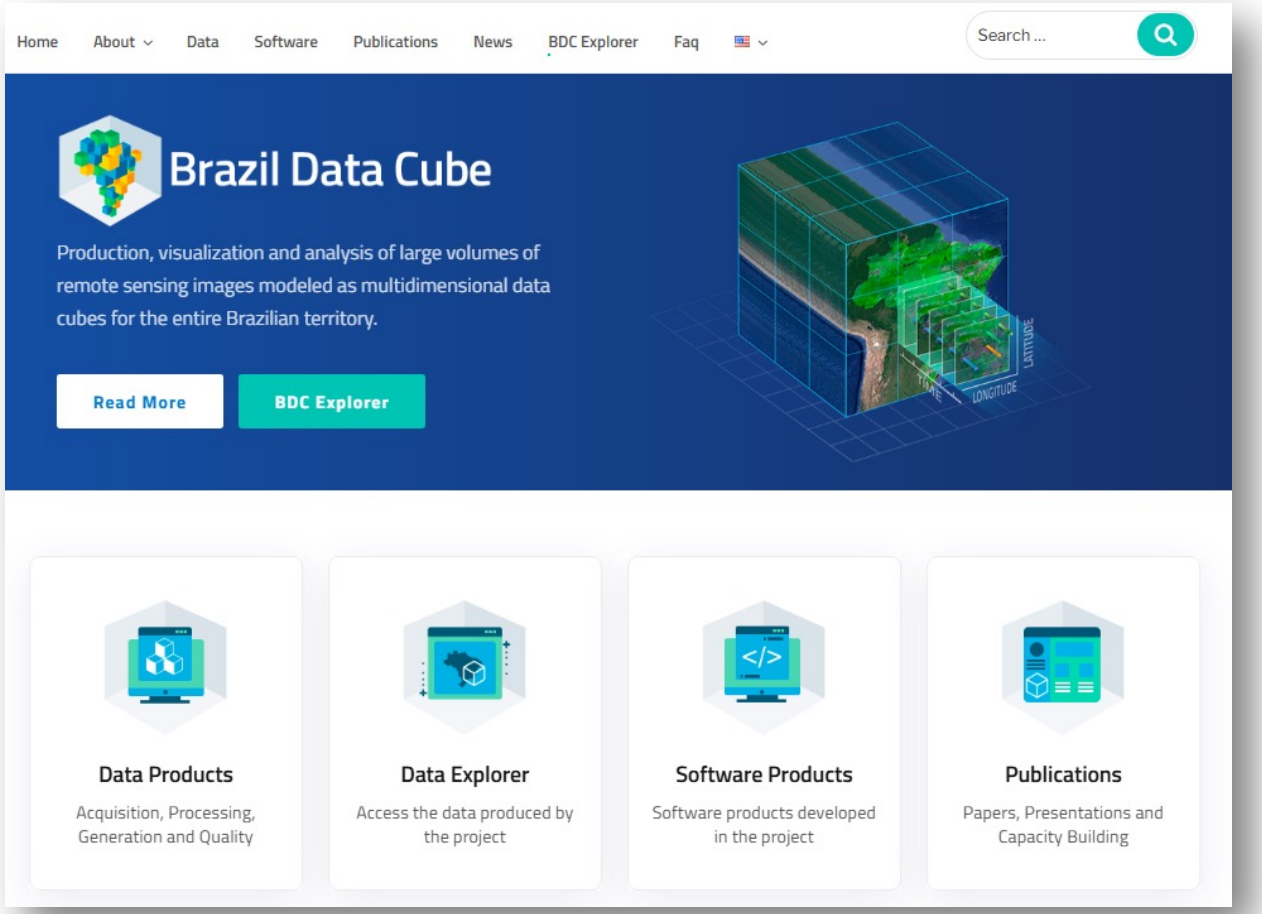


https://data.inpe.br/biomasbr/citacoes/

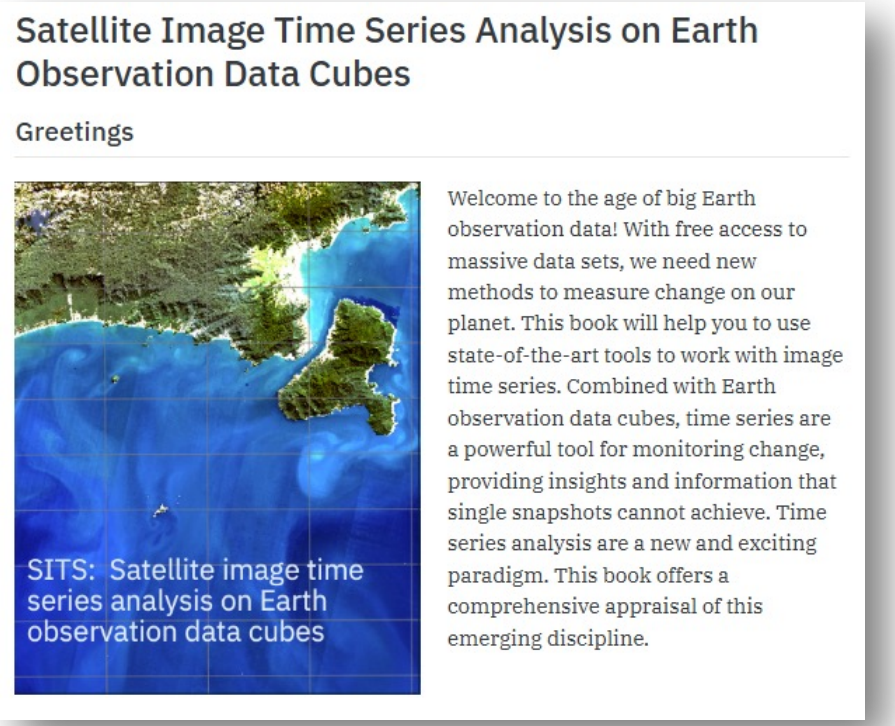
BDC - SITS

Novas tecnologias do INPE para o Prodes - acesso aberto - análise com IA para sensoriamento remoto

-



https://data.inpe.br/bdc/



https://e-sensing.github.io/sitsbook/

BiomasBR

https://data.inpe.br/big/web/biomasbr/

Um programa estratégico do INPE

Construção / histórico
Equipes – pesquisa científica
Colaborações e parcerias

Acesso aberto
Cobertura completa
Acurácia consistente dos dados
Séries históricas
Melhoria contínua

