

Áreas agrícolas no Brasil
Image © 2026 Planet Labs PBC

Climate Change AI
Escola de verão virtual 2026

IA para a agricultura e a segurança alimentar

Da observação da Terra a decisões climaticamente inteligentes

Dra. Aliny Reis
Cientista sênior de sensoriamento remoto · Corvian

Julho de 2026

O que esta aula aborda

Temas

- Agricultura, mudanças climáticas e segurança alimentar
- Observando os sistemas agrícolas por meio de dados
- Da observação da Terra ao apoio à decisão com IA
- Aplicações de IA, da fazenda à segurança alimentar global
- IA responsável, perspectivas e próximos passos



Áreas agrícolas na Polônia
Image © 2026 Planet Labs PBC

Agricultura, segurança alimentar e mudanças climáticas

A agricultura contribui para as mudanças climáticas e sofre seus efeitos.

Entender esse papel duplo é essencial para projetar sistemas de IA que realmente melhorem a vida das pessoas e do planeta.

A agricultura como causa das mudanças climáticas

A agricultura contribui muito para as emissões de GEE pela mudança no uso da terra, pela pecuária e pelo manejo do solo.

Principais fontes de emissão

Mudança no uso da terra

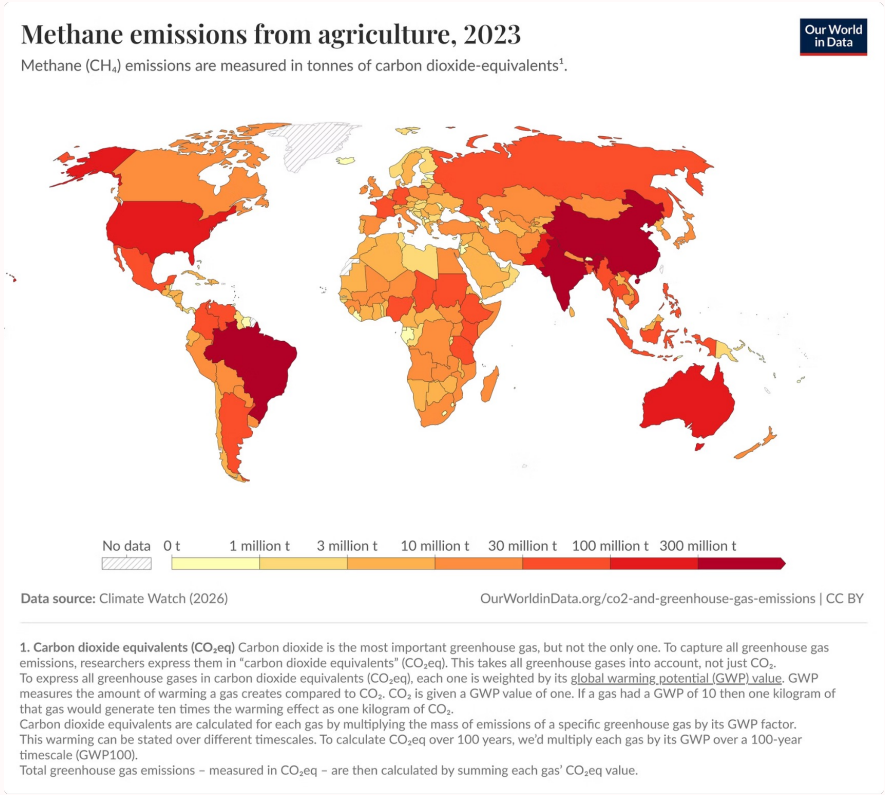
A conversão de florestas e ecossistemas naturais em áreas agrícolas libera o carbono armazenado.

Pecuária

Metano (CH_4) da fermentação entérica de ruminantes (p. ex., bovinos) e do manejo de dejetos.

Manejo de lavouras

Óxido nitroso (N_2O) de fertilizantes nitrogenados sintéticos e de práticas que perturbam o solo.



Riscos climáticos que afetam os sistemas agrícolas

Seca e estresse térmico

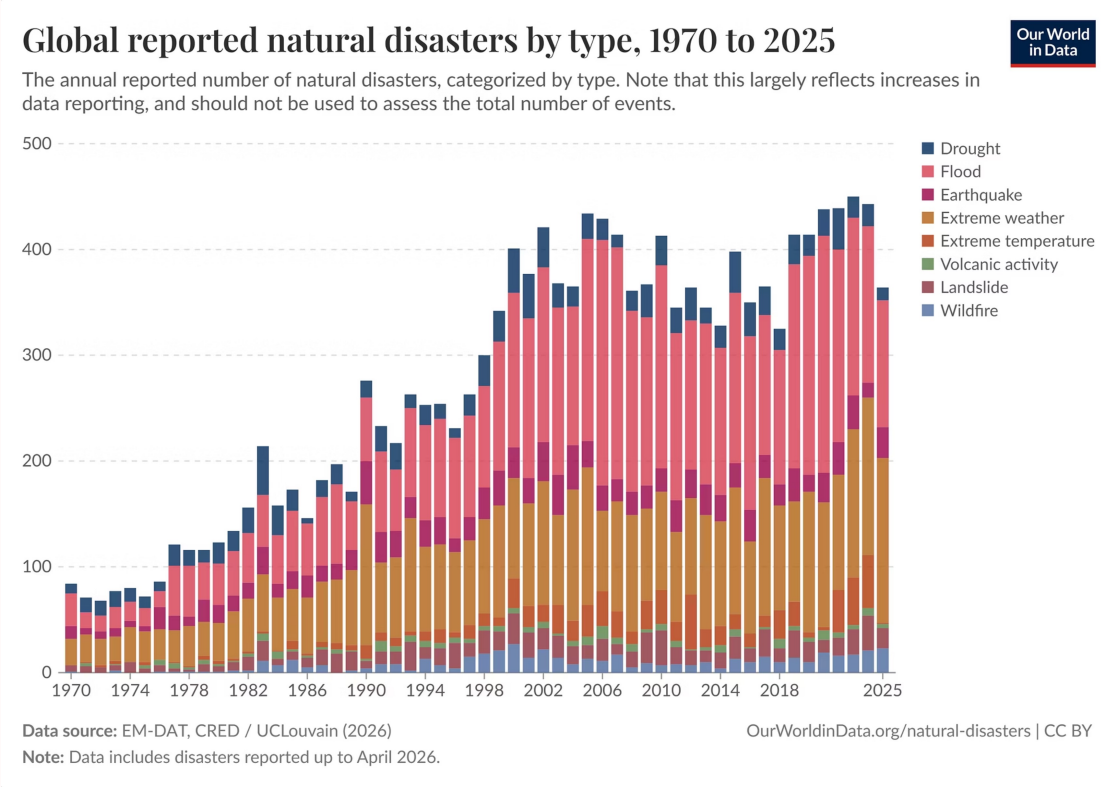
Longos períodos secos e temperaturas extremas reduzem a produtividade, danificam as lavouras e esgotam a umidade do solo.

Enchentes e eventos extremos

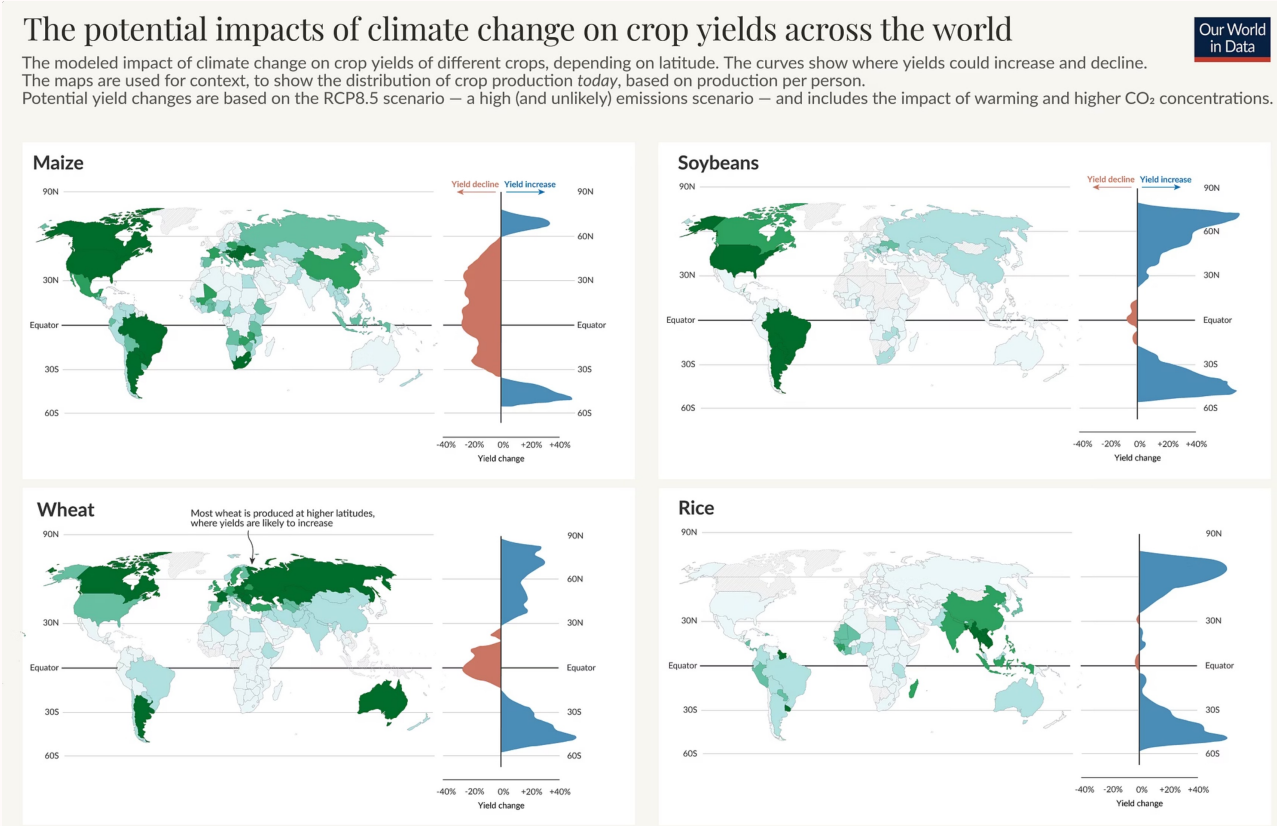
Chuvas intensas, enchentes e tempestades destroem colheitas e erodem terras agrícolas produtivas.

Degradação das terras

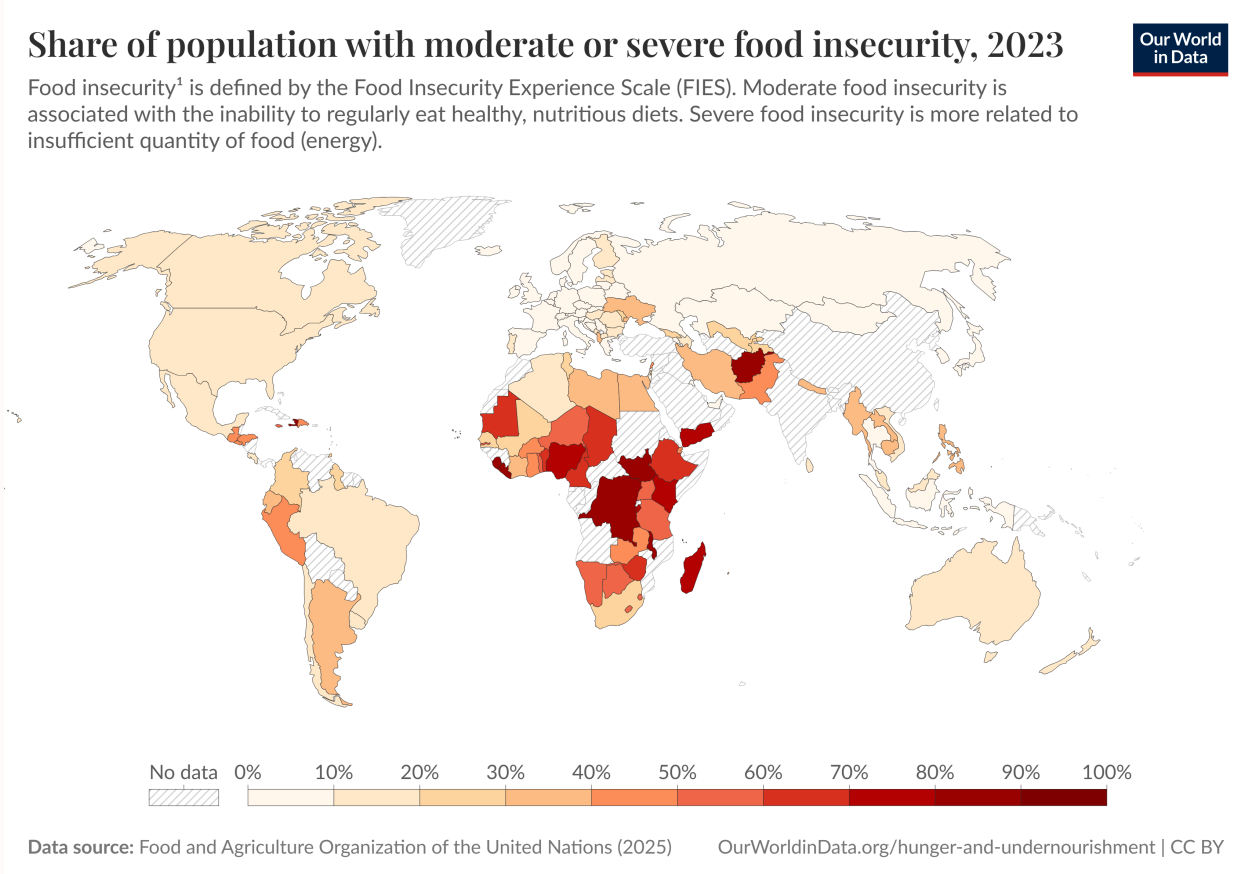
Erosão, salinização e esgotamento de nutrientes reduzem, com o tempo, a capacidade produtiva das terras agrícolas.



Riscos climáticos que afetam os sistemas agrícolas



Riscos climáticos que afetam os sistemas agrícolas



Segurança alimentar em um clima em mudança

As mudanças climáticas estão transformando a agricultura

- Secas, enchentes, ondas de calor e eventos extremos mais frequentes ameaçam a produção agrícola.
- Os impactos climáticos afetam os quatro pilares da segurança alimentar: **disponibilidade, acesso, utilização e estabilidade.**
- A agricultura precisa produzir mais alimentos usando os recursos com mais eficiência, adaptando-se às mudanças climáticas e reduzindo seus impactos ambientais.



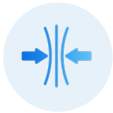
Aumentar a produtividade

Produzir mais alimentos para uma população crescente.



Melhorar a eficiência

Usar terra, água, fertilizantes e outros recursos com mais eficiência.



Fortalecer a resiliência

Adaptar os sistemas agrícolas à crescente variabilidade climática.



Proteger os ecossistemas

Reduzir emissões protegendo os ecossistemas naturais.

Quem usa informações agrícolas?

As decisões agrícolas são tomadas em muitos níveis, **da propriedade individual às organizações globais**. **Embora seus objetivos sejam diferentes, todos dependem de informações oportunas, precisas e acionáveis.**

Agricultores e produtores

Decisões: plantio, irrigação e momento da colheita.

Agrônomos e consultores agrícolas

Decisões: manejo da lavoura, otimização de insumos e planejamento da colheita.

Governos e seguradoras

Decisões: política agrícola, seguro rural e resposta a desastres.

Organizações humanitárias e climáticas

Decisões: monitoramento da segurança alimentar, resposta humanitária e adaptação climática.

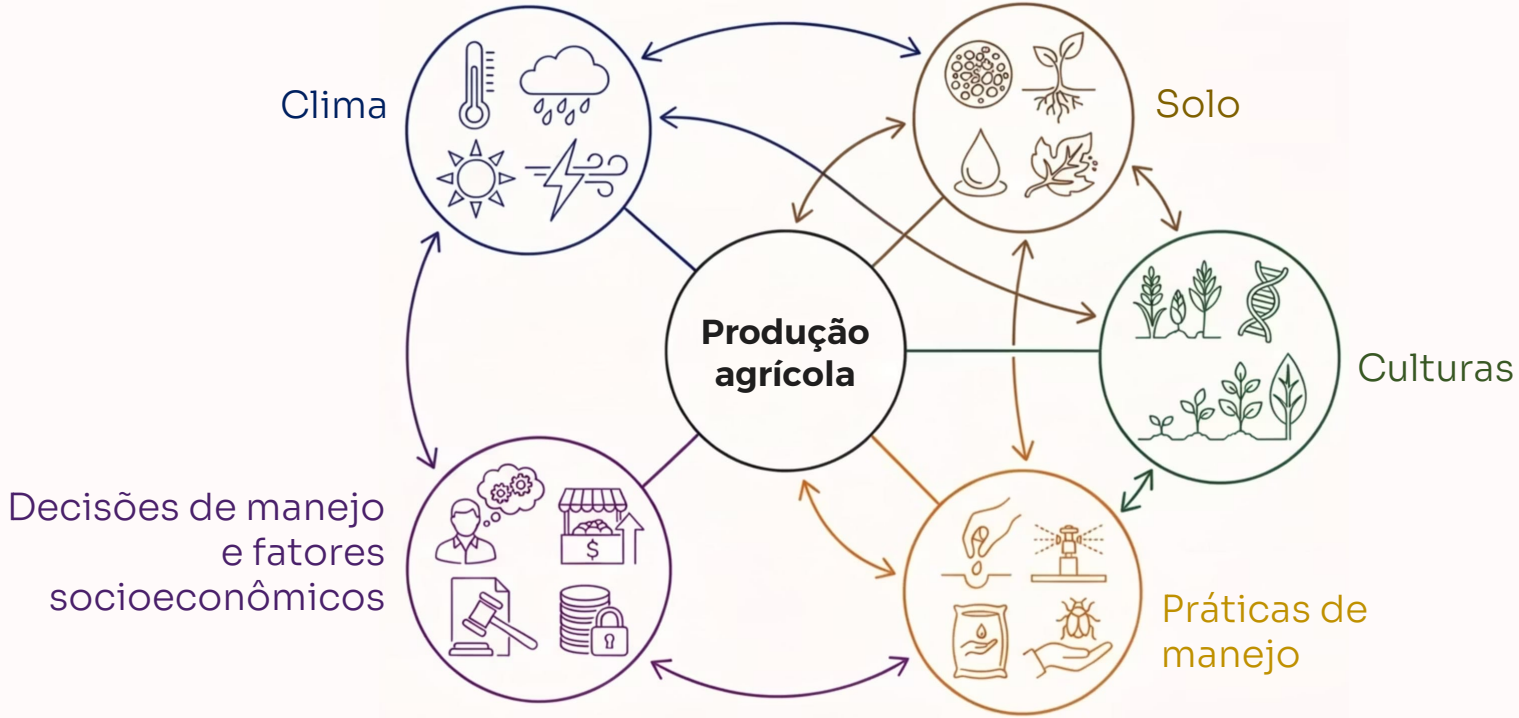


Áreas agrícolas no Canadá
Image © 2026 Planet Labs PBC

Entendendo os sistemas agrícolas por meio de dados

Os sistemas agrícolas surgem de interações complexas entre **clima**, **solo**, **culturas**, **práticas de manejo e decisões humanas**. Captar essa complexidade exige fontes de dados diversas e complementares.

O que determina a produção agrícola?



A produção agrícola resulta da interação entre clima, solo, culturas, manejo e fatores socioeconômicos. **Entender essas interações exige integrar várias fontes de dados complementares.**

Observando os sistemas agrícolas



Sensoriamento remoto

Observações de satélite, aéreas e por drone fornecem informações contínuas sobre o crescimento das culturas, a cobertura do solo e as condições da vegetação.



Dados meteorológicos e climáticos

Temperatura, precipitação, radiação e outras variáveis meteorológicas de estações, reanálises e modelos climáticos.



Informações sobre o solo

Propriedades do solo, como textura, matéria orgânica, umidade e fertilidade, influenciam o crescimento e a produtividade das culturas.



Observações de campo e estatísticas

Observações em campo, levantamentos de safra, registros de manejo e estatísticas agrícolas fornecem informações de referência essenciais.

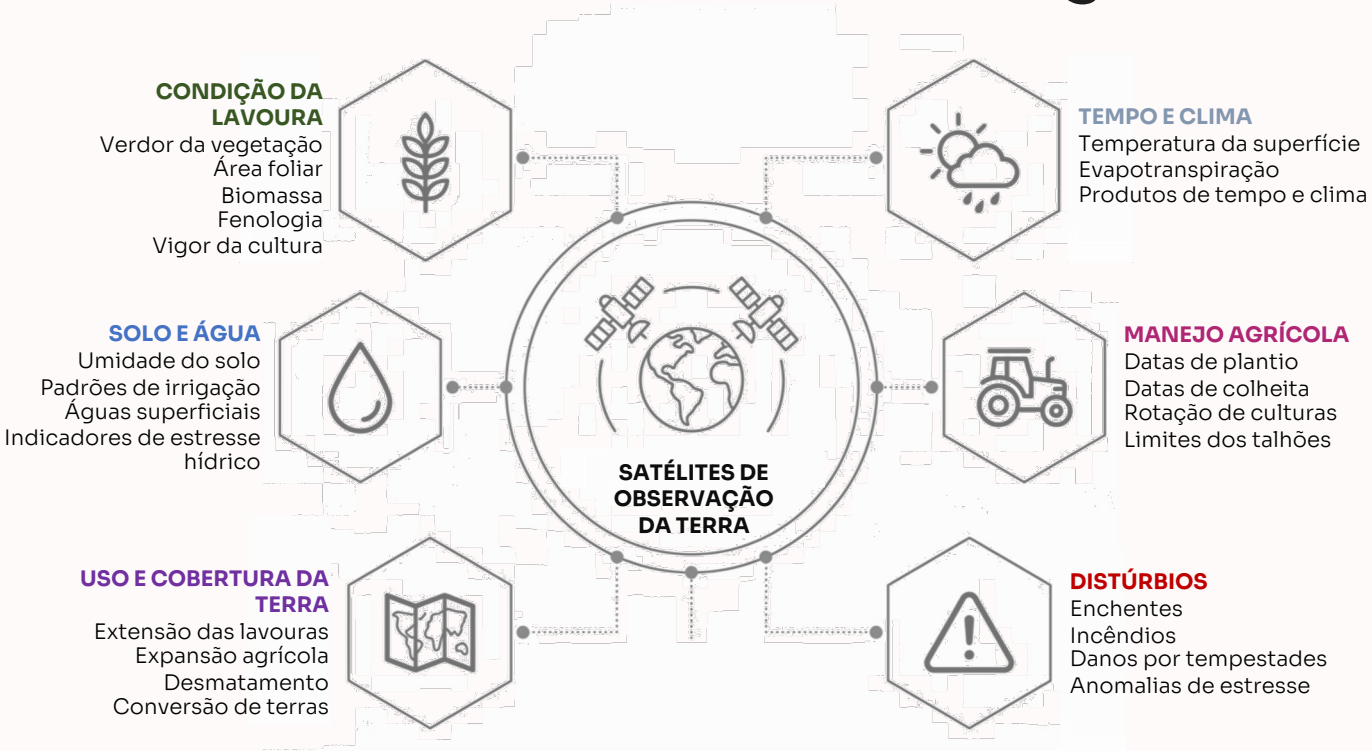
O que o sensoriamento remoto consegue observar?

AS MUITAS FACES DA TERRA



Fonte: ESA

O que o sensoriamento remoto consegue observar?



O sensoriamento remoto fornece **observações contínuas, objetivas e espacialmente explícitas** que permitem **o monitoramento agrícola em escalas local, regional e global**.

Por que a observação da Terra amplia o monitoramento agrícola

A observação da Terra complementa o monitoramento tradicional em campo com observações contínuas e escaláveis no espaço e no tempo.

Monitoramento tradicional em campo

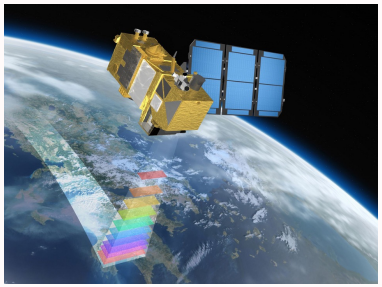




- Alta precisão local
- Exige muita mão de obra
- Demorado
- Cobertura espacial limitada
- Difícil de escalar

Observações locais detalhadas

Observação da Terra a partir do espaço



- Cobertura de grandes áreas
- Observações frequentes
- Arquivos históricos
- Medições consistentes
- Monitoramento quase em tempo real

Monitoramento contínuo e escalável

Tanto as **observações de campo** quanto a **observação da Terra** são essenciais.
Juntas, elas fornecem informações complementares para o monitoramento agrícola.

Do talhão ao planeta

O Sentinel-2 revisita cada ponto da Terra a cada cinco dias, fornecendo observações consistentes para o monitoramento agrícola em escalas local, regional e global.

COBERTURA GLOBAL DO SENTINEL-2



Fonte: ESA

Observações consistentes coletadas ao longo do tempo permitem monitorar os sistemas agrícolas em escalas que seriam impossíveis só com observações de campo.

Observação da Terra em diferentes escalas

Cada decisão agrícola exige dados em uma escala diferente, com compromissos entre **detalhe espacial, cobertura e frequência temporal**.



Talhão

Submétrica–10 m

Agricultores

Monitoramento da sanidade
Manejo em taxa variável



Fazenda

3–30 m

Gestores/ agrônomos

Previsão de produtividade
Zonas de manejo



Regional

10–30 m

Governo/pesquisadores

Mapeamento de culturas
Estimativa de área



Nacional

30–250 m

Governo/ministério

Estatísticas agrícolas
Monitoramento do uso da terra



Global

250 m–1 km+

Organizações internacionais

Monitoramento da segurança alimentar
Avaliação de secas

Alto detalhe espacial — **Maior cobertura geográfica**

Cada decisão agrícola exige uma escala de observação diferente. Escolher os dados de observação da Terra certos sempre envolve equilibrar detalhe espacial, cobertura, frequência de revisita e custo computacional.

Pontos fortes e limitações da observação da Terra

Pontos fortes

- Monitoramento consistente de grandes áreas no espaço e no tempo.
- Observações multissensor fornecem informações complementares sobre os sistemas agrícolas.
- Missões de satélite abertas democratizaram o monitoramento em escala global.

Limitações

- A cobertura de nuvens limita as observações ópticas.
- Compromissos entre resolução espacial, temporal e espectral.
- Os satélites medem as condições da superfície, não diretamente os processos agrícolas.
- Observações de campo continuam essenciais para calibração e validação.
- Volumes enormes de dados exigem computação escalável e abordagens de modelagem robustas.

A observação da Terra oferece capacidades de monitoramento sem precedentes, mas transformar observações em informação acionável exige **integrar dados de satélite com observações de campo, conhecimento do setor e abordagens de modelagem robustas.**

Pergunta do quiz 1

Uma organização humanitária precisa monitorar possíveis riscos à segurança alimentar em vários países e atualizar as avaliações a cada poucas semanas. Qual opção é a mais adequada?

A

Voos de drone sobre vilarejos selecionados

B

Monitoramento por satélite regional a global combinado com indicadores climáticos

C

Imagens de altíssima resolução de algumas propriedades

D

Apenas levantamentos de campo manuais

Resposta correta: B. A organização precisa de ampla cobertura geográfica e atualizações frequentes, mesmo que a resolução espacial seja mais grosseira que a do monitoramento por talhão.

Das observações às decisões

A inteligência artificial integra várias fontes de informação agrícola para gerar insights acionáveis para a tomada de decisão.



Observações brutas

Imagens de satélite ▪ Clima ▪ Solo ▪ Observações de campo



Modelos de IA e integração de dados

Aprender padrões ▪ Integrar dados ▪ Extrair informação



Informação acionável

Mapas ▪ Previsões ▪ Indicadores · Alertas



Apoio à decisão

Agricultores ▪ Governos ▪ Organizações humanitárias

A IA transforma observações heterogêneas em informação acionável ao integrar a observação da Terra com fontes complementares de dados agrícolas.

Cada problema exige uma abordagem de IA

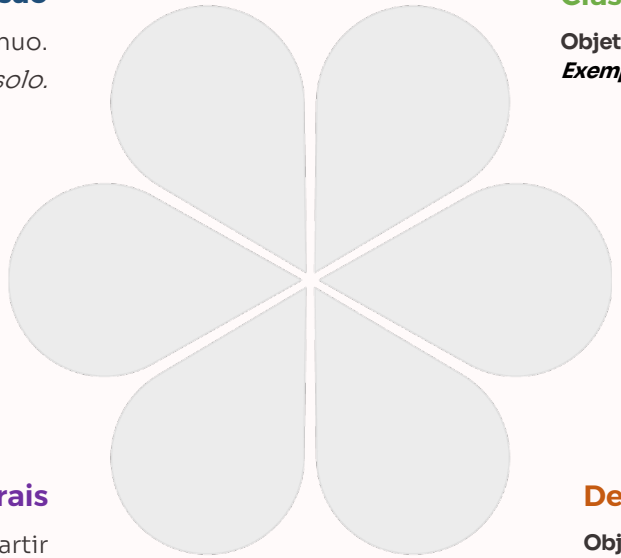
A escolha do método de IA depende do tipo de pergunta que queremos responder e da informação que queremos produzir.

Regressão

Objetivo: prever um valor numérico contínuo.
Exemplo: *produtividade, biomassa, umidade do solo.*

Classificação

Objetivo: atribuir uma categoria a cada observação.
Exemplo: *tipos de cultura, uso da terra.*



IA para a agricultura

Segmentação semântica

Objetivo: classificar cada pixel de uma imagem.
Exemplo: *delimitação de talhões.*

Detecção de objetos

Objetivo: detectar e localizar objetos individuais.
Exemplo: *contagem de frutos, detecção de plantas daninhas.*

Previsão de séries temporais

Objetivo: prever condições futuras a partir de observações passadas.
Exemplo: *previsão de produtividade, previsão de secas.*

Detecção de anomalias

Objetivo: detectar padrões incomuns ou inesperados.
Exemplo: *estresse da lavoura, falhas de irrigação.*

Cada problema exige uma abordagem de IA

Problema de IA	AM clássico	Aprendizado profundo	Exemplos na agricultura
Regressão	Regressão linear, regressor Random Forest, XGBoost, LightGBM	MLP, LSTM, Transformer temporal	Previsão de produtividade, estimativa de biomassa, de umidade do solo e de nitrogênio
Classificação	Regressão logística, Random Forest, XGBoost, SVM	CNN (ResNet, EfficientNet), Vision Transformer (ViT)	Mapeamento de culturas, identificação de doenças, plantas daninhas versus cultura
Detecção de objetos	Raro em aplicações modernas	YOLO, Faster R-CNN, RetinaNet, DETR	Contagem de frutos, detecção de plantas daninhas e de animais, contagem de plantas
Segmentação	Raro em aplicações modernas	U-Net, DeepLabV3+, Mask R-CNN, SegFormer	Delimitação de talhões, mapeamento de enchentes e de áreas queimadas
Séries temporais/previsão	ARIMA, Random Forest, XGBoost	LSTM, GRU, Temporal Fusion Transformer (TFT), Transformer de séries temporais	Previsão de produtividade, do crescimento da cultura e da demanda de irrigação
Detecção de anomalias	Isolation Forest, One-Class SVM	Autocodificadores, autocodificadores variacionais	Surtos de doenças, detecção de estresse, falhas de irrigação, crescimento anormal

Escolher a abordagem de IA certa começa por entender o problema que se quer resolver.

Pergunta do quiz 2

Um ministério quer estimar a produção nacional de milho três meses antes da colheita para apoiar o planejamento das importações de alimentos. Qual combinação de imagens e método de IA é a mais adequada?

A

Imagens de drone de altíssima resolução combinadas com um modelo de detecção de objetos (p. ex., YOLO) para contar plantas individuais.

B

Imagens de satélite nacionais de alta resolução analisadas com uma rede neural convolucional (CNN) usando uma única imagem adquirida perto da data da previsão.

C

Uma única imagem de satélite de alta resolução analisada com um modelo de segmentação para delimitar os talhões.

D

Séries temporais de imagens de satélite regionais combinadas com dados meteorológicos e um modelo de aprendizado profundo espaço-temporal para prever a produtividade.

Resposta correta: D. A previsão nacional de produtividade exige ampla cobertura, profundidade temporal e integração por AM de dados de observação da Terra e climáticos.



Áreas agrícolas na Índia
Image © 2026 Planet Labs PBC

IA para o monitoramento agrícola

O monitoramento agrícola fornece a consciência situacional necessária para decisões informadas, do **manejo do talhão à política nacional**. **A IA transforma observações contínuas da Terra em informação oportuna e acionável em várias escalas.**

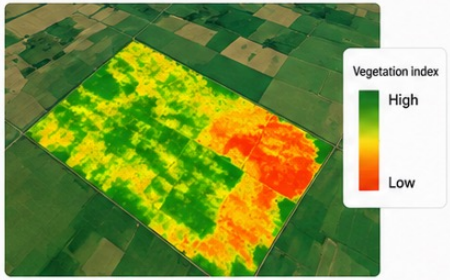
Aprendendo a dinâmica agrícola no espaço e no tempo

Muitos problemas agrícolas dependem também de como as culturas evoluem ao longo do tempo.

1. SPATIAL ANALYSIS

Where is it happening?

Analyzes patterns within a single moment in time.



Captures spatial variability and context across a field or landscape.

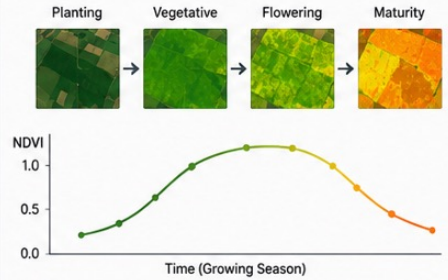
Exemplos

- Variabilidade dentro do talhão
- Mapas de umidade do solo
- Focos de estresse

2. TEMPORAL ANALYSIS

How is it changing over time?

Analyzes how a variable evolves over time.



Captures crop dynamics and seasonal trajectories.

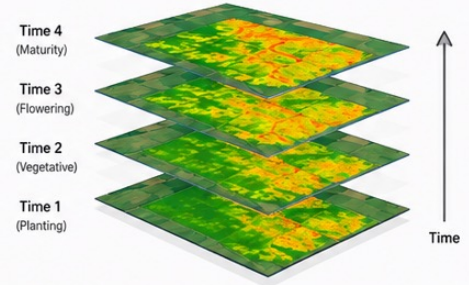
Exemplos

- Estádios fenológicos
- Previsão de produtividade
- Monitoramento de secas ao longo do tempo

3. SPATIO-TEMPORAL ANALYSIS

Where and how is it changing?

Combines spatial patterns and temporal dynamics.



Captures how patterns change over time across space.

Exemplos

- Previsão espaço-temporal de produtividade
- Mapeamento de culturas
- Detecção de mudanças e alertas de anomalias

Os modelos de IA agrícola mais poderosos combinam o contexto espacial com a dinâmica temporal para entender como as culturas evoluem.

IA em todas as escalas: do agricultor às políticas públicas

A **escala da decisão** determina **os dados, os métodos de IA e os resultados necessários**.



Os mesmos dados de observação da Terra podem apoiar decisões muito diferentes conforme a escala espacial.



Áreas agrícolas no Brasil
Image © 2026 Planet Labs PBC

Intervalo

IA para apoio à decisão no talhão e na fazenda

Na escala do talhão e da fazenda, a IA viabiliza **a agricultura de precisão**: **a intervenção certa, no lugar certo, na hora certa.**

Isso melhora a produtividade e reduz os impactos ambientais do excesso de insumos.

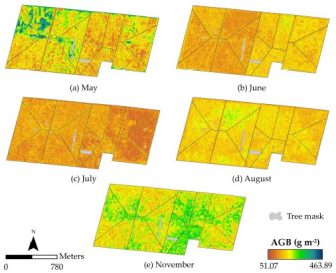


Imagem: Pixabay

Agricultura de precisão:

O insumo certo, no lugar certo, na hora certa

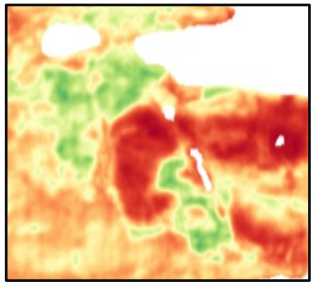
Aplicar insumos (p. ex., água, fertilizantes, defensivos) apenas onde e quando necessário, com base na **variabilidade dentro do talhão detectada por IA e sensoriamento remoto.**



Biomassa ao longo do tempo

PlanetScope, XGBoost

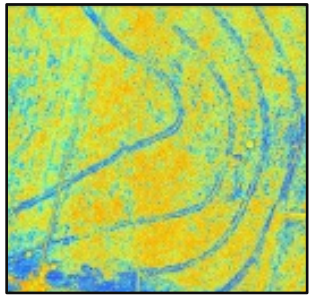
O crescimento está no ritmo ou está
atrasado em alguma parte dos talhões?



Previsão de produtividade

Produto comercial, metodologia proprietária

Quanto este talhão vai produzir antes da colheita? Como a produtividade varia dentro do talhão?



Estimativa de nitrogênio

Drone + Sentinel-2, Random Forest

Onde este talhão precisa
de nitrogênio agora?



Mapa de taxa variável

Produto comercial, metodologia proprietária

Quantidade exata de semente ou fertilizante, zona por zona

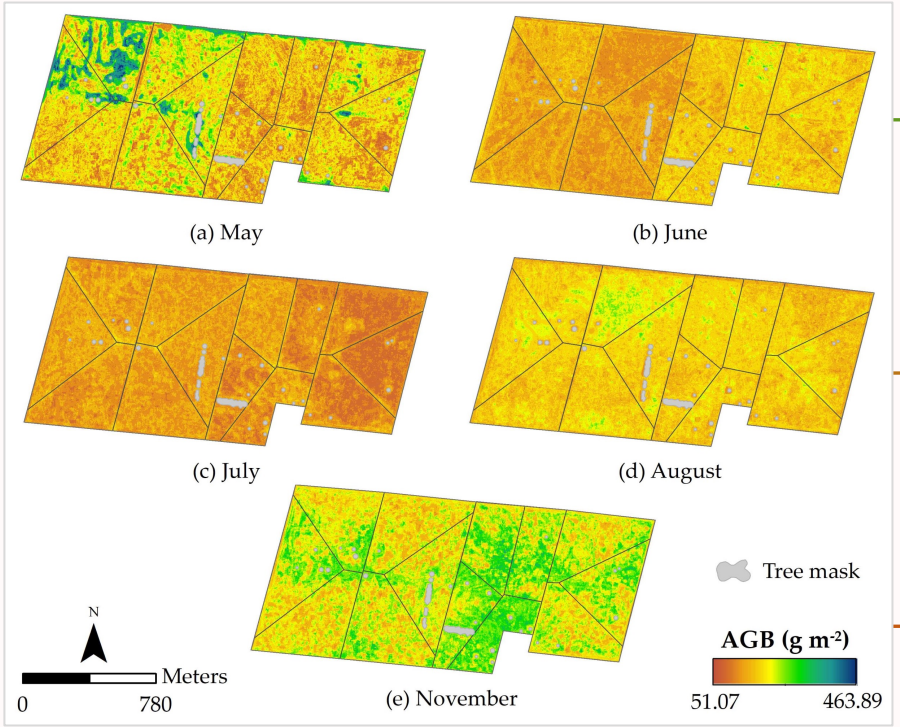
Fontes: Reis et al. (2020), Pereira et al. (2022).

Fonte: CORVIAN

Aplicações de IA no talhão e na fazenda

Estimativa de biomassa ao longo do tempo

Séries temporais PlanetScope + XGBoost/Random Forest, treinados com biomassa aérea medida em campo



ESTE MÊS

Onde pastejar ou roçar

Levar os animais para os piquetes mais verdes do mês; descansar os laranja.

PRÓXIMA ADUBAÇÃO

Onde adubar em seguida

Zonas que continuam laranja por dois meses ou mais, não o talhão inteiro.

HORIZONTE MAIS LONGO

Onde investigar em campo

Zonas sempre baixas, qualquer que seja o mês: verificar sombra, drenagem ou compactação antes de culpar os nutrientes.

Fonte: Reis et al. (2020)

AGB = biomassa aérea

Aplicações de IA no talhão e na fazenda

Estimativa de nitrogênio: de pontos isolados a mapas

Imagens de drone, PlanetScope e Sentinel-2 + Random Forest, treinado com nitrogênio medido em campo



O QUE O MAPA MOSTRA

O talhão não é uniforme

Algumas áreas precisam de nitrogênio agora; outras não: **um retrato desta cultura, neste estádio**.

QUE TIPO DE CONHECIMENTO É

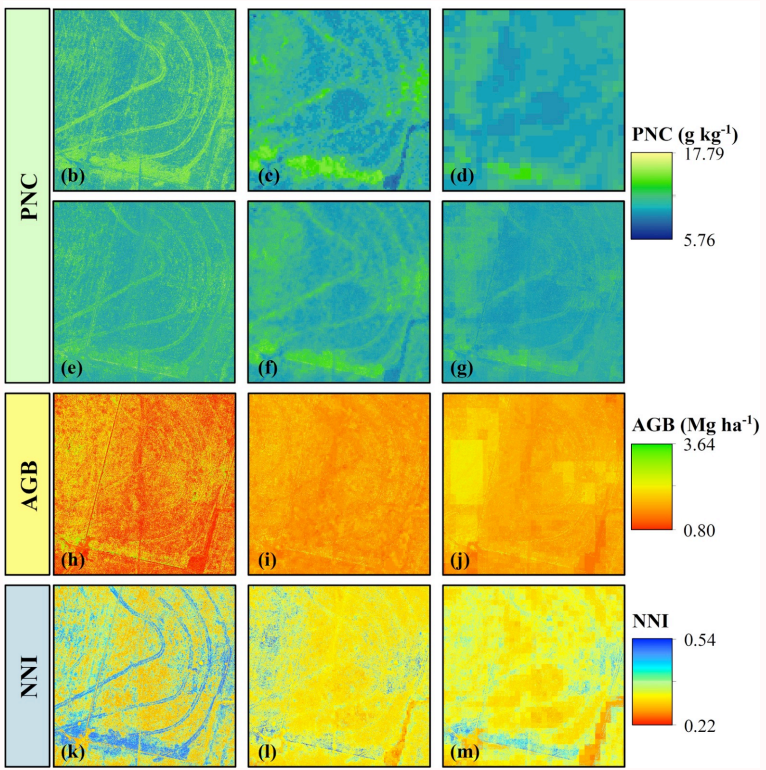
Um retrato dinâmico da safra

Ligado ao clima e ao estádio da cultura deste ano: **será diferente no próximo mês/safra**.

