IA para a contabilidade de carbono

Dan Cusworth

Escola de verão virtual CCAI

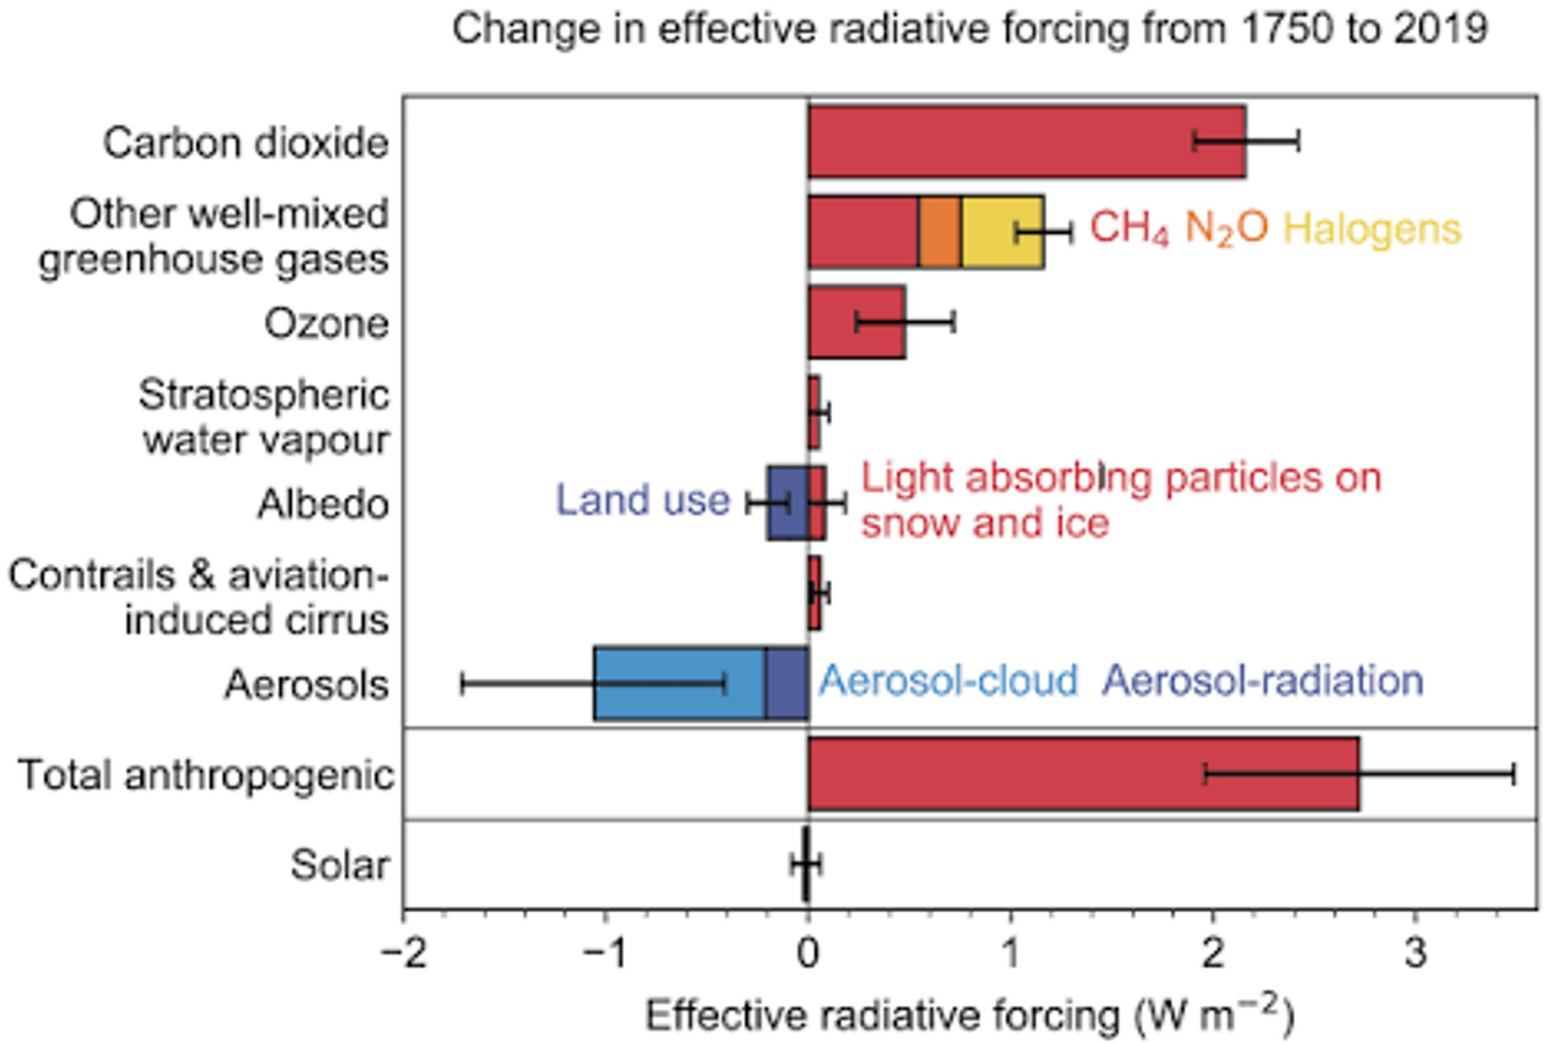
Agosto de 2026

Roteiro da aula

0:00–0:30	**Parte 1** Fundamentos da contabilidade de carbono
0:30–0:35	Momento de participação
0:35–1:05	**Parte 2** Sensoriamento remoto para a contabilidade de carbono
1:05–1:15	Intervalo + momento de participação
1:15–1:45	**Parte 3** Usando IA para melhorar a contabilidade de carbono
1:45–2:00	Discussão e encerramento

Parte 1 Fundamentos da contabilidade de carbono

Por que as pessoas querem contabilizar o carbono?



Emissões de duas moléculas de carbono

Dióxido de carbono (CO2)

Metano (CH4)

Responsáveis pela maior parte do aquecimento desde a era pré-industrial

Fonte: IPCC

Por que as pessoas querem contabilizar o carbono:

- Estimar as emissões de gases de efeito estufa (GEE)
- Monitorar os estoques de carbono e outros GEE
- Quantificar incertezas

Foco da aula de hoje

- Melhorar a contabilidade corporativa
- Fortalecer a avaliação do ciclo de vida
- Apoiar os processos de verificação e auditoria

Uma taxonomia: onde a IA entra na contabilidade de carbono?

Use este mapa como guia: cada nó é abordado mais adiante na aula

Dados de atividade	Estimativa de emissões	Relato e agregação	Verificação e auditoria
Que atividades estão acontecendo e em que escala?	Quanto GEE é emitido por unidade de atividade?	Combinar fontes em inventários	Verificações cruzadas independentes de dados autodeclarados
Imagens: detecção de objetos (fazendas, poços de petróleo, siderúrgicas, árvores)	Detecção e segmentação de plumas	Homogeneização/organização automatizada dos dados de atividade	Validação cruzada por satélite
Imagens: detecção de desmatamento/mudança no uso da terra	Inversão atmosférica (fluxo top-down)	Escalonamento da avaliação do ciclo de vida para todos os tipos de produto	Sinalização de anomalias/superemissores
Proxies: coleta de conjuntos de dados públicos (p. ex., concessões de operadores)	Aprimoramento dos fatores de emissão	Estimativa de escopo 3 da cadeia de suprimentos	Quantificação da incerteza

Esta aula aprofunda a estimativa de emissões (detecção de plumas) e os dados de atividade, com conexões com a verificação ao longo de toda a aula.

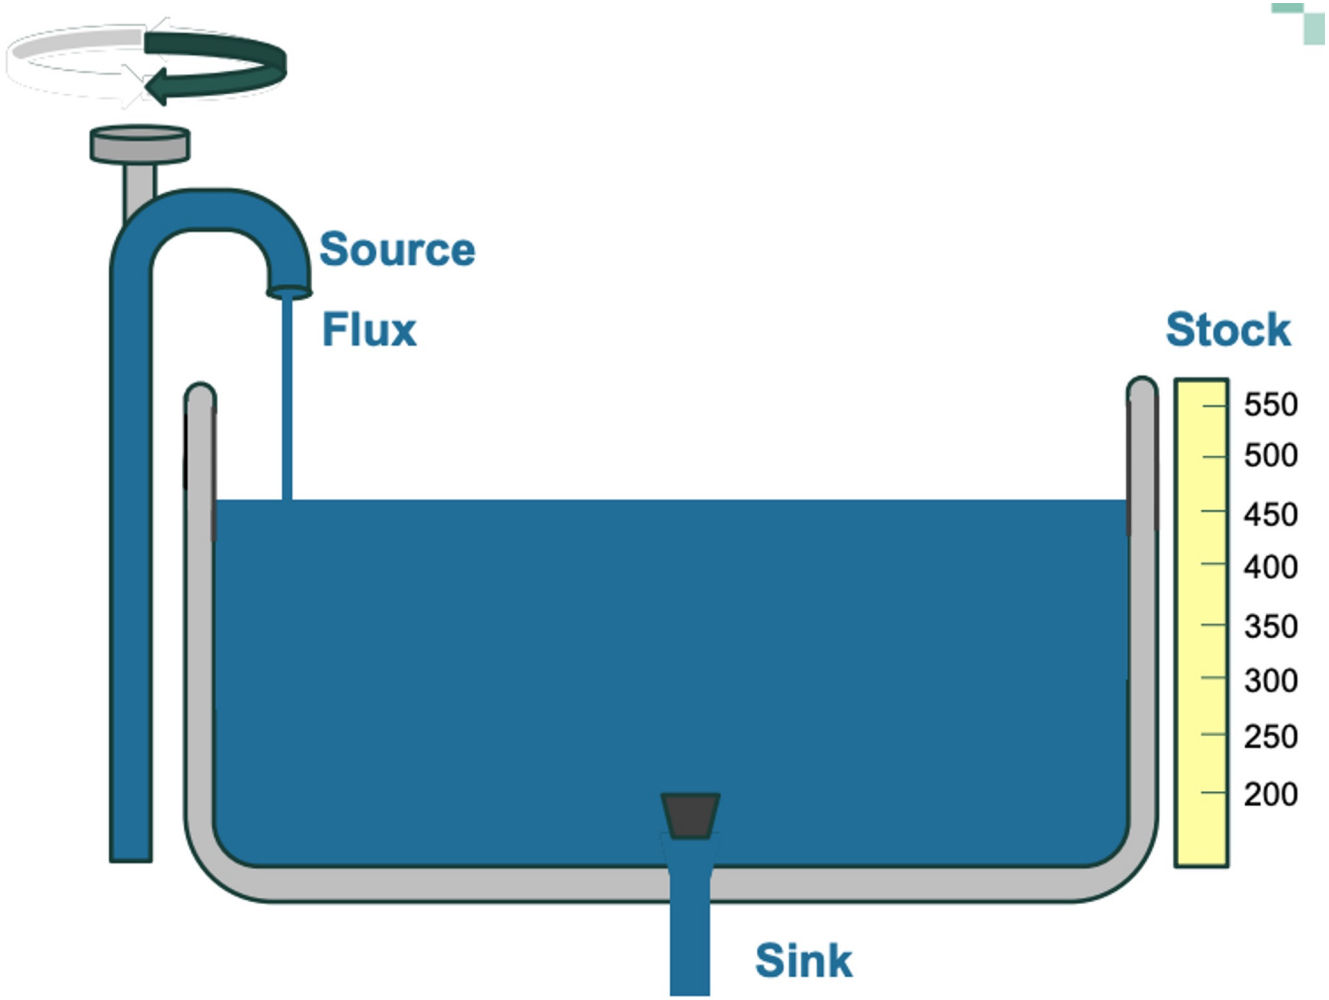
Relação entre fontes, sumidouros e estoques

Imagine uma pia com uma torneira e um tampão no fundo.

- **Estoque**: a água na pia
- **Fonte**: adicionar água à pia
- **Sumidouro**: retirar água da pia

- A taxa de aumento do estoque na pia é chamada de fluxo.

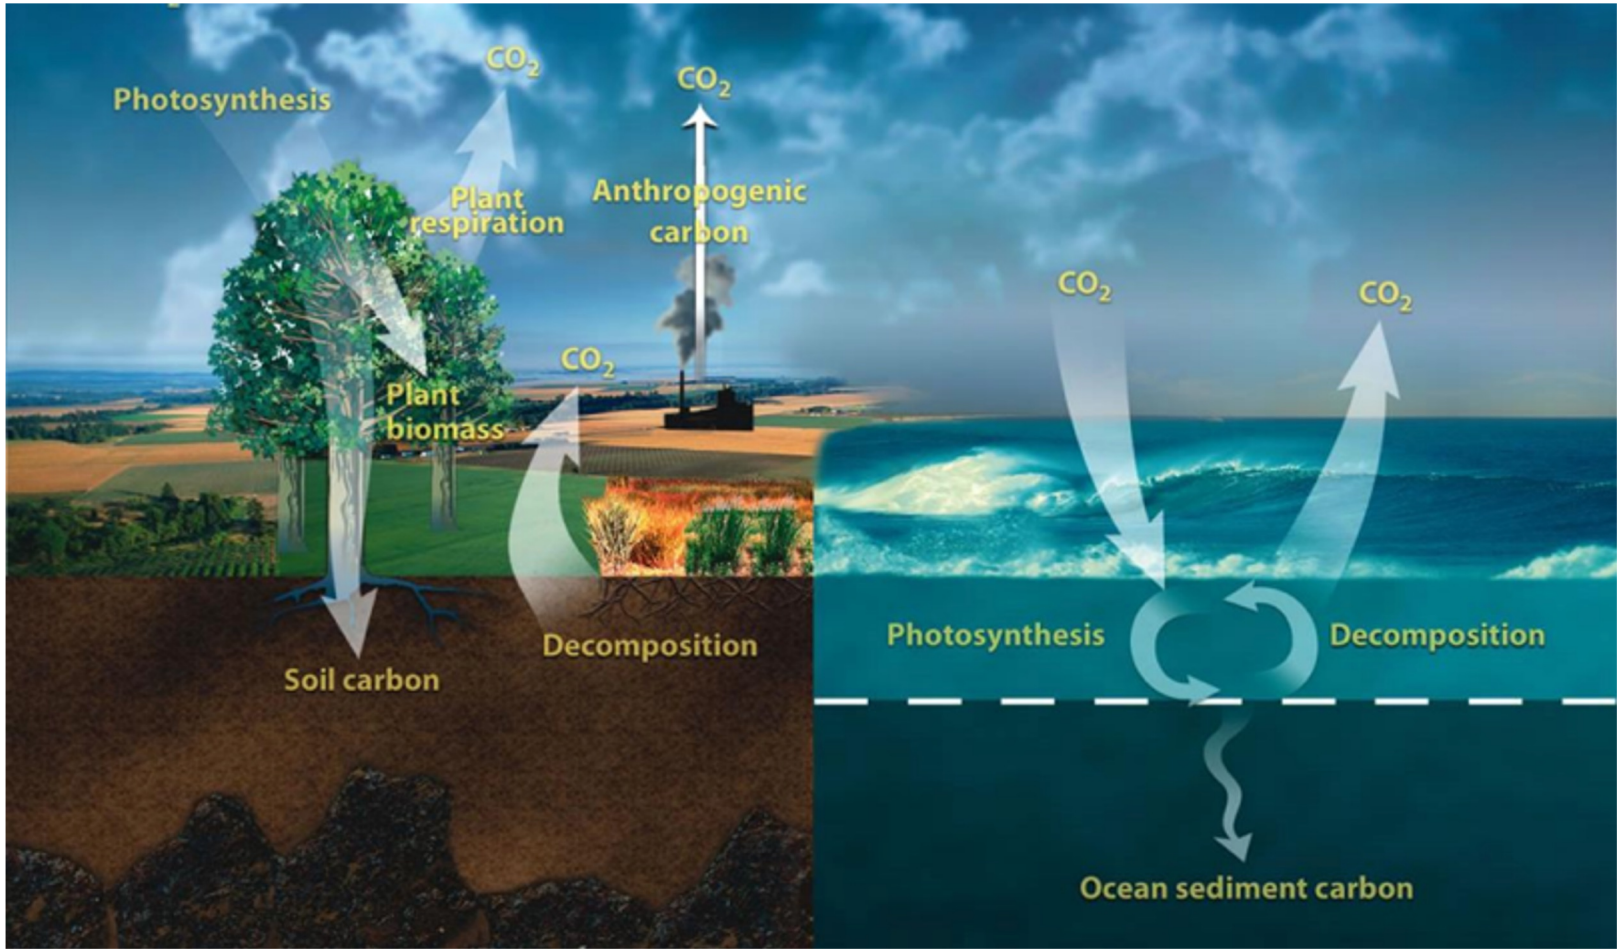
– As fontes geram fluxos positivos.
– Os sumidouros geram fluxos negativos.



Fonte: NASA ARSET

Quais são as principais fontes e sumidouros de carbono?

Fontes e sumidouros de carbono



Contabilizar o carbono/CO2 exige entender

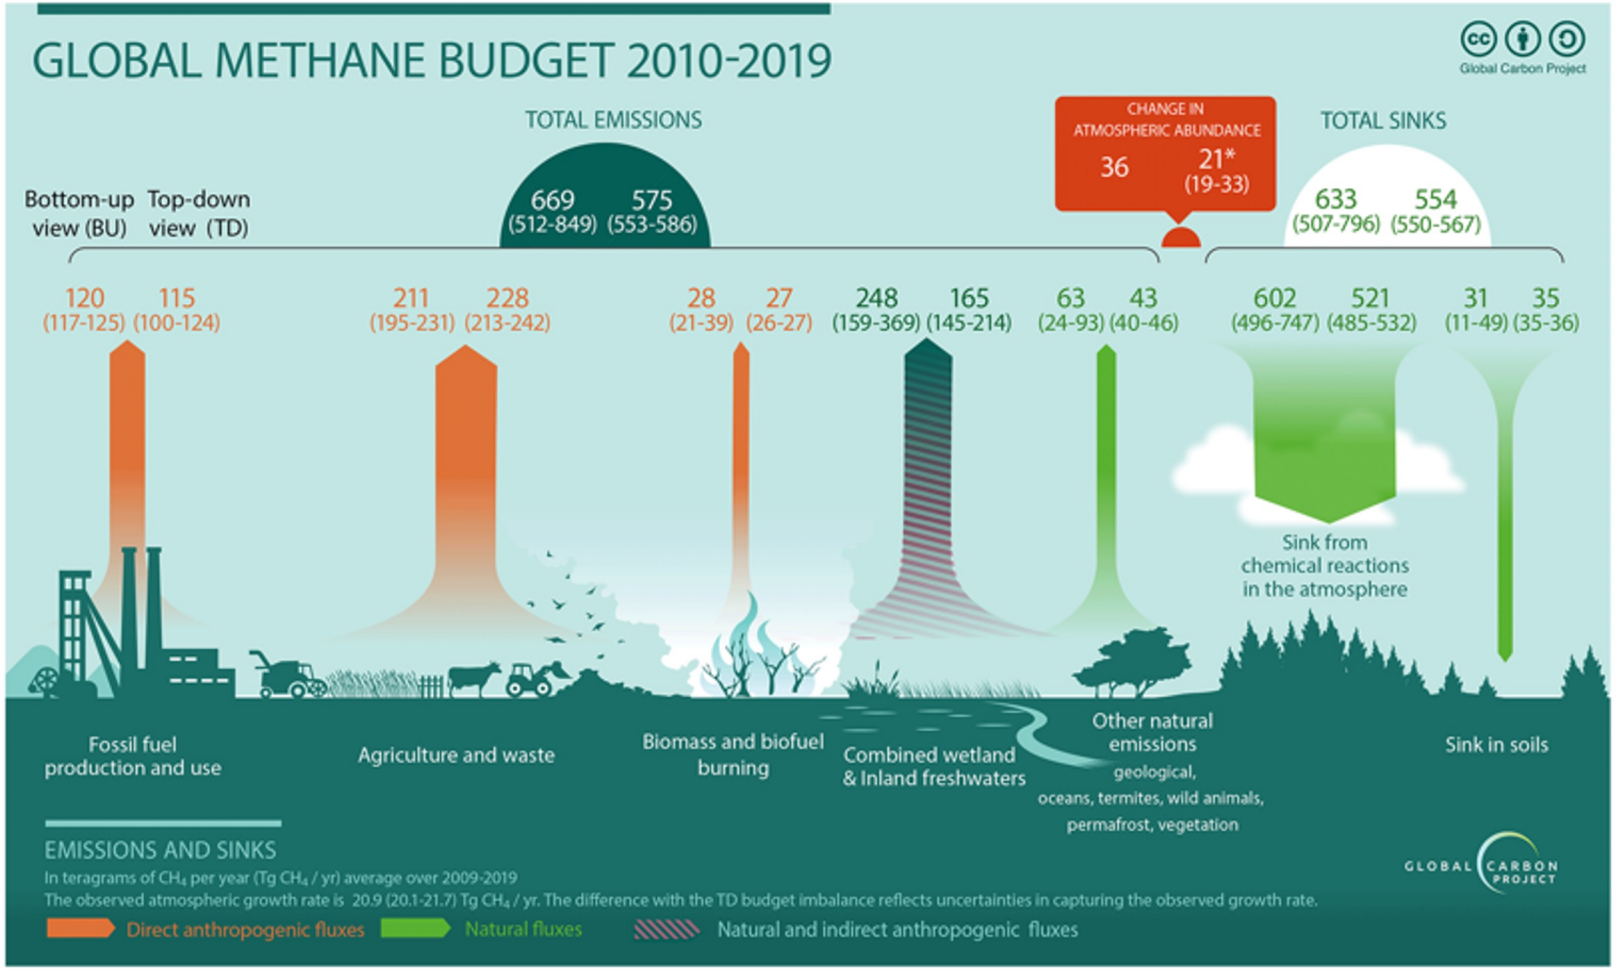
- O tamanho dos estoques de carbono nos diversos "reservatórios"

- Os processos que alteram esses estoques (p. ex., ciclagem e emissões)

Fonte: ORNL

Quais são as principais fontes e sumidouros de carbono?

Fontes e sumidouros de metano (CH4)



O metano é diferente do CO2:

- Seu principal sumidouro é a atmosfera, por oxidação
- Vida curta (~10 anos versus centenas de anos)
- GEE 80 vezes mais potente que o CO2 (por unidade emitida) em um horizonte de 20 anos

Fonte: Sanuois et al. (2020)

Acordo de Paris: tratado internacional juridicamente vinculante com o objetivo de manter o aquecimento global bem abaixo de 2 °C



- **Contribuições Nacionalmente Determinadas (NDCs):** cada país deve apresentar e atualizar progressivamente seu próprio plano de redução de emissões a cada cinco anos.

- **Transparência e prestação de contas:** os membros acompanham e relatam seu progresso rumo às NDCs com relatórios padronizados e revisão internacional.

- Um **Balanço Global** periódico, em que os países avaliam o progresso coletivo rumo a metas como manter o aumento da temperatura global bem abaixo de 2 °C.

Quais métodos tradicionais são usados na contabilidade de carbono?

1

Dados de atividade

O que foi feito? Combustível queimado, rebanho, terras desmatadas

2

Fatores de emissão

Quanto GEE por unidade de atividade? Fatores padrão do IPCC ou específicos do setor

3

Autodeclaração

As entidades enviam inventários aos órgãos reguladores ou a padrões voluntários (GHG Protocol)

4

Verificação e auditoria

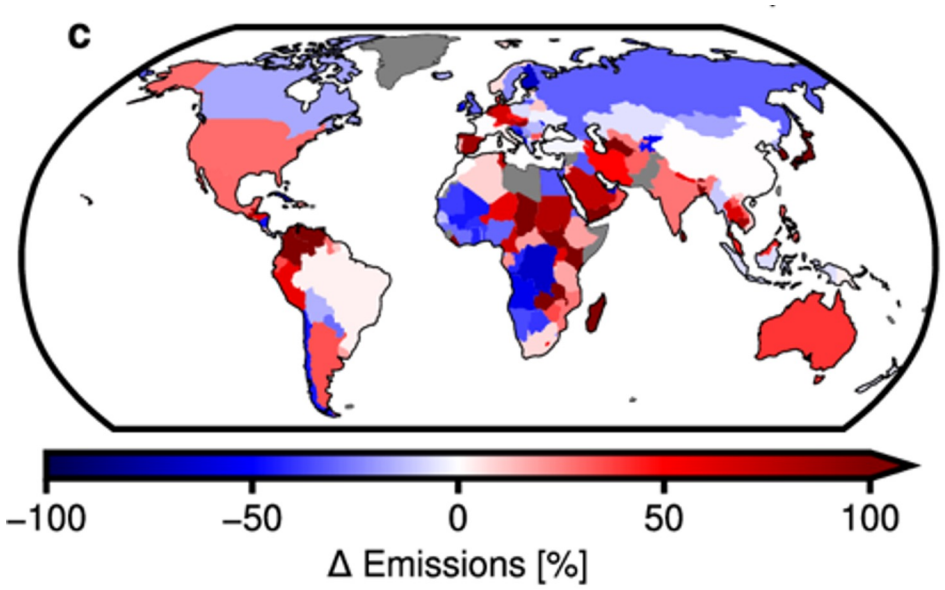
Verificação por terceiros; checagens pontuais; validação cruzada por satélite

Onde isso pode se complicar?

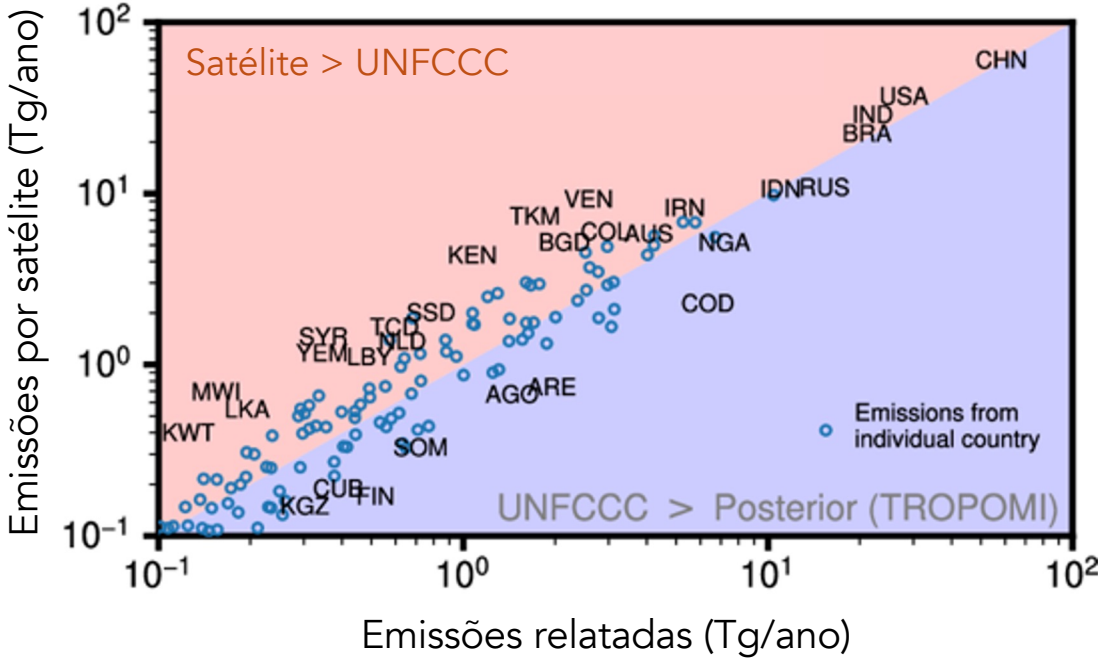
- Dados autodeclarados podem ter vieses por incentivos
- Os fatores de emissão podem não representar as condições locais
- A verificação consome muitos recursos e muitas vezes é incompleta.

Exemplo: estudo de satélite "top-down" comparado aos relatos de CH4 ao IPCC/à UNFCCC

Diferença relativa entre satélite e relatórios à UNFCCC



Satélite versus relatórios à UNFCCC



Fonte: East et al. (2025)

Perguntas para a turma

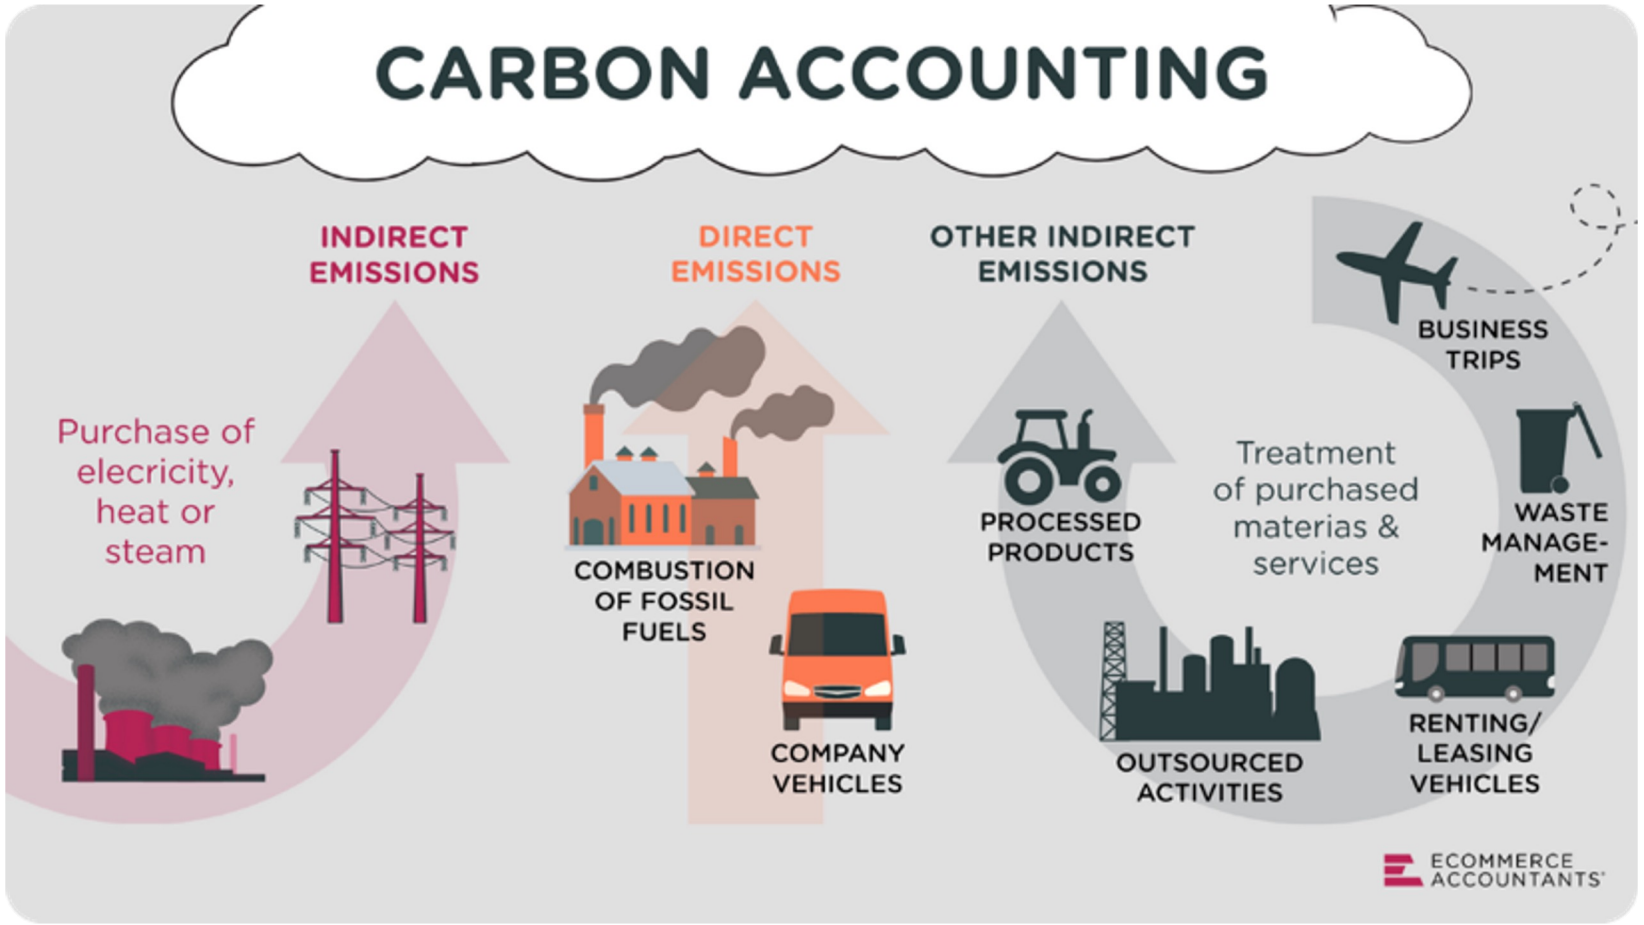
- Daqui a pouco vamos aprofundar os métodos “top-down” (baseados em medições atmosféricas) de contabilidade de carbono. Mas, com base no que você sabe e já viu sobre medições top-down e bottom-up

    - Enquete ao vivo: em qual você tende a confiar mais? Por quê?
        - Vote: em que você confia mais, top-down ou bottom-up?

    - Como você construiria confiança em um método, ou em ambos?

    - Quão bom é “bom o suficiente”?

Panorama rápido de outros usos da contabilidade de carbono: contabilidade de carbono corporativa



Contabilidade:

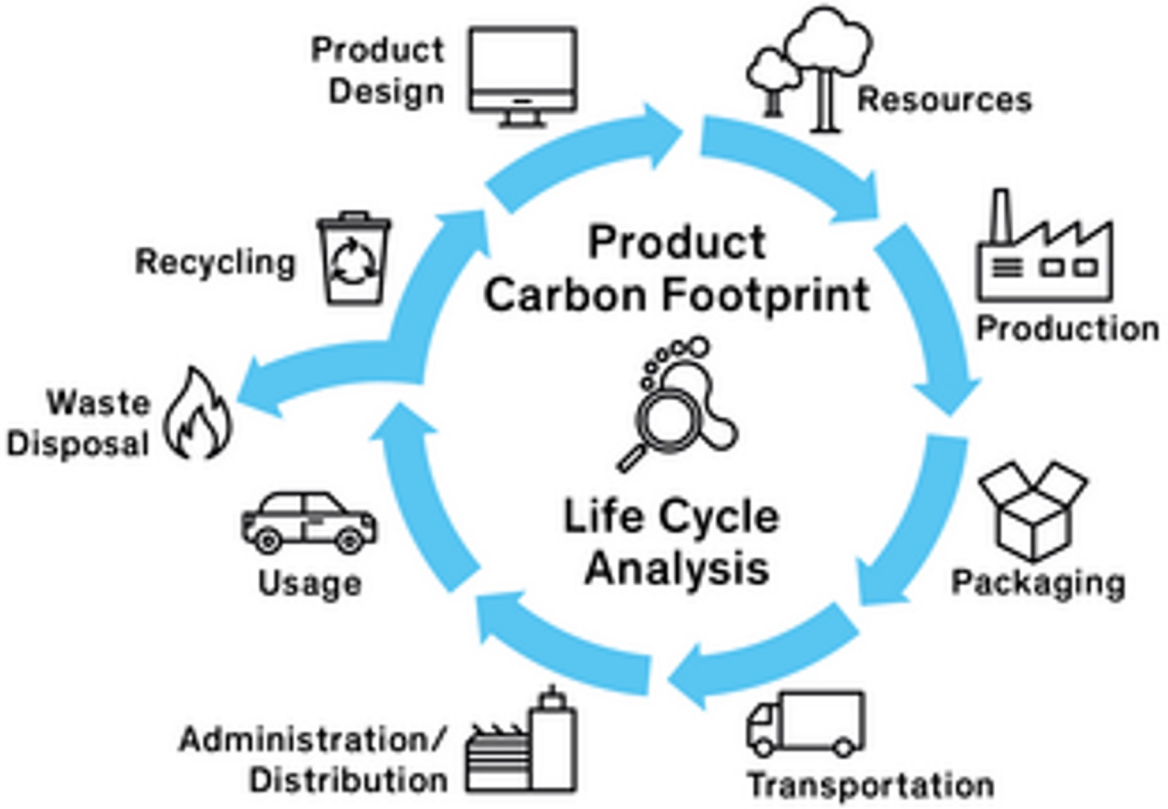
- Quantificação de todas as fontes de emissão, diretas e indiretas

Mercados:

- Compra de créditos ou permissões de emissão se/quando as emissões forem excessivas:
  - Comércio de emissões (conformidade): compra de emissões "excedentes" de uma entidade de baixa emissão
  - Créditos de carbono (voluntários): compra de créditos de projetos verificados que removem ou mitigam emissões

Fonte: ecommerceaccountants.co.uk

Avaliação do ciclo de vida: detalhando o carbono de cada produto ou processo



Em geral, segue procedimentos padronizados (p. ex., ISO 14040 e 14044) para contabilizar todos os materiais, a energia e a água usados em um produto/processo

Possíveis aplicações de IA:

- Extração automatizada de dados
- Modelagem preditiva (p. ex., se faltarem dados de fornecedores)
- Modelagem preditiva dos possíveis ganhos de carbono se partes do processo forem atualizadas
- Escalonamento para todos os produtos/processos de um portfólio (e não só os produtos principais)

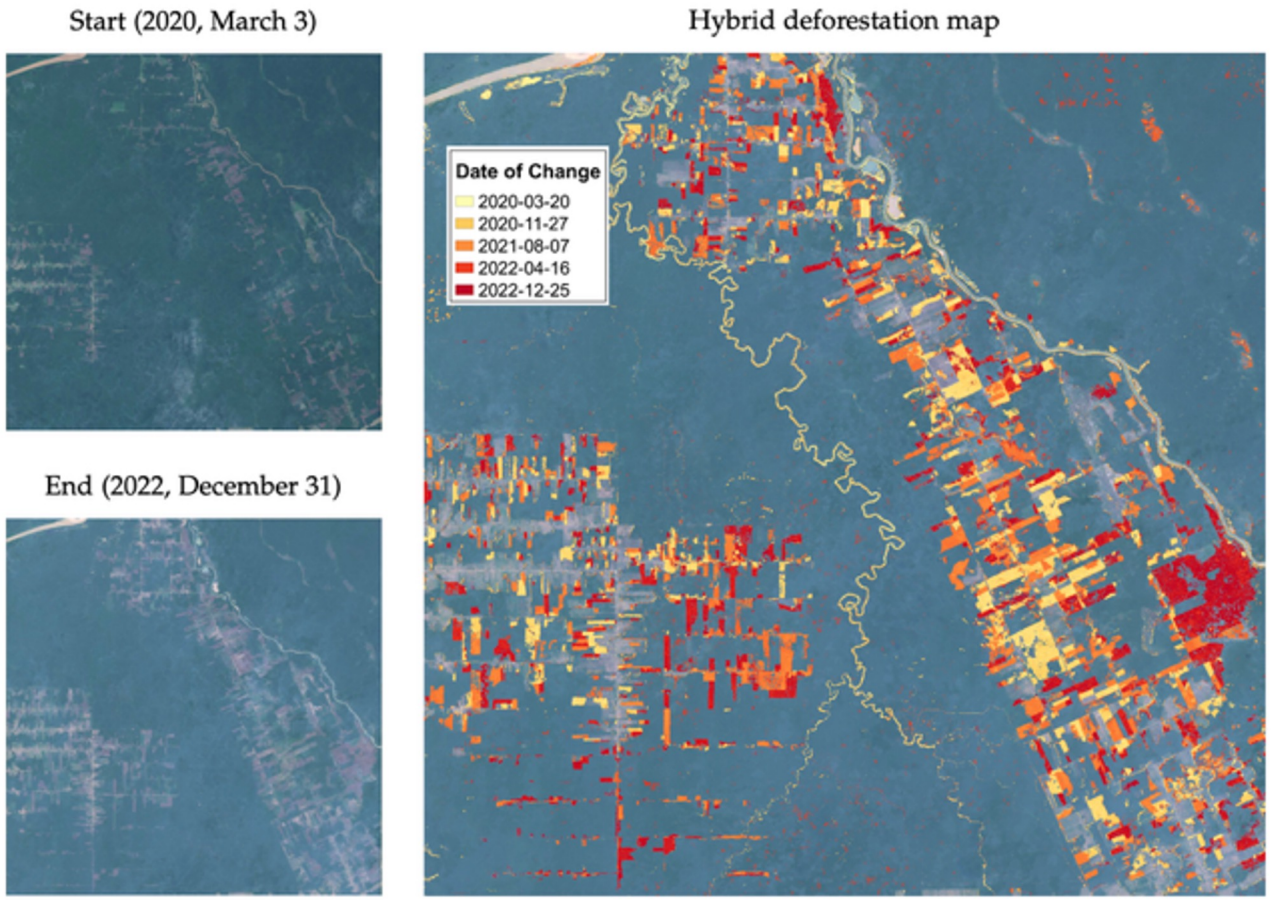
Fonte: myclimate.org

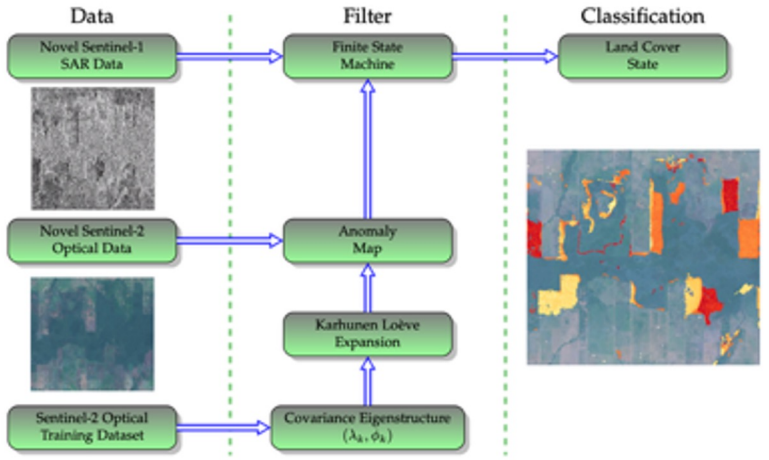
Parte 2 Sensoriamento remoto para a contabilidade de carbono

De volta à quantificação de emissões: o papel do sensoriamento remoto por satélite

Dados de atividade: uso de imagens de alta resolução (visível, infravermelho, radar) para identificar equipamentos, processos e mudanças

Exemplo: combinação de visível (RGB) e radar de abertura sintética (SAR) para acompanhar o desmatamento





Fonte: Castrillon-Candas et al. 2026: https://arxiv.org/pdf/2510.14092´

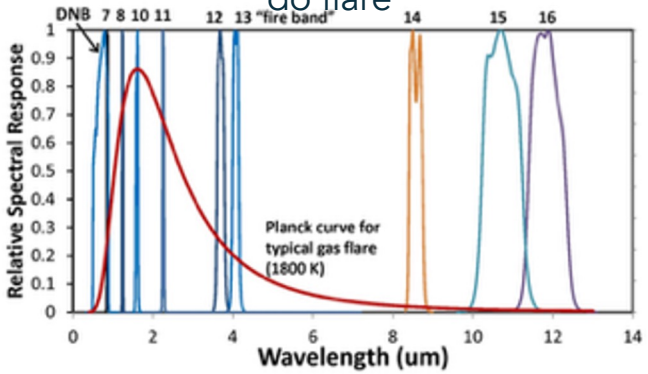
De volta à quantificação de emissões: o papel do sensoriamento remoto por satélite

Dados de atividade: detecção de combustão térmica em setores naturais e antrópicos

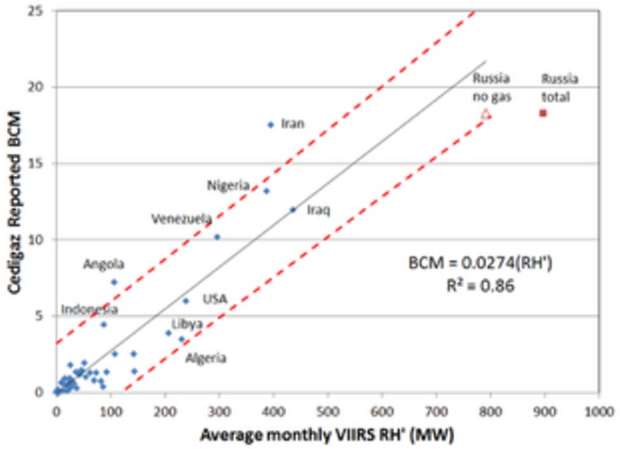
Queima de gás em flare (satélite VIIRS)



Ajustar uma curva de Planck ao espectro observado para estimar o calor do flare



Relacionar a assinatura térmica ao volume de gás queimado

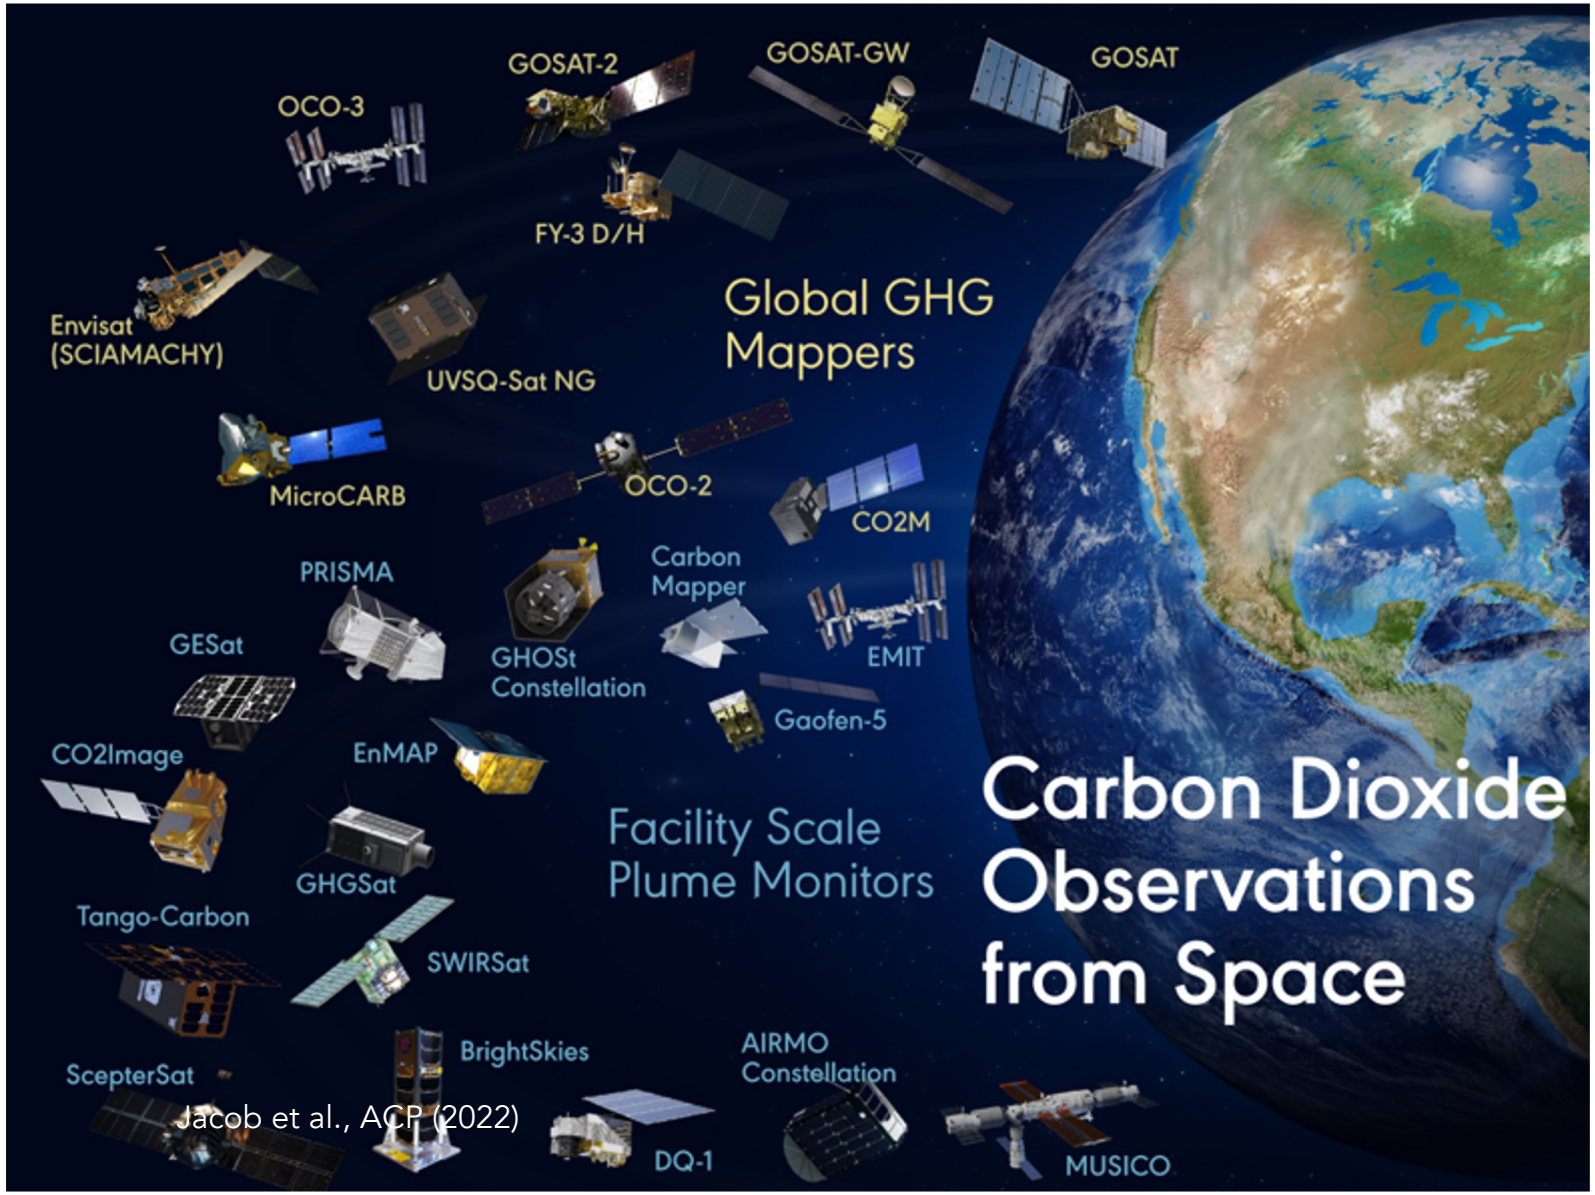


Incêndios (satélite VIIRS)



Fonte: Elvidge et al. (2016), NASA Worldview

De volta à quantificação de emissões: o papel do sensoriamento remoto por satélite



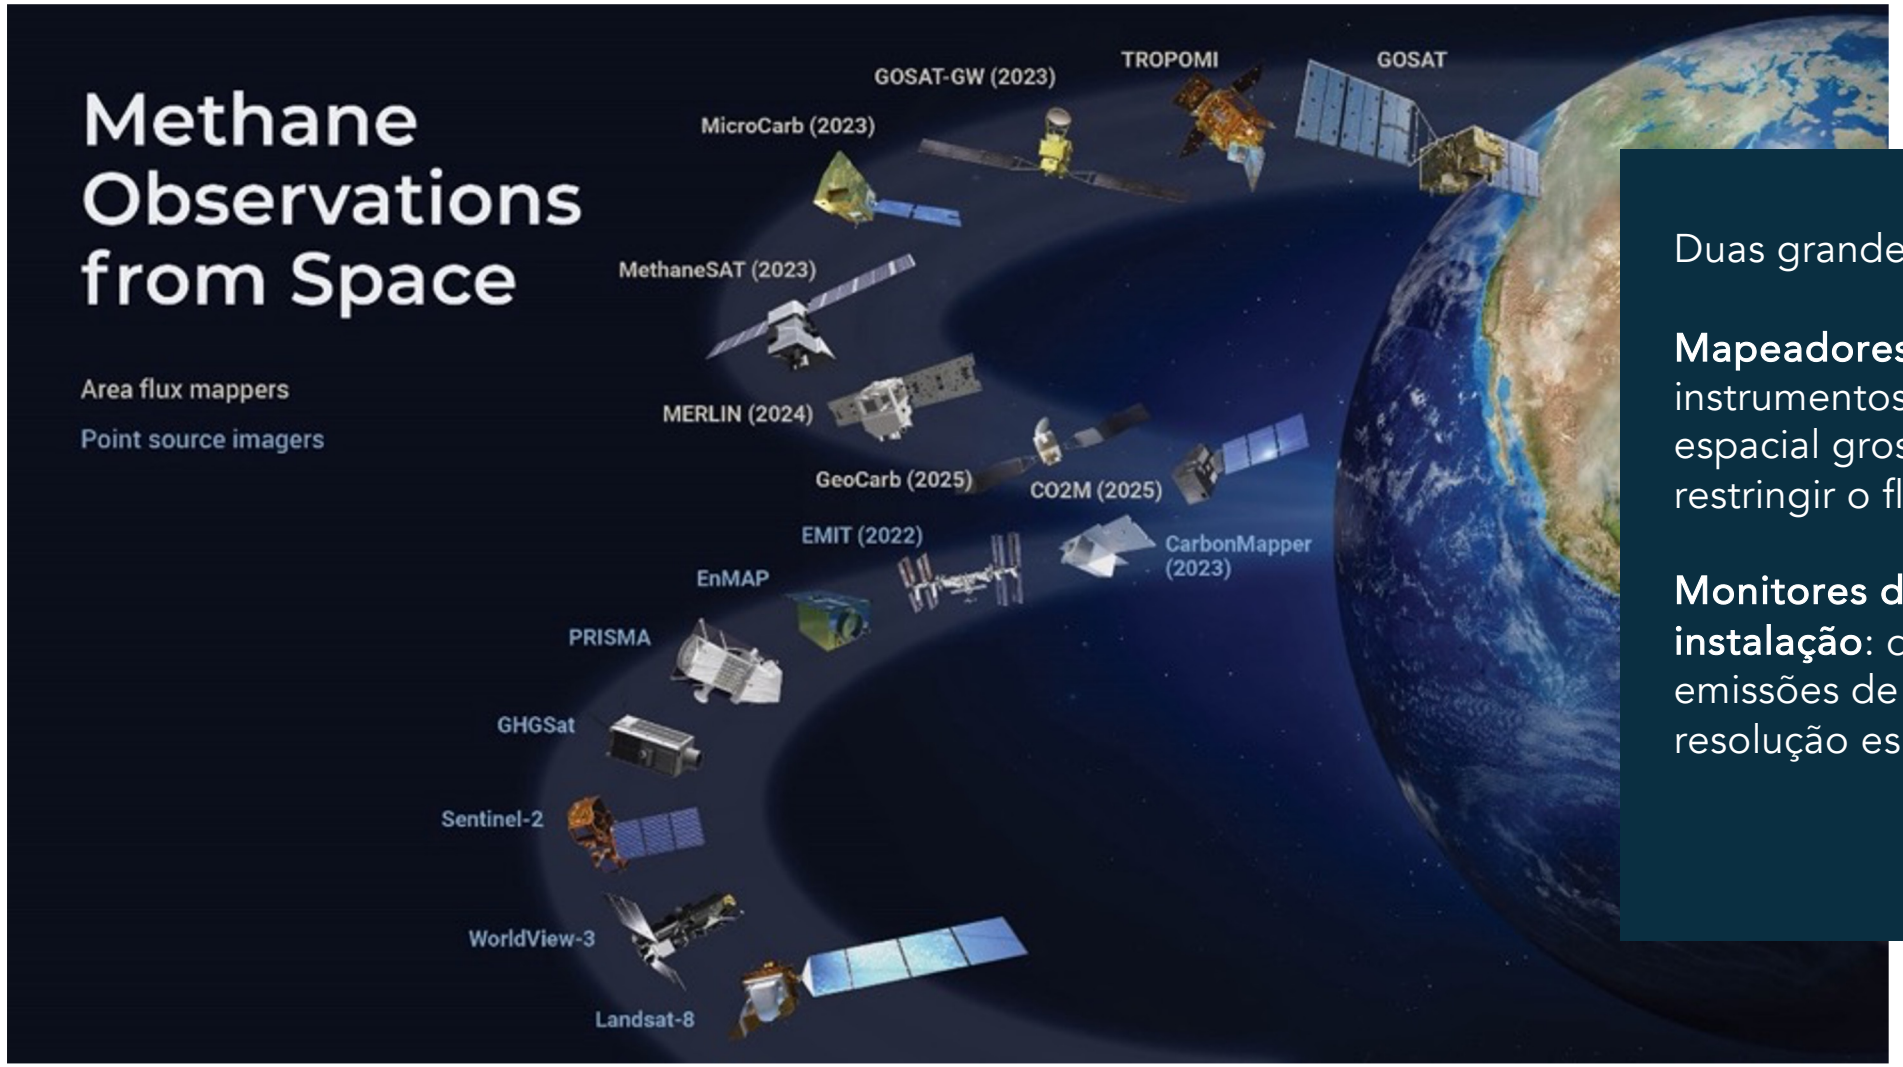
Jacob et al., ACP (2022)

Duas grandes categorias:

Mapeadores globais de GEE: instrumentos de faixa ampla e resolução espacial grosseira, projetados para restringir o fluxo líquido regional a global.

Monitores de plumas em escala de instalação: detecção e quantificação de emissões de superemissores com resolução espacial fina

De volta à quantificação de emissões: o papel do sensoriamento remoto por satélite



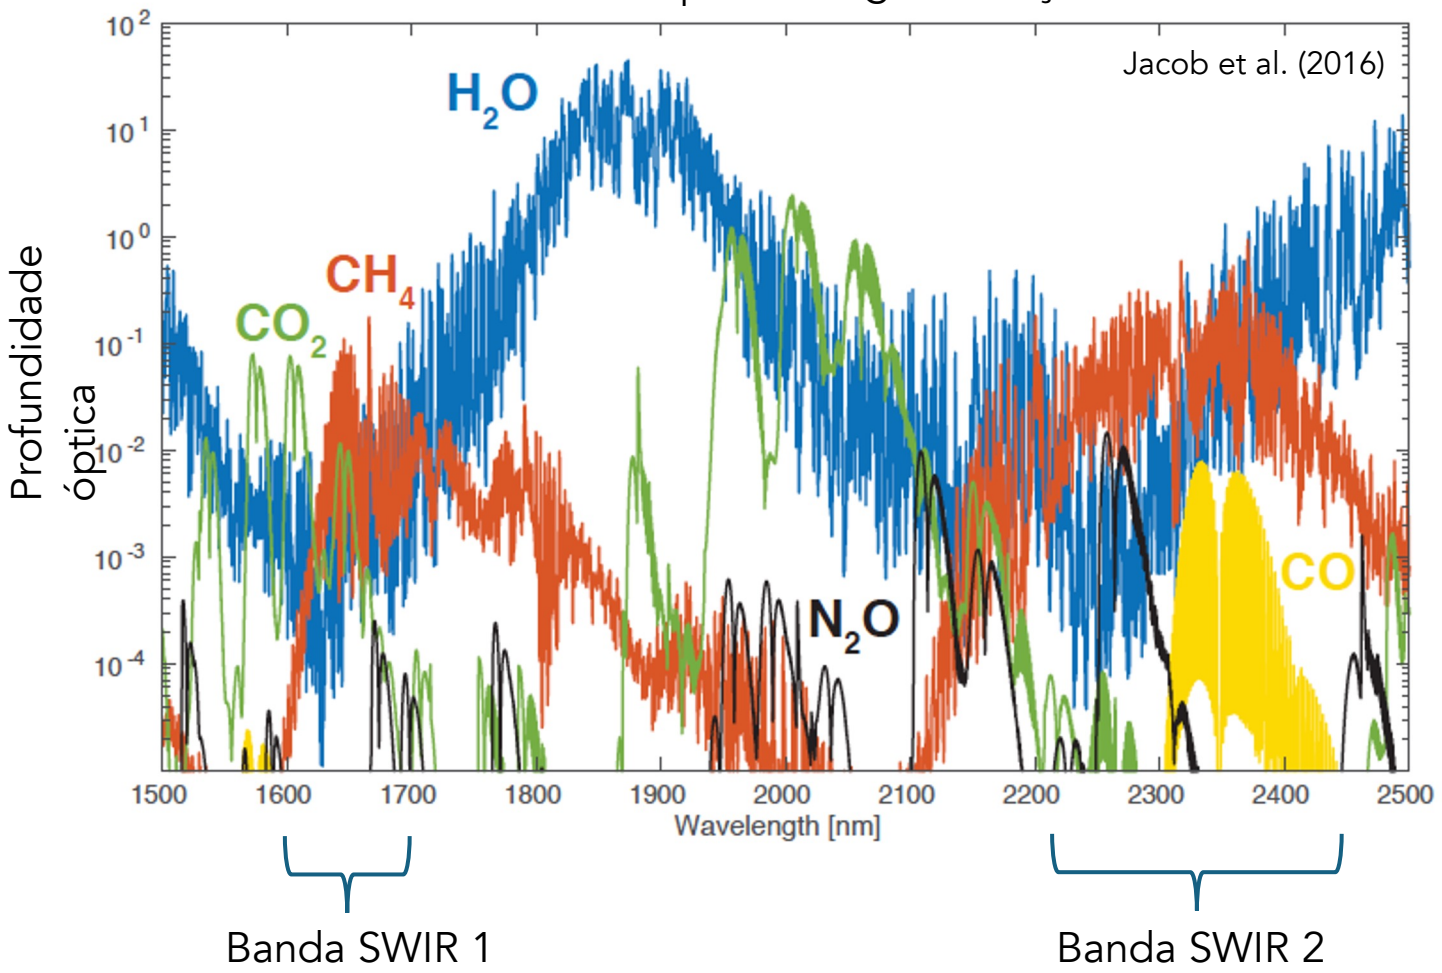
Duas grandes categorias:

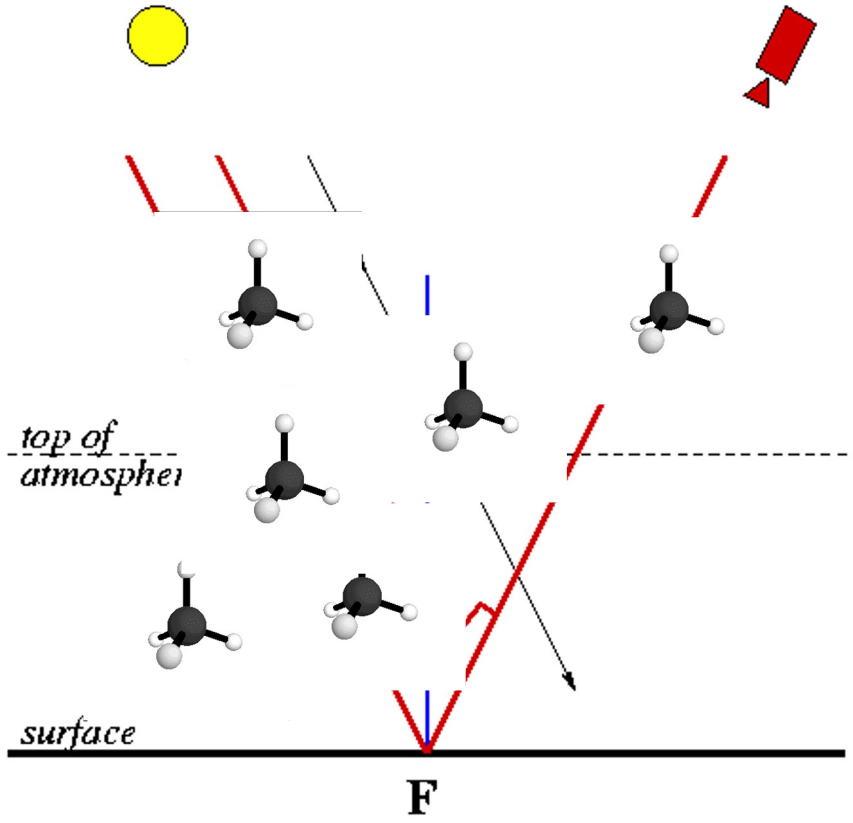
Mapeadores globais de GEE: instrumentos de faixa ampla e resolução espacial grosseira, projetados para restringir o fluxo líquido regional a global.

Monitores de plumas em escala de instalação: detecção e quantificação de emissões de superemissores com resolução espacial fina

O sensoriamento remoto de CH4 baseia-se na observação da radiância perto das feições de absorção rovibracionais do CH4.

Profundidades ópticas de gases traço atmosféricos





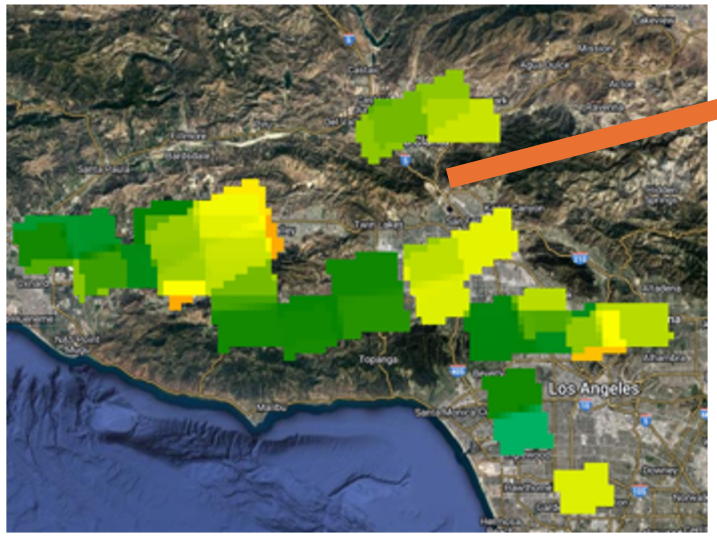
Transmitância atmosférica:

$$T = \frac{\Phi_e^t}{\Phi_e^i} = e^{-\tau} = 10^{-A}$$

Profundidade óptica (depende da absorção do gás)

A separação entre mapeador global de GEE e monitor em escala de instalação é determinada pelo compromisso entre resolução espacial e espectral.

TROPOMI sobre Los Angeles/Aliso Canyon (15/09/2020)

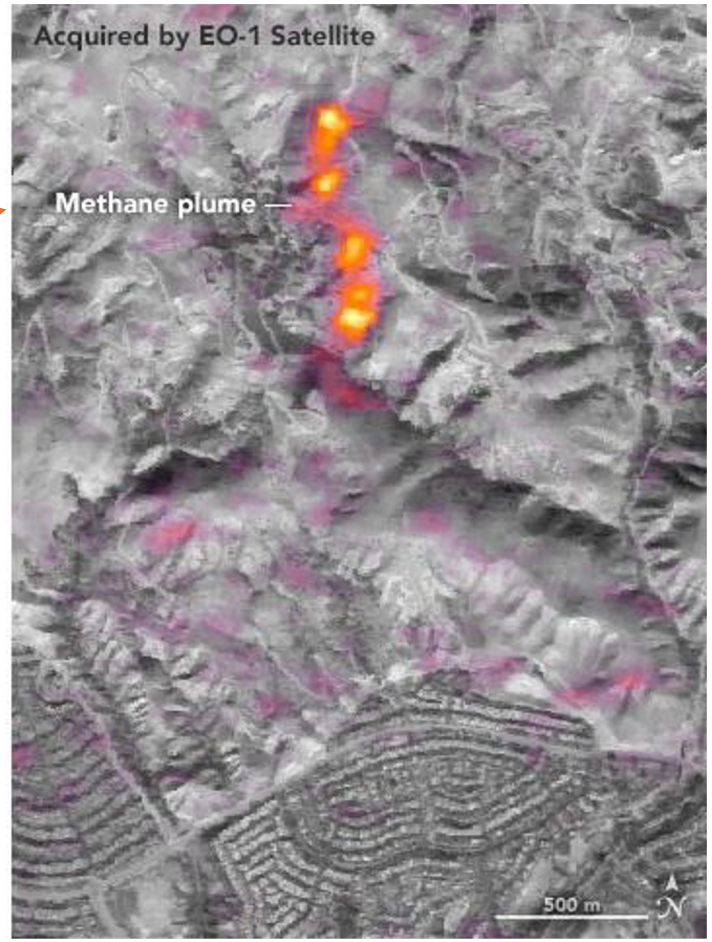


Google Earth Engine





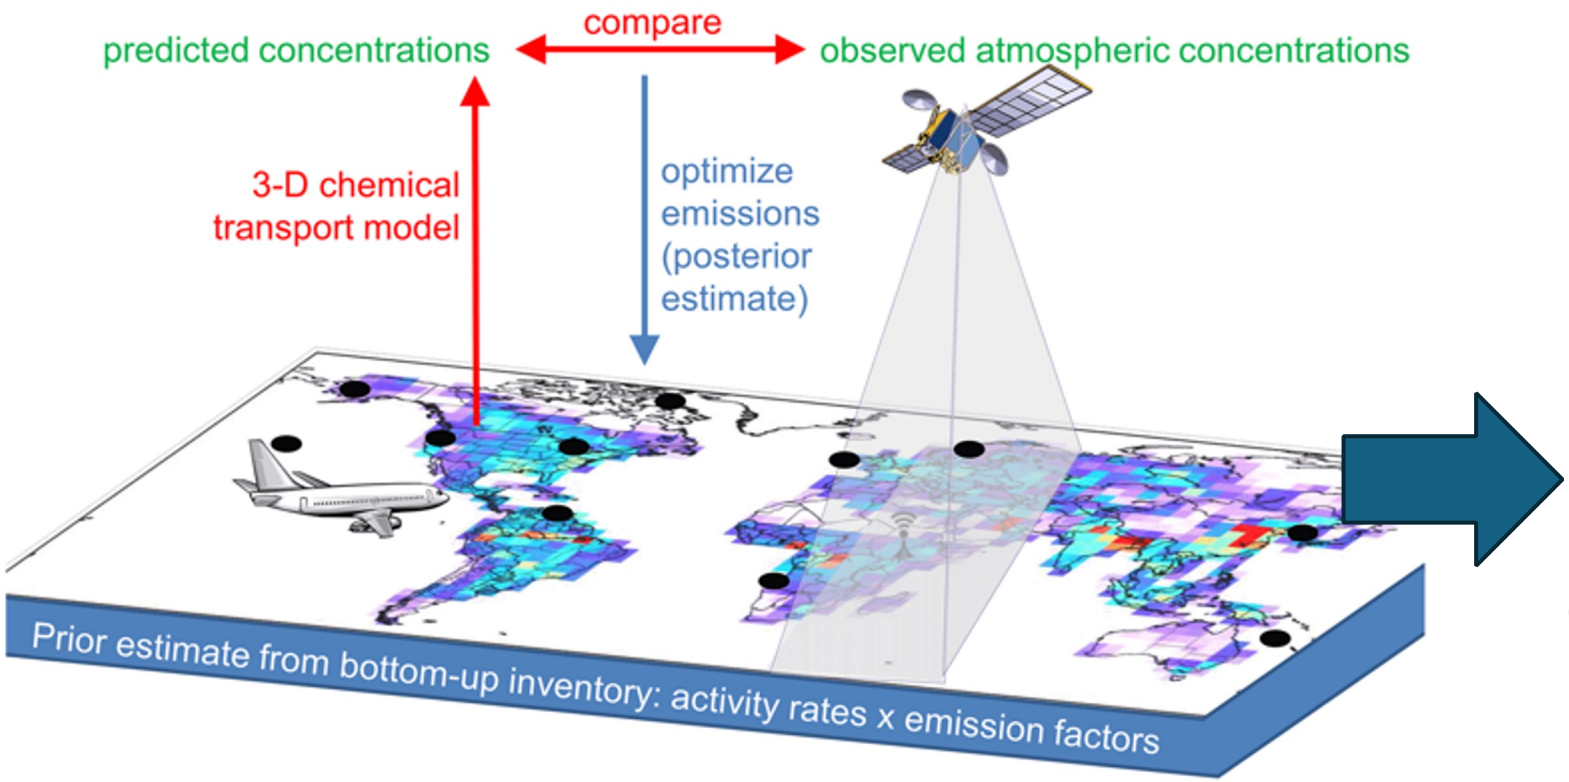
Instrumento Hyperion do EO-1: vazamento de Aliso Canyon (2016)

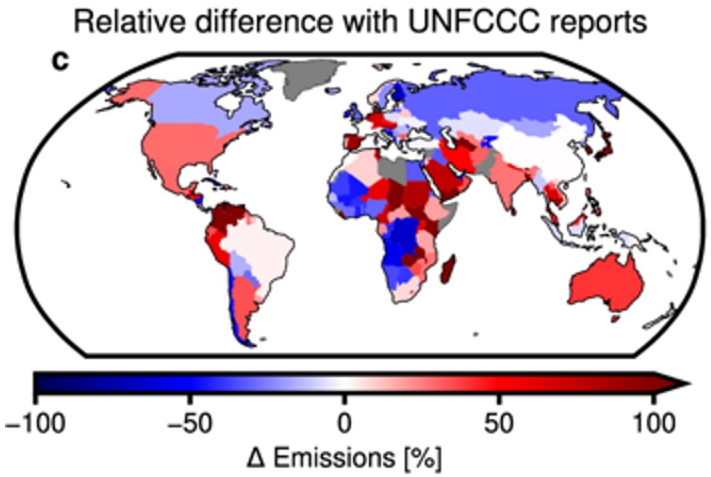


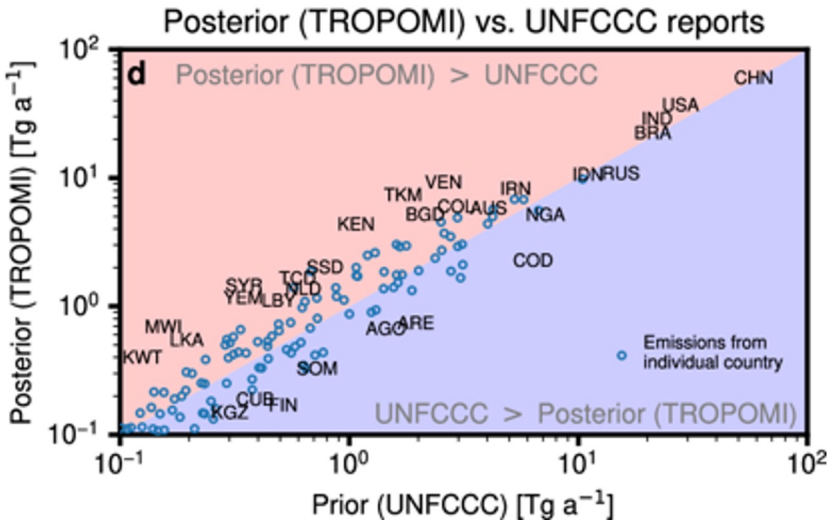
Thompson et al., GRL (2016)

Resolução espectral mais grosseira -> resolução espacial mais fina. Capacidade de resolver grandes plumas em escala de instalação.

Satélites de mapeamento global de GEE estimam emissões regionais "invertendo" as concentrações atmosféricas observadas em fluxos de emissão





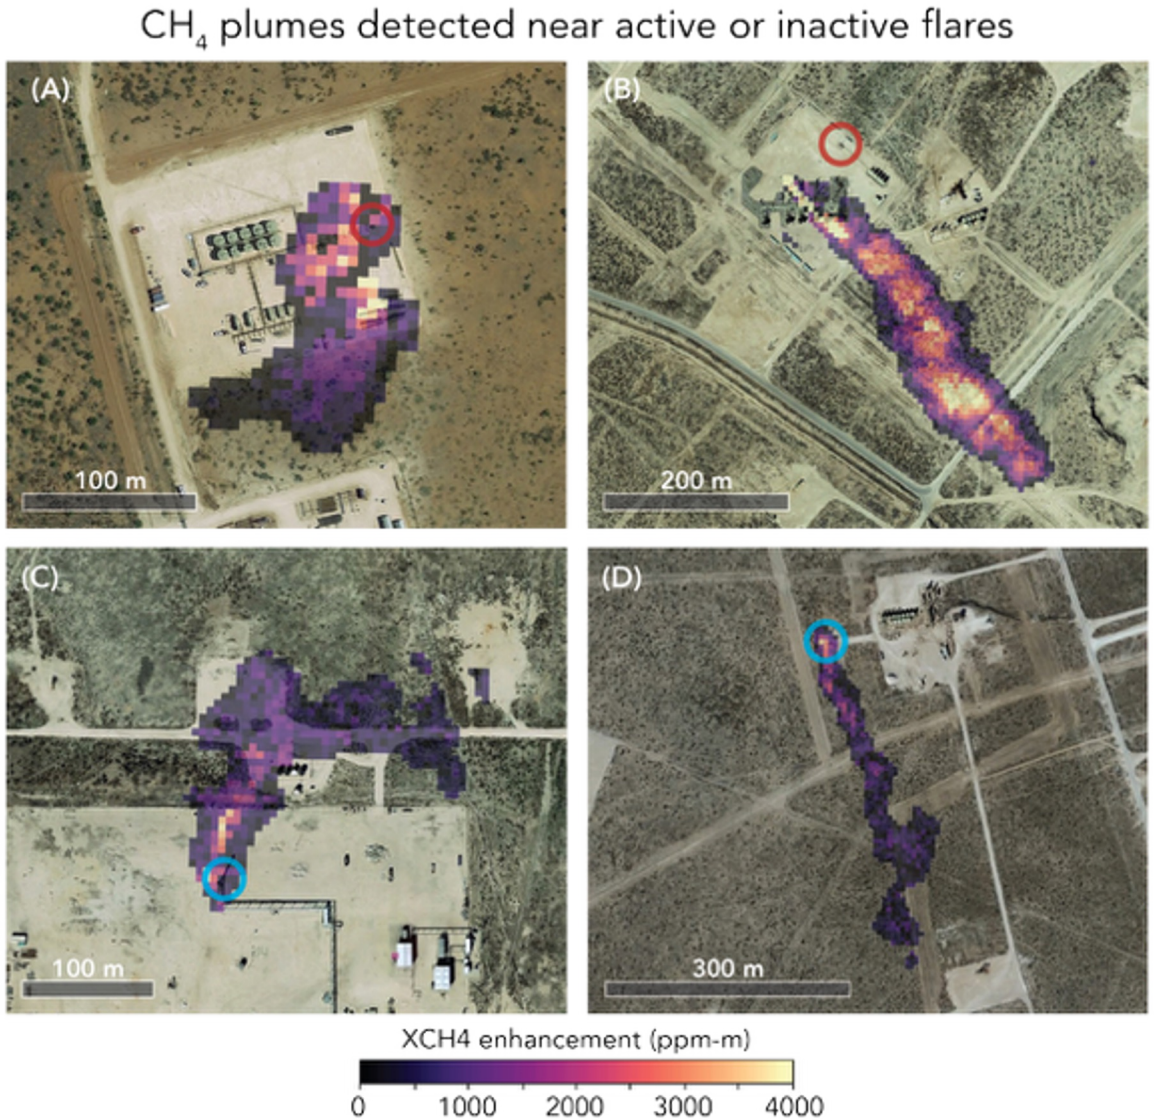


$$\hat{\mathbf{x}} = \arg\min \left\{ \|\boldsymbol{y} - \mathbf{H}\boldsymbol{x}\|_{S_o} + \|\boldsymbol{x} - \boldsymbol{x}_A\|_{S_A} \right\}$$

Aqui, **x** representa as emissões, **y** as concentrações e **H** um modelo de transporte.

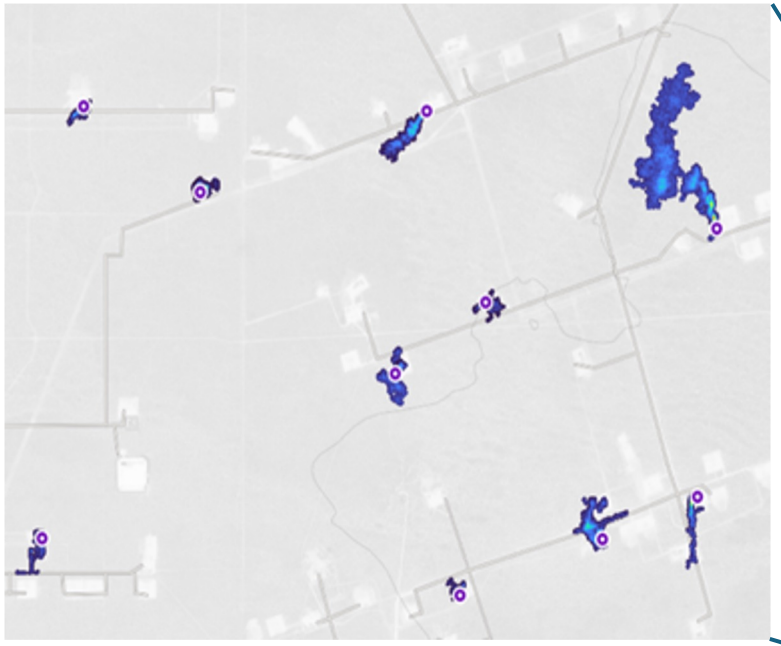
Worden et al., ACP (2022); East et al. (2025)

Satélites em escala de instalação detectam apenas uma fração das fontes, mas permitem atribuir as emissões a cada instalação

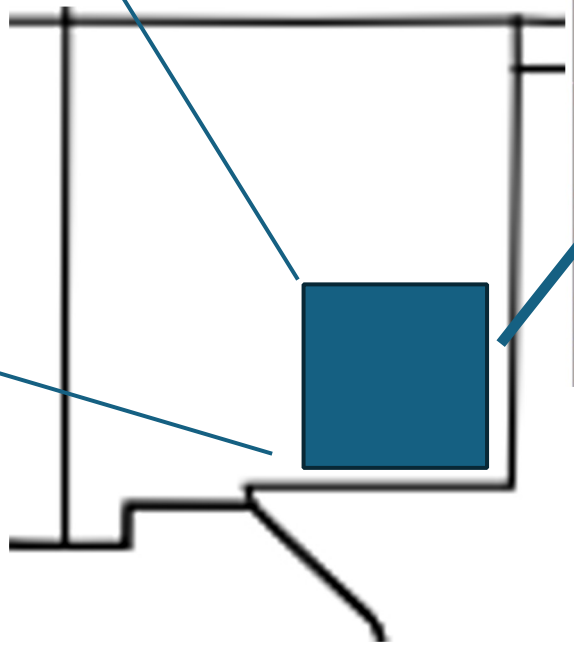


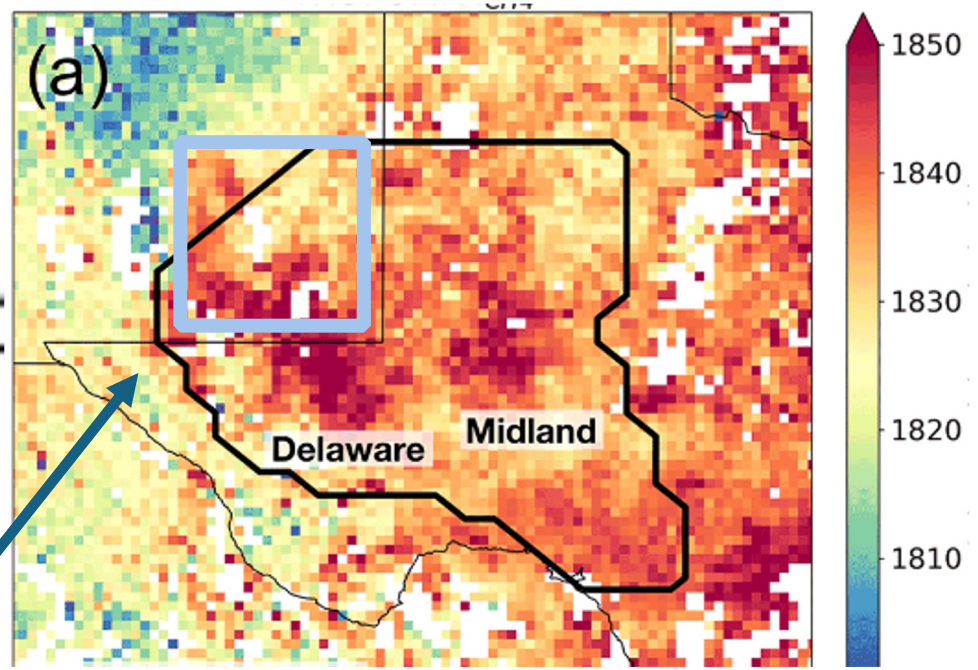
Entendendo as emissões em escala de bacia:
fluxo total, superemissores, conjuntos de dados atribuídos

Estudo aéreo + por satélite de 2024 no Permiano do Novo México



Mapeamento aéreo completo de toda a infraestrutura do Permiano do Novo México: mais de 200 mil visitas a locais em 3 semanas

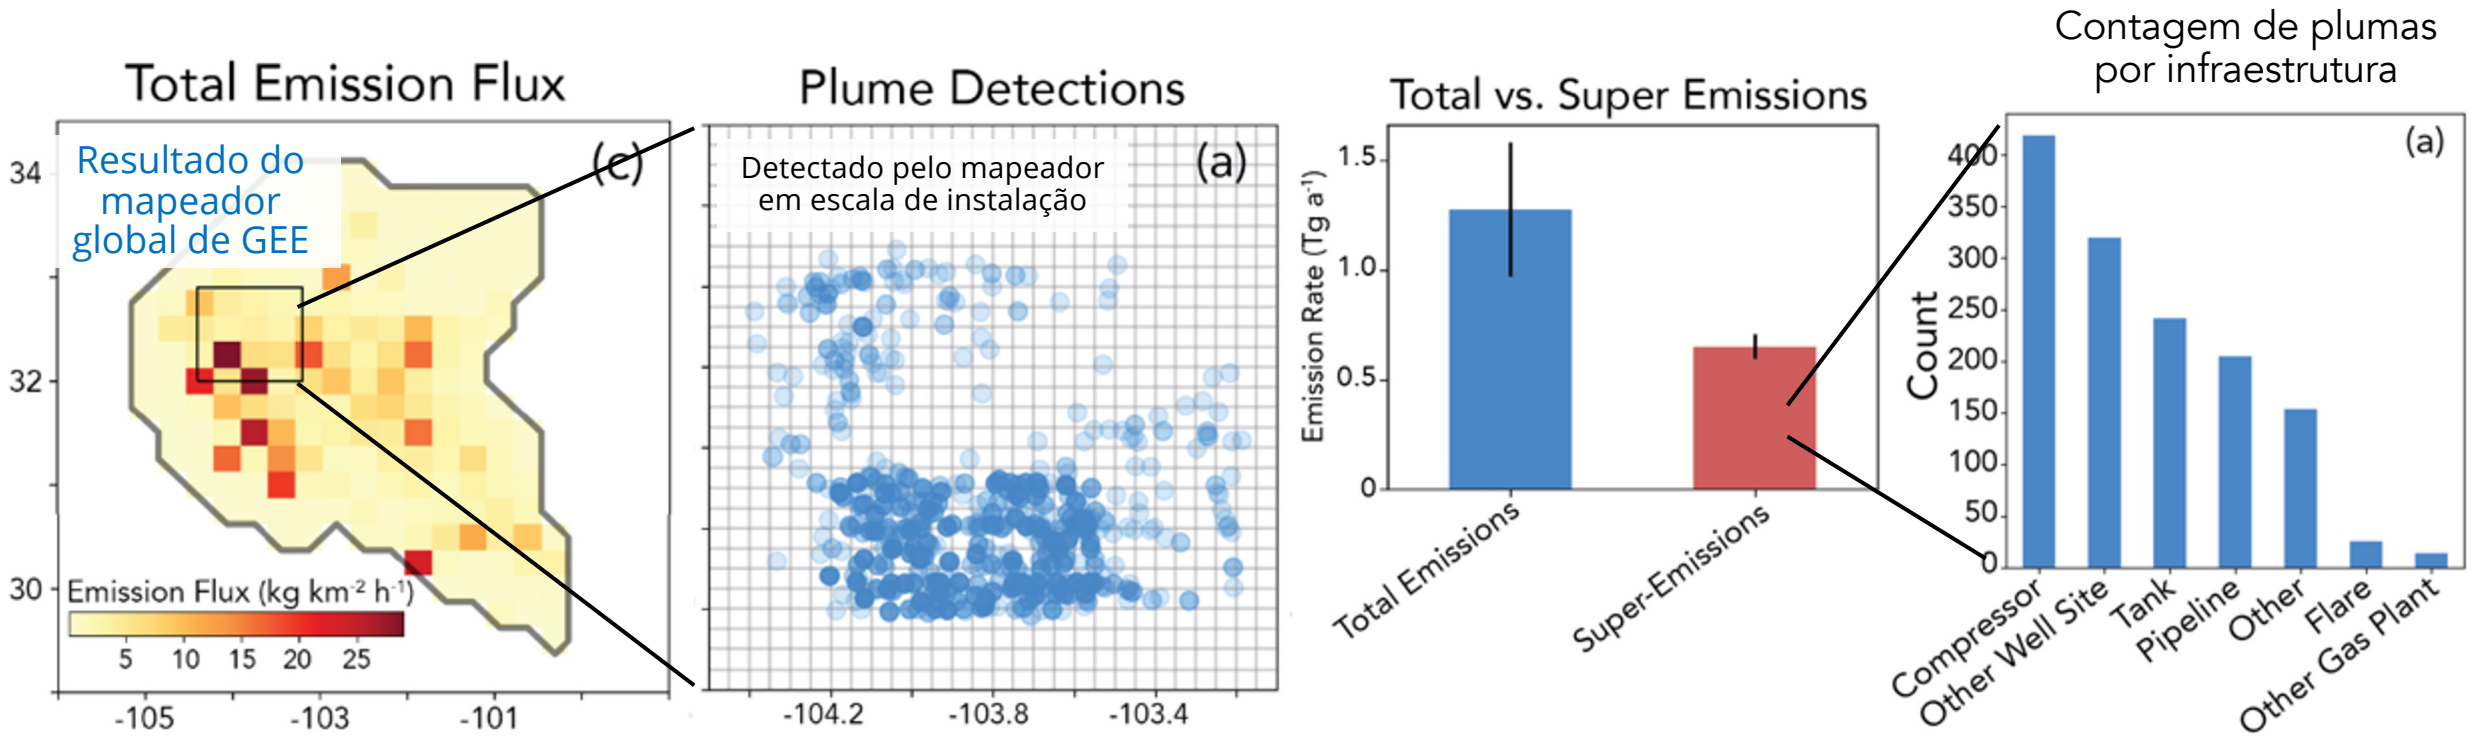




Estimativa do fluxo da bacia com observações do satélite TROPOMI

Entendendo as emissões em escala de bacia:
fluxo total, superemissores, conjuntos de dados atribuídos

Estudo aéreo + por satélite de 2024 no Permiano do Novo México

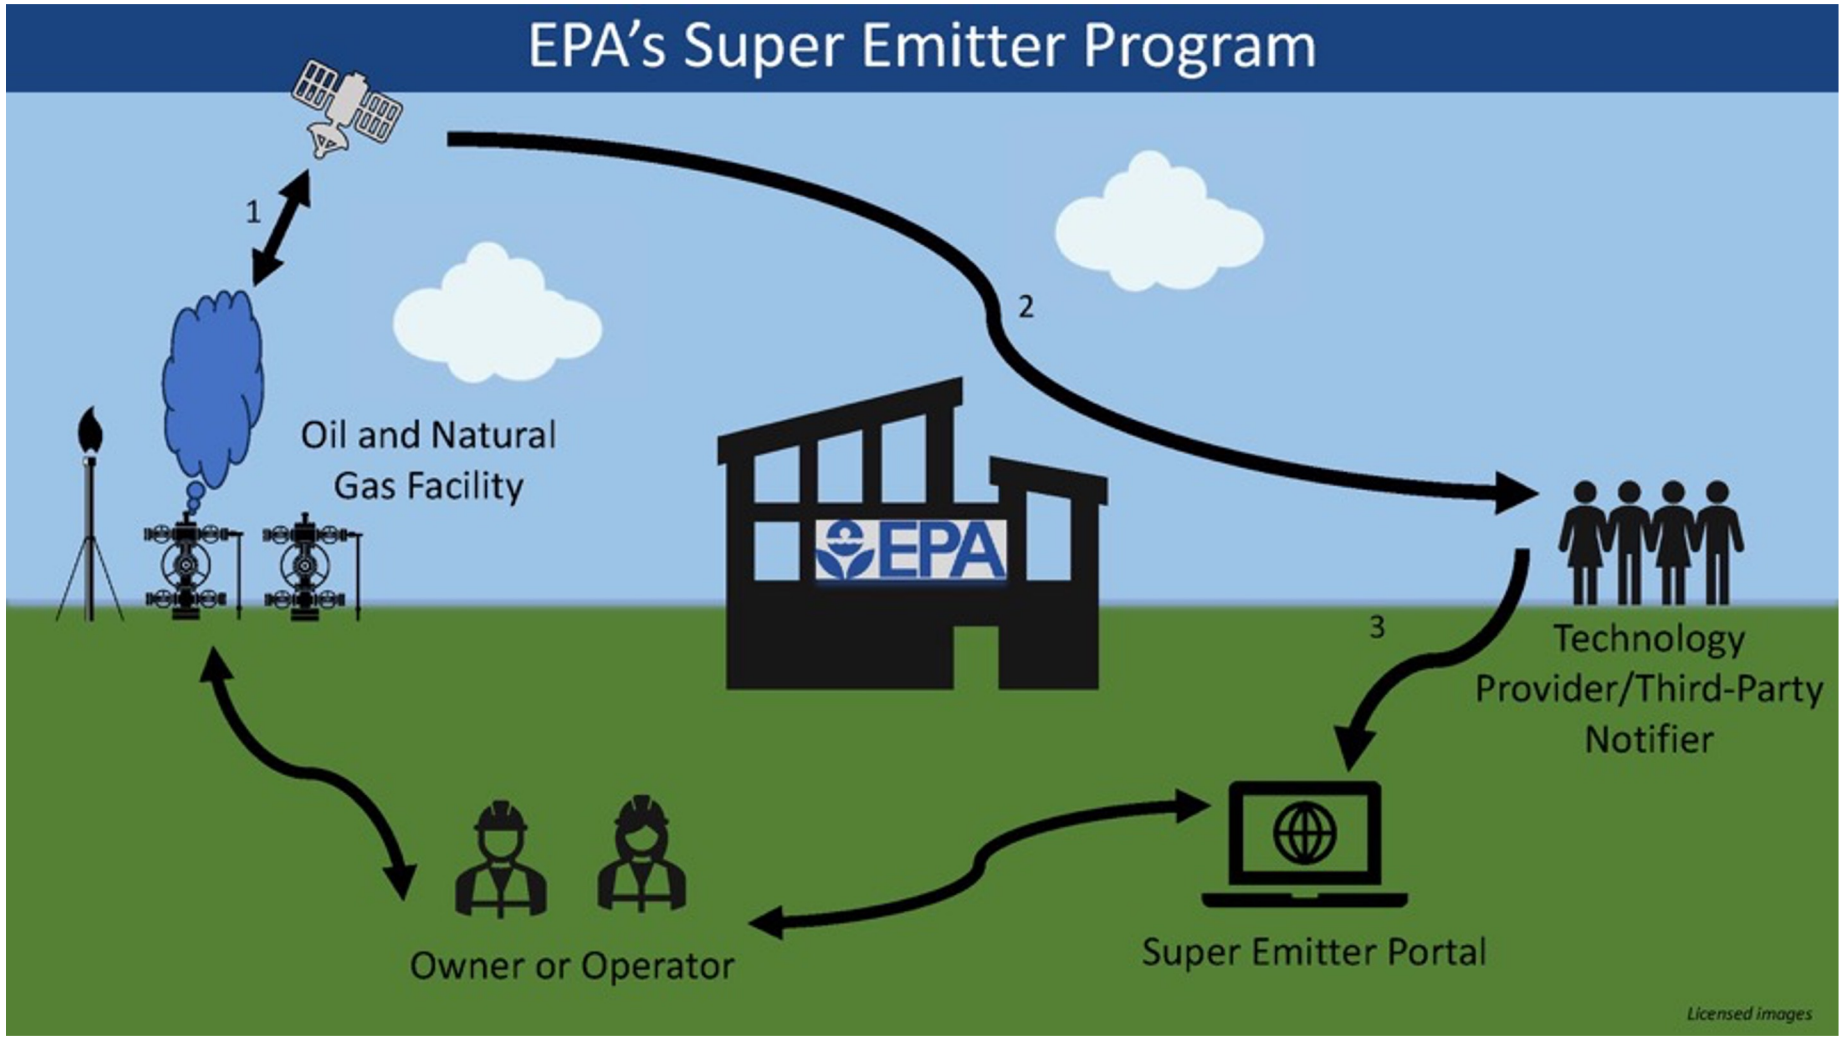


Cusworth et al. (em revisão)

Intensidade + infraestrutura + atribuição ao operador: um caminho para a mitigação

Cusworth et al. (2026)

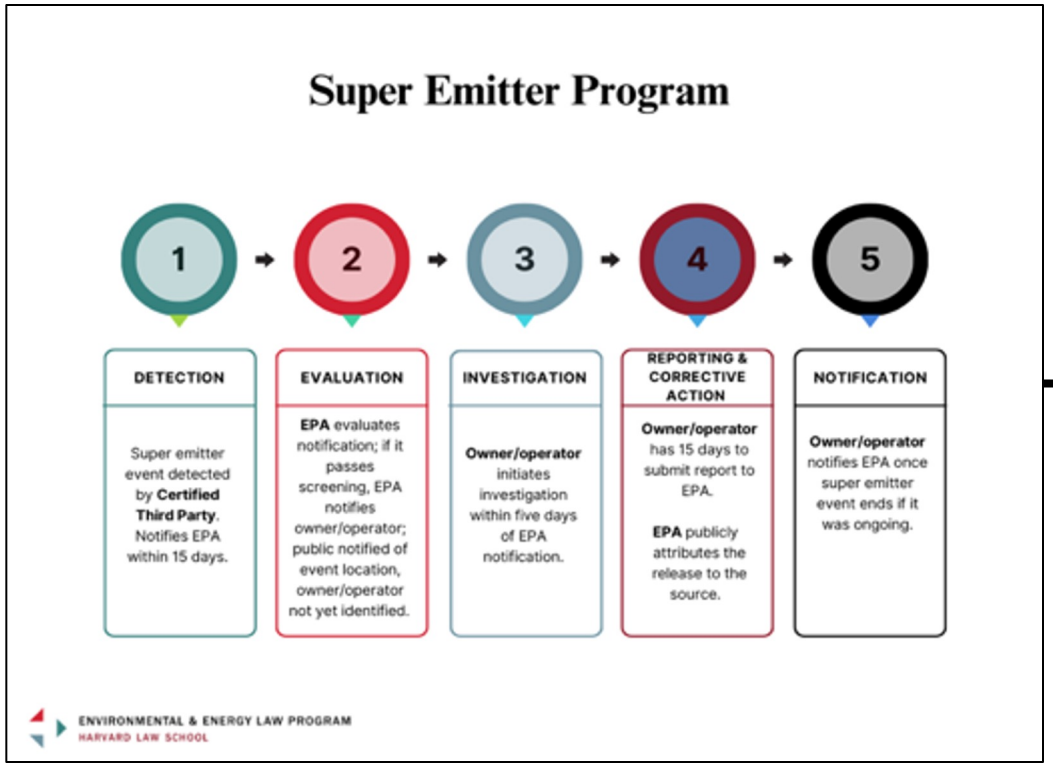
De volta aos programas de relato:



Nova regra nos EUA: detecções de superemissores por satélite feitas por terceiros podem ser relatadas à EPA (por relatores aprovados), exigindo resposta dos operadores

Fonte: epa.gov

Esperava-se que qualquer detecção de superemissor fosse então relatada pelos operadores no programa obrigatório de relato (Greenhouse Gas Reporting Program)



Anualmente: o operador deve relatar qualquer emissão > 100 kg/h independentemente da duração

Anualmente: os operadores pagam a taxa sobre emissões de resíduos acima de 1.000 tCH4/ano

EPA GHGRP (subparte W)* emissões totais de metano para qualquer operação acima de 1.000 tCH4/ano

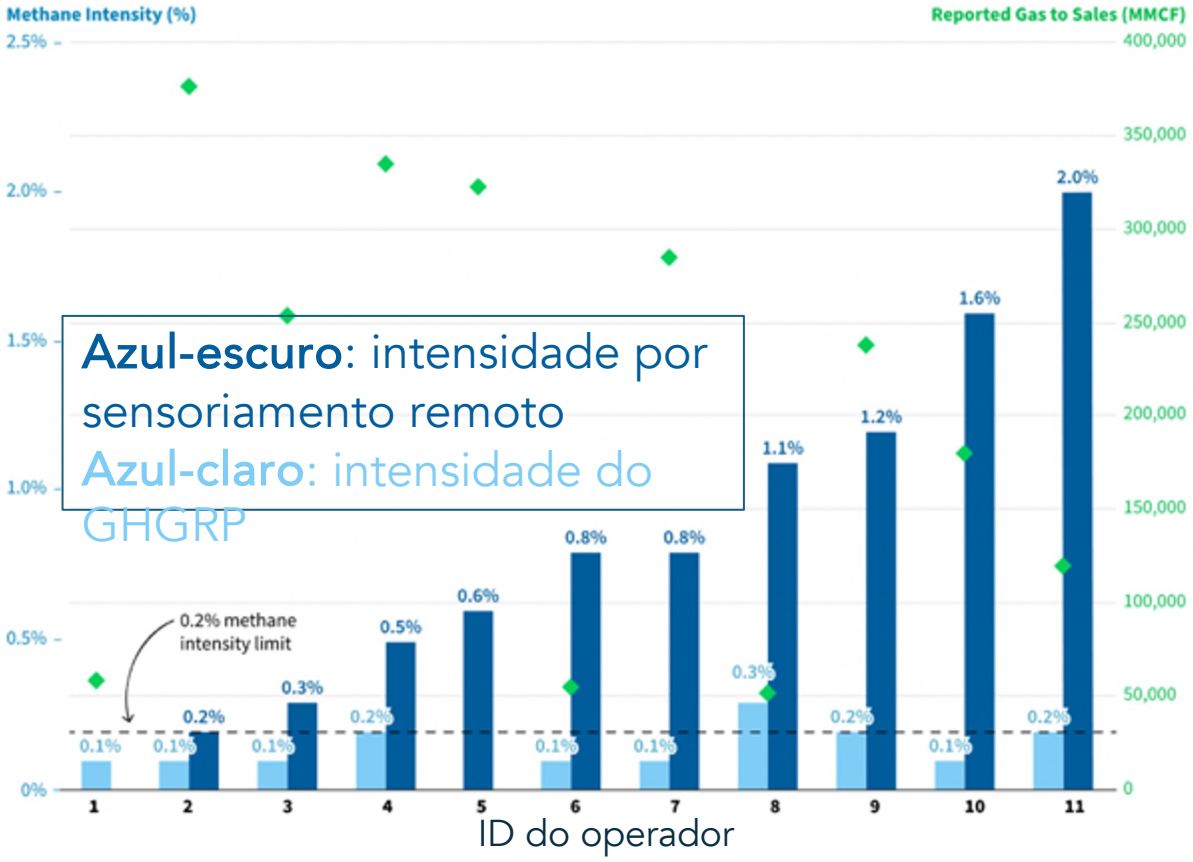
Programa de Redução de Emissões de Metano da IRA (MERP)*

Outras medições empíricas de metano (não superemissores) e/ou estimativas bottom-up

Outros relatos de detecção única de superemissores (p. ex., triagem LDAR do operador)

A Inflation Reduction Act (IRA) estabeleceu que toda emissão de desperdício resultaria em uma taxa (Waste Emissions Charge, WEC), calculada com base nos relatos ao GHGRP.

Intensidade observada por operador em campanhas aéreas comparada aos protocolos atuais do GHGRP



Azul-escuro: intensidade por sensoriamento remoto
Azul-claro: intensidade do GHGRP

Intensidade com base em Hmiel al. (2022)

Análise conservadora da subnotificação feita pelo RMI

Waste emissions charge difference: Super-emitter observations vs. reported emissions for the Permian Basin in 2020

Operator	**Reported to EPA:** Tax payments at $900/ton	**Aerial measurements:** Tax payments at $900/ton	**Cumulative difference** between tax payments
1	$0	$0	$0
2	$0	$0	$0
3	$0	$5,000,000	$5,000,000
4	$300,000	$16,000,000	$21,000,000
5	$0	$25,000,000	$45,000,000
6	$0	$6,000,000	$51,000,000
7	$0	$30,000,000	$81,000,000
8	$800,000	$8,000,000	$89,000,000
9	$0	$41,000,000	$130,000,000
10	$0	$42,000,000	$172,000,000
11	$900,000	$37,000,000	$208,000,000

Relevância para a IRA: a subnotificação não exposta nos EUA pode representar mais de US$ 800 milhões/ano em taxas não pagas

Intervalo

Discussão

Como poderíamos/deveríamos ancorar os resultados top-down em verdade de campo, padrões e validação?

Sua opinião sobre a confiabilidade da contabilidade top-down versus bottom-up mudou?

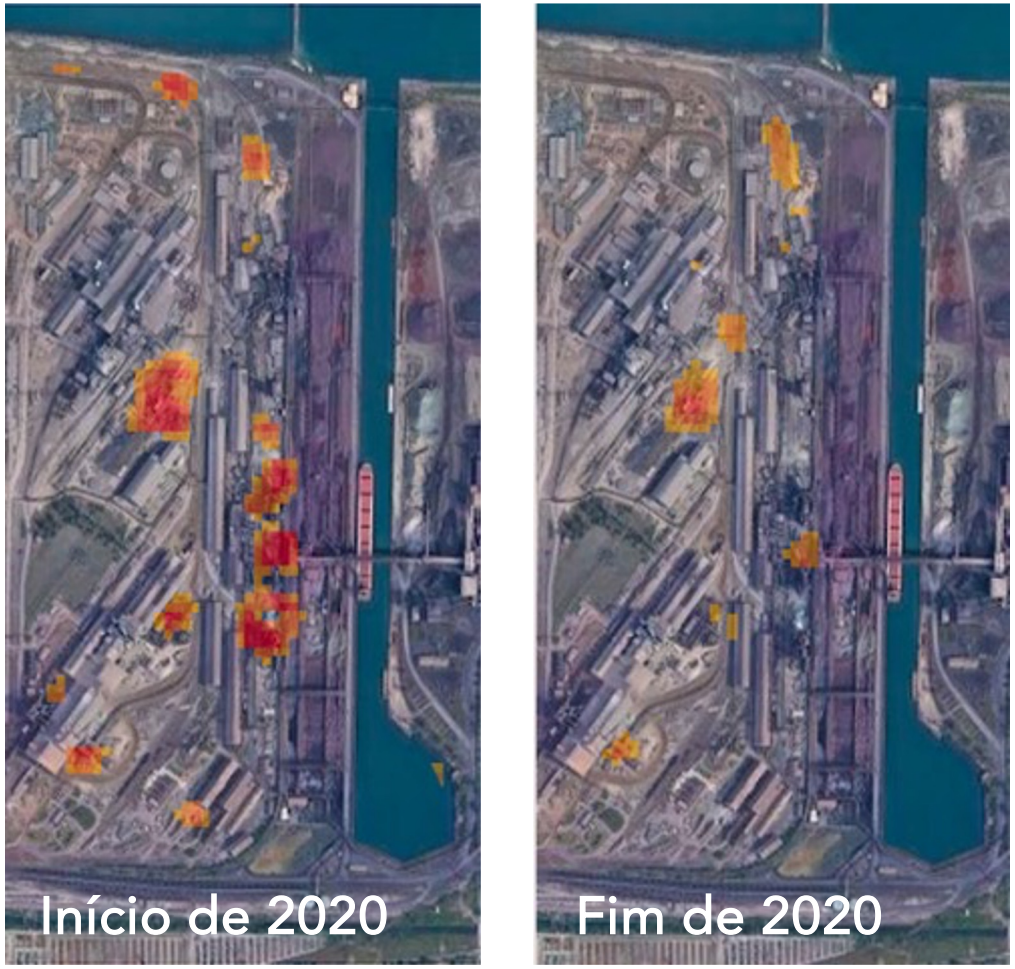
- Vote: em que você confia mais, top-down ou bottom-up?

Que tipos de experimentos você sugeriria/faria para aumentar a confiança nas estimativas top-down/por sensoriamento remoto?

Parte 3 Usando IA para melhorar a contabilidade de carbono

Dados de atividade: preenchendo lacunas de produção

Exemplo: siderúrgica Gary Works



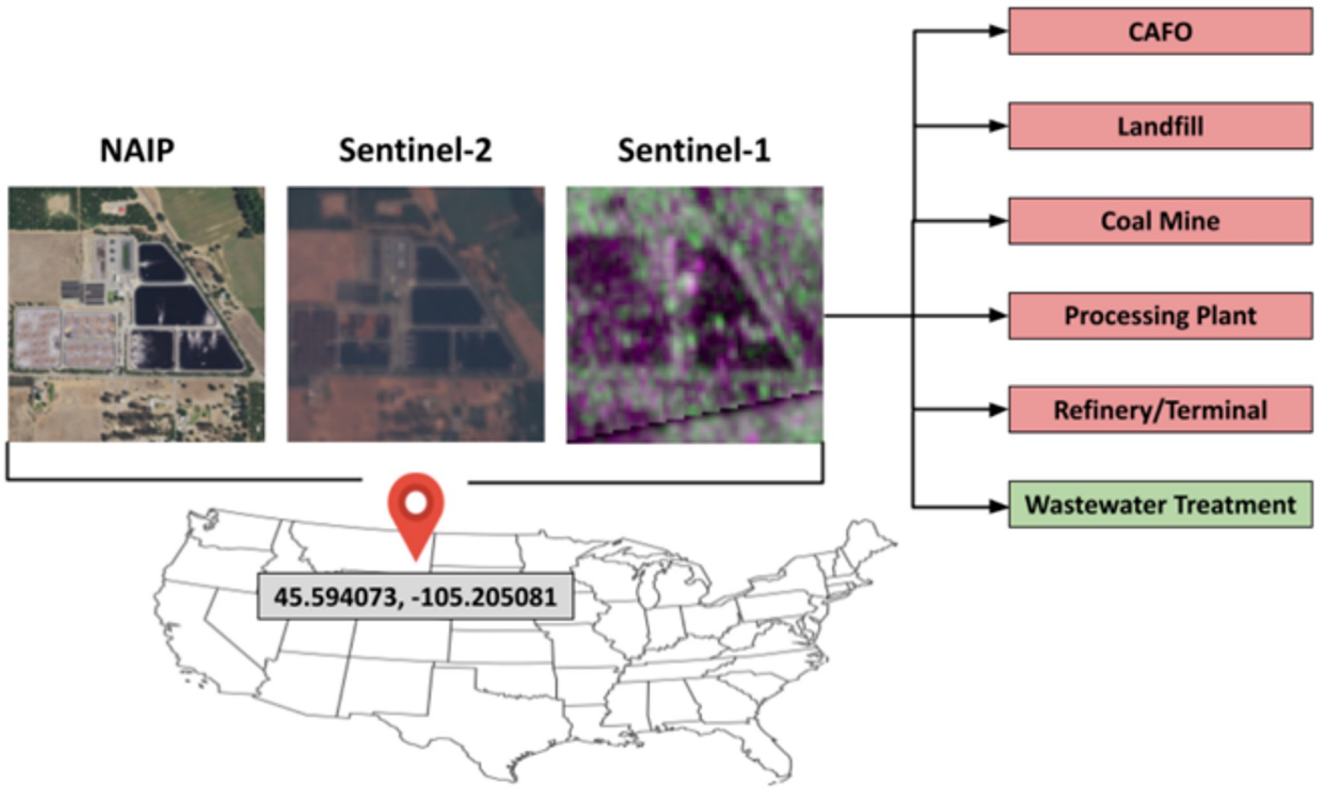
TransitionZERO

Centenas de siderúrgicas no mundo não relatam suas emissões.

Para criar uma base de emissões estimadas: treinar um modelo de aprendizado de máquina com assinaturas térmicas detectadas nas bandas infravermelhas do Landsat-8 e do Sentinel-2.

Fonte: TransitionZERO; Climate TRACE

Dados de atividade: detecção de objetos

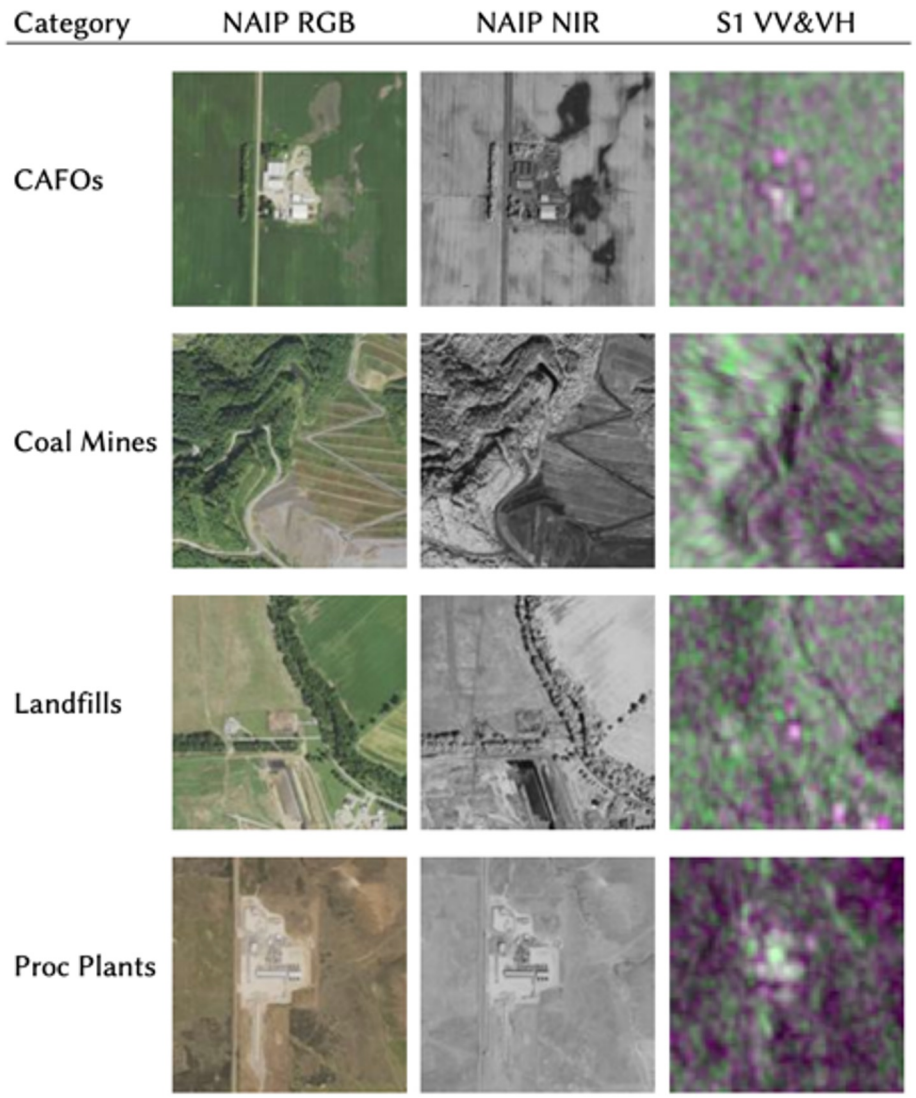


MEthane Tracking Emissions Reference (METER)

Objetivo: construir uma base completa de infraestruturas antrópicas emissoras de metano usando diversas imagens de satélite.

Fonte: METER-ML

Dados de atividade: detecção de objetos



Para criar os rótulos, os pesquisadores coletaram todas as bases de dados SIG de infraestrutura disponíveis e recortaram as imagens de satélite de acordo

~50.000 rótulos/imagens para treinamento

Fonte: METER-ML

Dados de atividade: detecção de objetos

Resultados de classificação (AUPRC) após aplicar CNNs aos conjuntos rotulados

Image Product	Bands	CAFOs	Landfills	Mines	Proc Plants	R&Ts	WWTPs	Overall
S1	VH&VV	0.519	0.107	0.152	0.218	0.487	0.119	0.267
S2	RGB	0.889	0.268	0.305	0.374	0.694	0.204	0.456
S2	All	0.889	0.189	0.382	0.368	0.690	0.183	0.450
S2 & S1	All	0.923	0.152	0.379	0.391	0.612	0.231	0.448
NAIP	RGB	0.903	0.270	0.348	0.327	0.849	0.182	0.480
NAIP	All	**0.945**	**0.276**	0.401	**0.508**	**0.857**	**0.303**	**0.548**
NAIP & S2 & S1	All	0.889	0.214	**0.473**	0.457	0.796	0.272	0.517

Há muitos dados de satélite, mas bons rótulos ainda são difíceis de obter e variam muito conforme a geografia

Validação dos rótulos: 2 revisores especialistas revisaram manualmente 1.500 rótulos:

If the expert identified no clearly visible methane source categories in the image, the example was labeled "negative", and if the expert was uncertain about any label, the example was labeled "uncertain". The two labels per example were then resolved as follows:

1. If the experts agreed and neither was uncertain, the agreed upon label was taken as the final label.
2. If the experts disagreed, and one was uncertain but the other was not, the expert's certain label was taken as the final label.
3. If the experts disagreed, but one agreed with the original label, the original label was taken as the final label.
4. In all other scenarios, the example was reviewed jointly by the experts and a final label was assigned.

Fonte: METER-ML

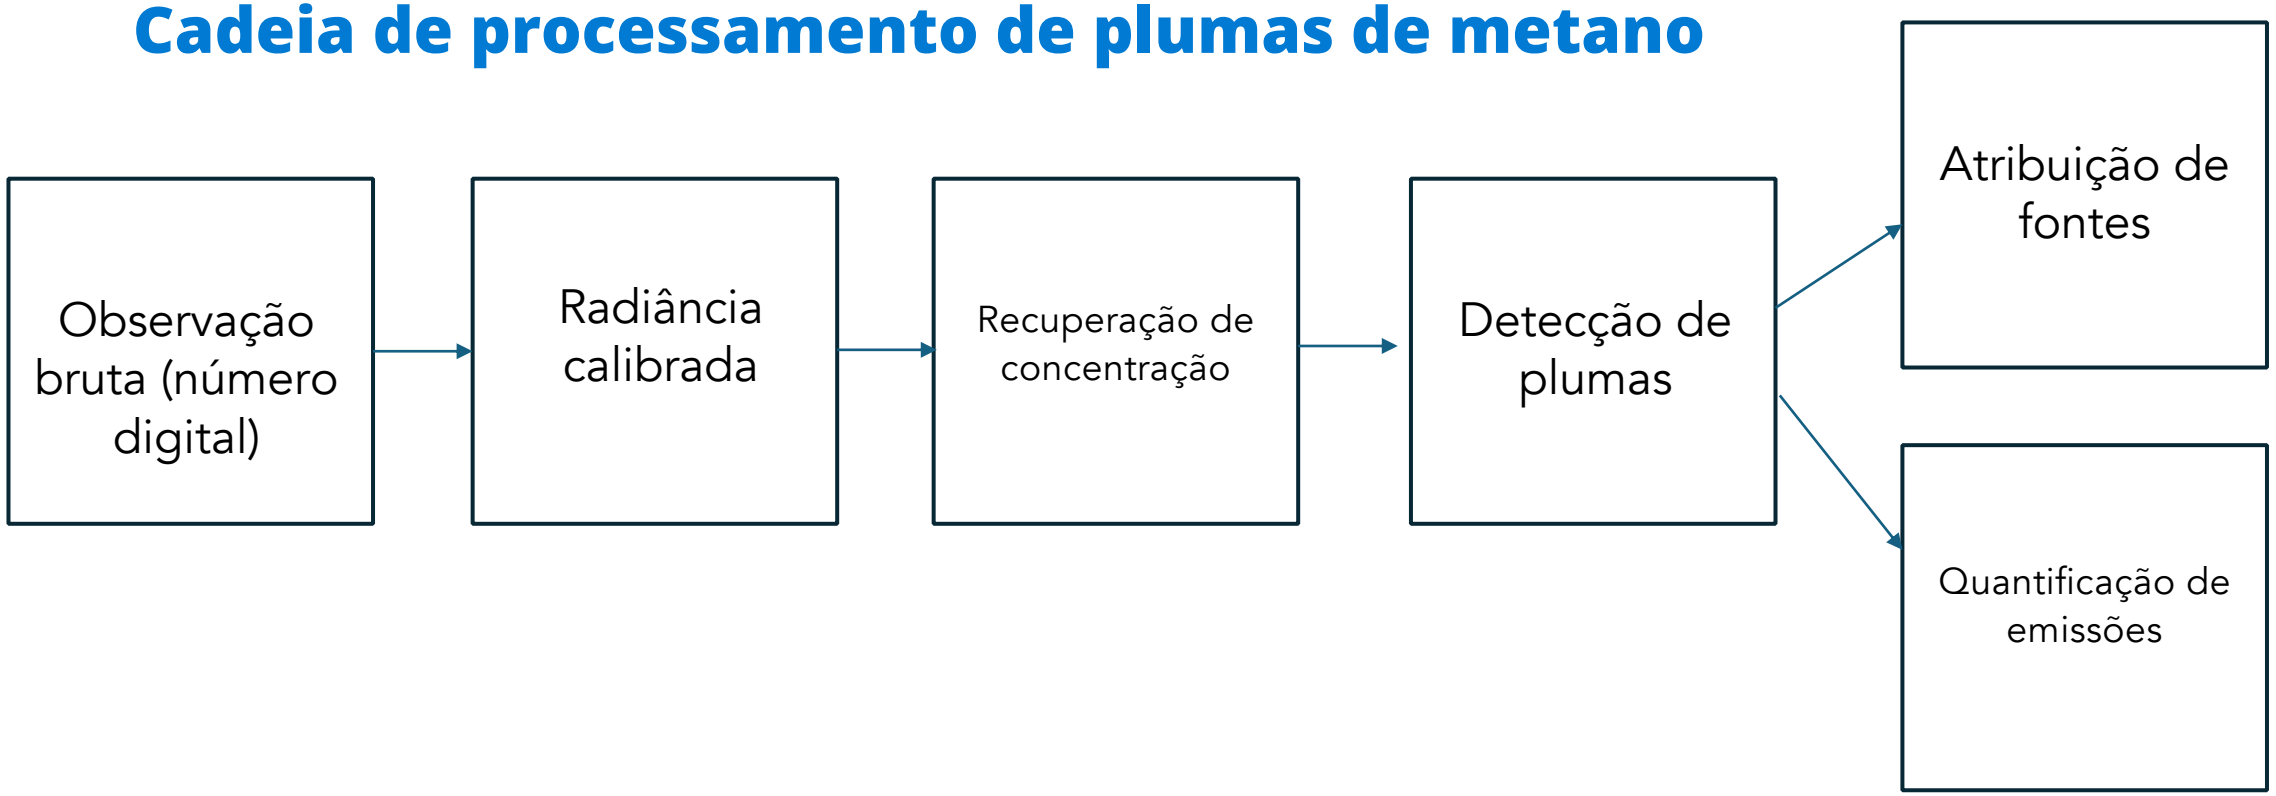
Exemplo passo a passo:

Cadeia de processamento de plumas de metano

Tarefa: ao longo deste exemplo, pense em como a IA pode ajudar no processo

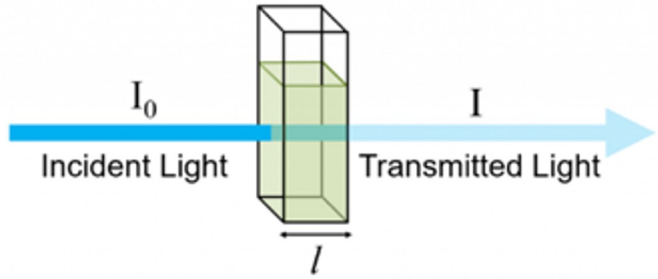
Criar produtos de dados de plumas exige várias etapas de processamento.

Cadeia de processamento de plumas de metano



O satélite observa a radiância no topo da atmosfera, a partir da qual as concentrações em coluna são estimadas por meio de uma recuperação.

Algoritmo de "filtro casado" por coluna, baseado na lei de Beer-Lambert



$$x_m = x_r e^{-k\Delta c}$$

- x_m: Espectro modelado
- x_r: Espectro de referência
- k: Absorção
- Δc: Aumento de concentração

Expansão de Taylor (caso linearizado)

$$x_m = x_r(1 - k\Delta c)$$

Usando um estimador de máxima verossimilhança, o aumento de concentração "ótimo" que minimiza os resíduos entre modelo e observação (ponderados por uma covariância) é:

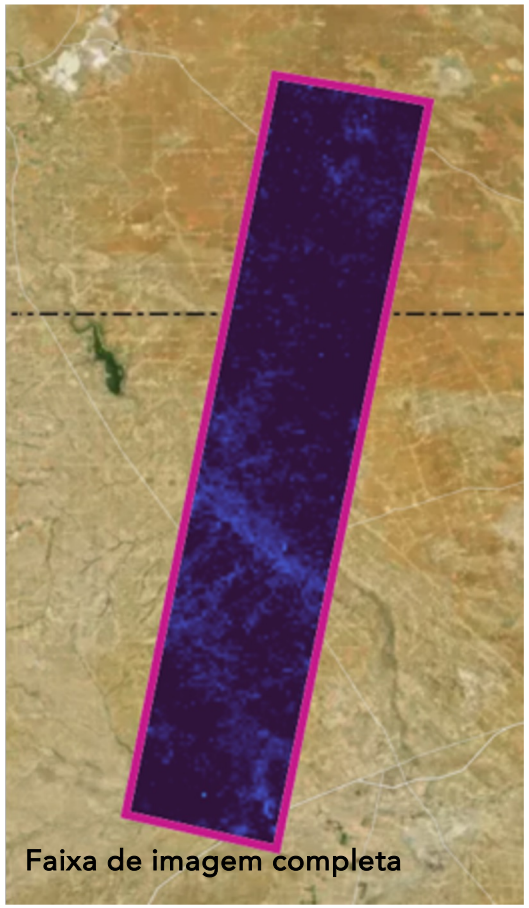
$$\Delta c = \frac{t^T \Sigma^{-1}(x_r - x_o)}{t^T \Sigma^{-1} t}$$

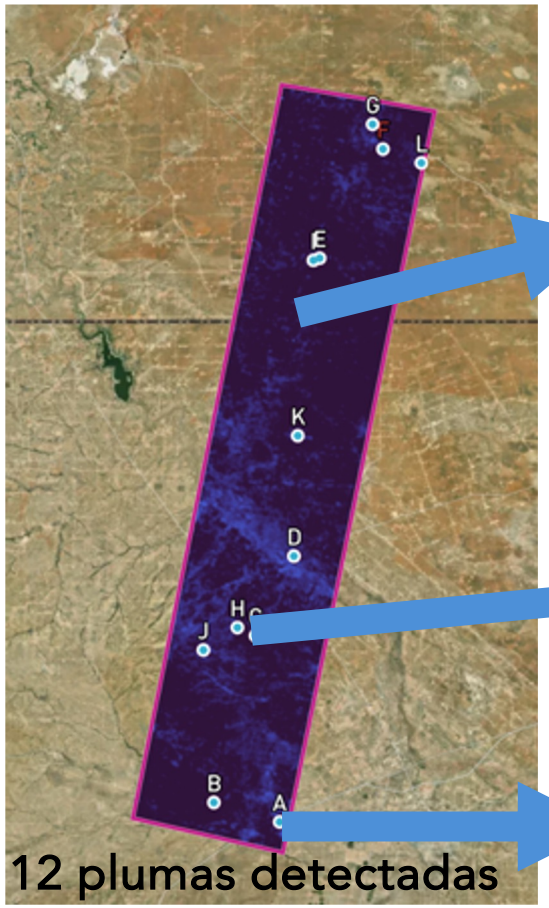
Aumento de CH4 na coluna

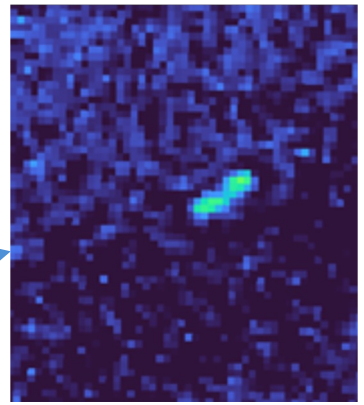
We choose x_r and Σ to be the mean and covariance of a collection of pixels in the image, and t is a mapping between radiance and concentration

Processo de detecção de plumas: procurando agulhas no palheiro

Exemplo: imagem de 20 x 100 km2 (satélite Tanager) tomada sobre densa infraestrutura de petróleo e gás no Texas

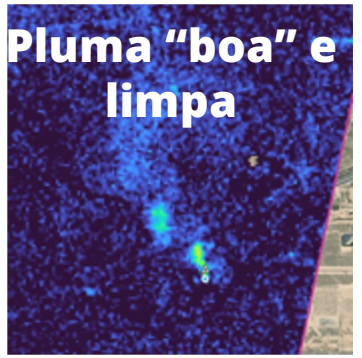


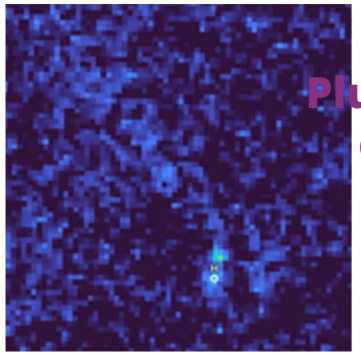






Falso aumento: telhados brancos

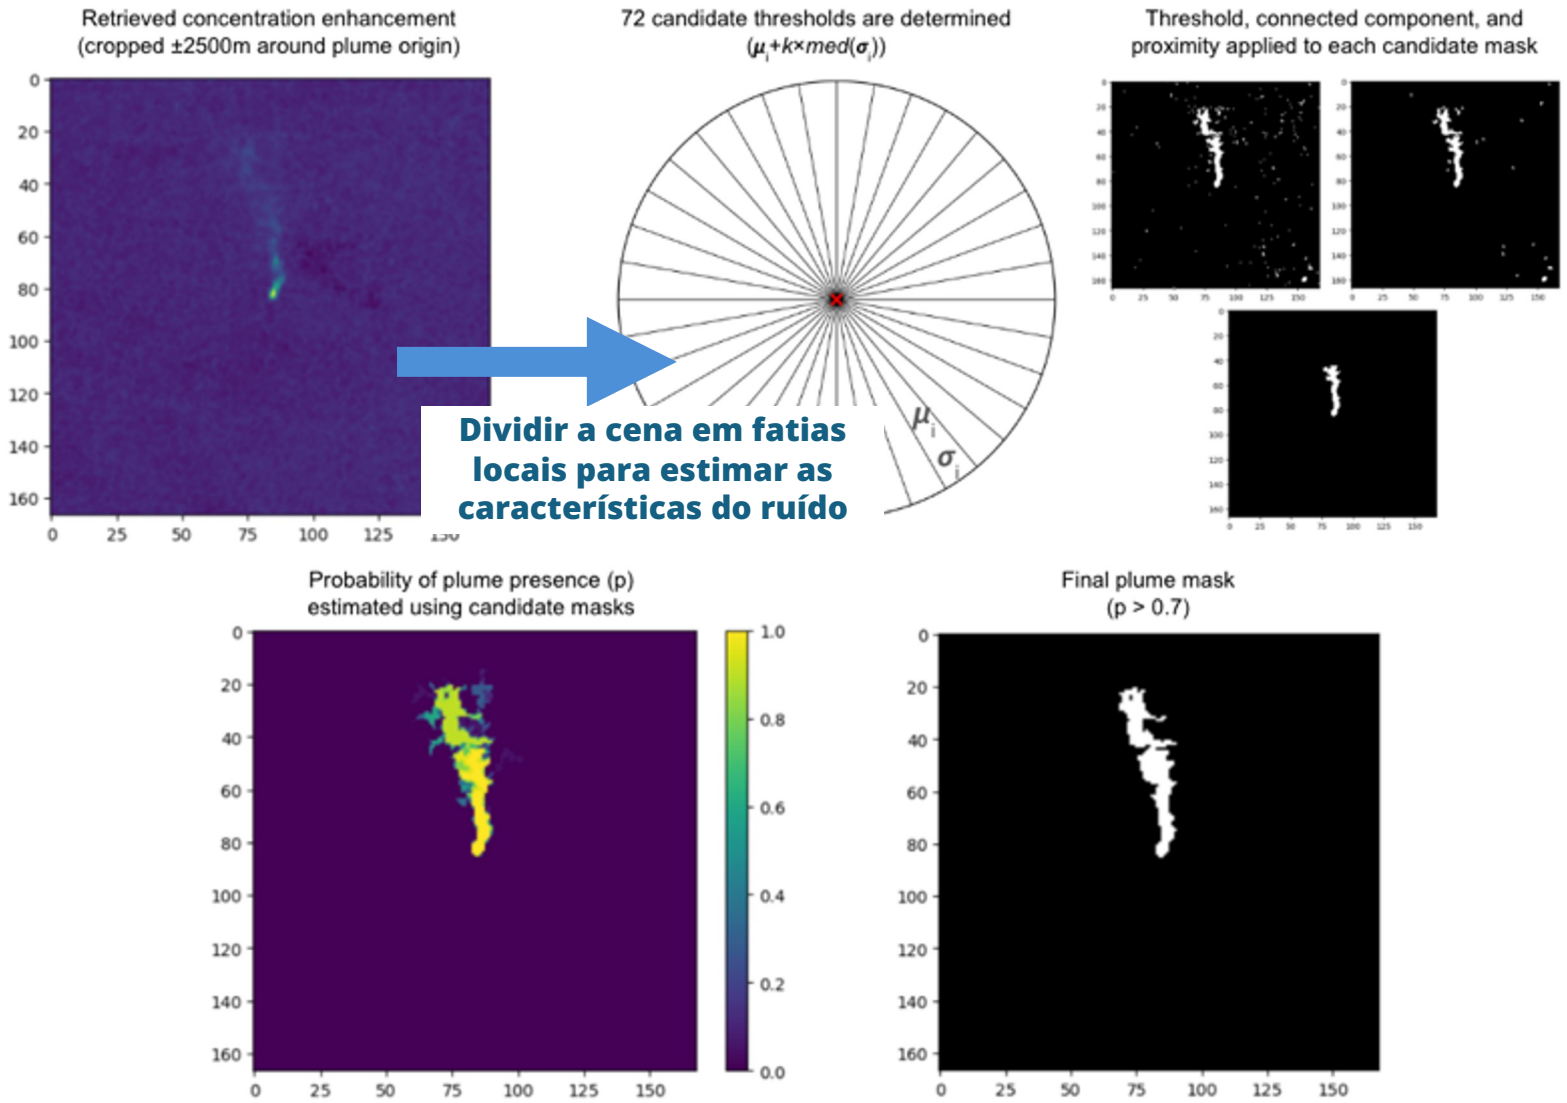




Pluma peque e marginal

Pergunta: qual é o risco de um único falso positivo (lembre do início da aula)?

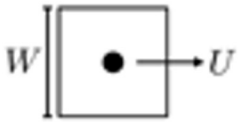
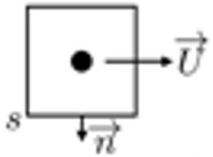
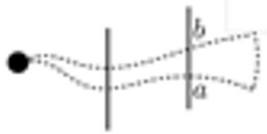
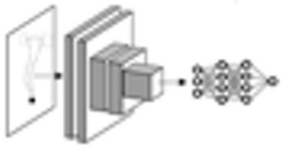
Segmentando (“mascarando”) as detecções de plumas



Passos críticos para a quantificação

A segmentação define os limites da pluma, permitindo quantificar massa e comprimento

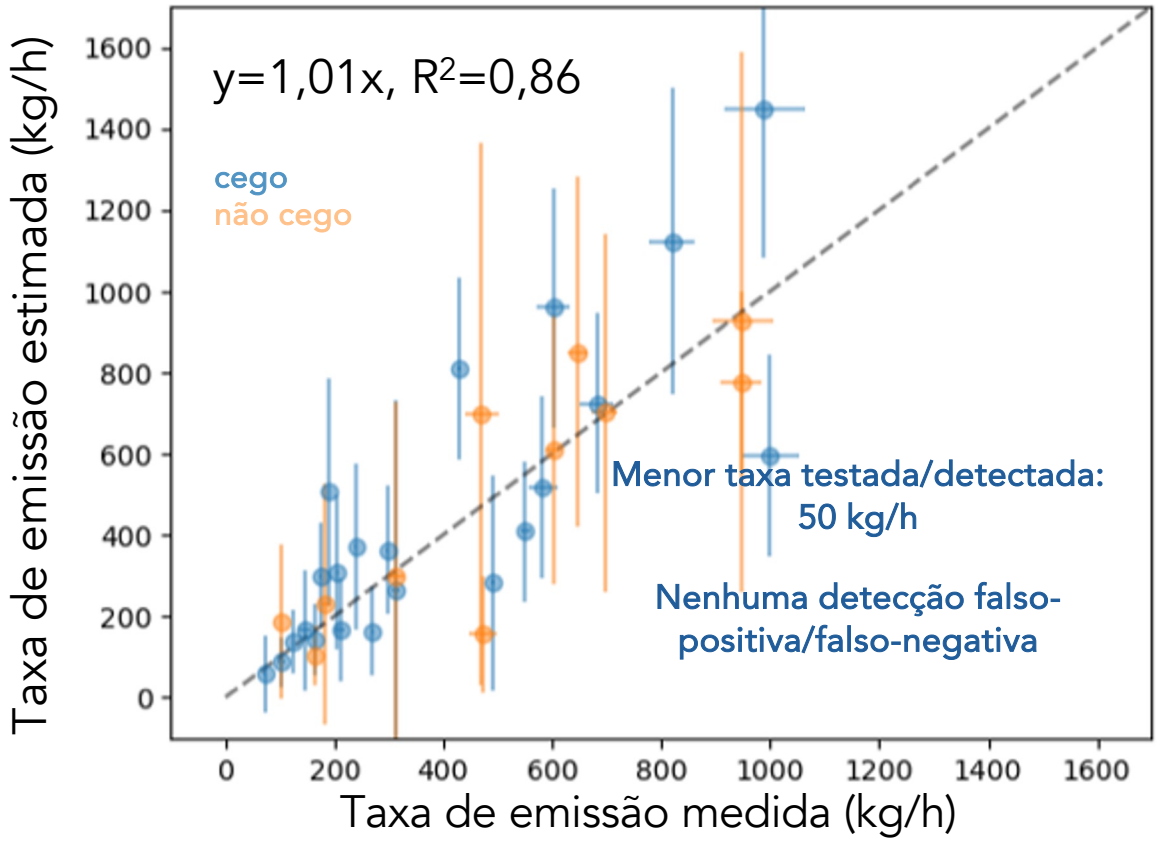
Quantificando a taxa de emissão de uma pluma

Gaussian Plume		$Q = U\Delta\Omega(x,y)\left(\sqrt{2\pi}\sigma_y(x)e^{\frac{y^2}{2\sigma_y(x)^2}}\right)$
Local mass balance		$Q = UW\Delta\Omega$
Gauss theorem		$Q = \oint_s \Omega(s)\vec{U}\cdot\vec{n}\,ds$
Cross-sectional flux (CSF)		$Q = U\int_a^b \Delta\Omega(x,y)dy$
Integrated mass enhancement (IME)		$Q = \frac{U_{\text{eff}}\ \text{IME}}{L}$
Angular width		$Q = f(\text{IME},\theta)$
Machine learning		$Q = \text{CNN}(\text{Plume image})$

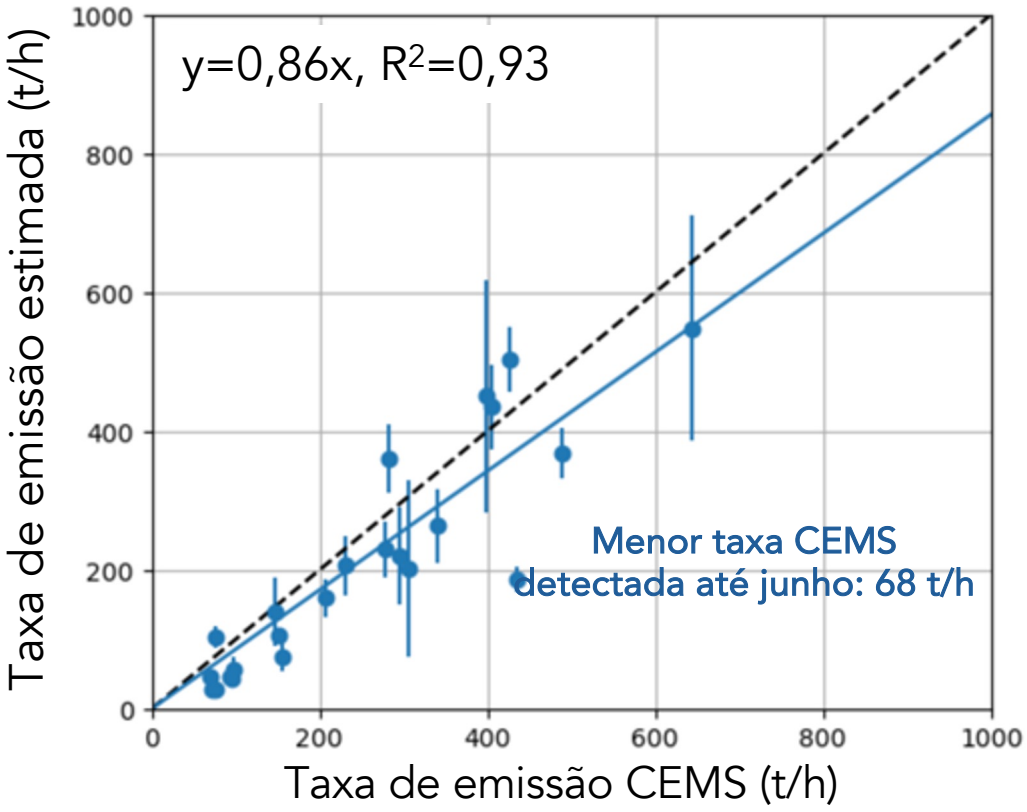
Abordagens mais comuns

Experimentos de liberação controlada podem ser feitos para avaliar o viés e a incerteza dos métodos de quantificação

Liberações controladas de CH4 para o Tanager (Stanford; Casa Grande, Arizona)



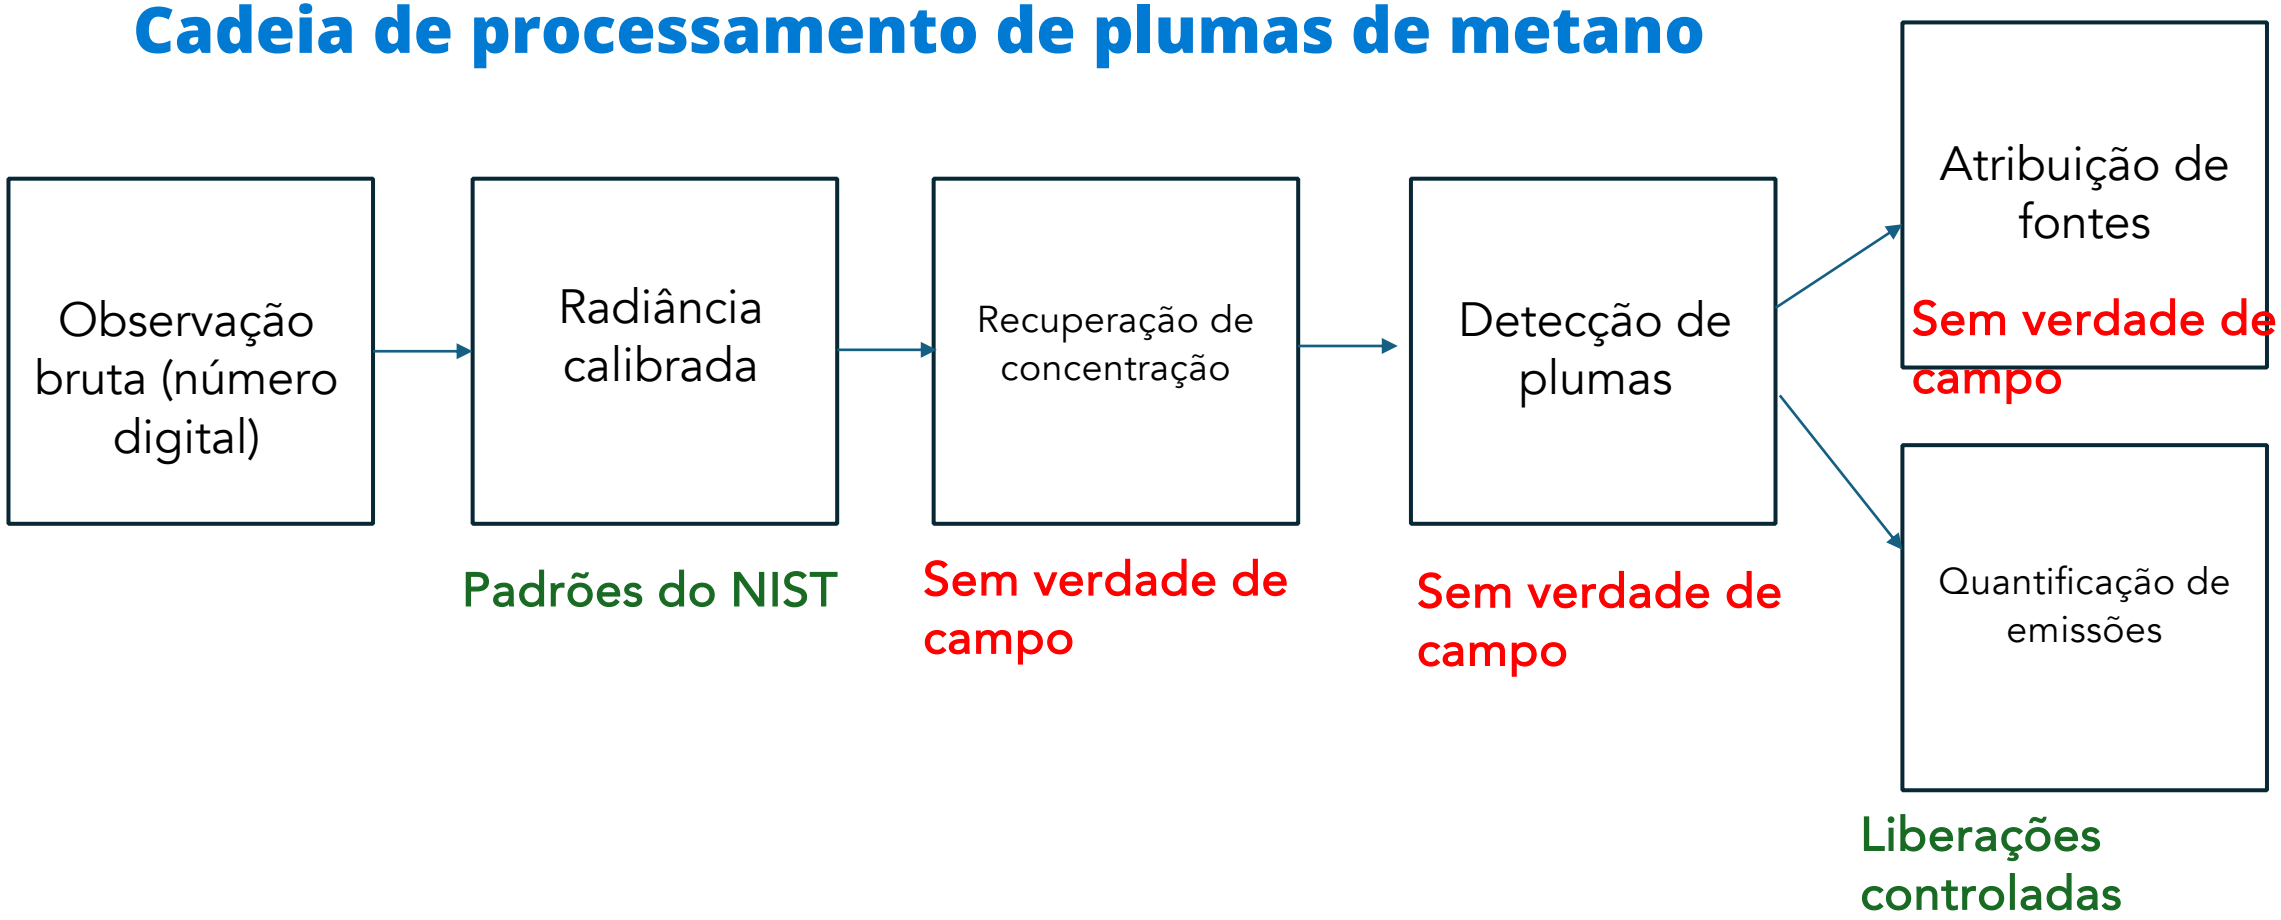
Satélite Tanager e sistemas de monitoramento contínuo de emissões de CO2 (CEMS, US EPA, distribuídos regionalmente)



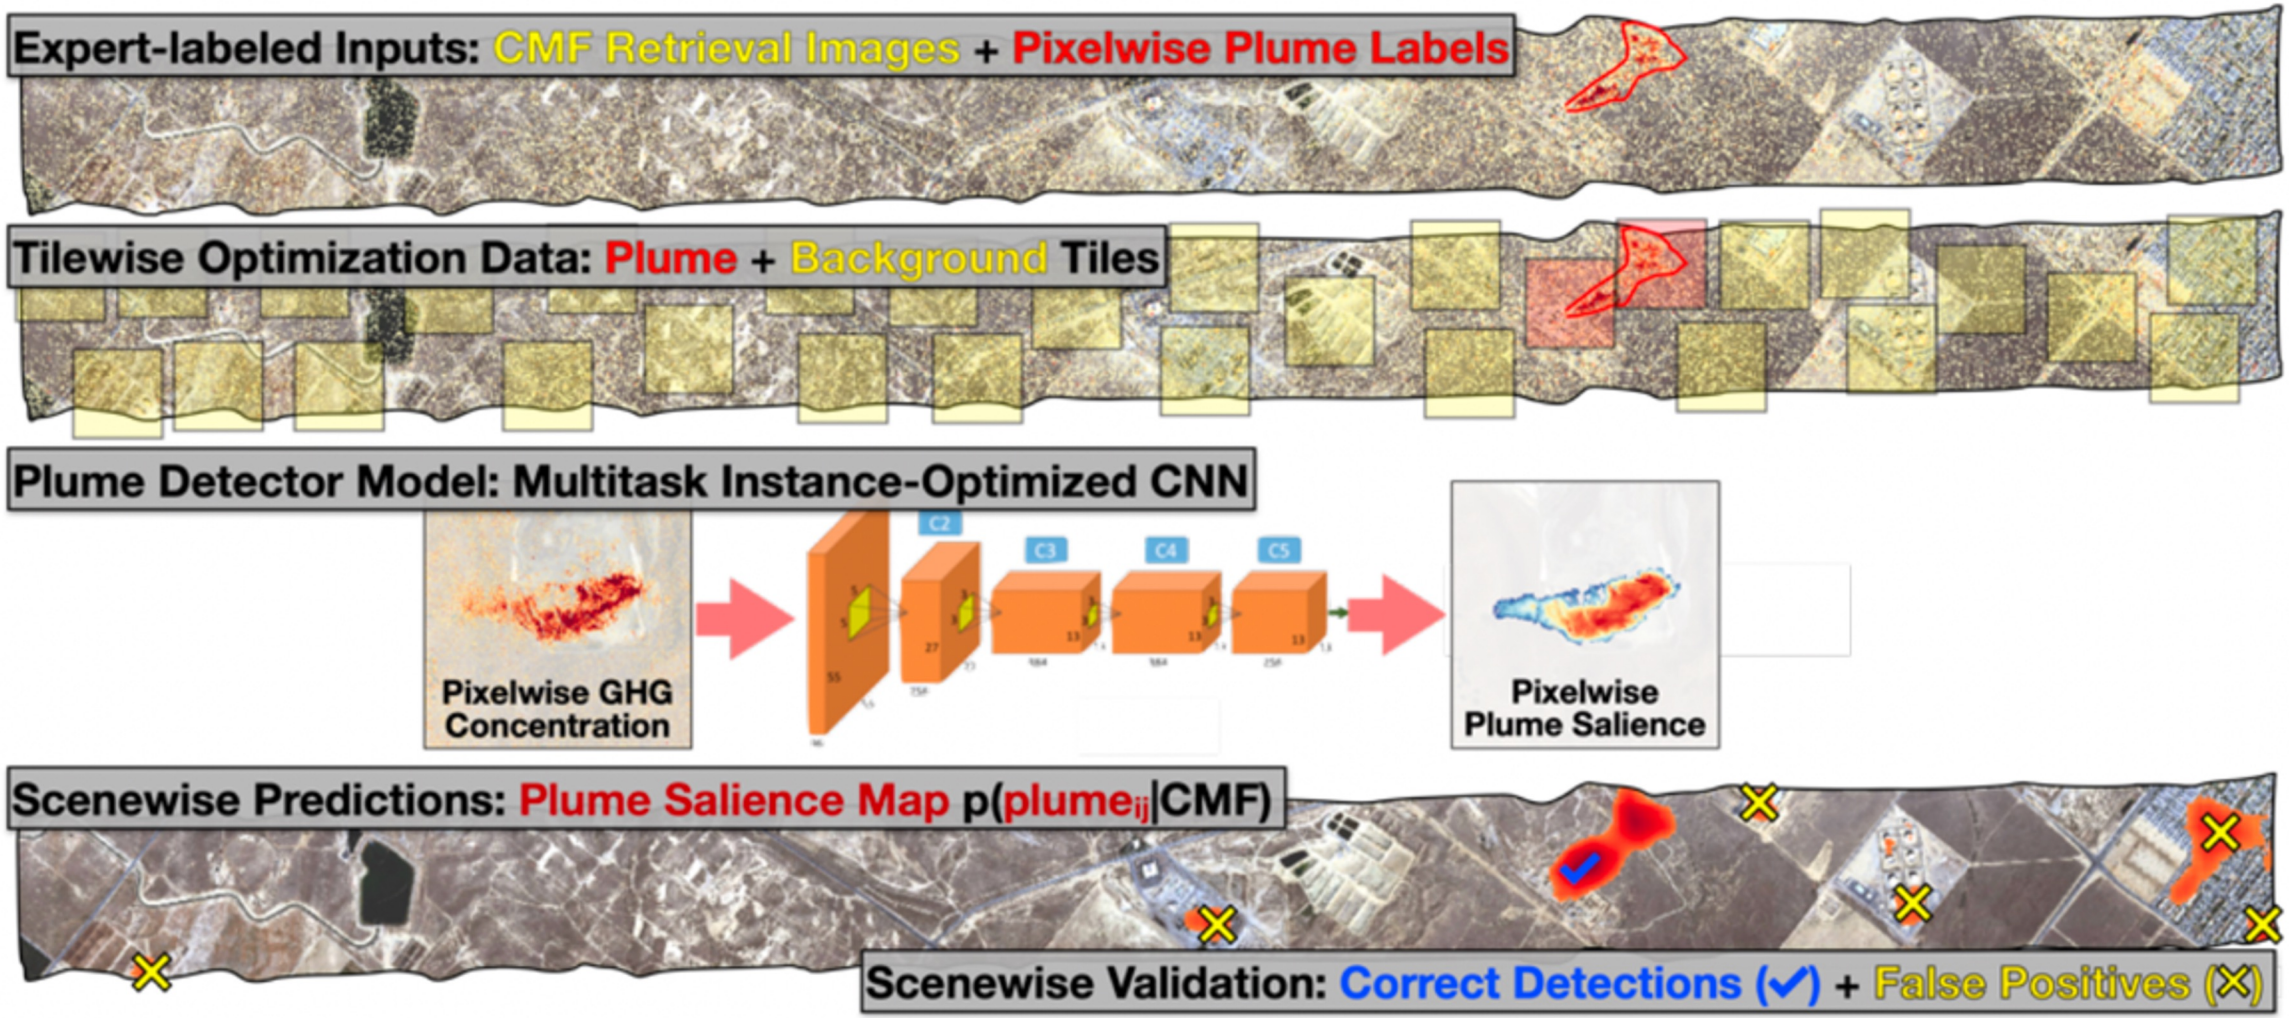
Reuland et al. (submetido)

Verdade de campo limitada

Cadeia de processamento de plumas de metano

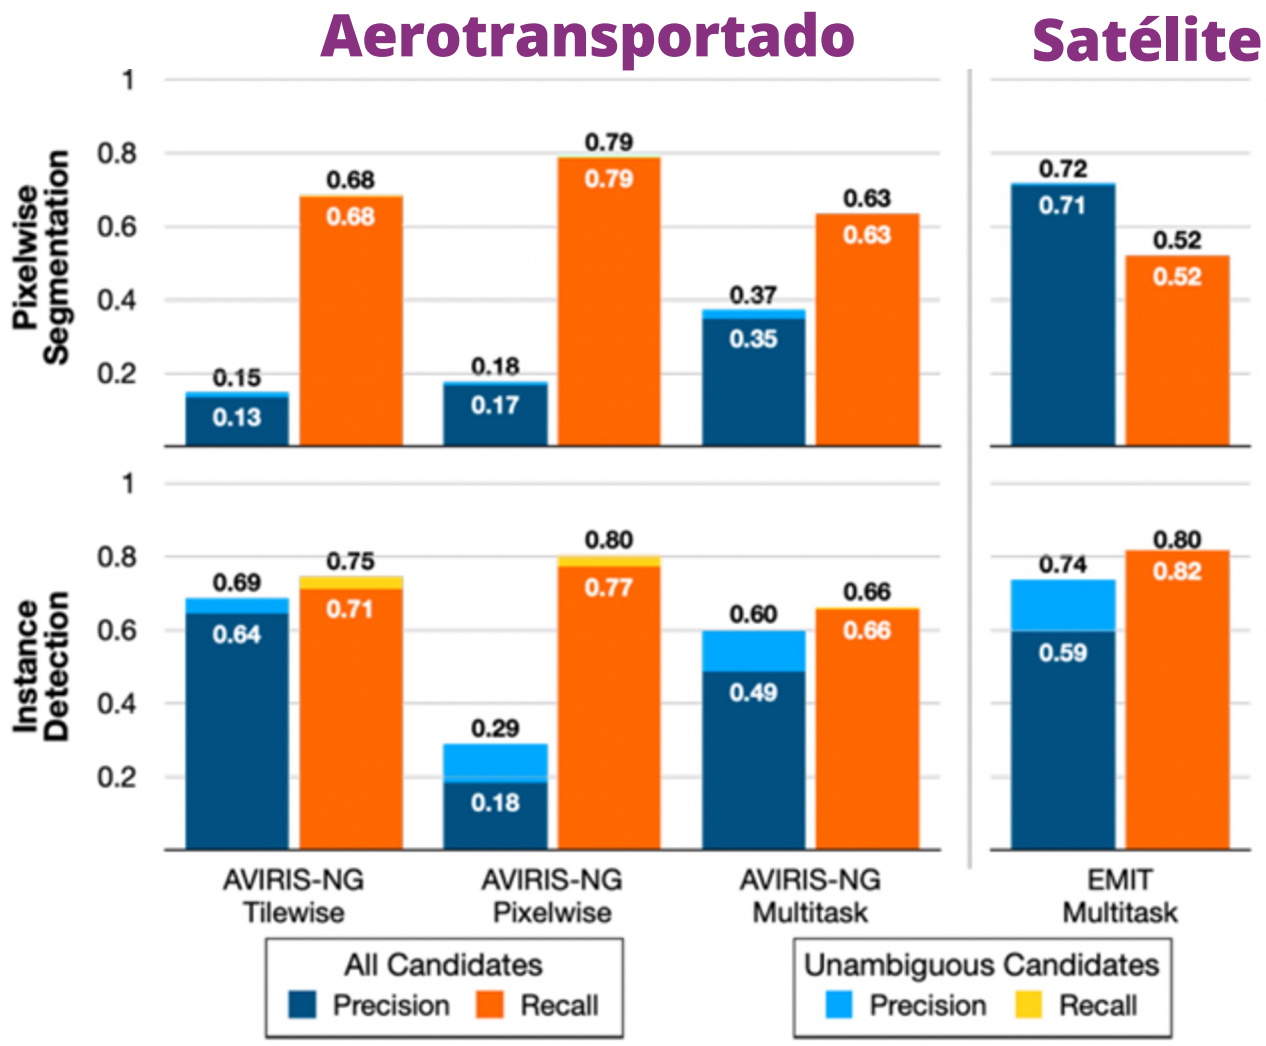


A detecção de plumas é o gargalo da cadeia de processamento. Explorar métodos para reduzir a latência/a necessidade de anotação manual



Bue et al. (em revisão)

Qual é o objetivo de aprendizado? Encontrar pixels com metano elevado (segmentação densa) ou encontrar plumas (detecção de instâncias)?

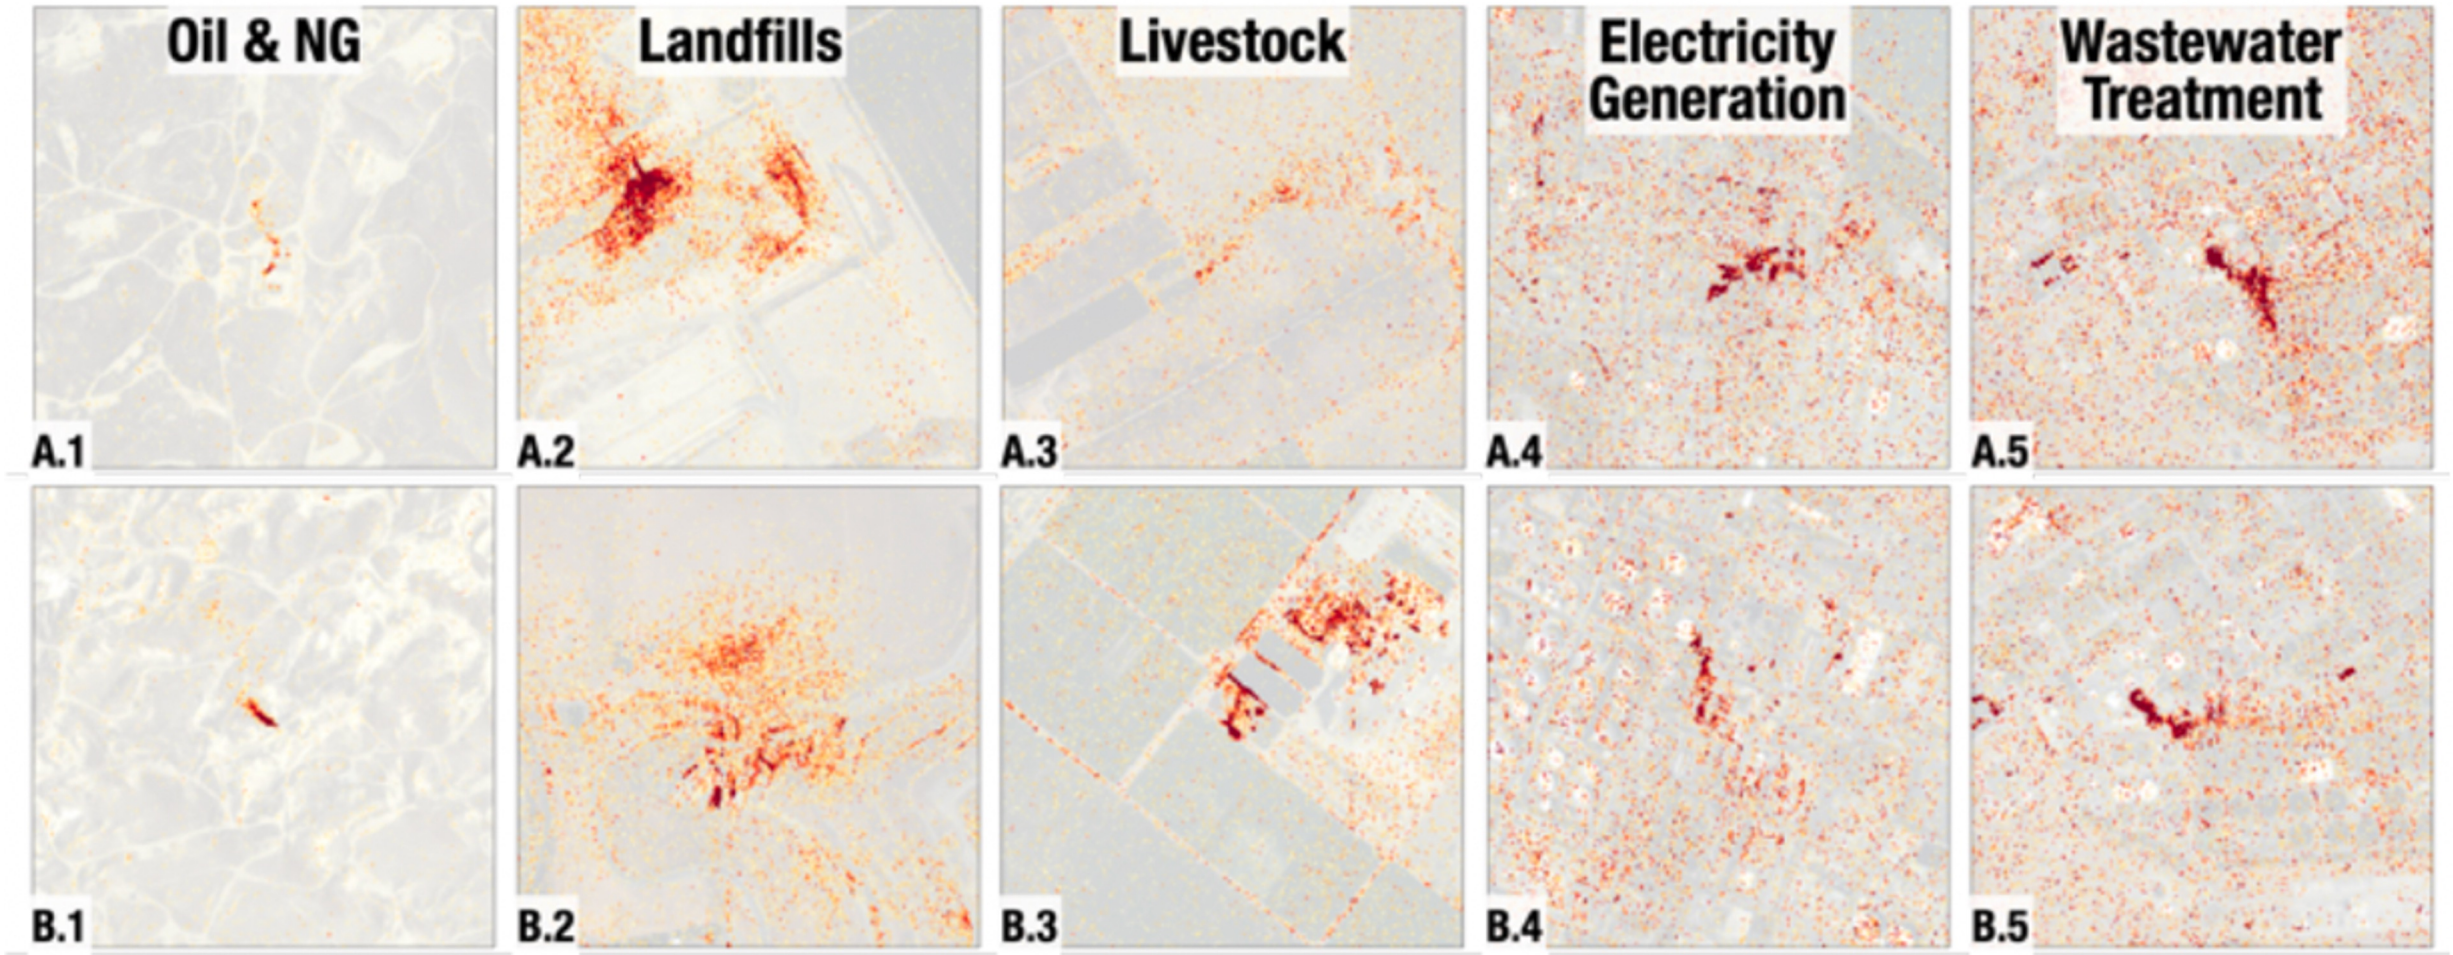


Problema: superemissores de metano são raros, poucos milhares de amostras de treinamento

A arquitetura do modelo e a função de perda fazem uma enorme diferença conforme a tarefa

Bue et al. (em revisão)

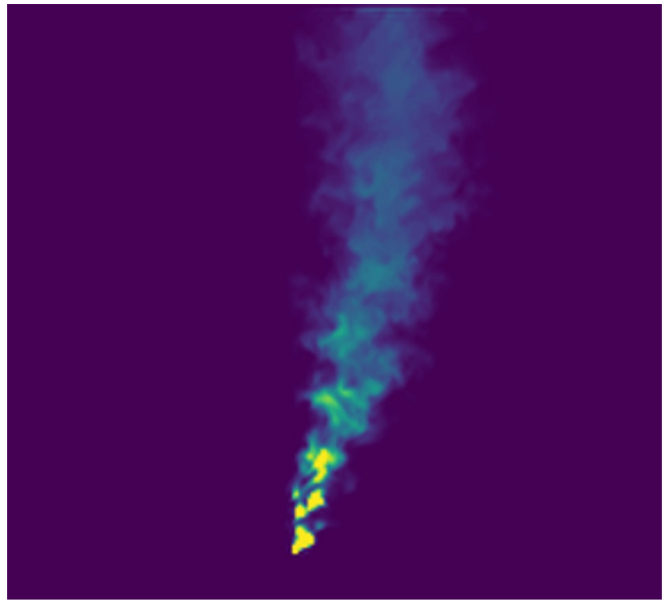
As plumas de metano têm formas muito diversas conforme o setor emissor. O ruído instrumental também depende da região e do ambiente.

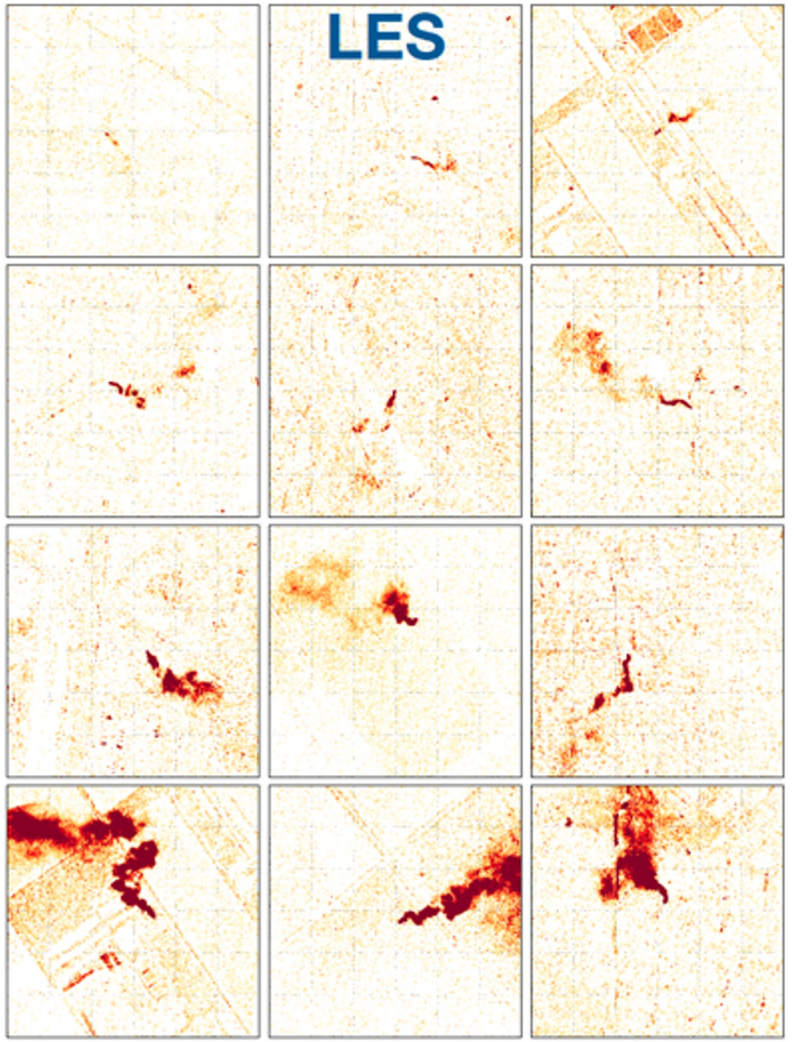


Bue et al. (em revisão)

Aumento de dados: inserir plumas sintéticas em imagens realistas para criar mais amostras

Gerar plumas falsas com simulações de grandes turbilhões (LES)



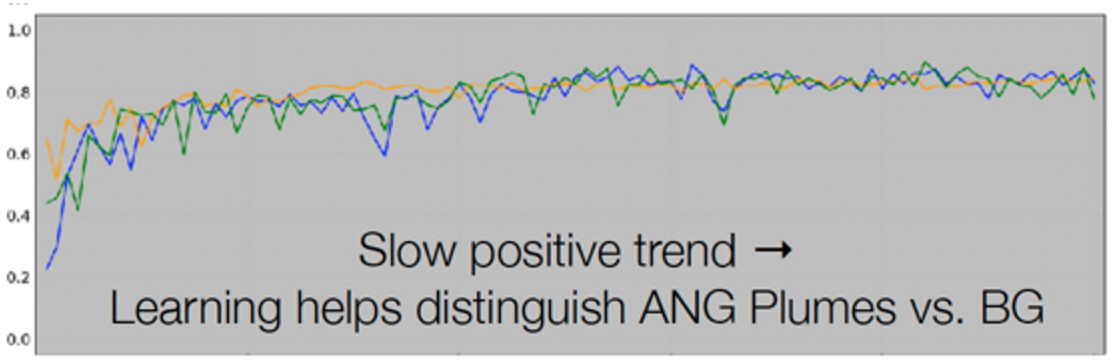


Inserir as plumas em blocos com ruído realista para o treinamento

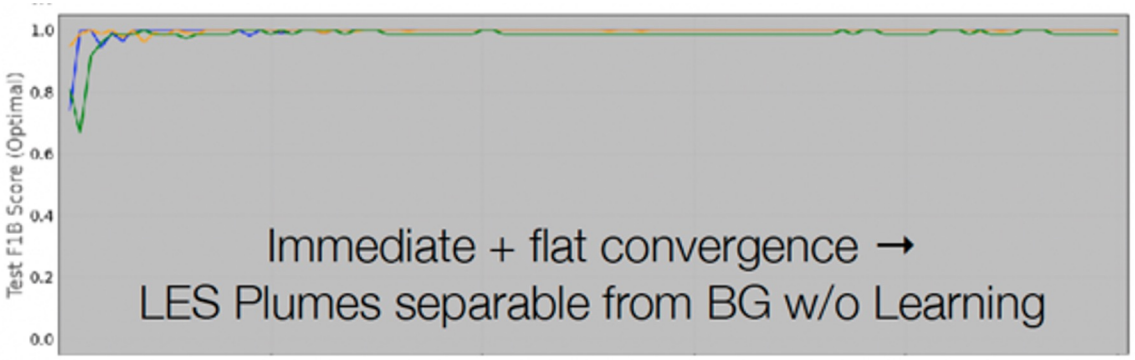
O aumento de dados tem um problema de generalização com arquiteturas CNN

Pontuação F1

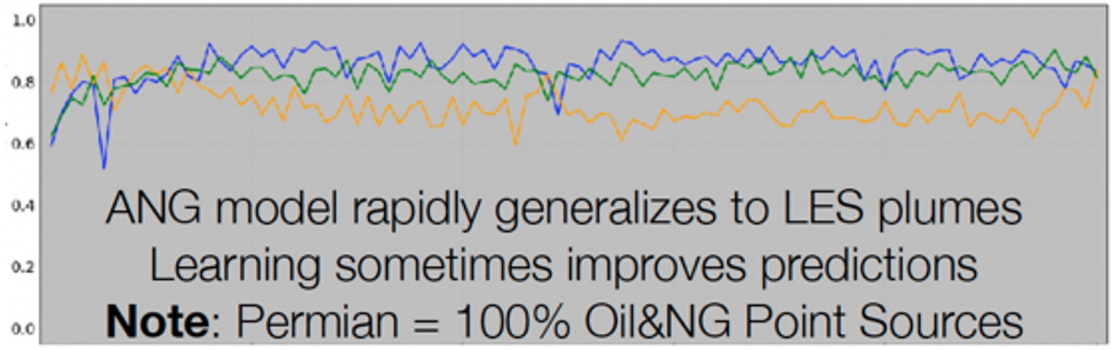
Treino aéreo -> teste aéreo



Treino LES -> teste LES



Treino aéreo -> teste LES



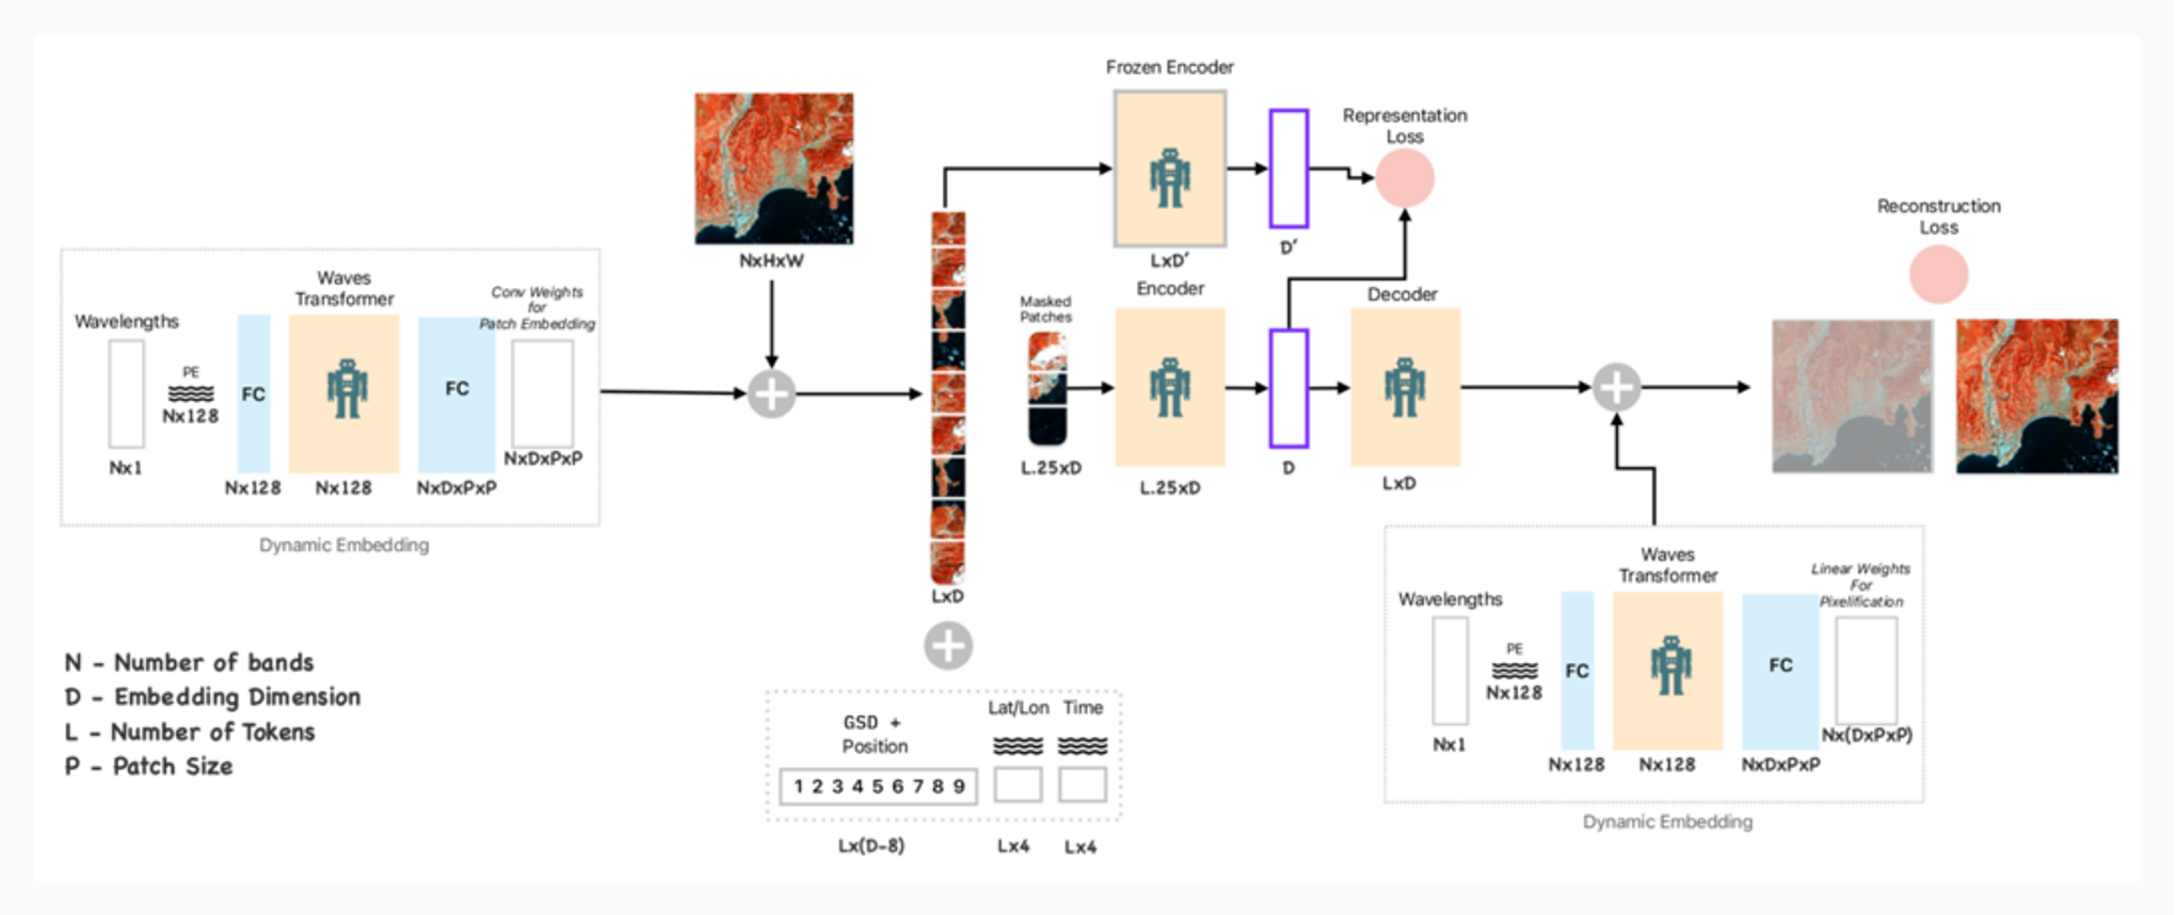
Treino LES -> teste aéreo



Época

Teste de modelos de base da Terra nesta aplicação

Embeddings do Clay



Testamos diversos embeddings existentes e novos com Tanager, Sentinel-2 e tamanhos de bloco variados.

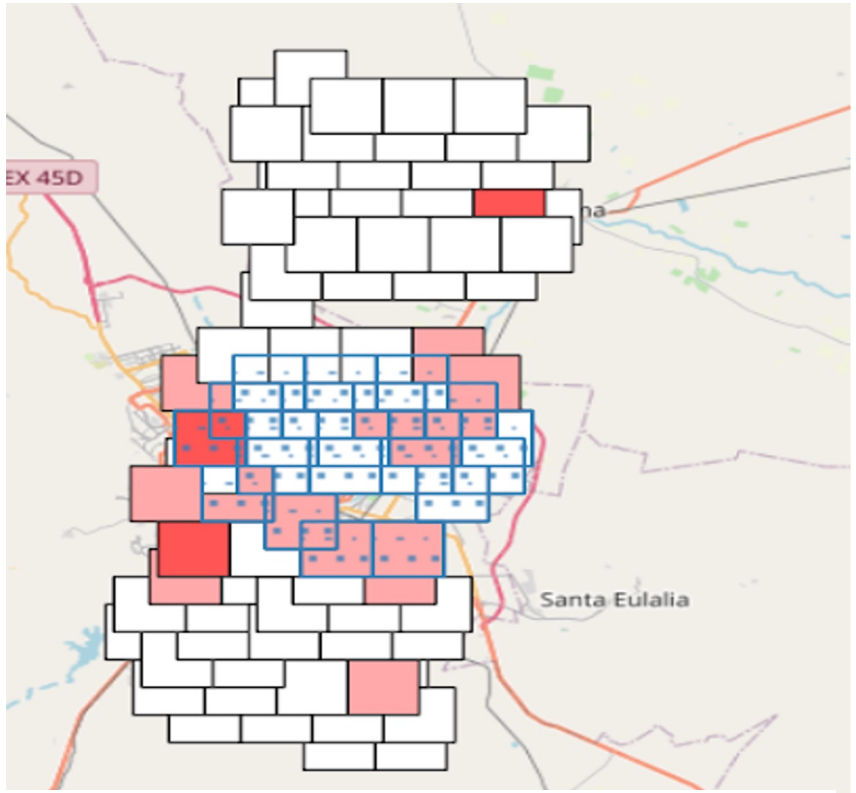
Os embeddings sugerem que ~10 bandas do Tanager + Sentinel-2 bastam para a melhor classificação

Fonte(s)	Tamanho do bloco [metros][1]	Nº de bandas do Tanager	F1 positivo[2]	F1 ponderado por classe	F1 negativo
Tanager	3840	10	0.64	0.61	0.19
Tanager	**3840**	**Todas**	**0.74**	**0.69**	0.19
Tanager	2560	10	0.43	0.40	0.17
Tanager	2560	Todas	0.69	0.64	**0.21**
Tanager, S2	3840	10	**0.74**	**0.69**	0.15
Tanager, S2	3840	Todas	0.69	0.64	0.12

Baixo desempenho na previsão da classe sem pluma. Pior que os testes baseados em CNN

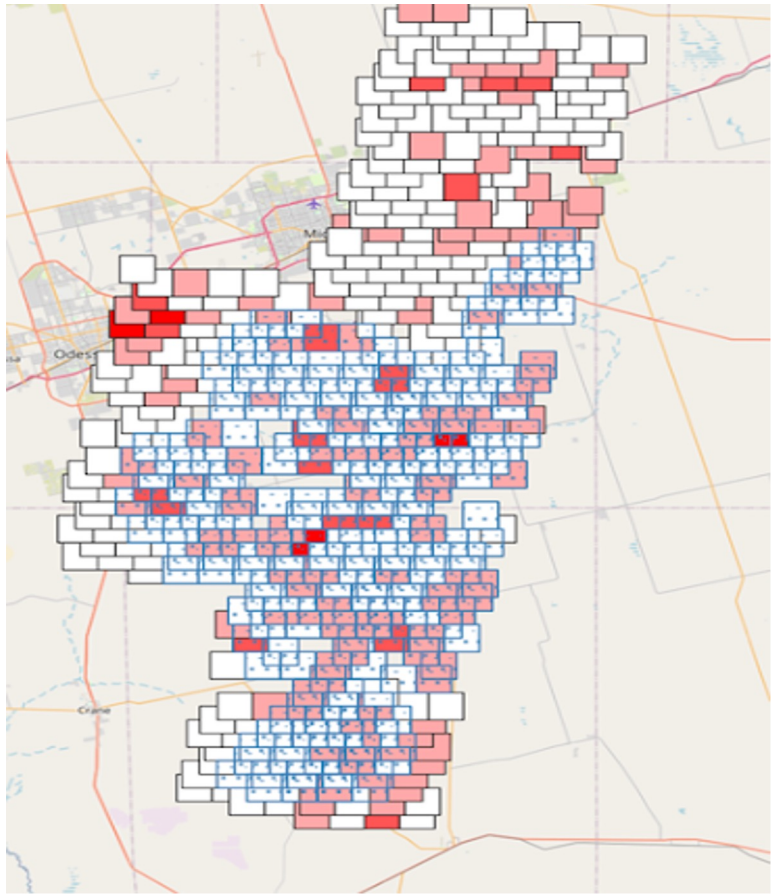
A inspeção visual dos resultados não mostra padrões claros nos erros

Exemplo de resultado do modelo Clay em Oklahoma



Pontos azuis: locais de plumas conhecidas
Quadrados brancos: classe negativa
Quadrados vermelhos: classe positiva

Exemplo de resultado do modelo Clay no Texas

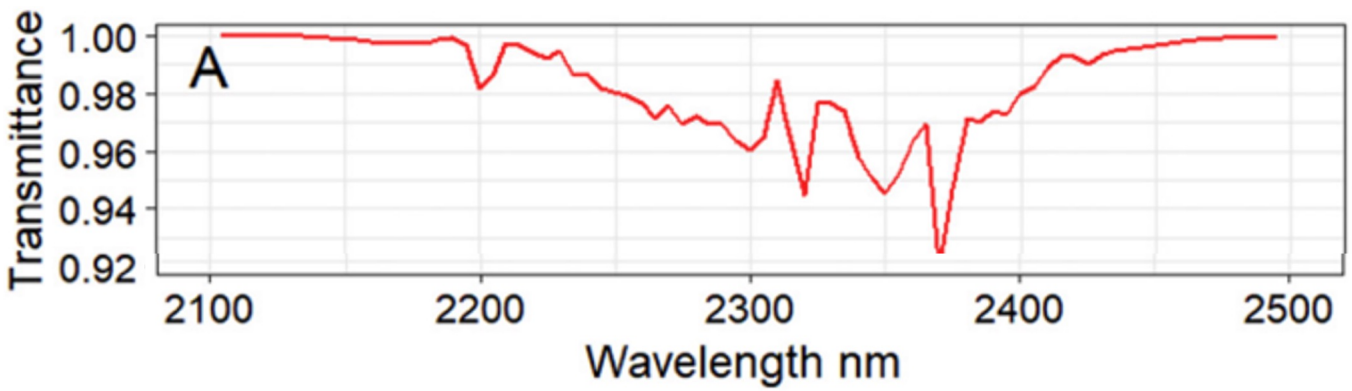


Hipótese:

A absorção do metano é uma feição secundária do retroespalhamento solar observado

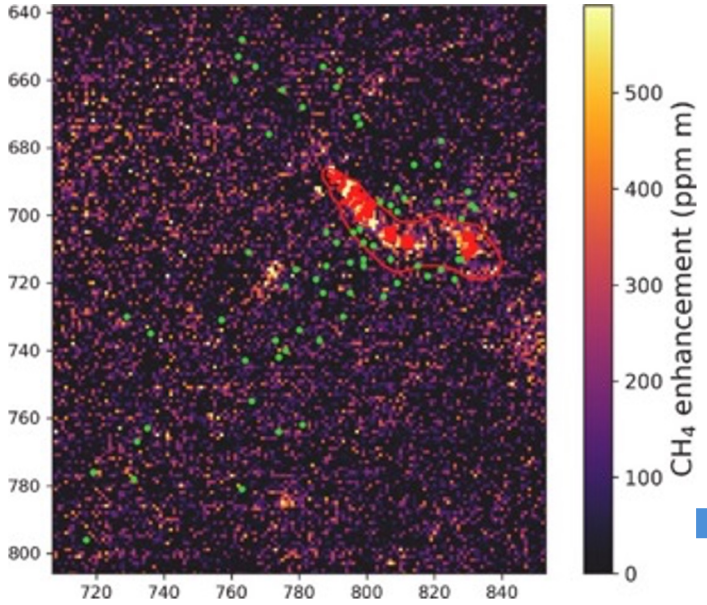
Modelos de base genéricos da Terra podem perder essa assinatura sutil ao criar os embeddings

De volta aos espectros, à física e às CNNs: avaliação a posteriori

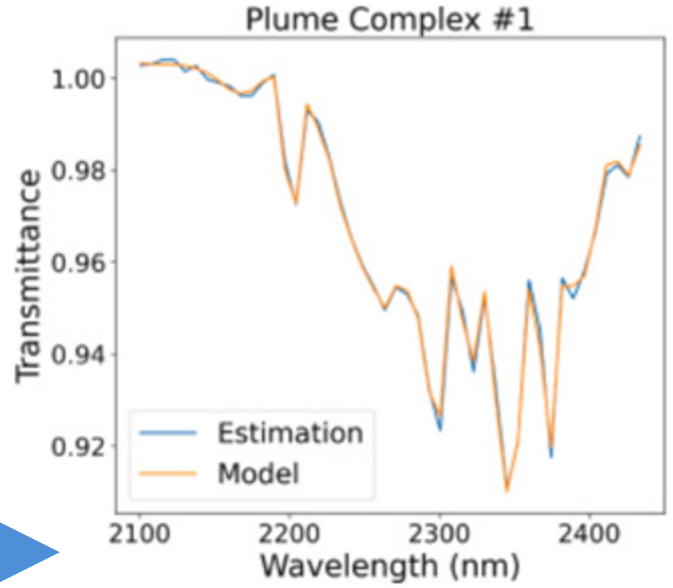


É assim que a absorção do metano aparece espectralmente com espaçamento de banda de 5 nm (isto é, um satélite como o Tanager)

Então, se eu tiver uma pluma real e tomar espectros dentro da pluma e fora da pluma…



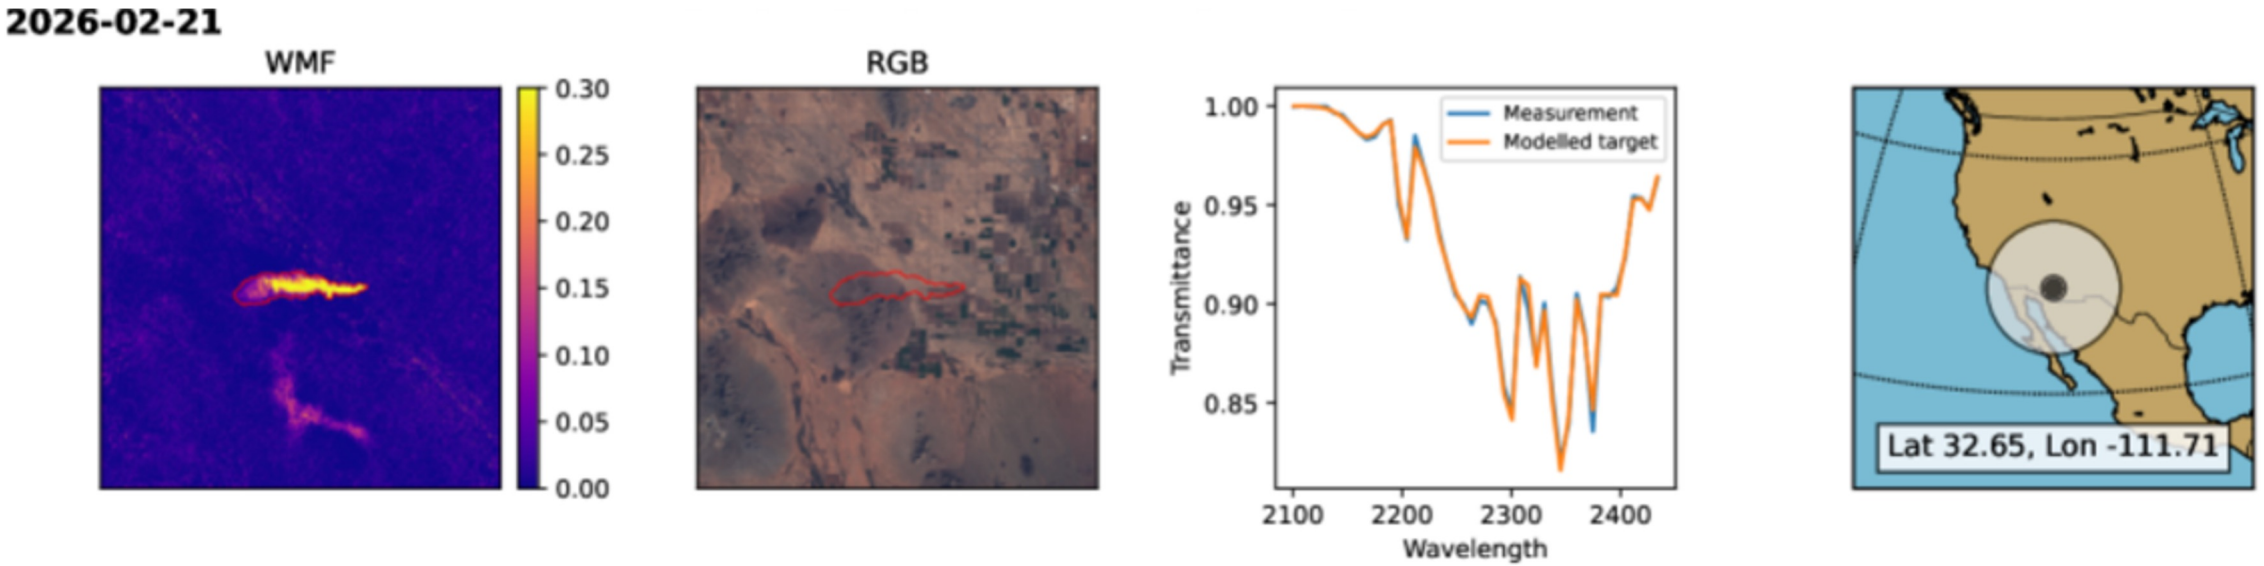
Devo obter algo que se pareça com absorção



Xiang et al. (2025)

Unindo AM e intuição física para notificação de plumas com baixa latência

Exemplo de alerta de pluma totalmente automatizado em operação



Detecção da pluma por CNN → Passou por uma verificação física automatizada (sem AM) → A Carbon Mapper alertou a autoridade local

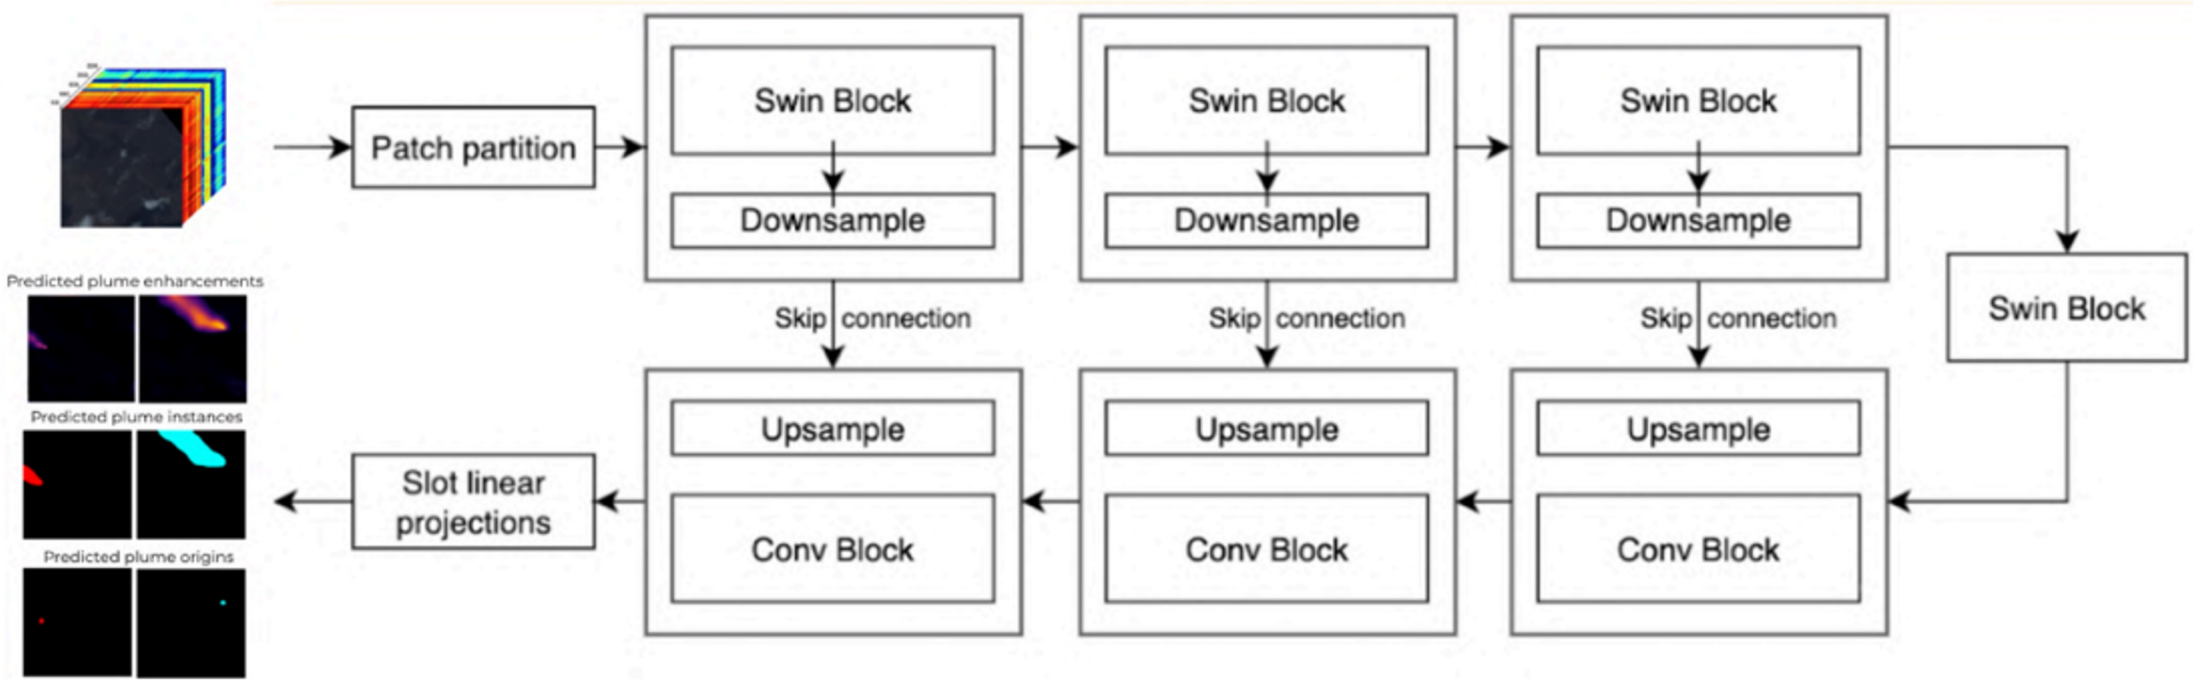
Aqui, um modelo de AM com muitos falsos positivos é aceitável quando combinado com sólida intuição física para produzir uma detecção

Pergunta: sistemas de IA ou AM precisam ser realmente de ponta a ponta?

Růžička et al. (2026)

Entrando no mundo dos transformers e dos conjuntos de dados massivamente aumentados

MAPL-EMIT: arquitetura U-Net com codificador Swin Transformer



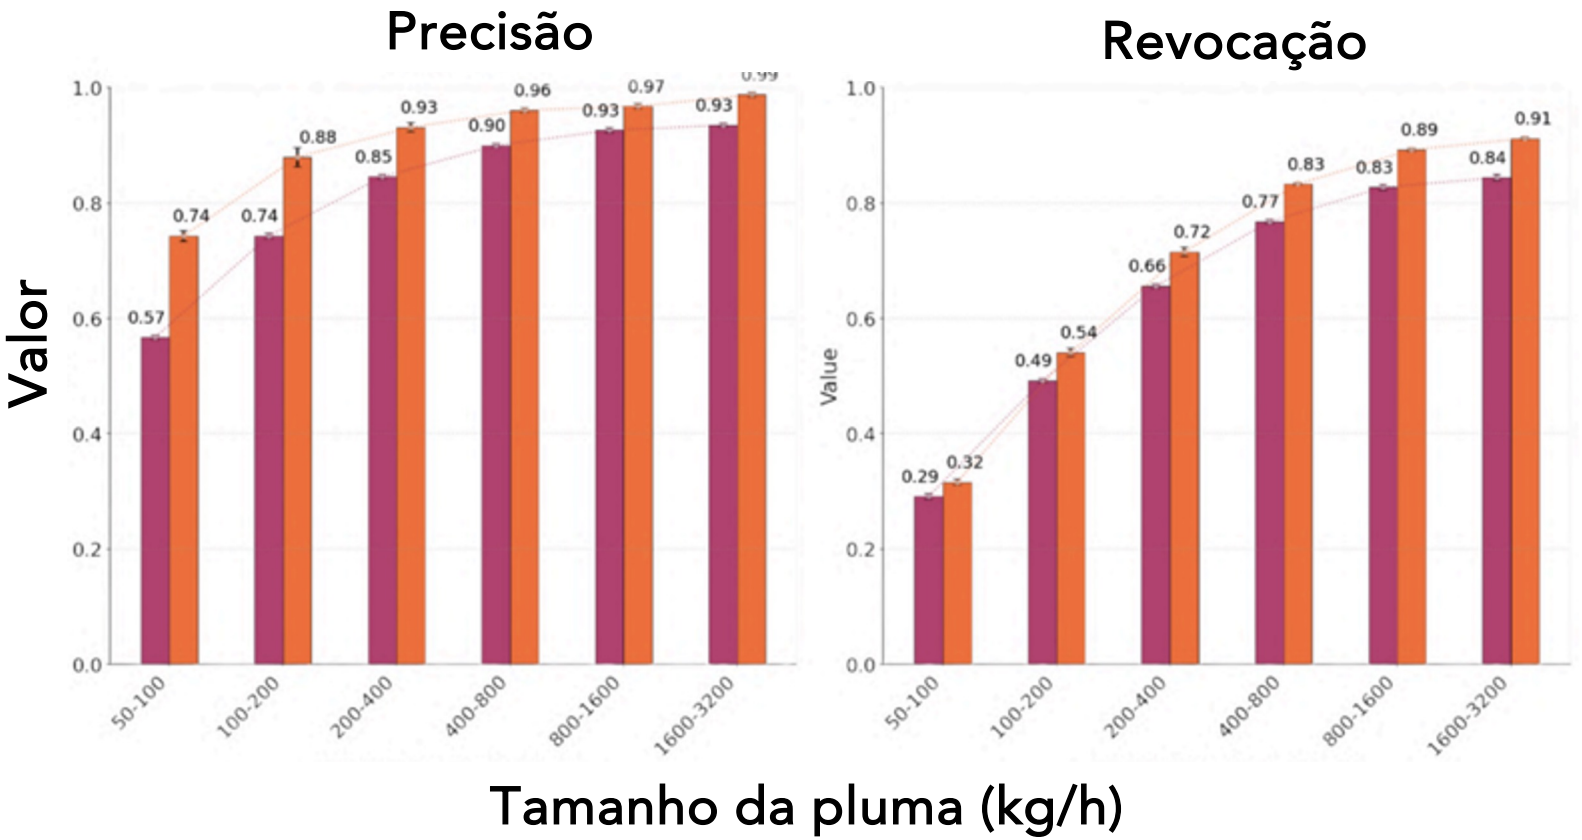
Aumento com plumas sintéticas: 3,6 milhões de plumas sintéticas

Treinamento com todos os canais de radiância e todos os pixels de um bloco de imagem

Batchu et al. (2026)

Entrando no mundo dos transformers e dos conjuntos de dados massivamente aumentados

MAPL-EMIT: arquitetura U-Net com codificador Swin Transformer



Animador, mas ainda há um problema de "verdade de campo":

"…apenas 54% das plumas do MAPL-EMIT estavam na coleção de plumas EMIT L2B, indicando que o MAPL-EMIT identificou o dobro de plumas que os analistas humanos."

Como avaliar a precisão com confiança se os rótulos humanos podem ter esse nível de erro?

Batchu et al. (2026)

Discussão

Voltando às perguntas anteriores, agora sob a ótica da IA:

Como poderíamos/deveríamos ancorar os resultados top-down [ou de IA] em verdade de campo, padrões e validação?

Enquete ao vivo: sua opinião sobre a confiabilidade da contabilidade top-down, baseada em IA ou bottom-up mudou?

- Vote: em que você confia mais? Top-down (manual); top-down (IA); bottom-up?

Que tipos de experimentos você sugeriria/faria para aumentar a confiança nas estimativas top-down/por sensoriamento remoto?

Pontos-chave para a contabilidade de carbono baseada em IA

Temas comuns a todos os exemplos desta aula

Verdade de campo e qualidade dos rótulos

Muitas vezes, não temos verdade de campo confiável (recuperação, detecção, quantificação). A qualidade dos rótulos varia conforme a geografia. Planeje sua avaliação levando isso em conta.

Generalização geográfica e de domínio

Modelos treinados em uma região ou sensor muitas vezes falham em outros. Avalie explicitamente o desempenho fora da distribuição antes da implantação.

Os custos de falsos positivos e falsos negativos são assimétricos

Um falso positivo pode desencadear uma ação regulatória ou uma taxa para o operador; um falso negativo deixa emissões sem contabilização. O ponto de operação certo na curva precisão-revocação depende da decisão posterior, não apenas da pontuação F1.

Física/explicabilidade como salvaguarda

Você consegue explicar os resultados de um modelo de IA? A física nos mantém com os pés no chão, sobretudo em aplicações em que a confiança é crucial.

Caminho de implantação e adesão das partes interessadas

Quem aceita os resultados: reguladores, operadores, auditores? O desempenho técnico sozinho não basta sem confiança institucional.

A disponibilidade de dados define o escopo

Dados mais ricos: América do Norte (p. ex., GHGRP), UE (p. ex., ETS). Dados escassos: a maior parte do Sul Global. A cobertura que seu modelo afirma ter pode não se confirmar onde ela mais importa para a contabilidade global.

IA ética e responsável na contabilidade de carbono

Implicações de vigilância

- A detecção por satélite de emissões de instalações feita por terceiros cria uma camada independente de monitoramento. Mas também levanta questões:
  - Quem deveria poder relatar? O caminho de aprovação da EPA para relatores de superemissores é um modelo para regular o acesso.
  - Quem controla os dados?

Desempenho desigual entre geografias

- Modelos treinados em regiões ricas em dados (EUA, UE) muitas vezes pioram em regiões com poucos rótulos (Sul da Ásia, África, América Latina), onde uma contabilidade precisa pode ser mais importante para o progresso global.
- O desempenho de referência em dados nacionais reservados não é evidência suficiente de prontidão para implantação global.

Quem arca com as consequências dos erros?

- Falsos positivos: um operador é apontado para uma ação regulatória que não provocou. Se o modelo estiver errado, quem é responsável?
- Falsos negativos: as emissões passam despercebidas, minando a integridade dos mercados de carbono ou permitindo descartes ilegais.
- Em ambos os casos, os afetados raramente são os desenvolvedores do modelo.

Transparência e contestabilidade

- Uma estimativa de emissões derivada de satélite que gera uma taxa regulatória precisa ser explicável. Modelos caixa-preta criam desafios para o devido processo.
- Que recurso um operador tem para contestar uma detecção? Órgãos de normalização (ISO, OMM, Verra) começam a tratar disso para os mercados de carbono.
- Modelos de código aberto e conjuntos de dados de referência públicos (METER-ML, EMIT L2B) favorecem o escrutínio. Sistemas proprietários sem divulgação minam a confiança.

Como começar: dados, ferramentas e problemas em aberto

Conjuntos de dados abertos e benchmarks

METER-ML

Benchmark multissensor para detecção de infraestrutura de metano (CAFOs, aterros, poços, unidades de processamento).
https://stanfordmlgroup.github.io/projects/meter-ml/

Climate TRACE

Inventário aberto de emissões por instalação para mais de 352 milhões de ativos em todos os grandes setores. API gratuita + download em CSV.
Climatetrace.org

TROPOMI / Sentinel-5P

Produtos diários e globais da ESA de colunas de metano e CO. Gratuitos pelo Copernicus Open Access Hub.
https://scihub.copernicus.eu/

Portal de dados da Carbon Mapper

Recuperações de metano e dióxido de carbono do Tanager, do EMIT e de diversos instrumentos aerotransportados:
data.carbonmapper.org

Problemas de pesquisa em aberto

- Melhor quantificação de incerteza nas cadeias completas de quantificação de plumas
- Benchmarks de generalização entre sensores/geografias
- Coleta escalável de verdade de campo para setores difíceis de rotular (agricultura, cimento)
- Integrar as detecções de IA aos marcos regulatórios de relato
- Aplicar a dados espectrais de sensoriamento remoto modelos de base com pré-treinamento informado pela física
- Fechar em escala a lacuna entre a inversão atmosférica e a atribuição por instalação

Encerramento: o que vimos e o que está em aberto

✅ O que vimos

- Por que e como funciona a contabilidade de carbono
- Estimativa bottom-up versus top-down
- Monitoramento de CH_4/CO_2 por satélite
- Métodos de inversão atmosférica
- IA para dados de atividade
- IA para detecção de plumas
- Usar a IA para agilizar a tomada de decisão
- Quantificação da incerteza

🔭 Questões em aberto e além desta aula

- Contabilidade corporativa e da cadeia de suprimentos (abordada brevemente)
- Avaliação do ciclo de vida com IA
- IA para fortalecer os processos de auditoria
- Fusão de sensores (satélite + solo + aeronave)
- Governança de modelos, padrões e certificação

Hora de mais perguntas/discussão

Quiz

P1 *Múltipla escolha*

Qual das alternativas descreve melhor a principal limitação da contabilidade de carbono bottom-up?

A. Exige observações por satélite, que são caras

B. Depende de dados de atividade autodeclarados e fatores de emissão que podem não refletir as emissões locais reais

C. Só pode ser usada para CO_2, não para metano

D. Só se aplica a países desenvolvidos com marcos regulatórios sólidos

P2 *Múltipla escolha*

Na cadeia de processamento de plumas de metano de alta resolução, qual etapa tem atualmente a MENOR verdade de campo disponível para treinar ou avaliar modelos de IA?

A. Calibração das observações brutas de satélite

B. Recuperação de concentração com filtro casado

C. Detecção de plumas

D. Quantificação de emissões

P3 *Verdadeiro/Falso*

Verdadeiro ou falso: modelos de base da Terra (p. ex., Clay) superaram abordagens baseadas em CNN na detecção de plumas de metano nos experimentos com o Tanager descritos nesta aula.

P4 *Múltipla escolha*

Uma empresa quer implantar um detector de plumas de metano baseado em IA para apoiar uma iniciativa de relato do Programa de Superemissores. Que consideração deve influenciar mais a escolha do limiar de decisão (compromisso precisão/revocação)?

A. Maximizar a pontuação F1 geral no conjunto de teste reservado

B. O custo relativo de falsos positivos versus falsos negativos, dadas as consequências regulatórias e financeiras posteriores

C. Usar o mesmo limiar do melhor artigo publicado sobre detecção de plumas

D. Minimizar o tempo de inferência para permitir alertas em tempo real

Leituras prévias

Joyce et al. (2023) — METER-ML: A Multi-Sensor Earth Observation Benchmark for Automated Methane Source Mapping

Jacob et al. (2022) — Quantifying methane emissions from the global scale down to point sources using satellite observations