Métodos de IA – classificação de imagens
Contribuição para a mudança climática

Dados abertos e
ferramentas de IA para a sociedade



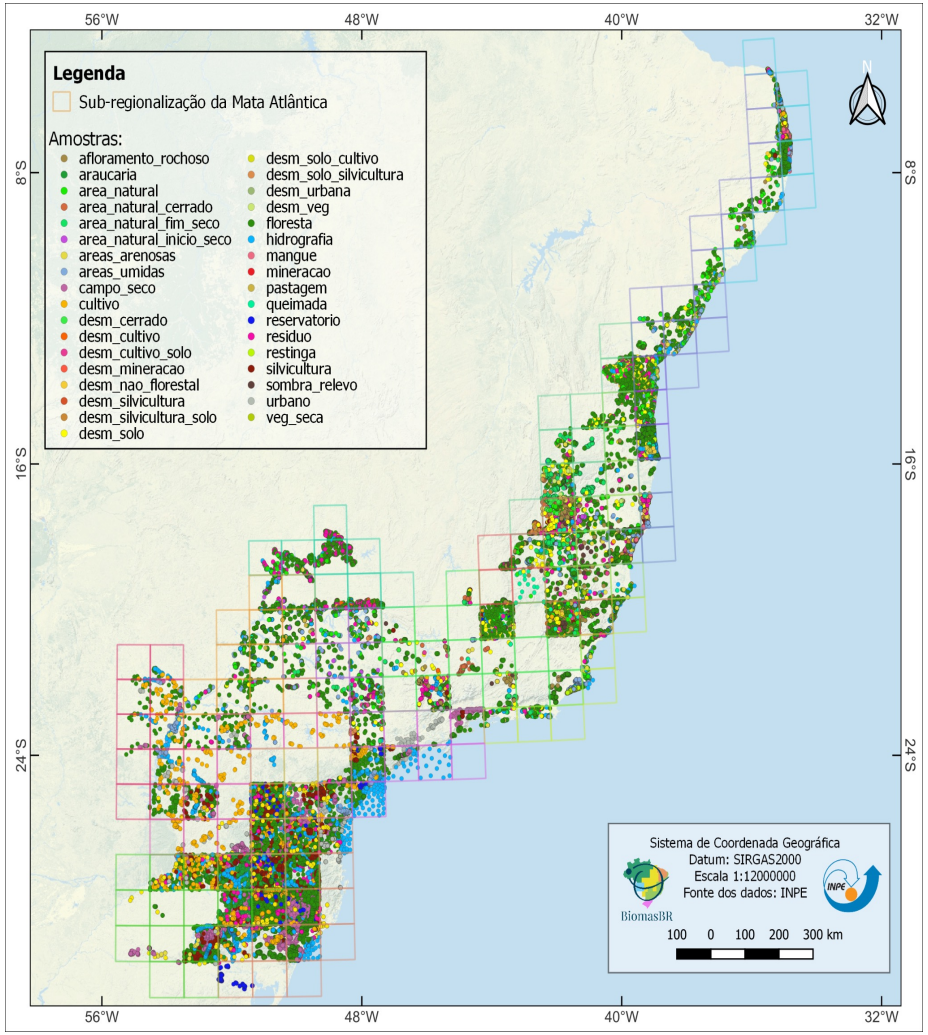


IA para florestas – grandes desafios

Poucos conjuntos de dados rotulados

Dados de referência de qualidade são caros e demorados de produzir.

Isso limita o aprendizado supervisionado e a acurácia dos modelos.





IA para florestas – grandes desafios

Generalização entre ecossistemas

Modelos treinados em um bioma ou país muitas vezes têm desempenho ruim em outros lugares

Isso reduz a transferibilidade para novos ecossistemas e climas.





IA para florestas – grandes desafios

Variabilidade temporal
Cobertura de nuvens

Sazonalidade, fenologia, distúrbios
Degradação x desmatamento

Floresta tropical – cobertura de nuvens

A IA não detecta exploração seletiva, danos do fogo e degradação do sub-bosque

Séries temporais incompletas





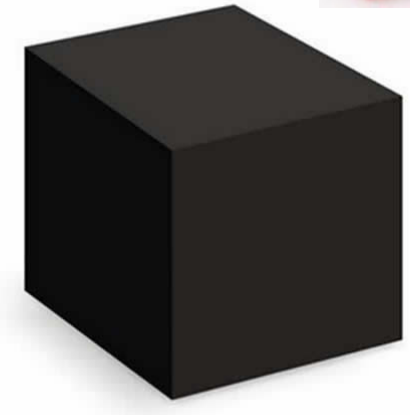
IA para florestas – grandes desafios

Explicabilidade e estimativa de incerteza



Os modelos de aprendizado profundo muitas vezes são “caixas-pretas”.

É difícil para órgãos e gestores confiar nos produtos operacionais.





IA para florestas – grandes desafios

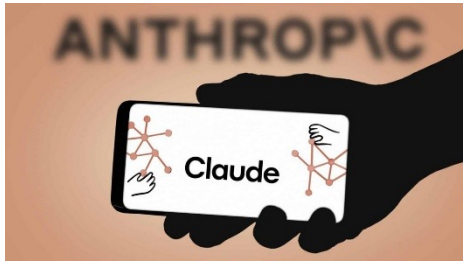
Grande exigência computacional

O aprendizado profundo moderno e os modelos de base exigem GPUs, muito armazenamento e computação de alto desempenho.

Hoje, o acesso é restrito a algumas organizações



Supercomputador JACI do INPE



Google DeepMind

OpenAI



IA para florestas – grandes desafios

- Integração a **sistemas de monitoramento operacionais**
- Consistência de longo prazo para relatórios ambientais
- Escala - modelos de base para o monitoramento florestal global

Questões éticas e de governança



IA para florestas

Monitoramento florestal para carbono e mudança climática

Sensoriamento remoto e IA – evolução e desafios

Discussão – uso de dados florestais outra palestra
Pesquisa e desenvolvimento – contamos com vocês!

In this world
It´s just us
You know it´s not the same
As it was

menti.com

3825 2546

Do you believe Foundation Models will replace traditional machine learning methods in forest monitoring within the next 10 years?

YES	NO	Partially	Not Sure
0	0	0	0

What is the biggest challenge for applying AI to forest monitoring worldwilde?

What topics should be included in the next version of this presentation?

Obrigada!

Silvana Amaral

+55 12 996255480

silvana.amaral@inpe.br

https://data.inpe.br/biomasbr/



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO