Climate Change AI

Climate Change AI Virtual Summer School 2026





Climate Change AI

INPE

MINISTRY OF
SCIENCE, TECHNOLOGY
AND INNOVATION

IA para los bosques

Aportes de la IA al monitoreo de la vegetación

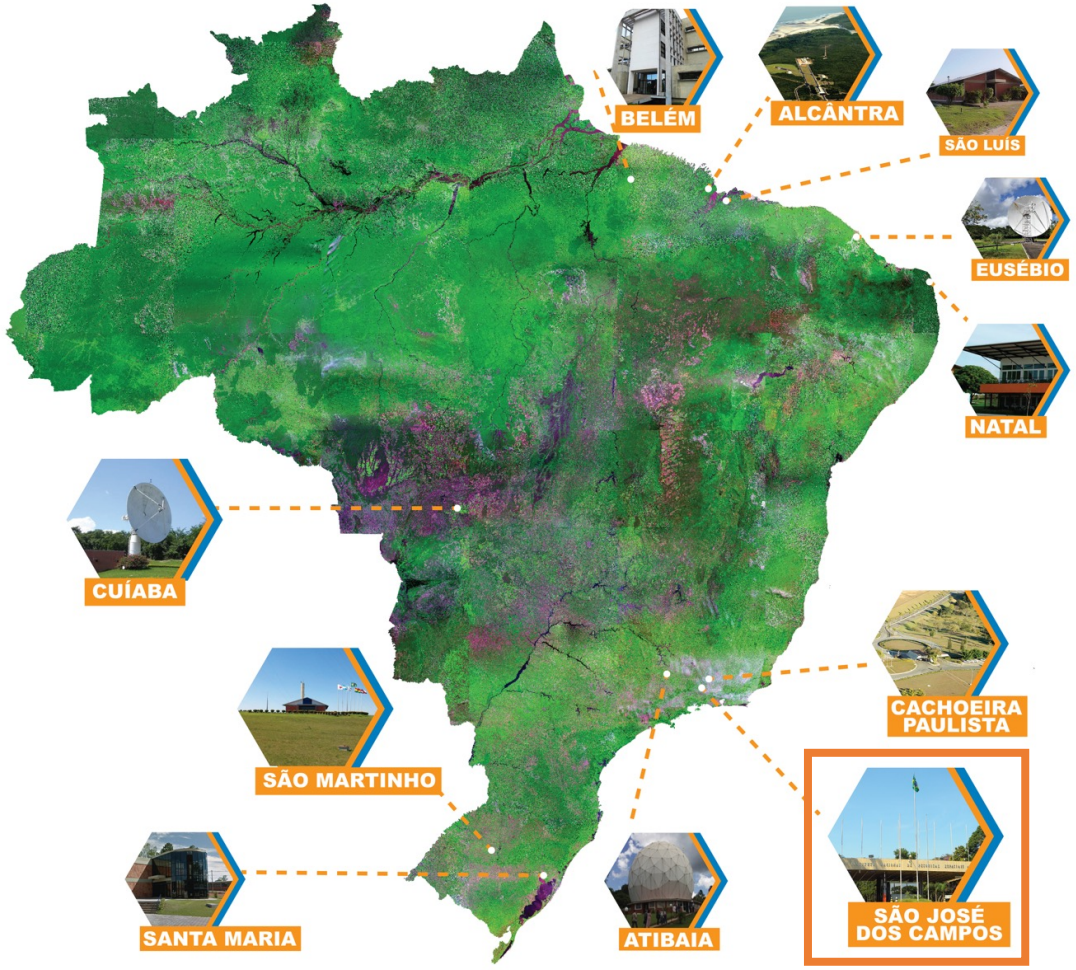
Silvana Amaral

Coordinadora adjunta de la División de Proyectos Estratégicos 1 – DIPE 1
División de Observación de la Tierra y Geoinformática – DIOTG
Instituto Nacional de Investigaciones Espaciales – INPE

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



De dónde vengo...



627 funcionarios, ~360 estudiantes, ~460 contratados

Ciencias espaciales y atmosféricas



Tiempo y clima



Tecnología espacial



Ciencias del sistema Tierra



Seguimiento y control de satélites



Observación de la Tierra



Laboratorios asociados



Laboratorio de integración y pruebas



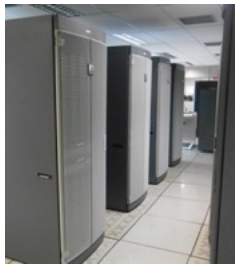
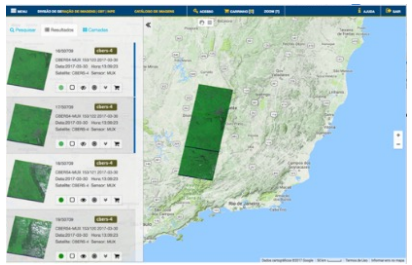
Diapositiva: Kampel (2025)

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO

Lo que hacemos






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



SBSR
XXI Simpósio Brasileiro de Sensoriamento Remoto

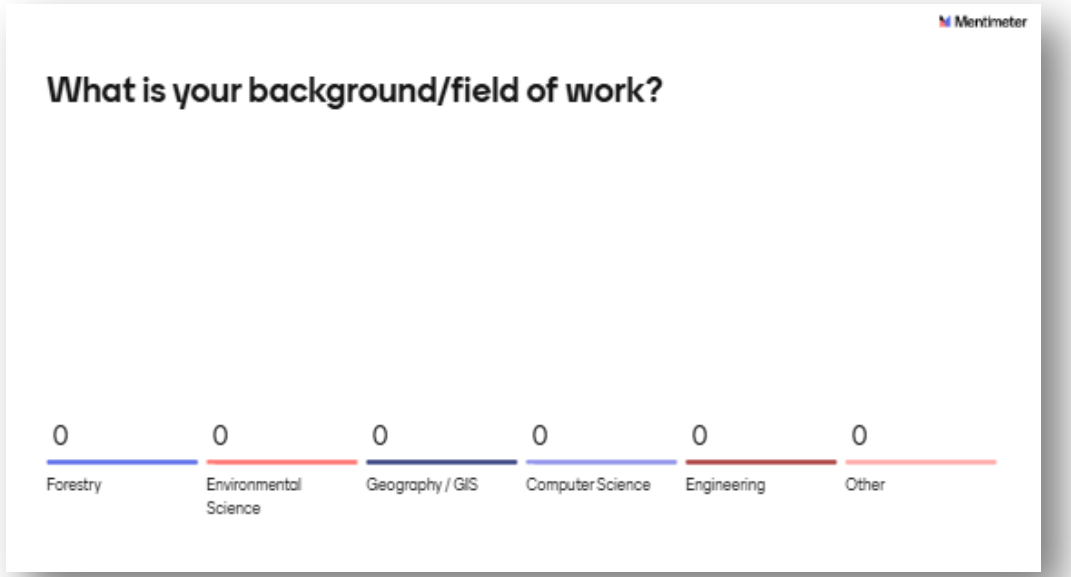
GEOINFO
May 19 to 21, 2025
INPE, São José dos Campos, SP, Brazil

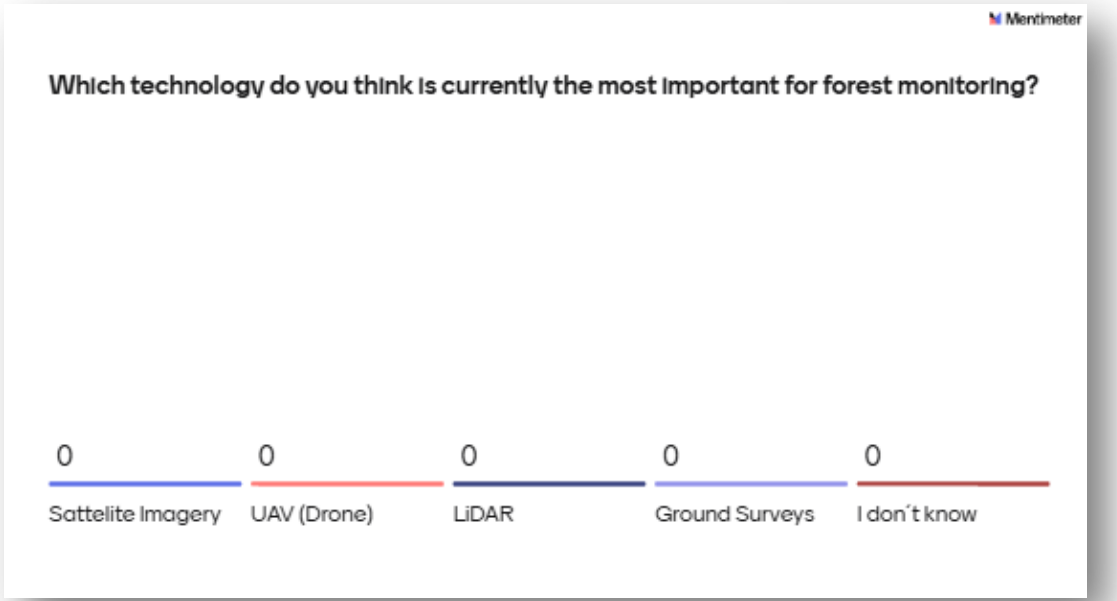
8º Simpósio de Geotecnologias no Pantanal
8º GeoPantanal

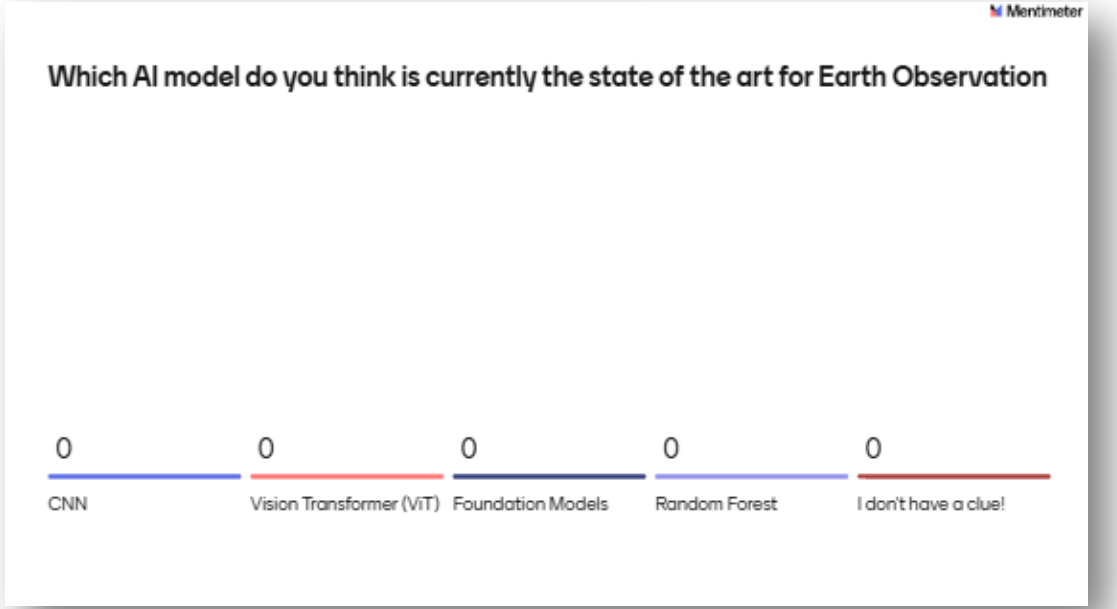
MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO

Diapositiva: Kampel (2025)

menti.com
5859 8794









¿Por qué es importante monitorear los bosques?

¿Cómo se ha usado la IA en aplicaciones forestales?

Evolución de la IA para el monitoreo forestal

Los fundamentos (conceptos) de los modelos de IA más usados

Ejemplos: clasificación de especies arbóreas, evaluación de incendios forestales, estimación de biomasa y carbono

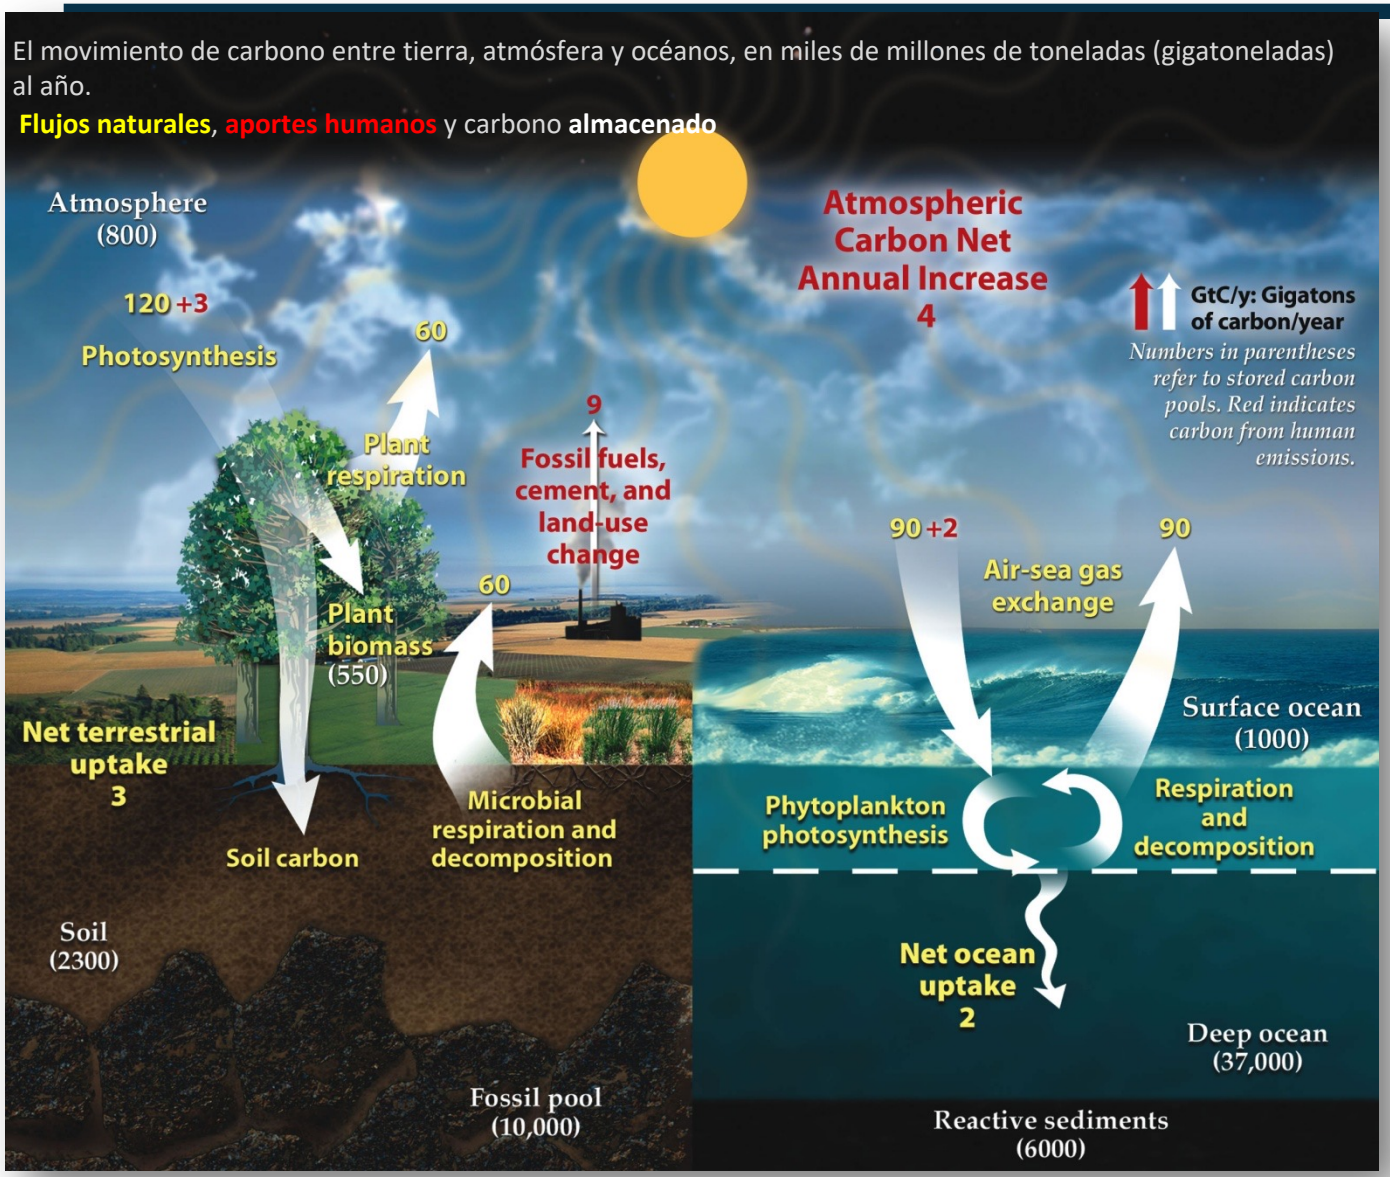
La evolución del uso de la IA para el monitoreo de la vegetación en los biomas brasileños

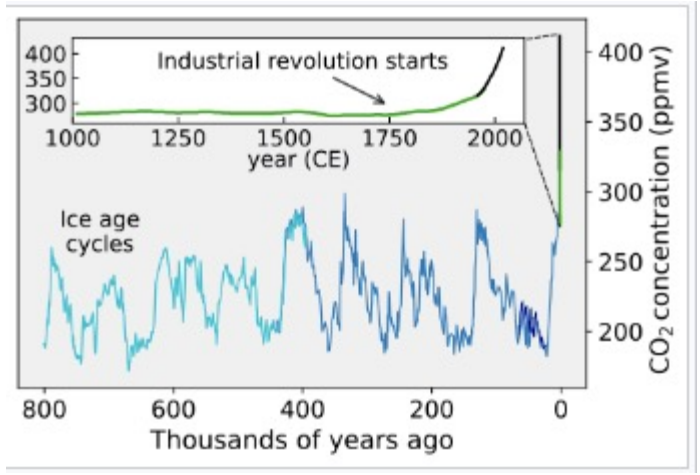
«El ciclo del carbono»

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

El movimiento de carbono entre tierra, atmósfera y océanos, en miles de millones de toneladas (gigatoneladas) al año.

Flujos naturales, **aportes humanos** y carbono **almacenado**

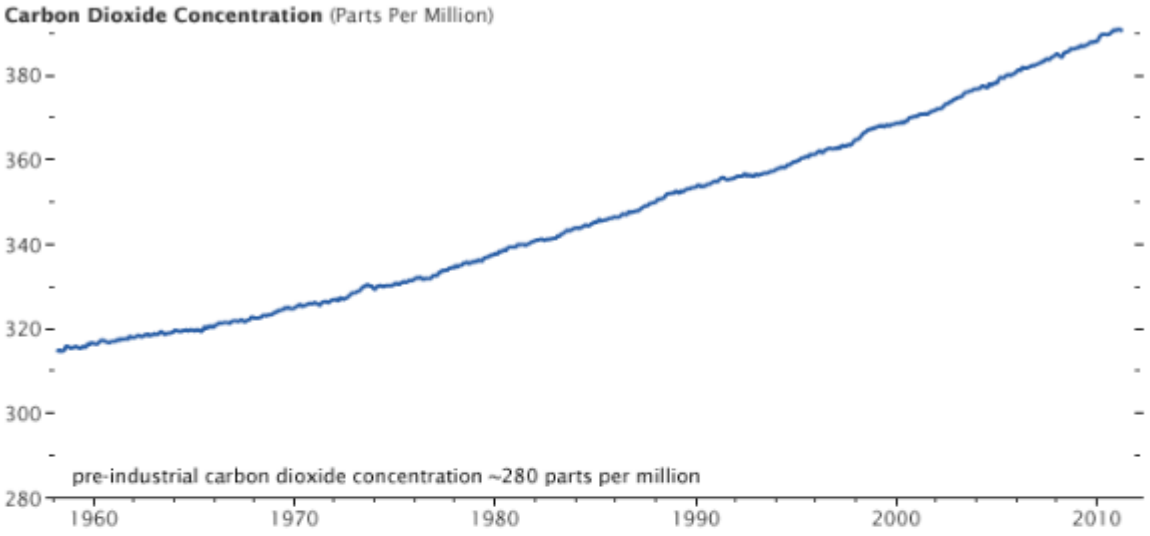


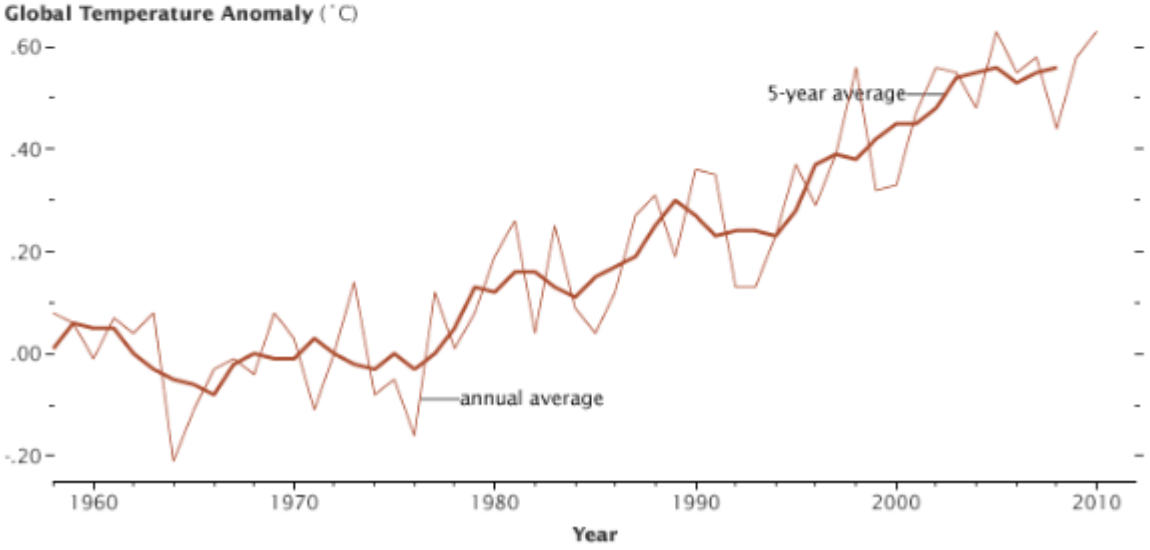


Concentraciones de CO_2 en los últimos 800 000 años, medidas en testigos de hielo (azul/verde) y directamente (negro)

«El ciclo del carbono»

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



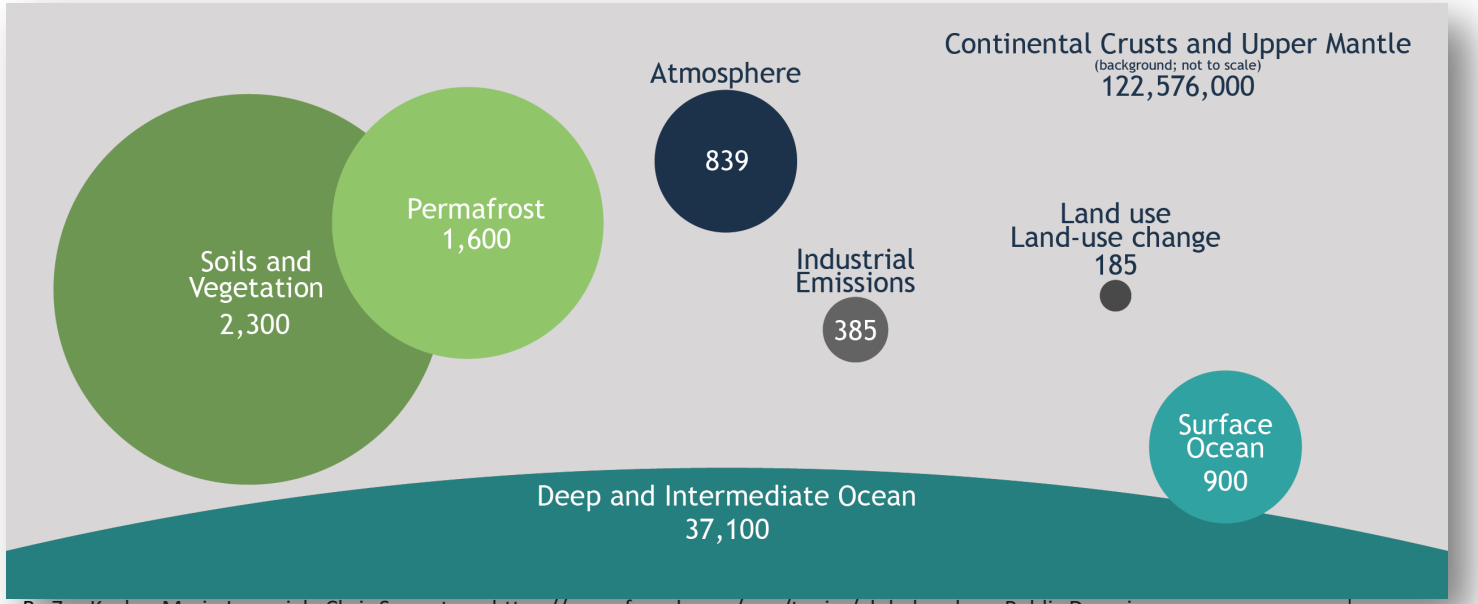


El dióxido de carbono es el gas que fija la temperatura.

El dióxido de carbono controla la cantidad de vapor de agua en la atmósfera y, por tanto, la magnitud del efecto invernadero.

¡Estamos hechos de carbono (y lo necesitamos)!
Pero…
esta necesidad también está estrechamente ligada a uno de los problemas más graves que afrontamos hoy:
el cambio climático global.

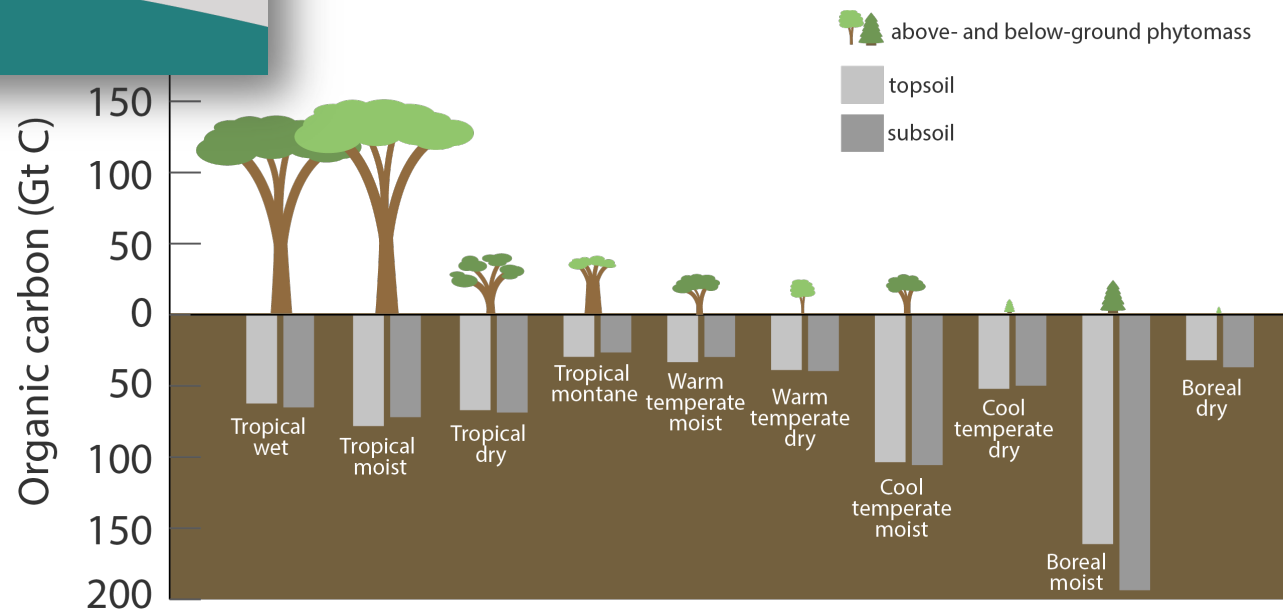
Las reservas de carbono



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

Tamaños relativos (en gigatoneladas) de los principales reservorios de carbono de la Tierra.

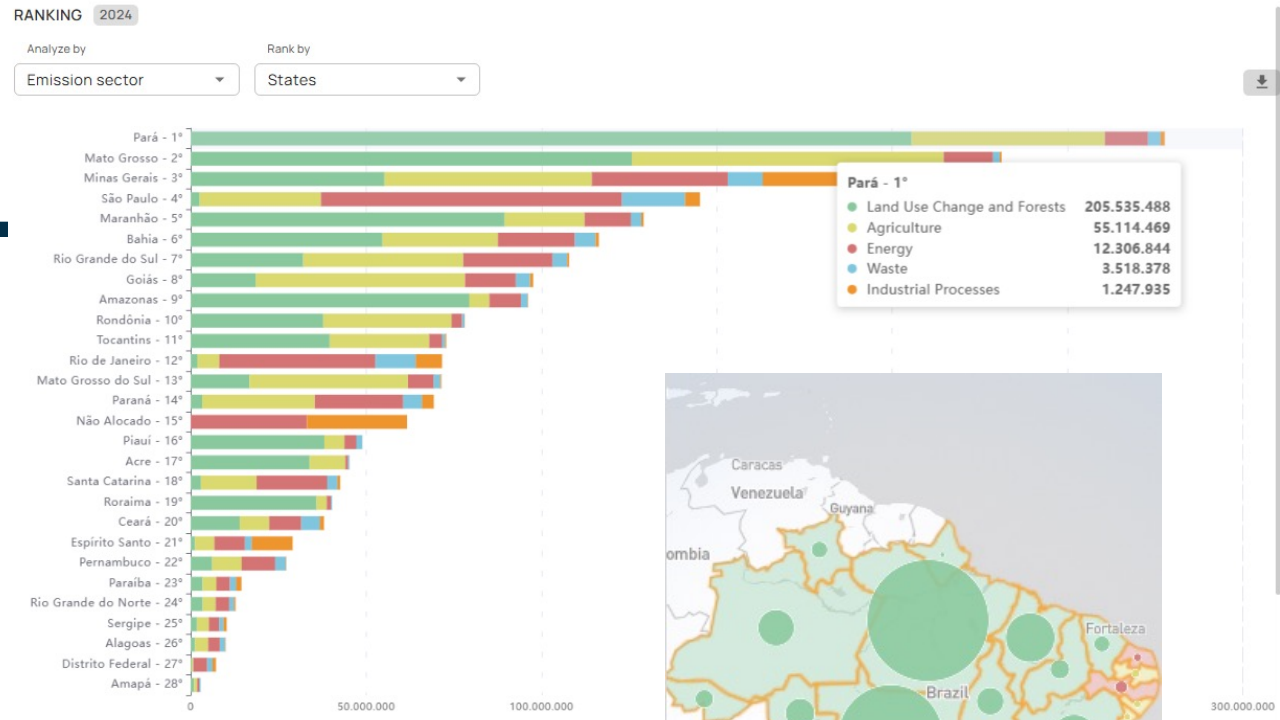
Cantidad de carbono almacenada en los distintos ecosistemas terrestres (en gigatoneladas).

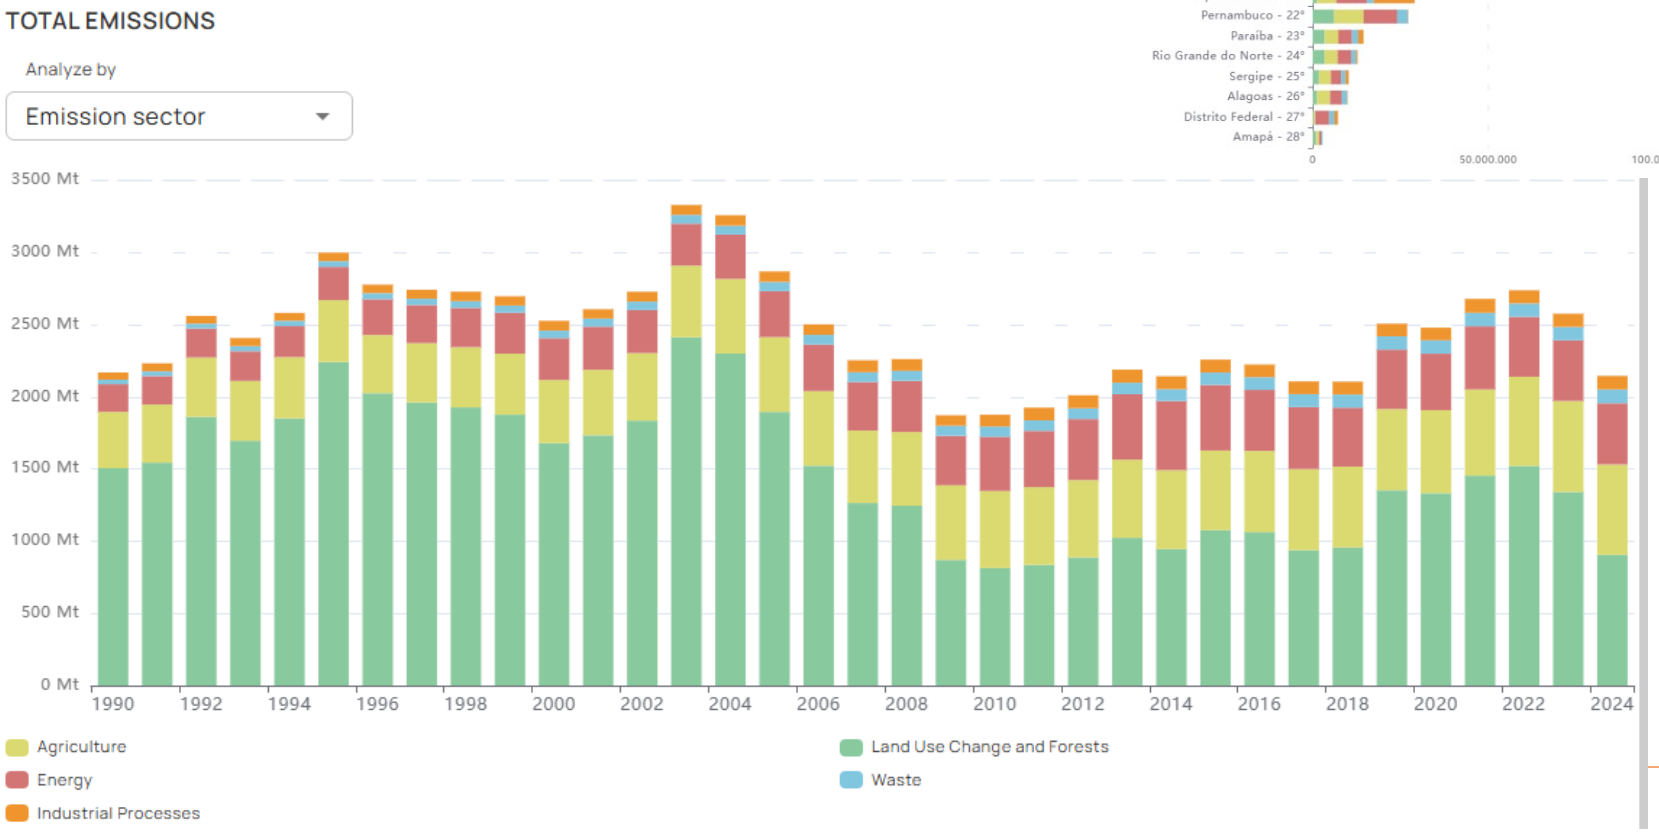


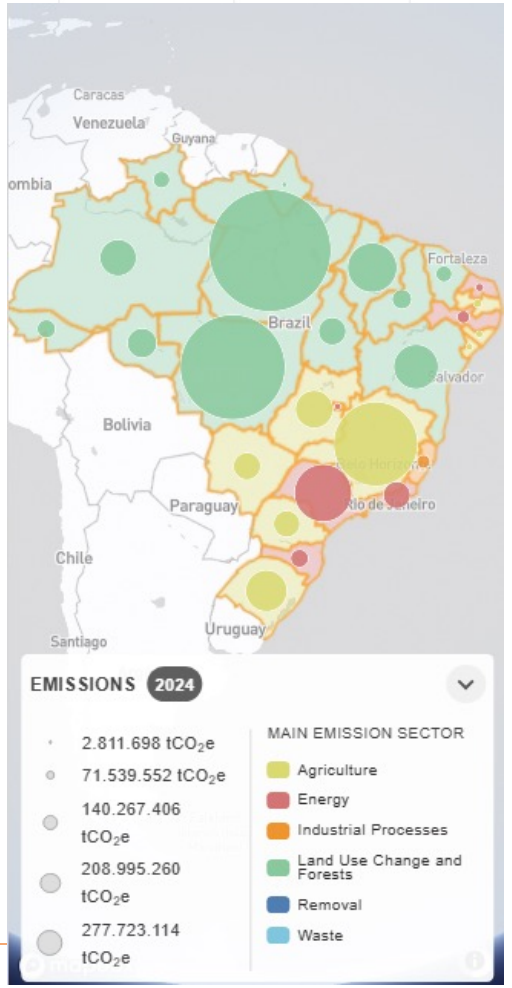
By Zac Kayler, Maria Janowiak, Chris Swanston - https://www.fs.usda.gov/ccrc/topics/global-carbon, Public Domain, https://commons.wikimedia.org/w/index.php?curid=95677627

Emisiones brutas de Brasil por sector

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

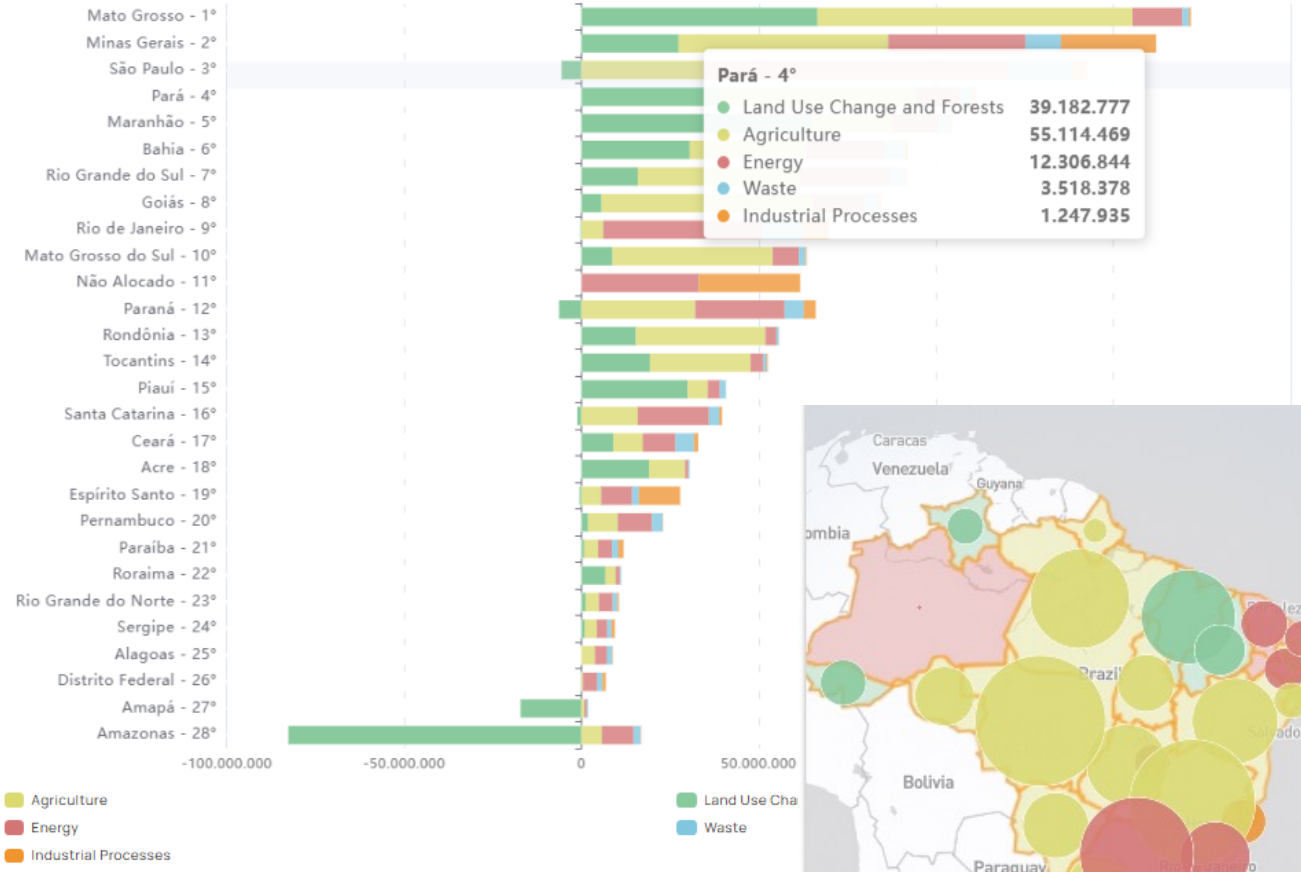


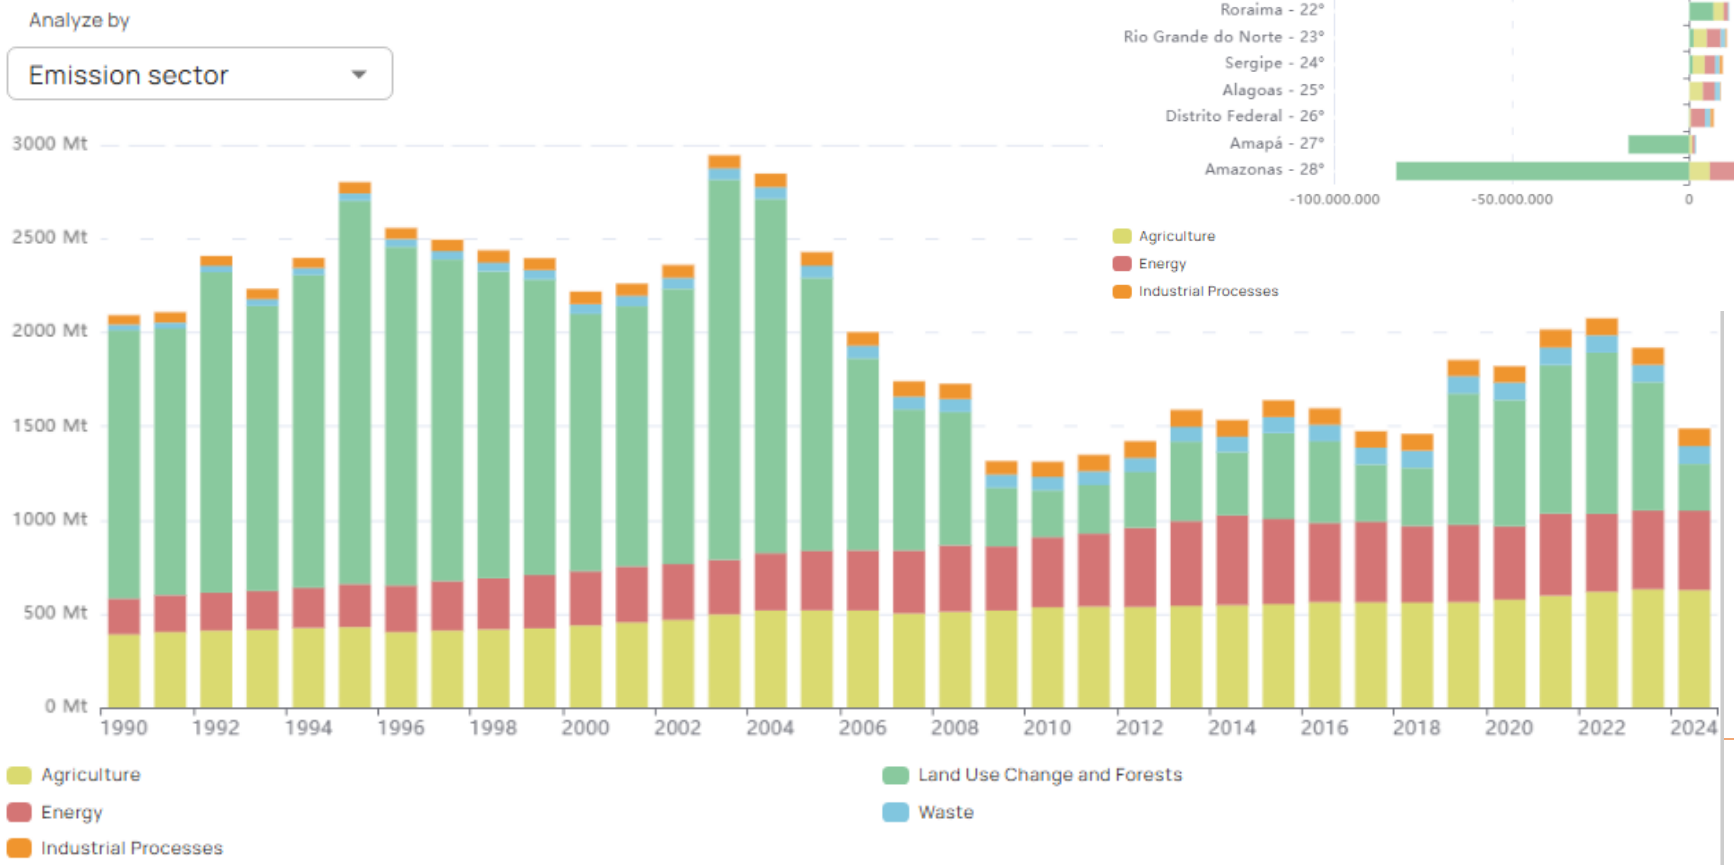


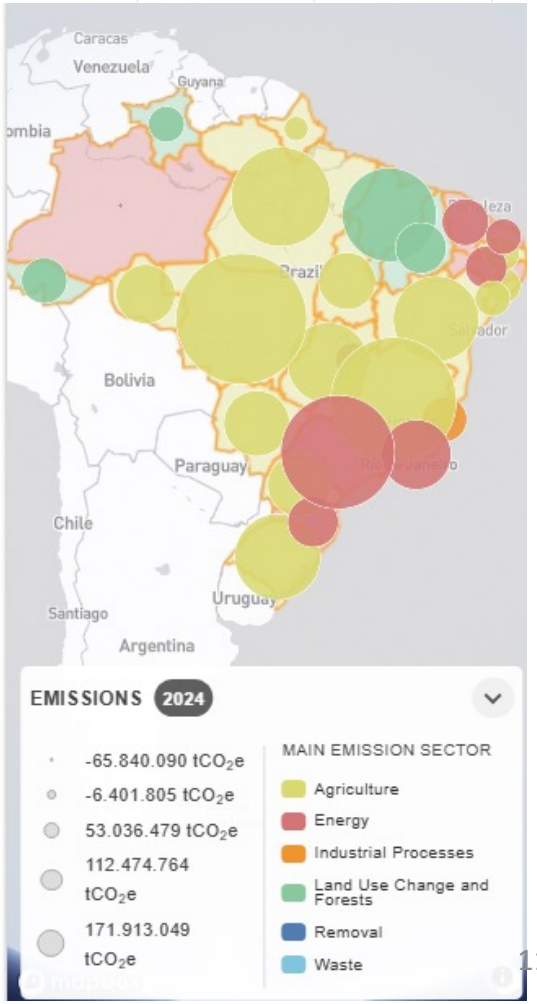


Emisiones netas de Brasil pc

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







Climate Change 2022: Impacts, Adaptation and Vulnerability

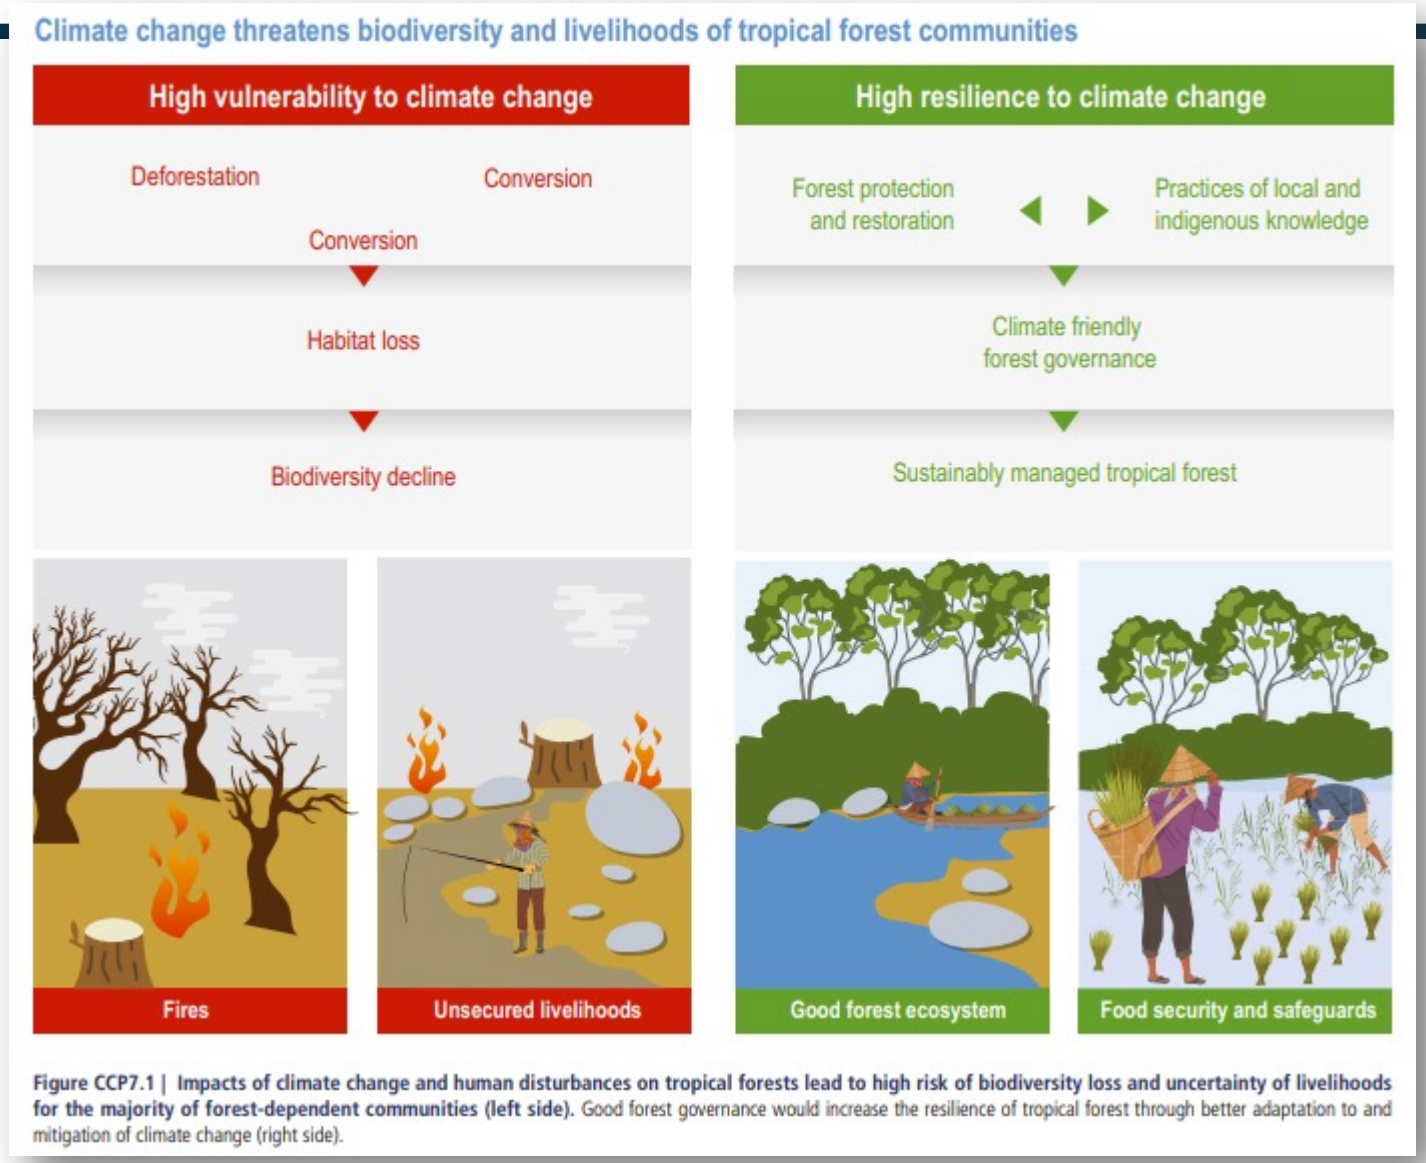


Figure CCP7.1 | Impacts of climate change and human disturbances on tropical forests lead to high risk of biodiversity loss and uncertainty of livelihoods for the majority of forest-dependent communities (left side). Good forest governance would increase the resilience of tropical forest through better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

Más de 420 millones de ha de bosque se perdieron por la deforestación entre 1990 y 2020;

Más del 90 % de esa pérdida ocurrió en zonas tropicales,

Amenazando la biodiversidad, los servicios ambientales, los medios de vida de las comunidades forestales y la resiliencia ante los impactos climáticos

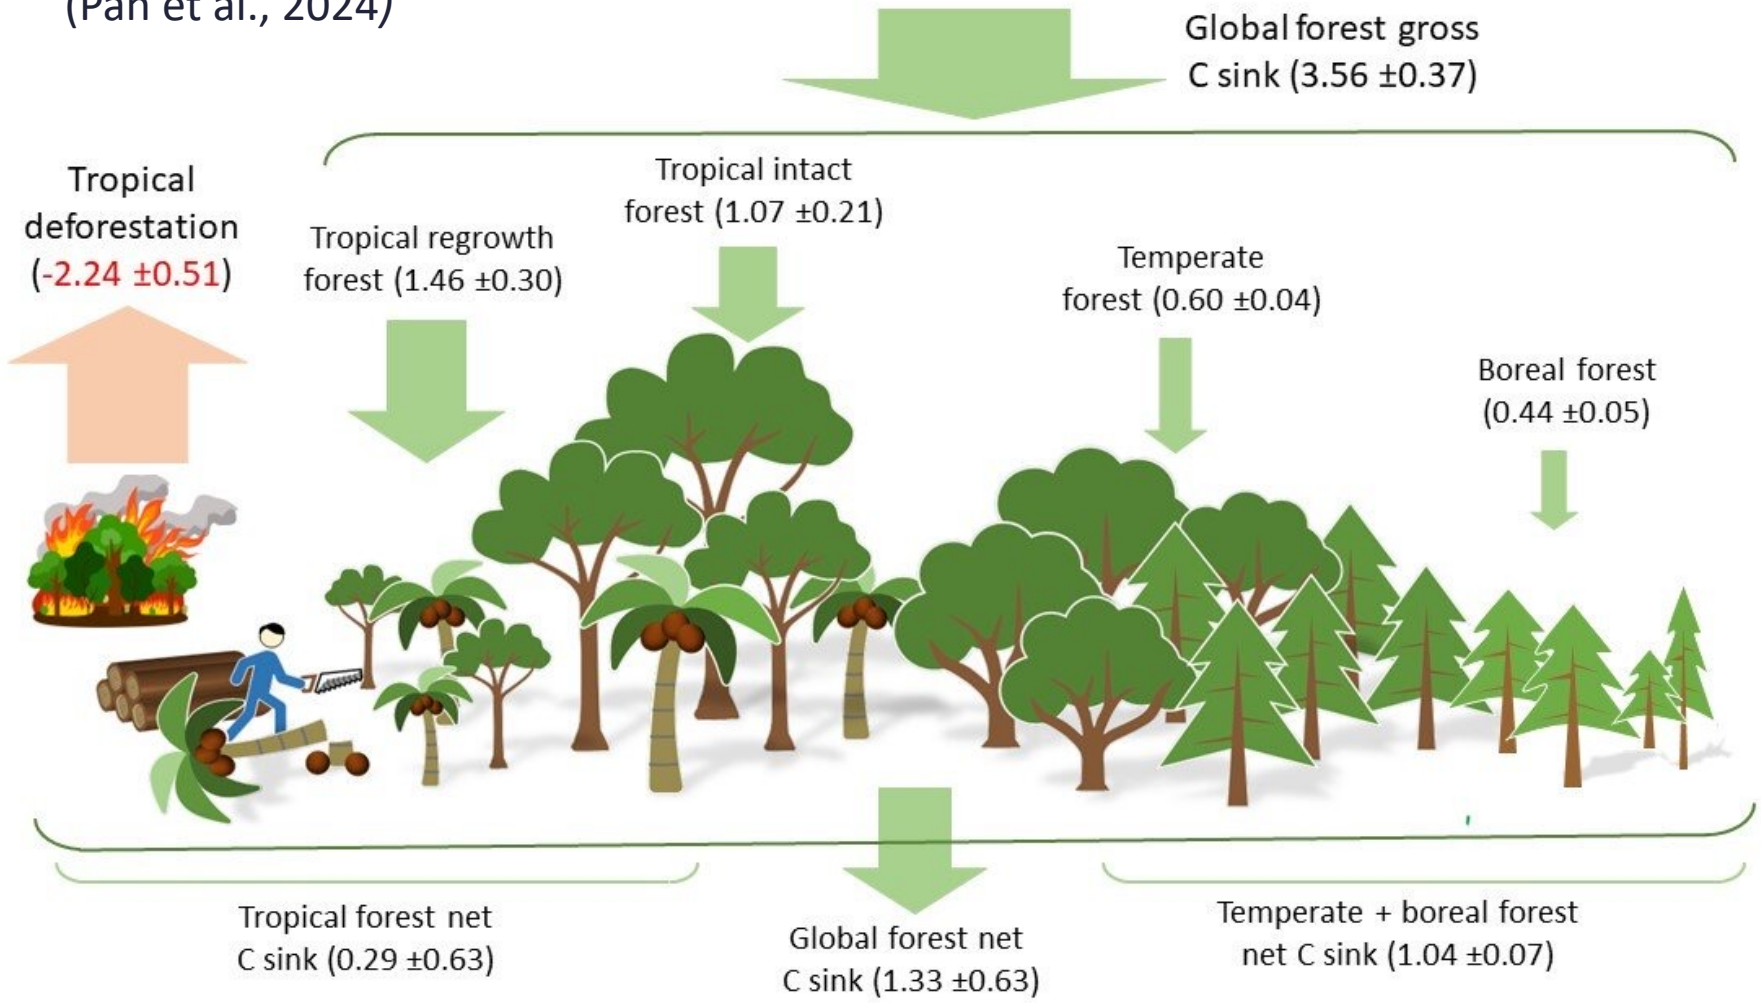
(Ometto et al., 2022)

IPCC AR6, CCP7 sobre bosques tropicales

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

¿Por qué monitorear la deforestación y la vegetación?

El persistente sumidero de carbono forestal mundial
(Pan et al., 2024*)*



Para proteger el sumidero de carbono**, se necesitan políticas de gestión del territorio que limiten la deforestación,** promuevan la restauración forestal y mejoren las prácticas de aprovechamiento maderero

Sumideros y fuentes de carbono de los bosques del mundo (Pg C año^{-1}), tasa media anual entre 1990 y 2019.

¿Por qué monitorear la deforestación y la vegetación?

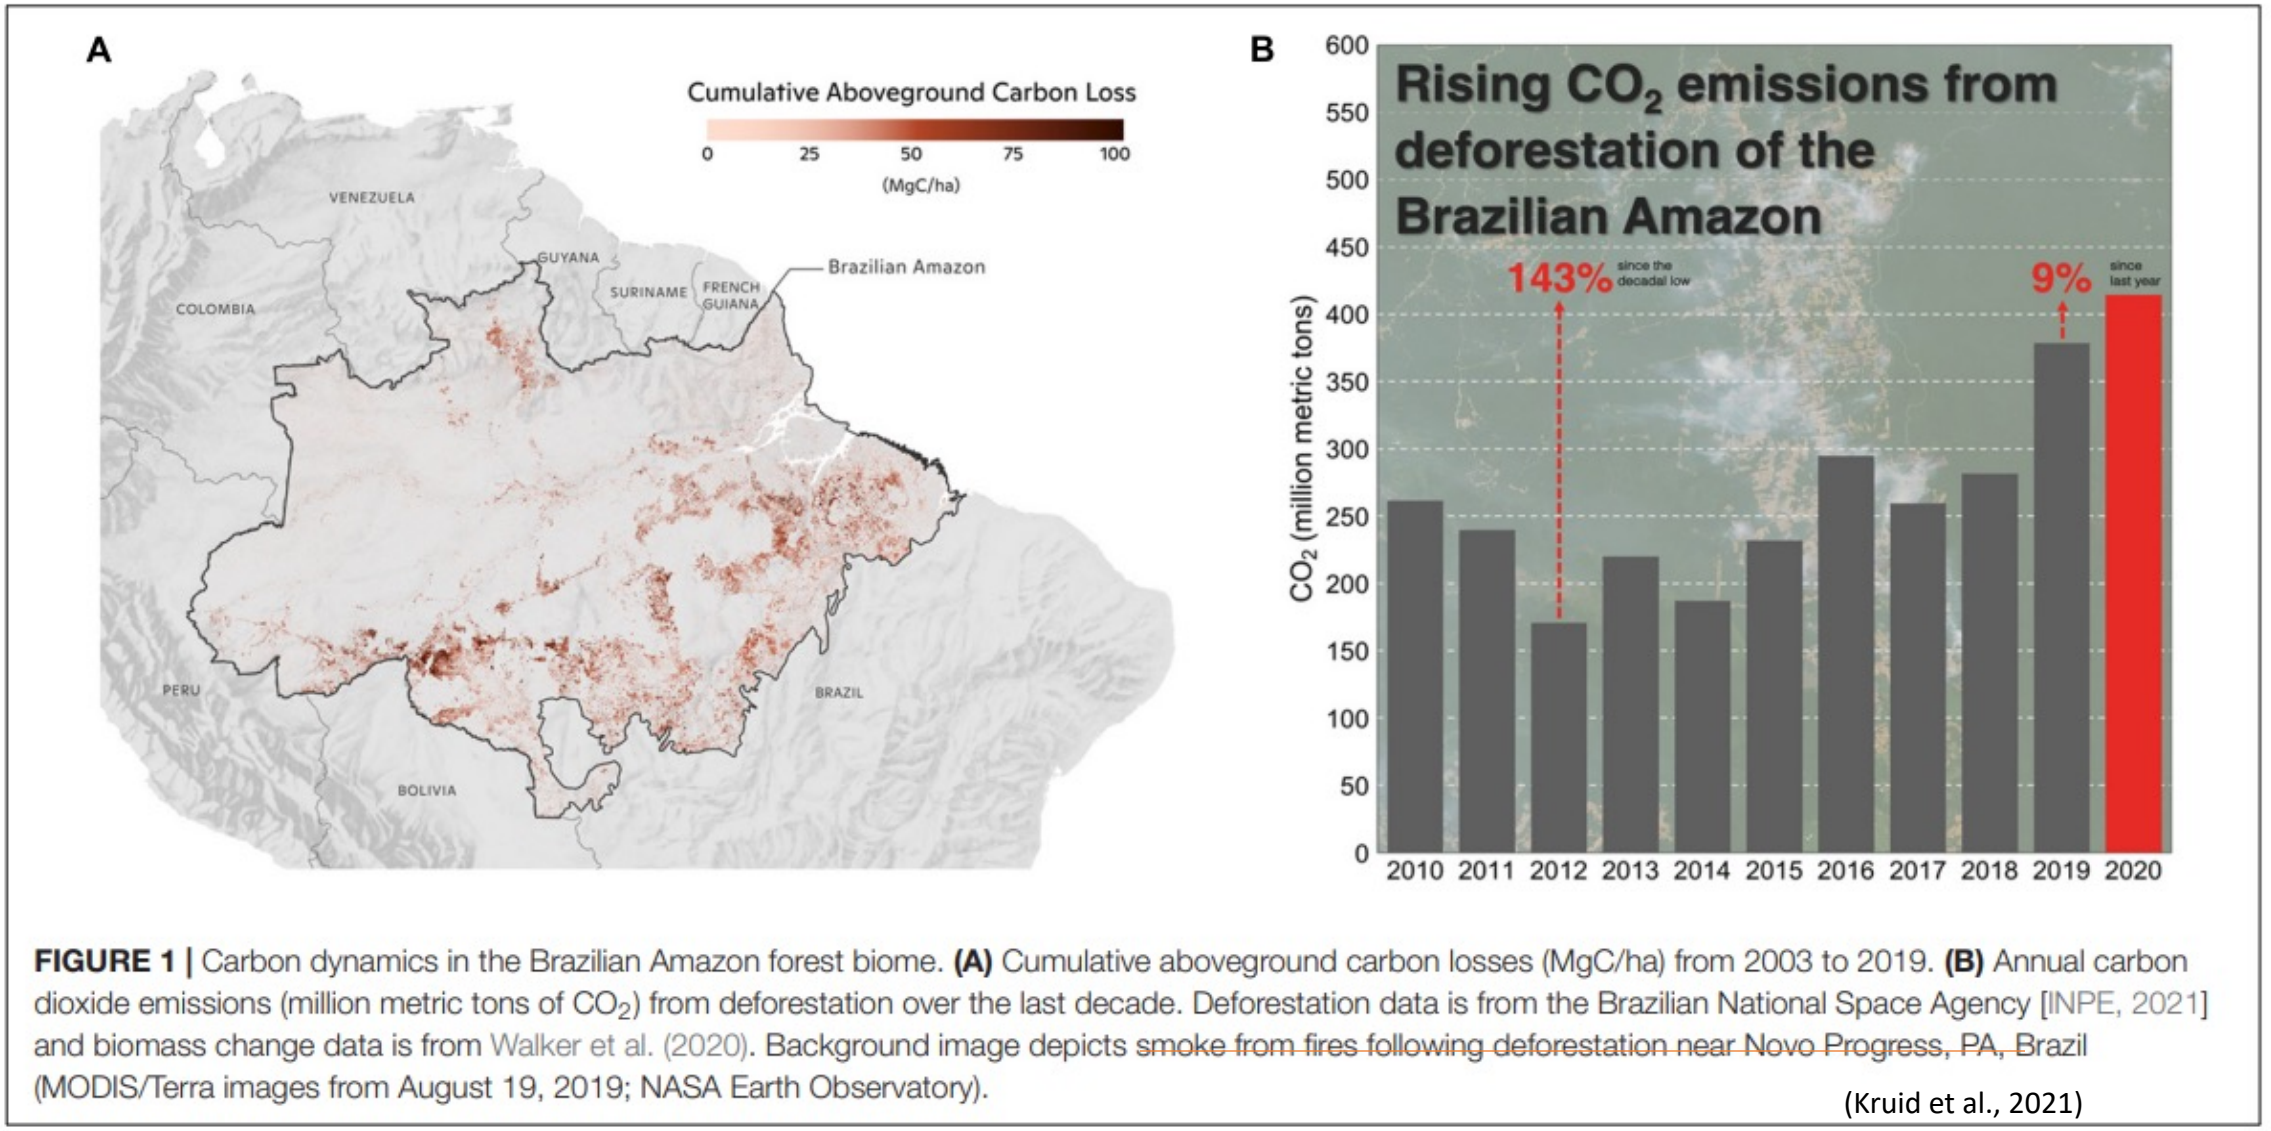


FIGURE 1 | Carbon dynamics in the Brazilian Amazon forest biome. **(A)** Cumulative aboveground carbon losses (MgC/ha) from 2003 to 2019. **(B)** Annual carbon dioxide emissions (million metric tons of CO_2) from deforestation over the last decade. Deforestation data is from the Brazilian National Space 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 qué monitorear la deforestación y la vegetación?

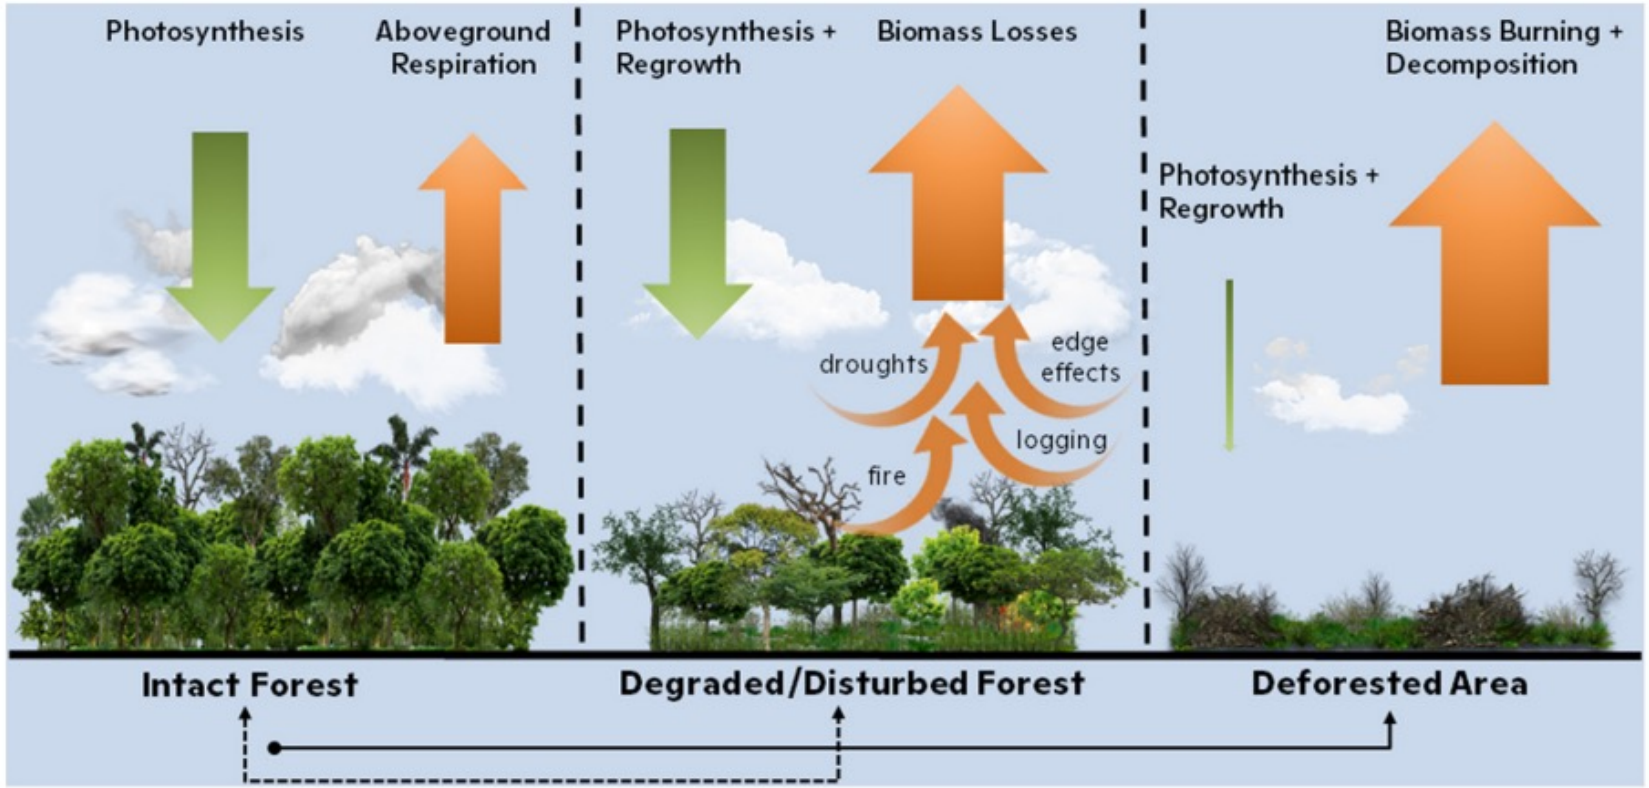


FIGURE 2 | Conceptual diagram showing above-ground carbon fluxes typical of healthy forests (left), degraded/disturbed forests (middle), and newly defo areas (right) in the Amazon. In each panel, carbon stocks are represented by the standing vegetation, losses by the orange upward arrows, and gains by 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.

Comprender los **impulsores y patrones de las pérdidas de carbono forestal**

Primer paso para diseñar **estrategias de mitigación eficaces**

Clave para los compromisos de Brasil y los países tropicales en el marco del **Acuerdo de París**.

Conservación de los bosques tropicales

(Kruid et al., 2021)

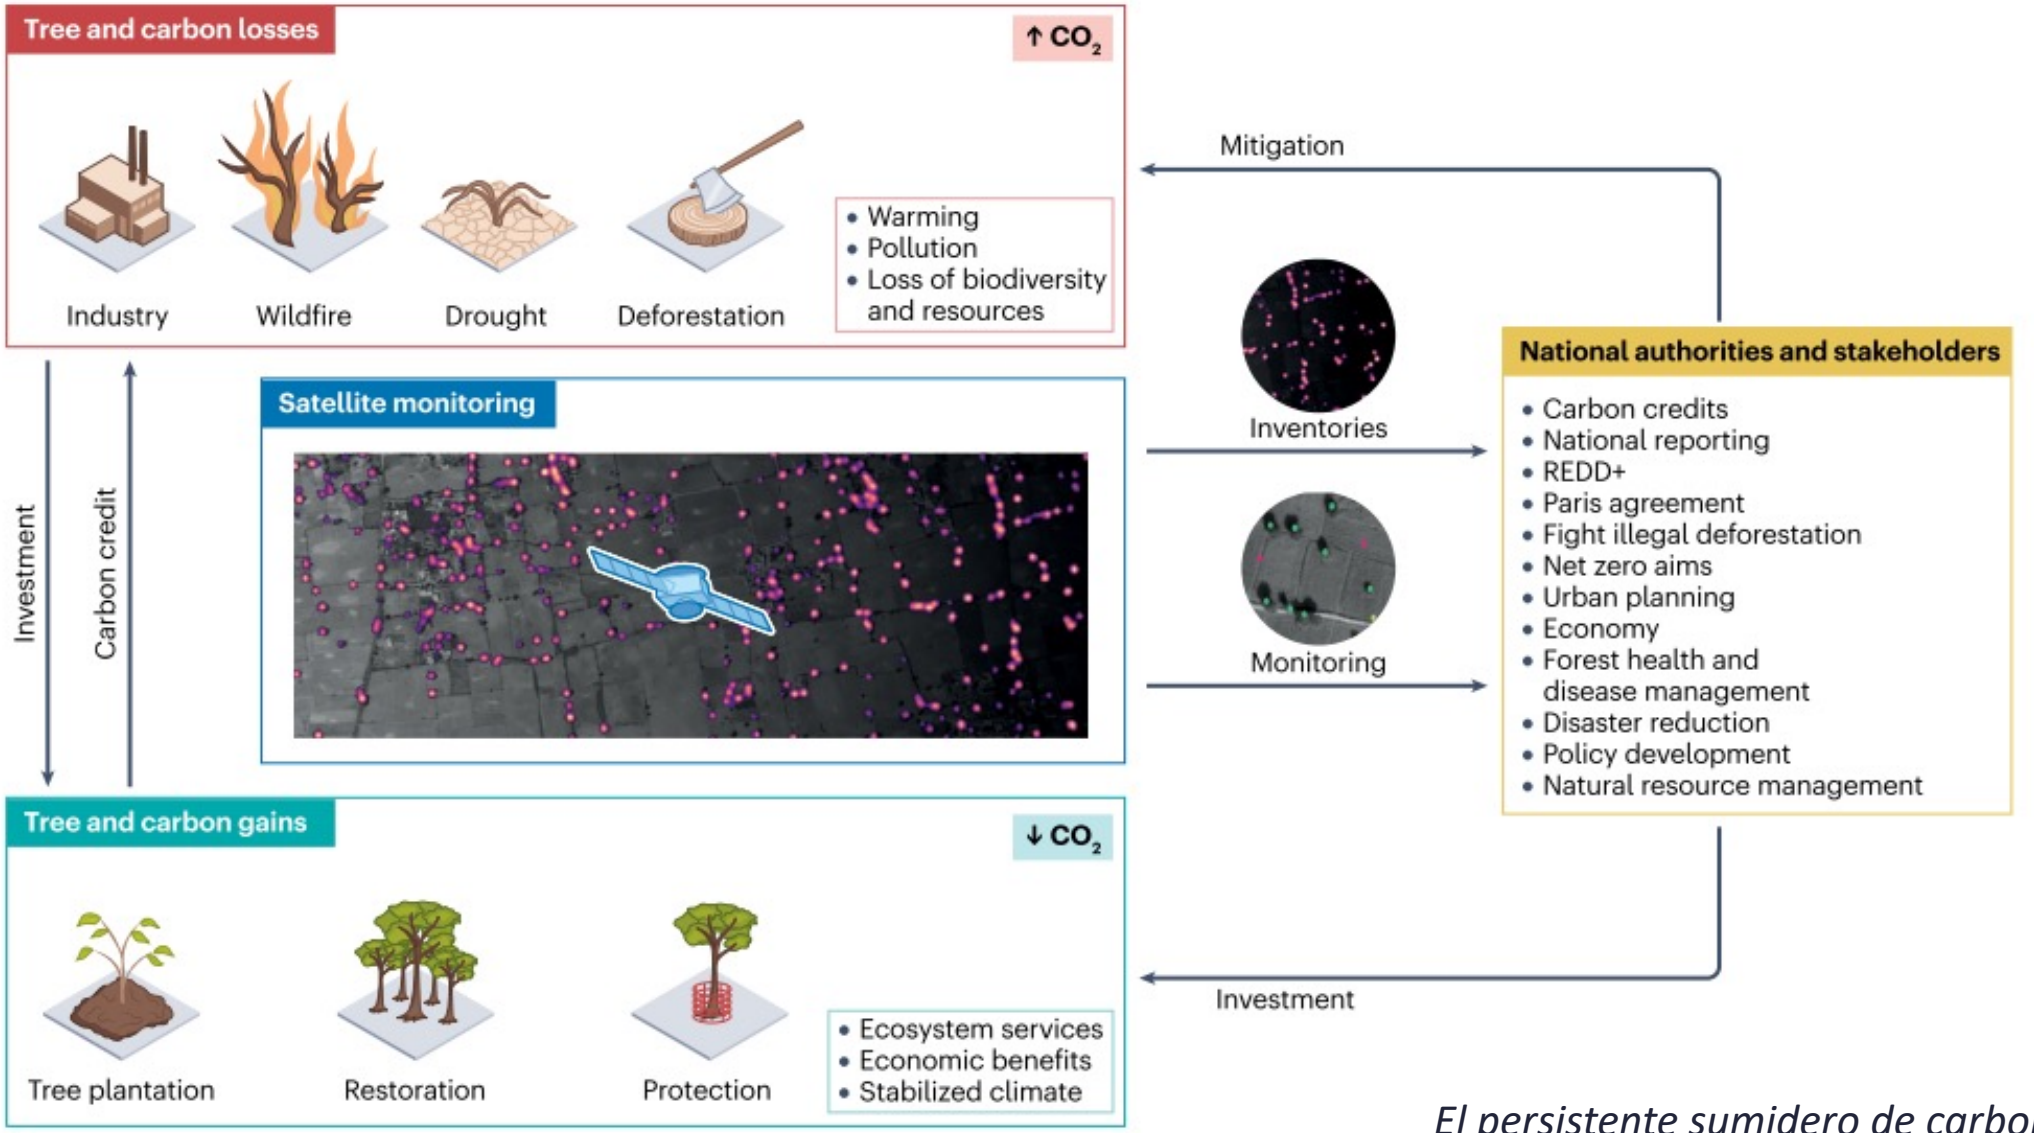


Fig. 1 | The importance of tree resource monitoring.

El persistente sumidero de carbono forestal mundial
(Brandt et al., 2024)



IA – *un recordatorio….*

La inteligencia artificial (IA) es un campo de la informática que desarrolla sistemas computacionales capaces de simular procesos cognitivos humanos como el aprendizaje, el razonamiento y la toma de decisiones (Russell & Norvig, 2010).

¿Métodos de IA?

- Aprendizaje automático (**supervisado**, **no supervisado** y por refuerzo);
- Aprendizaje profundo y redes neuronales;
- Procesamiento del lenguaje natural (PLN);
- Visión por computador;
- IA simbólica (incluidos sistemas expertos y modelado basado en reglas);
- Computación evolutiva;
- Lógica difusa



IA para los bosques: tendencias actuales

Del aprendizaje automático al aprendizaje profundo

Periodo	Métodos de IA predominantes
~2010–2017	Bosques aleatorios, máquinas de vectores de soporte (SVM)
~2017–2022	Redes neuronales convolucionales (CNN) y arquitecturas U-Net
~2022–2024	Vision Transformers y modelos temporales de aprendizaje profundo
~2024–actualidad	Modelos fundacionales, IA multimodal y aprendizaje autosupervisado

Clasificación de la cobertura del suelo y estimación de biomasa

Robustez y baja demanda de datos de entrenamiento



IA para los bosques: tendencias actuales

Del aprendizaje automático al aprendizaje profundo

Periodo	Métodos de IA predominantes
~2010–2017	Bosques aleatorios, máquinas de vectores de soporte (SVM)
~2017–2022	Redes neuronales convolucionales (CNN) y arquitecturas U-Net
~2022–2024	Vision Transformers y modelos temporales de aprendizaje profundo
~2024–actualidad	Modelos fundacionales, IA multimodal y aprendizaje autosupervisado

Mapeo forestal, detección de la deforestación y caracterización del dosel.

Capacidad de captar patrones espaciales complejos.



IA para los bosques: tendencias actuales

Del aprendizaje automático al aprendizaje profundo

Periodo	Métodos de IA predominantes
~2010–2017	Bosques aleatorios, máquinas de vectores de soporte (SVM)
~2017–2022	Redes neuronales convolucionales (CNN) y arquitecturas U-Net
~2022–2024	Vision Transformers (ViT) y modelos temporales de aprendizaje profundo
~2024–actualidad	Modelos fundacionales, IA multimodal y aprendizaje autosupervisado

Extracción de **dependencias espaciales** de largo alcance y

Aprovechamiento de **series temporales de imágenes** satelitales densas para monitorear la dinámica forestal.



IA para los bosques: tendencias actuales

Del aprendizaje automático al aprendizaje profundo

Periodo	Métodos de IA predominantes
~2010–2017	Bosques aleatorios, máquinas de vectores de soporte (SVM)
~2017–2022	Redes neuronales convolucionales (CNN) y arquitecturas U-Net
~2022–2024	Vision Transformers (ViT) y modelos temporales de aprendizaje profundo
~2024–actualidad	Modelos fundacionales, IA multimodal y aprendizaje autosupervisad

Datos masivos de OT sin etiquetar

Integración de fuentes (óptica, SAR, LiDAR, clima, topografía)

Transferibilidad entre regiones y sensores

Menor dependencia de datos etiquetados,

Soporte de múltiples tareas posteriores con un ajuste fino mínimo.



IA para los bosques: tendencias actuales

Del aprendizaje automático al aprendizaje profundo

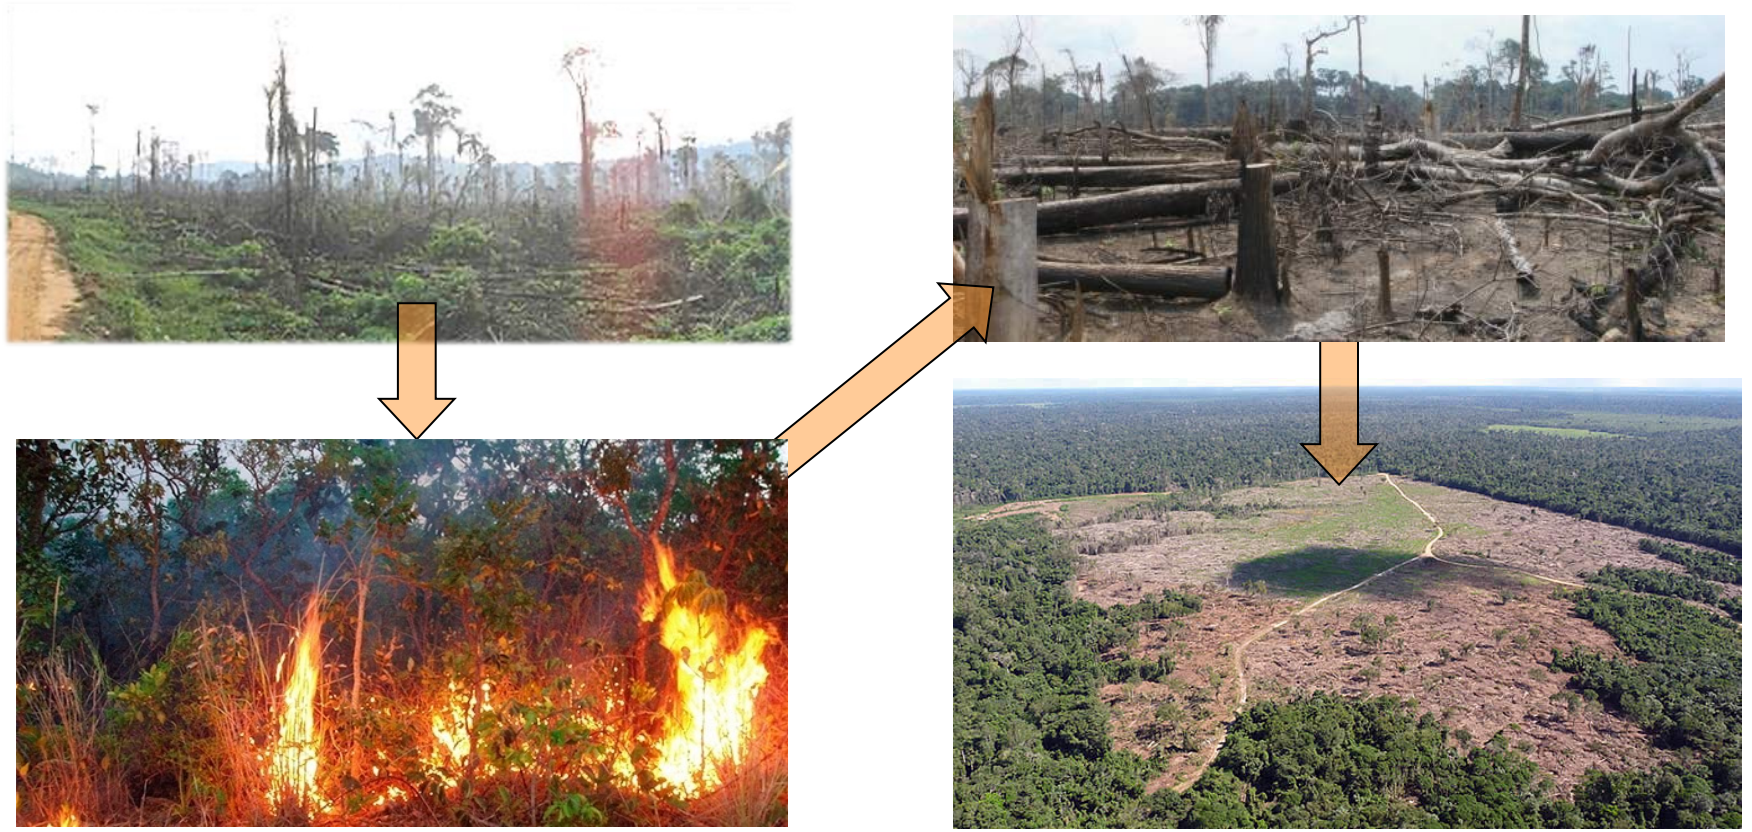
Periodo	Métodos de IA predominantes
~2010–2017	Bosques aleatorios, máquinas de vectores de soporte (SVM)
~2017–2022	Redes neuronales convolucionales (CNN) y arquitecturas U-Net
~2022–2024	Vision Transformers (ViT) y modelos temporales de aprendizaje profundo
~2024–actualidad	Modelos fundacionales, IA multimodal y aprendizaje autosupervisado

Cobertura del suelo, biomasa y aplicaciones con pocos datos etiquetados

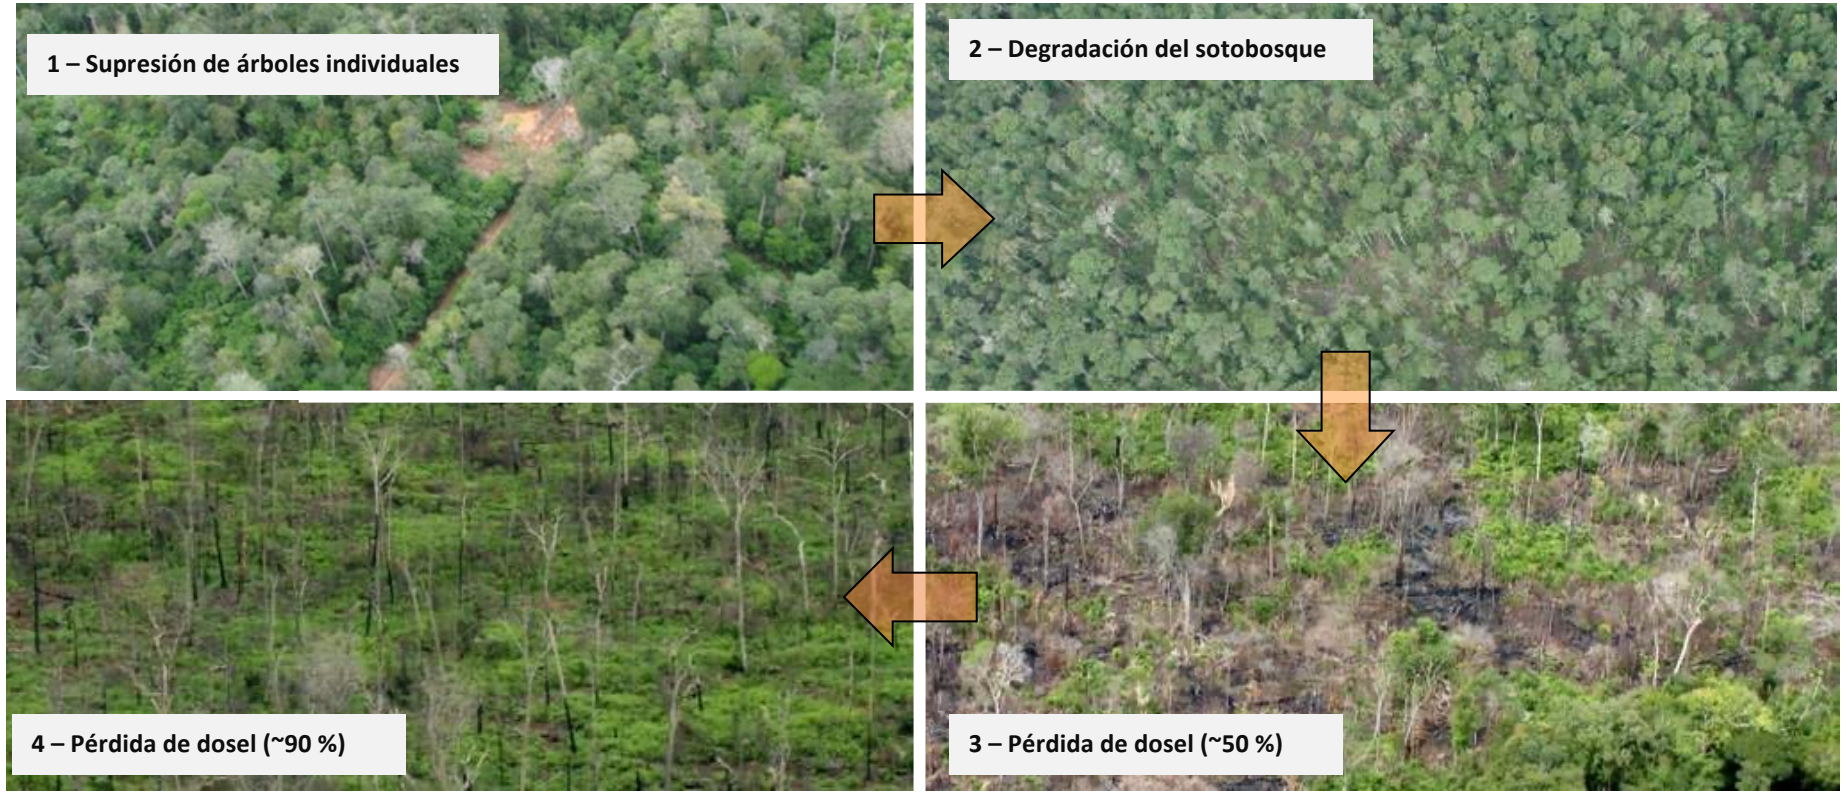
Degradación forestal, mapeo de perturbaciones, monitoreo continuo y análisis a gran escala

Deforestación, incendios forestales, tala rasa

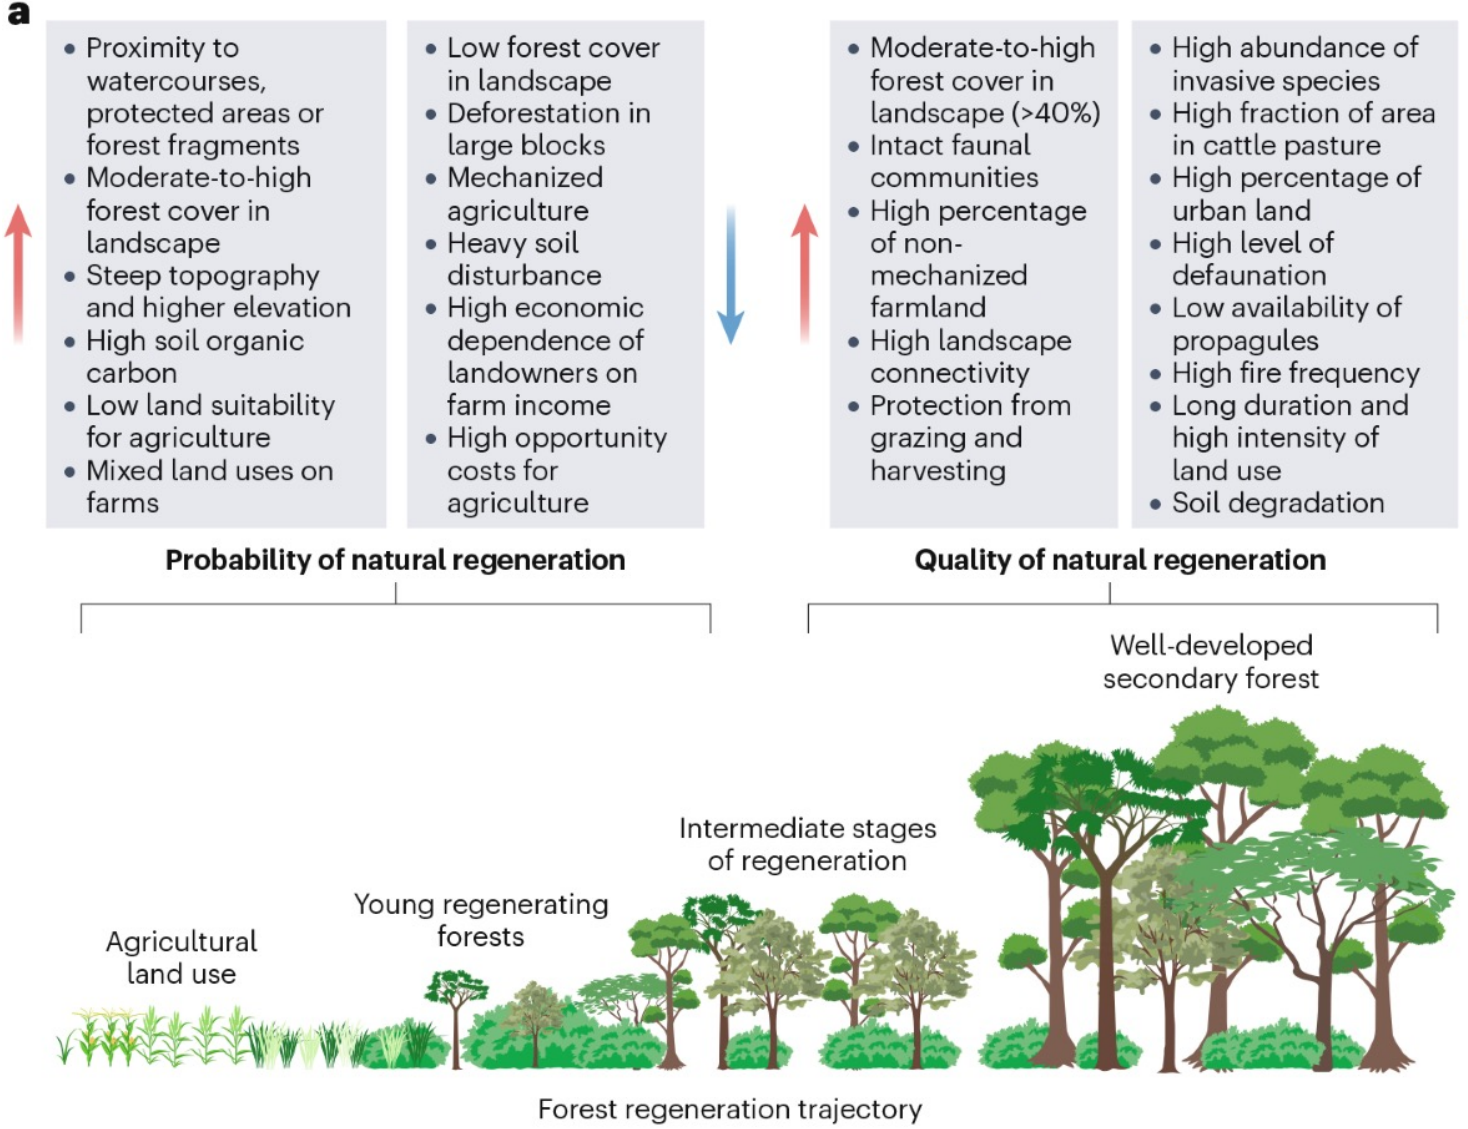
Roza y quema en la Amazonía

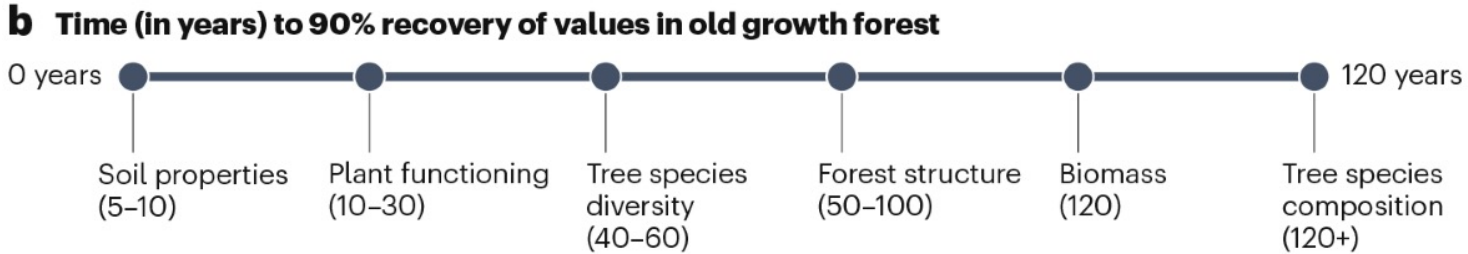


Degradación forestal



Biomas Br





Impulsores y beneficios de la regeneración natural en los bosques tropicales

Chazdon et al. (2025)



Monitoreo forestal con teledetección e IA

Tarea	Aplicaciones representativas	Referencias clave
Mapeo forestal y clasificación de la cobertura del suelo	Mapeo bosque/no bosque, clasificación de tipos de bosque, inventarios de bosques tropicales	Belgiu & Drăguț (2016); Mountrakis et al. (2011); Ma et al. (2019)
Detección de la deforestación	Detección de talas rasas, tala ilegal, monitoreo casi en tiempo real	Zhu et al. (2017); Chen et al. (2021); Bandara & Patel (2022)
Monitoreo de la degradación forestal	Tala selectiva, perturbación del sotobosque, degradación del dosel	Rußwurm & Körner (2018); Pelletier et al. (2019)
Recuperación y regeneración forestal	Sucesión de bosque secundario, monitoreo de la restauración, recuperación de la vegetación	Pelletier et al. (2019); Ma et al. (2019)
Estimación de biomasa y carbono	Biomasa aérea, existencias de carbono, monitoreo REDD+	Belgiu & Drăguț (2016); Maxwell et al. (2018)
Detección de árboles individuales y caracterización del dosel	Delimitación de copas, reconocimiento de especies, claros del dosel	Ma et al. (2019); Zhu et al. (2017)
Perturbaciones forestales y detección de cambios	Cicatrices de incendios, tormentas, plagas de insectos, cambio de uso del suelo	Chen et al. (2021); Bandara & Patel (2022)
Evaluación de incendios forestales	Mapeo de áreas quemadas, severidad del fuego, recuperación posincendio	Ma et al. (2019); Zhu et al. (2017)
Monitoreo forestal casi en tiempo real	Sistemas de alerta operativos, vigilancia forestal continua	Ayush et al. (2021); Jakubik et al. (2024)
Análisis geoespacial de propósito general	Aprendizaje multitarea, aprendizaje por transferencia, monitoreo forestal continental y mundial	Robinson et al. (2024); Jakubik et al. (2024)



Monitoreo forestal con teledetección e IA

Tarea	Principales métodos de IA
Mapeo forestal y clasificación de la cobertura del suelo	Bosques aleatorios, SVM, CNN, Vision Transformers
Detección de la deforestación	CNN, U-Net, redes siamesas, Transformers
Monitoreo de la degradación forestal	CNN, CNN temporales, LSTM, Vision Transformers
Recuperación y regeneración forestal	LSTM, GRU, Transformers temporales
Estimación de biomasa y carbono	Bosques aleatorios, gradient boosting, redes neuronales profundas
Detección de árboles individuales y caracterización del dosel	CNNs, Mask R-CNN, U-Net, YOLO
Perturbaciones forestales y detección de cambios	CNN siamesas, BIT, ChangeStar, Vision Transformers
Evaluación de incendios forestales	CNN, DeepLab, Transformers
Monitoreo forestal casi en tiempo real	Transformers temporales, aprendizaje autosupervisado, modelos fundacionales
Análisis geoespacial de propósito general	Modelos fundacionales, IA multimodal



IA para las tareas de monitoreo forestal

Tarea	Principales métodos de IA
Mapeo forestal y clasificación de la cobertura del suelo	Bosques aleatorios, SVM, CNN, Vision Transformers
Detección de la deforestación	CNN, U-Net, redes siamesas, Transformers
Monitoreo de la degradación forestal	CNN, CNN temporales, LSTM, Vision Transformers
Recuperación y regeneración forestal	LSTM, GRU, Transformers temporales
Estimación de biomasa y carbono	Bosques aleatorios, gradient boosting, redes neuronales profundas
Detección de árboles individuales y caracterización del dosel	CNNs, Mask R-CNN, U-Net, YOLO
Perturbaciones forestales y detección de cambios	CNN siamesas, BIT, ChangeStar, Vision Transformers
Evaluación de incendios forestales	CNNs, DeepLab, Transformers
Monitoreo forestal casi en tiempo real	Transformers temporales, aprendizaje autosupervisado, modelos fundacionales
Análisis geoespacial de propósito general	Modelos fundacionales, IA multimodal

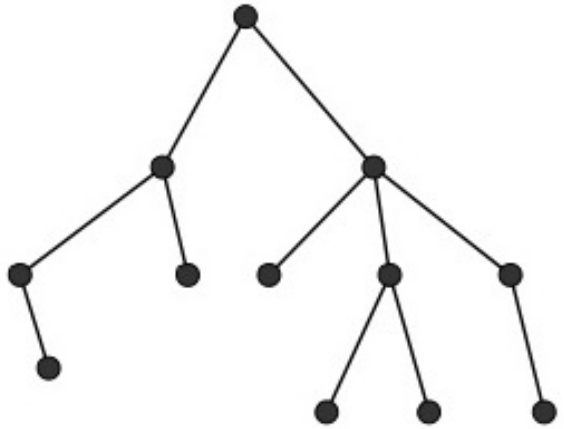


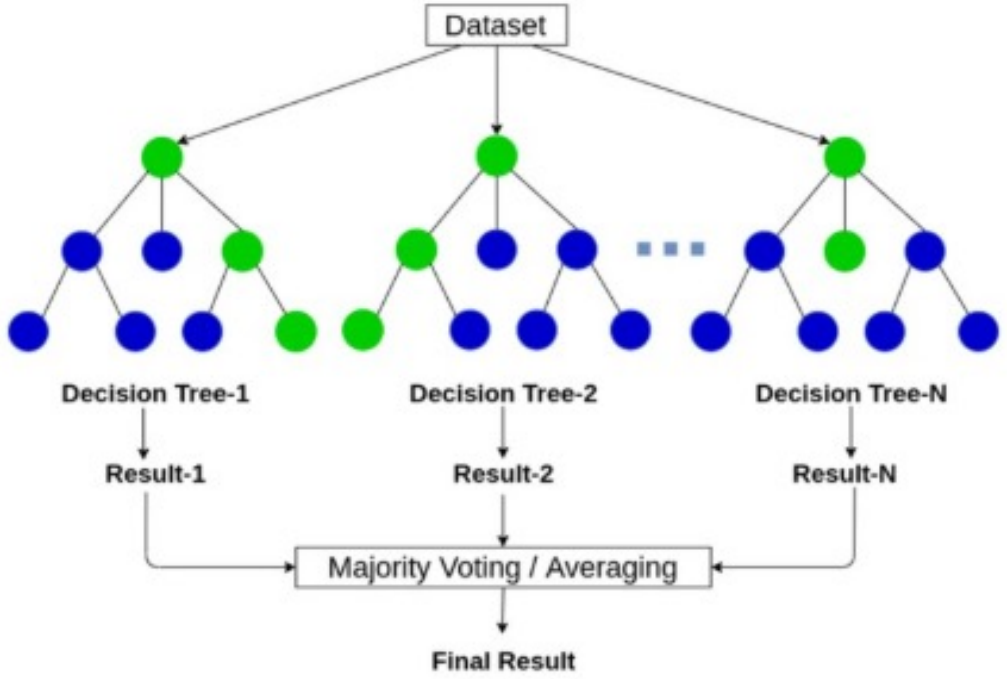
Bosques aleatorios

Árboles de decisión: **algoritmos** de aprendizaje automático

Punto de decisión = «nodos» del árbol, que deciden seguir un camino u otro
Camino = «ramas»
La variable con mayor ganancia de información estará en el primer nodo del árbol.







Bosque aleatorio - un conjunto de árboles de decisión - para clasificación y regresión

Entropía / índice de Gini – para definir la influencia de las variables

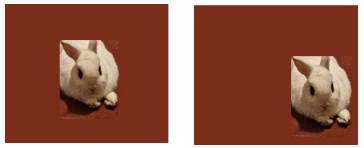
https://pt.stackoverflow.com/questions/216885/o-que-seria-uma-%C3%A1rvore-e-uma-floresta

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

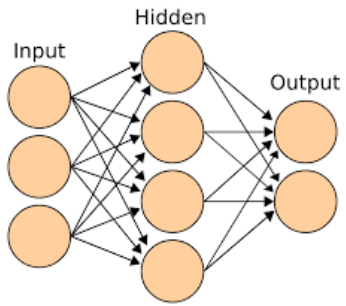


CNN Red neuronal convolucional

Los modelos de aprendizaje profundo usan datos tridimensionales para la clasificación de *imágenes* y el reconocimiento de objetos (**procesamiento de datos con topología de cuadrícula)**



Convoluciones matemáticas: para **preservar la estructura espacial y extraer automáticamente características** como bordes, texturas y formas



Red neuronal artificial (RNA)

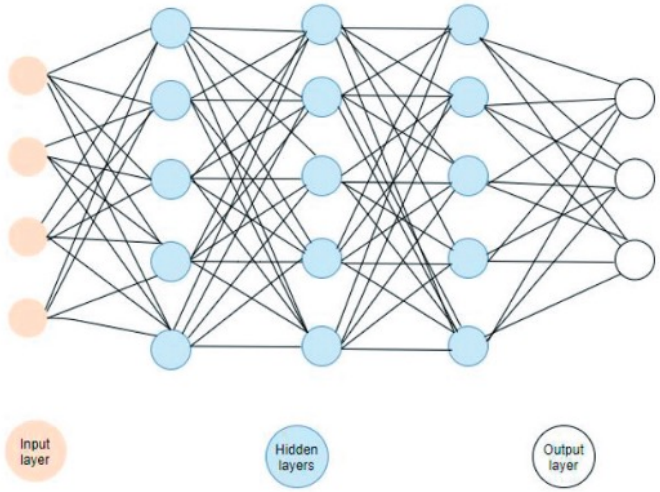
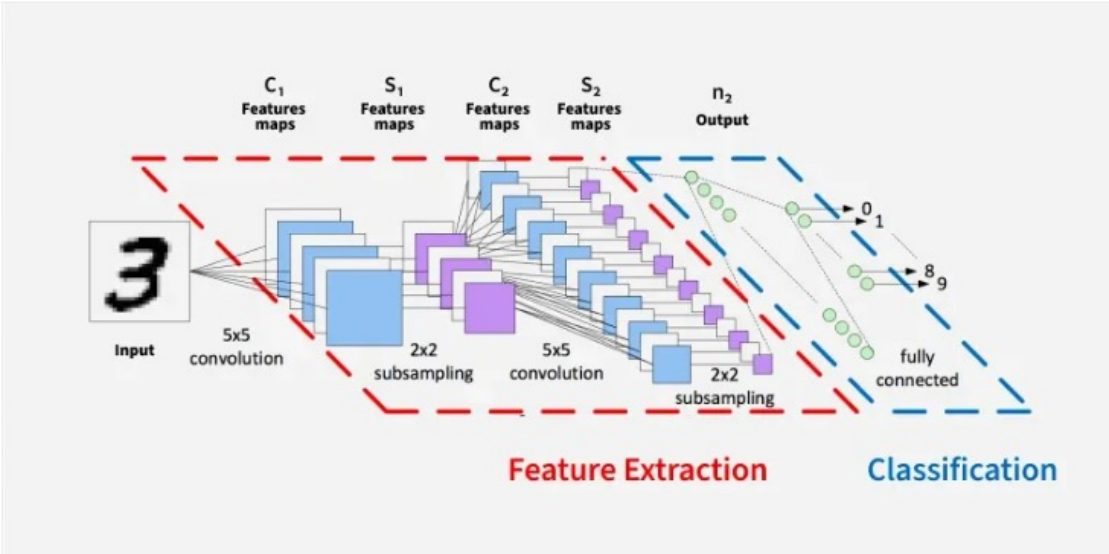


Figure 2.
Deep neural network.

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



Red neuronal convolucional

Una red neuronal con muchas capas ocultas se denomina aprendizaje profundo

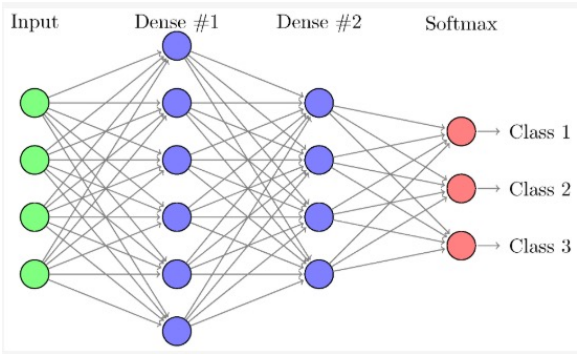
https://www.geeksforgeeks.org/deep-learning/convolutional-neural-network-cnn-in-machine-learning/

TempCNN

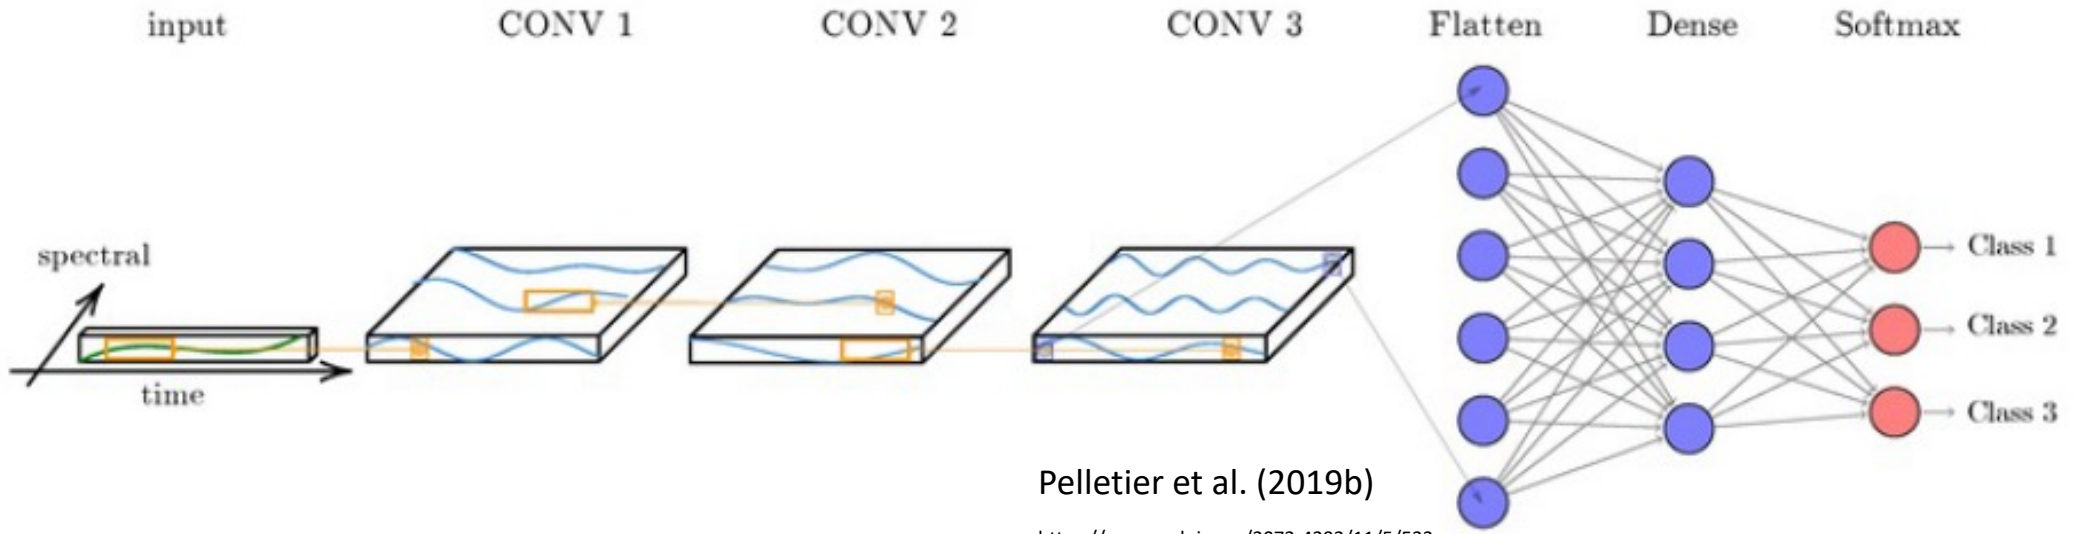
Red neuronal convolucional temporal

La **entrada** de la red es una serie temporal multivariante.
Se aplican sucesivamente tres **filtros** convolucionales, luego una capa densa,
y finalmente la capa Softmax, que da la distribución de clases predicha.

Red neuronal totalmente conectada



Arquitectura TempCNN para una tarea de clasificación.



Pelletier et al. (2019b)

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



Transformers

Attention Is All You Need

Vaswani et al. (2017)

Arquitectura
Basada solo en mecanismos de atención, sin recurrencia ni convoluciones

Procedentes del PLN (procesamiento del lenguaje natural)
– traducción automática en lugar de palabra a palabra o frase a frase
– todo el libro, con atención (marcadores)
– recuperar fácilmente un párrafo (como en una conversación: ¿qué es interesante?)

Autoatención: modela las relaciones entre todos los elementos de la entrada;
Atención multicabezal : aprendizaje simultáneo de distintos tipos de relaciones;
Eliminación de las redes recurrentes;
Procesamiento en paralelo;
Arquitectura Transformer.

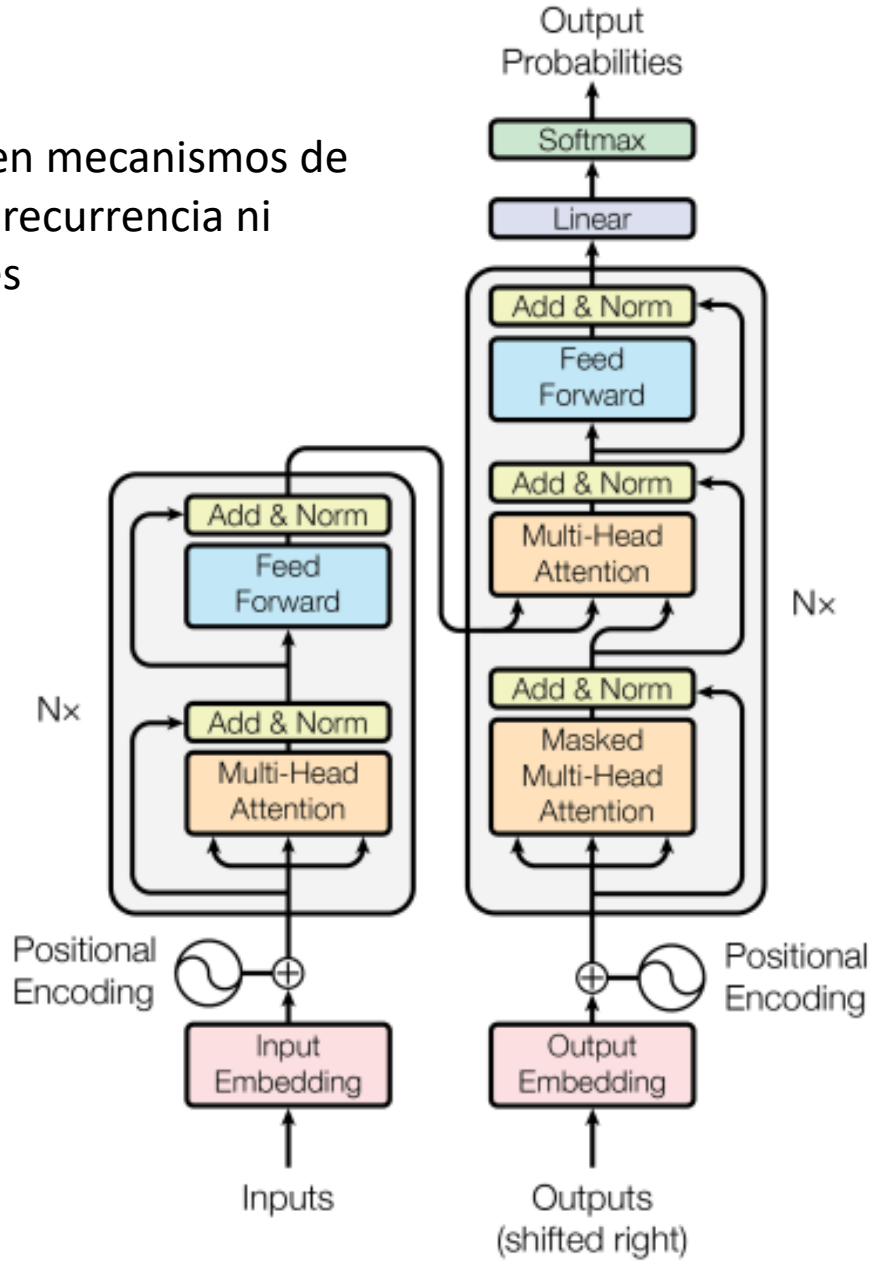


Figure 1: The Transformer - model architecture.

Transformers

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

Mecanismos de autoatención para modelar tanto las relaciones espaciales como las trayectorias temporales en grandes paisajes

Vegetación secundaria identificada
no solo por su firma espectral,
sino también porque está:
- situada en una zona ya deforestada,
- cerca de otros fragmentos en regeneración,
- con una evolución coherente a lo largo de una serie temporal de imágenes.



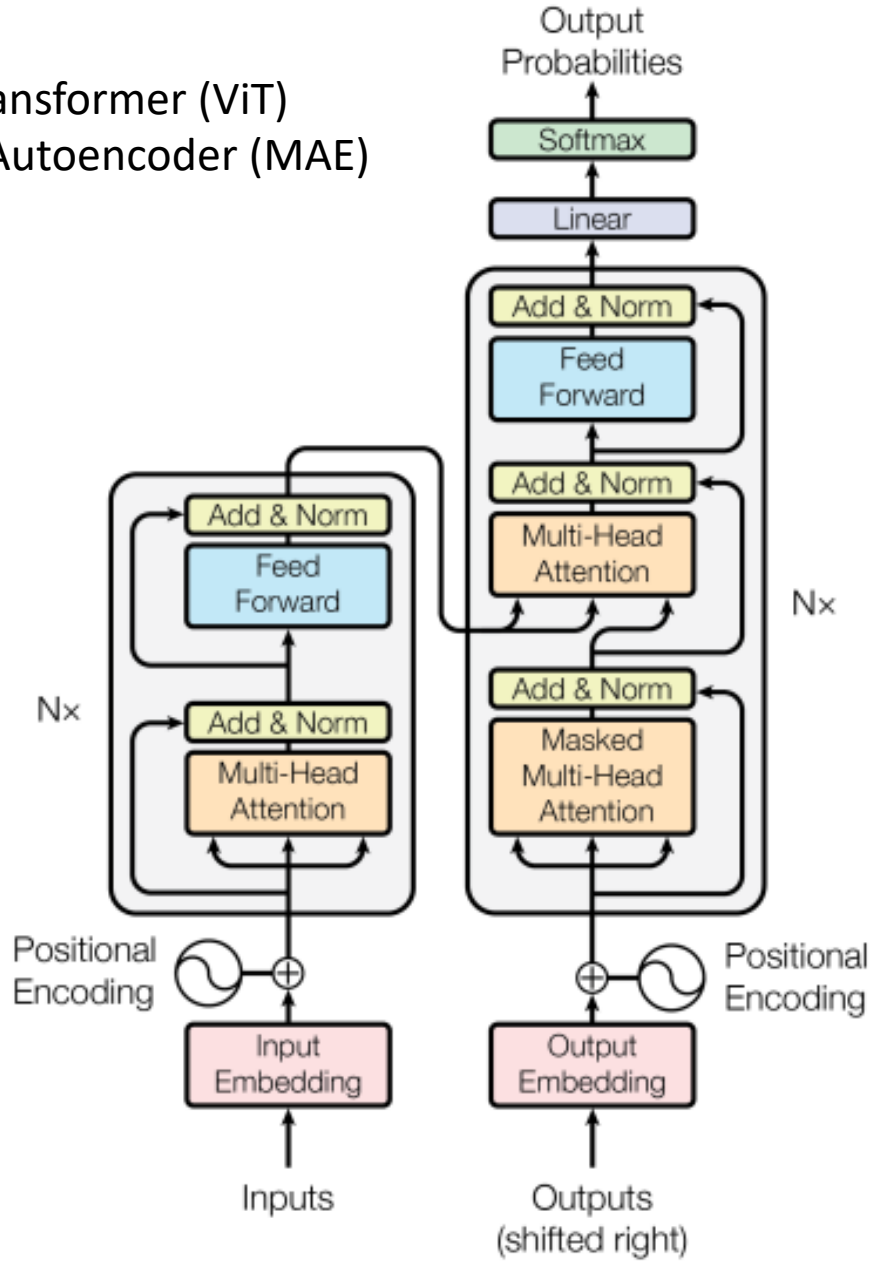


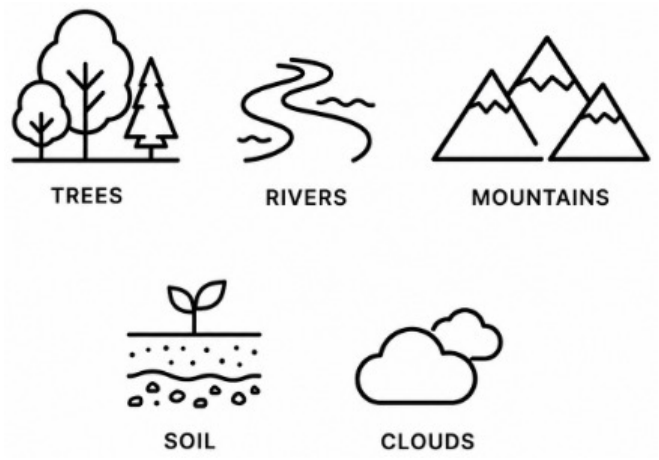
Figure 1: The Transformer - model architecture.

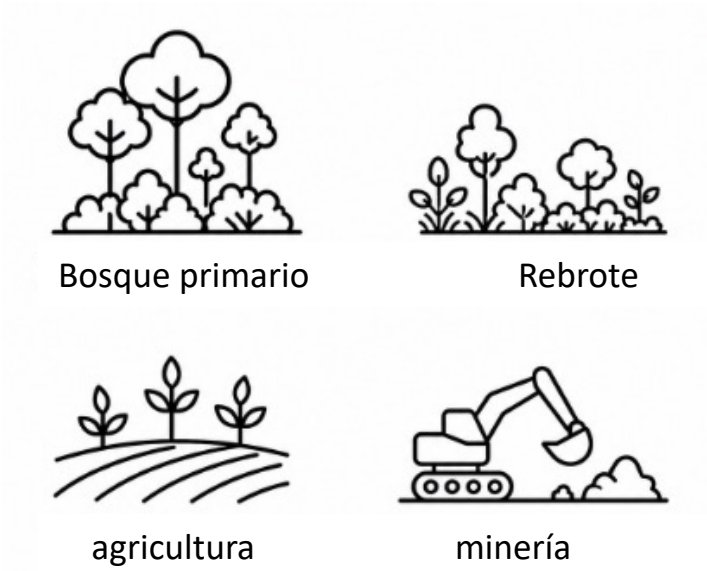
Es la **integración del contexto espacial y temporal** lo que hace a los Transformers especialmente prometedores para la teledetección.

Modelos fundacionales

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

Un **Transformer** es una **arquitectura** de red neuronal (el «motor»).
Un modelo fundacional (MF) es un **paradigma de entrenamiento** (una forma de construir modelos de propósito general adaptables a muchas tareas posteriores)

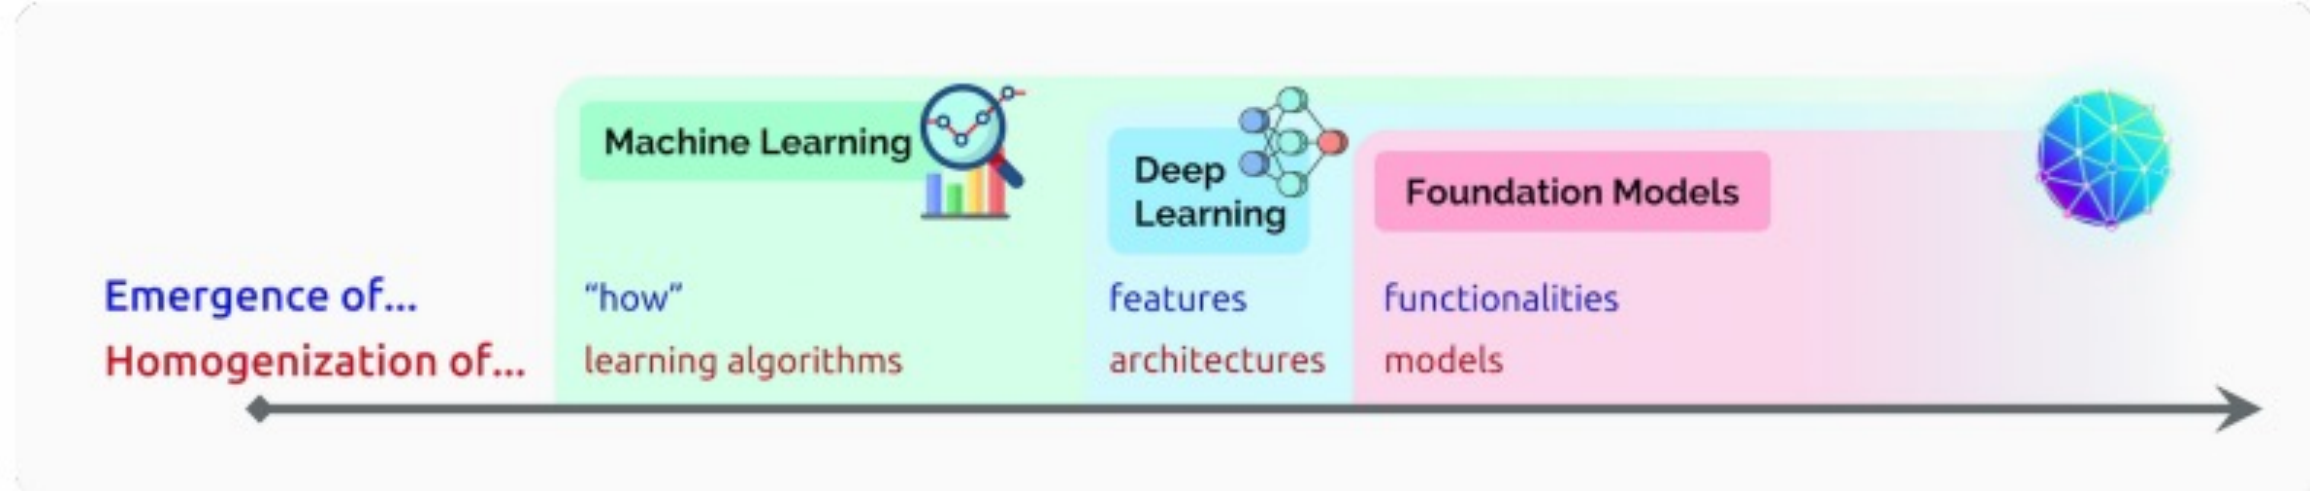




Preentrenamiento
En lugar de enseñar directamente al modelo que «**esto es un bosque**»,
el modelo aprende primero **conceptos más fundamentales** como texturas, patrones espaciales, relaciones espectrales, dinámica temporal, formas de objetos e información contextual.
Después, el modelo puede especializarse para una aplicación concreta.

Modelos fundacionales

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



«¿Cómo construir un modelo mejor para esta tarea?»

«¿Cómo adaptar un modelo de propósito general para resolver esta tarea lo mejor posible?»

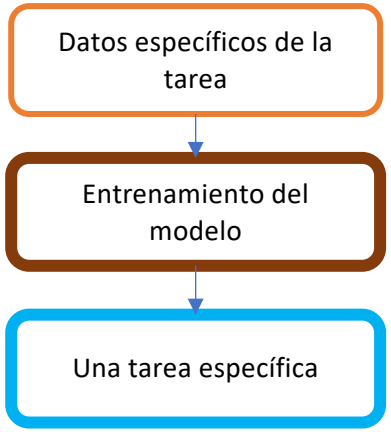
Un cambio de paradigma en la forma de desarrollar sistemas de IA

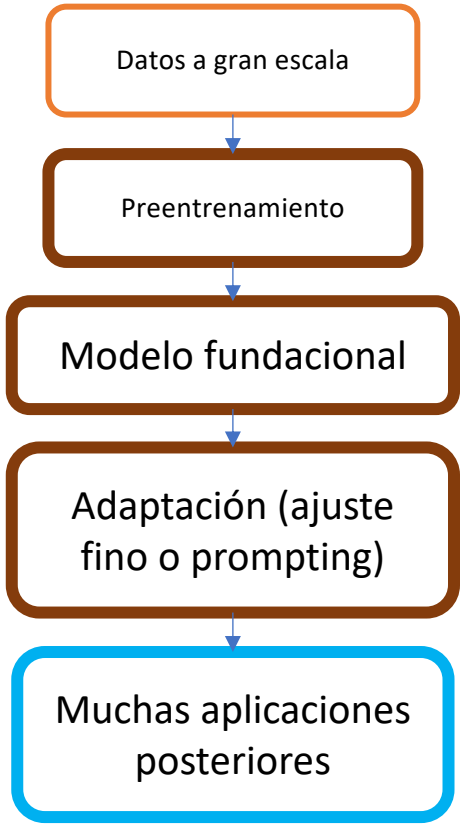


Modelos fundacionales

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

Un modelo entrenado con datos amplios y diversos, normalmente mediante aprendizaje autosupervisado a gran escala, que puede adaptarse a una gran variedad de tareas posteriores.





Aprendizaje autosupervisado

Ventajas:

- Reutilización del conocimiento: un solo modelo para distintas aplicaciones.
- Menor dependencia de datos etiquetados, gracias al preentrenamiento autosupervisado a gran escala.
- Mejor rendimiento que los modelos entrenados con datos específicos de la tarea.
- Transferencia de conocimiento entre dominios y aplicaciones.

- Innovación acelerada: los investigadores pueden centrarse en adaptar modelos preentrenados en lugar de desarrollar modelos nuevos desde cero.

Modelos fundacionales

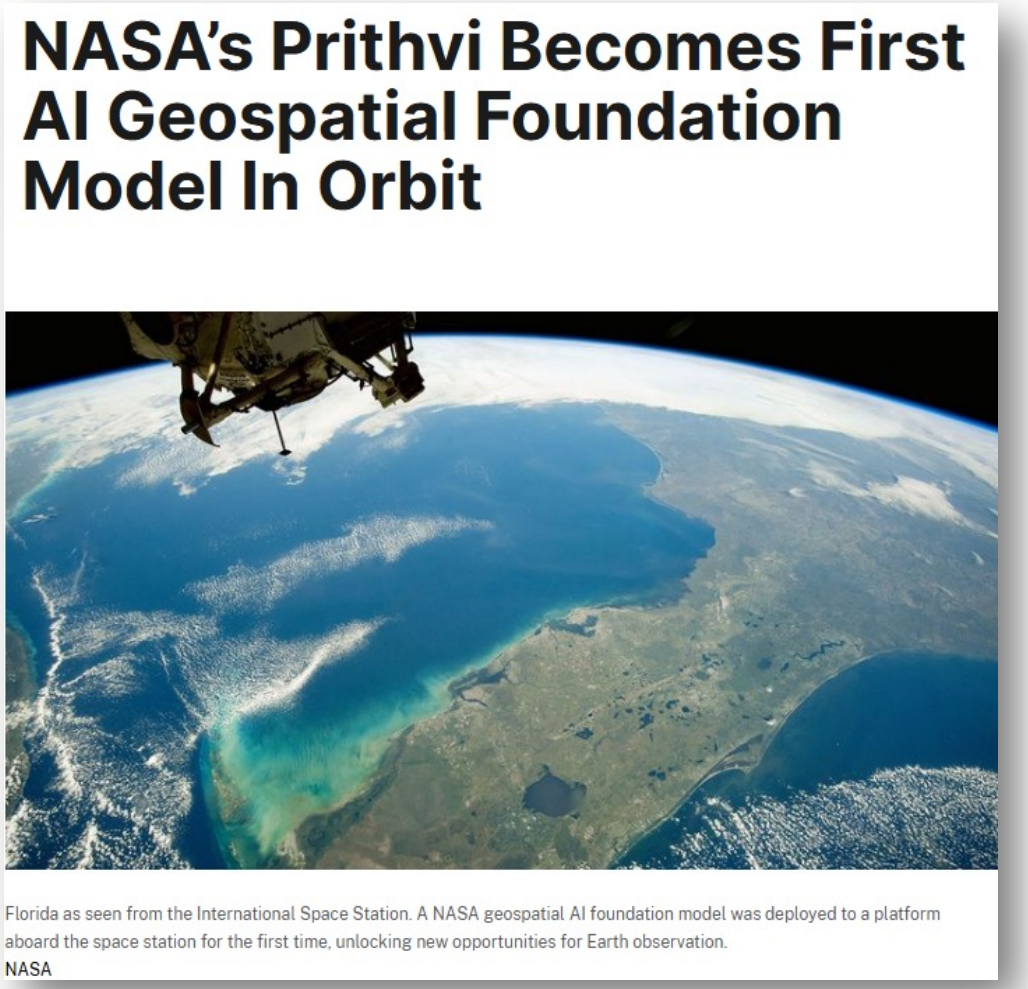
Retos

1. **Altos requisitos de datos y cómputo**
   Entrenamiento

   De millones a miles de millones de imágenes
   Cientos de millones (o incluso miles de millones) de parámetros
   Miles de GPU funcionando durante semanas o meses

   Pocas instituciones de investigación pueden entrenar un modelo fundacional desde cero
   La mayoría de los usuarios recurre a modelos preentrenados públicos y los ajusta para sus aplicaciones.

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



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

Modelos fundacionales

Retos

2. Generalización limitada - No generalizan perfectamente



Un modelo preentrenado con
- paisajes agrícolas de EE. UU.,
- ciudades europeas,
- bosques boreales,



puede rendir mal aplicado a la Amazonía,
la sabana africana,
los bosques de Nueva Zelanda

Los ecosistemas difieren en:
composición de especies,
clima,
características de los sensores,
fenología,
estructura de la vegetación.

Por eso, un buen rendimiento suele requerir aún
- ajuste fino,
- adaptación de dominio,
- datos de entrenamiento recogidos localmente.



Modelos fundacionales

Retos

3. Dependencia de los datos de preentrenamiento - depende de la diversidad del conjunto de preentrenamiento.

Hoy, los conjuntos de datos públicos contienen relativamente poca información sobre:

bosques tropicales,
bosques secundarios,
degradación forestal,
manejo forestal,
daños por incendios en distintas etapas de recuperación.

4. Interpretabilidad limitada – «cajas negras».

No pueden responder a preguntas sobre la contribución o importancia de las variables

Esta falta de transparencia complica

- la validación científica,
- la explicabilidad de los modelos,
- la confianza operativa.







Modelos fundacionales

Retos

5. Alto coste computacional en la inferencia - exigentes en cómputo, incluso tras el entrenamiento.

Limitaciones:

Grandes requisitos de memoria GPU,
inferencia lenta,
altos costes de computación en la nube,
escalabilidad limitada para sistemas operativos.

Algunos modelos actuales tienen cientos de millones de parámetros, lo que encarece computacionalmente su despliegue operativo a escala nacional.

6. Generalización entre sensores – preentrenamiento básico

Muchos modelos fundacionales están preentrenados con

- Sentinel-2,
- Landsat,
- imágenes RGB.

El monitoreo forestal se basa en

- Sentinel-1 SAR,
- LiDAR,
- GEDI,
- imágenes Planet,
- CBERS,
- imágenes hiperespectrales.

6. El modelado de series temporales sigue siendo un reto

Pocos modelos fundacionales aprovechan hoy de forma eficaz las largas series temporales de imágenes satelitales (AnySat, Prithvi)

Requiere un desarrollo activo.

Fronteras de investigación en el monitoreo forestal con IA



IA para las tareas de monitoreo forestal

Tarea	Principales métodos de IA
Mapeo forestal y clasificación de la cobertura del suelo	Bosques aleatorios, SVM, CNN, Vision Transformers
Detección de la deforestación	CNN, U-Net, redes siamesas, Transformers
Monitoreo de la degradación forestal	CNN, CNN temporales, LSTM, Vision Transformers
Recuperación y regeneración forestal	LSTM, GRU, Transformers temporales
Estimación de biomasa y carbono	Bosques aleatorios, gradient boosting, redes neuronales profundas
Detección de árboles individuales y caracterización del dosel	CNNs, Mask R-CNN, U-Net, YOLO
Perturbaciones forestales y detección de cambios	CNN siamesas, BIT, ChangeStar, Vision Transformers
Evaluación de incendios forestales	CNNs, DeepLab, Transformers
Monitoreo forestal casi en tiempo real	Transformers temporales, aprendizaje autosupervisado, modelos fundacionales
Análisis geoespacial de propósito general	Modelos fundacionales, IA multimodal

Clasificación de especies arbóreas

scientific reports

Manacá da Serra

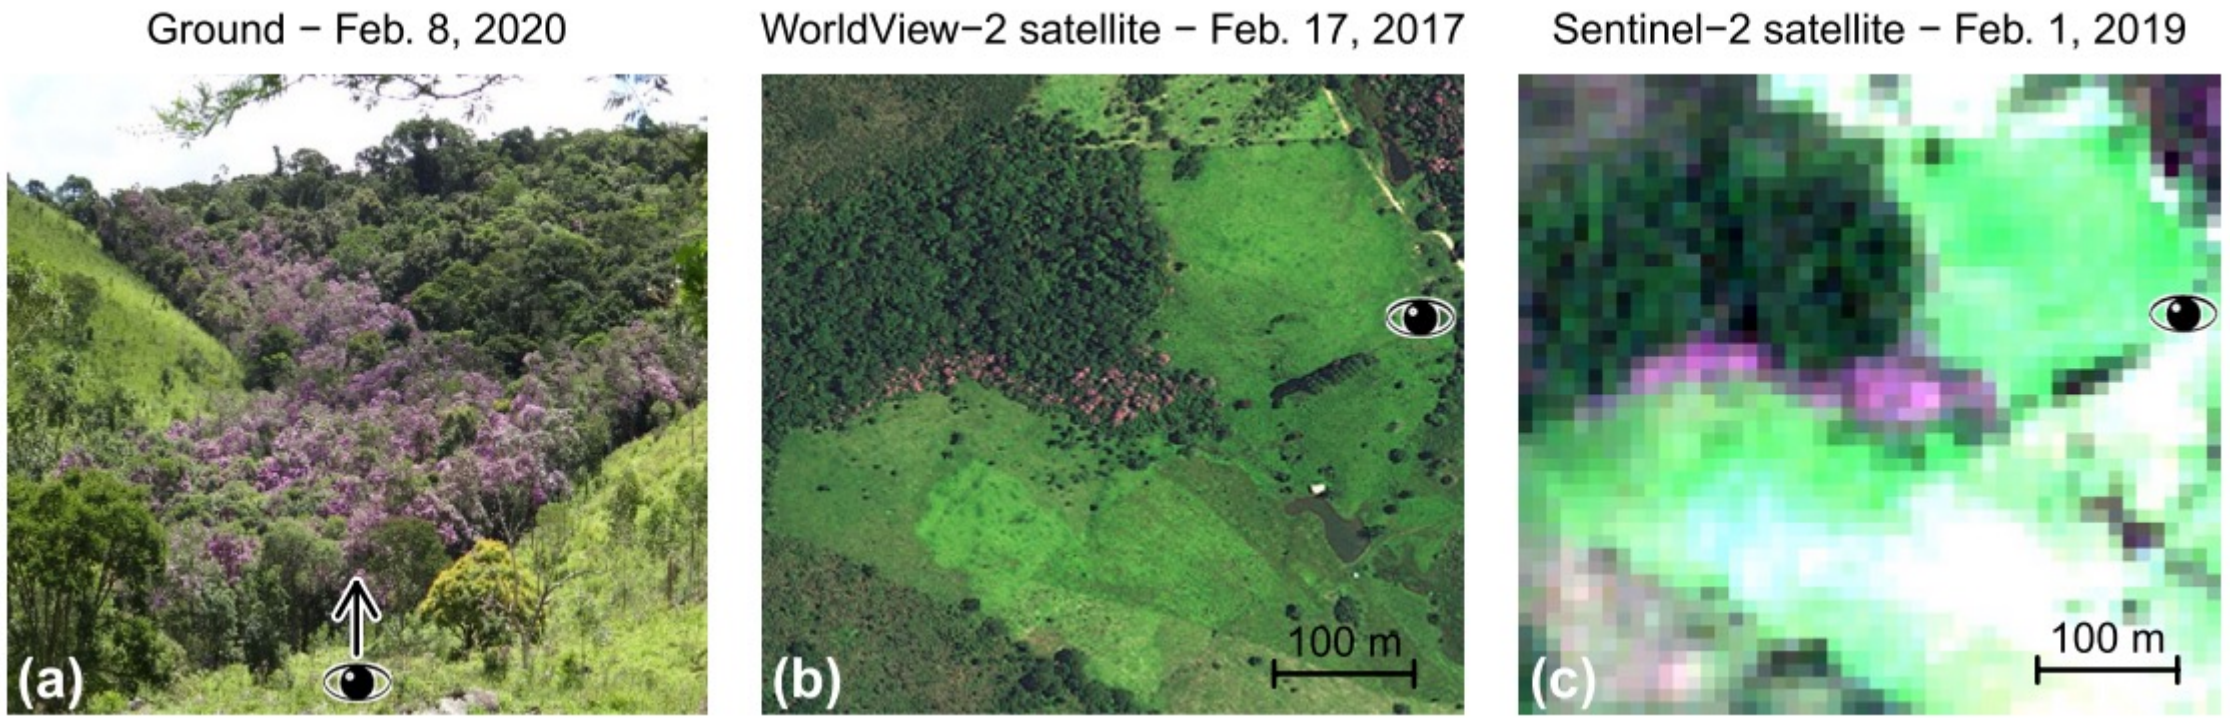


OPEN

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

El aprendizaje profundo (CNN) con series temporales Sentinel-2 (33 798 imágenes) puede mapear géneros de árboles en flor a escala de bioma.

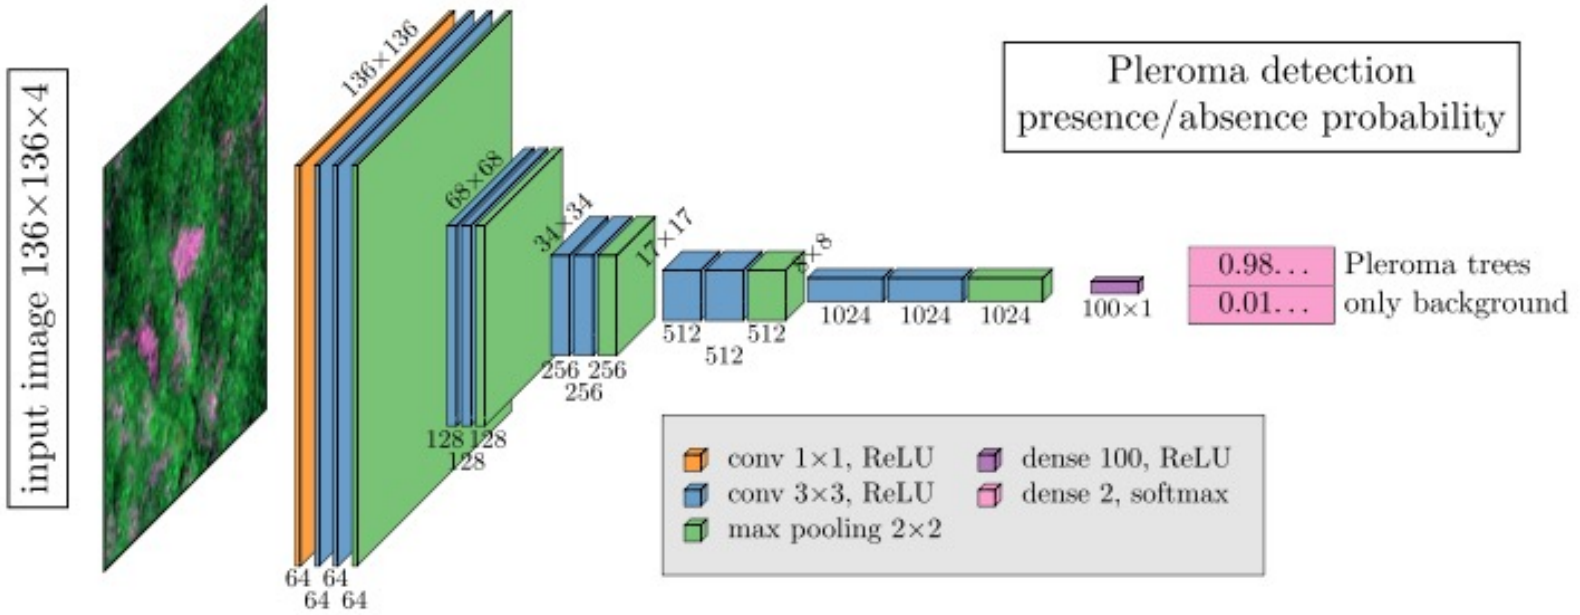


Figure 13. Architecture of the *Pleroma* blossom detection model.

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)

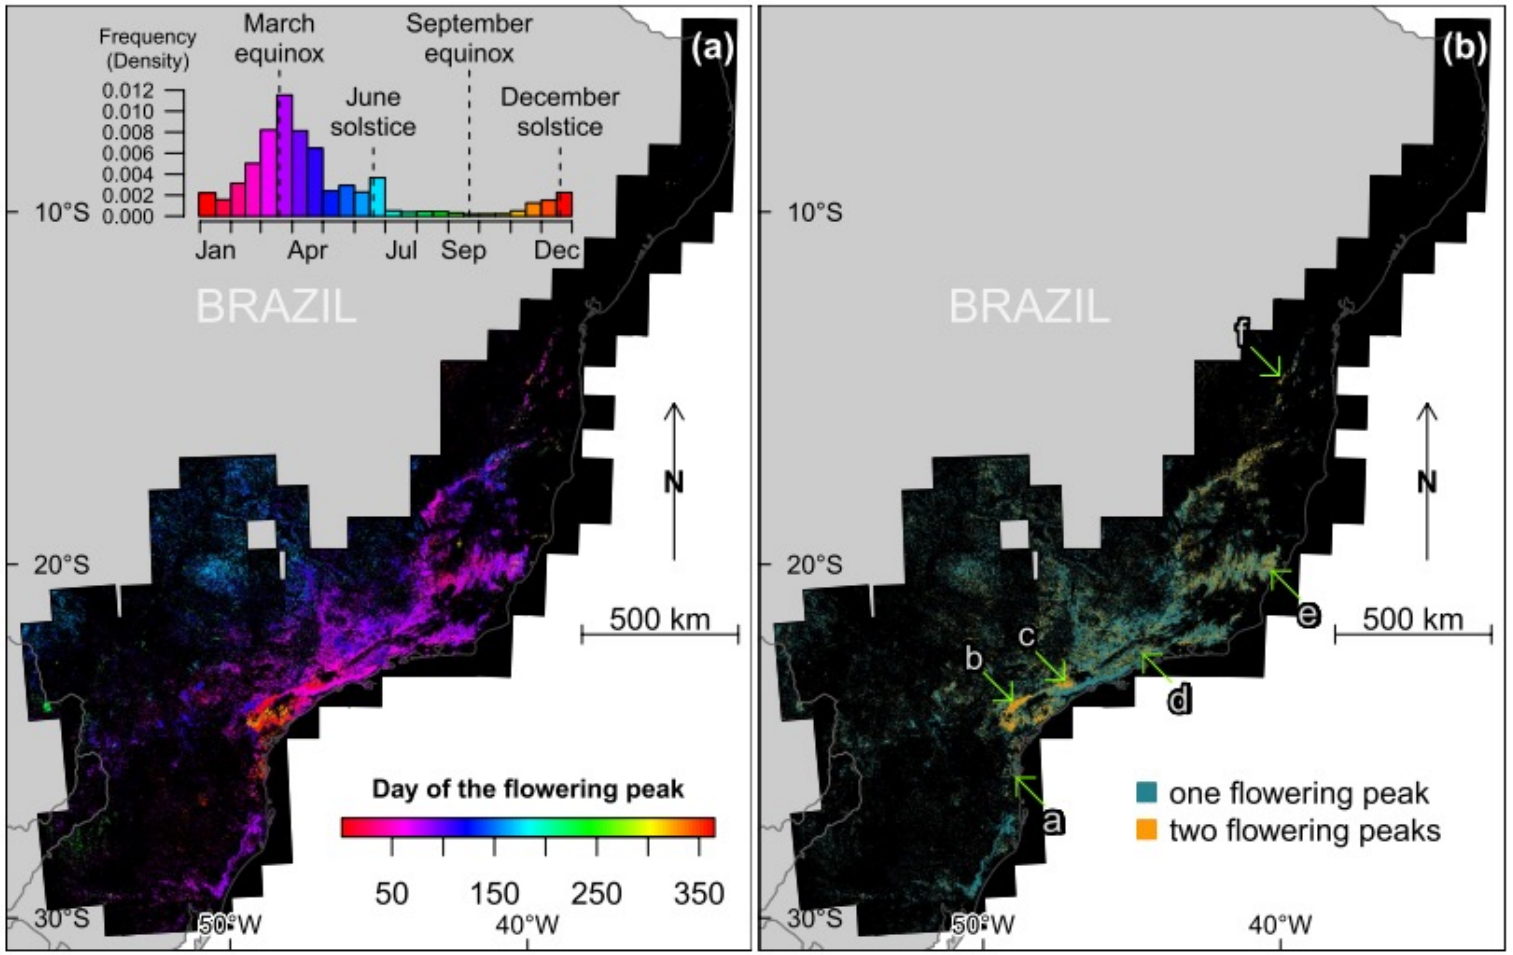
OPEN

The flowering of Atlantic Forest *Pleroma* trees

Fabien H. Wagner

comportamiento biológico estacional





eventos fenológicos (floración)

características muy discriminantes para el mapeo de especies con aprendizaje profundo

usando imágenes 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

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.)

Clasificación de especies arbóreas

Crear el **mayor conjunto de referencia** para la clasificación de **especies arbóreas** con **escaneo láser aerotransportado (ALS)** multiespectral y evaluar el rendimiento de algoritmos de **AA** y **AP** de vanguardia.

Conjunto de datos

- 6326 árboles etiquetados individualmente
- 9 especies arbóreas
- Dos conjuntos ALS multiespectrales con distintas densidades de puntos

Algoritmos comparados

- **Aprendizaje automático:** Random Forest, XGBoost, LightGBM, MLP
- **Aprendizaje profundo:** PointNet++, PointMLP, **Point Transformer**, DetailView

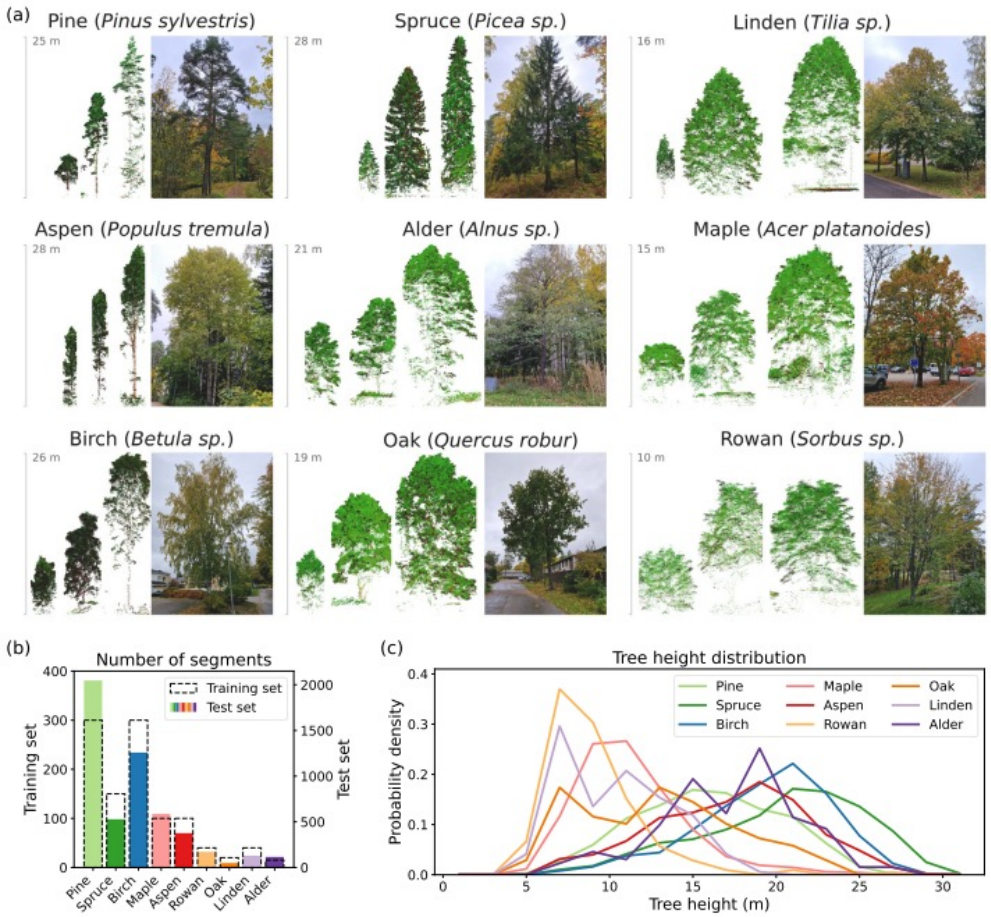
Taher et al. (2026)

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



Comparación de rendimiento

- **Point Transformer** logró la mayor precisión de clasificación (**~92 % de precisión global**).
- El aprendizaje profundo superó sistemáticamente al aprendizaje automático tradicional.
- La información multiespectral mejoró claramente la precisión frente a la geometría sola.
- Las mejoras fueron especialmente evidentes en:
  - nubes de puntos dispersas
  - conjuntos de entrenamiento más grandes
  - especies difíciles 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

Clasificación de especies arbóreas

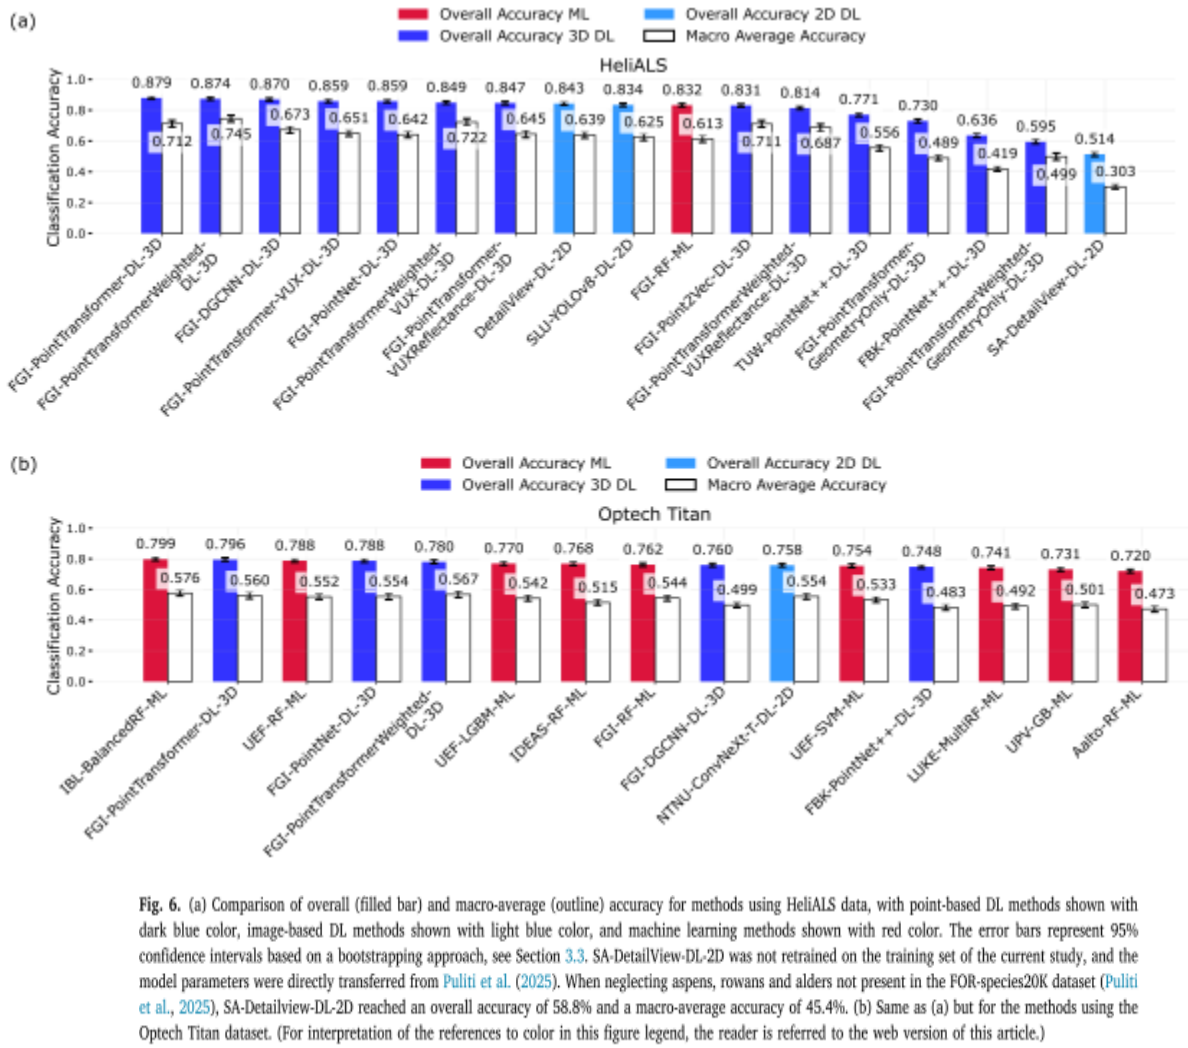


Fig. 6. (a) Comparison of overall (filled bar) and macro-average (outline) accuracy for methods using HeliALS data, with point-based DL methods shown with dark blue color, image-based DL methods shown with light blue color, and machine learning methods shown with red color. The error bars represent 95% 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.)

Principales contribuciones

- Primer conjunto de referencia completo que compara AA y AP para la clasificación de especies arbóreas con ALS multiespectral.
- Demuestra la superioridad de los **modelos basados en Transformers** frente a los enfoques tradicionales.
- Confirma la importancia de combinar información **estructural 3D** y **espectral** (para el entrenamiento).
- Ofrece un **conjunto de referencia abierto**, que favorece la investigación reproducible y el desarrollo de métodos de IA de nueva generación para el monitoreo forestal.

Evaluación de incendios forestales

Evaluación de incendios forestales

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

- Desarrollar un **marco de aprendizaje automático interpretable** para predecir las características de los incendios en las diversas regiones climáticas de Australia.
- Identificar los **impulsores ambientales** del comportamiento del fuego mediante **IA explicable (XAI)**.

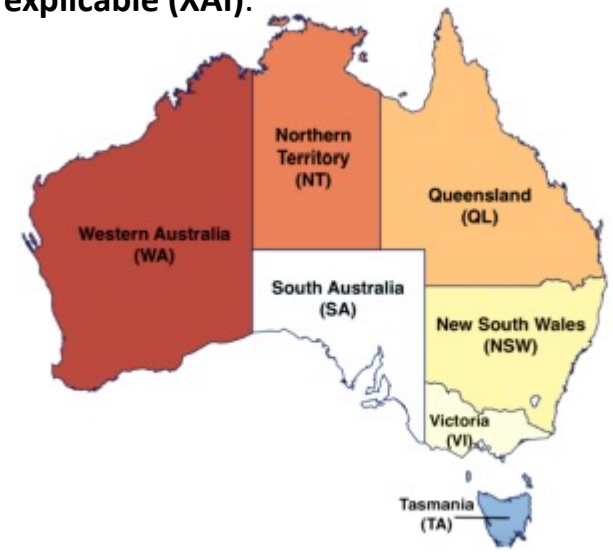


Figure 1. Study area: the seven Australian regions.

Metodología

Área de estudio: siete regiones australianas (2005-2021).

Datos de entrada:

- Variables climáticas ERA5 (temperatura, precipitación, humedad, velocidad del viento, humedad del suelo, radiación solar)
- Productos MODIS de fuegos activos

Variables de incendio predichas:

- Área del incendio (FA)
- Temperatura de brillo del incendio (FBT)
- Potencia radiativa del i

Modelos de aprendizaje auto

- Regresión Lasso
- Random Forest
- LightGBM
- XGBoost

Explicabilidad:

- SHAP (SHapley Additive exPlanations)
- Análisis de la importancia de las variables para cuantificar la contribución de cada una.

Innovación

Alto rendimiento predictivo con **interpretabilidad del modelo** identificación de los procesos físicos que controlan la ocurrencia y la intensidad de los incendios.

Evaluación de incendios forestales

Article

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

Principales resultados

La humedad del suelo, la radiación solar, la precipitación y la humedad relativa son los principales predictores de incendios.

La variabilidad climática y las condiciones extremas (varianza, mínimos y máximos) son **más informativas que las medias a largo plazo**.

La importancia de los predictores varía entre las zonas climáticas australianas:

- **Regiones áridas:** Lasso capta bien las relaciones lineales.
- **Regiones tropicales:** los ensambles de árboles (LightGBM, Random Forest, XGBoost) representan mejor las interacciones no lineales complejas.

Mejor rendimiento predictivo:

- **Área del incendio:** Tasmania (LightGBM)
- **Potencia radiativa:** Queensland (Lasso)

Potencia radiativa del incendio

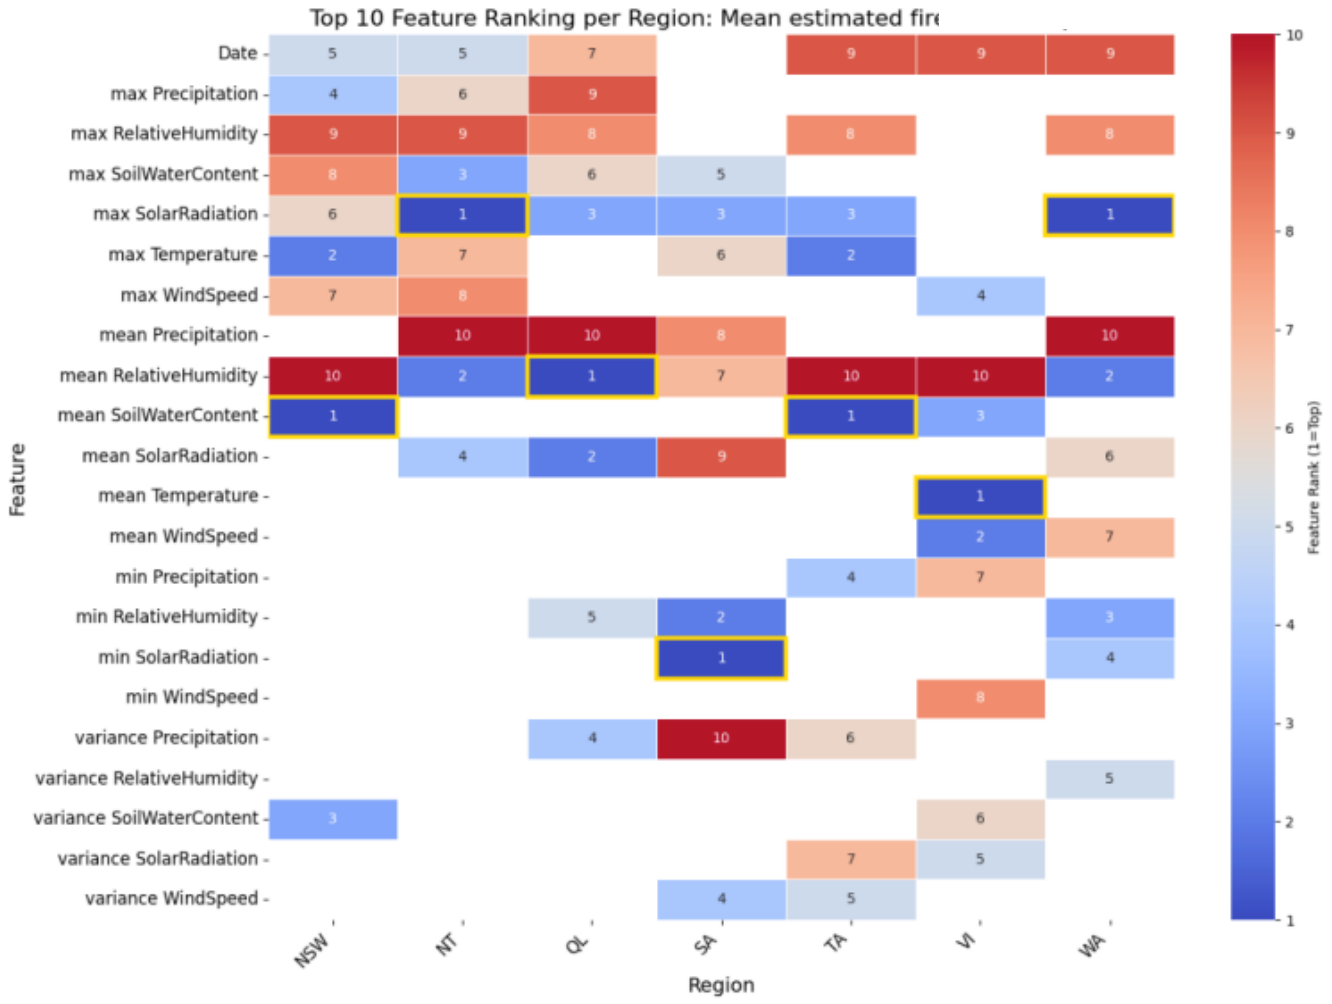


Figure 5. Top 10 features for each region's best model in predicting FRP, with 1 = Most Important to 10 = Least Important, and the yellow outline highlighting the top feature for that region.

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



Conclusiones clave

El comportamiento del fuego sigue un proceso jerárquico:

- **El estrés ambiental a largo plazo** (agotamiento de la humedad del suelo + radiación solar) determina el potencial de incendio.

- **La variabilidad meteorológica a corto plazo** (humedad, temperatura, viento) controla la ignición y la propagación.

La IA explicable aporta información transparente para una **gestión de incendios adaptada a cada región**, en apoyo de la adaptación climática y la toma de decisiones operativas.

Los trabajos futuros deberían integrar **modelos fundacionales, transformers, IA generativa y fusión de datos multifuente** para la predicción de incendios en tiempo 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

Desarrollar un **modelo eficiente de segmentación de incendios en tiempo real** para la vigilancia con video de drones.

Superar las limitaciones de los métodos basados en **CNN**, que a menudo no captan la información **temporal** ni localizan con precisión los **bordes del fuego**.

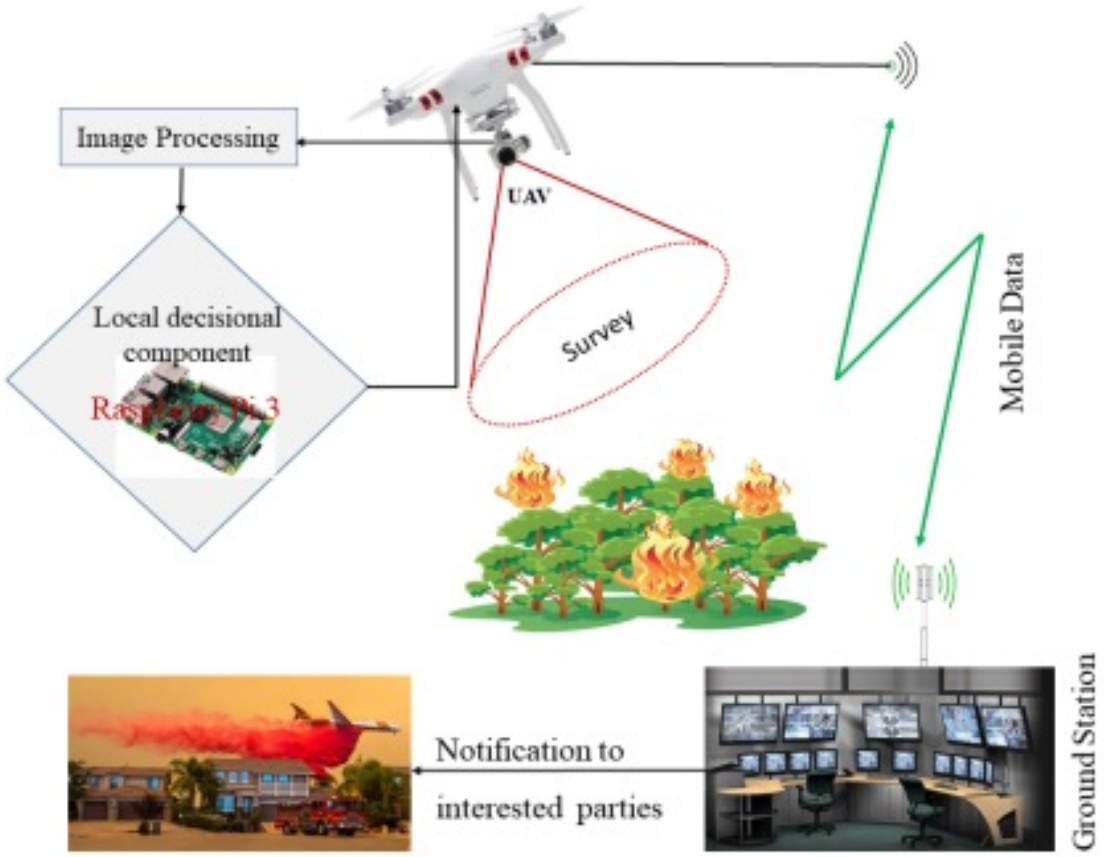


Figure 1. A conceptual model for early forest fire detection.

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,*]

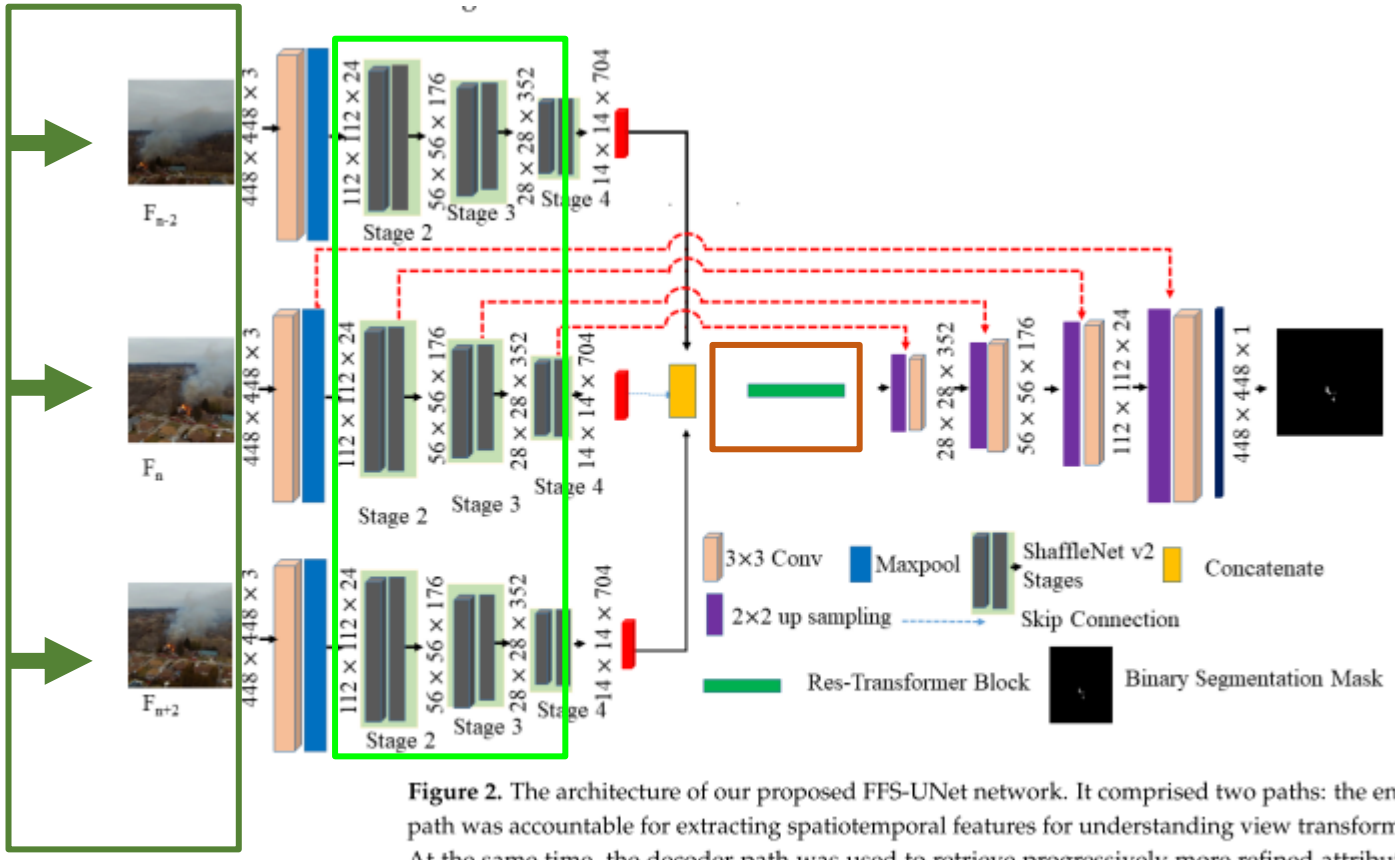


Figure 2. The architecture of our proposed FFS-UNet network. It comprised two paths: the encoder path was accountable for extracting spatiotemporal features for understanding view transformation. At the same time, the decoder path was used to retrieve progressively more refined attributes by combining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

Método propuesto: FFS-UNet

Nueva arquitectura **UNet + Vision Transformer (ViT)** para la segmentación semántica del fuego.

Tres ramas de codificador en paralelo procesan tres fotogramas consecutivos del dron (Fn−2, Fn, Fn+2) para aprender **información espacial y temporal**.

El módulo Transformer modela **dependencias temporales de largo alcance** y distingue mejor el fuego de objetos visualmente similares.

Una red troncal ligera **ShuffleNetV2** reduce el coste computacional y hace el modelo apto para **dispositivos de borde y drones**.

Una pérdida combinada **Dice + entropía cruzada binaria** mejora la segmentación con clases desequilibradas.

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],



Principales resultados y contribuciones

Rendimiento

Logró un **rendimiento de vanguardia** en conjuntos de datos de incendios grabados con drones:
(**IoU:** 86,8 %; **precisión:** 96,3 %, **exhaustividad:** 94,0 %, **F1:** 95,1 %, **exactitud:** 97,9 %)

Ventajas

Superó a **UNet, DeepLabV3+, TransUNet, Swin-UNet, SegFormer y STNet+DenseFire**.

Localización del fuego más precisa, con menos falsos positivos, sobre todo en escenas difíciles (humo, sombras, fondos recargados).

Mostró una fuerte **generalización** en el conjunto independiente Corsican Fire.

Robusto ante la degradación de imágenes (niebla, ruido gaussiano y desenfoque por movimiento).

Implementación ligera (**14,2 millones de parámetros**) a **66 FPS**, lo que permite un **despliegue en tiempo real en drones**.

La información temporal es crucial para detectar incendios.

Integrar **Vision Transformers** con **UNet** hace la segmentación de fuego más fiable que las CNN de imagen única y ofrece una solución práctica para la **vigilancia de incendios en tiempo real y la alerta temprana**.

Un ejemplo temprano de combinación de **Vision Transformers** y **segmentación semántica** para la **detección de incendios**

Innovación: el uso del **contexto temporal de los videos de dron**, en lugar de la clasificación o segmentación de imágenes aisladas.

INPE Programa Queimadas

El PROGRAMA QUEIMADAS del INPE investiga, desarrolla, opera y difunde sistemas de datos e información para el monitoreo de incendios de vegetación por satélite.

FOCOS DE FUEGO ACTIVOS

Muestra dónde están los fuegos activos casi en tiempo real con imágenes satelitales.

ÁREA QUEMADA

Determina la extensión de la vegetación afectada por el fuego.

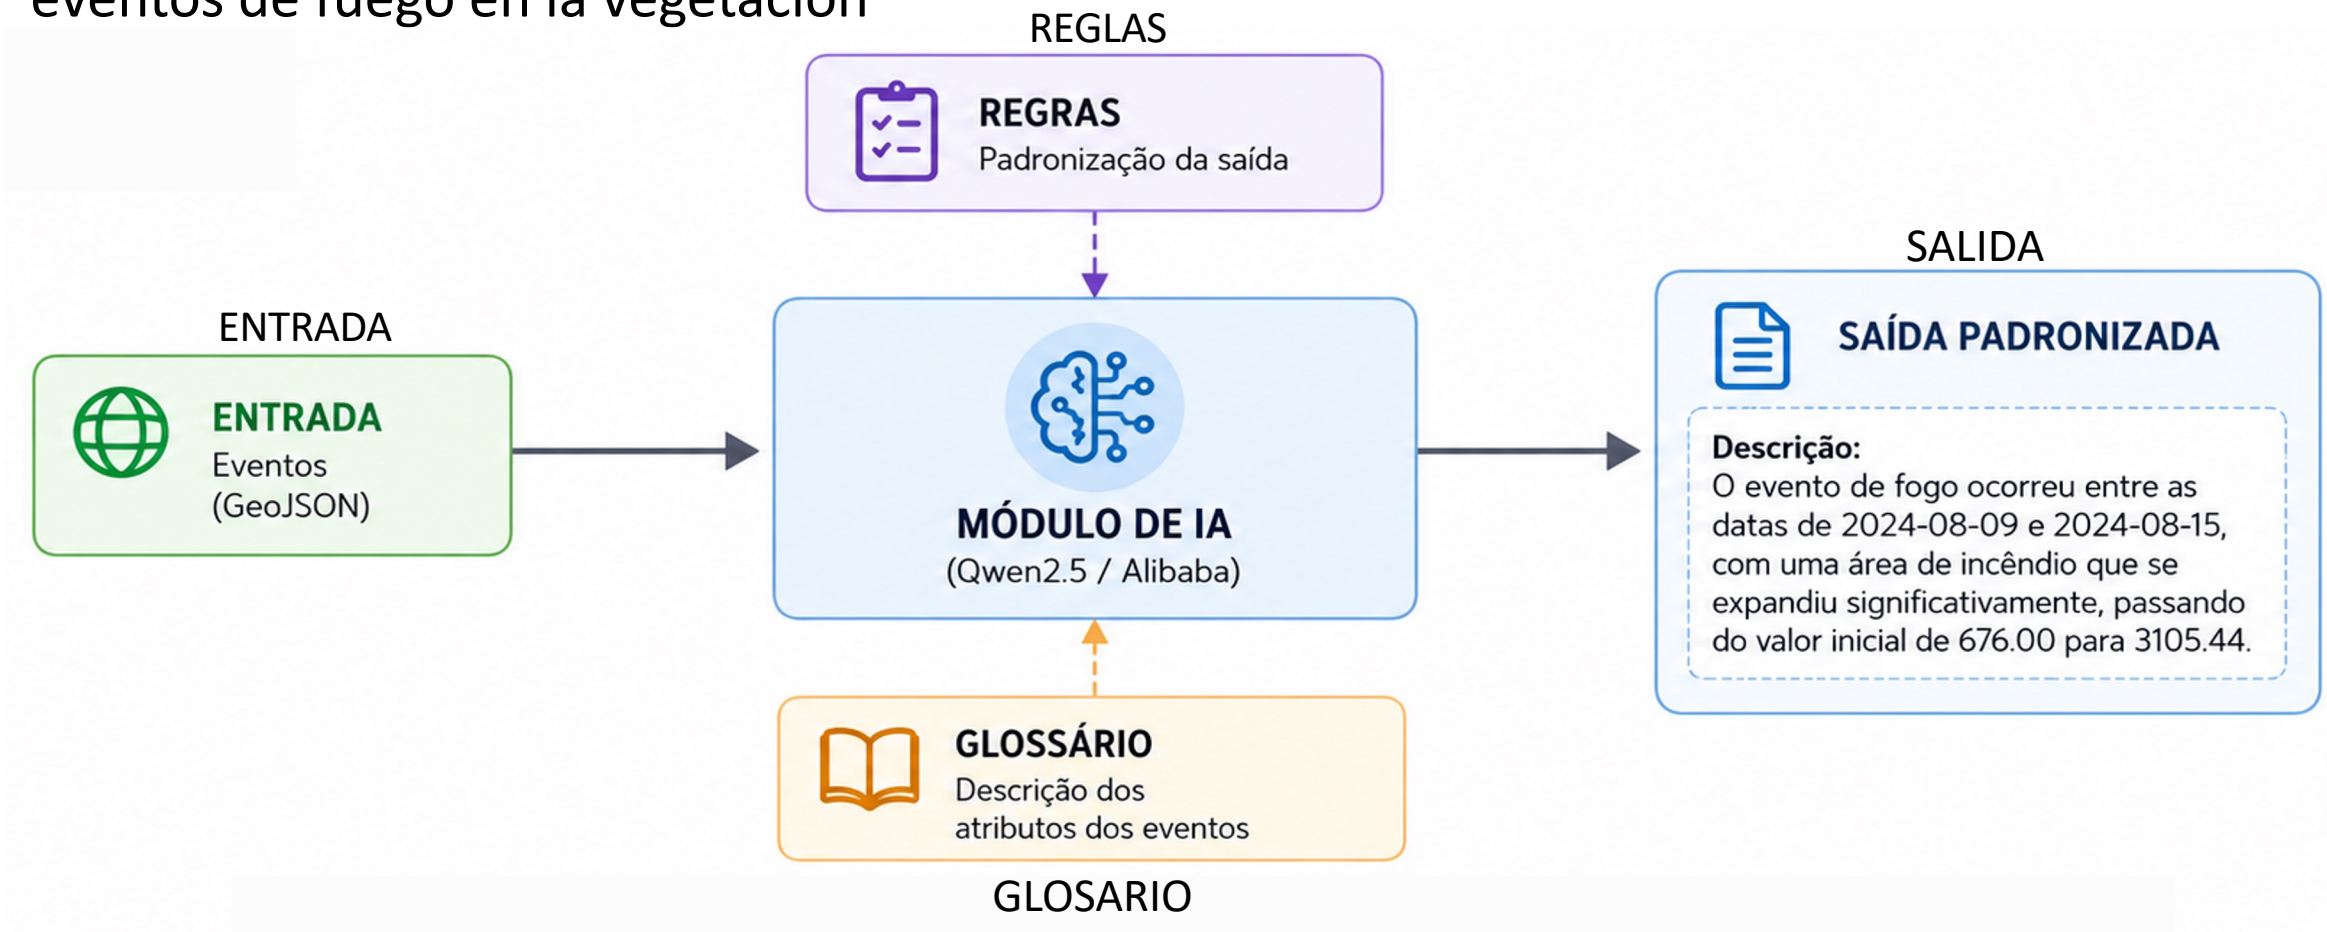
RIESGO DE INCENDIO

Previsión del riesgo de incendio de vegetación a partir de datos meteorológicos.



IA para caracterizar los incendios: **Descreve Fogo**

Generación de un texto consolidado que integra datos para describir regiones o eventos de fuego en la vegetación



IA para caracterizar los incendios: **Descreve Fogo**

Ejemplos de información generada por **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.

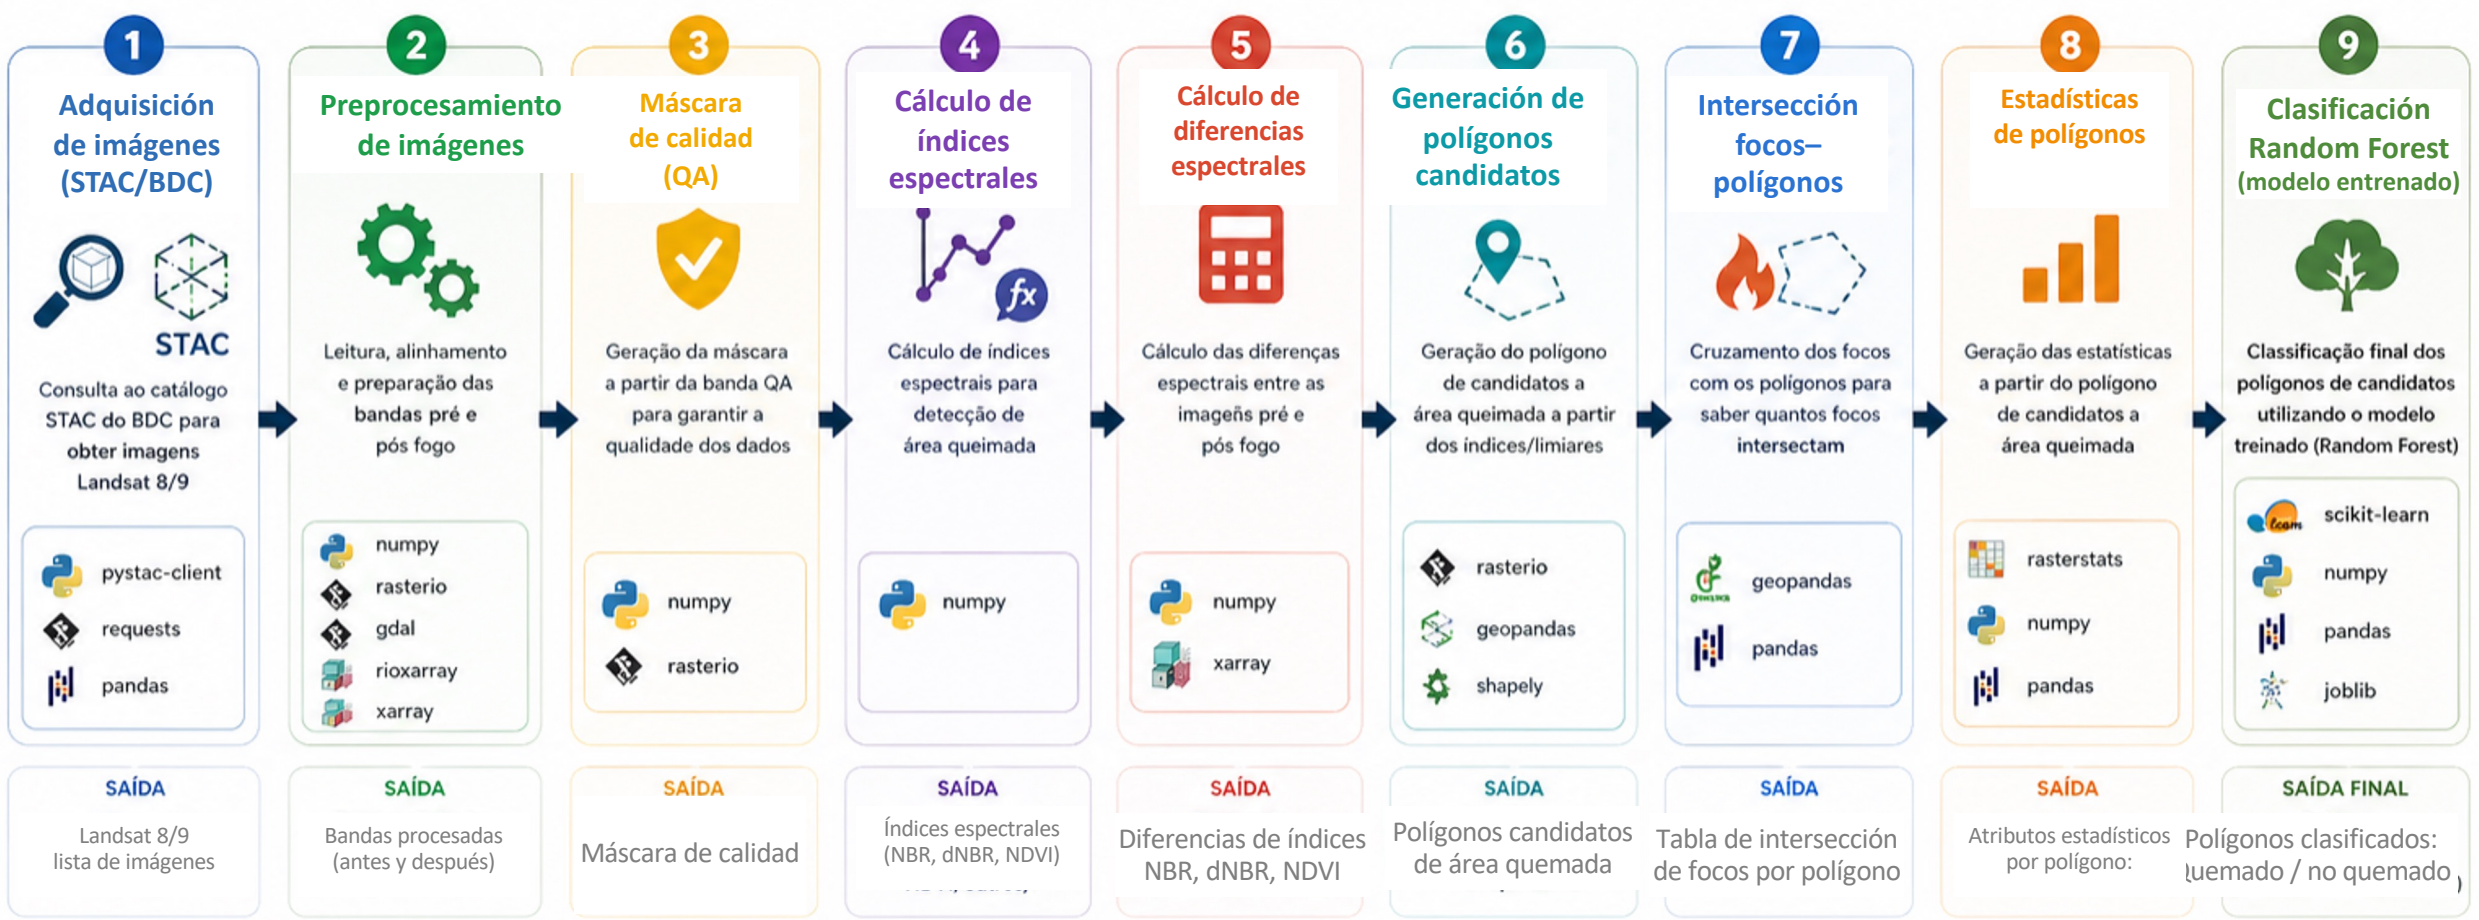
Quantidade de frentes
91 frentes
Média na região: **48** frentes
Posicionado entre os **100%** maiores

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

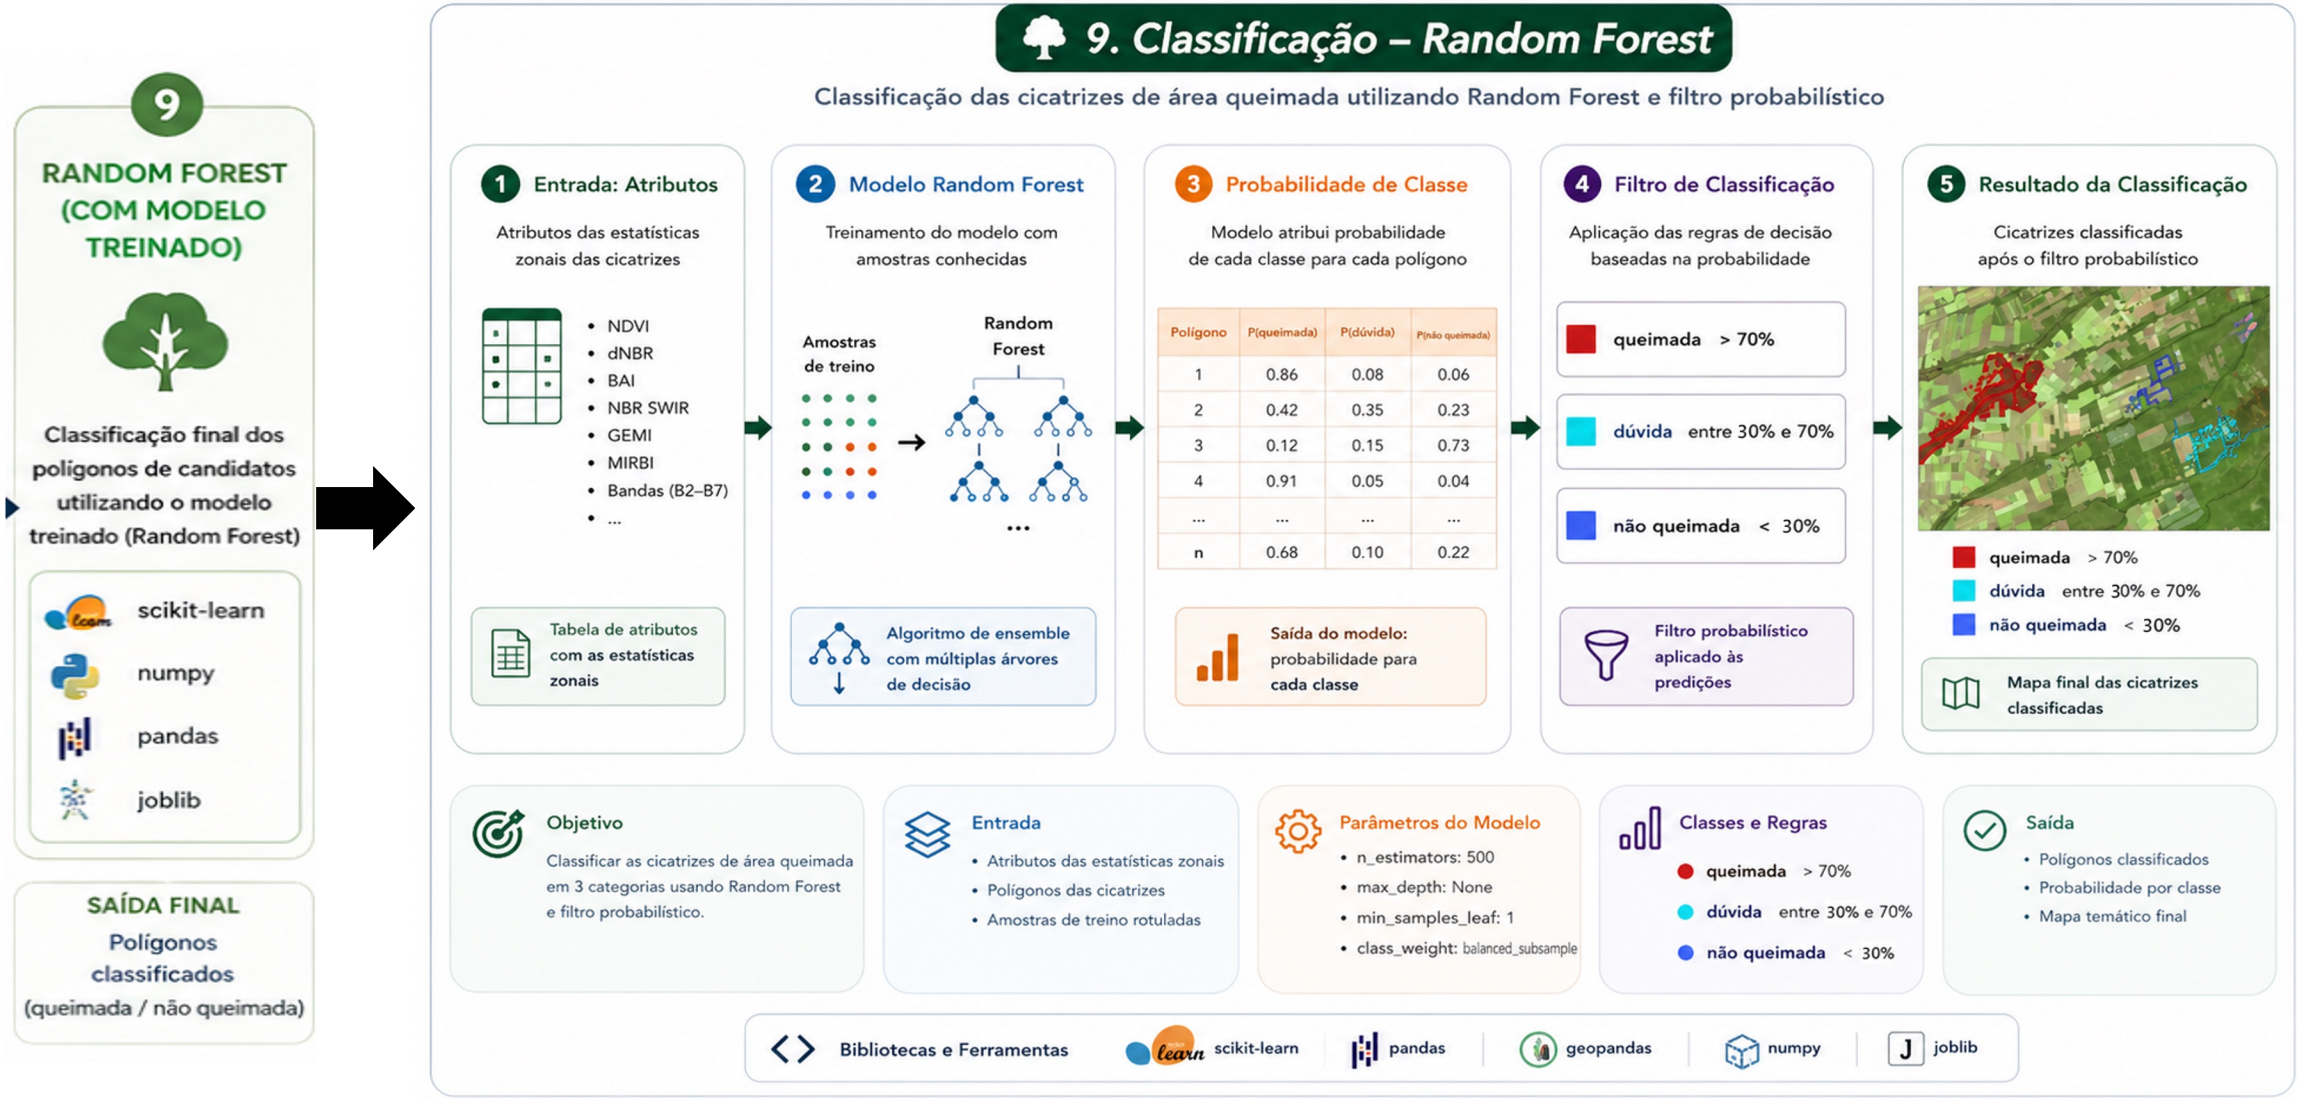
Área afetada
12.427,93 ha
Média na região: **7.177,11** ha
Posicionado entre os **100,0%** que afetam as maiores áreas

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 quemadas en el BDC



Metodología de control de calidad de los datos puestos a disposición de los usuarios.





IA-FogoBio

Instituto Federal do Amazonas (IFAM)



Foto: CARL DE SOUZA/AFP

Redes neuronales LSTM (Long Short-Term Memory), redes convolucionales y Random Forest

Historial de incendios de los últimos 20 años, vegetación, tipo de suelo y condiciones ambientales zonas con mayor riesgo de incendio.

Zonas de riesgo (7-14 días) y alertas (6 horas)

Ibama / ICMBio Tiempo para planificar el despliegue de brigadistas, equipos y rutas de acción preventiva

Vigila el 100 % de las tierras indígenas, unidades de conservación y territorios quilombolas del bioma amazónico

Financiado por Google.org con 1,9 millones de reales

Hub de Innovación del IFAM / Centro Gestor y Operativo del Sistema de Protección de la Amazonía (Censipam)

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

Estimación de biomasa y carbono

Biomasa y carbono: evolución

La biomasa aérea (AGB), variable climática esencial

La estimación de la biomasa forestal ha pasado de modelos empíricos locales a enfoques globales basados en IA que integran teledetección y observaciones de campo.

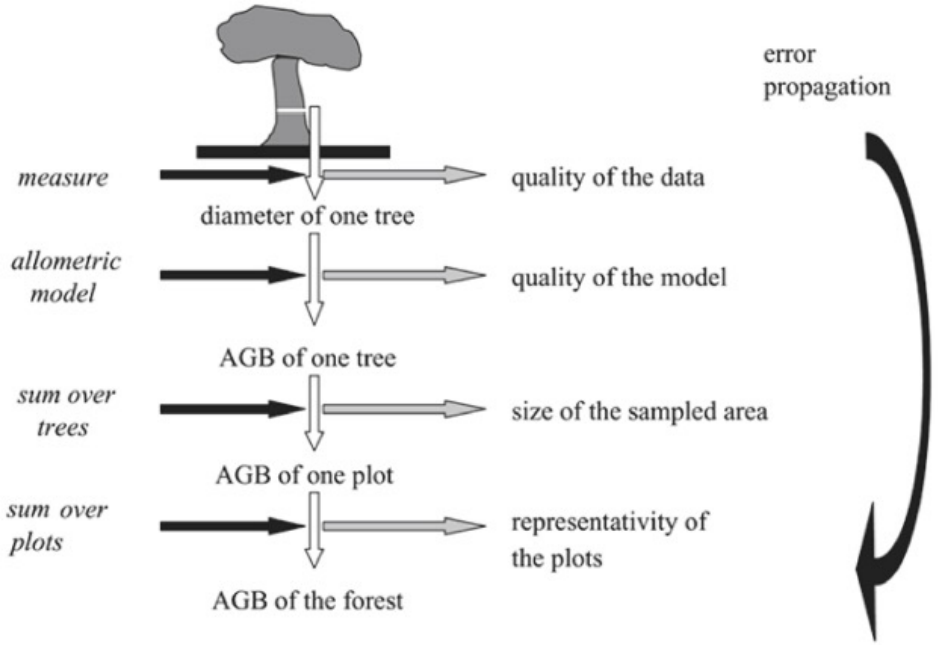


Fig. 1. Procedure for biomass estimation in plots and its error propagation (Rodríguez et al., 2017).

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

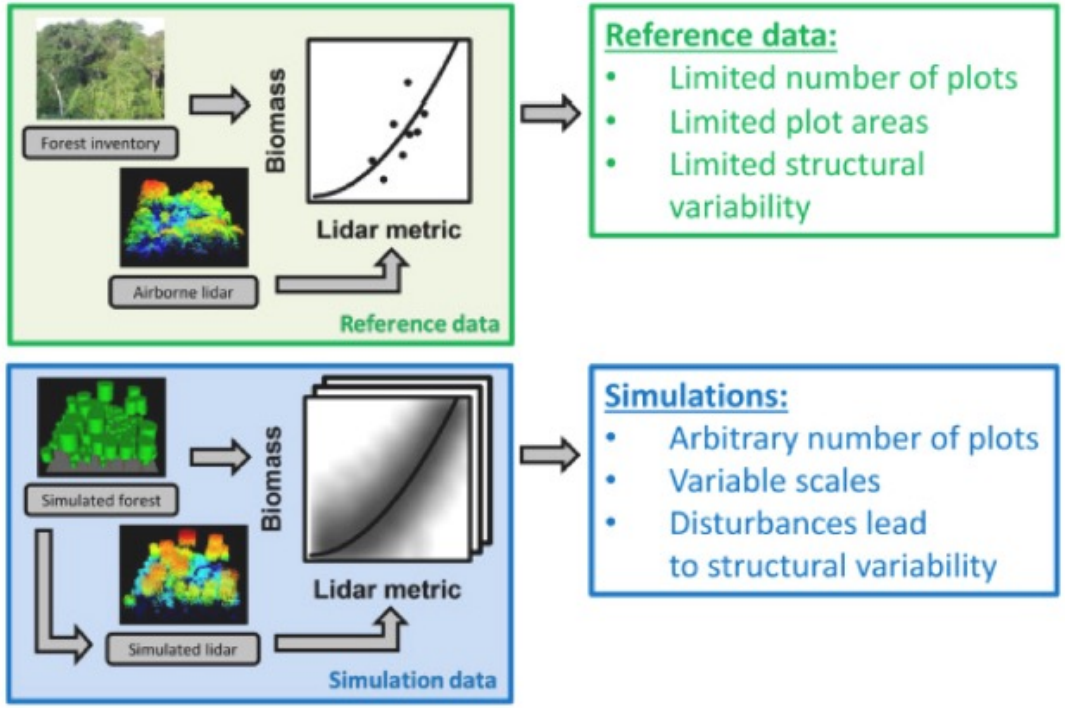


Fig. 2. Use of LiDAR data for biomass estimation (Knapp et al., 2018).

Biomasa y carbono: evolución

Inventarios forestales → teledetección → inteligencia artificial

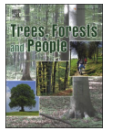
Variables ambientales y biomasa:
AA (Random Forest, SVM, redes neuronales artificiales) y AP superan a los métodos estadísticos convencionales.

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 estadísticos → Random Forest / XGBoost → Aprendizaje profundo (CNN) → Vision Transformers → Modelos fundacionales → Modelos a escala global

La IA está transformando la estimación de biomasa y carbono forestal **de modelos específicos de cada sitio a sistemas de predicción escalables y aplicables a escala global.**

Fusión de datos multisensor, IA explicable (XAI), LiDAR espacial y computación en la nube

Integración de datos

Óptico + SAR + LiDAR mejora la estimación de la AGB más que un solo algoritmo de IA

La teledetección multifuente importa más que cualquier algoritmo

forests

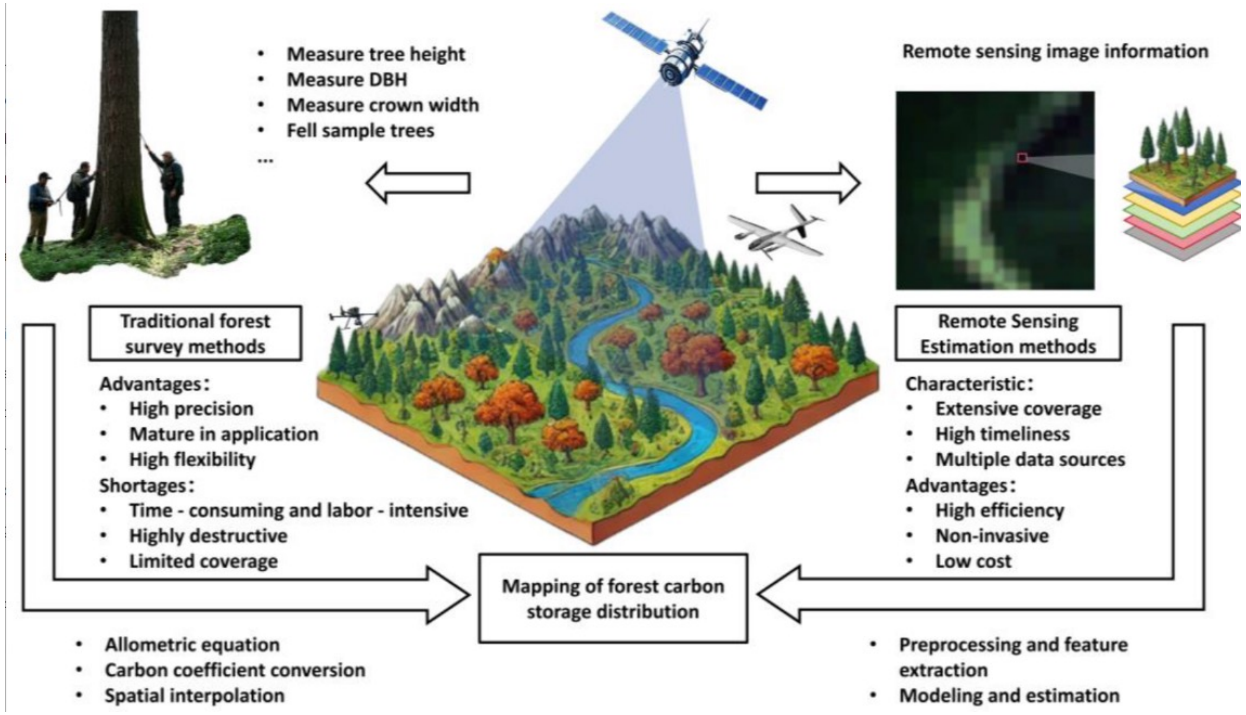
MDPI

Review

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

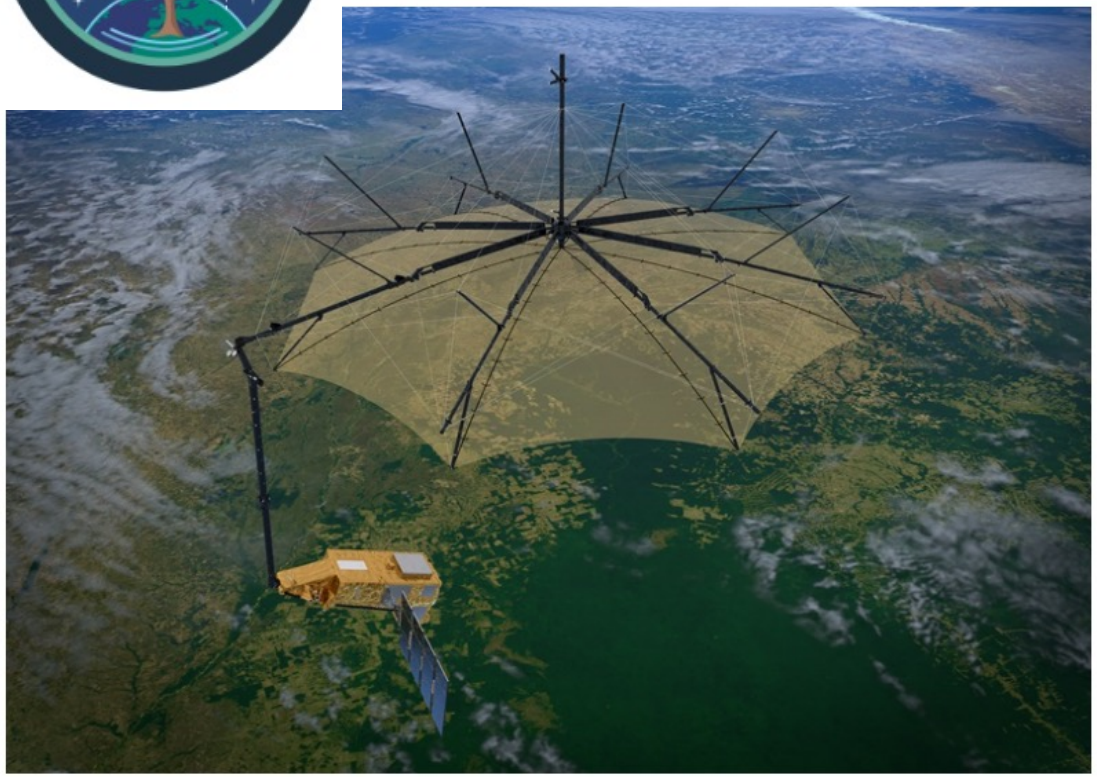
Weifeng Xu [1,†], Yaofei Cheng [2,†], Mengyuan Luo [3], Xuzhi Mai [4], Wenhuan Wang [3,4], Wei Zhang [4,*] and Yinghui Wang [3,4,*]

(2025)

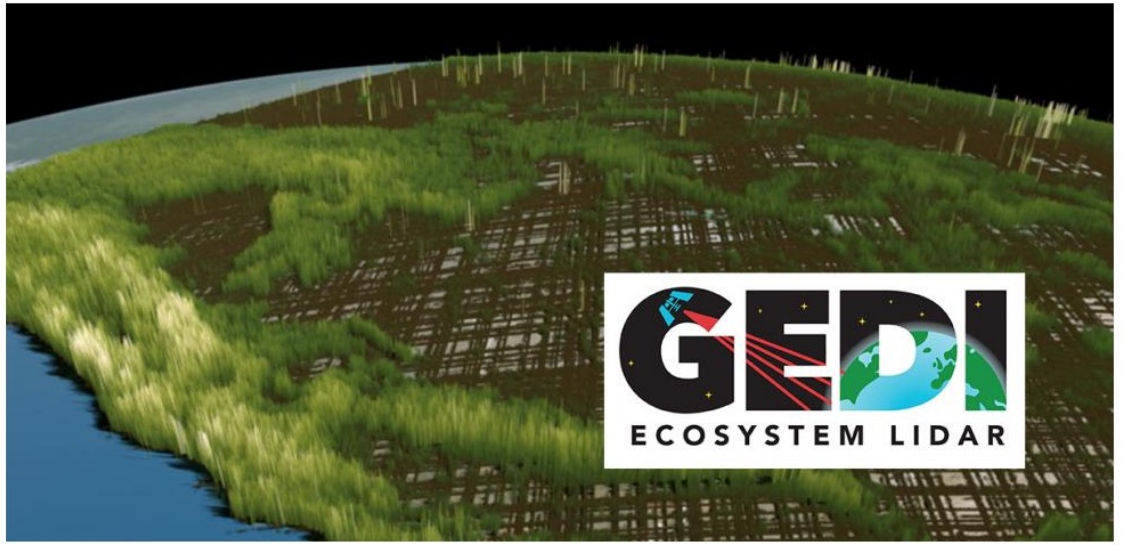


Perspectivas

- Mayor integración de las **misiones LiDAR espaciales** (GEDI, ICESat-2).
- Mayor uso de la **inteligencia artificial** y de enfoques de modelado híbridos.
- Desarrollo de **modelos globales transferibles** capaces de generalizar entre ecosistemas.
- Mejor **evaluación de la incertidumbre** y **protocolos de validación estandarizados**.
- Se espera que los **modelos fundacionales** emergentes y el aprendizaje autosupervisado mejoren la estimación del carbono aprovechando grandes conjuntos de datos multimodales de observación de la Tierra.



BIOMASS – la misión forestal de la ESA



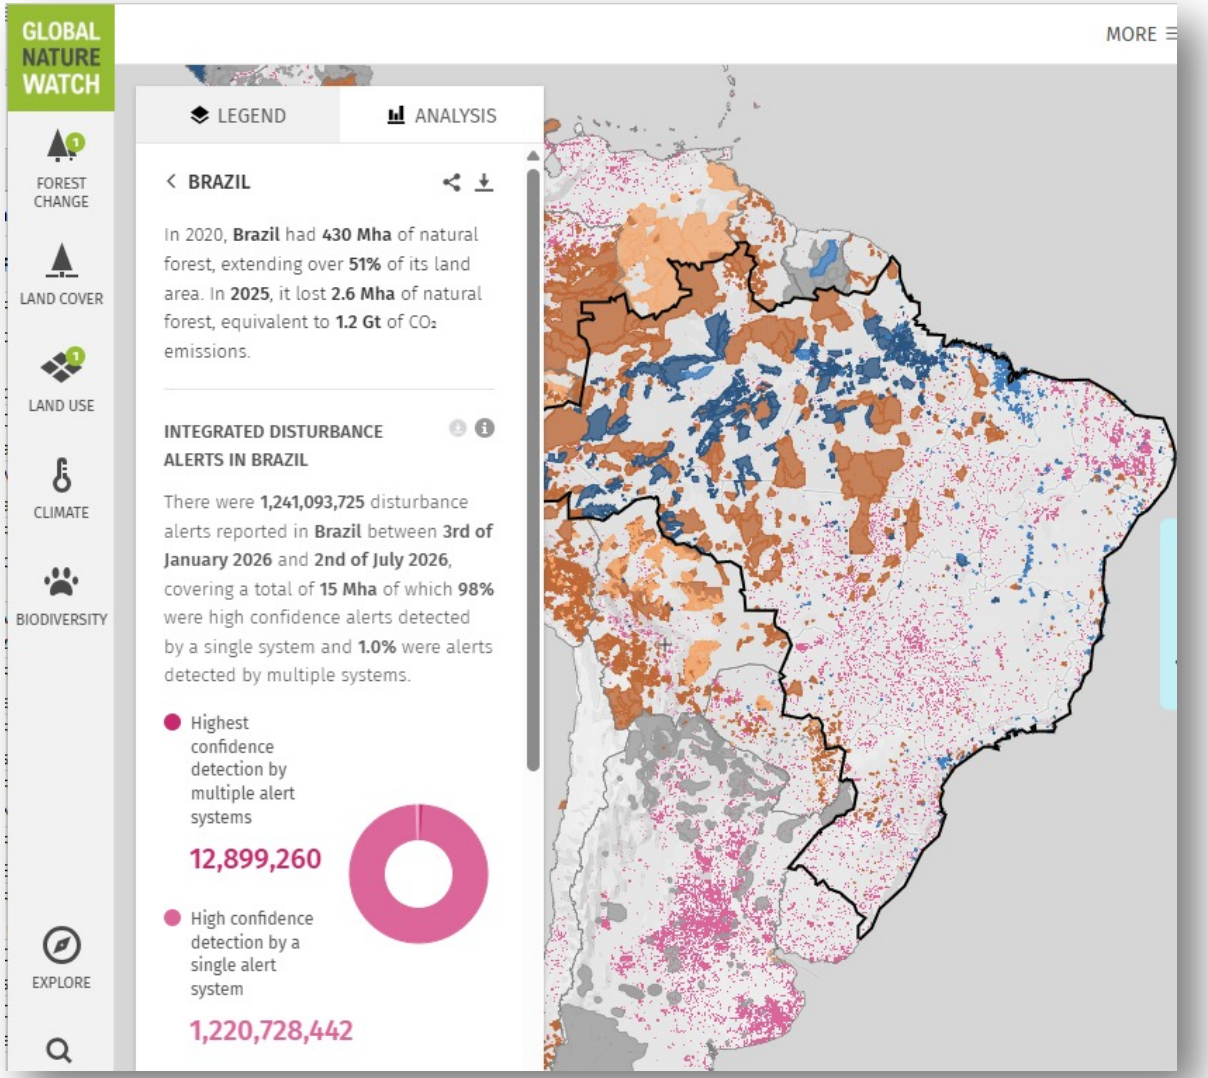
Global Ecosystem Dynamics Investigation Lidar (GEDI Lidar)

IA para los bosques en otros lugares, como….
¿ÁFRICA?

Iniciativa	Alcance geográfico	Aplicación principal	Uso de la IA	Fuentes de datos
FAO AIM4Forests	Panafricana (p. ej., RDC, Ghana, Kenia, Uganda)	Sistemas nacionales de **monitoreo** forestal (SNMF), **REDD+**, contabilidad de **carbono**	**Aprendizaje automático** para mapeo forestal, estimación de biomasa, detección de cambios y apoyo a la decisión	Sentinel-1, Sentinel-2, Landsat, GEDI, inventarios de campo
Open Foris / SEPAL (FAO)	Panafricana	Monitoreo **forestal** operativo, mapeo de la cobertura del suelo, evaluación de la deforestación	**Clasificación con aprendizaje automático**, **flujos de IA en la nube**, modelado del riesgo de deforestación	Landsat, Sentinel, Planet (si está disponible), datos de campo
SERVIR Africa (NASA–USAID)	Varios países africanos	Monitoreo **forestal**, detección de incendios, **restauración**, evaluación de la **biomasa**	**Aprendizaje automático** para clasificación de la cobertura del suelo, detección de la degradación y modelos ambientales predictivos	Datos ópticos, SAR, climáticos y geoespaciales
Global Forest Watch Africa (WRI)	Panafricana	Alertas de deforestación casi en tiempo real y **monitoreo** de cambios forestales	**Detección de cambios asistida por IA**, modelos predictivos de deforestación, evaluación de riesgos	Landsat, Sentinel, radar, datos espaciales auxiliares
Programas de monitoreo forestal de la cuenca del Congo	África central	Cobertura forestal, **biomasa, existencias de carbono,** monitoreo de la **tala** ilegal	**Aprendizaje automático** para estimación de biomasa, clasificación de la cobertura del suelo, detección de cambios	Sentinel-1, Sentinel-2, Landsat, LiDAR, parcelas de campo
IA para el monitoreo de paisajes cacaoteros	Ghana, Côte d'Ivoire	**Monitoreo de la deforestación ligada al cacao y cumplimiento del EUDR**	**Aprendizaje profundo**: segmentación de imágenes, clasificación del uso del suelo, detección de cambios	Sentinel-1, Sentinel-2, imágenes de alta resolución
Regreening Africa (CIFOR-ICRAF)	África oriental y occidental	Planificación de la **restauración** de paisajes forestales y la **agroforestería**	**Asistida por IA**: planificación de la restauración, modelado de idoneidad de especies, monitoreo de la restauración	Imágenes satelitales, clima, suelos, observaciones de campo
M-Situ	Kenya	Detección de **tala** ilegal e incendios forestales	**IA embarcada** para detectar eventos acústicos (motosierras, disparos, incendios) con alertas automáticas	Sensores acústicos (IoT), IA en el borde
Iniciativa de investigación Miti360	Kenya	**Monitoreo de la** reforestación **e inventario de árboles**	**Aprendizaje profundo** para detección de árboles, delimitación de copas, seguimiento del crecimiento	Imágenes de dron, datos de campo, observaciones meteorológicas

IA y monitoreo forestal - GFW

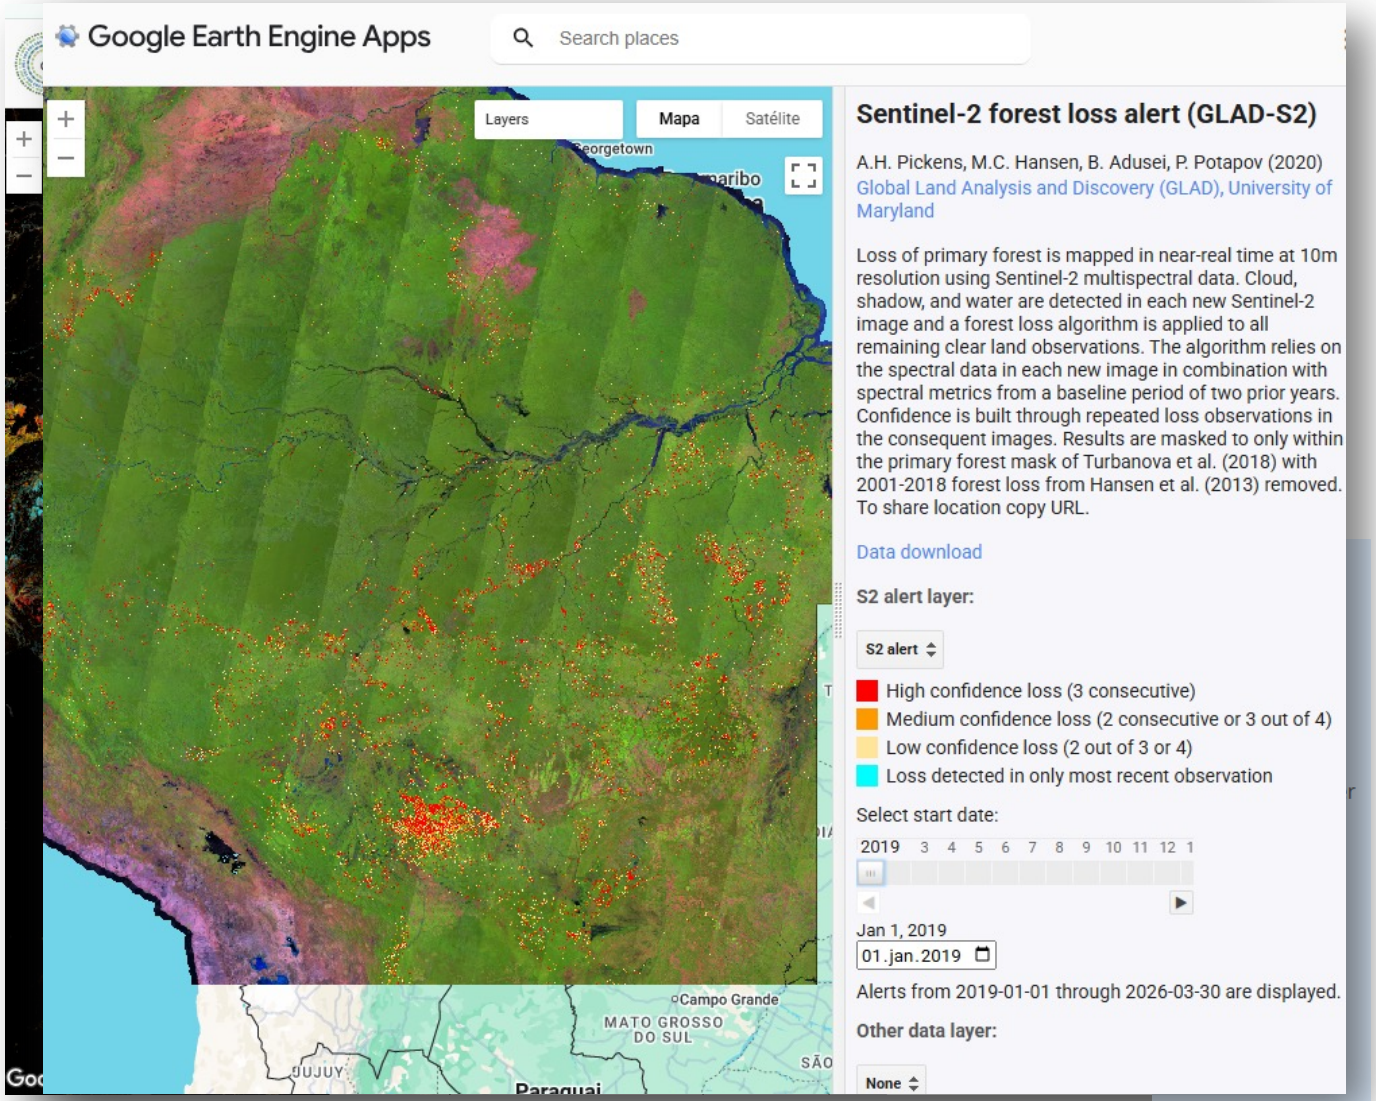
Sistema de monitoreo	Global Forest Watch (GFW)
Región	Mundial
Principales métodos de IA / análisis	Random Forest, detección temporal de cambios, aprendizaje automático, integración creciente de productos de aprendizaje profundo de instituciones asociadas
Principales aplicaciones	Alertas de pérdida forestal, extensión forestal, monitoreo de cambios forestales
Datos de teledetección	Landsat, Sentinel-1/2, Planet



https://www.globalforestwatch.org/

IA y monitoreo forestal - GLAD

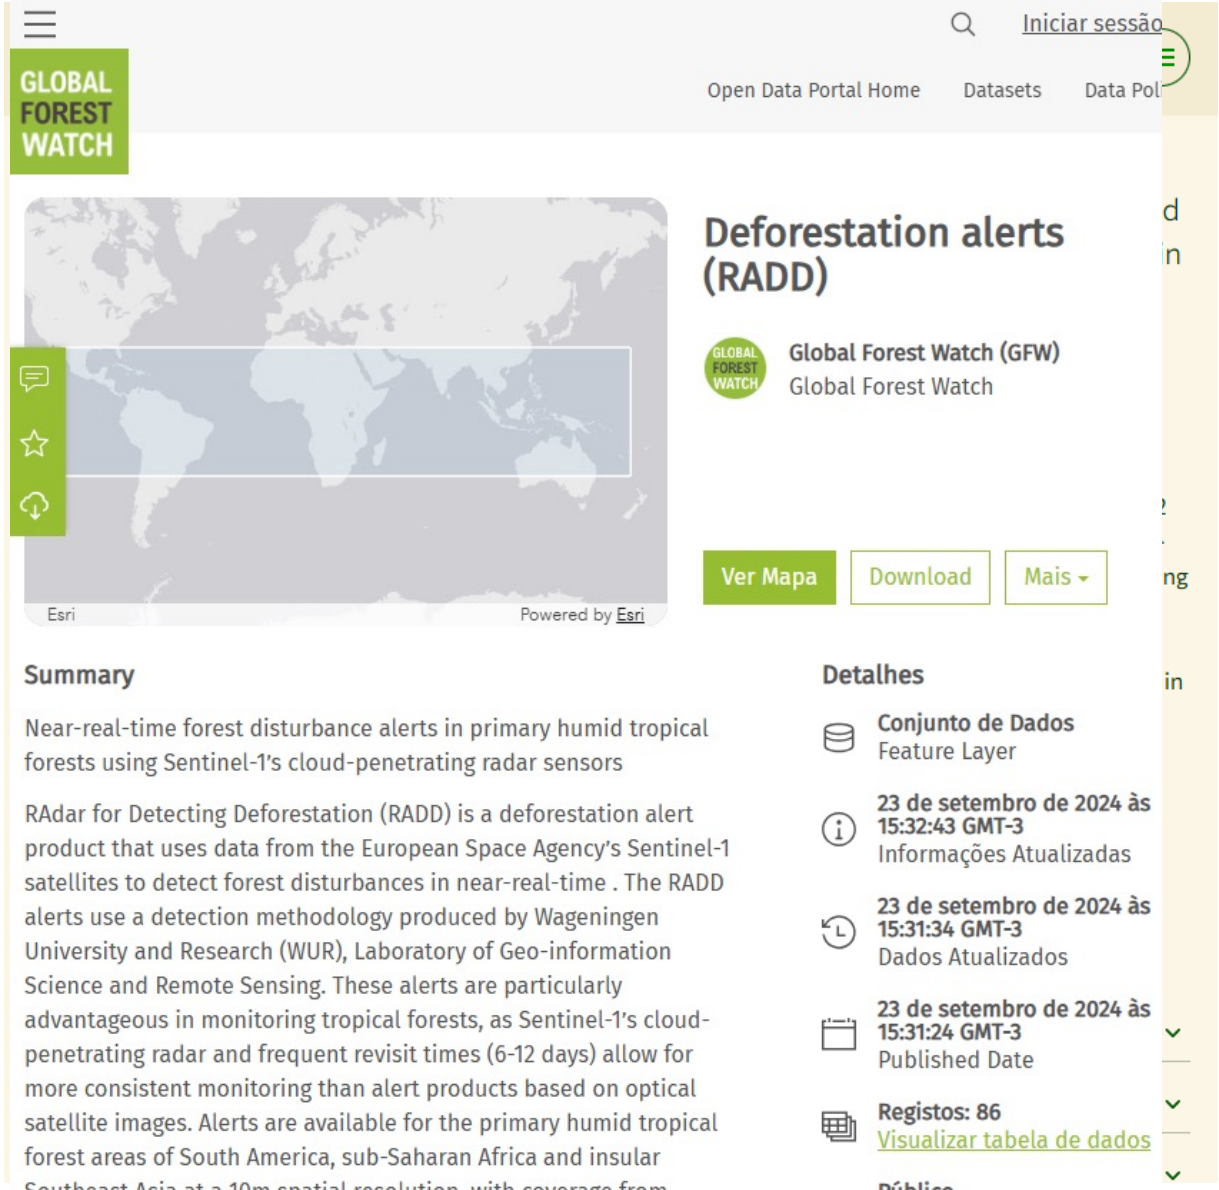
Sistema de monitoreo	Alertas GLAD (Universidad de Maryland)
Región	Trópicos (mundial)
Principales métodos de IA / análisis	Algoritmos de árboles de decisión, análisis de series temporales, detección estadística de cambios, aprendizaje automático
Principales aplicaciones	Detección de perturbaciones forestales casi en tiempo real
Datos de teledetección	Landsat (GLAD-L) Sentinel (GLAD-S2)



https://glad.umd.edu/dataset

IA y monitoreo forestal - RADD

Sistema de monitoreo	Alertas RADD (Universidad de Wageningen y WRI)
Región	Bosques tropicales
Principales métodos de IA / análisis	Aprendizaje automático, análisis de series temporales SAR, detección bayesiana de cambios
Principales aplicaciones	Deforestación casi en tiempo real bajo cobertura nubosa
Datos de teledetección	Sentinel 1 SAR



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

IA y monitoreo forestal - GEDI

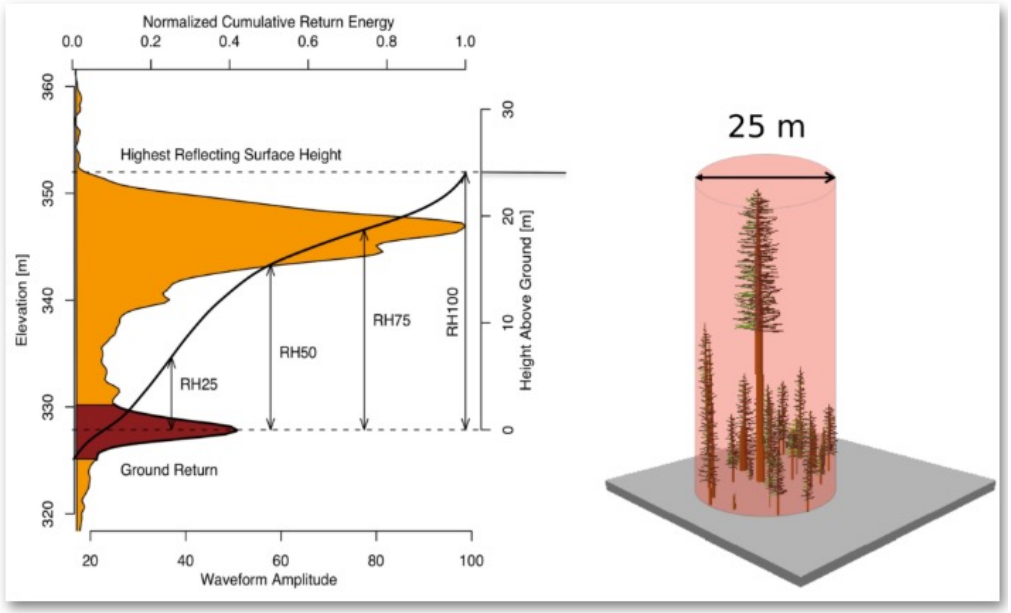
Sistema de monitoreo	Productos de biomasa GEDI de la NASA
Región	Mundial
Principales métodos de IA / análisis	Random Forest, Gradient Boosting , Redes neuronales profundas, (CNN, modelos con codificador Transformer), Aprendizaje por transferencia
Principales aplicaciones	Estimación de biomasa aérea, estructura forestal
Datos de teledetección	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.



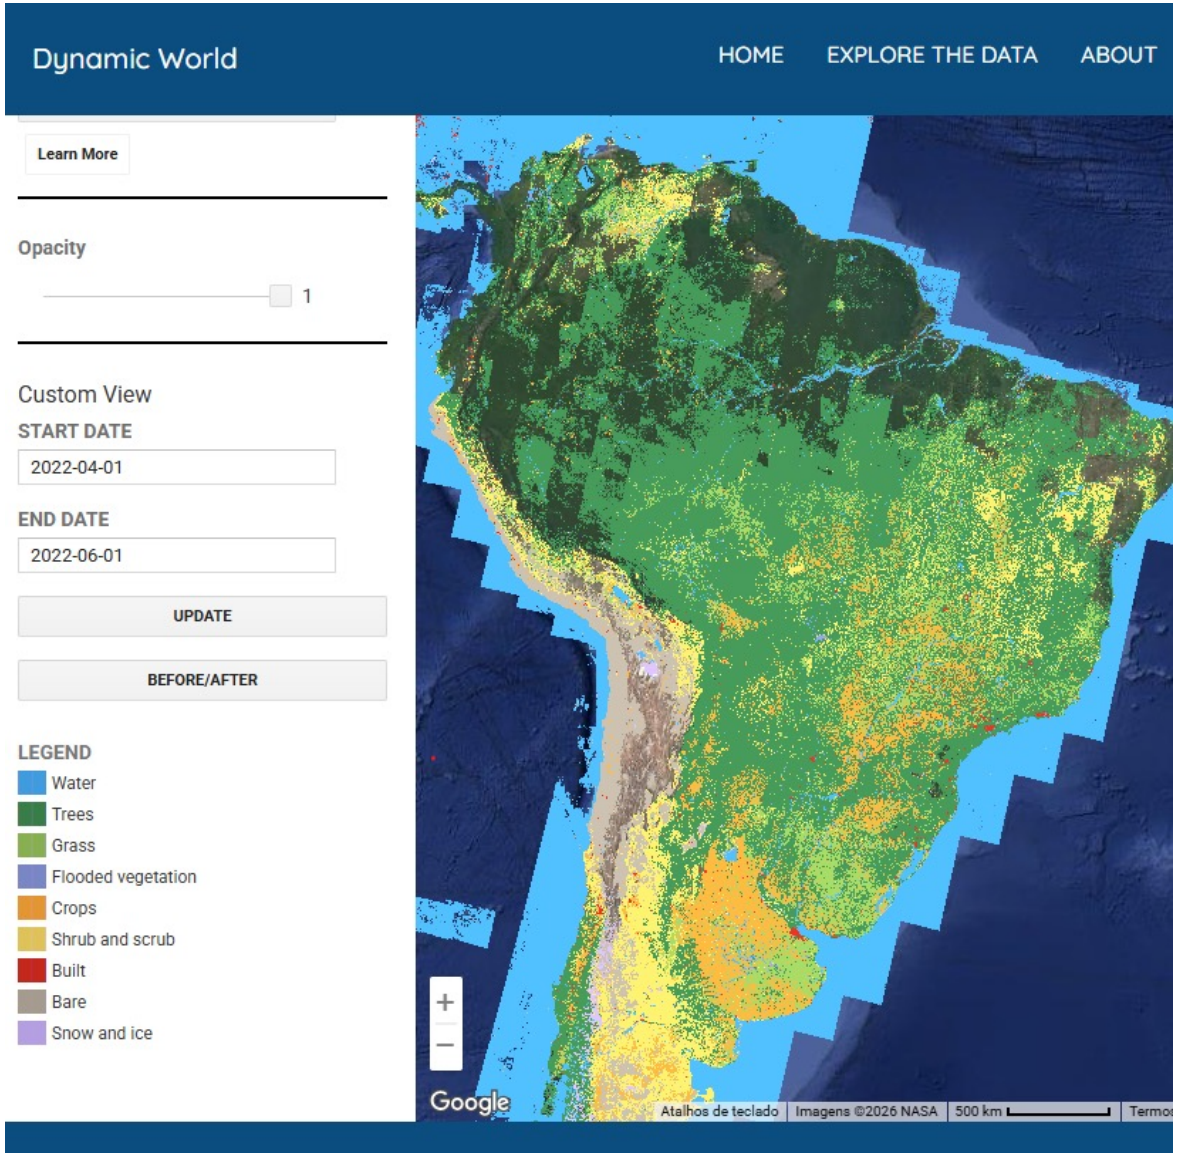
LEVEL 3 - GRIDDED CANOPY HEIGHT METRICS AND VARIABILITY

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

IA y monitoreo forestal

Dynamic World

Sistema de monitoreo	Google Dynamic World
Región	Mundial
Principales métodos de IA / análisis	Redes neuronales profundas (segmentación semántica basada en CNN)
Principales aplicaciones	Clasificación de la cobertura del suelo casi en tiempo real
Datos de teledetección	Sentinel-2



https://dynamicworld.app/

BiomasBR - INPE

Programa del INPE de monitoreo de la vegetación por imágenes satelitales

Información sistemática sobre la vegetación nativa, **las actividades de** deforestación (supresión) y **degradación** en todos los biomas brasileños

Datos oficiales brasileños de deforestación para las políticas públicas

Conservación y desarrollo sostenible

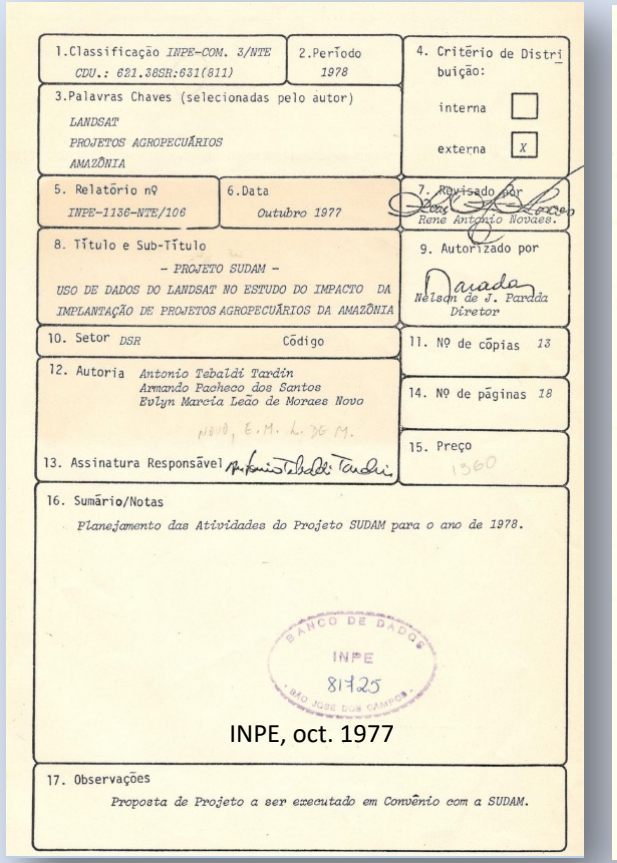


https://data.inpe.br/big/web/biomasbr/

Historia – teledetección e investigación en el INPE



INPE – Cuiabá, 1973
Recepción y procesamiento de imágenes 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

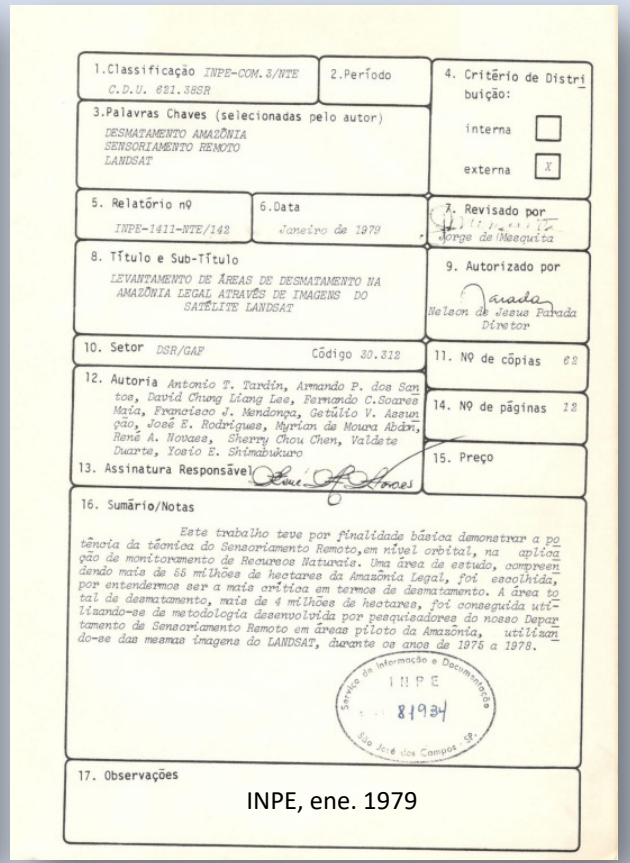
15. Preço
1360

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, oct. 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

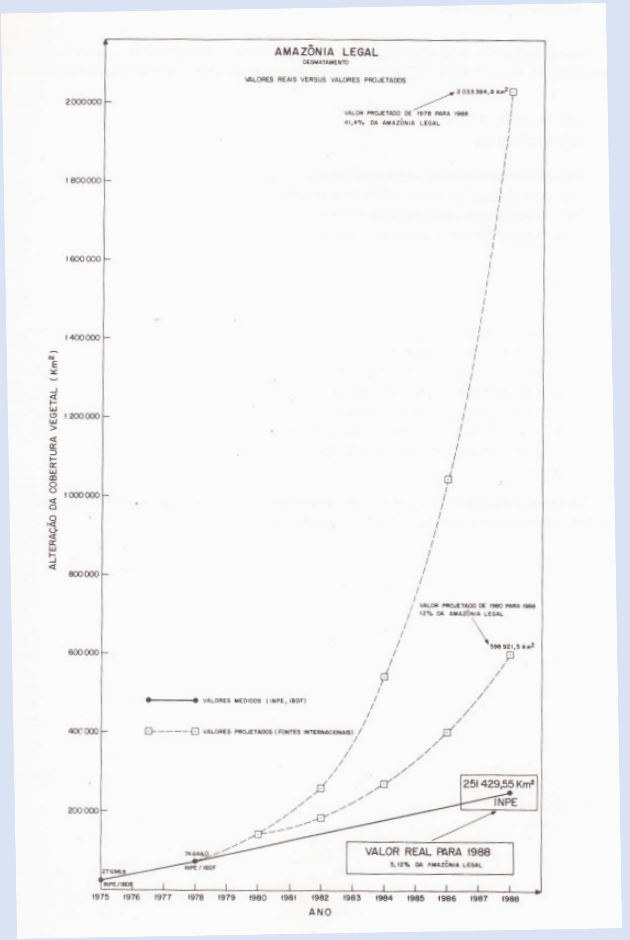
INPE, ene. 1979

Década de 1980: inicio del monitoreo por satélite - PRODES

Deforestación proyectada > 2 000 000 km²



1989 - Primer mapeo completo de la Amazonía Legal brasileña

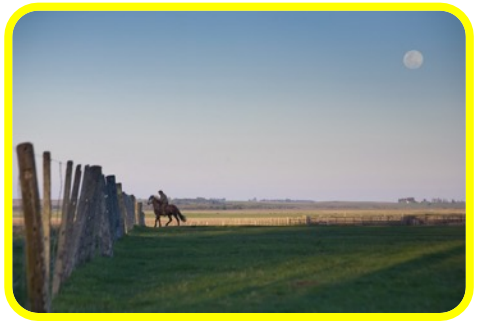


76

Biomas brasileños















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 - Monitoreo anual de la vegetación nativa suprimida

Prodes – Metodología

Sistema incremental - aumento anual de la **deforestación**
Supresión de la vegetación nativa

Resolución espacial media (**10**-30 m) – Sentinel-2
Unidad mínima de mapeo = **1 ha** (6,25 ha - serie histórica más larga)
Cobertura exhaustiva (solo la Amazonía = 516 teselas Sentinel)

Hasta 2023 - identificación visual por **intérpretes**,
revisión por **auditores** y **validación independiente** por
expertos externos de cada bioma

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

Datos abiertos – Terrabrasilis (https://terrabrasilis.dpi.inpe.br/)



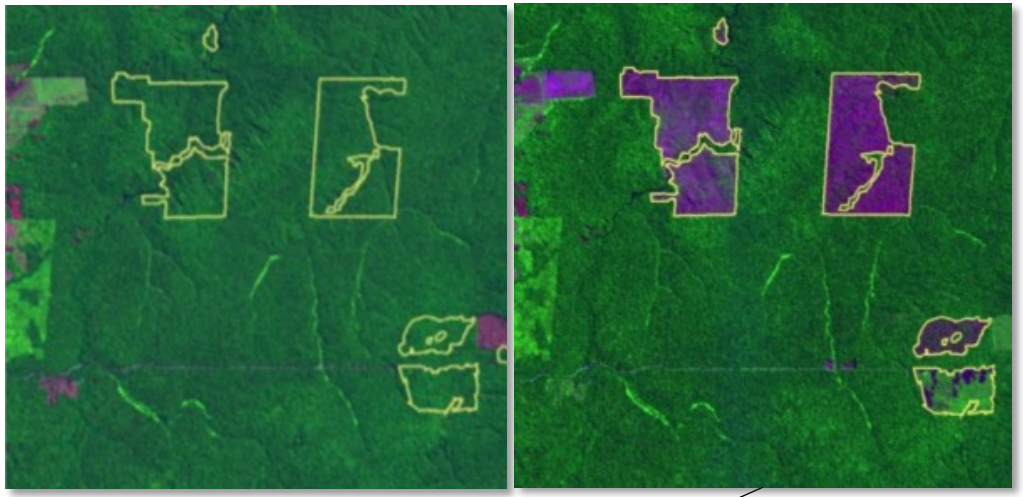
Almeida *et al*. Methodology for Forest Monitoring used in PRODES and DETER projects. 2022 . http://urlib.net/ibi/8JMKD3MGP3W34R/443H3RE

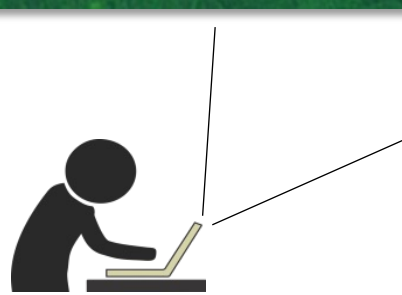
Prodes – Evolución metodológica

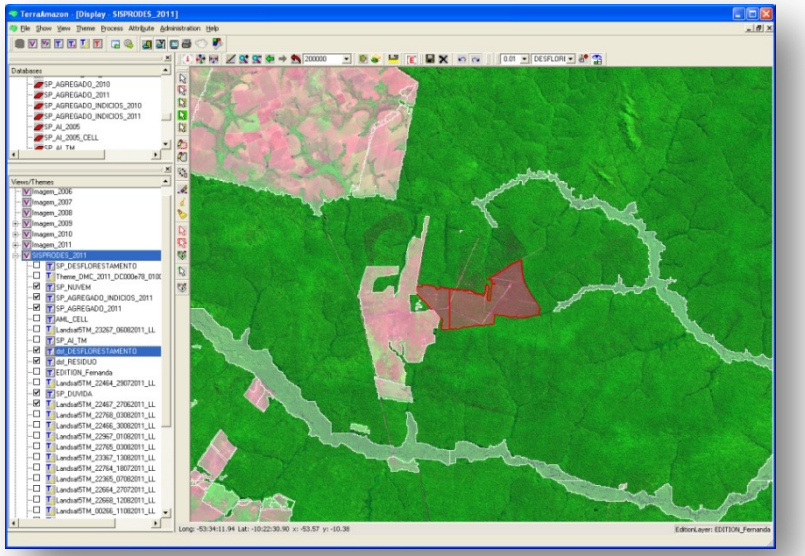
Prodes Amazonía – metodología anterior

Año anterior

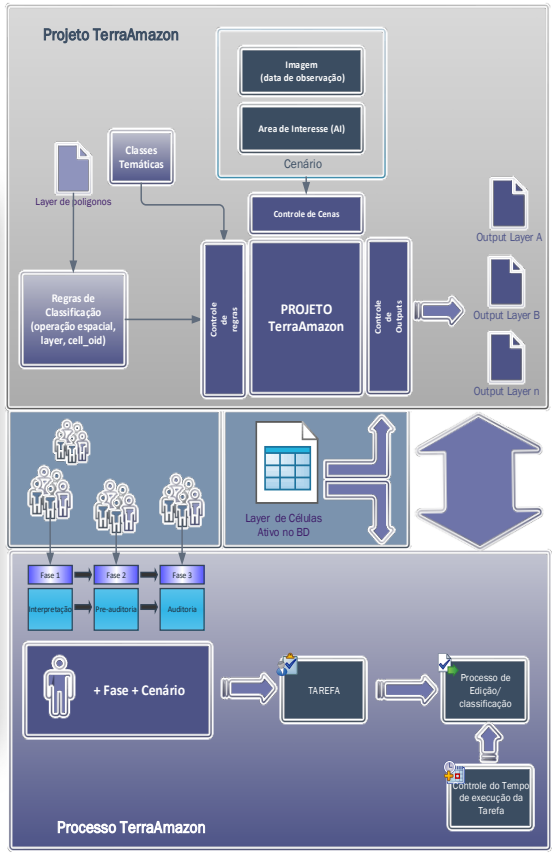
Año mapeado







TerraAmazon



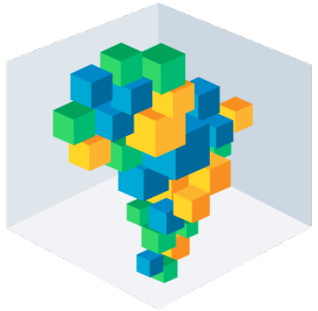
Prodes – Evolución metodológica

Prodes – De imágenes Landsat anuales únicas a cubos de datos de series temporales Sentinel

Big data de imágenes de teledetección modelado en cubos de datos multidimensionales

Motivación: innovación tecnológica para los proyectos de monitoreo ambiental del INPE (**BiomasBR**)

Mapeo del uso y la cobertura del suelo



BRAZIL DATA CUBE

Análisis de series temporales

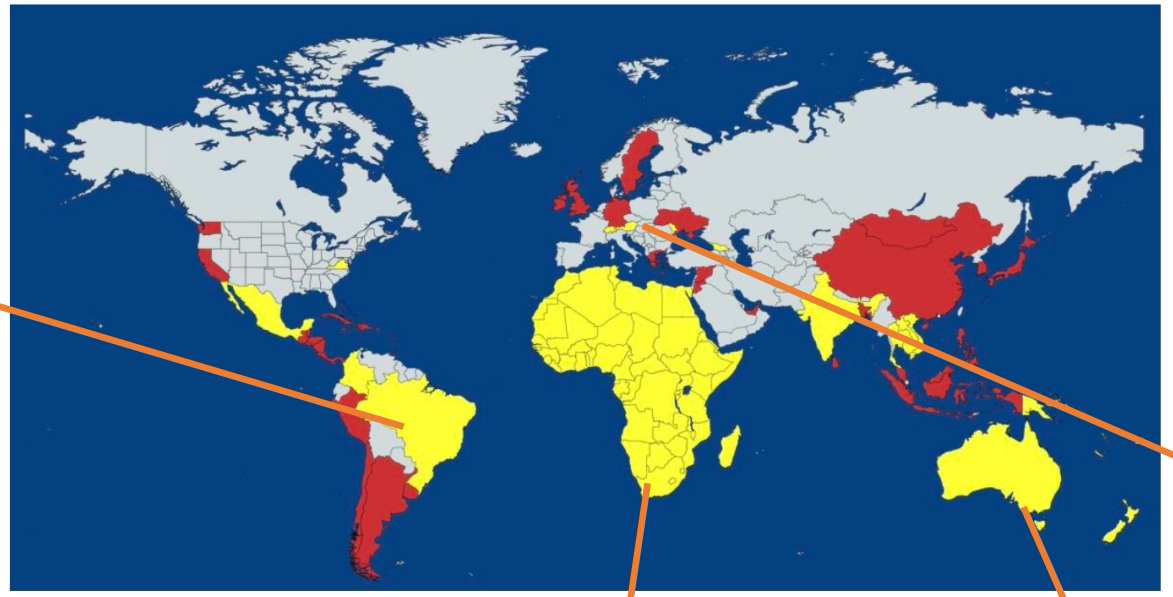
Tecnología de <u>aprendizaje automático</u> para big data

Fuente: Ferreira y Queiroz (2025)

Alianza con iniciativas similares

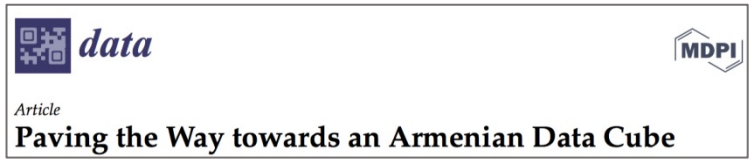
Fuente: [Sudmanns et al, 2022]

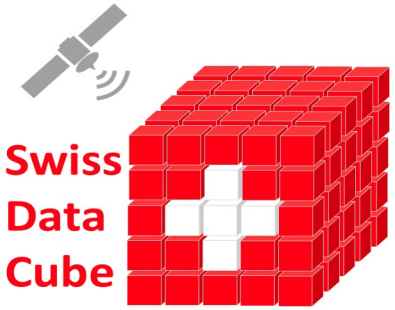
Amarillo: operativo
Rojo: en desarrollo



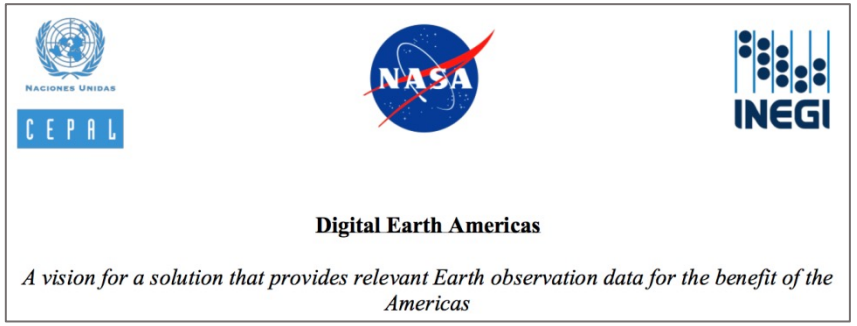
BRAZIL DATA CUBE

http://brazildatacube.org





https://www.swissdatacube.org/



Fuente: Ferreira y Queiroz (2025)

Digital Earth AFRICA

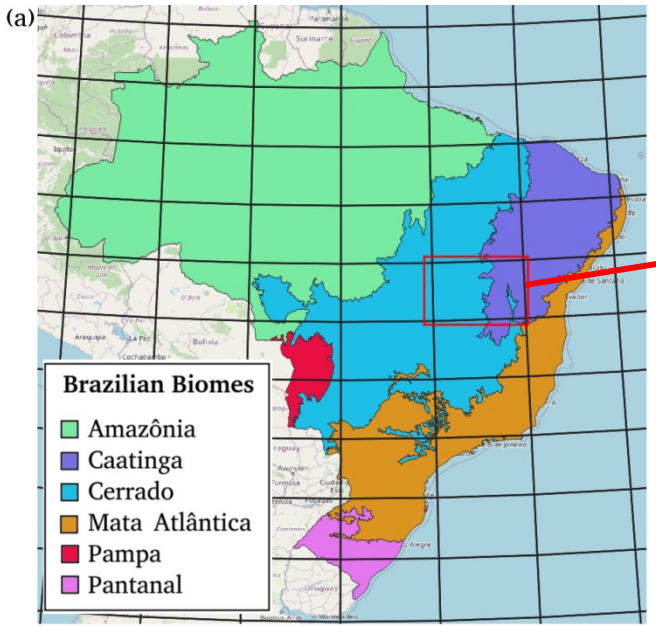
https://digitalearthafrica.org/

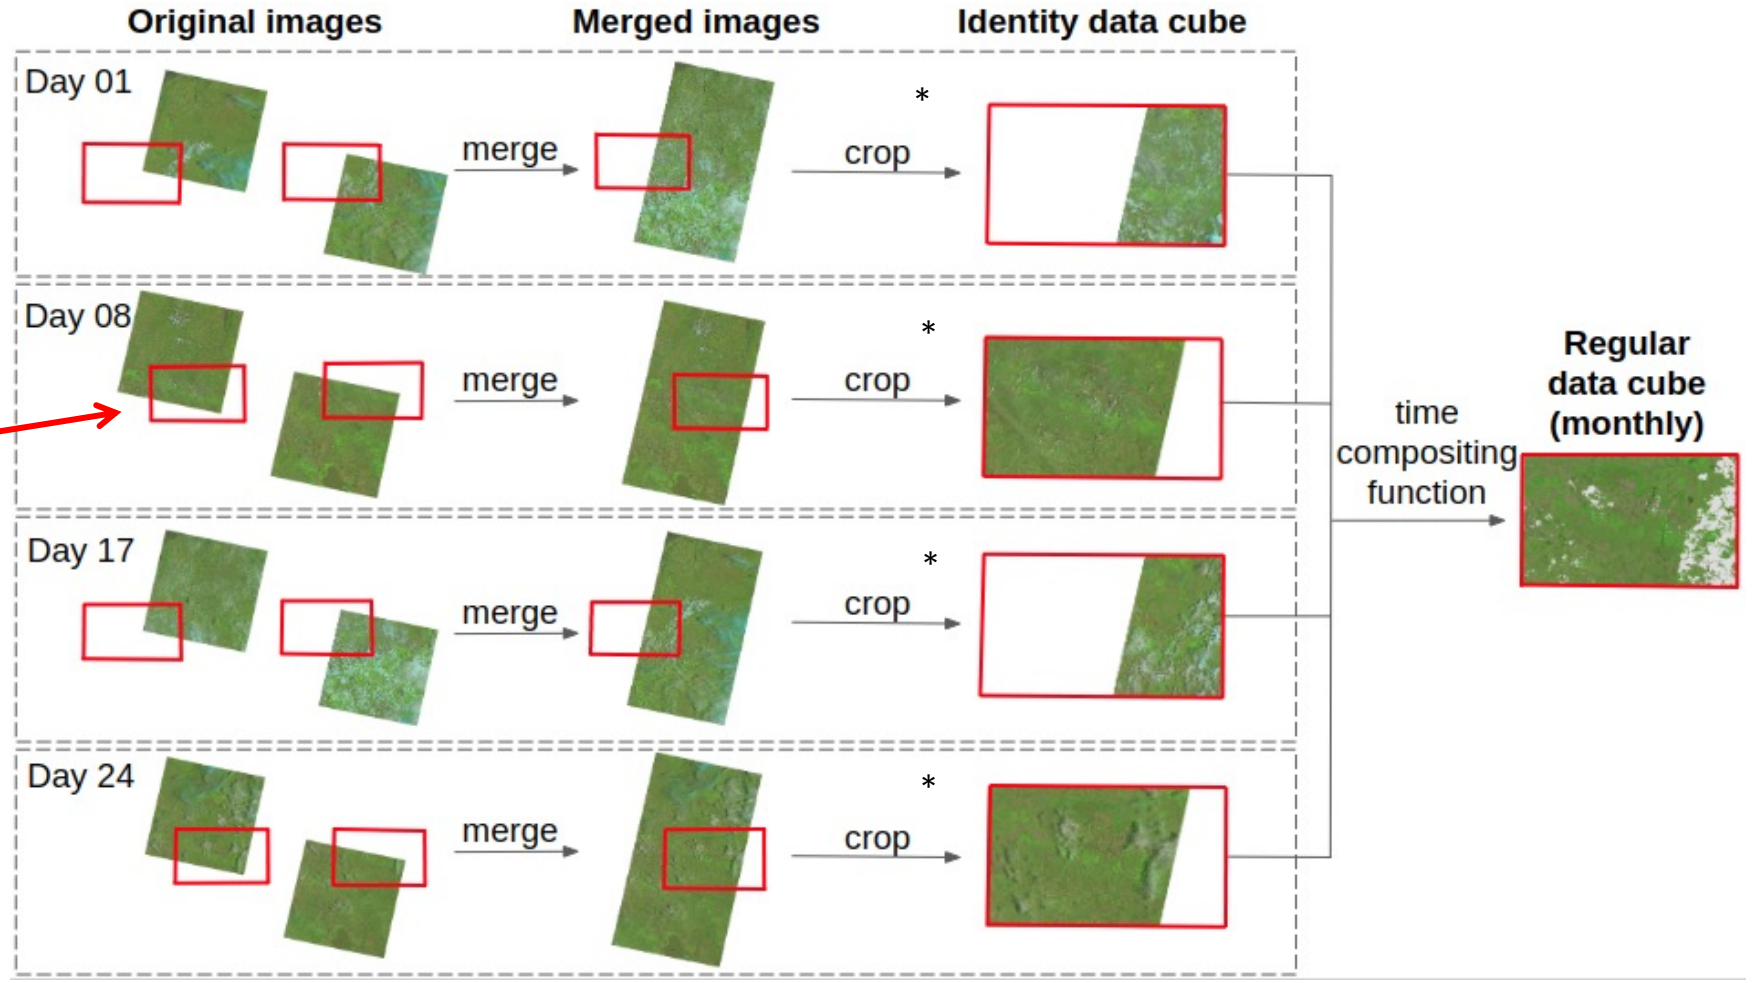
Digital Earth AUSTRALIA

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

Fuente: Ferreira y Queiroz (2025)

Construcción de cubos de datos





*remuestreo bilineal para la banda de mejor resolución espacial

Fuente: Ferreira y Queiroz (2025)

Brazil Data Cube - BDC

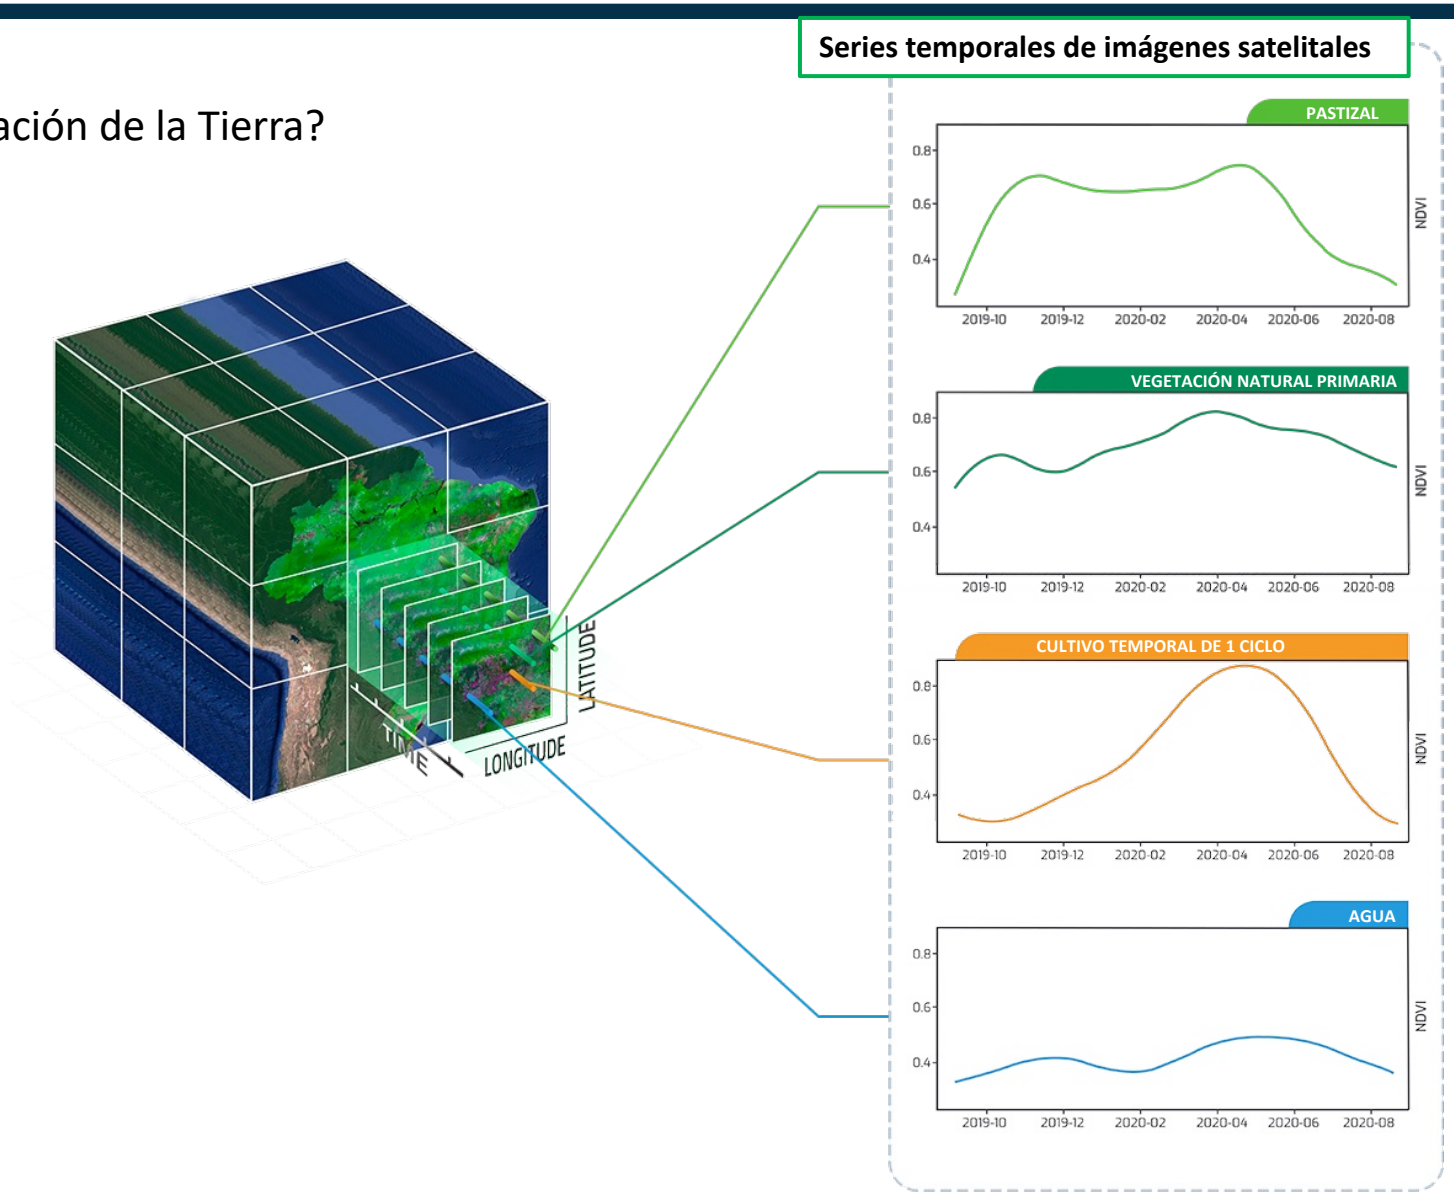
¿Por qué un cubo de datos de observación de la Tierra?

Matriz multidimensional de imágenes satelitales con

4 dimensiones
latitud, longitud, fecha y atributos

para el análisis de series temporales.

(Appel et al., 2019)



Fuente: Ferreira y Queiroz (2025)

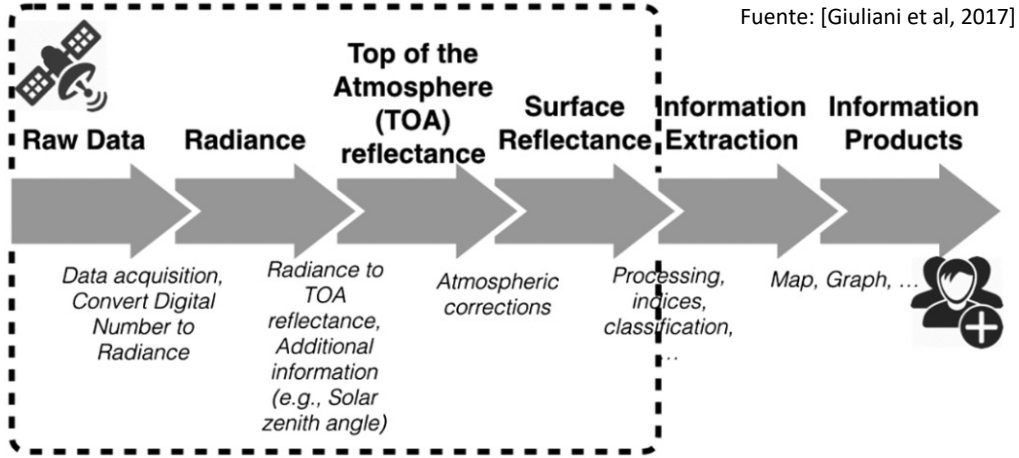
Prodes - Monitoreo anual de la vegetación nativa suprimida

Prodes Amazonía – nuevas tecnologías - ANÁLISIS DE BIG DATA

Brazil Data Cube

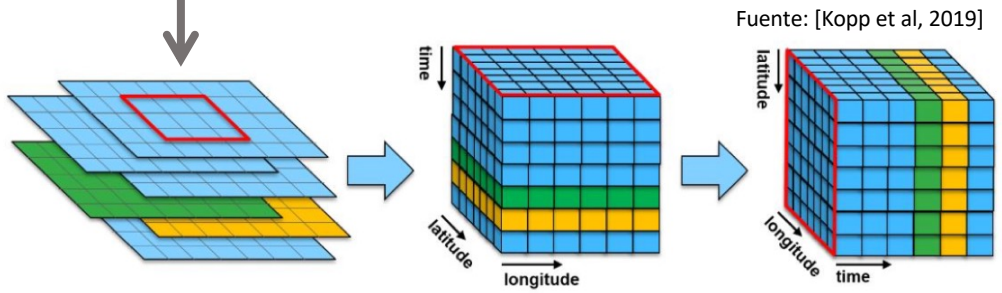
(1) Datos listos para el análisis (ARD) de imágenes satelitales de resolución media para Brasil: CBERS-4, Landsat 8, Sentinel 2.

(2) Cubos de datos multidimensionales.



Fuente: [Giuliani et al, 2017]

Datos CEOS listos para el análisis de tierras:
https://ceos.org/ard/index.html



Fuente: [Kopp et al, 2019]

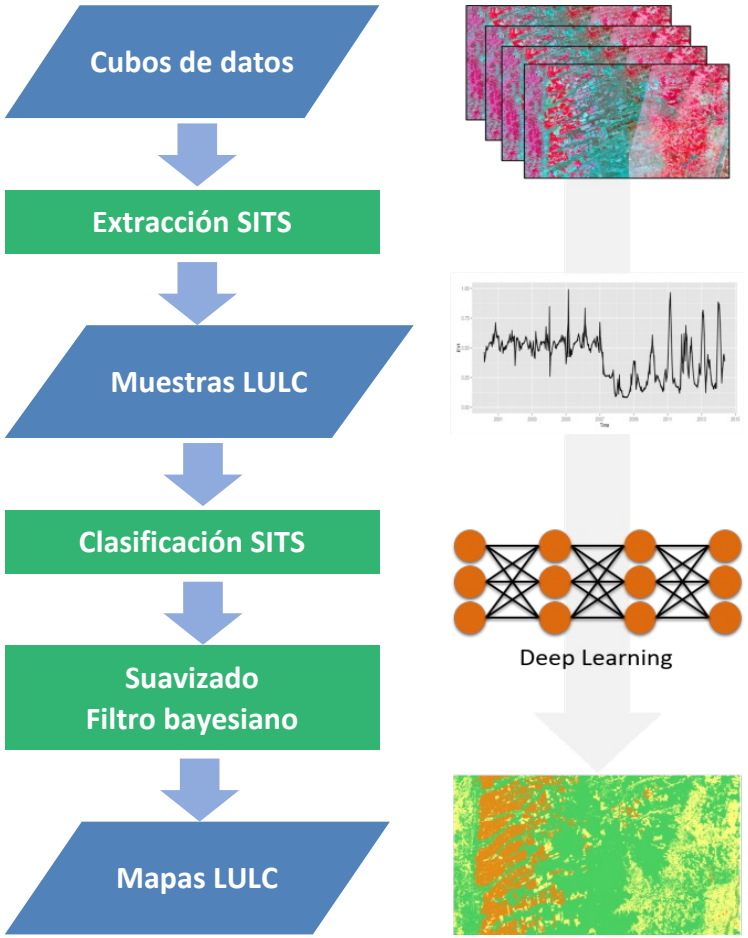
Colecciones de imágenes satelitales de observación de la Tierra – ARD

Cubos de datos – matriz de cuatro dimensiones.

Fuente: Ferreira y Queiroz (2025)

Brazil Data Cube - BDC

Mapeo del uso y la cobertura del suelo (LULC)



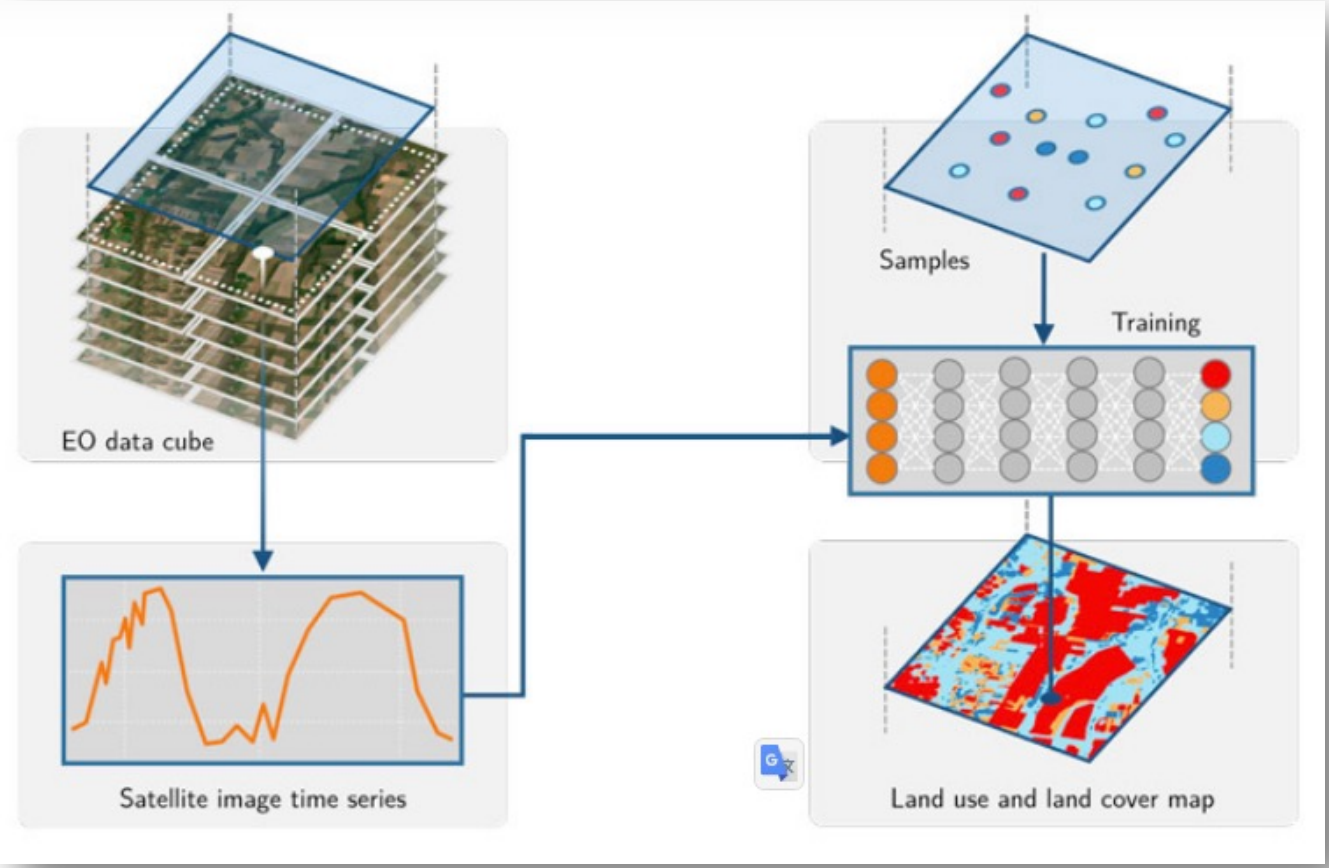
Fuente: [Ferreira et al, 2020]

Cubo de datos de OT,
análisis de series temporales de imágenes satelitales (SITS),
y
aprendizaje automático para producir mapas LULC a partir de grandes bases de OT.

Las SITS permiten procesamientos complejos, difíciles con enfoques de detección de cambios bitemporales o incluso anuales.

(Pasquarella et al., 2016)

SITS – series temporales de imágenes satelitales



Simoes et al, (2021]

SITS - herramientas de análisis y clasificación de series temporales: mapas autoorganizados, agrupamiento, filtrado y visualización de datos.

Algoritmos avanzados de aprendizaje automático para mapear el uso y la cobertura del suelo a partir de series temporales de imágenes satelitales.

Algoritmos de AA:

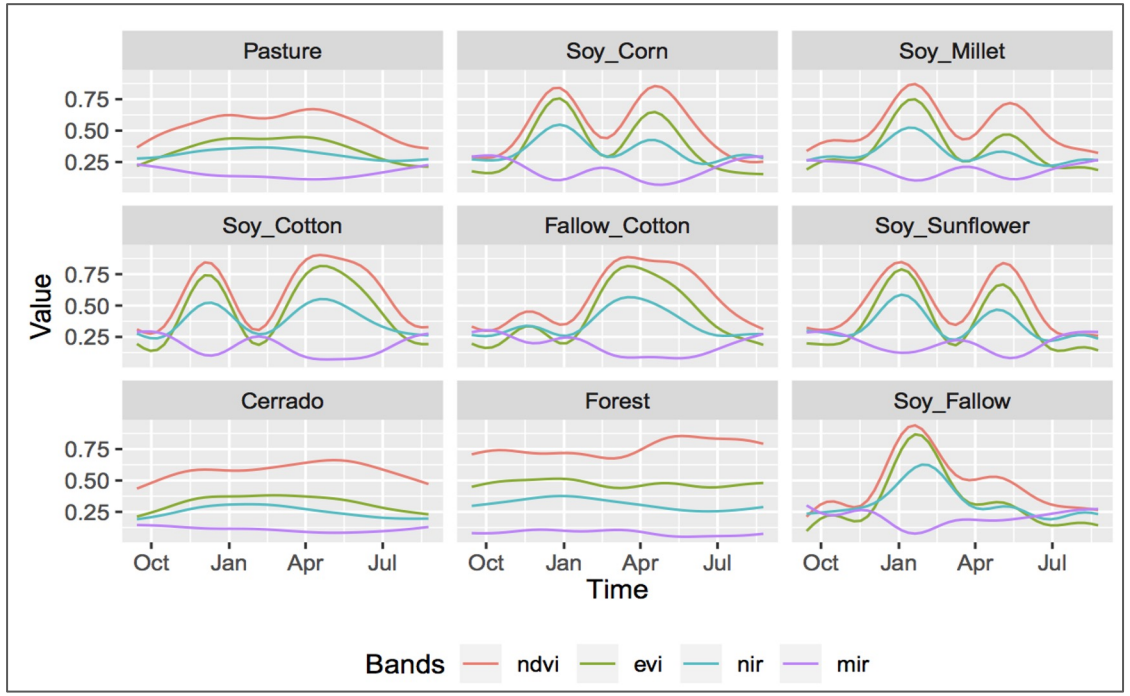
- Máquinas de vectores de soporte (SVM),
- Bosques aleatorios (RF),
- Extreme Gradient Boosting,
- Perceptrones multicapa 1D totalmente conectados,
- Redes neuronales convolucionales 1D,
- Versión 1D del método ResNet.

Embeddings

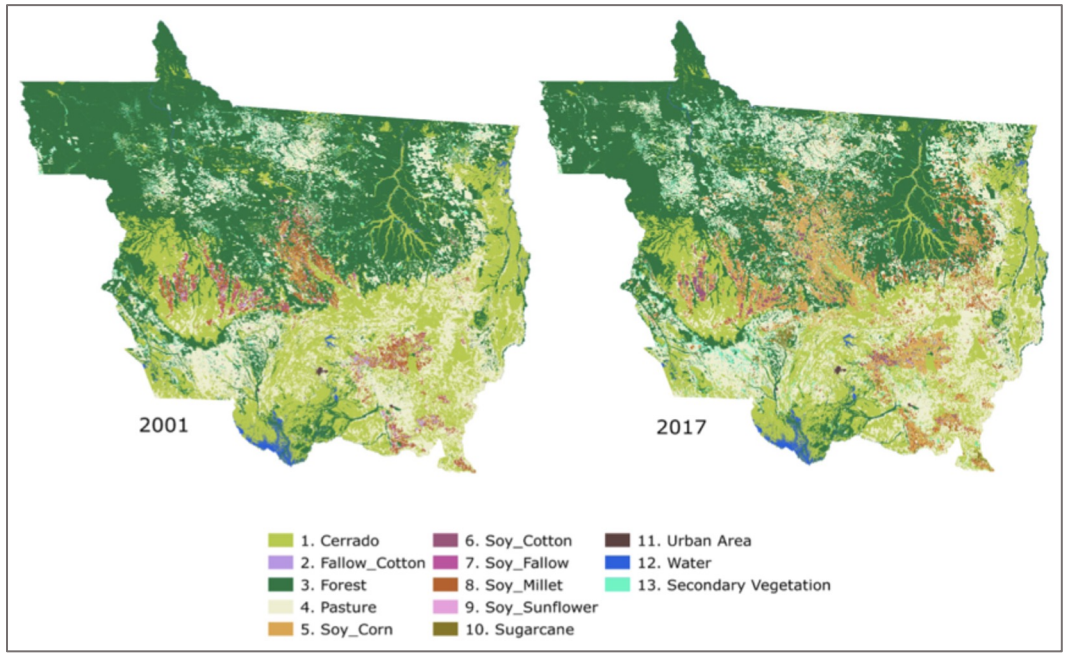
https://data.inpe.br/bdc/sits-satellite-image-time-series/

Brazil Data Cube - BDC

Análisis de series temporales de imágenes y **aprendizaje automático**
para producir
mapas de uso y cobertura del suelo a partir de grandes bases de observación de la Tierra



Series temporales de imágenes NDVI, EVI, NIR, MIR - año agrícola MODIS – producto MOD13Q1 / método – SVM (máquina de vectores de soporte)

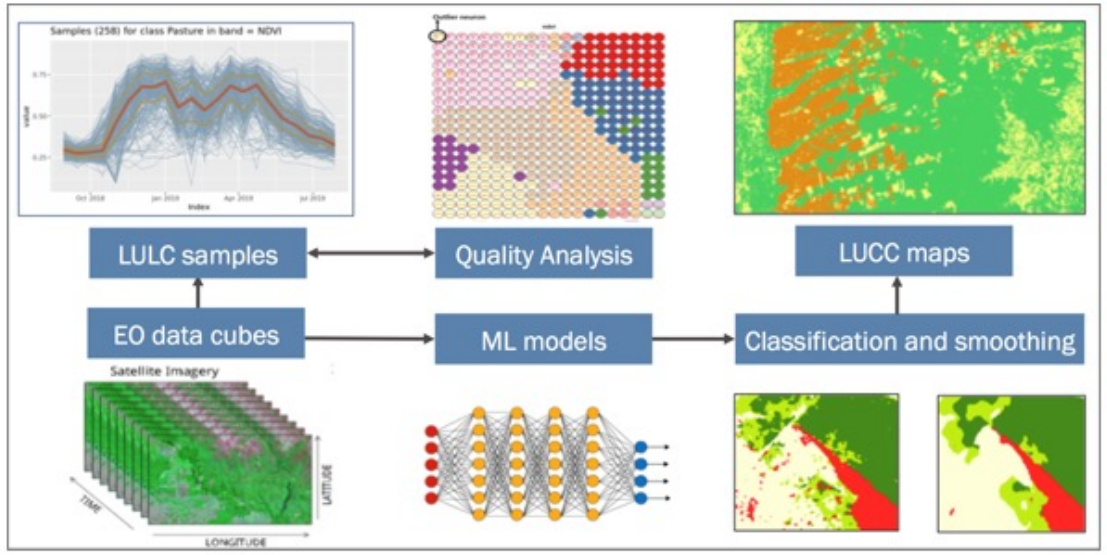


Mapas de uso y cobertura del suelo del estado de Mato Grosso (Brasil) de 2001 a 2017, Scientific Data, 2020 (Simões et al., 2020)

Prodes – nuevas tecnologías - análisis con IA

SITS (Satellite Image Time Series)
R package

https://github.com/e-sensing




```r
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")

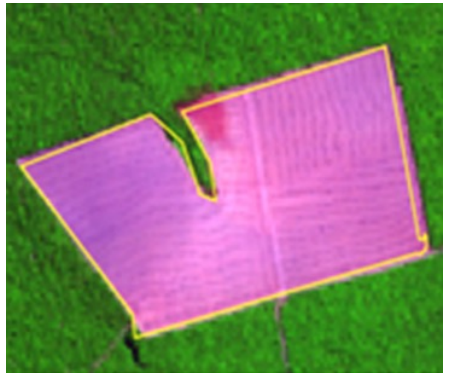
dl_model <- sits_train(samples, mlp_model)

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

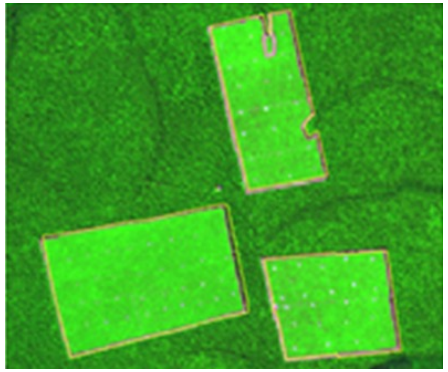
Prodes - Monitoreo anual de la vegetación nativa suprimida

Prodes Amazonía – clases

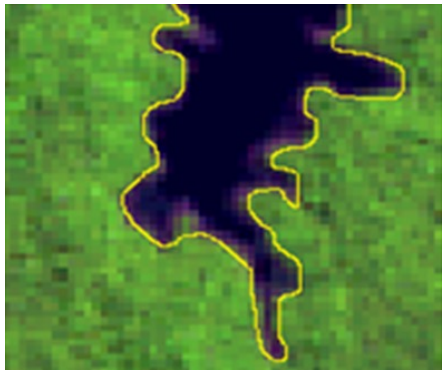
Deforestación por tala rasa suelo desnudo



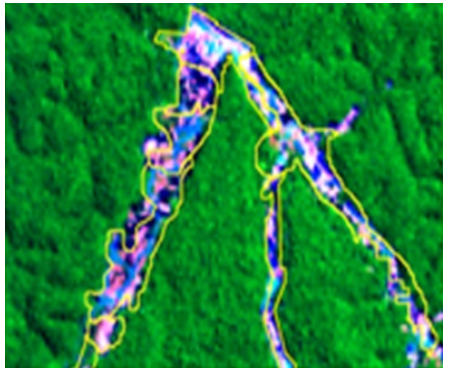
Deforestación por tala rasa vegetación herbácea



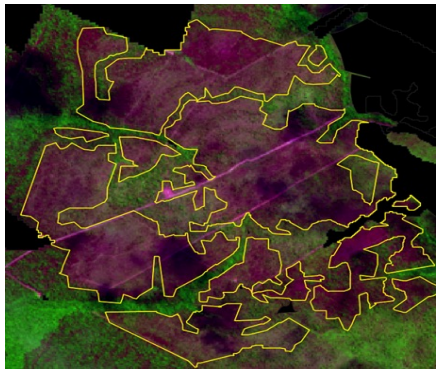
Deforestación por tala rasa bosque inundado



Deforestación por tala rasa minería

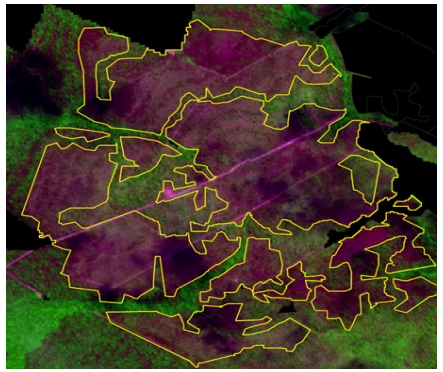


Deforestación por degradación progresiva



Prodes Amazonía – clases de degradación - desde 2022

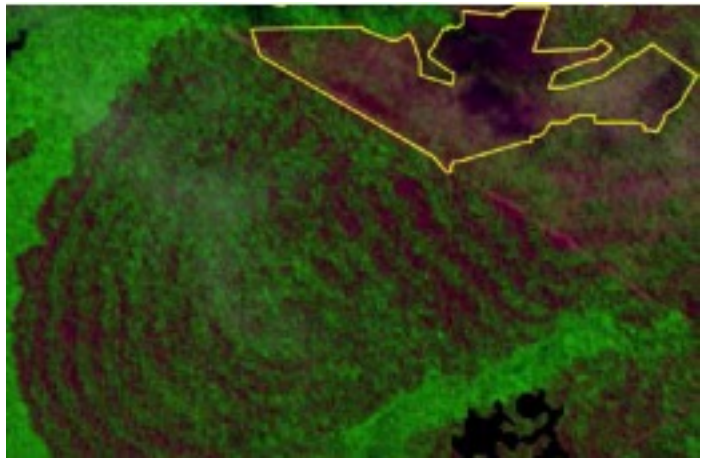
Deforestación por degradación progresiva



Tala selectiva



Incendios forestales recurrentes



Prodes - Monitoreo anual de la vegetación nativa suprimida

Prodes BRASIL

Desde 1988 - Amazonía Legal brasileña

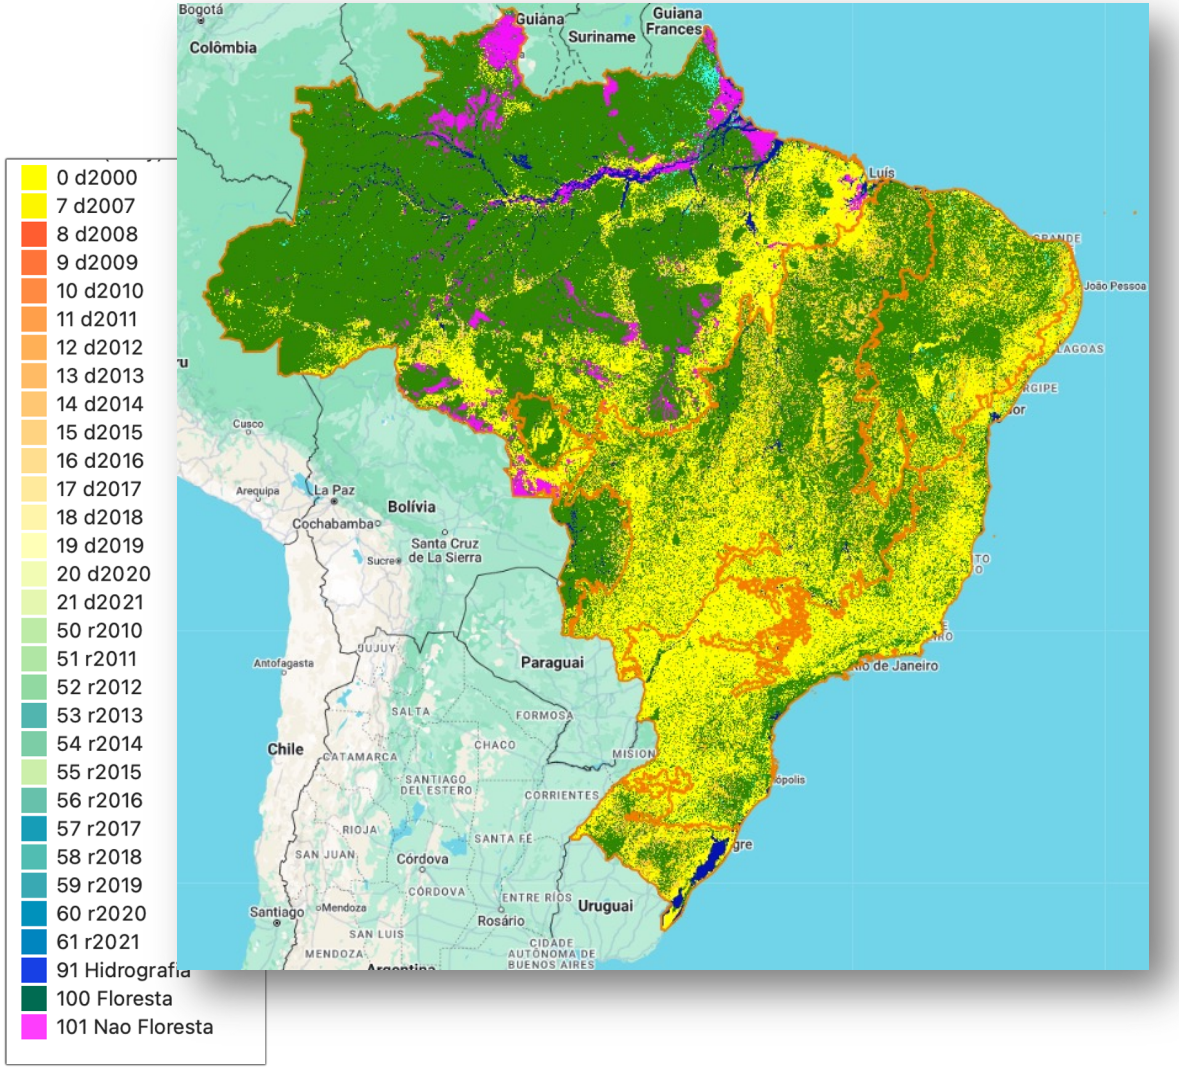
Todos los biomas de 2001 a **2025** (1 ha)

Amazonía, Amazonía no forestal*
Cerrado, Caatinga, Mata Atlántica, Pantanal y Pampa

Sentinel-2 - Brazil Data Cube, automatización de procesos

Datos oficiales de deforestación del gobierno brasileño

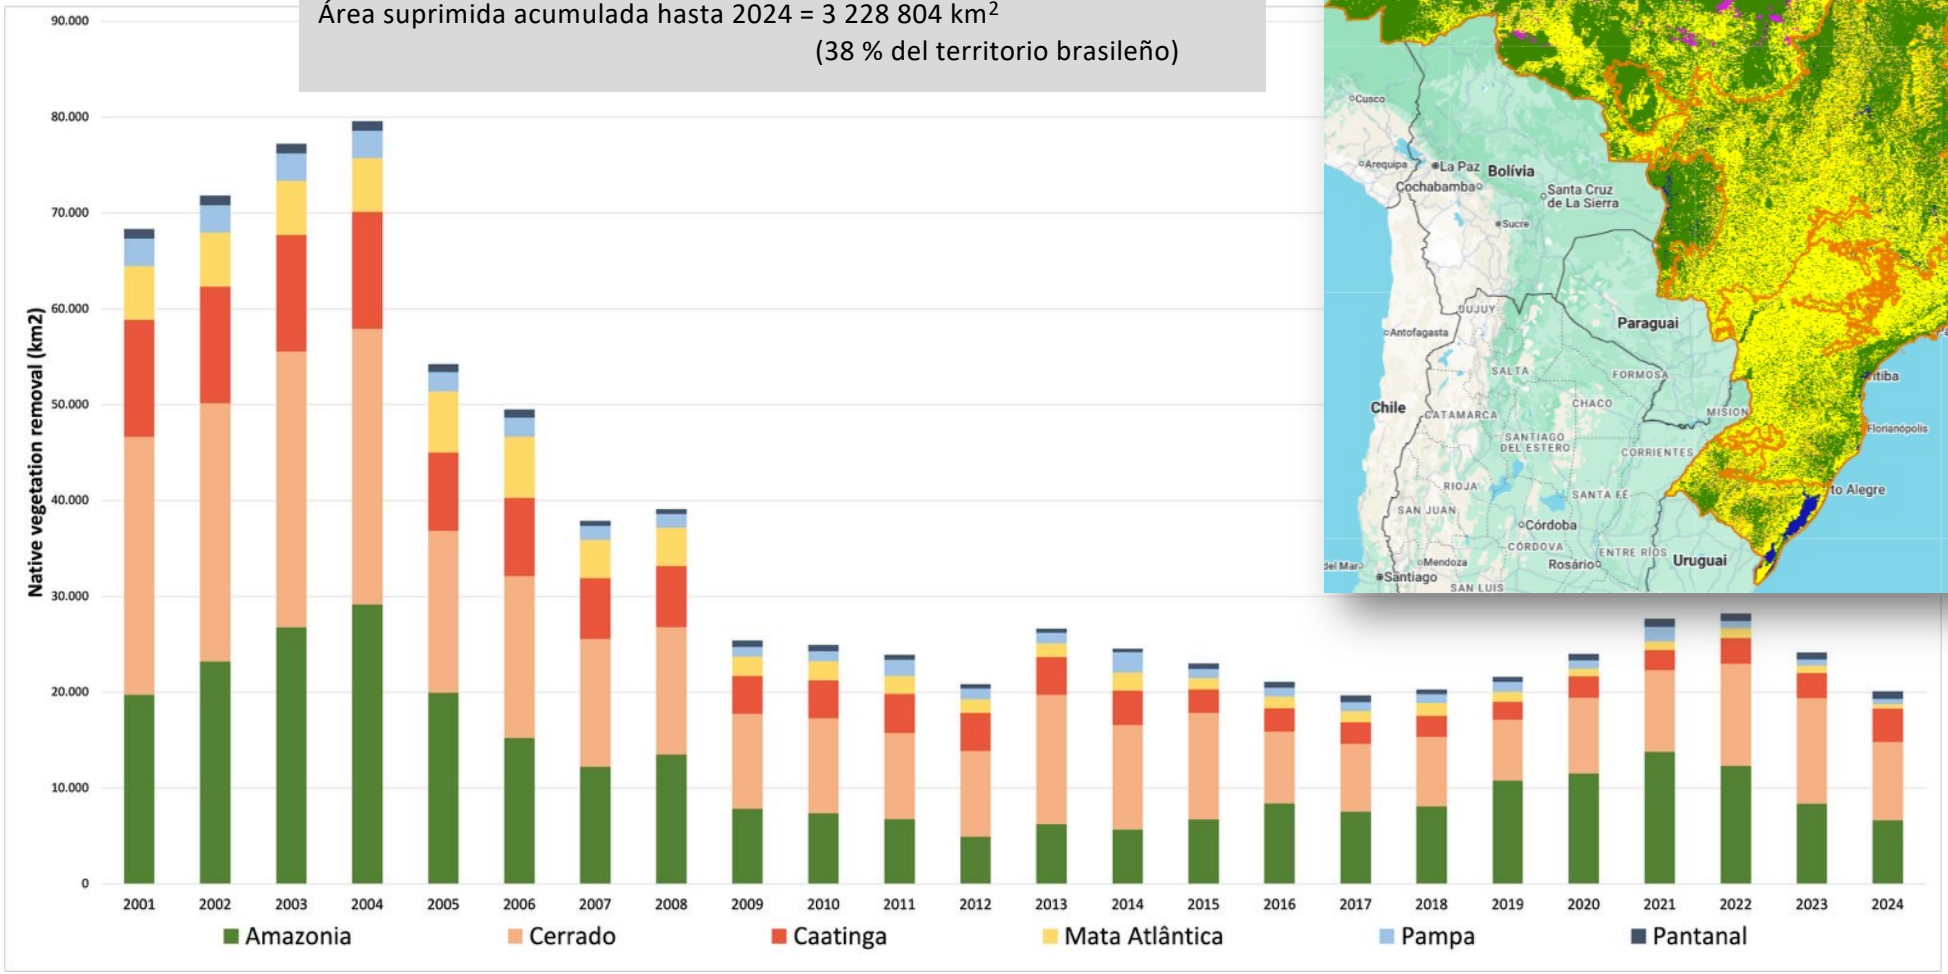
Base para políticas públicas y otras iniciativas: PPCDAm/PPCerrado, Fondo Amazonía, Moratoria de la soja, TAC de la carne, etc., además de innumerables trabajos científicos.

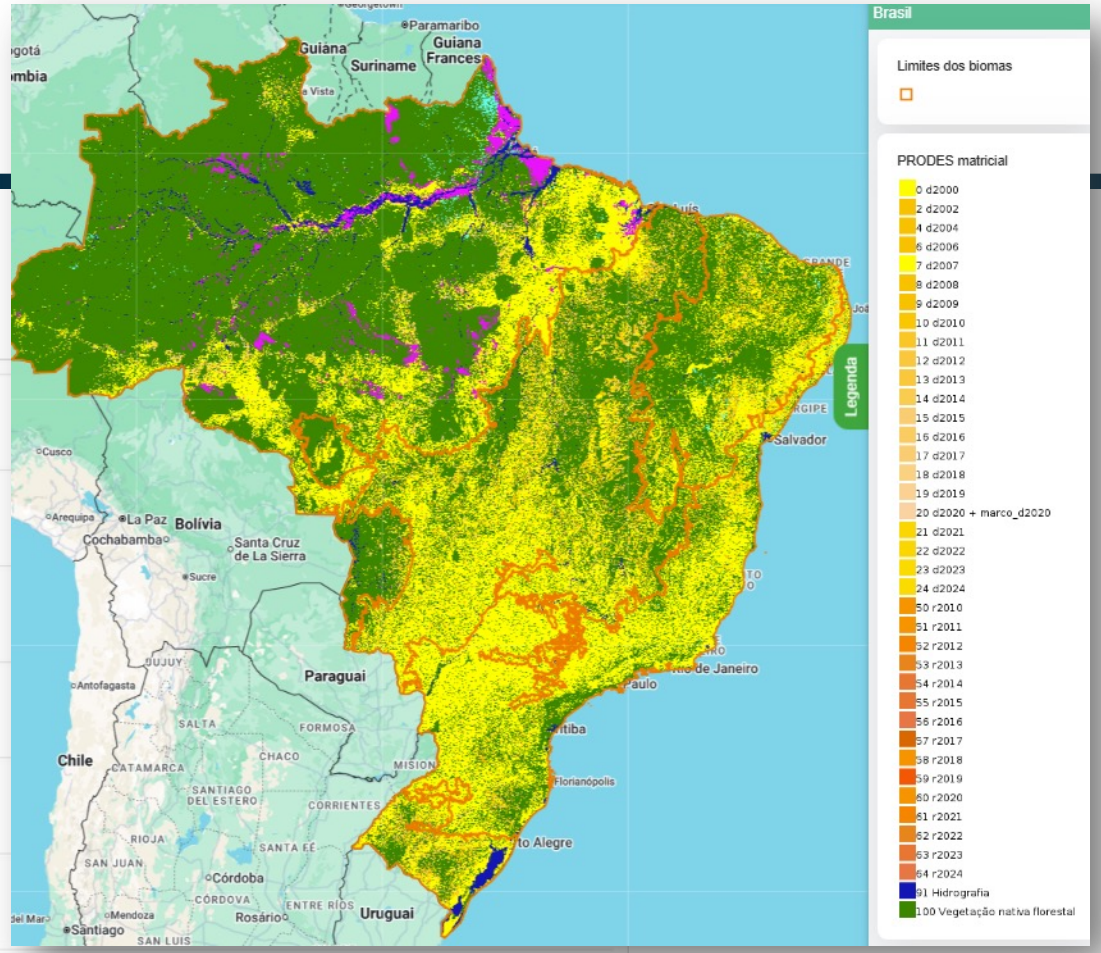


Prodes - Brasil

TerraBrasilis
Supresión de la vegetación nativa 2024

Área suprimida acumulada hasta 2024 = 3 228 804 km^2
(38 % del territorio brasileño)



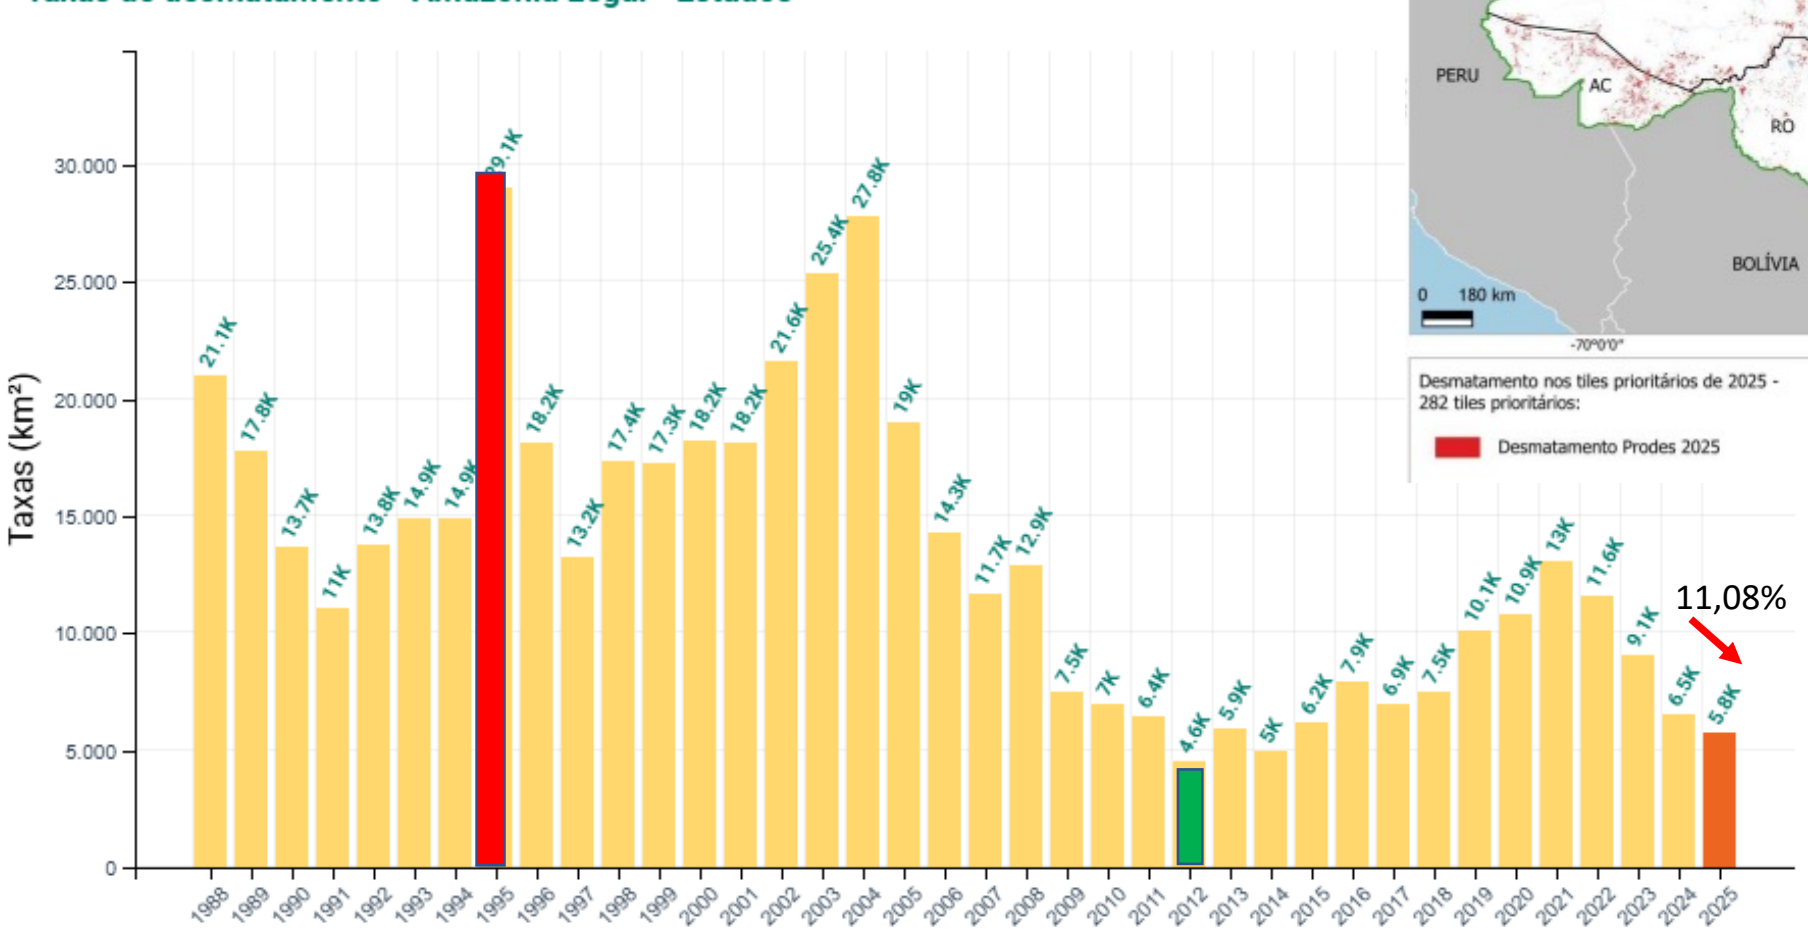


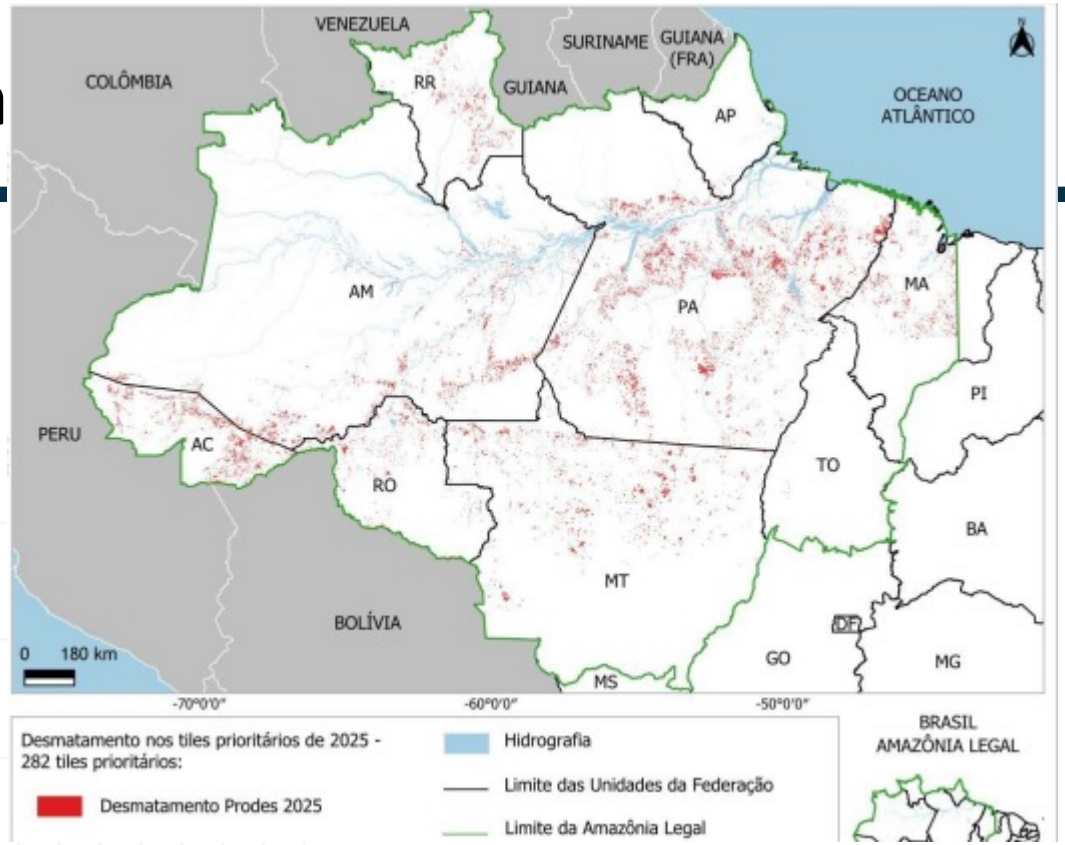
Polígonos > 1 ha
Imagen Sentinel (10 m)
Supresión de la vegetación nativa

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

Prodes - Amazonía Legal brasileña

Deforestación acumulada hasta 2024 > 857 301,71 km²
> 21 % del bosque original de la región amazónica



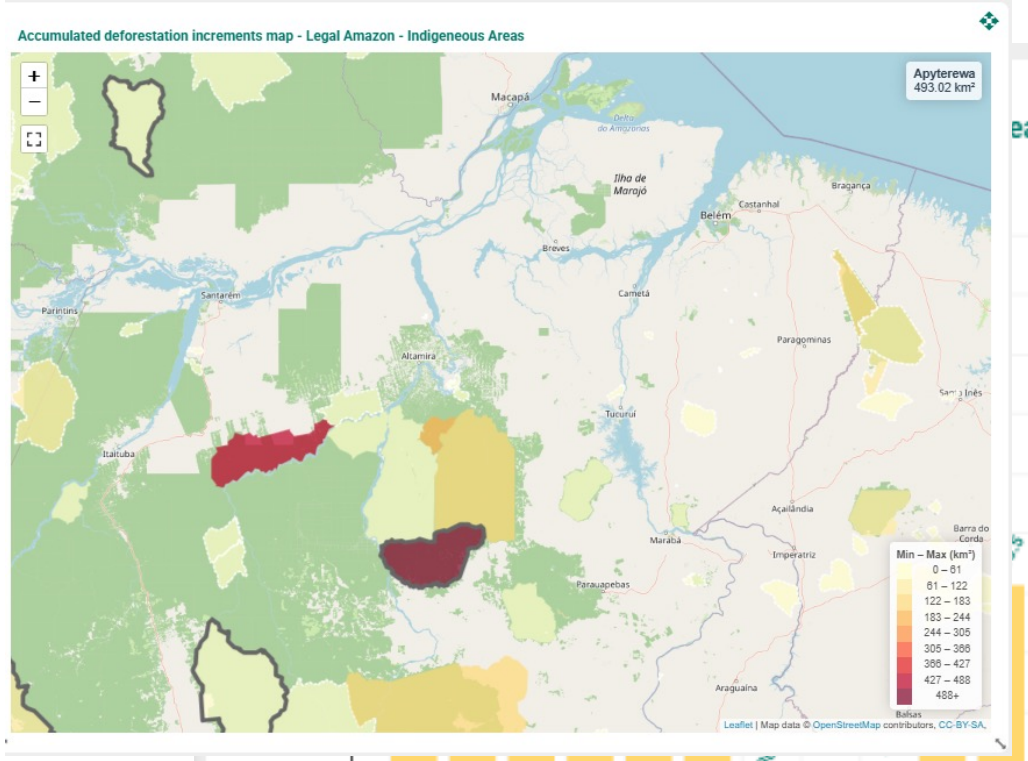


5731 km²
Tasa de deforestación 2025 (consolidada)

https://terrabrasilis.dpi.inpe.br

94

Prodes - Tierras indígenas



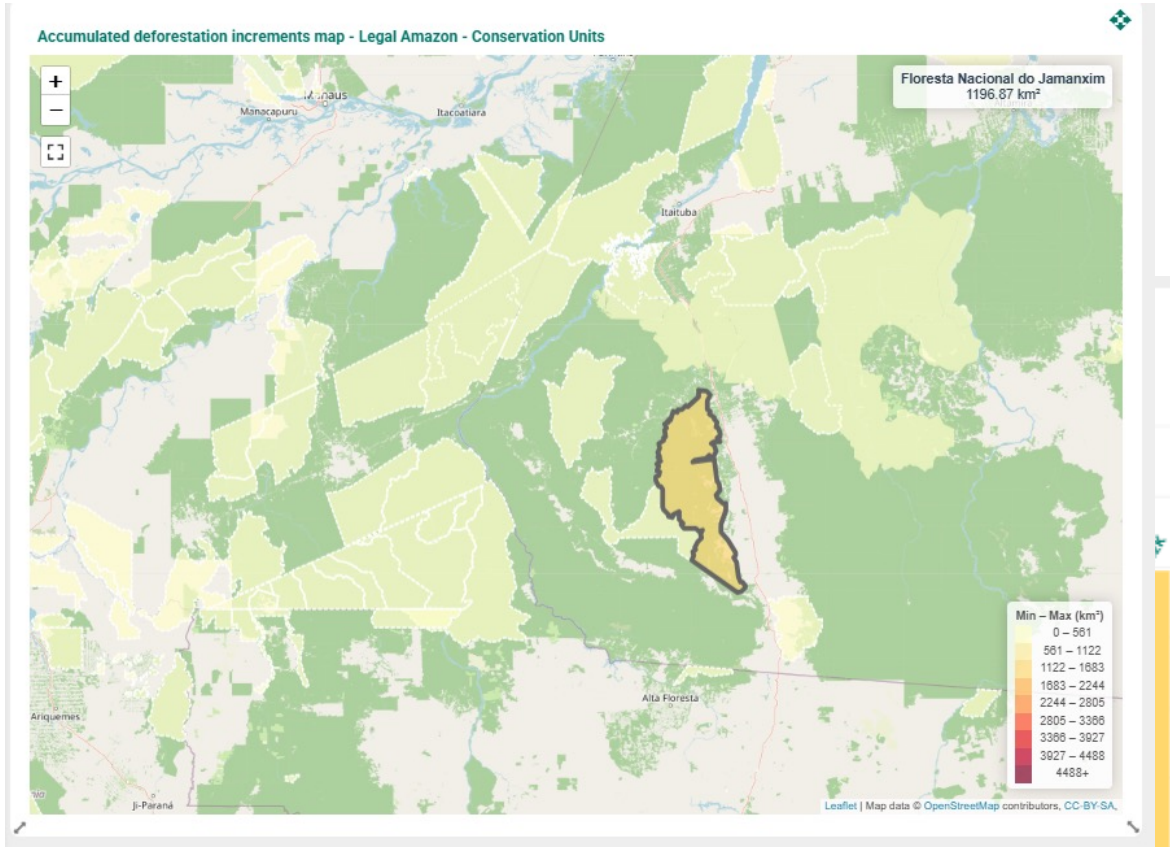
Deforestación 2025
489,11 km^2

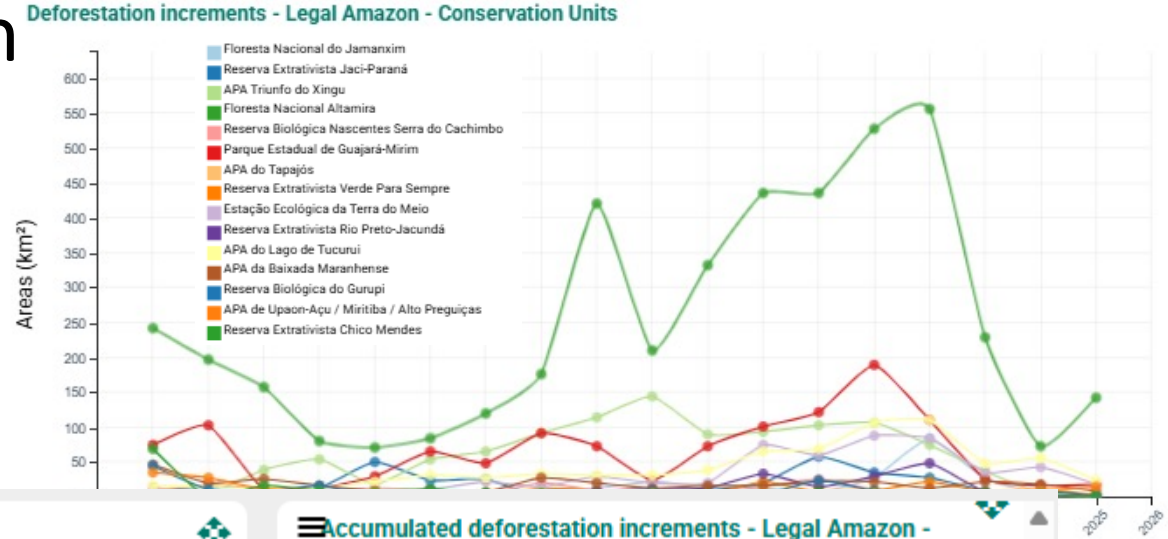


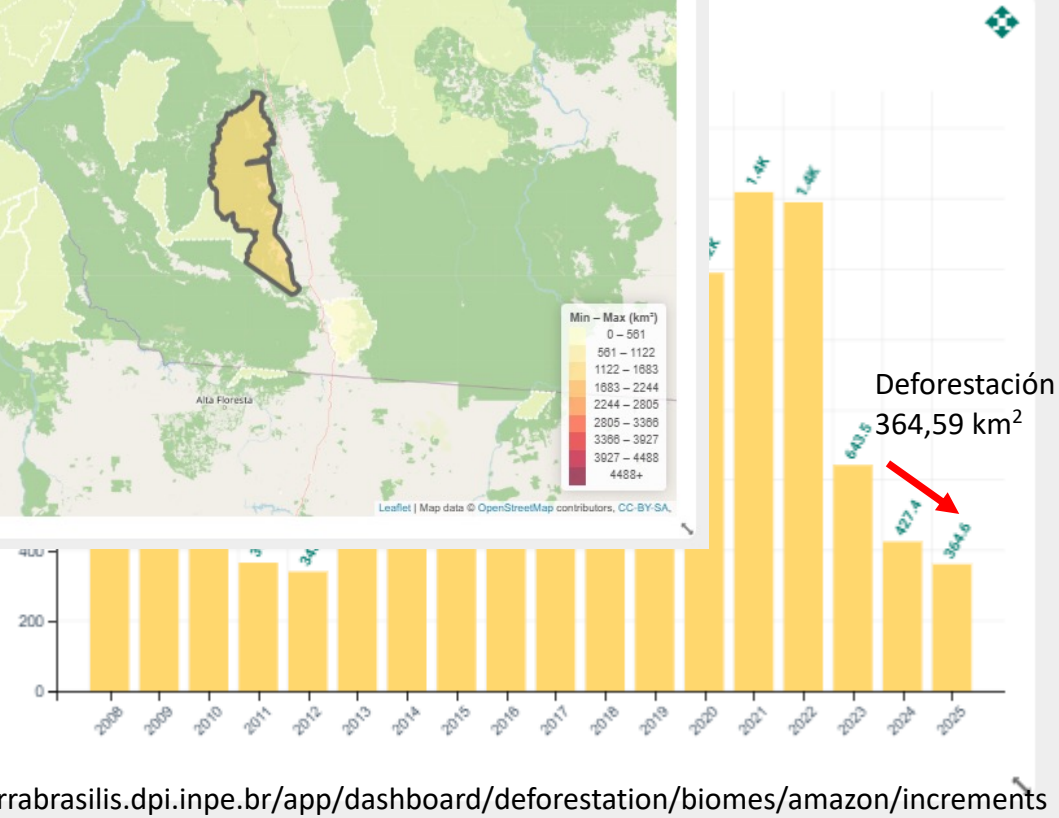
https://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/increments

104

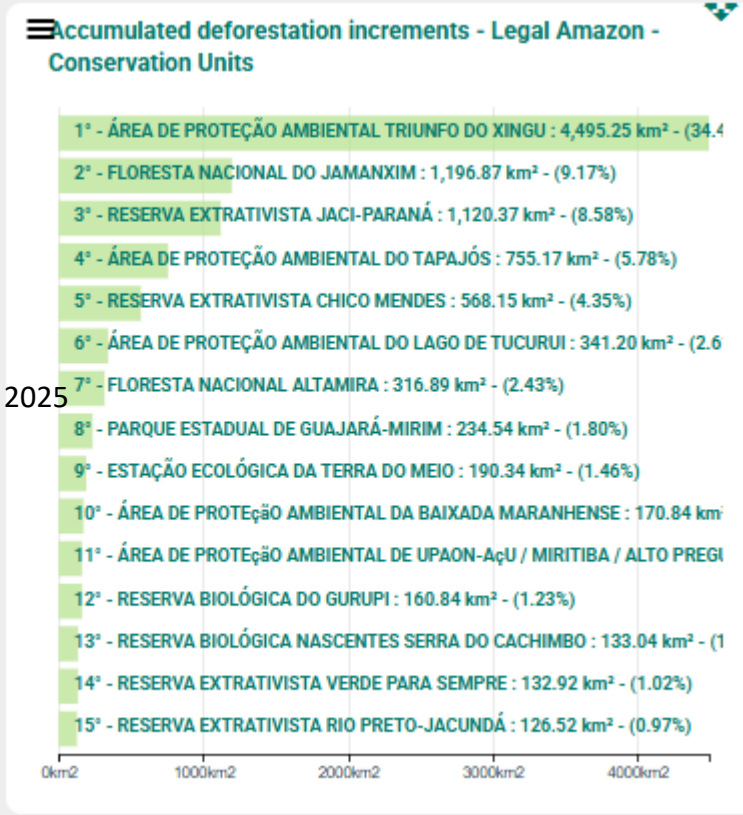
Unidades de conservación







Deforestación 2025
364,59 km²



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

105

Biomas Br

Prodes

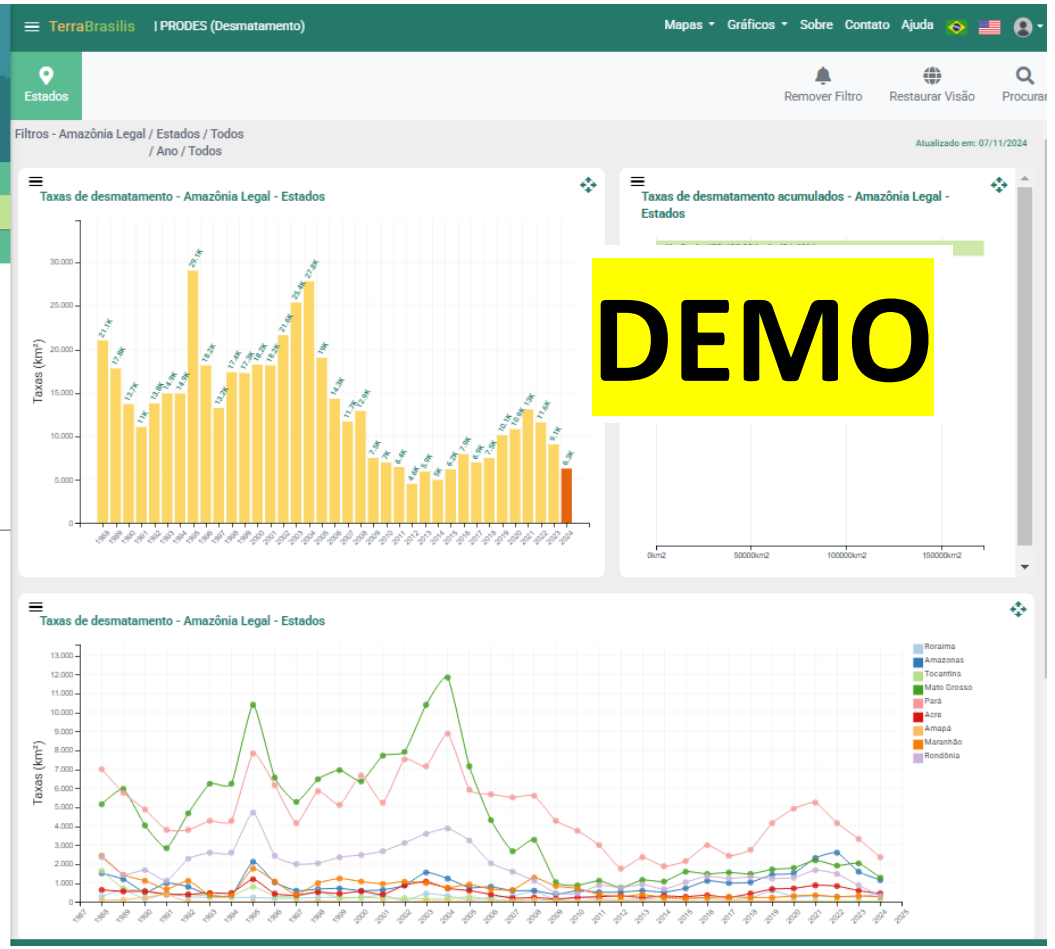
TerraBrasilis

TerraBrasilis - plataforma desarrollada por el INPE para la **organización, el acceso y el uso** de los datos geográficos de los sistemas de monitoreo ambiental.

Mapas



Panel - gráficos / consultas



Y descarga https://terrabrasilis.dpi.inpe.br/

Prodes – Cumplimiento ambiental

Instituciones brasileñas que evalúan el cumplimiento (CONAB / SERPRO) con datos Prodes

A) EUDR - Reglamento de la Unión Europea sobre deforestación

Los productos procedentes de tierras deforestadas después del **31 de diciembre de 2020** no podrán comercializarse

B) **Crédito agrícola** (Resolución CMN n.º 5.193/2024)

Restricciones de crédito para áreas deforestadas después del **31 de julio de 2019**

C) **«Área rural consolidada»*** (Decreto n.º 6.514/2008),

Código Forestal – la deforestación ilegal anterior al **22 de julio de 2008** se considera consolidada y amnistiada.



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

* Son áreas que ya estaban ocupadas por agricultura, ganadería o infraestructuras antes del 22 de julio de 2008 (fecha fijada por el Código Forestal).

107

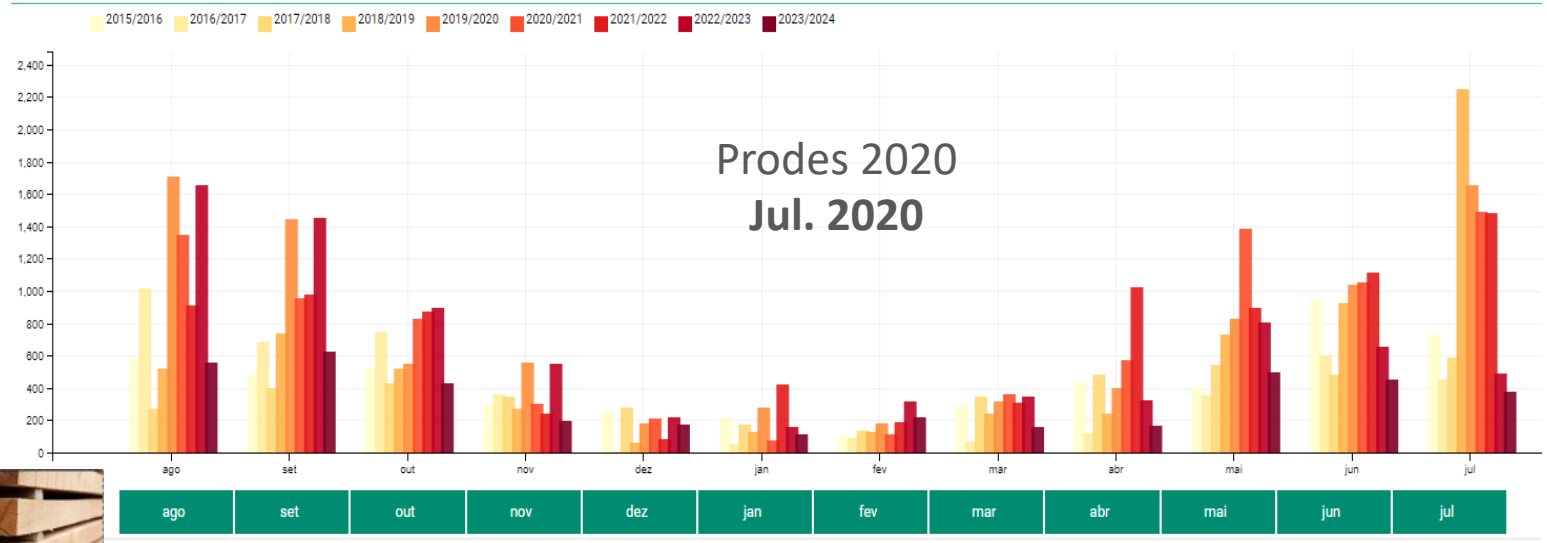
Prodes – diciembre de 2020 EUDR

Reglamento de la Unión Europea sobre deforestación (EUDR)*
(EUDR 2023/1115)

Referencia – **31/12/2020**

Área mínima = **0,5 ha**

Prodes – Calendario





** El EUDR 2023/1115 busca prevenir la deforestación y la degradación forestal ligadas a productos comercializados en la UE o exportados desde ella, exigiendo a las empresas garantizar que los productos no procedan de tierras deforestadas después del 31 de diciembre de 2020.*

Prodes – diciembre de 2020 EUDR

Reglamento de la Unión Europea sobre deforestación (EUDR)
(EUDR 2023/1115)

Metodología

Datos Sentinel-2/MSI – series temporales
Brazil Data Cube (BDC)

Atributos espectrales:
B04, B8A, B11, NDVI, NBR, NDWI, AWEINSH, textura B8A (media).

Algoritmos de agrupamiento no supervisado
SOM - Mapa autoorganizado (SOM)
AHC - Agrupamiento jerárquico aglomerativo

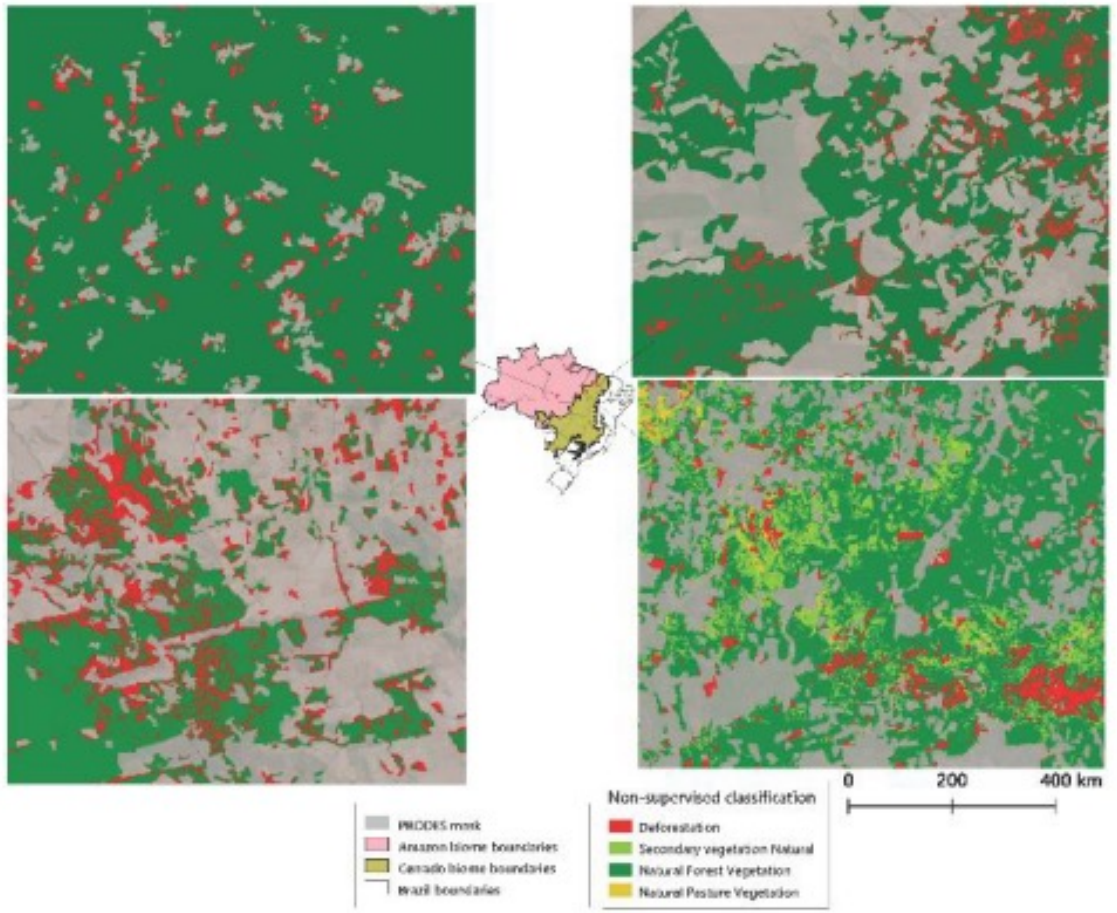
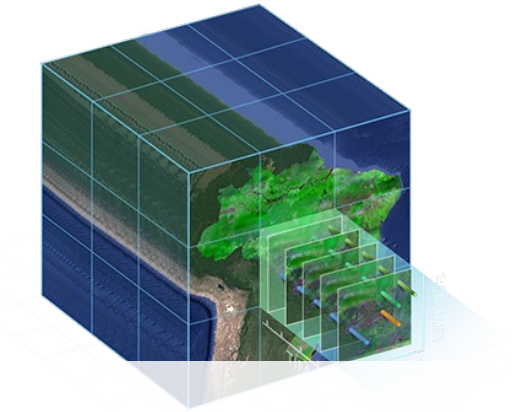


Figure 2. Tiles classified in the Brazilian Amazon and Cerrado biomes using the non-supervised approach.

Soler et al. (2025)

Prodes – dic. 2020 EUDR

Reglamento de la Unión Europea sobre deforestación (EUDR)
(EUDR 2023/1115)



Brazil Data Cube

Ago.-dic. 2020

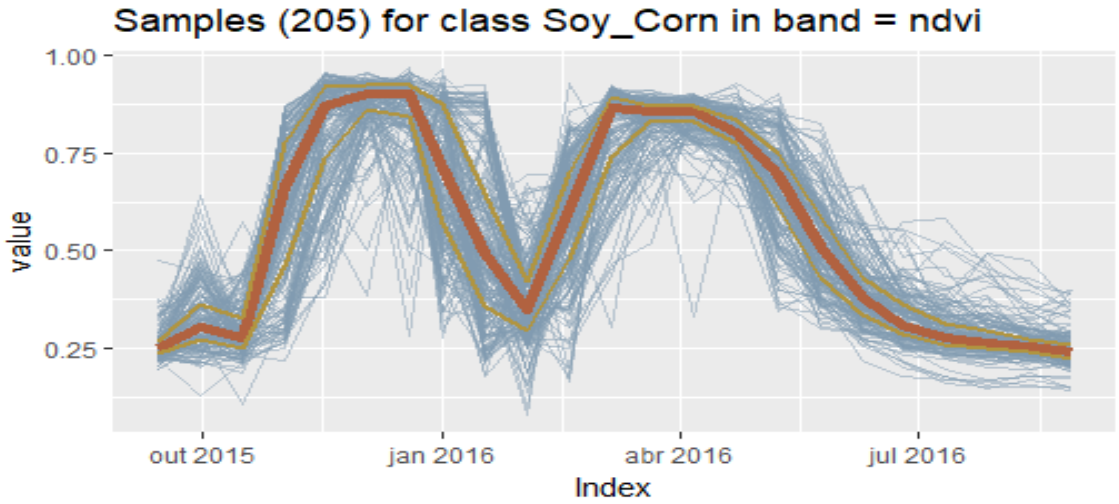
Mapa autoorganizado (SOM)
Algoritmo no supervisado basado en IA
(aprendizaje profundo)

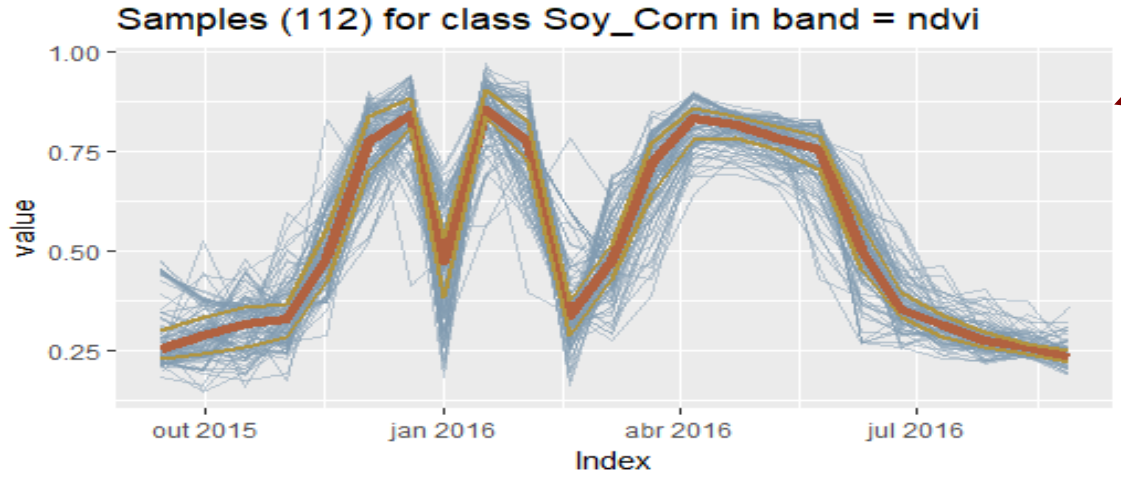
Dendrogramas - número de neuronas
AHC - Agrupamiento jerárquico aglomerativo

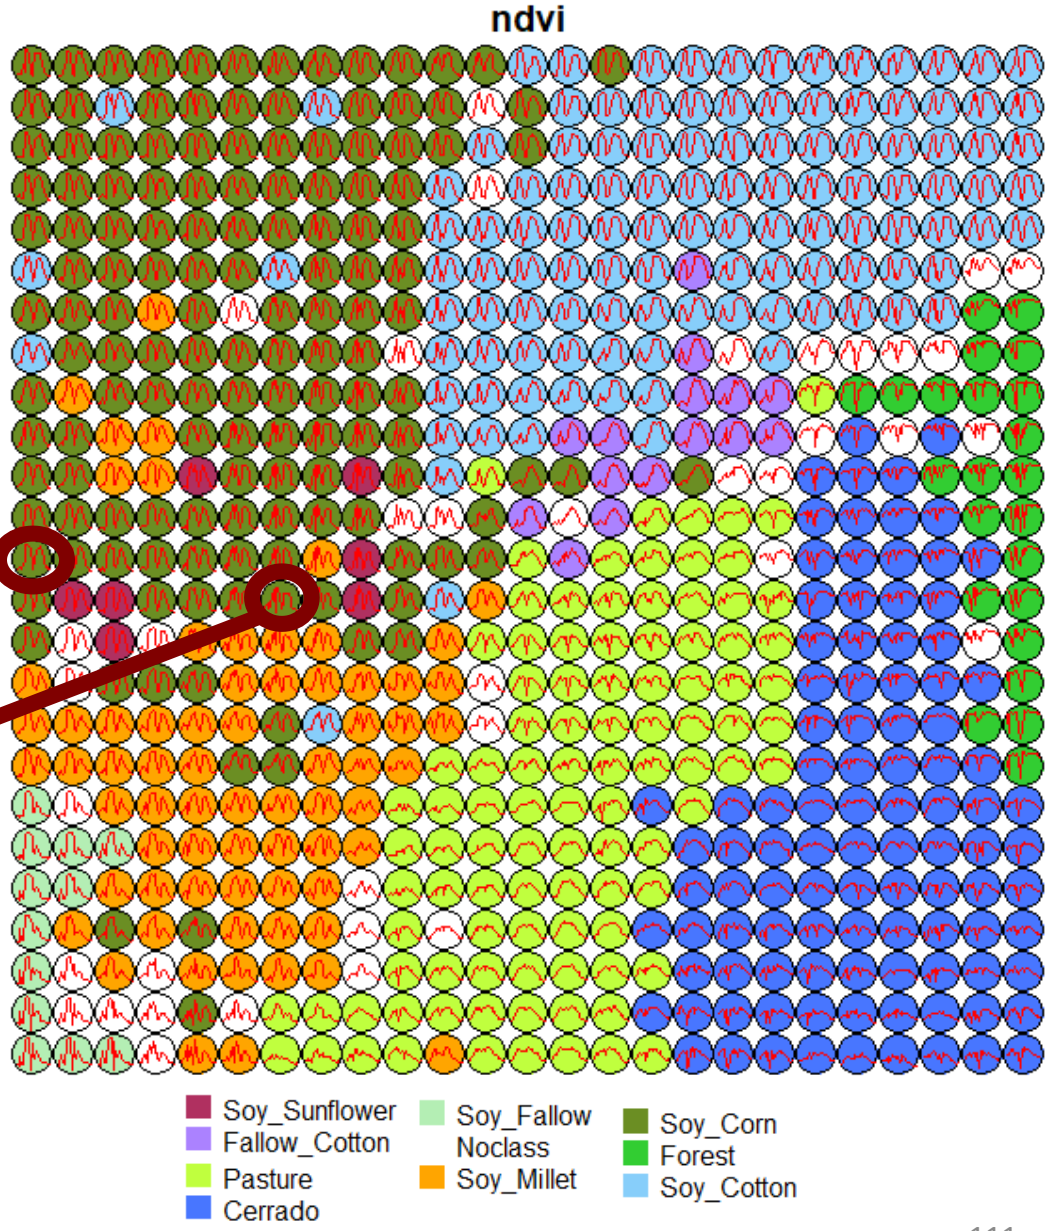
Etiquetado de segmentos – inspección visual

SOM para identificar distintos patrones SITS

Red neuronal de mapas autoorganizados (SOM) para agrupar SITS

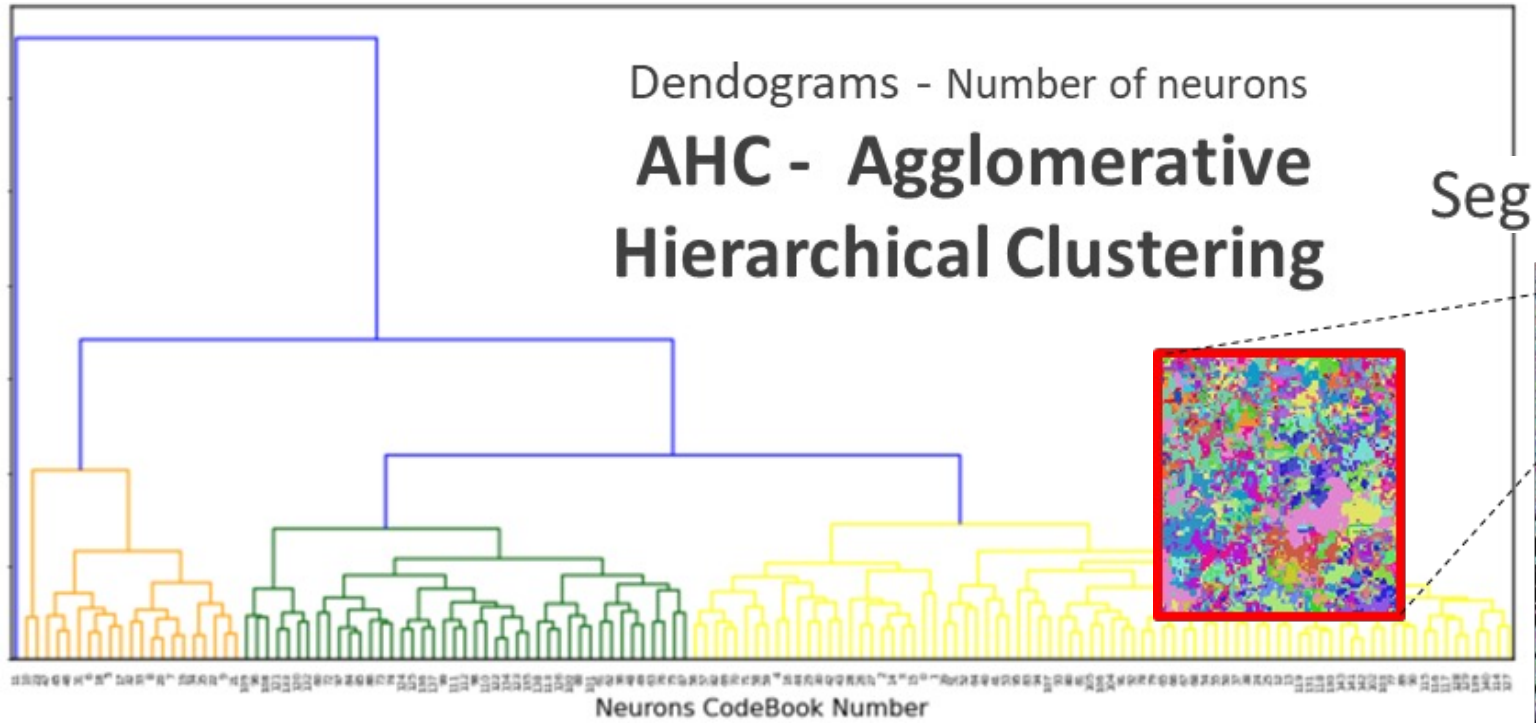




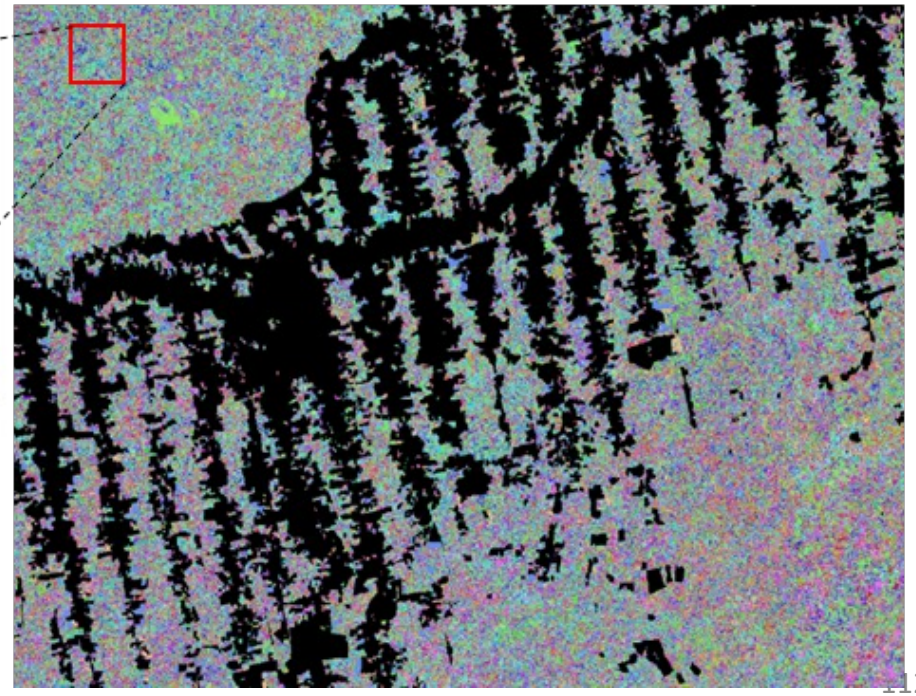


Prodes – dic. 2020 EUDR

Reglamento de la Unión Europea sobre deforestación



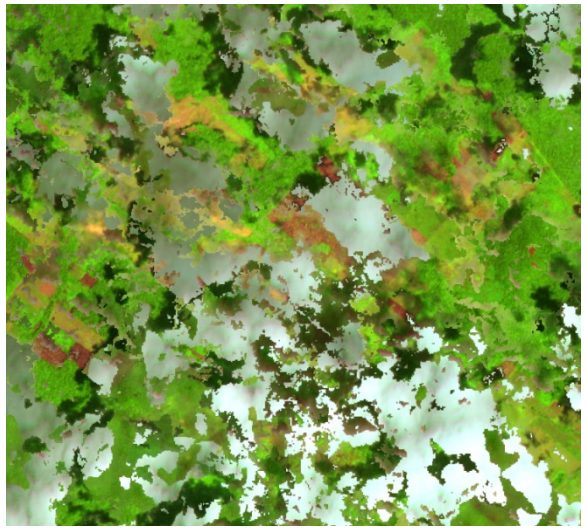
Segment labelling – Visual inspection



Prodes – diciembre de 2020 EUDR

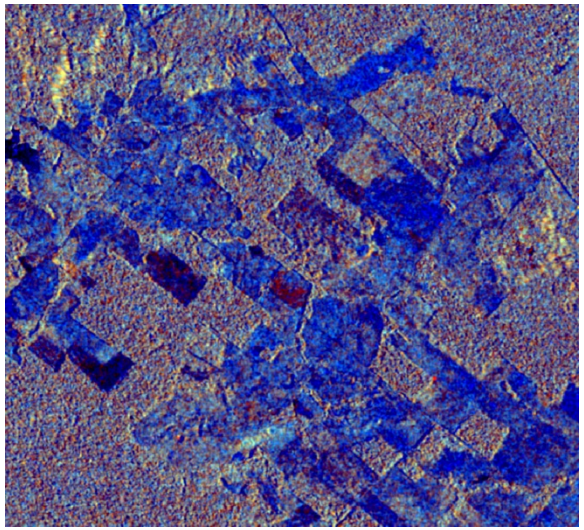
Radar – datos auxiliares

Imagen mosaico Sentinel-2 BDC dic. 2020



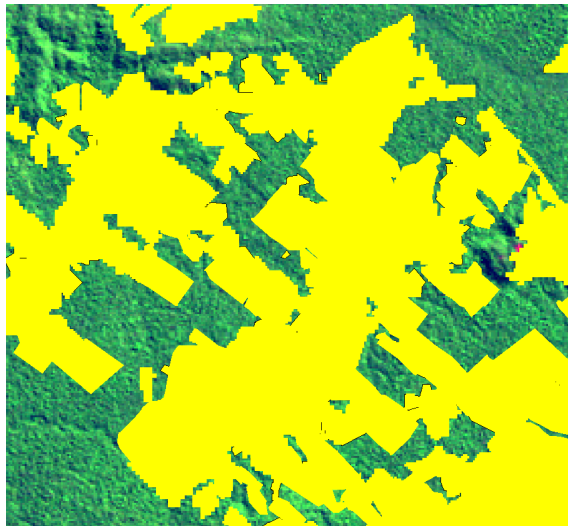
Sentinel - 2 (MSS)

Imagen radar 28/12/2020 (sin nubes)



Sentinel - 1 (SAR)

Delimitación de áreas deforestadas (amarillo)



Prodes – Validación de la precisión

Procesos PRODES: implicaciones para la calidad de los datos

Aspectos de la **calidad de PRODES**:

I - Requisitos de los procesos de mapeo

II - Validación externa

III - Transparencia

Selección y procesamiento de imágenes	Mejor periodo de detección Menor cobertura nubosa
Inspección visual	Equipo multidisciplinario y con experiencia Estandarización de la leyenda y del protocolo Datos auxiliares Información sobre particularidades regionales o locales
Auditoría	Proceso sistemático (100 % del territorio) Inspección visual
Posprocesamiento	Verificación de coherencia y de reglas de procesamiento
Validación del mapa	Muestreo estratificado y aleatorio Personal externo
Difusión de datos	Transparencia (http://terrabrasilis.dpi.inpe.br/) Informes técnicos Publicaciones científicas

Auditor independiente
Expertos de cada bioma

Validador

Imágenes satelitales de alta resolución como referencia

Mosaico mensual Planet (5 m)

WPM/CBERS4 – PCA (2m)

Prodes – Comando y control

Plan de Acción para la Prevención y el Control de la Deforestación en la Amazonía Legal (PPCDAm)

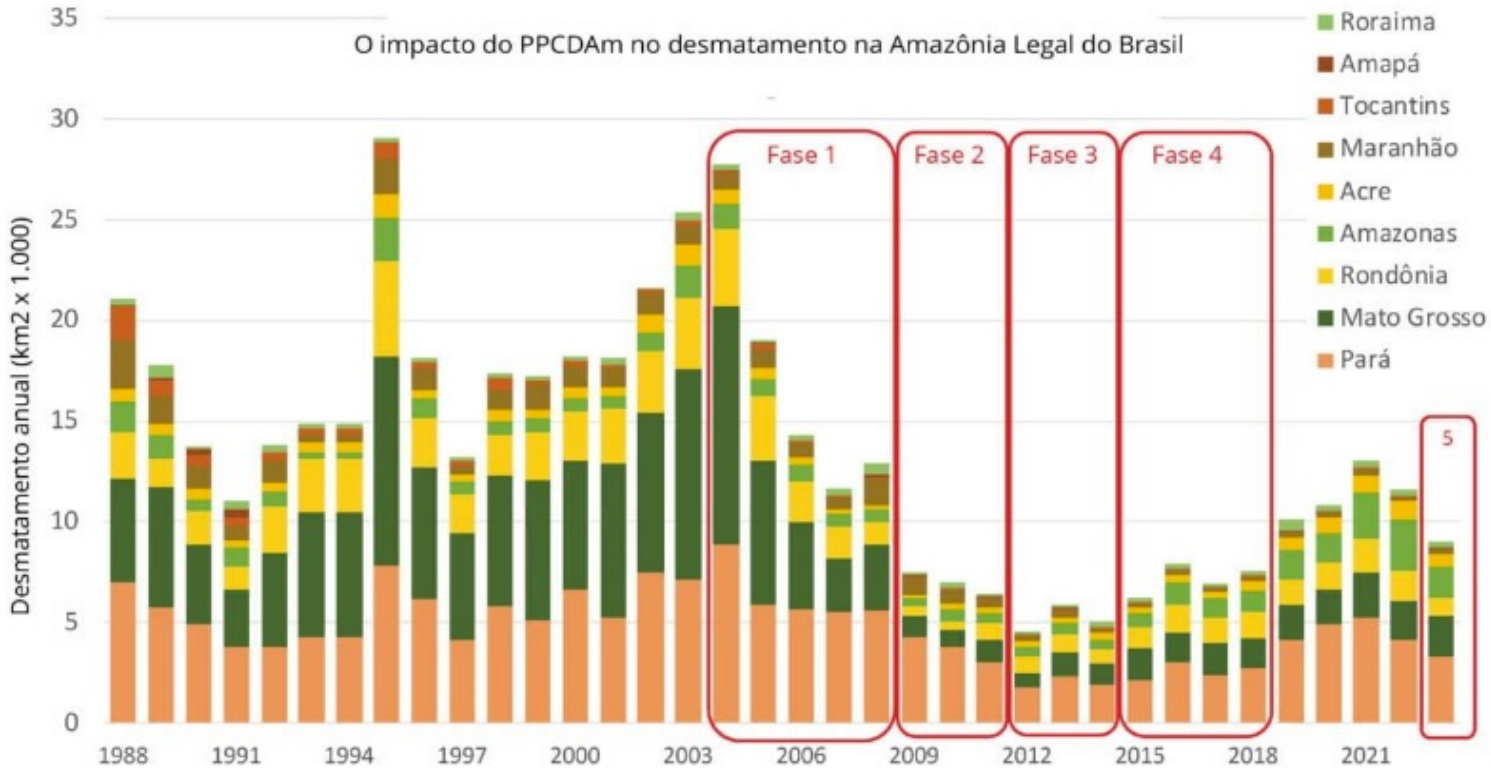
Lanzado en 2003 – descenso de la deforestación entre 2004 y 2012.