O QUE AINDA FALTA

Saber onde não é um plano

Transformar isso em uma dose aplicável é o próximo passo.



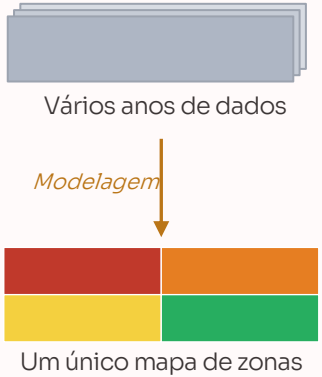
PNC = teor de N da planta, AGB = biomassa aérea, NNI = índice de nutrição nitrogenada

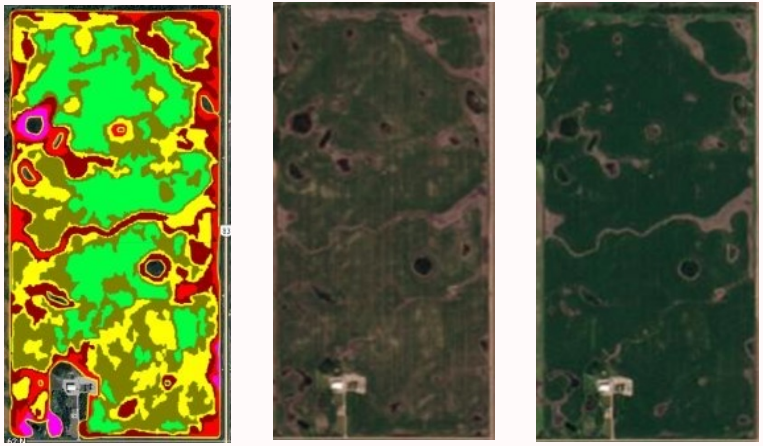
Fonte: Pereira et al. (2022)

Aplicações de IA no talhão e na fazenda

Mapa de taxa variável: transformando zonas em ação

Vários anos de dados, modelados pelo software proprietário da Corvian





O QUE MUDA AQUI

Um padrão estrutural, não um retrato

Construído com vários anos de dados

A DECISÃO

Dose exata por zona, automática

Taxa de semente ou fertilizante enviada direto para o equipamento.

POR QUE AMBOS IMPORTAM

Insumo certo, lugar certo

Ajustar os insumos à **variabilidade real do talhão** aumenta a rentabilidade e **reduz o excesso de fertilizante e água** : um apoio direto a uma agricultura climaticamente inteligente e eficiente no uso de recursos.

Aplicações de IA no talhão e na fazenda

Mapas de previsão de produtividade

Modelado pelo software proprietário da Corvian

PRÉ-COLHEITA

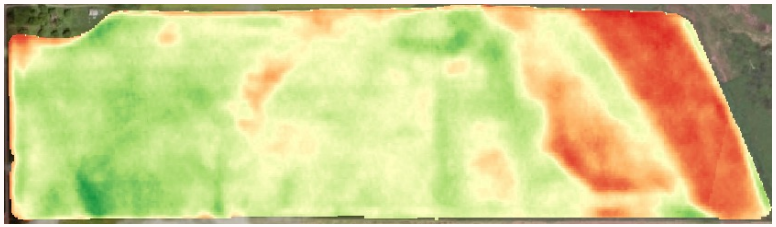
Planejar armazenagem, vendas, logística e sequência

COLHEITA

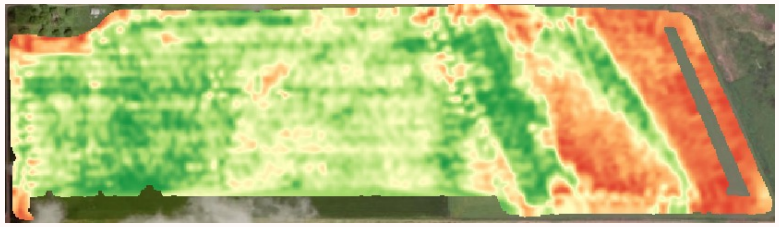
A colhedora registra o que de fato aconteceu

PÓS-COLHEITA

Validar o modelo, diagnosticar zonas de baixa produtividade persistente, alimentar os modelos da próxima safra



Mapa de previsão de produtividade



Mapa gerado pelo monitor de produtividade da colhedora

A produtividade média resume o desempenho. Os mapas de produtividade mostram onde o manejo pode melhorar a produção.

IA para decisões nas escalas regional e nacional

Nas escalas regional e nacional, a pergunta muda totalmente: **quais culturas estão sendo cultivadas, onde estão mudando e como os sistemas agrícolas evoluem ao longo do tempo?**

À medida que práticas climaticamente inteligentes, como plantas de cobertura, plantio direto e sistemas integrados, se tornam mais comuns, as paisagens agrícolas ficam mais diversas e mais difíceis de monitorar com abordagens convencionais.

A IA ajuda a captar esses padrões espaciais e temporais complexos, permitindo um monitoramento agrícola preciso nas escalas regional e nacional.

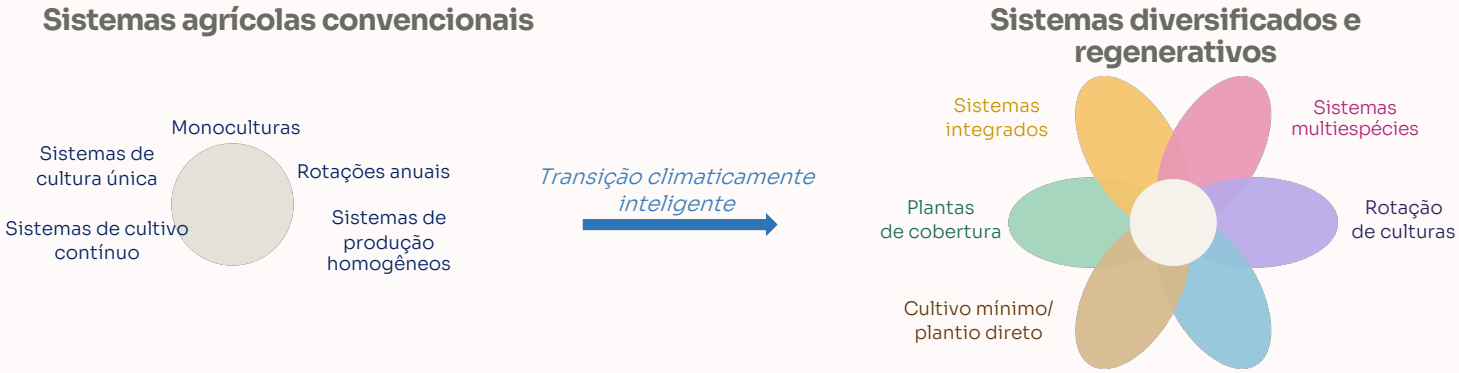


Áreas agrícolas na França
Image © 2026 Planet Labs PBC

Aplicações de IA nas escalas regional e nacional

A agricultura climaticamente inteligente está mudando as paisagens agrícolas

Os sistemas agrícolas estão se diversificando para melhorar a resiliência, a saúde do solo e a sustentabilidade.

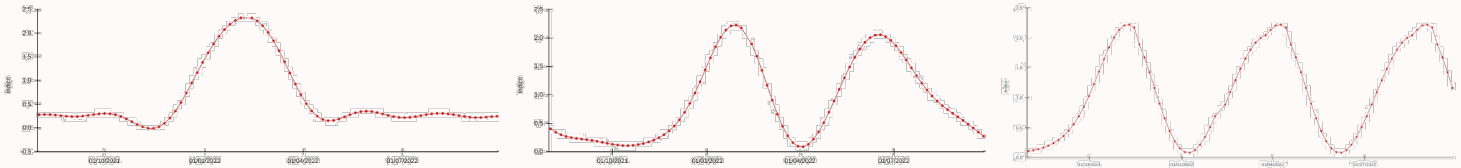


A agricultura climaticamente inteligente cria sistemas de produção mais saudáveis e resilientes.

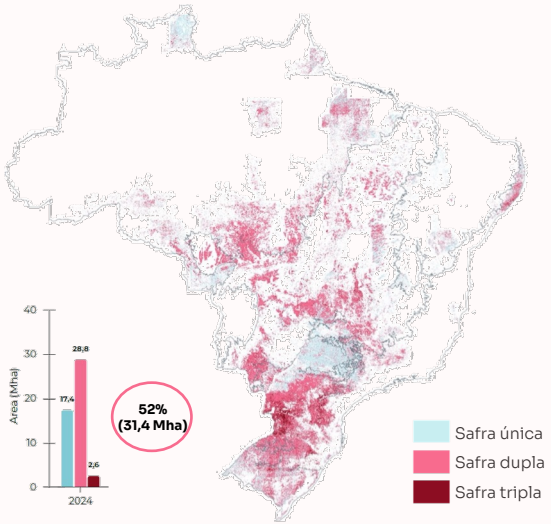
Aplicações de IA nas escalas regional e nacional

Sistemas agrícolas mais complexos exigem monitoramento mais avançado

As paisagens agrícolas estão passando de sistemas de cultivo relativamente simples para sistemas de manejo dinâmicos, com complexidade temporal crescente.







Fonte: adaptado de MapBiomas

Por que esses sistemas são mais difíceis de monitorar?

→ Culturas semelhantes em estádios diferentes

→ Vários ciclos de cultivo no mesmo ano

→ Dinâmica sazonal

→ Plantas de cobertura de ciclo curto

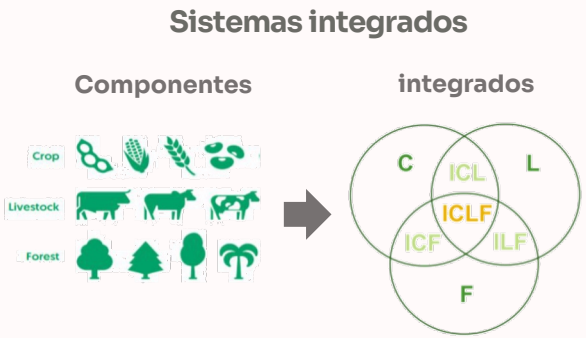
→ Alta variabilidade temporal

→ Assinaturas espectrais semelhantes

Captar essas dinâmicas espaciais e temporais complexas exige abordagens de IA mais robustas.

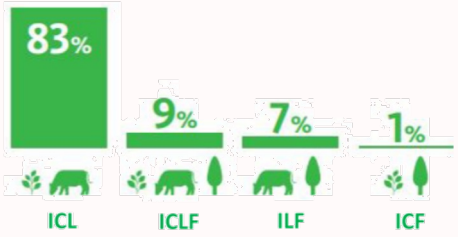
Aplicações de IA nas escalas regional e nacional

Estudo de caso: *mapeando sistemas agrícolas complexos com aprendizado profundo, o caso dos sistemas de integração lavoura-pecuária (ICLS) no Brasil*

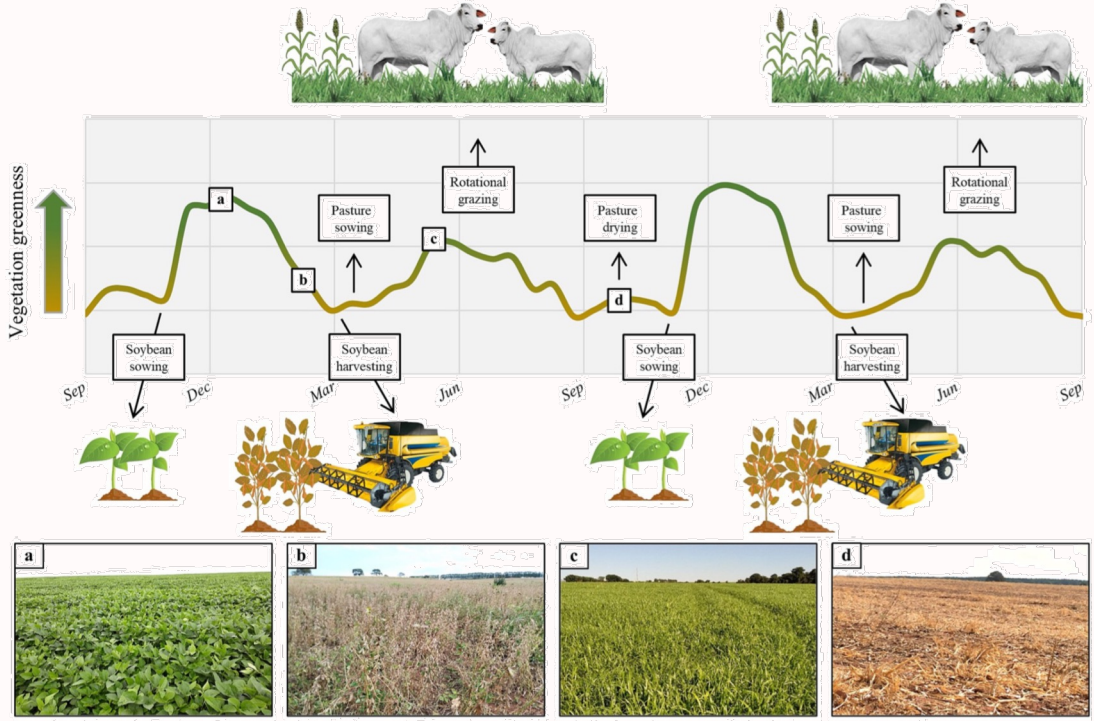


Área total de ICLS no Brasil:

~17 milhões de hectares



Fonte: Rede ILPF (2023, 2026)

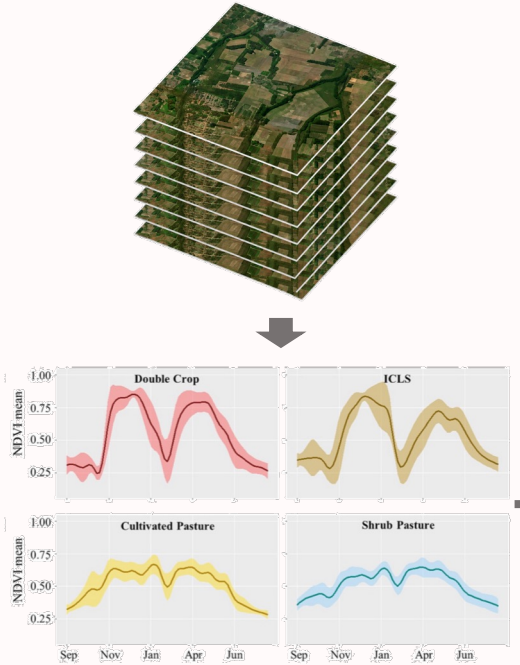


Fonte: Bueno et al. (2023)

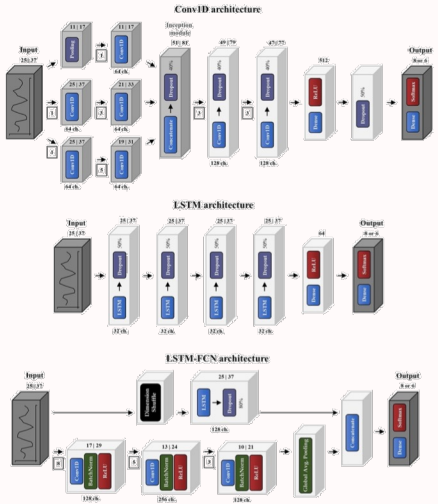
Aplicações de IA nas escalas regional e nacional

Estudo de caso: *mapeando sistemas agrícolas complexos com aprendizado profundo, o caso dos sistemas de integração lavoura-pecuária (ICLS) no Brasil*

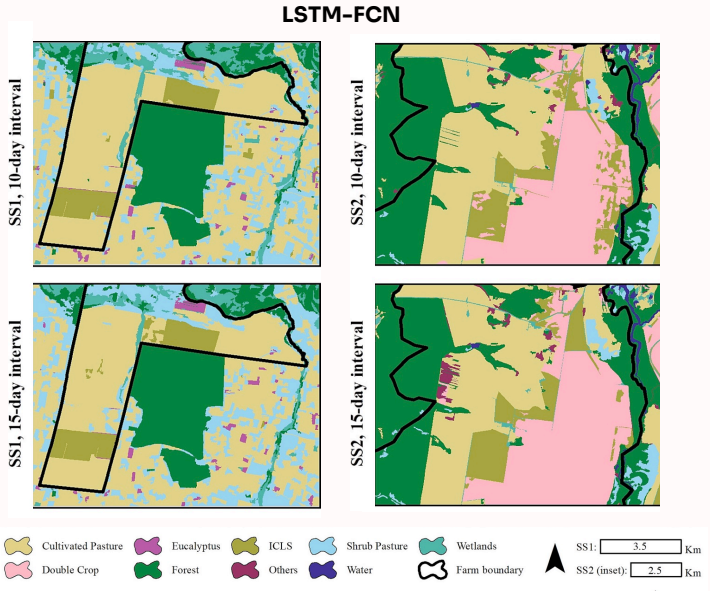
Séries temporais PlanetScope



Classificadores de redes neurais profundas



Mapeamento de ICLS



Acurácias por classe de ICLS:
PA (acurácia do produtor) = 97,0%;
UA (acurácia do usuário) = 97,0% para SS1 (área de estudo 1)
PA = 82,0%; UA = 96,5% para SS2 (área de estudo 2).

Fonte: adaptado de Bueno et al. (2023)

Aplicações de IA nas escalas regional e nacional

Por que mapear sistemas integrados importa?

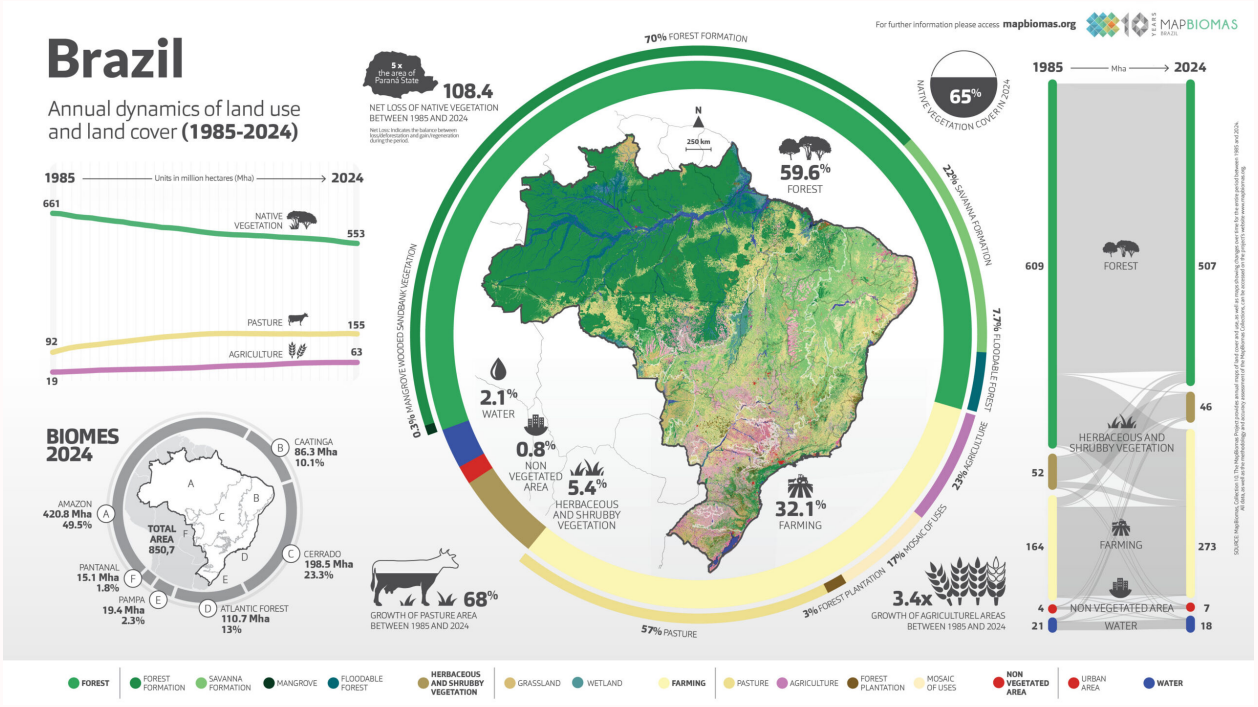
Mapas melhores permitem decisões melhores para vários atores.



Aplicações de IA nas escalas regional e nacional

Estudo de caso: *MapBiomas*

*O MapBiomas é uma **iniciativa brasileira multi-institucional** que envolve ONGs, universidades e empresas de tecnologia e mapeia a cobertura e o uso da terra e suas mudanças no Brasil.*



Fonte: MapBiomas Brasil, Coleção 10

40 anos
1985–2024, contínuos

30 m e 10 m
(Coleção Beta)
Resolução Landsat e Sentinel-2

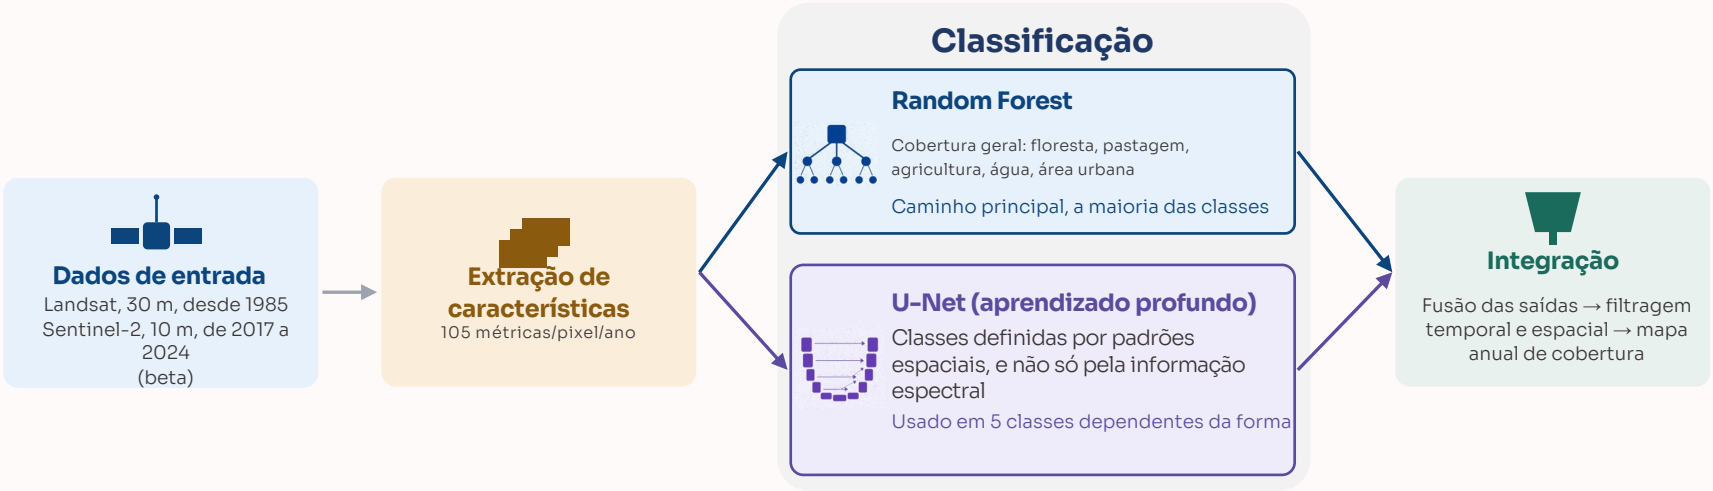
9 bi+
pixels classificados/ano

+30
classes de cobertura e uso da terra

Aplicações de IA nas escalas regional e nacional

Estudo de caso: *MapBiomas*

O MapBiomas ajusta o modelo ao problema: Random Forest para a cobertura geral, U-Net para classes que dependem da forma.



O modelo certo para o problema certo.

Escolher o algoritmo certo para cada problema, em vez de depender de um único modelo para tudo, permite ao MapBiomas cobrir um país inteiro mantendo alta acurácia em classes complexas dependentes da forma.

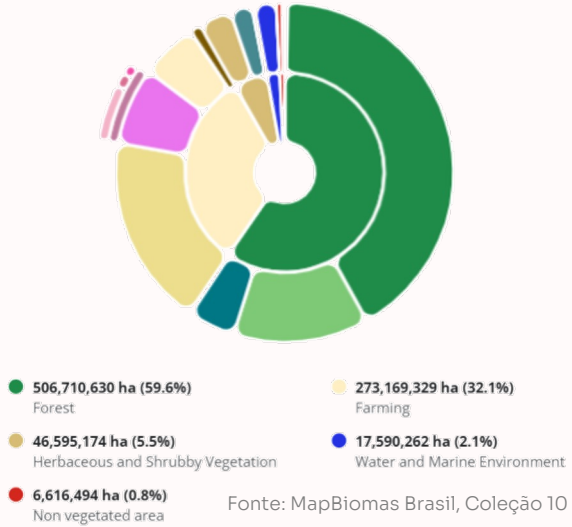
Fonte: MapBiomas Brasil, Coleção 10

Aplicações de IA nas escalas regional e nacional

Por que importa: decisões viabilizadas pelo MapBiomas

- *Os produtos do MapBiomas alimentam diretamente a governança ambiental do Brasil e funcionam como infraestrutura operacional, e não apenas como produto de pesquisa.*

Cobertura por classe – 2024



Fonte: MapBiomas Brasil, Coleção 10

Tomada de decisão

→ Apoiar políticas e programas
→ Avaliar a eficácia das políticas
→ Apoiar a fiscalização do desmatamento
→ Subsidiar a contabilidade de carbono
→ Garantir a conformidade do crédito rural
→ Orientar o manejo do fogo
→ Apoiar a gestão dos recursos hídricos
→ Priorizar o planejamento da conservação
→ Apoiar e viabilizar a pesquisa global
→ Fazer cumprir a regularidade fundiária

Uma base de evidências única, transparente e pública, independente de qualquer governo, permite que governo, tribunais, ONGs e organismos internacionais ajam com base nos mesmos fatos.

IA para decisões em escala global

Em escala global, precisamos saber **onde as culturas são cultivadas, quanto produzem e onde podem surgir riscos à produção.**

O monitoramento global de safras enfrenta **lacunas de dados, cobertura desigual de levantamentos e safras defasadas entre hemisférios.**

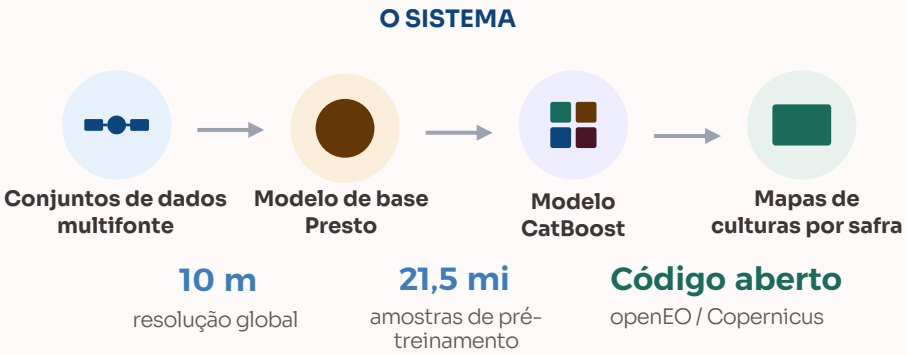
A IA combinada com várias fontes de dados oferece uma visão global da agricultura, apoiando avaliações de segurança alimentar e decisões de alerta precoce.



Aplicações de IA em escala global

ESA WorldCereal

O WorldCereal é um projeto de pesquisa financiado pela Agência Espacial Europeia que busca oferecer um sistema de processamento gratuito, em nuvem, para gerar produtos personalizados de alta resolução sobre a localização e o tipo de culturas, em escala local e global.



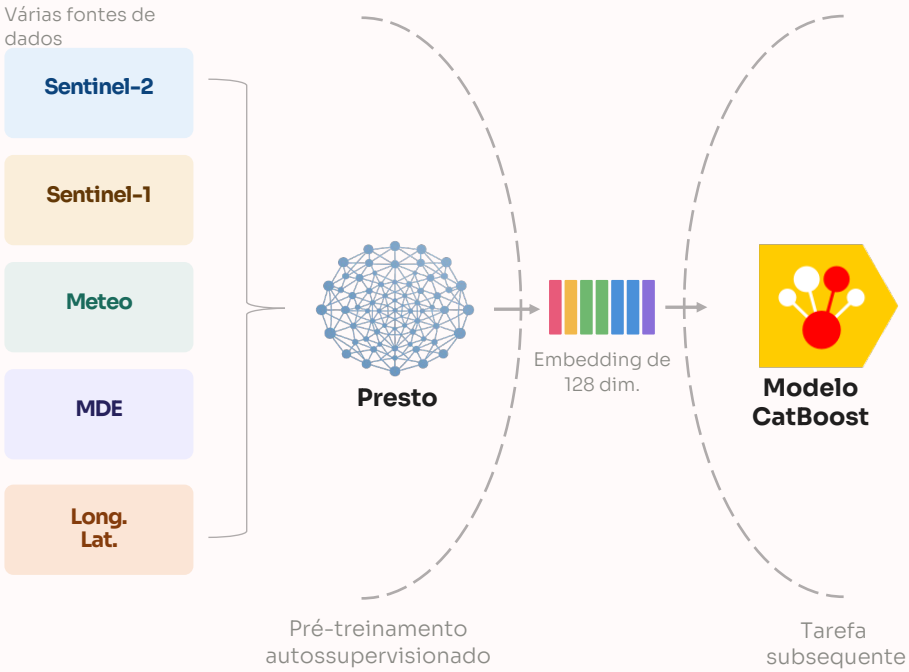


Mapa de culturas temporárias do WorldCereal com resolução de 10 m para 2021.
Fonte: ESA WorldCereal, 2026.

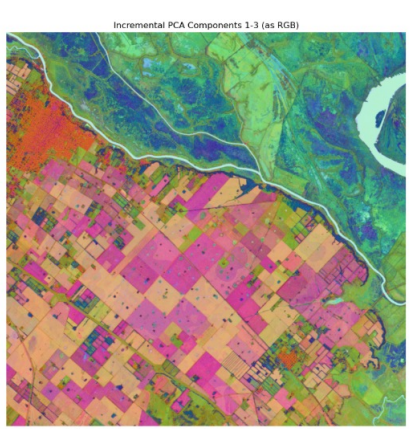
Aplicações de IA em escala global

Modelos de base geoespaciais: *Presto, Pretrained Remote Sensing Transformer*

O modelo pré-treinado por trás da classificação de culturas do WorldCereal.



- → Desenvolvido pela **NASA Harvest (Tseng et al., 2023)**
- → **Aprende com milhões de dados sem rótulo**
- → Representa **séries temporais multimodais como um único vetor de embedding de 128 dimensões**
- → Treina o mapeamento de culturas subsequente com alta capacidade de generalização
- → Atualizado para o WorldCereal para usar muito menos rótulos



Exemplo visual de embeddings do Presto calculados dinamicamente em uma região próxima a Buenos Aires, Argentina. Os 128 embeddings são visualizados aqui com base em uma PCA reduzida a três componentes RGB. ***Fonte: ESA WorldCereal***

Aplicações de IA em escala global

GEOGLAM
GLOBAL AGRICULTURAL MONITORING

GEOGLAM Global Crop Monitor

O GEOGLAM (Group on Earth Observations Global Agricultural Monitoring) *é uma iniciativa do G20 que coordena observação da Terra, informações agroclimáticas e conhecimento especializado para fortalecer o monitoramento agrícola e apoiar a segurança alimentar global.*

*O **GEOGLAM Global Crop Monitor** é o principal produto do GEOGLAM: uma avaliação global mensal da condição das lavouras que combina produtos de observação da Terra (incluindo conjuntos de dados derivados de IA), informações agroclimáticas, observações de campo e o consenso de especialistas de agências parceiras internacionais.*

DADOS DE ENTRADA

Extensão das culturas
Máscaras de áreas agrícolas e mapas de culturas de várias fontes, incluindo produtos derivados de IA, como o ESA WorldCereal, quando disponíveis.

Observação da Terra
Indicadores de satélite da condição da vegetação, incluindo NDVI, fAPAR e anomalias de vegetação.

Condições agroclimáticas
Chuva, temperatura, umidade do solo, evapotranspiração e indicadores de seca.

Observações de campo
Relatórios nacionais e observações locais de agências parceiras.

AVALIAÇÃO DE ESPECIALISTAS

Especialistas regionais e nacionais avaliam de forma independente a condição das lavouras.

As divergências são revisadas com várias linhas de evidência.

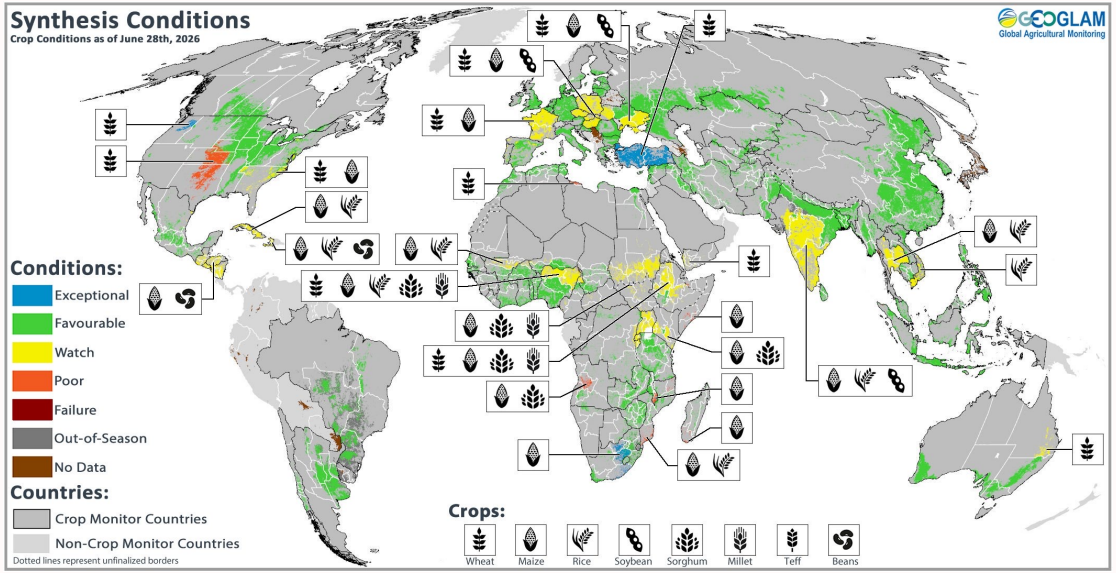
Os especialistas discutem as avaliações regionais e chegam a um consenso antes da publicação.

As avaliações de consenso são publicadas no Crop Monitor mensal.

Aplicações de IA em escala global

GEOGLAM Global Crop Monitor

Síntese do Crop Monitor for AMIS (Agricultural Market Information System), do Crop Monitor for Early Warning e de contribuições diretas de diferentes países.



A condição das lavouras nas principais áreas produtoras baseia-se em dados ***que incluem sensoriamento remoto, observações em campo, relatórios de campo e especialistas nacionais e regionais****.*

Decisões apoiadas

- Alerta precoce de riscos à produção de alimentos
- Planejamento da resposta humanitária
- Transparência de mercado e avaliações de segurança alimentar
- Preparação nacional e coordenação internacional

Fonte: GEOGLAM Crop Monitor (12 de julho de 2026)

Aplicações de IA em escala global

A IA viabiliza o monitoramento global; a expertise humana, decisões confiáveis.

O que a IA permite

- Monitorar a condição das lavouras de forma consistente entre países e continentes.
- Detectar sinais precoces de seca, estresse das lavouras e riscos à produção.
- Gerar, a tempo e em larga escala, produtos de observação da Terra impossíveis de produzir manualmente.
- Fornecer informação objetiva e reprodutível para o monitoramento agrícola global.

Por que manter o humano no circuito

- Interpretar os resultados da IA com conhecimento local e contexto real.
- Avaliar a incerteza antes de agir em decisões de alto impacto.
- Resolver evidências conflitantes entre várias fontes de dados.
- Combinar os insights da IA com o julgamento de especialistas e observações de campo.
- Garantir transparência e responsabilização nas decisões operacionais.

A IA amplia a informação. A expertise humana a transforma em decisões confiáveis.

Quanto maior a escala da decisão, mais importante se torna combinar a IA com expertise humana, transparência e colaboração institucional.

Pergunta do quiz 3

Um país está adotando um sistema de alerta precoce de secas baseado em IA para orientar a assistência alimentar emergencial. Qual escolha de design tem mais chances de melhorar a tomada de decisão?

A

Maximizar a acurácia preditiva usando um modelo complexo de aprendizado profundo.

B

Produzir previsões na resolução espacial mais fina possível.

C

Combinar previsões confiáveis com estimativas de incerteza e entregar os resultados em um formato que os órgãos locais possam interpretar e usar facilmente.

D

Priorizar um modelo que possa ser implantado globalmente sem adaptação regional.

Resposta correta: C. Combinar previsões confiáveis com estimativas de incerteza e entregar os resultados em um formato que os órgãos locais possam interpretar e usar facilmente.

Limitações, IA responsável e desafios reais

Limitações técnicas

- Disponibilidade e qualidade limitadas dos dados de treinamento
- Viés geográfico: modelos treinados em uma região podem não generalizar para outras
- Transferibilidade limitada entre culturas, regiões e sistemas de manejo
- Não estacionariedade do clima: o passado pode não prever o futuro
- A incerteza das previsões aumenta com condições ambientais em mudança

Considerações de IA responsável

- Interpretabilidade e transparência dos resultados dos modelos
- Acessibilidade e equidade: quem se beneficia das ferramentas de IA?
- Riscos da dependência excessiva da IA em decisões de alto risco
- Comunicar claramente a incerteza aos tomadores de decisão
- Avaliar os modelos com base nas decisões que devem apoiar

⚠ **Os resultados da IA devem apoiar a tomada de decisão, e não substituir o julgamento de especialistas nem ser tratados como verdade de campo.**

Perspectivas e oportunidades de pesquisa

A IA está evoluindo de modelos específicos para sistemas integrados, reutilizáveis e acessíveis de observação da Terra.

Evolução tecnológica

Embeddings da Terra

Representações gerais da superfície terrestre que podem ser adaptadas a várias tarefas subsequentes.

Modelos de base

Grandes modelos pré-treinados que podem ser ajustados para uma ampla gama de tarefas de observação da Terra.

Aprendizado multimodal

Modelos que aprendem em conjunto com imagens de satélite, tempo, solo, manejo e texto.

Democratizando o acesso

Dados abertos

Maior disponibilidade de dados agrícolas e ambientais de qualidade para pesquisa e desenvolvimento.

Ferramentas de código aberto

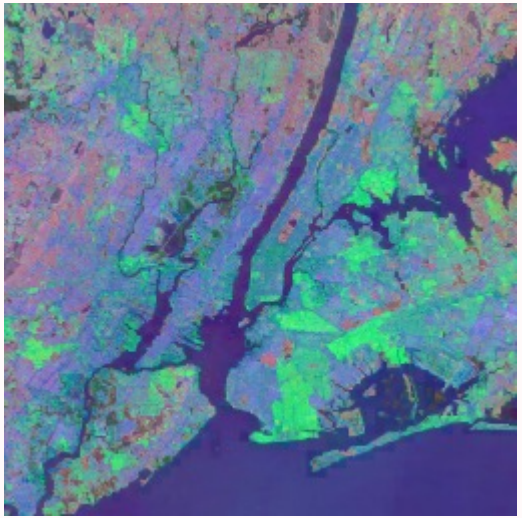
Ferramentas de código aberto tornam métodos avançados de IA mais acessíveis e reprodutíveis.

Acessibilidade global

Reduzir barreiras para pesquisadores e profissionais, sobretudo em regiões com poucos dados.

> Sistemas de IA integrados que combinam observação da Terra, clima, manejo e dados de campo para gerar informação acionável para decisões climaticamente inteligentes.

Perspectivas e oportunidades de pesquisa



Exemplo de embeddings anuais do AlphaEarth

Fonte: Google Earth Engine Data Catalog; Google DeepMind.

Modelos de base e embeddings da Terra

Em vez de treinar modelos separados para cada tarefa agrícola, os modelos de base aprendem representações gerais da superfície terrestre que podem ser adaptadas a muitas aplicações subsequentes.

Aplicações potenciais

- Mapeamento de culturas
- Monitoramento de culturas
- Monitoramento do uso da terra
- Detecção de mudanças
- Estimativa de biomassa

Limitações atuais

- Projetados para análise histórica, e não para monitoramento durante a safra
- Embeddings anuais podem misturar várias safras
- Dinâmicas agrícolas finas podem se perder em sistemas muito sazonais
- Exigem ajuste fino específico para aplicações agrícolas operacionais

Próximos passos práticos

Continue explorando a IA para a agricultura e a segurança alimentar

Explorar dados

→ Embeddings do AlphaEarth (Google Earth Engine)
→ ESA WorldCereal
→ MapBiomas
→ Fields of the World
→ Conjuntos de dados de referência (p. ex., CY-Bench)

Explore conjuntos de dados reais para IA agrícola.

Construir com ferramentas abertas

→ Google Earth Engine
→ Python (leafmap, geemap)
→ Google Colab

Crie e teste fluxos de trabalho de IA com ferramentas de código aberto.

Praticar e experimentar

→ Explorar tutoriais e notebooks
→ Reproduzir fluxos de trabalho publicados
→ Ajustar modelos de base

Prática com notebooks e fluxos de trabalho reais.

Participar da comunidade

→ Climate Change AI
→ NASA Harvest
→ GEOGLAM
→ IEEE GRSS

Lugares para continuar aprendendo e se conectar com profissionais.

Recursos: AlphaEarth Colab Notebook · AlphaEarth Dataset (GEE) · CY-Bench (Crop Yield Benchmark) · WorldCereal (GitHub) · MapBiomas



Áreas agrícolas ao redor do mundo
Imagens © 2026 Planet Labs PBC

Climate Change AI
Escola de verão virtual 2026

Obrigada!

Dra. Aliny Reis
Cientista sênior de sensoriamento remoto · Corvian

alinyreis@hotmail.com
aliny.reis@corvian.com

linkedin.com/in/aliny-reis

Decisões melhores começam com informações melhores.

A IA está transformando observações da Terra em informação acionável, permitindo decisões agrícolas melhores, do talhão à segurança alimentar global.