En 2009,
Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC)
Reducción del 80 % de la deforestación para 2020.

2012 – meta superada.
Tasa anual = 20 % de su media histórica de veinte años.

2018 – gobierno de Bolsonaro – desmanteló el programa

2023 – fase 5 – ONG, contención de la deforestación y regularización de la tierra para comunidades forestales, asentamientos agrarios y agricultores familiares; - producción sostenible, REDD+, restauración



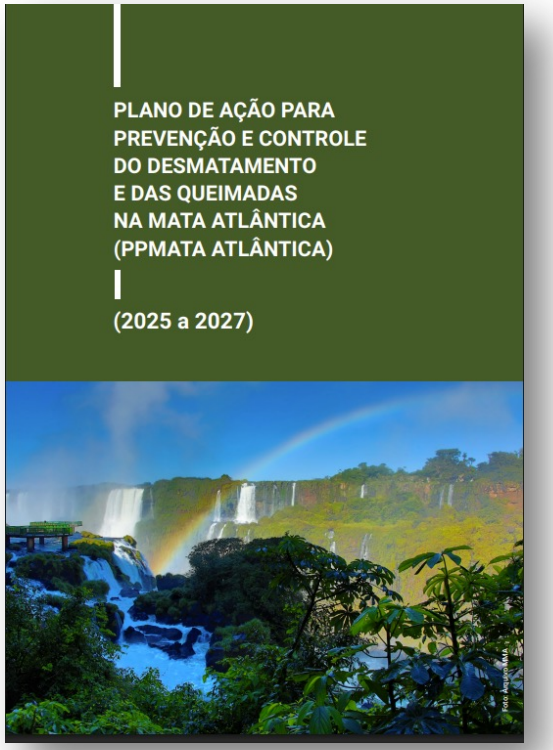
https://brasil.mongabay.com/2025/09/a-formula-que-reduziu-o-desmatamento-no-brasil-no-seculo-21/

115

Prodes – Comando y control

Plan de Acción para la Prevención y el Control de la Deforestación (PPCD)
Todos los biomas

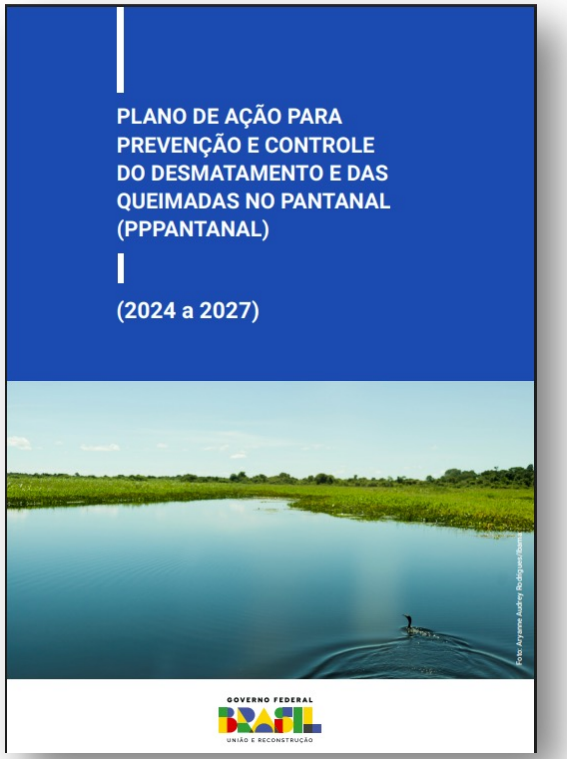
(decreto de 2023 – además del PPCDAm y el PPCerrado)



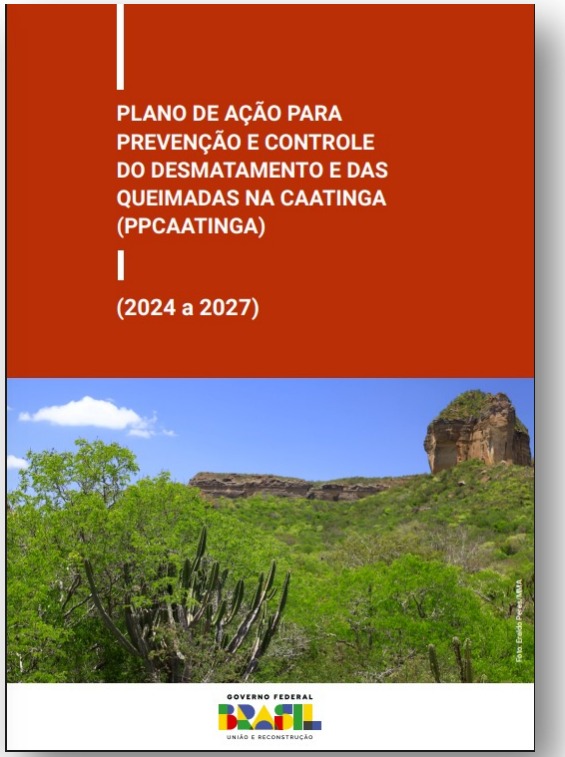
https://www.gov.br/mma/pt-br/assuntos/controle-ao-desmatamento-queimadas-e-ordenamento-ambiental-territorial/controle-do-desmatamento-1/ppmata-atlantica/PPMata_Atlantica_2025_internet_final.pdf



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

Monitoreo diario de la supresión y la degradación de la vegetación nativa



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

Alertas de supresión/degradación

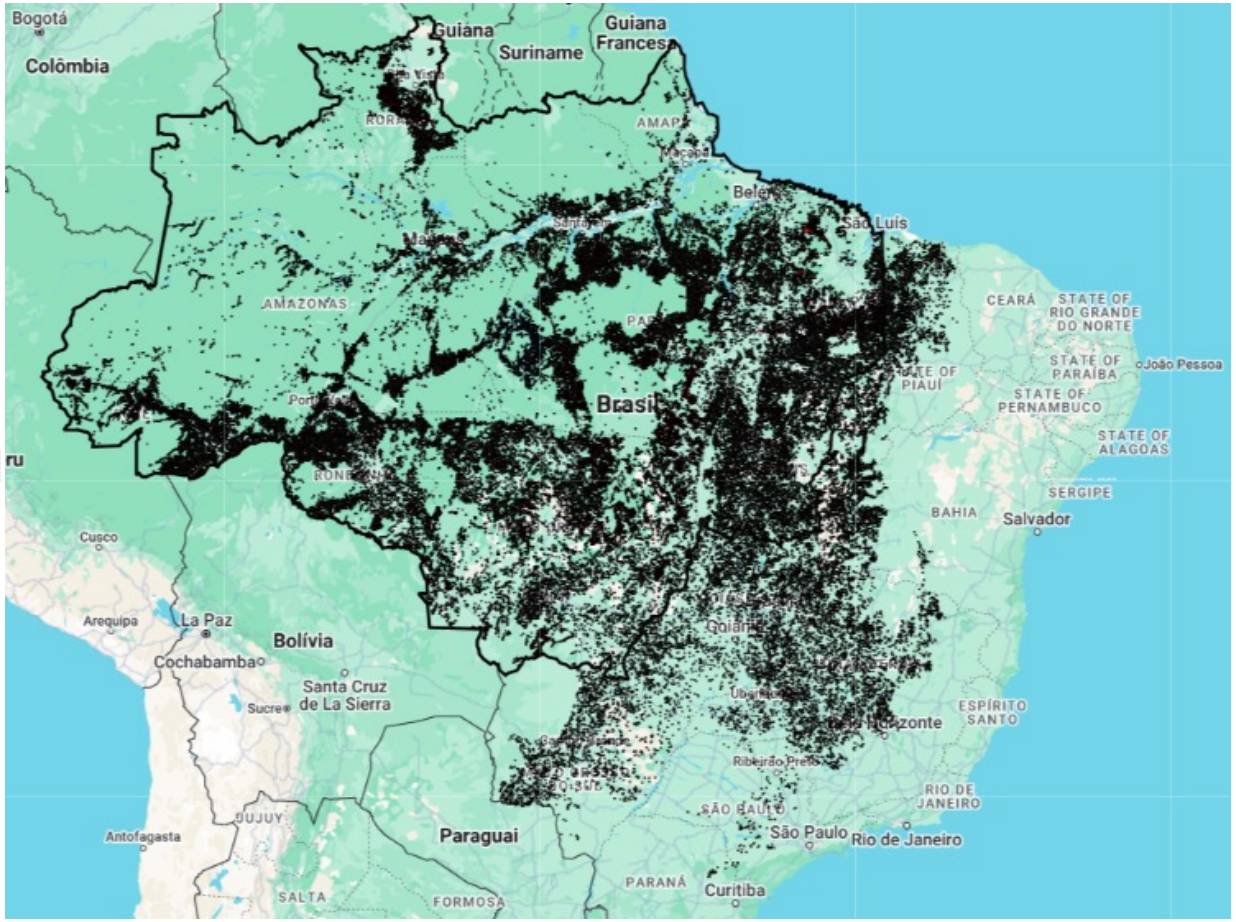
Deter

Amazonía, Cerrado,
Pantanal y Amazonía no forestal

Se producen <u>alertas</u> diarias
Agregados mensuales, también publicados

Las alertas se envían a las instituciones de control
IBAMA, secretarías de medio ambiente estatales y municipales, etc.

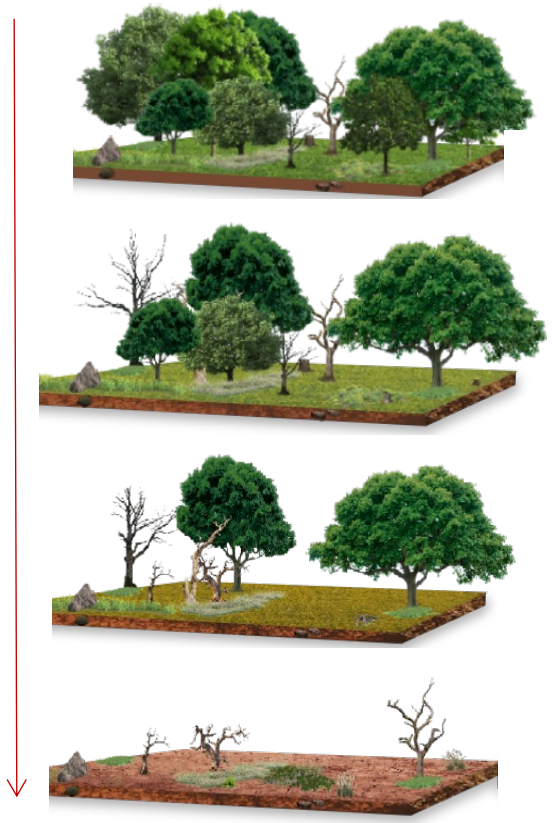
Datos: polígonos, tablas, vectores;
Disponibles en la plataforma **TerraBrasilis**

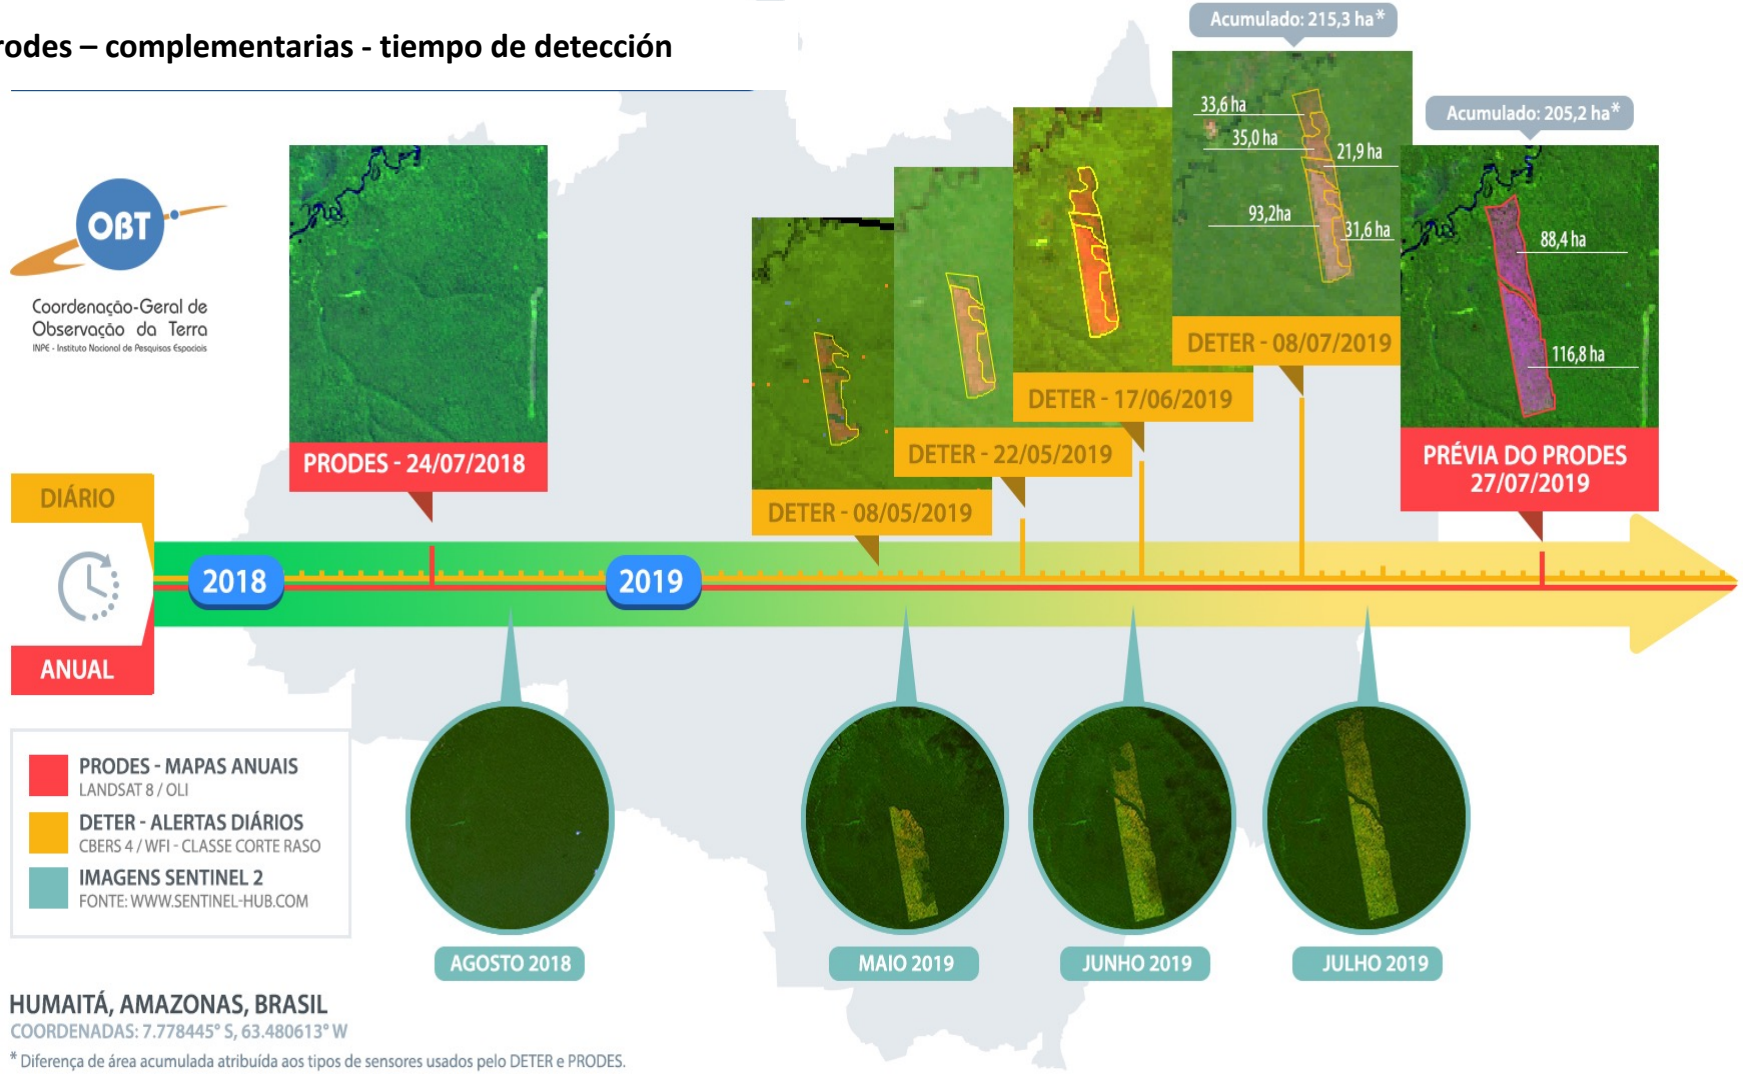


https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supresión/degradación

Alertas diarias Deter x Prodes – complementarias - tiempo de detección





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 supresión/degradación

Deter

Amazonía, Cerrado,
Pantanal y Amazonía no forestal

Deforestación, supresión y degradación forestal

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

Satélites brasileños
Amazonia 1, CBERS 4 y CBERS 4A
Sensor Wide Field Imaging – WFI

Alertas
Área mínima de **3 hectáreas**
Interpretación visual de imágenes

Máscara Prodes
Mapeo incremental
Puede tener «repeticiones»

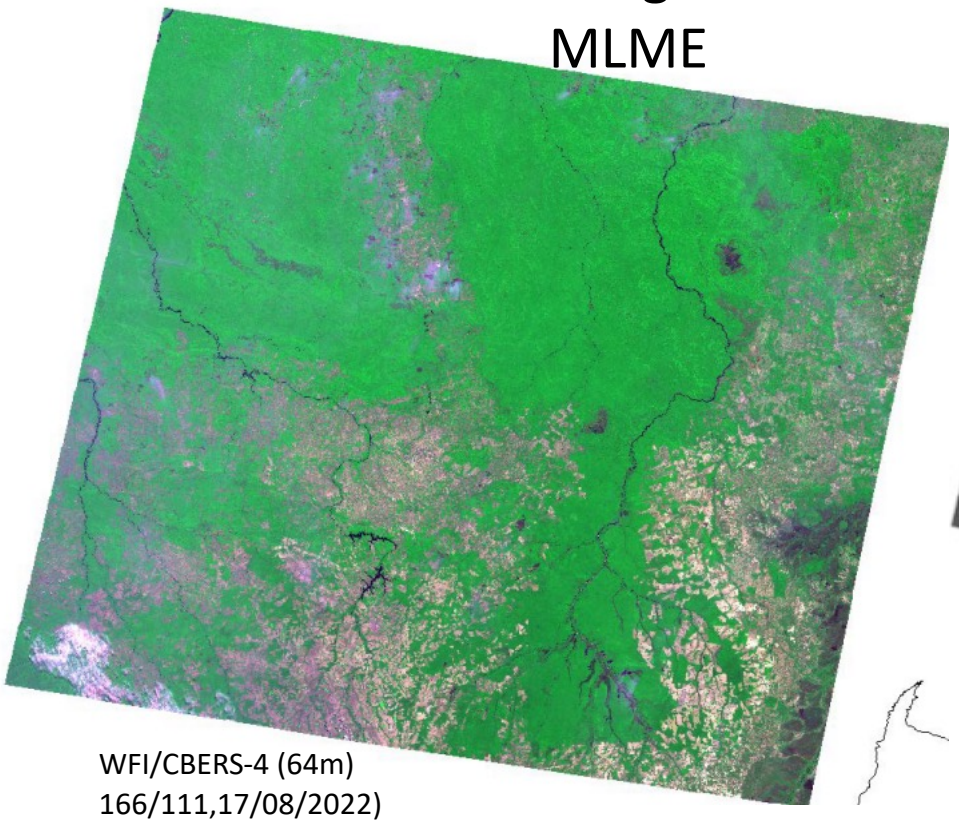




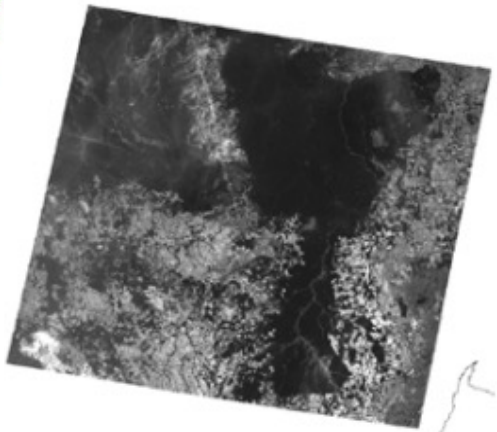
https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supresión/degradación

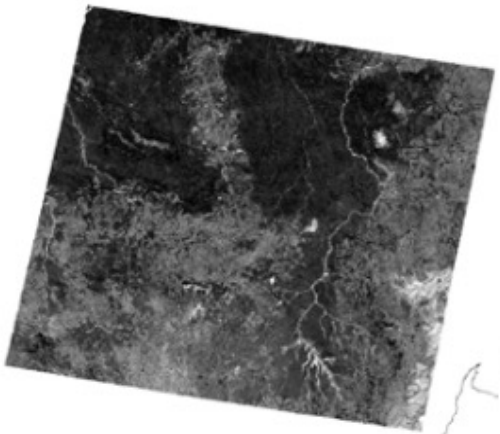
Imágenes WFI modelo lineal de mezcla espectral - MLME



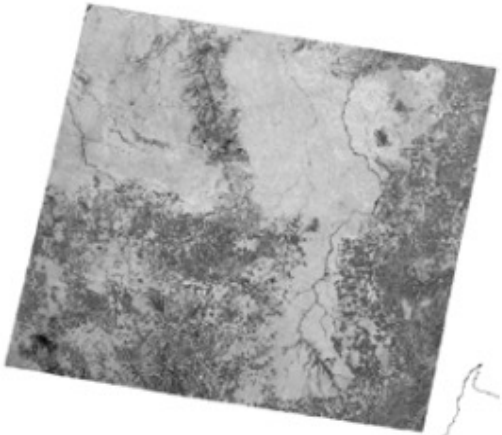
WFI/CBERS-4 (64m)
166/111,17/08/2022)
R(R)/IRp(G)/G (B)



Fracción suelo



Fracción sombra



Fracción vegetación

***Máscara Prodes para detectar alertas**

Alertas de supresión/degradación

Deter

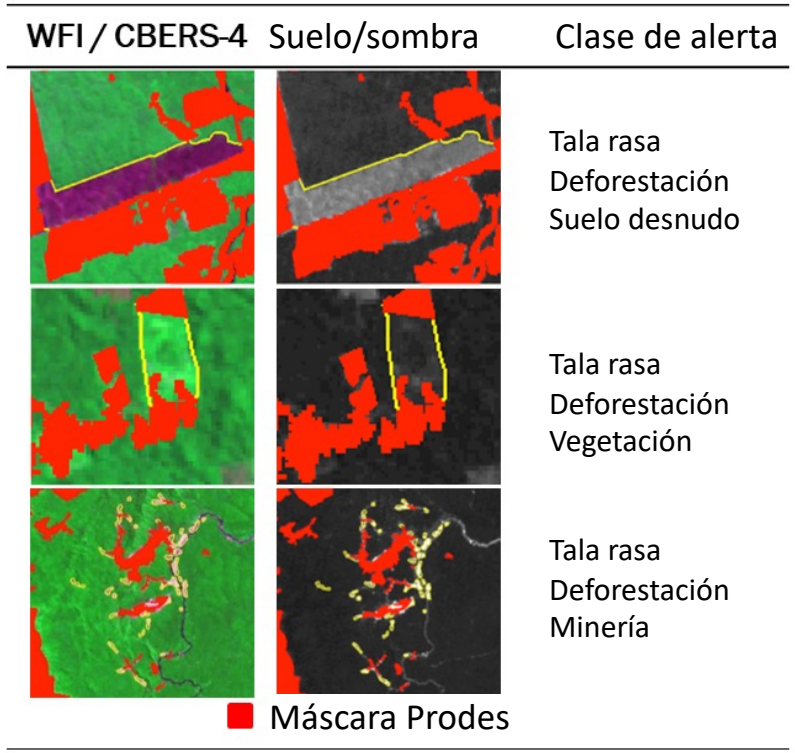
Alertas diarias

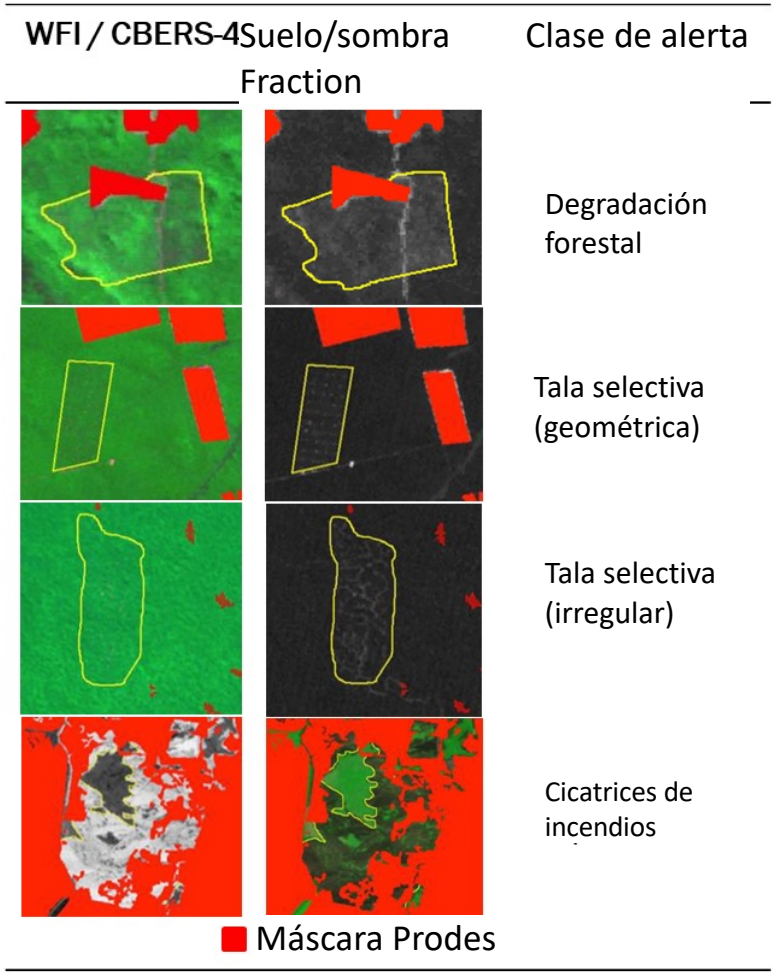
Clases:
Deforestación / supresión,

y

Cicatrices de incendios, degradación forestal y tala selectiva *(indicadores de **degradación** forestal)*

Clases DETER - Amazonía





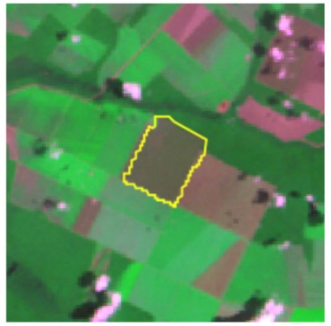
https://data.inpe.br/big/web/biomasbr/deter-monitoramento-diario-da-supressao-e-degradacao-de-vegetacao-nativa/

Alertas de supresión/degradación

DETER - antes y después

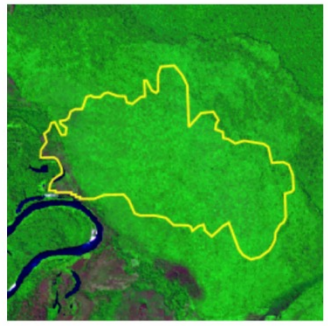
(4)
Id: 88234
Classe Deter: DESMATAMENTO_CR
Area Deter: 3.27 km2
Data imagem anterior deteccao: 2022-12-11 (CBERS-4/AWFI)
Data deteccao alerta Deter: 2023-02-01 (CBERS-4/AWFI)
Intervalo entre datas: 52 dias
Orbita/Ponto: 162/111
Ano da imagem Prodes: 2022
Ano mes mosaico Planet: 2023-02
UF: MT
Lat: -12.6941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

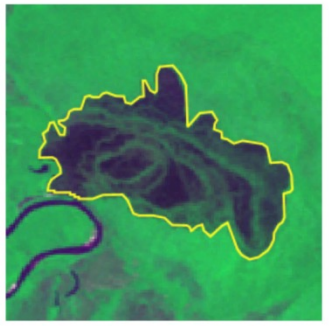
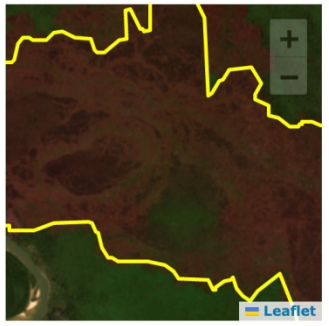





L8 2022-08 | CB4 2022-12-11 | CB4 2023-02-01 | Planet 2023-02

(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



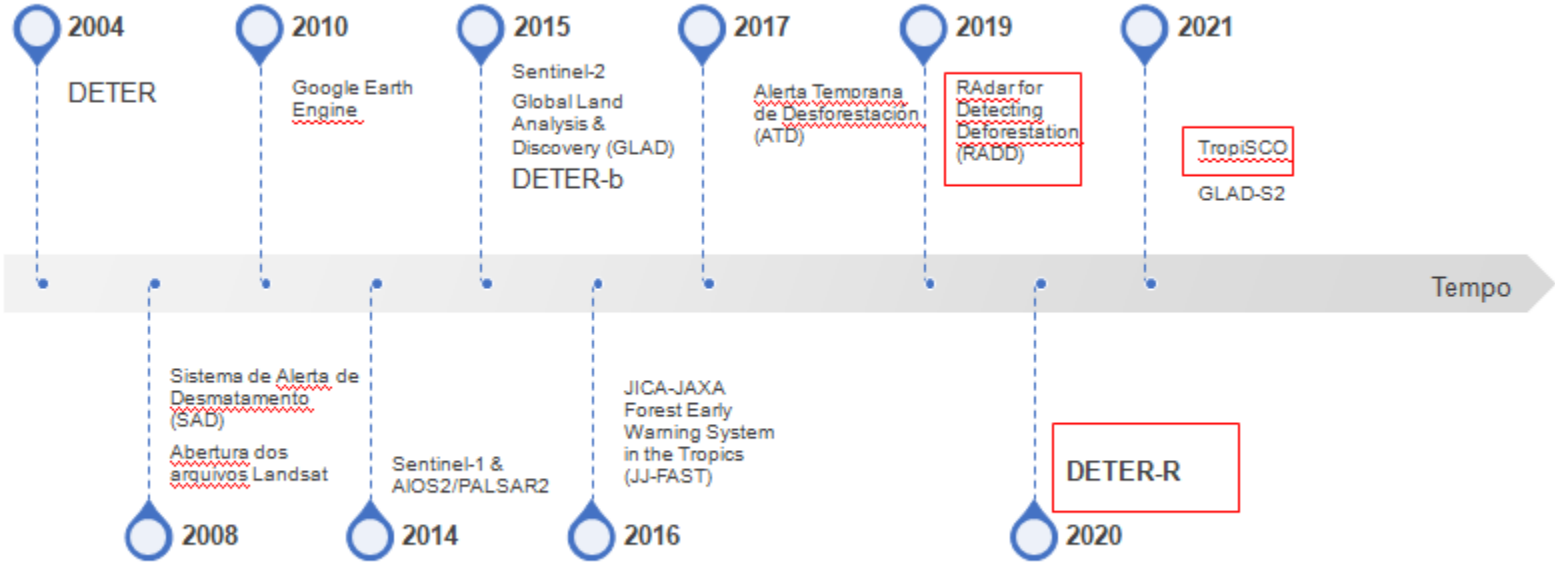



L8 2022-08 | CB4 2022-08-29 | CB4 2022-10-20 | Planet 2022-10

Alertas de supresión/degradación

Deter-R

Sistema automático de detección de perturbaciones forestales casi en tiempo real basado en imágenes SAR de banda C.



Operado de nov. 2020 a ago. 2024

Los datos generados no son públicos.

Deter-RT

El nuevo sistema INPE-TropiSCO de monitoreo de la deforestación en el bioma amazónico.

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

124

Alertas de supresión/degradación

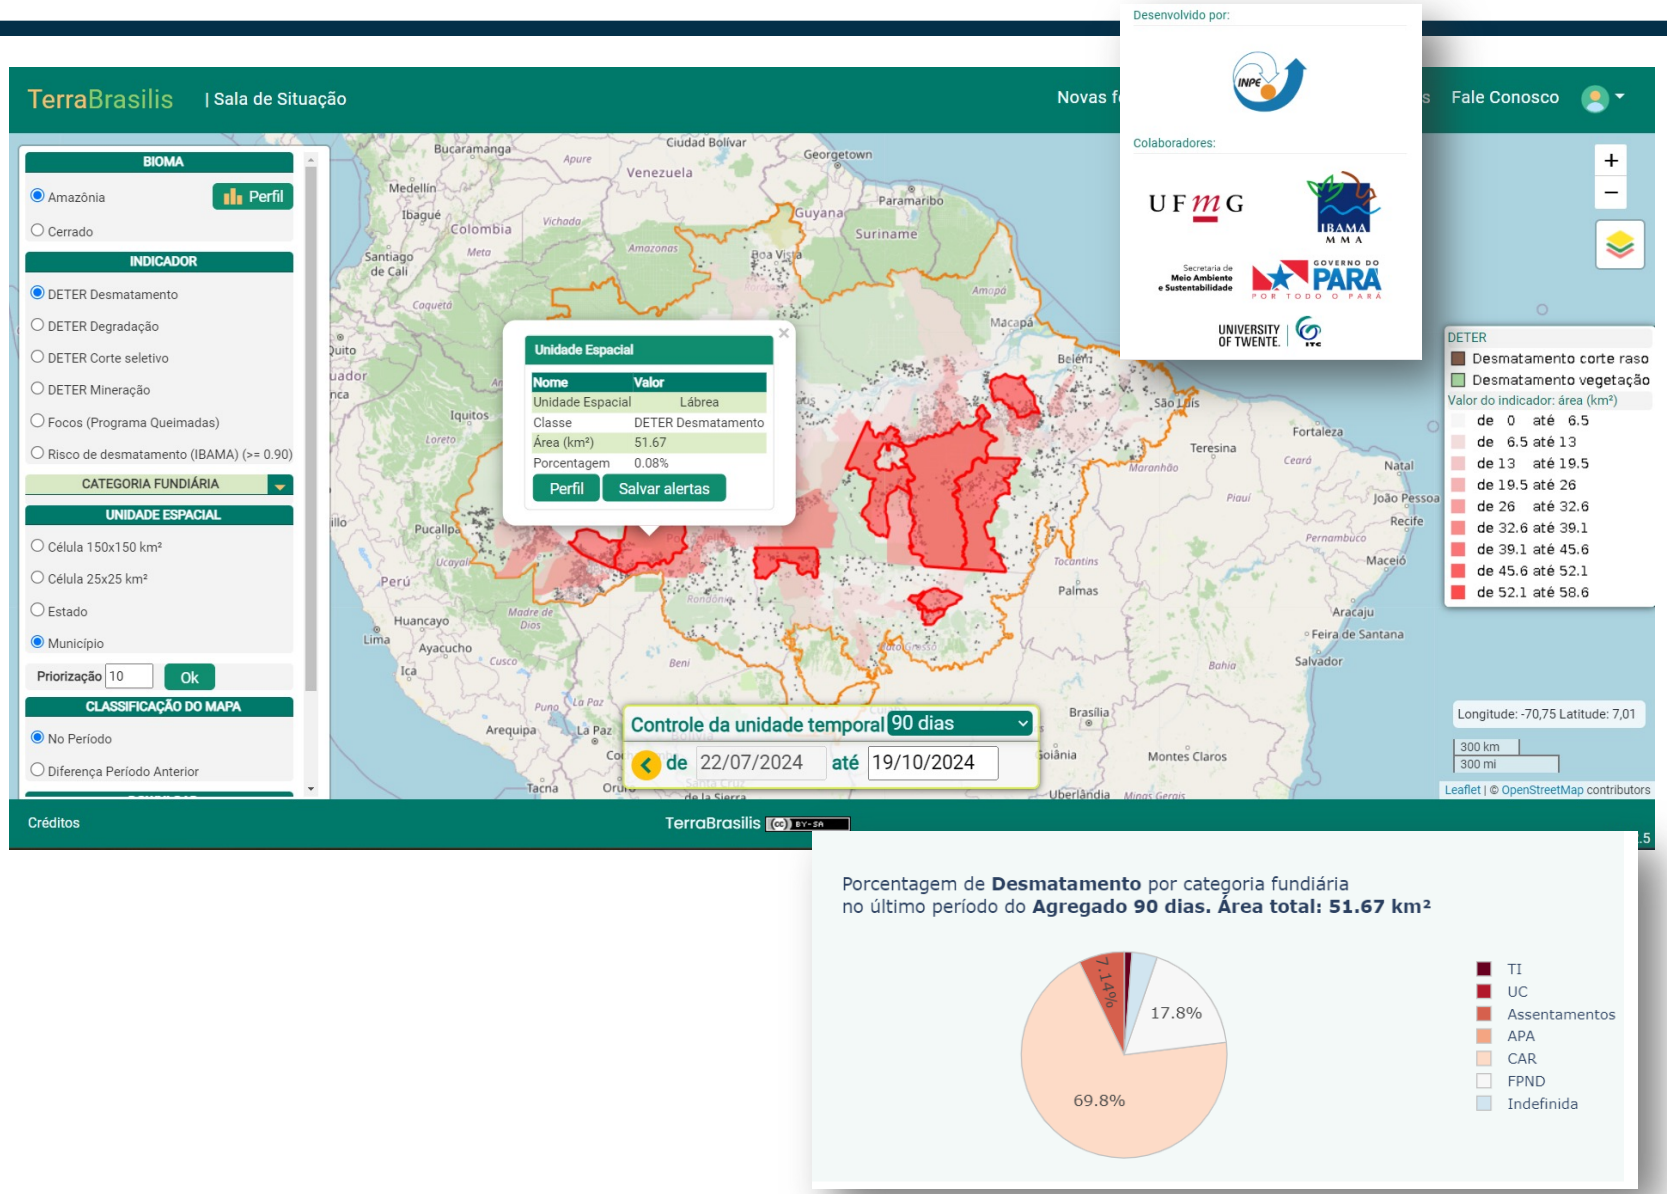
Sala de situación

DETER e incendios forestales (programa Queimadas)

Riesgo de deforestación
Modelo del IBAMA

Herramienta para los responsables de decisiones

MUNICIPIOS



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

Alertas de supresión/degradación

Evolución de Deter

Prueba de las clases Deter Amazonía



COEAM (2025)



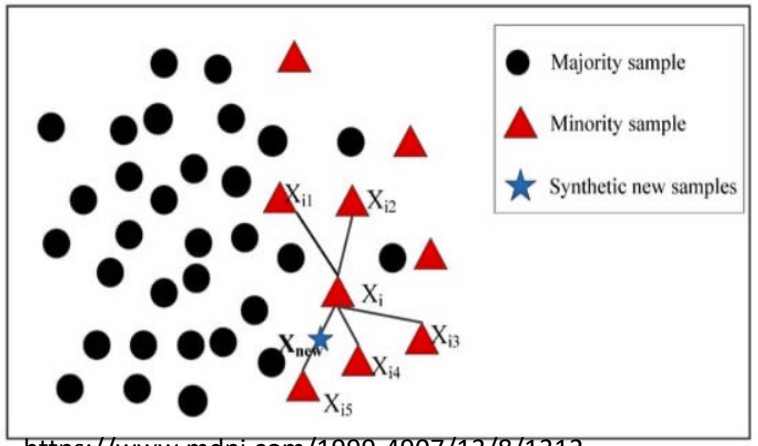
Deforestación

Random Forest con muestras sintéticas



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

Principio del algoritmo SMOTE basado en los k vecinos más cercanos.



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

Alertas de supresión/degradación

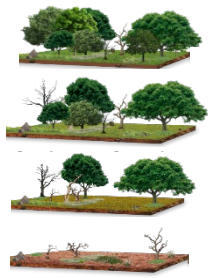


COEAM (2025)

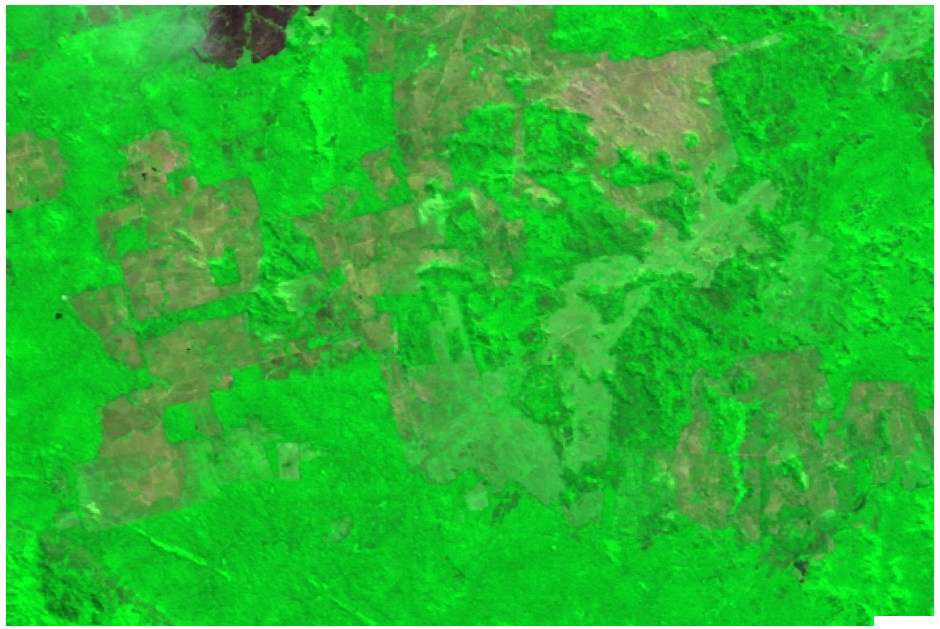
Evolución de Deter

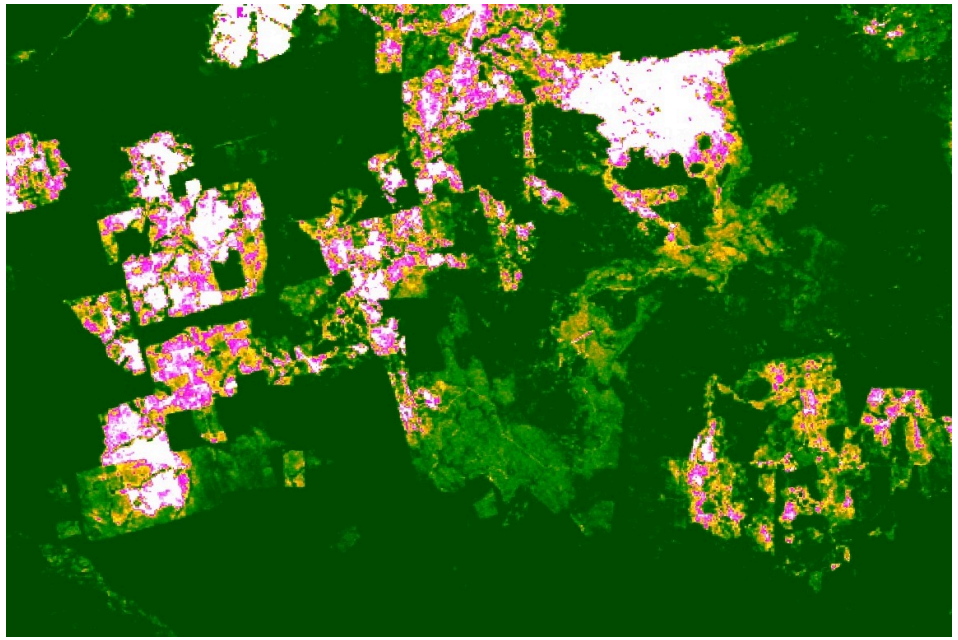
Prueba de las clases Deter Amazonía

Índices derivados del modelo lineal tipo NDFI (Normalized Difference Fraction Index)



Degradación





Distintos niveles de degradación forestal

Alertas de supresión/degradación

Evolución de Deter



COEAM (2025)

Prueba de las clases Deter Amazonía

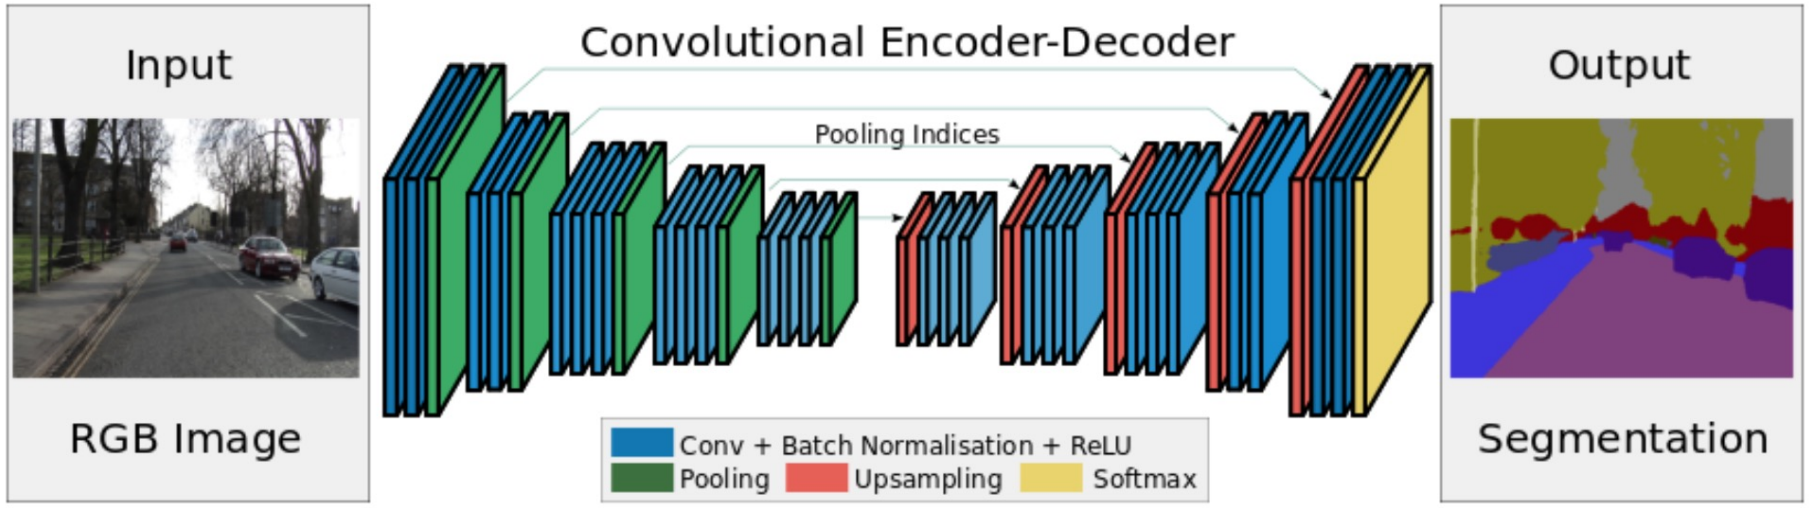


Degradación forestal por fuego



Minería

La segmentación identifica el contexto



Aprendizaje profundo con arquitectura U-net

Alertas de supresión/degradación



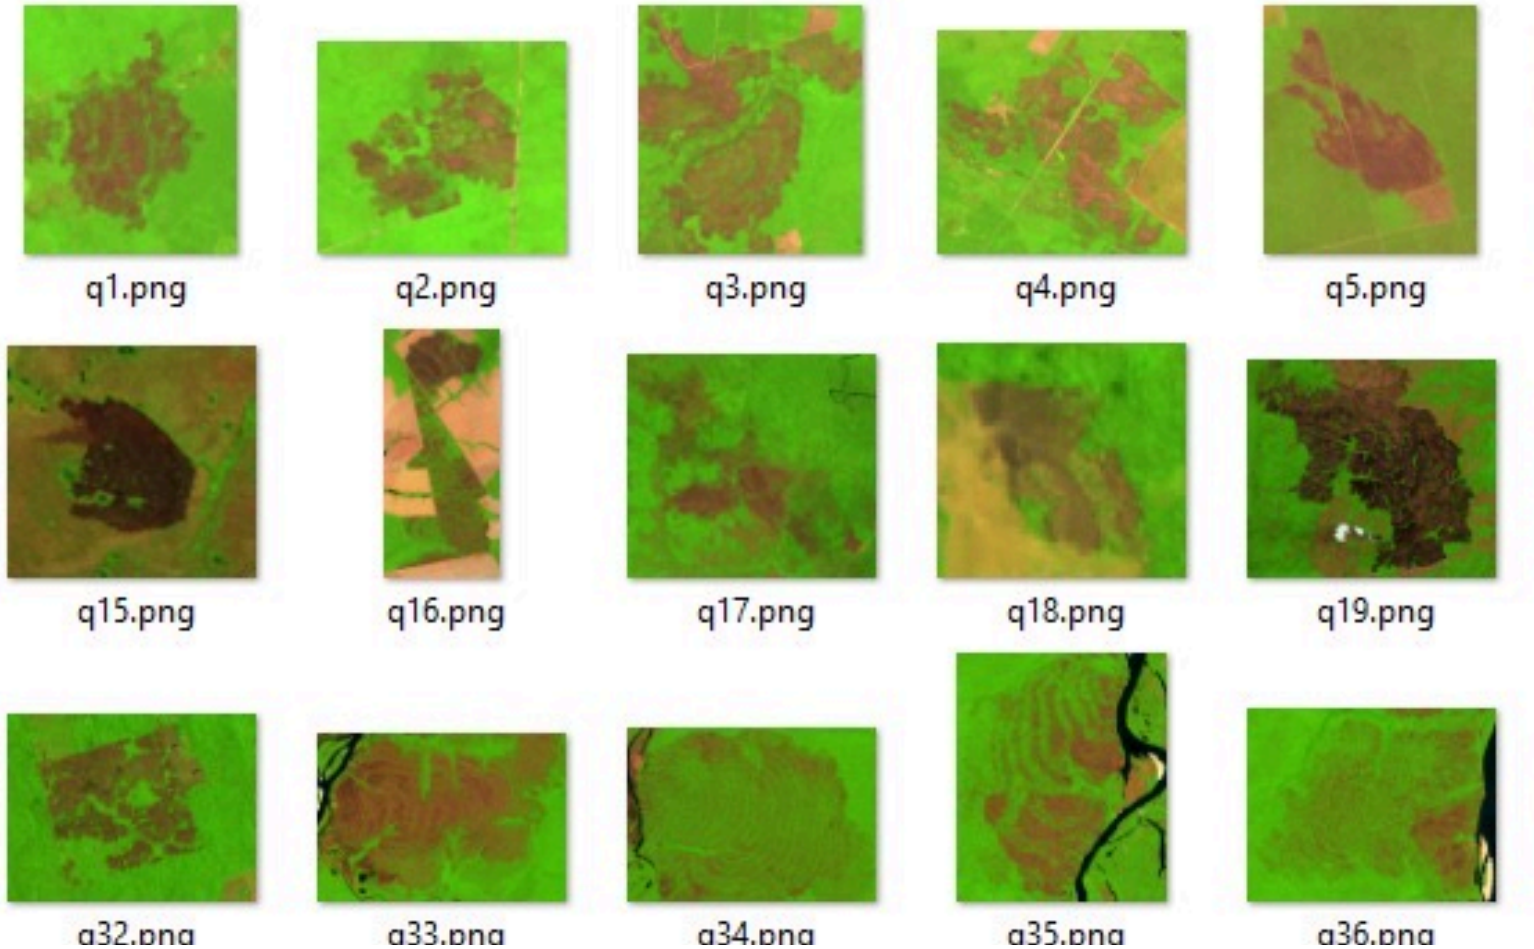
COEAM (2025)



Fuego

Evolución de Deter

Entrenamiento



Aprendizaje profundo con arquitectura U-net

Alertas de supresión/degradación



COEAM (2025)

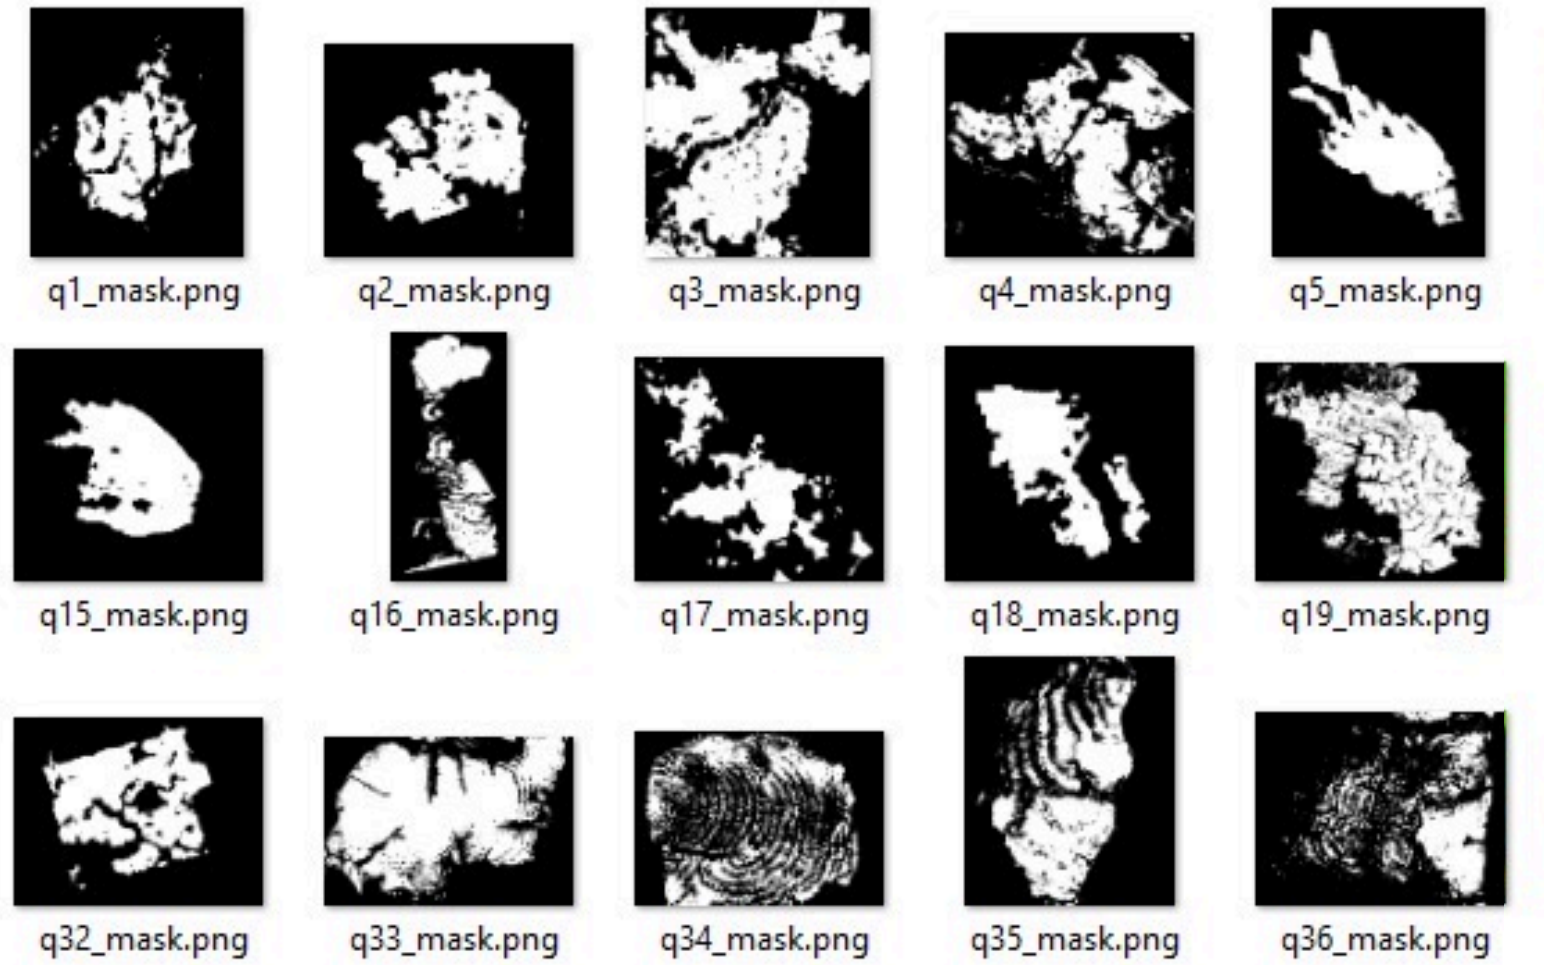
Máscara para entrenar a la red a «ver» una quema e identificarla.

Como si se entrenaran los ojos del algoritmo de segmentación.

Evolución de Deter

Enmascaramiento





Aprendizaje profundo con arquitectura U-net

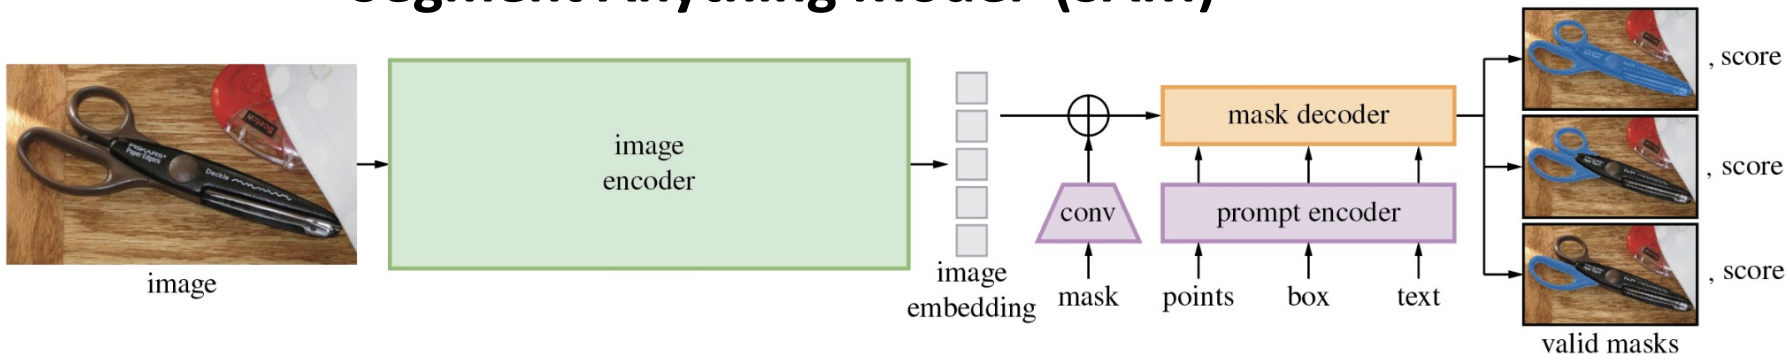
Alertas de supresión/degradación



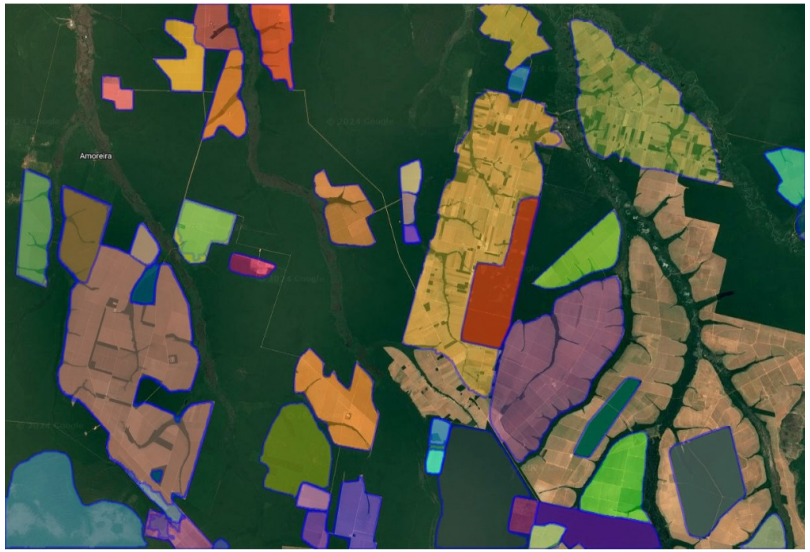
COEAM (2025)

Evolución de Deter – pruebas de algoritmos

Segment Anything Model (SAM)







YOLO (You Only Look Once)

CNN

Alertas de supresión/degradación

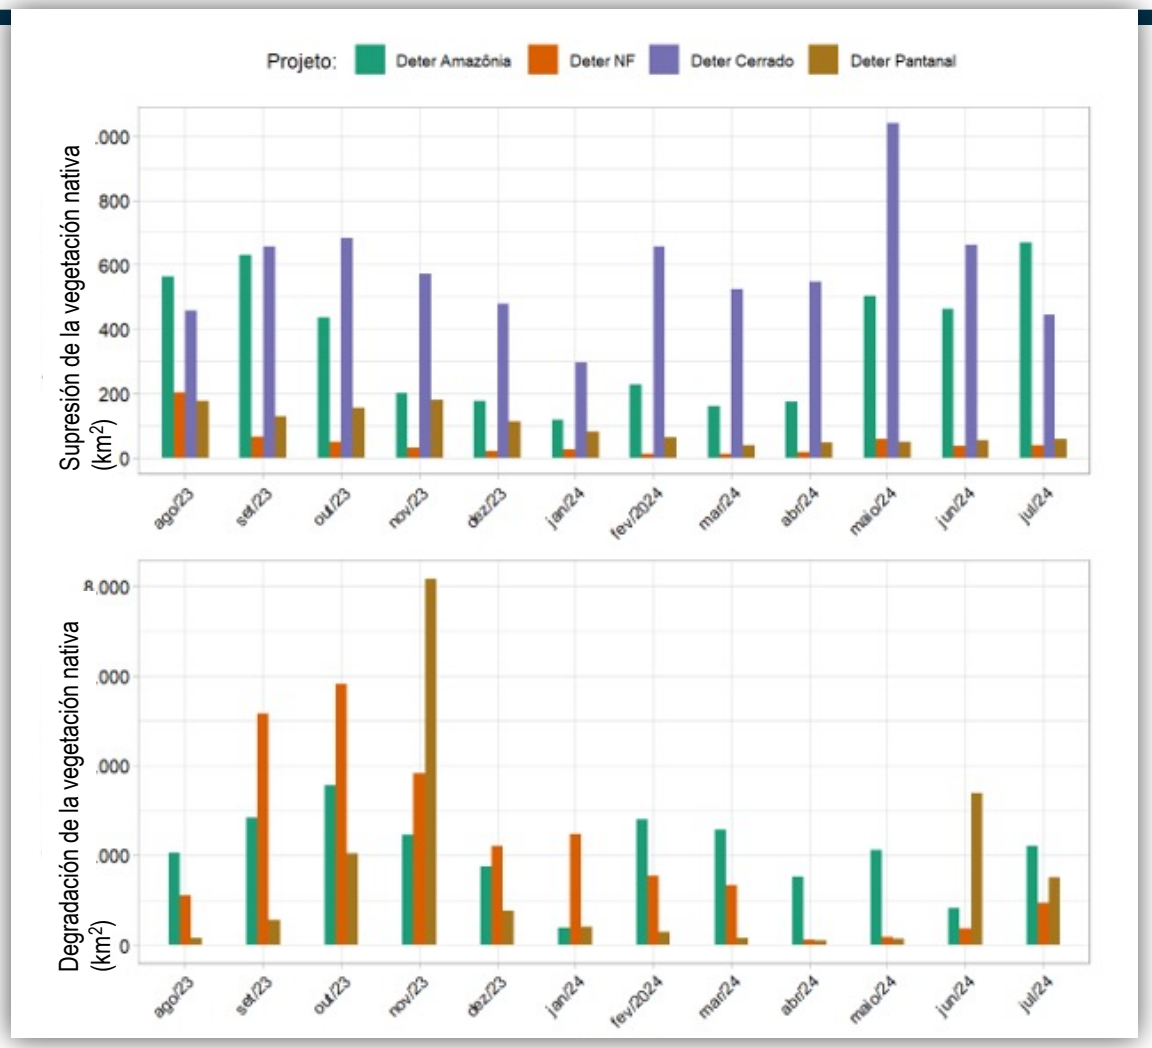
Mapas, polígonos y estadísticas DETER disponibles en la plataforma TerraBrasilis

Datos valiosos para:

- *planificar y monitorear estrategias*
- *analizar las* ***tendencias de la deforestación*** *comparando periodos*

Degradación Deter 2025 Amazonía 2025 previsión de deforestación

**Evolución – sistema integrado: Prodes a partir de Deter*



Supresión de la vegetación nativa y degradación forestal. DETER ago. 2023 – jun. 2024

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

Alertas también para la sociedad

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

Monitoreo sistémico del uso y la cobertura del suelo



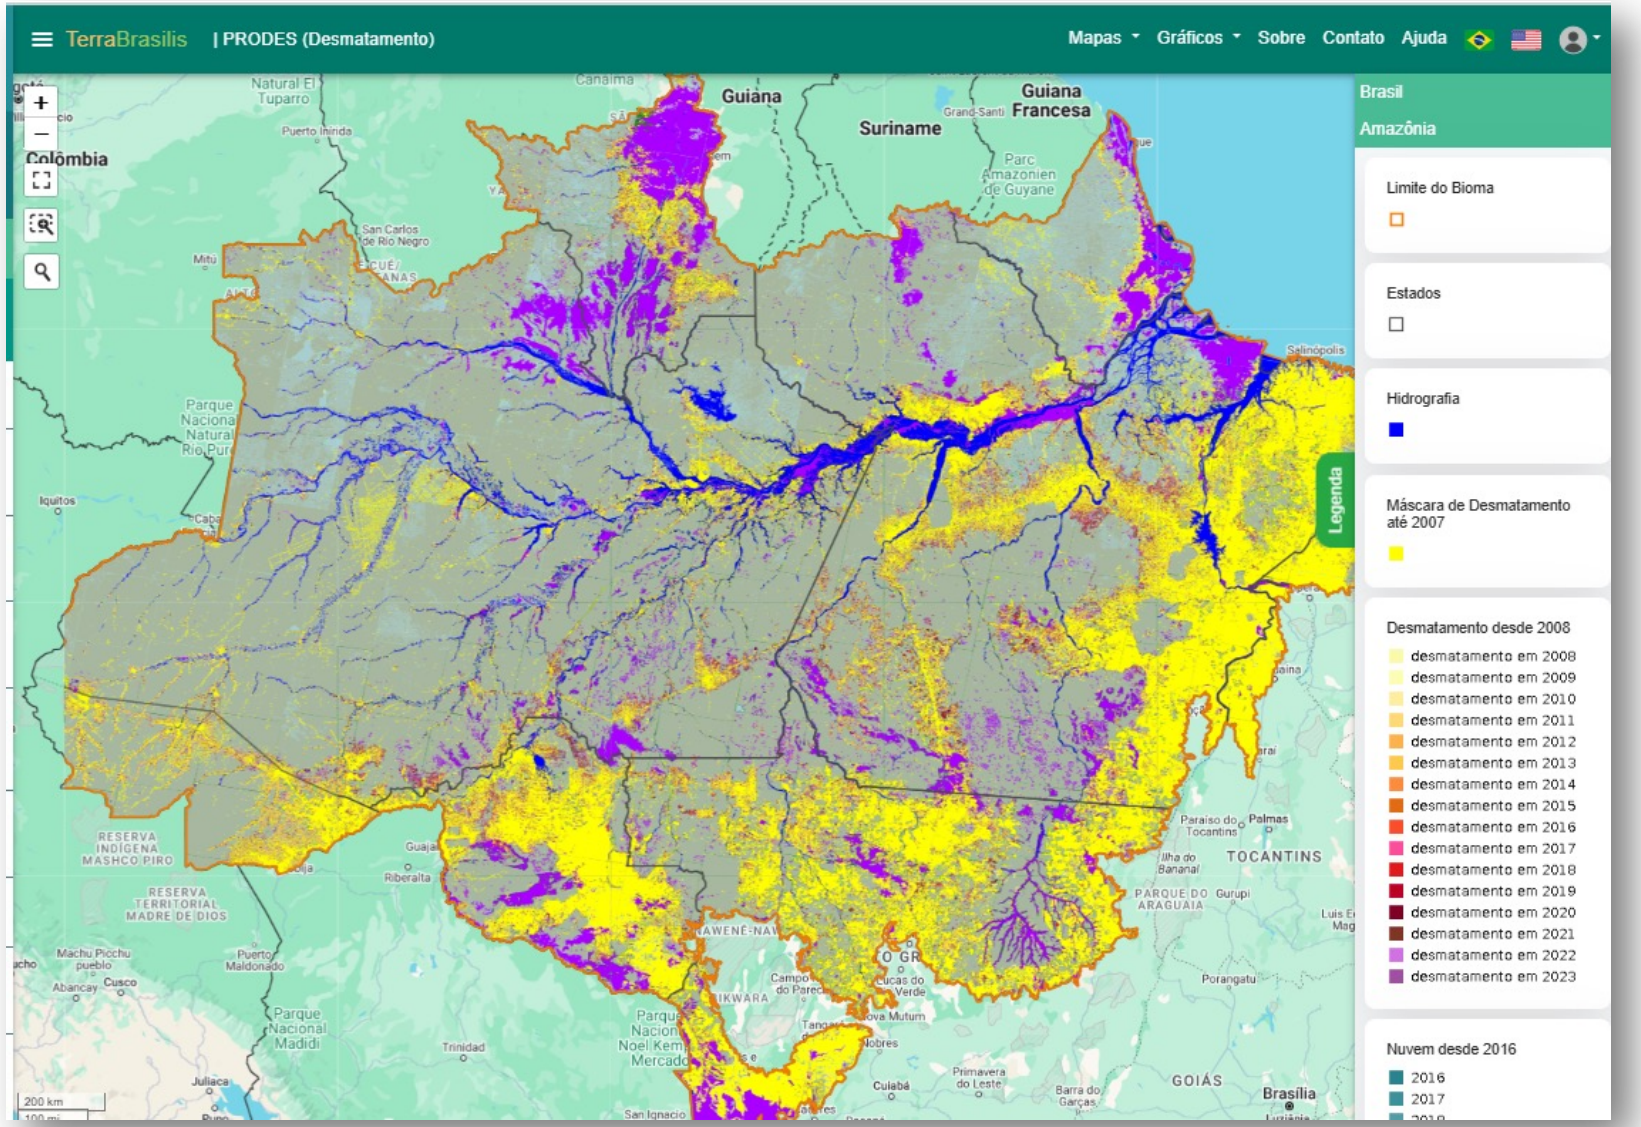
Embrapa

Empresa Brasileña de Investigación Agropecuaria

INPE

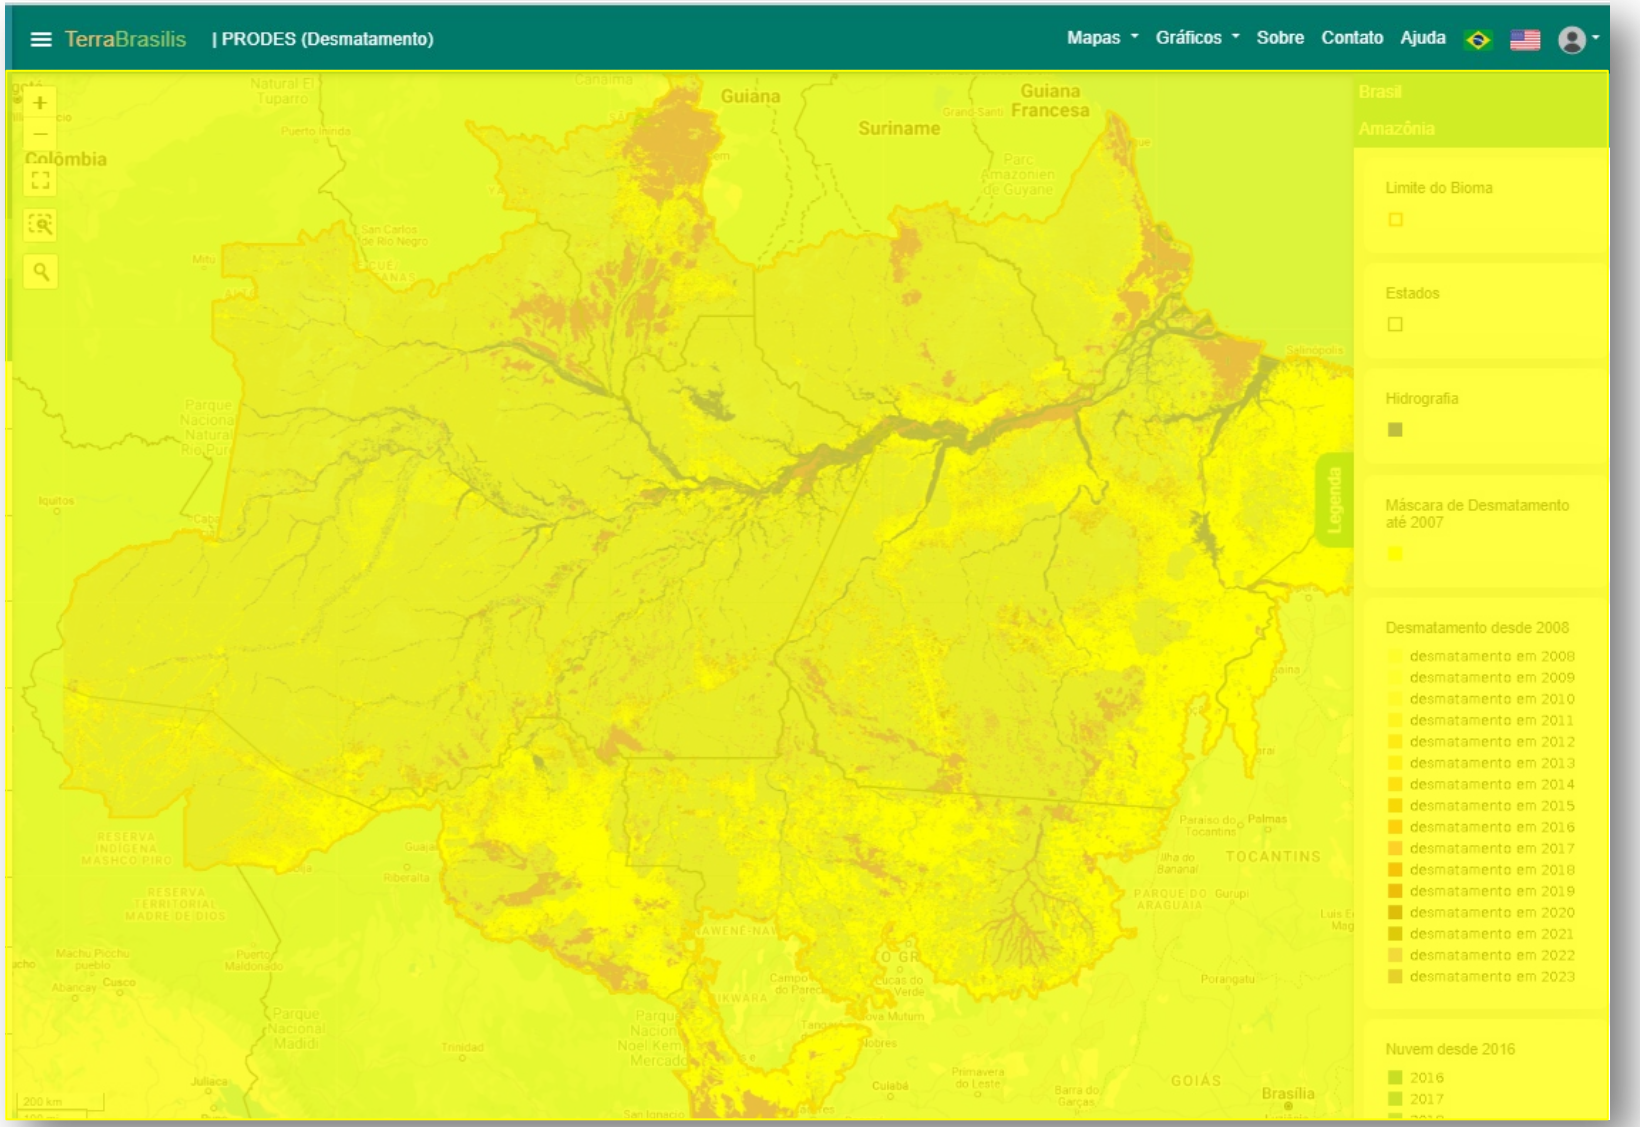
https://data.inpe.br/big/web/biomasbr/terraclass-monitoramento-sistemico-de-uso-e-cobertura-da-terra/

¿Qué ha sustituido a la vegetación nativa?



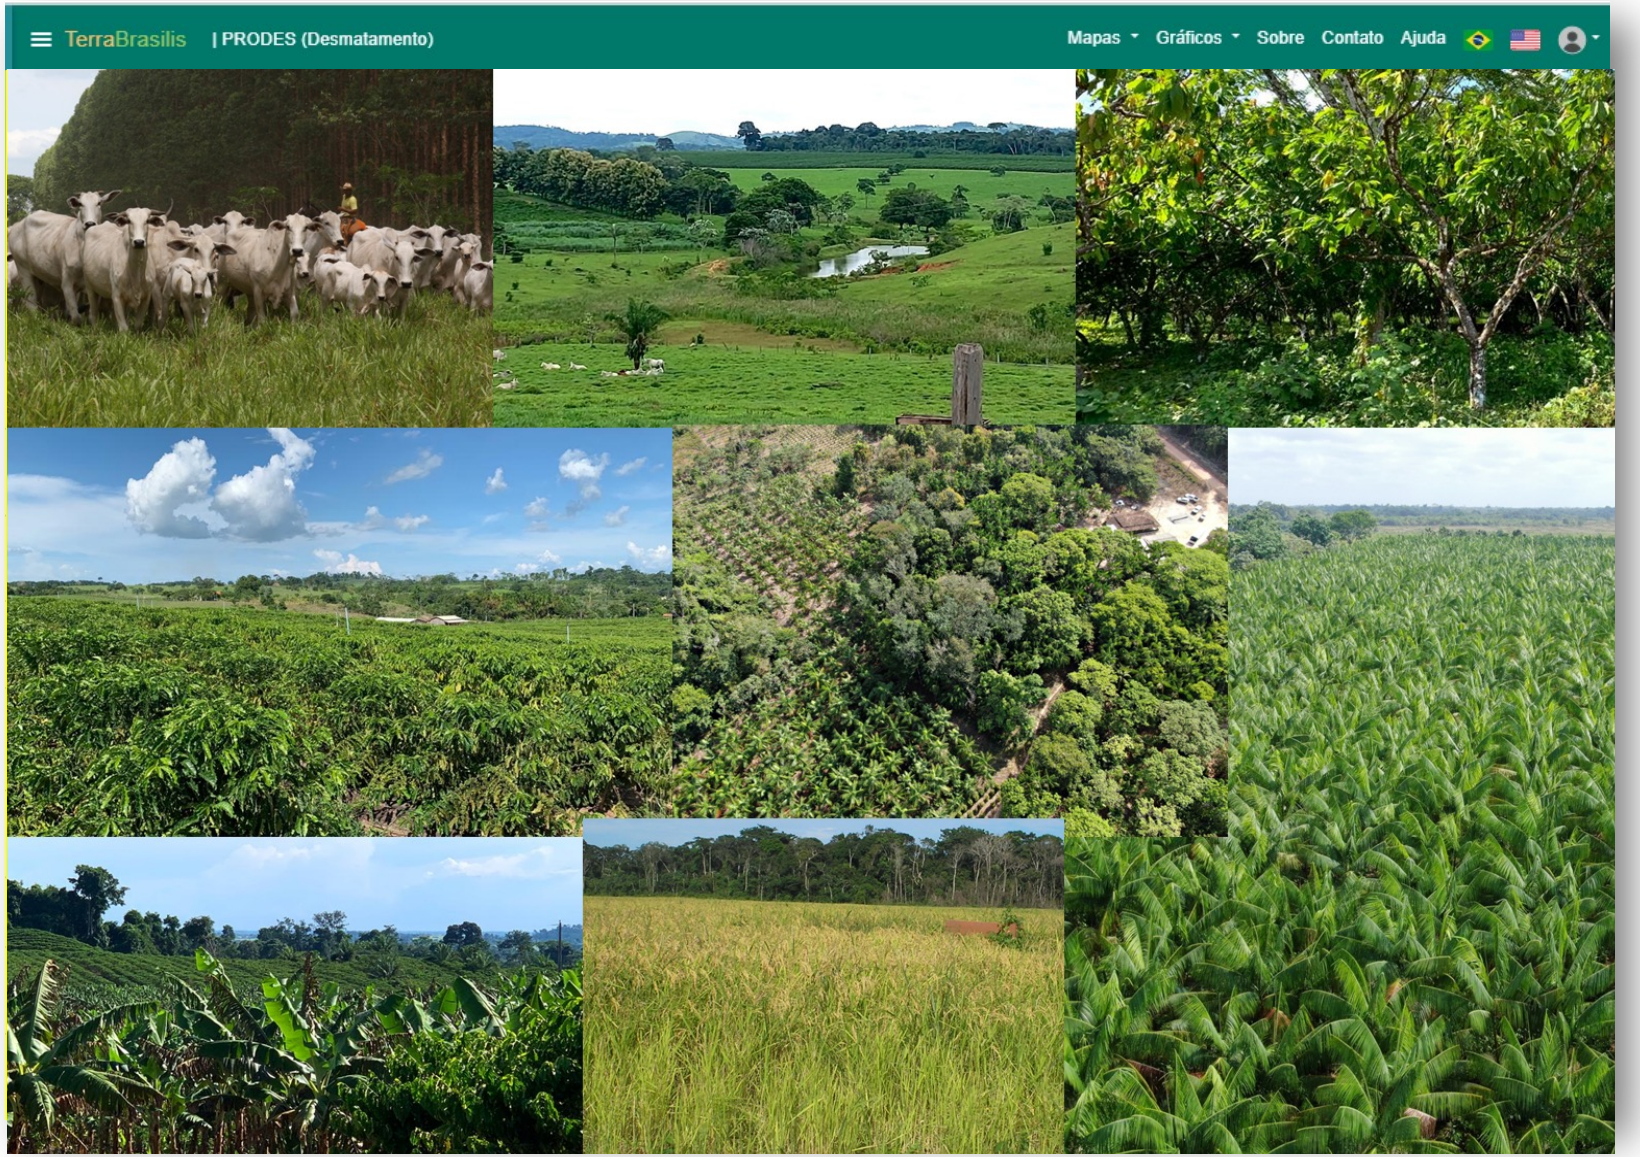
De la deforestación (Prodes)

¿Qué ha sustituido a la vegetación nativa?



De la deforestación (Prodes)

¿Qué ha sustituido a la vegetación nativa?



De la deforestación (Prodes)
al
uso y la cobertura del suelo TerraClass

Ventirueri (2025)

PROYECTO TERRACLASS

Alianza entre el INPE y EMBRAPA (desde 2011)



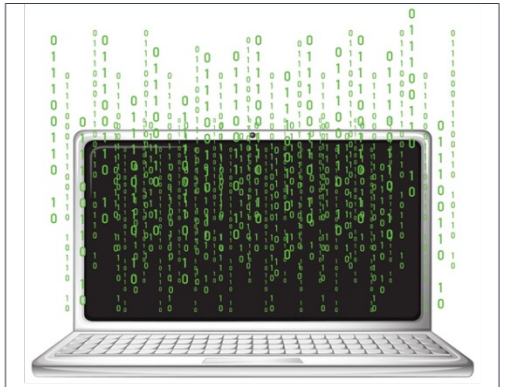
METODOLOGÍA



Sentinel-2 10 m Images

BRAZIL DATA CUBE

Brazil Data Cube



Machine Learning Algorithms

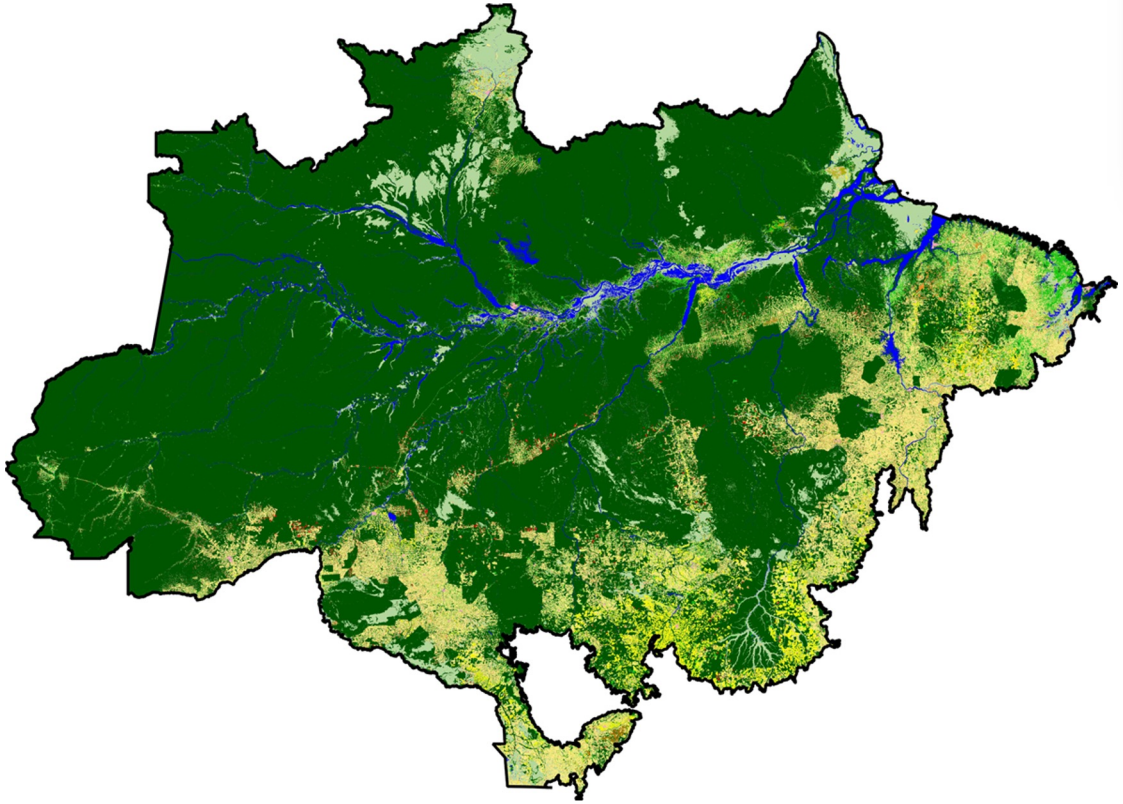
sits

SITS computing package

Coutinho (2023)

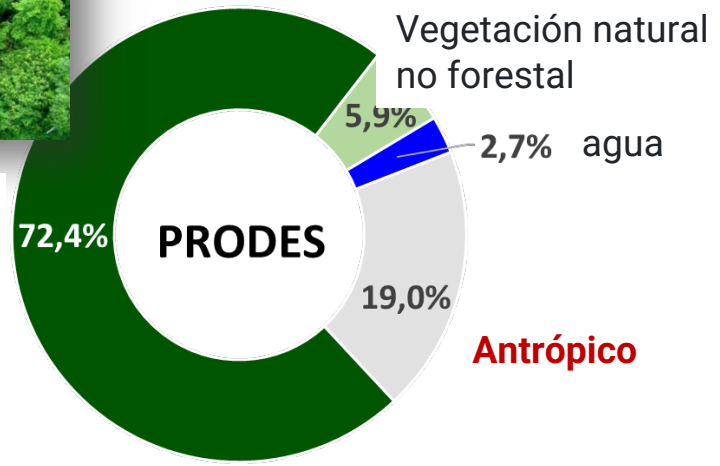
RESULTADOS

TerraClass 2022





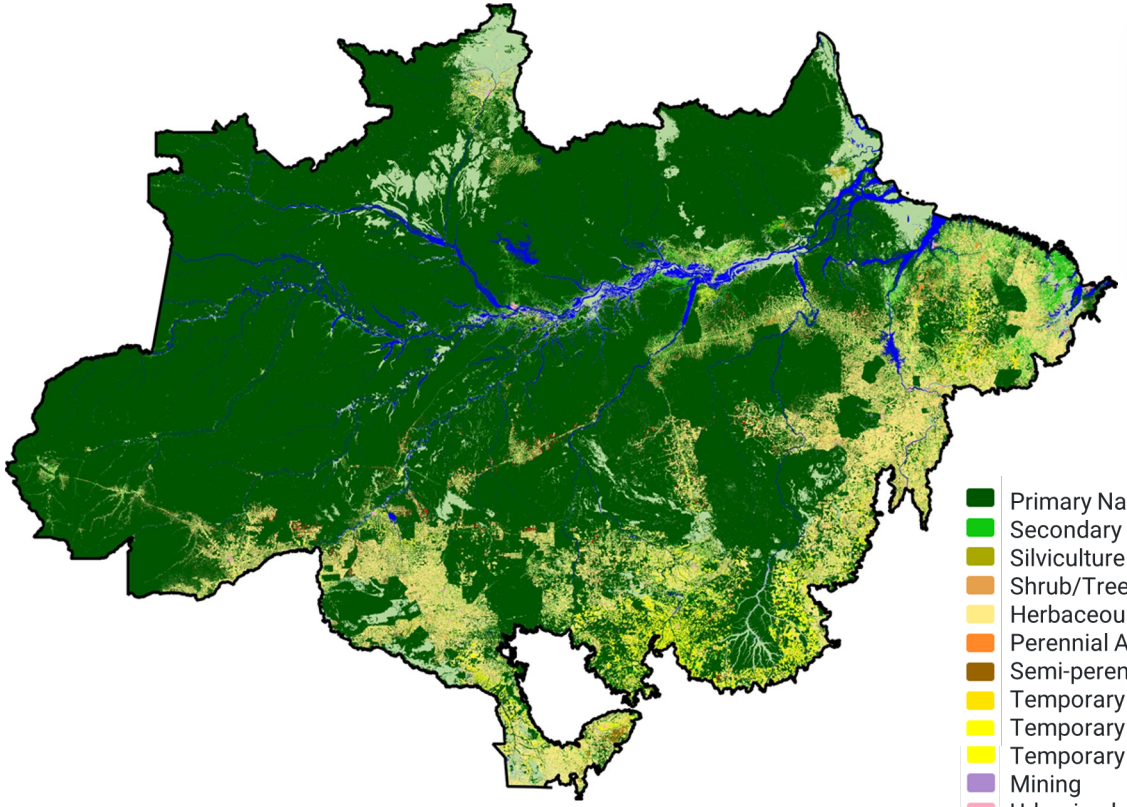
Vegetación natural forestal primaria



PRODES (2022)

RESULTADOS

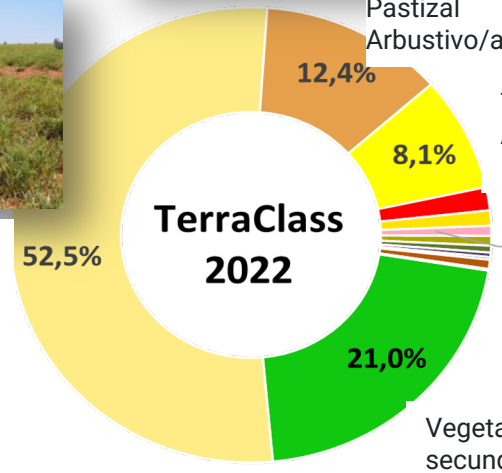
TerraClass 2022











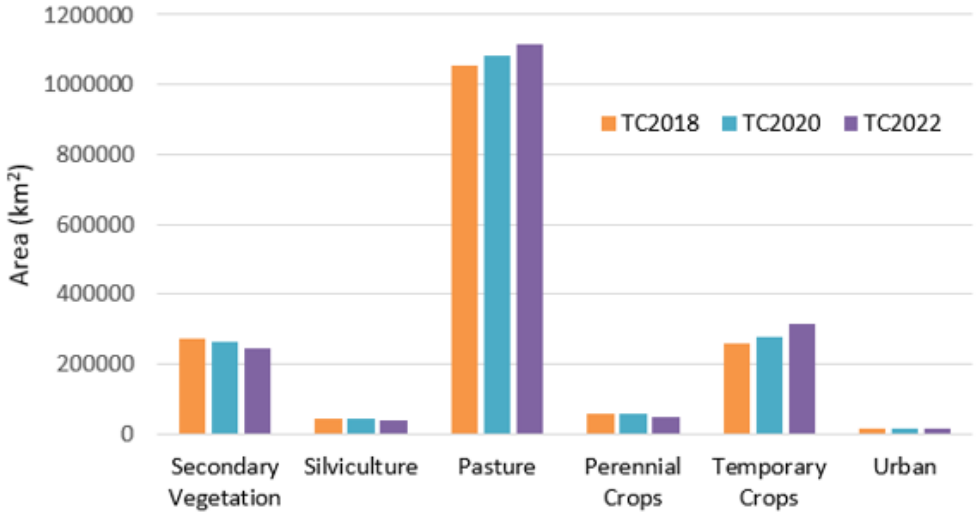
TerraClass (2022)



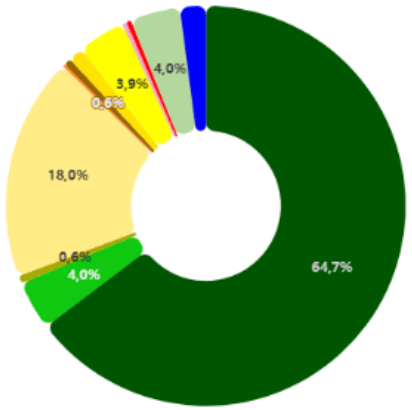
TRAYECTORIAS DE USO DEL SUELO

Amazonía (2008 – 2022) y Cerrado – 2018, 2020 y 2022 (unificado)

Mapeo bienal



2018
2020
2022







Amaral et al. 2025

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

TerraClass

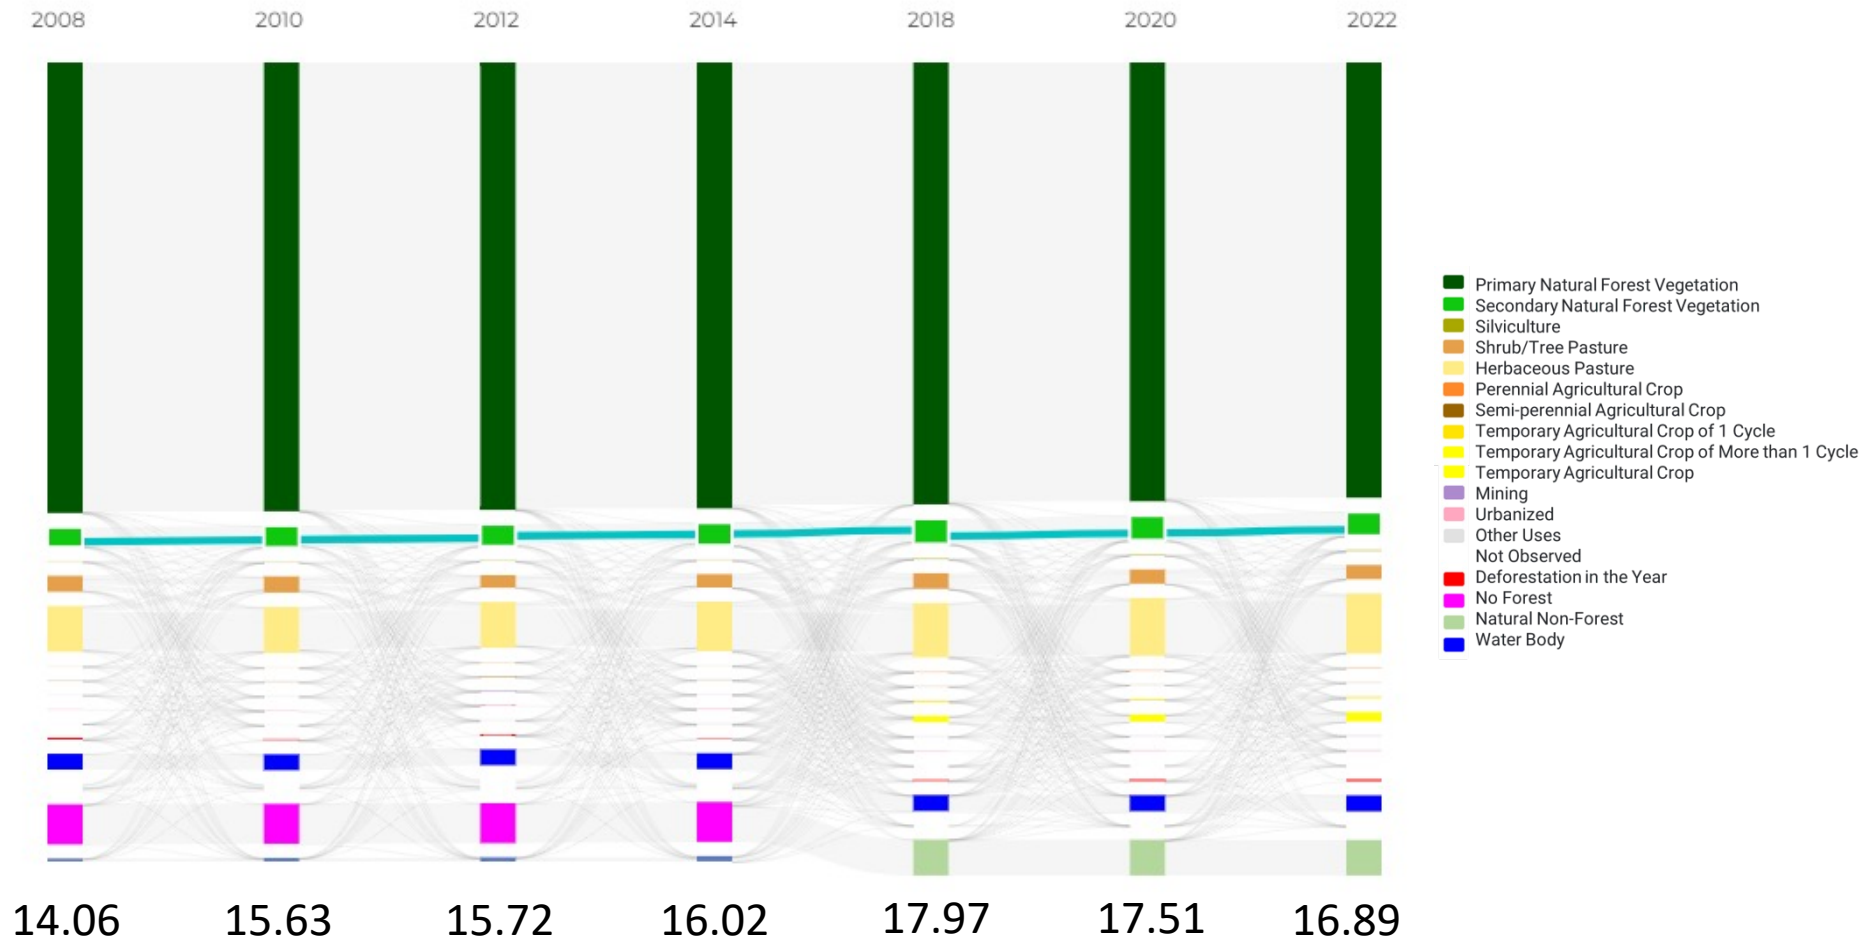
Vegetación secundaria (VS) en la Amazonía

Persistencia

6 735 018,71 ha
2012 – 2022
(10 años)

6 027 202,24 ha
2010 – 2022
(12 años)

5 304 131,67 ha
2008 – 2022
(14 años)



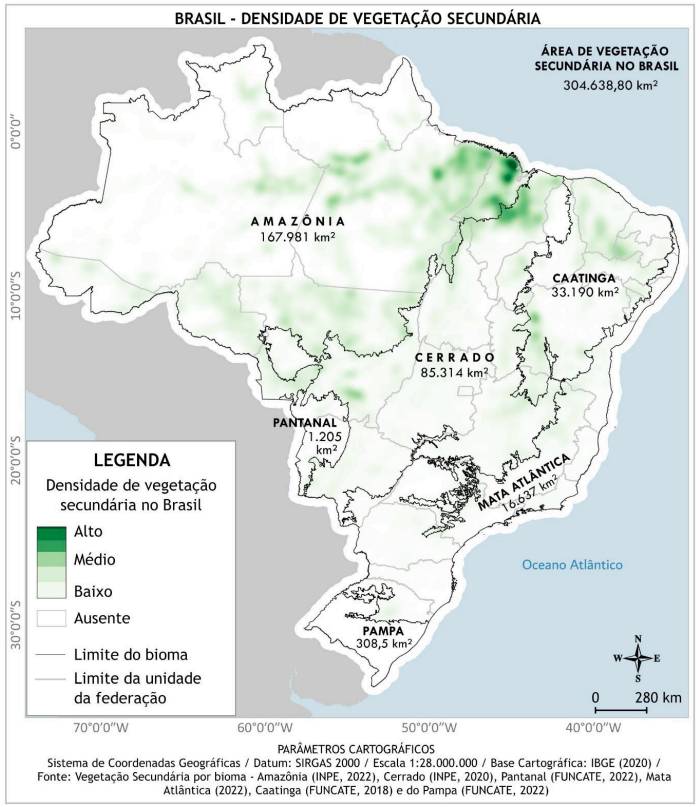
Miles de ha	14.06	15.63	15.72	16.02	17.97	17.51	16.89

TerraClass - Paisaje

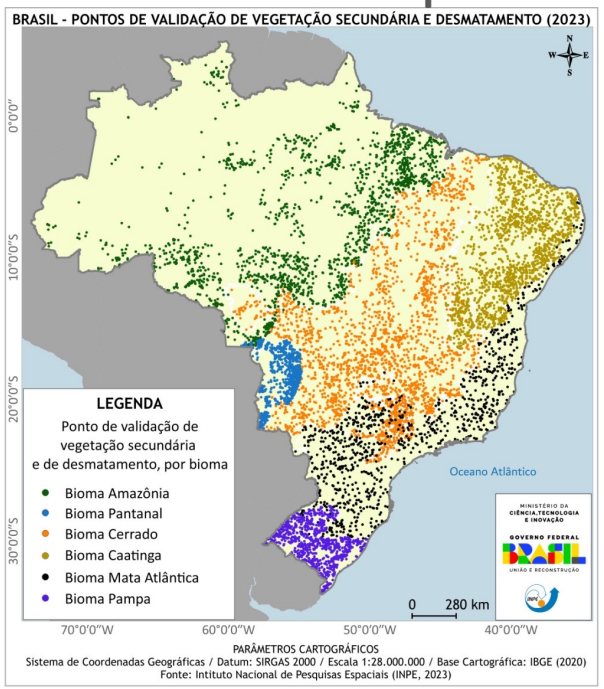
Mapeo de la vegetación secundaria (VS)

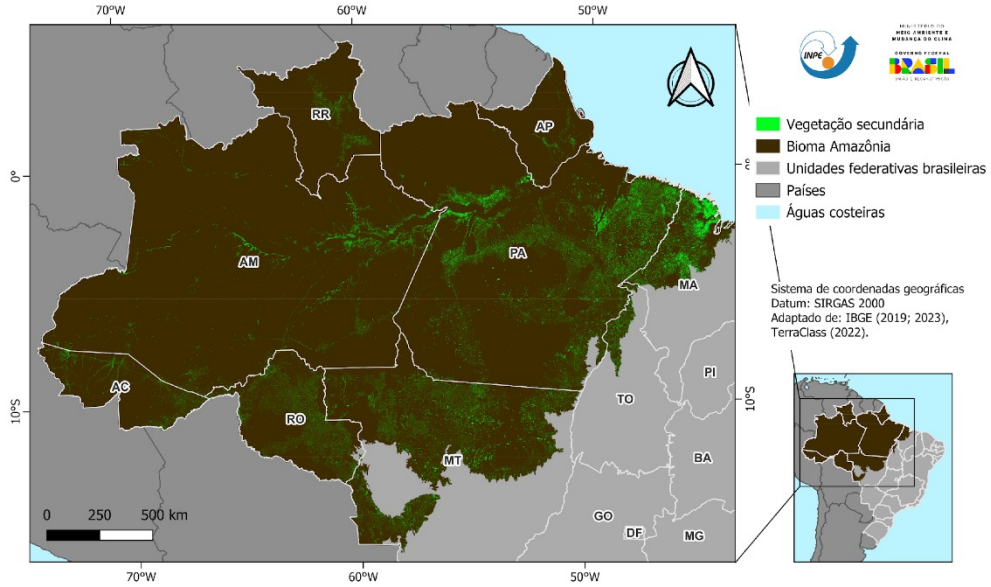
Áreas de vegetación secundaria para todos los biomas brasileños 2018, 2020 y 2022

Se integrarán y publicarán en TerraBrasilis en 2025



VS 2022 - Validación por bioma





Vegetación secundaria del bioma amazónico

TerraClass - Paisaje

Análisis del paisaje de la vegetación secundaria (VS) – BRASIL

Categoría territorial	Área (%)
Territorios quilombolas	0.85
UC de protección integral	1.28
Bosques públicos no destinados	1.82
UC de uso sostenible (sin APA)	3.11
Tierras indígenas	5.03
Área de protección ambiental (APA)	6.18
Asentamiento rural	**15.46**
Propiedades privadas (SIGEF)	**22.34**
Área sin registro de tierras	**43.92**

Área total (VS) = 16 247 366,72 ha (689 288 manchas)

MÉTRICA	Análisis		
	Área	Polígonos	OBS
Edad ponderada (años)	(34.38%) 7–9 (07.66%) 1–3	(34.69%) 4 - 6 (09.36%) 13 - 14	joven (4 – 9 años)
Área (ha)	(32.51%) 100 –| 1,000 (19.28%) > 1,000	(42.25%) 2 –| 5 (39.40%) 5 –| 20	Muchas pequeñas, algunas grandes relevantes
Área núcleo	(41.40%) 10 –| 1,000	(87,04 %) nula	relevante efecto de borde
Dimensión fractal	(99,33%) 1.25–1.5	(93.76%) 1.25–1.5	forma geométrica - antrópica
Distancia euclidiana al vecino más cercano	84,30 % - 0 m	69,80 % - 0 m	adyacente a vegetación
Vegetación vecina más cercana	85,47 % - vegetación primaria	73,85 % - vegetación primaria	vegetación primaria

TerraClass y PLANAVEG

Comissão de Recuperação da Vegetação Nativa (Conaveg)
La Comisión de Recuperación de la Vegetación Nativa
objetivo común de restaurar 12 millones de hectáreas de vegetación nativa en nuestro país.
Este nuevo pacto e hito se reflejan ahora en el Planaveg 2025-2028.

Planaveg
Plano Nacional de Recuperação da Vegetação Nativa
Plan Nacional de Recuperación de la Vegetación Nativa
(artículo 5 del Decreto n.º 8.972 de 23 de enero de 2017,
Ordenanza Interministerial n.º 230 de 14 de noviembre de 2017)

«Los datos de vegetación secundaria (VS) generados por el proyecto TerraClass se consolidarán como una capa estructural de inteligencia espacial y monitoreo de la recuperación de la vegetación nativa en Brasil, y figurarán entre las principales capas de la plataforma nacional de monitoreo».

OBJETIVO
Restauración de la vegetación nativa en áreas degradadas de unidades de conservación (UC), tierras indígenas (TI) y otros territorios colectivos.



Planaveg

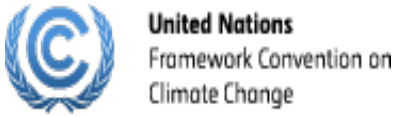
146

USUARIOS DE LOS DATOS PRODES

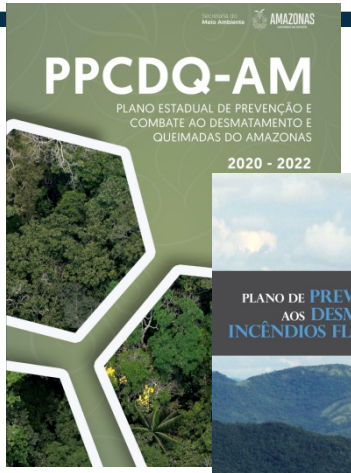
Biomas Br

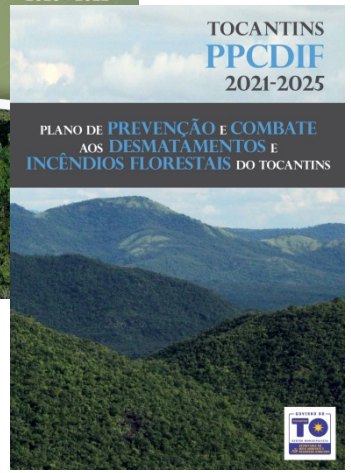
Políticas públicas











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.

Ciencia y estudios académic

PRODES
07/17/2026:
1787 artículos en
576 revistas

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



Control del comercio

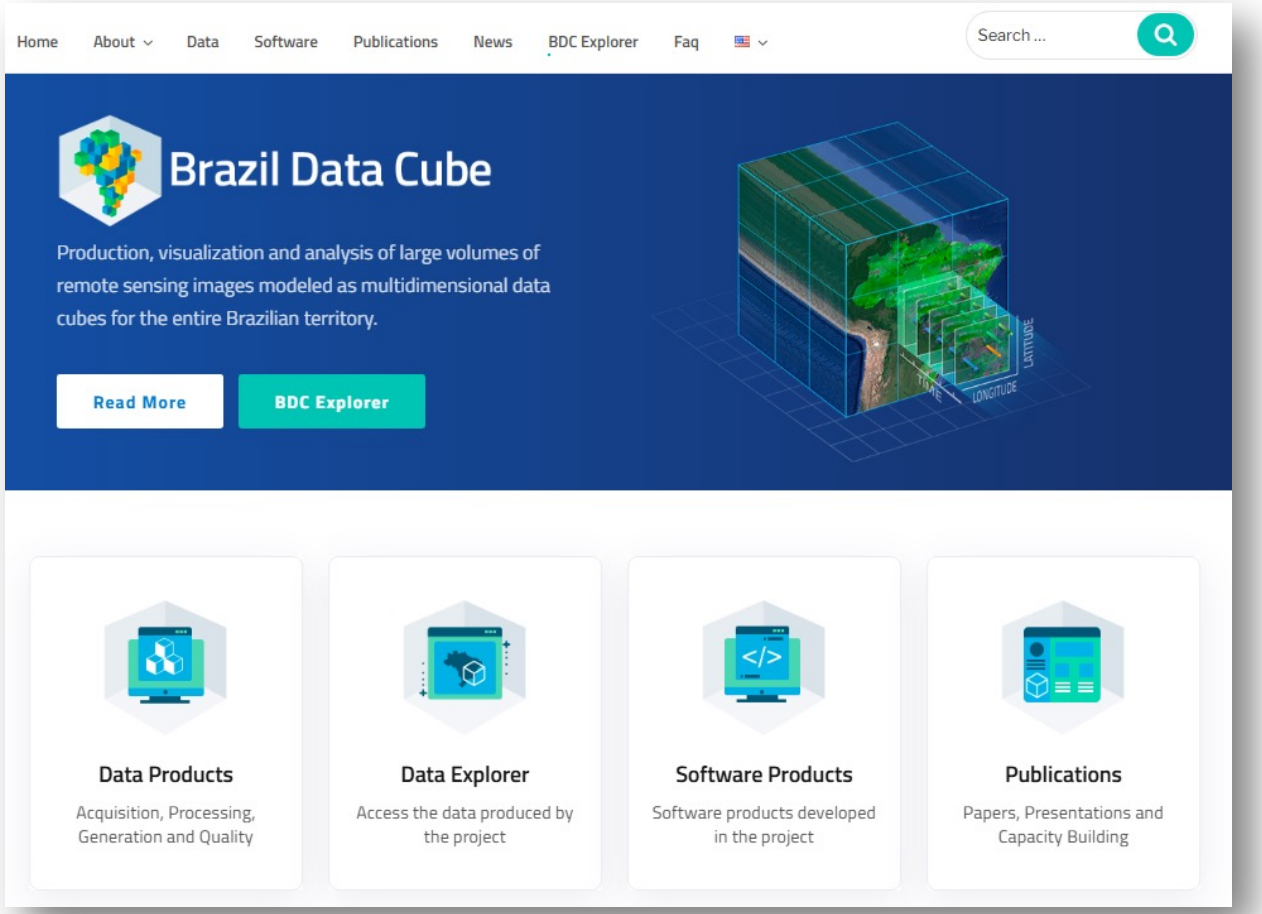




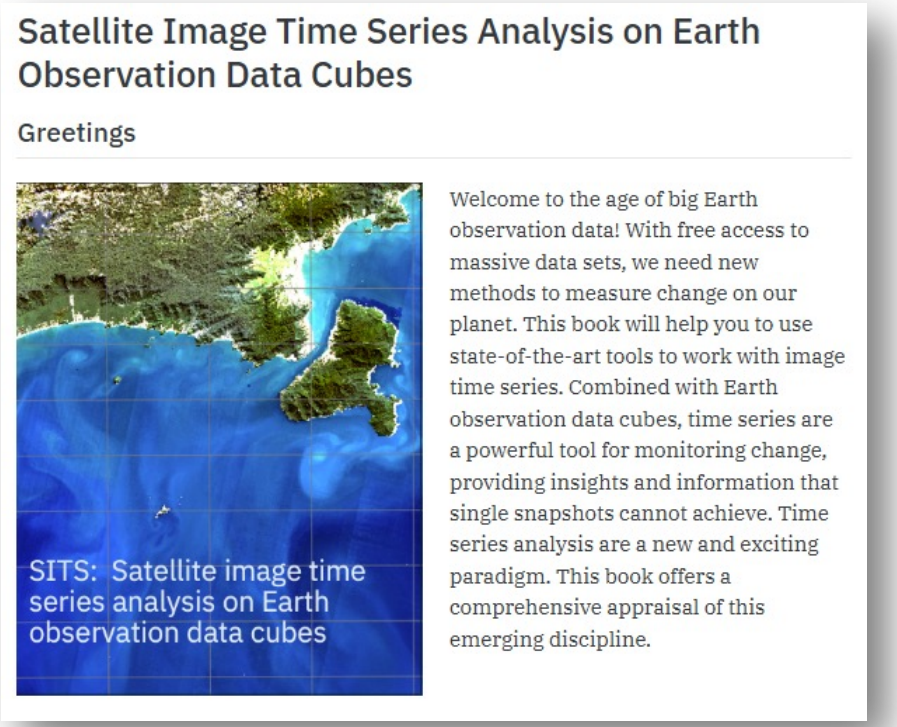
https://data.inpe.br/biomasbr/citacoes/

BDC - SITS

Nuevas tecnologías del INPE para Prodes - acceso abierto - análisis con IA para teledetección -



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



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

BiomasBR

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

Un programa estratégico del INPE

Construcción / historia
Equipos – investigación científica
Colaboraciones y alianzas

Acceso abierto
Cobertura exhaustiva
Precisión constante de los datos
Series históricas
Mejora continua

Métodos de IA – clasificación de imágenes
Contribución frente al cambio climático

Datos abiertos y
herramientas de IA para la sociedad



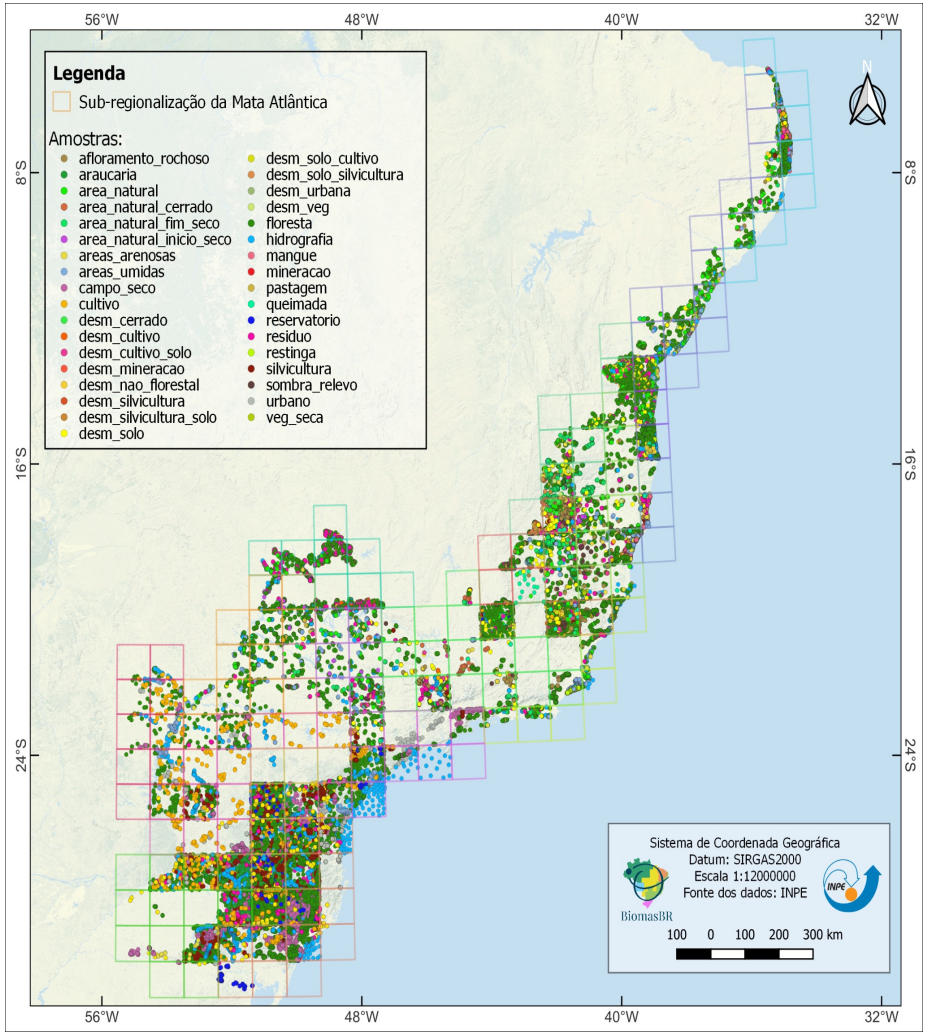


IA para los bosques – grandes retos

Pocos conjuntos de datos etiquetados

Los datos de referencia de calidad son caros y lentos de producir.

Esto limita el aprendizaje supervisado y la precisión de los modelos.



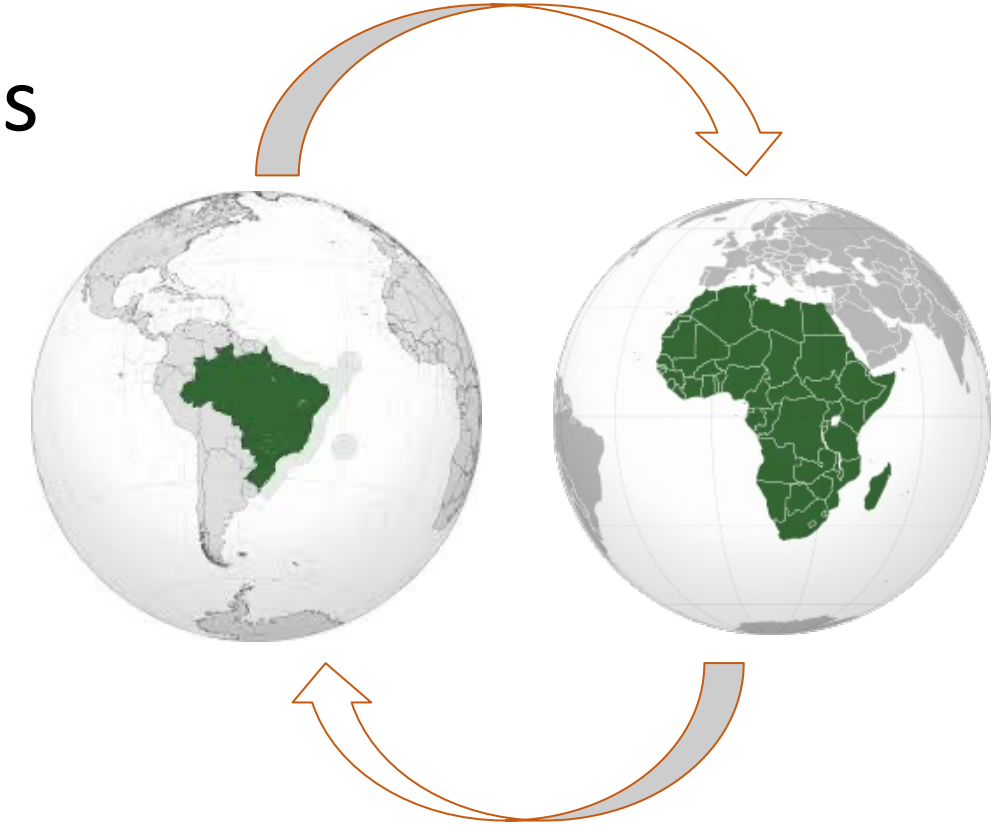


IA para los bosques – grandes retos

Generalización entre ecosistemas

Los modelos entrenados en un bioma o país suelen rendir mal en otros lugares

Esto reduce la transferibilidad a nuevos ecosistemas y climas.





IA para los bosques – grandes retos

Variabilidad temporal
Cobertura nubosa

Estacionalidad, fenología, perturbaciones
Degradación x deforestación

Bosque tropical – cobertura nubosa

La IA no detecta la tala selectiva, los daños por fuego ni la degradación del sotobosque

Series temporales incompletas





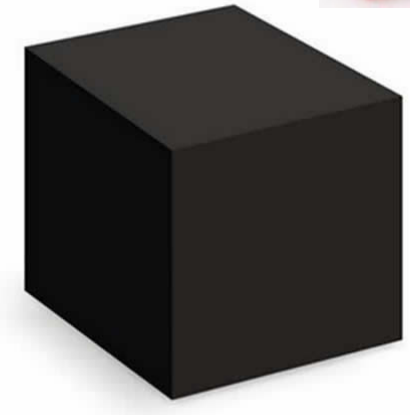
IA para los bosques – grandes retos

Explicabilidad y estimación de la incertidumbre

Los modelos de aprendizaje profundo suelen ser «cajas negras».



A las agencias y a los responsables de decisiones les cuesta confiar en los productos operativos.





IA para los bosques – grandes retos

Grandes requisitos computacionales

El aprendizaje profundo moderno y los modelos fundacionales requieren GPU, mucho almacenamiento y computación de alto rendimiento.

Hoy, el acceso está restringido a ciertas organizaciones


Supercomputadora JACI del INPE



Google DeepMind

OpenAI



IA para los bosques – grandes retos

- Integración en **sistemas de monitoreo operativos**
- Coherencia a largo plazo para los informes ambientales
- Escalado - modelos fundacionales para el monitoreo forestal mundial

Cuestiones éticas y de gobernanza



IA para los bosques

Monitoreo forestal para el carbono y el cambio climático

Teledetección e IA – evolución y retos

Debate – uso de los datos forestales otra charla
Investigación y desarrollo – ¡contamos con ustedes!

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?

¡Gracias!

Silvana Amaral

+55 12 996255480

silvana.amaral@inpe.br

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



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO