

Campinas, SP / Dezembro, 2025

Identificação e caracterização de infraestruturas em propriedades rurais utilizando imagens de sensoriamento remoto

Sérgio Aparecido Braga da Cruz⁽¹⁾, Matheus Papa de Almeida⁽²⁾, Julio Cesar Dalla Mora Esquerdo⁽¹⁾ e Ivan Bergier Tavares de Lima⁽¹⁾

⁽¹⁾ Pesquisador, Embrapa Agricultura Digital, Campinas, SP. ⁽²⁾ Tecnólogo em Análise e Desenvolvimento de Sistemas, mestre em Engenharia Agrícola, bolsista na Embrapa Agricultura Digital, Campinas, SP.

Introdução

O desafio constante do aumento de produtividade aliado a práticas sustentáveis de produção impõe a necessidade de monitoramento, análise, planejamento e execução de ações que promovam o crescimento do setor agropecuário (Vieira Filho et al., 2019). A existência de dados em diferentes escalas espaciais e temporais é essencial para a realização destas atividades, e subsidia a gestão desde o nível de propriedade rural até o nível nacional para apoio na definição de políticas públicas.

O tema da agricultura de precisão (AP) descreve métodos e ferramentas para coleta de dados em alta resolução espacial em nível de talhão de produção. Em AP são utilizados sensores embarcados em maquinários agrícolas, equipamentos proximais ou de contato capazes de medir em alta resolução espacial grandezas que caracterizam os solos e as culturas. (Grego et al., 2023; Hegedus et al., 2023). De forma complementar, a identificação e caracterização da infraestrutura existente na propriedade rural possibilitam avaliar aspectos qualitativos e quantitativos na sua produção. Galpões, áreas de secagem de grãos, pivôs de irrigação, maquinários, painéis de energia solar, áreas de pastagem exemplificam itens de recursos e de infraestrutura físicos de uma propriedade rural que indicam a sua

capacidade produtiva. (Fogle; Kime, 2024; Llanto, 2012; Yu et al., 2025)

A identificação e caracterização destas infraestruturas podem ser realizadas com maior acurácia através de seu mapeamento local, por técnicos especializados com ferramentas específicas ou de forma voluntária por usuários utilizando aplicativos móveis. No entanto, o deslocamento de técnicos eleva os custos da coleta de dados de campo e a delegação desta atividade de coleta para usuários voluntários requer algum mecanismo de validação para confirmação dos dados fornecidos. Os gastos para esta coleta de dados aumentam consideravelmente quando consideramos o levantamento de dados de uma região, município ou estado, podendo inviabilizar a realização desta atividade. (Branthomme, 2012; Koenig et al., 2000). O uso de satélites para sensoriamento remoto representa uma alternativa para levantamento desses dados com capacidade de abranger grandes áreas de cobertura de superfície com alta precisão. O número cada vez maior de satélites tem aumentado a oferta de dados obtidos por sensoriamento remoto. Cada coleção de dados desses satélites possui características específicas de resolução espacial, temporal, espectral e radiométrica (Dritsas; Trigka, 2025; Macário et al., 2020)

e possibilita a cobertura de grandes áreas da superfície terrestre chegando ao nível global. No entanto, a utilização direta de imagens de sensoriamento remoto na identificação e caracterização de alvos na superfície terrestre se mostra ineficiente quando verificamos a escala e distribuição dispersa de alguns itens de infraestrutura de uma propriedade rural e os requisitos de acurácia necessários para descrevê-los.

A aplicação direta de métodos baseados em algoritmos de inteligência artificial (IA), comumente utilizados para identificação de objetos em fotos, apresenta algumas limitações quando empregados na identificação de itens de infraestrutura com distribuição espacial esparsa em imagens de satélite de alta resolução. Alvos isolados e com distribuição espacial esparsa demandam um alto custo computacional de processamento e armazenamento, principalmente para análise de grandes áreas, uma vez que a imagem de satélite precisará ser dividida em um grande número de pedaços de tamanho compatível com os modelos de identificação de objetos (Sirko et al., 2021).

Se considerarmos um levantamento em escala de município, com dados de sensoriamento remoto de altíssima resolução espacial, no nível submétrico por exemplo, seria possível identificar de forma detalhada alguns itens de infraestrutura de uma propriedade rural, mas em contrapartida seria gerado um grande volume de dados que requer uma alta capacidade de recursos computacionais para processamento e análise. Além disso, existe um alto custo associado à aquisição de imagens de sensoriamento remoto em alta resolução. Por outro lado, se os dados de sensoriamento remoto são capturados em resoluções espaciais menores, os custos de aquisição se tornam menores, as áreas de cobertura serão maiores para um mesmo volume de dados, mas a caracterização detalhada de itens de infraestrutura torna-se inviável.

Neste trabalho propomos uma abordagem mista no uso de dados de sensoriamento remoto para caracterização de infraestrutura em propriedades rurais. Nessa abordagem, a análise de dados é realizada em duas etapas com o objetivo de explorar da melhor forma as características de resolução espaço-temporais das imagens de sensoriamento remoto de baixa e alta resolução e dos algoritmos utilizados para processá-las. Na primeira etapa são utilizadas imagens de sensoriamento remoto de menor resolução, porém de resolução suficiente para prospectar áreas com maior probabilidade de ocorrência das infraestruturas de interesse. Em uma segunda etapa, um conjunto de imagens de alta resolução das

áreas selecionadas pela primeira etapa é utilizado como entrada em procedimentos para detecção de objetos baseado em algoritmos de aprendizagem de máquina. A pré-filtragem realizada pela primeira etapa reduz o volume de imagens necessárias para processamento na segunda etapa, tornando mais eficiente o processamento global para identificação e caracterização da infraestrutura.

Dados de sensoriamento remoto

Atualmente existem inúmeros dispositivos de sensoriamento remoto desenvolvidos para as mais diferentes aplicações, com diferentes características. Esses dispositivos para observação da superfície terrestre estão embarcados em satélites, que possuem diferentes órbitas para imageamento. Um dispositivo de sensoriamento remoto é um instrumento que mede a energia, em diferentes comprimentos de onda, refletida e emitida pela superfície terrestre e que permite inferir as características desta superfície. A resolução de um sensor é uma das características fundamentais na determinação de quais tipos de dados ele pode coletar e em quais aplicações podem ser utilizados (Dritsas; Trigka, 2025, Estados Unidos, 2025), como ilustrado na Figura 1. A resolução de um sensor remoto pode ser de quatro tipos.

- Resolução radiométrica: determina como o valor da medida captada pelo sensor é representado numericamente. Em uma representação binária, quanto maior o número de bits para representação melhor é a discriminação dos valores das medidas.
- Resolução espacial: indica as dimensões da área da superfície terrestre representada por cada pixel. Esta característica é um fator importante na determinação da escala da aplicação em que os dados podem ser utilizados.
- Resolução espectral: indica a capacidade do sensor em discernir a medida de energia em diferentes comprimentos de onda. Quanto maior a resolução espectral de um sensor, maior é a sua capacidade de descrever em detalhes os tipos de materiais sobre a superfície terrestre.
- Resolução temporal: corresponde ao tempo que o dispositivo demora para dar uma volta em sua órbita e visitar uma mesma área.

Devido a suas características de projeto, dispositivos individuais de sensoriamento remoto

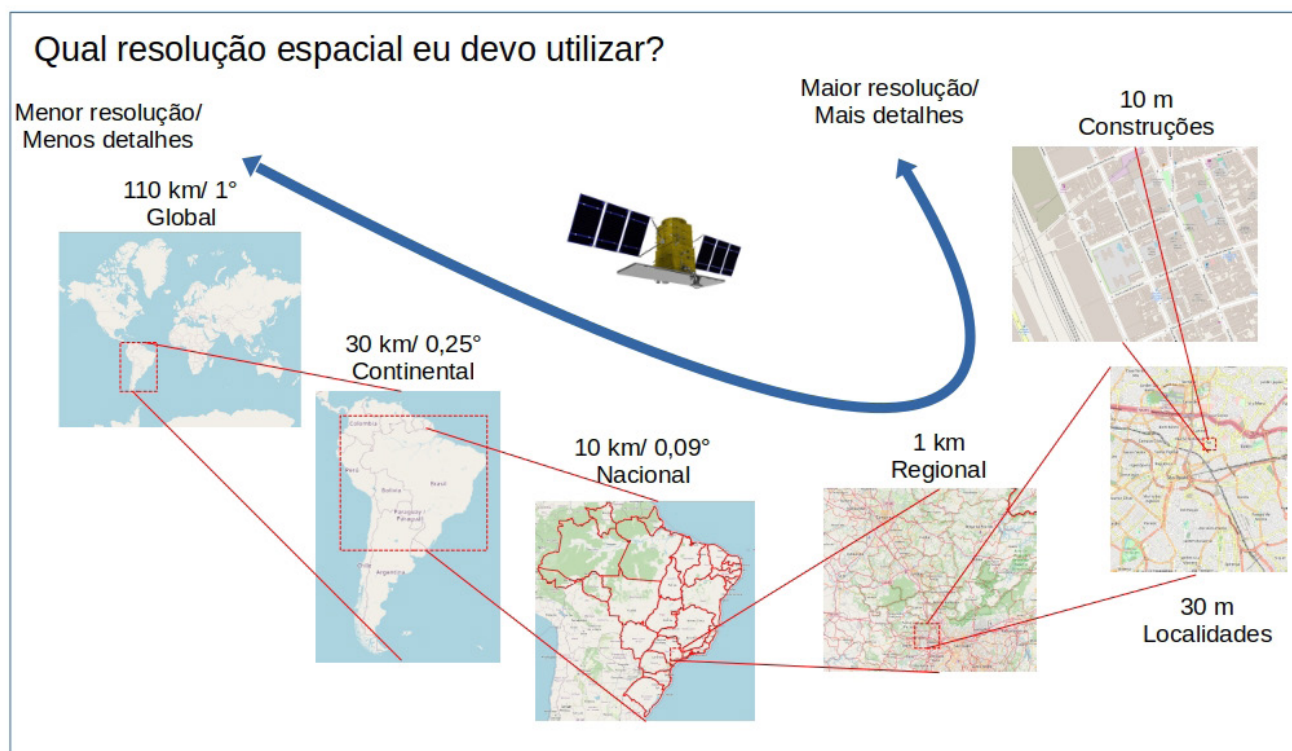


Figura 1. Resolução espacial e tipos de aplicação indicados.

Fonte: Adaptado de Estados Unidos (2025).

baseados em princípios ópticos possuem um conflito entre resolução espacial e resolução temporal (Xiao et al., 2023). Sensores com maior resolução espacial geralmente possuem uma menor resolução temporal. Isto permite a captura mais detalhada da superfície terrestre, porém com uma menor frequência. Como exemplo podemos citar a missão Sentinel-2, formada por 2 satélites que imageiam individualmente a superfície terrestre a cada dez dias, fornecendo dados de resolução espacial de 10x10 m por pixel. A combinação dos dois satélites possibilita o imageamento de cinco em cinco dias. Por outro lado, a missão Moderate-resolution Imaging Spectroradiometer (MODIS) fornece dados diários na resolução de 250x250 m e 1x1 km. A solução de sensoriamento remoto da PlanetScope consegue obter dados quase diários em alta resolução espacial de três a quatro metros por pixel utilizando uma constelação de cerca de 180 satélites individuais (Planet, 2025). A Tabela 1 descreve alguns satélites e suas características de resolução. Nessa tabela podemos ver o aumento do volume de pixels gerados e, consequentemente, a demanda para processamento que seria necessário para processá-los. Além do número de pixels, a demanda por processamento será maior quanto maior o número de bandas por pixel. Praticamente não existem opções de dados de satélite públicos com resolução espacial submétrica e, desta forma, a obtenção de dados com essa resolução representa um custo adicional

para análise. A coluna “Pixels x 1 km²”, da Tabela 1, dá uma indicação do aumento do volume de pixels a serem processados de acordo com a resolução espacial do satélite. Neste caso, para identificar alvos de interesse de infraestrutura em uma área de 1 km² seriam necessários processar 10.000 pixels (100x100 pixels) do Sentinel-2 e 11.111x10³ pixels (3.333x3.333 pixels) do WorldView 3, ou seja, um número mais de 1.000 vezes maior de pixels.

Ferramentas para identificação de objetos em imagens

A seguir são apresentados exemplos de ferramentas utilizadas na identificação de objetos em imagens. Ambas são baseadas em aprendizagem de máquina e redes neurais.

TorchGeo

A ferramenta TorchGeo (The Open Source Geospatial Foundation, 2025) é uma biblioteca que corresponde a uma especialização da ferramenta PyTorch (PyTorch, 2025), muito utilizada em aplicações envolvendo redes neurais. Na biblioteca TorchGeo, dados e funcionalidades estão adaptados para uso e integração de dados geoespaciais para construção de aplicações utilizando redes neurais profundas

Tabela 1. Características de resolução de alguns satélites/sensores.

Missão	Acesso aos dados	Sensor	Resolução		Bandas	Pixels x 1 km ² (1.000.000 m ²)
			Espacial (m)	Temporal		
MODIS	público/ gratuito	TERRA, AQUA	250, 500 e 1000*	2 dias	36	1 (1000 m) 4 (500 m) 8 (250 m)
Landsat-8	público/ gratuito	OLI	30	16 dias	8	1111
Sentinel-2/MSI	público/ gratuito	A, B	10, 20 e 60	5 dias (combina- dos)	13	10000 (10 m) 2500 (20 m) 277 (60 m)
CBERS 4A	público/ gratuito	WPM	2 e 8	31 dias	6	250000 (2 m) 15625 (8 m)
PlanetScope	comercial/pago	PSB.SD SuperDove	3.7	~1 dia	8	73046
WorldView 3 ⁽¹⁾	comercial/pago	WV110	0,3 (pancromática)	< 1 dia	36	11.111x10 ³ (0,3 m)

⁽¹⁾ Satélite comercial, além da banda pancromática são coletadas outras bandas em diferentes resoluções espaciais.

Fonte: Brazil Data Cube (2020), Instituto Nacional de Pesquisas Espaciais (2025), Planet (2025), WorldView [...] (2023).

especializadas no tratamento de dados de sensoriamento remoto. Ela inclui um conjunto de modelos pré-treinados de rede neurais específicos para este tipo de dado, e fornece mecanismos para tratamento adequado dos valores das bandas de dados de imagem, possibilitando a integração de diferentes fontes de sensoriamento remoto. O processamento de grandes imagens para identificação de alvos de interesse requer a divisão da imagem em um conjunto de células tratadas individualmente. Cada célula, normalmente definida no tamanho de 256x256 pixels, deve ter seu tamanho adaptado, dependendo das dimensões do alvo e da compatibilidade com o tamanho das células utilizadas durante o treinamento do modelo de detecção de alvos (Stewart et al., 2022). A construção de uma aplicação para identificação de alvos envolve o desenvolvimento de um programa em Python combinando funcionalidades para carregamento e preparação de dados de treinamento, configuração da arquitetura da rede neural, configuração de parâmetros do treinamento e execução do treinamento. Para esse desenvolvimento é necessário um conhecimento mais profundo sobre as características dos dados de sensoriamento remoto a serem processados e sobre a parametrização necessária para obtenção de um modelo de rede neural treinado efetivo.

Yolo

O Yolo é uma ferramenta de visão computacional que possibilita a realização de tarefas de detecção, segmentação e classificação de objetos (Redmon;

Farhadi, 2017; Ultralytics, 2025b). Essa ferramenta é baseada em técnicas de *Machine Learning* (ML) utilizando *Deep Neural Network* (DNN). Para realização dessas tarefas, o Yolo conta com um modelo de rede neural previamente treinado para identificação de uma série de objetos. Para identificar um objeto em uma imagem de entrada, o Yolo a divide em uma grade e, para cada célula, gera múltiplas caixas delimitadoras (*bounding boxes*) candidatas, atribuindo a cada uma delas uma pontuação de confiança que indica a probabilidade de conter um objeto. As caixas delimitadoras são selecionadas e redimensionadas de forma a manter as que possuem o maior grau de confiança no algoritmo denominado *Non Max Suppression* (NMS). Ao final do processamento, o Yolo indica caixas delimitadoras finais demarcando os objetos identificados, juntamente com o grau de confiança sobre a detecção. Normalmente, nesse algoritmo são utilizadas imagens de tamanho de 640x640 pixels. Imagens maiores fornecidas ao Yolo são redimensionadas com manutenção da proporção de sua largura e altura de modo que a maior dimensão possua 640 pixels. (Redmon; Farhadi, 2017; Ultralytics, 2025a). A utilização do Yolo está baseada em uma interface de mais alto nível, que pode ser utilizada programaticamente ou por linha de comando. Para o treinamento de um novo modelo de identificação de objetos, é necessário indicar um modelo base do Yolo, fornecer um conjunto de imagens de amostra rotuladas com a localização dos objetos de interesse e definir os parâmetros de treinamento.

As imagens utilizadas pelo Yolo podem ser coloridas ou até em preto e branco, e dados de georreferenciamento são ignorados.

Pode ser notado nestas duas ferramentas que a demanda por processamento é diretamente proporcional às dimensões da área em análise. A ocorrência esparsa de alvos implica que a maior parte do processamento será realizado em áreas onde eles estão ausentes. Uma otimização no uso dos recursos computacionais pode ser obtida se o processamento for realizado em áreas com indícios da presença do alvo.

Identificação e caracterização de infraestruturas em propriedades rurais

Neste trabalho é proposto o uso de imagens de resolução não submétrica para construção de proxies (Ghaffarian et al., 2018) para indicação de locais com maior probabilidade de ocorrência do alvo de interesse. Imagens de menor resolução propiciam uma maior área de cobertura de análise para um mesmo volume de dados e ampliam a possibilidade de construção de proxies baseados em comportamento espacial, temporal e espectral dos alvos de interesse. Proxies podem também ser utilizados para construção de máscaras para exclusão de regiões com baixa probabilidade de ocorrência dos alvos. Utilizando esta filtragem prévia, o uso de ferramentas para identificação de objetos como o Yolo ou o TorchGeo pode ser direcionado para áreas menores, compatíveis com os requisitos de imagem dessas ferramentas, e onde existe maior chance de ocorrência do alvo. Com a redução da necessidade de uso de imagens de alta resolução espacial, principalmente para trabalhos abrangendo grandes áreas de análise, os custos para aquisição desse tipo de imagem podem ser reduzidos juntamente com o esforço computacional para seu processamento.

Estudo de caso

Como prova de conceito, a abordagem proposta foi utilizada na identificação e caracterização de galpões de granja no município de Santa Helena (PR). As dimensões de um galpão são muito pequenas quando comparadas com a área de análise e sua distribuição espacial é dispersa sobre a área rural do município. A Tabela 2 resume as características de imagens Sentinel-2 e CBERS-4A WPM utilizadas nesse processamento. As imagens Sentinel-2

foram utilizadas por serem de acesso público e por apresentarem as melhores resoluções espaciais, temporais e espectrais disponíveis na plataforma do GEE (Google Earth Engine). O sensor CBERS-4A WPM foi utilizado por apresentar a maior resolução espacial disponível, com acesso público e gratuito, sem restrições para uso em aplicações baseadas em aprendizagem de máquina. Para fins de comparação, a Tabela 2 também apresenta as características da imagem ESRI Satélite Base, referente à mesma área do município de Santa Helena.

Na primeira etapa de processamento, foi gerado um conjunto de dados a partir do sensor Sentinel-2, com resolução espacial de 10x10 m. Esse conjunto é formado por médias de bandas originais do Sentinel-2, por índices e estatísticas de séries temporais que evidenciam características espectrais e temporais de um galpão. Amostras de galpões, juntamente com esse conjunto foram utilizados para construção de um modelo de classificação baseado no algoritmo Random Forest, o qual foi usado para identificar subáreas de ocorrências possíveis de galpões no município de Santa Helena. Na segunda etapa de processamento, estas subáreas selecionadas foram utilizadas para recortar imagens CBERS-4A WPM de resolução espacial de 2x2 m. Essas imagens de mais alta resolução recortadas possuem dimensões mais adequadas para os algoritmos utilizados pelas ferramentas de aprendizagem de máquina com rede neural utilizada na identificação de objetos. Amostras de imagens de galpões foram também utilizadas nessa etapa para treinar o modelo de rede neural. A ferramenta Yolo foi utilizada nessa segunda etapa em razão de sua simplicidade na construção de modelos para identificação de objetos, sem a necessidade de implementação envolvendo tratamento de dados georreferenciados. Os galpões, usados como amostras de treinamento do Yolo, foram anotados em imagens em tons de cinza obtidas diretamente das imagens da banda 0 do CBERS-4A WPM.

O mapeamento das subáreas possibilitou a redução da área para caracterização de galpões na imagem CBERS-4A de aproximadamente 1233,72 km² para cerca de 5 km². Nesse estudo de caso ocorreu uma redução significativa da área, superior a 95%.

A Figura 2 apresenta um esquema ilustrativo do funcionamento de um procedimento para identificação e caracterização de galpões utilizando diretamente ferramentas de detecção de objetos baseados em IA sobre imagens de alta resolução. Nesse esquema, toda a imagem original é dividida em pequenos pedaços, os quais são utilizados como dado de entrada para o Yolo. Akyon et al. (2022)

Tabela 2. Comparação entre processamento de alta resolução x média resolução.

	Dataset não submétrico (Base Sentinel-2)	Máscara sobre dataset não submétrico (Base Sentinel-2)	Dataset CBERS-4A WPM	Dataset submétrico (Base ESRI Satélite) Exemplo
Bandas	Band 1: B3_mean Band 2: B2_mean Band 3: B4_mean Band 4: NDVI_mean Band 5: NDBI_mean Band 6: LST_Galpoes_mean Band 7: SAVI_mean	-	Band 1	Band 1: Red Band 2: Green Band 3: Blue Band 4: Alpha
Dimensões	X: 3476 Y: 3863 Bands: 7	-	X: 16164 Y: 19539 Bands: 1	X: 69502 Y: 85148 Bands: 4
Tamanho	308,48 MB	...	602,51 MB	22,05 GB
Tamanho do Pixel (m)	8,98x8,98	-	2x2	0,5x0,5
Tipo do dado	Float32	-	Int16	Byte unsigned integer
Área (km²)	+/-1233,72	5,04	+/-1233,72	+/-1233,72

Traço (-): informação idêntica à do dataset não submétrico.

Três-pontos (...): informação não calculada.

**Imagem alta-resolução
CBERS4A WPM B0**

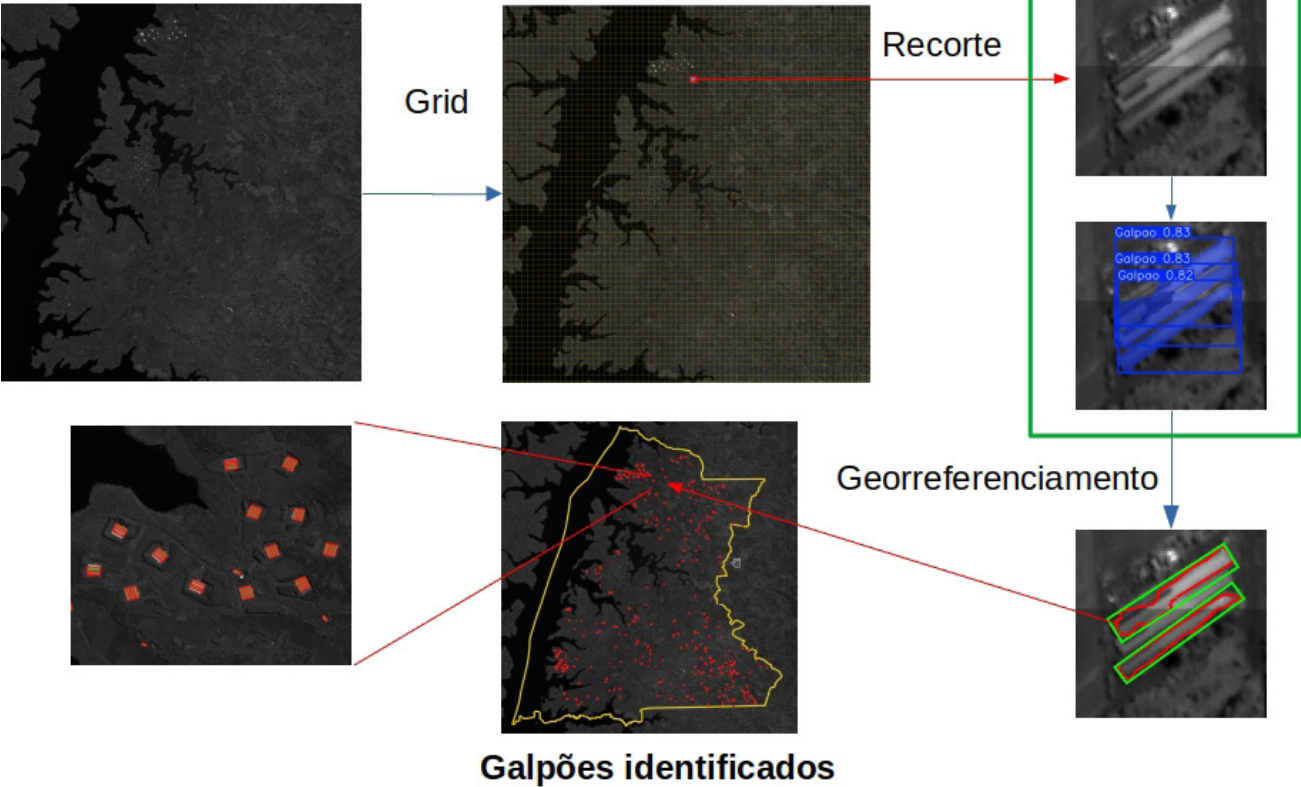


Figura 2. Identificação e caracterização de galpões usando fatiamento de imagem de alta resolução.

propuseram uma abordagem semelhante a essa, utilizando o recurso de fatiamento da imagem original para detecção de pequenos objetos.

A Figura 3 apresenta o esquema proposto nesse trabalho, formado por duas etapas para identificação e caracterização de infraestruturas em áreas rurais. Nessa proposta, as ferramentas para detecção de objetos baseadas em IA tem um uso otimizado para regiões da imagem com maior probabilidade de ocorrência dos galpões. As características desse alvo propiciaram que fossem criados critérios para a exclusão de grande parte das áreas para a segunda etapa.

A taxa de erro na detecção de objetos pela ferramenta baseada em IA é conhecida, resultado da qualidade e quantidade de amostras de treinamento utilizadas, ajustes de parâmetros de treinamento, escolha inicial do modelo base e da qualidade das imagens. A inclusão da etapa de pré-filtragem baseada em imagens de média resolução, que neste estudo de caso correspondem às imagens Sentinel-2, tem impacto importante se existirem erros de omissão. Nesse caso, nenhuma imagem de uma área contendo galpões será fornecida para a segunda etapa de análise e consequentemente esses galpões não serão identificados e caracterizados. A fim de reduzir esse tipo de erro, é possível realizar uma inspeção

visual para identificar galpões omitidos pelo classificador e incorporá-los como novas amostras no processo de refinamento do modelo. Erros de comissão nessa primeira etapa podem indicar indícios de presença de galpões em locais onde eles não existem, implicando em processamento desnecessário do Yolo, porém não afetam o resultado do número de galpões identificados. A existência de erros de comissão não teria um grande impacto neste caso, uma vez que a área de análise tratada pelo Yolo já foi reduzida consideravelmente.

Nesse estudo de caso, o modelo de classificação Random Forest utilizado nessa primeira etapa foi treinado com um conjunto de cerca de 2.500 amostras de pixels na região Oeste do Paraná, considerando as classes de galpões com cobertura metálica e cerâmica, estradas, áreas com vegetação rasteira, solo exposto e água. As classes adicionais além dos galpões foram incluídas com o objetivo de reduzir confusões na classificação.

Considerando 300 amostras de teste no município de Santa Helena, foi obtida a seguinte matriz de confusão agregada, apresentada na Tabela 3, considerando galpões de cobertura metálica, cerâmica e outras classes.

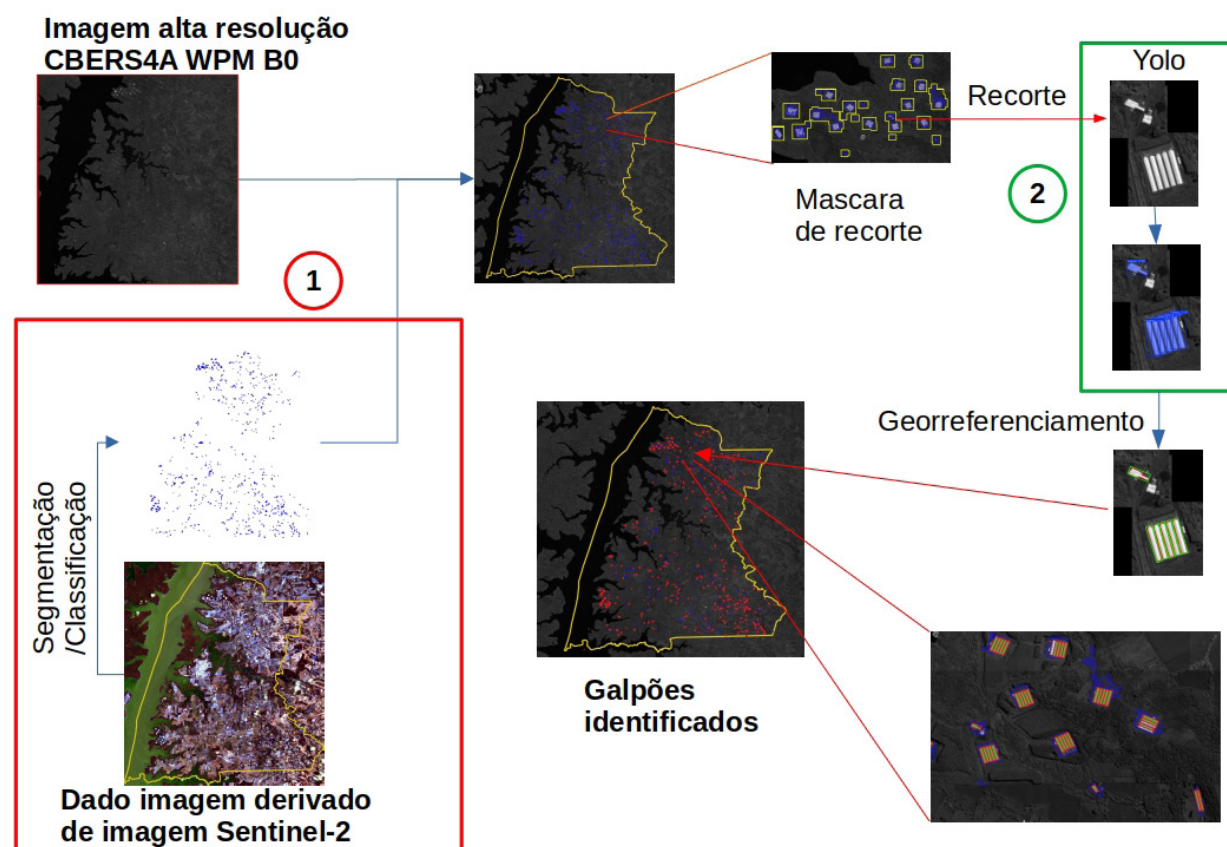


Figura 3. Identificação e caracterização de galpões em duas etapas, utilizando imagens de média resolução e recortes selecionados de imagens de alta resolução.

Tabela 3. Matriz de confusão agregada para classificação de galpões.

Classe	Galpão cerâmico	Galpão metálico	Outras classes
Galpão cerâmico	49	1	0
Galpão metálico	1	45	4
Outras classes	1	1	198

Tabela 4. Acurácia e erros na classificação de galpões.

Classe	Verdadeiro positivo	Total real	Total previsto	AP (%)	AU (%)	Erro de Omissão (1-AP) (%)	Erro de Comissão (1-AU) (%)
Galpão cerâmico	49	50	51	98	96,1	2	3,9
Galpão metálico	45	50	47	90	95,7	10	4,3
Galpão agregado	96	100	98	96	98,0	4	2,0

A acurácia do produtor (AP), indicativo de quantos pixels foram classificados corretamente como galpões cerâmicos e metálicos, é apresentada na Tabela 4, juntamente com a acurácia do usuário (AU) e erros de omissão e comissão correspondentes.

Nesse estudo de caso, para o município de Santa Helena o classificador apresentou o erro de omissão de 2% para galpões cerâmicos e 10% para galpões metálicos, porém como existe confusão entre essas duas classes, a classificação como galpão apresenta alta acurácia, com baixo erro de omissão para galpões, no valor de 4%. A acurácia global da classificação ficou em 98%. A alta acurácia associada ao baixo valor do erro de omissão sugere que o total de galpões identificados está ligeiramente abaixo do número real. Isto considerando um resultado ótimo do processamento do Yolo. Deve-se considerar também que essa análise estatística se baseia em pixels individuais, e não em objetos completos identificados.

Para identificação e caracterização dos galpões no município de Santa Helena, a área final filtrada corresponde aproximadamente a 5 km². Essa área resultou em 574 imagens recortadas e enviadas para identificação de objetos pelo Yolo, formando um volume total de 7,7 MB, e que foram processadas em 28,4 segundos. Este processamento foi realizado em um notebook i7-9750, com 32 GB de RAM e placa gráfica NVIDIA GeForce GTX 1660 Ti. O processamento dos dados do Sentinel-2 foi realizado na infraestrutura do Google Earth Engine, por meio de um script em Python executado em 134,88 segundos.

Considerações finais

A combinação de imagens de sensoriamento remoto de resolução espacial não submétrica e de alta resolução em duas etapas de processamento possibilita o uso racional de recursos computacionais na identificação e caracterização de infraestruturas de propriedades rurais, podendo ser utilizado em diferentes aplicações em que seja necessária a análise de grandes áreas com alvos com dimensões reduzidas e espacialmente dispersos.

Na primeira etapa, o uso de dados de sensoriamento remoto de baixa resolução para construção de proxies indicativos de ocorrência de alvos de interesse propicia uma pré-filtragem e redução de áreas a serem analisadas na segunda etapa, em que são utilizados mecanismos baseados em aprendizagem de máquina sobre imagens de alta resolução. O uso de imagens não submétricas na primeira etapa possibilita:

- Menor custo de aquisição de imagens: existem muitos sensores de até 10 m de resolução, com custo zero ou baixo custo. A varredura de uma área mais abrangente pode ser realizada a um menor custo.
- Maior resolução temporal: normalmente, sensores de menor resolução espacial possuem maior resolução temporal. Isso possibilita um menor custo para análises envolvendo séries temporais.
- Menor custo de processamento: a menor resolução espacial está associada a um menor detalhamento espacial e consequentemente uma menor quantidade de dados por área de cobertura, exigindo uma menor demanda de processamento por área de análise.

Na segunda etapa de processamento o volume de dados a ser processado é reduzido após a filtragem e, conseqüentemente, os gastos com recursos computacionais de armazenamento e processamento também são reduzidos.

Uma extensão deste trabalho pode ser a construção de proxies a partir da existência de determinados recursos de infraestrutura ou características de uma propriedade rural. Por meio dessas evidências, podem ser traçados e classificados perfis de uma propriedade rural ou região de análise. Outra possibilidade seria o uso inverso das ocorrências de alvos encontrados na etapa de alta resolução. Esses alvos podem ser utilizados como amostras parciais e, juntamente com as imagens não submétricas correspondentes, alimentar um mecanismo de aprendizagem de máquina para localização de áreas semelhantes às áreas do alvo encontrado, porém sob diferentes regiões. Dada a identificação e caracterização de uma cultura em um talhão, por exemplo, talhões com características semelhantes poderiam ser localizadas em outras áreas da propriedade, ou mesmo em uma região de análise maior, sendo um indicativo de presença da mesma cultura.

Agradecimentos

Este trabalho é resultado do projeto “AgroGeo - Desenvolvimento de sistema de validação geográfica de dados e sua customização para auditoria e análise de risco de crédito” que contou com o apoio financeiro parcial da Instituição Agroforte Securitizadora Consultoria e Serviços Financeiros, sob contrato 23800.23/0016-3.

Referências

AKYON, F. C.; ALTINUC, S. O.; TEMIZEL, A. Slicing aided hyper inference and fine-tuning for small object detection. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (ICIP), 2022, Bordeaux. **Proceedings** [...]. Piscataway: IEEE, 2022. p. 966-970. DOI: 10.1109/ICIP46576.2022.9897990.

BRANTHOMME, A. (ed.). **Manual for integrated field data collection**: National Forest Monitoring and Assessment. Version 3.0. 1st ed. Rome: FAO, 2012. (NFMA Working Paper, 37/E).

BRAZIL DATA CUBE. **BDC input data**. 2020. Disponível em: <https://brazil-data-cube.github.io/specifications/input-data.html>. Acesso em: 24 ago. 2025.

DRITSAS, E.; TRIGKA, M. Remote sensing and geospatial analysis in the big data era: a survey. **Remote Sensing**, v. 17, n. 3, 550, Feb. 2025. DOI: <https://doi.org/10.3390/rs17030550>.

ESTADOS UNIDOS. National Aeronautics and Space Administration. **Remote sensing**. Disponível em: <https://www.earthdata.nasa.gov/learn/earth-observation-data-basics/remote-sensing>. Acesso em: 24 ago. 2025.

FOGLE, N.; KIME, L. **Agriculture and infrastructure: what's the connection?** 2024. Disponível em: <https://extension.psu.edu/agriculture-and-infrastructure-whats-the-connection>. Acesso em: 24 ago. 2025

GHAFFARIAN, S.; KERLE, N.; FILATOVA, T. Remote sensing-based proxies for urban disaster risk management and resilience: a review. **Remote Sensing**, v. 10, n. 11, 1760, Nov. 2018. DOI: <https://doi.org/10.3390/rs10111760>.

GREGO, C. R.; SPERANZA, E. A.; RODRIGUES, G. C.; LUCHIARI JÚNIOR, A.; VENDRUSCULO, L. G.; RODRIGUES, C. A. G.; INAMASU, R. Y.; VAZ, C. M. P.; RABELLO, L. M.; JORGE, L. A. de C.; ZOLIN, C. A.; FRANCHINI, J. C.; RONQUIM, C. C. Technologies developed in precision agriculture. In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; OLIVEIRA, S. R. de M.; MEIRA, C. A. A.; LUCHIARI JUNIOR, A.; BOLFE, E. L. (Ed.). In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; OLIVEIRA, S. R. de M.; MEIRA, C. A. A.; LUCHIARI JUNIOR, A.; BOLFE, E. L. (ed.). **Digital agriculture: research, development and innovation in production chains**. Brasília, DF: Embrapa, 2023. cap. 7, p. 125-144. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1156753/1/LV-Digital-agriculture-2023-cap7.pdf>. Acesso em: 8 ago. 2025

HEGEDUS, P. B.; MAXWELL, B.; SHEPPARD, J.; LOEWEN, S.; DUFF, H.; MORALES-LUNA, G.; PEERLINCK, A. Towards a low-cost comprehensive process for on-farm precision experimentation and analysis. **Agriculture**, v. 13, n. 3, 524, Mar. 2023. DOI: <https://doi.org/10.3390/agriculture13030524>.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (Brasil). **Câmeras imageadoras**. 2024. Disponível em: <https://www.gov.br/inpe/pt-br/programas/cbers/sobre-o-cbers-1/cbers-04a/cameras-imageadoras>. Acesso em: 24 ago. 2025.

KOENIG, R. T.; WINGER, M.; KITCHEN, B. Simple, low-cost data collection methods for agricultural field studies. **The Journal of Extension**, v. 38, n. 2, 2, 2000. Disponível em: <https://open.clemson.edu/joe/vol38/iss2/2>. Acesso em: 24 ago. 2025

LLANTO, G. M. **The impact of infrastructure on agricultural productivity**. Makati City: Philippine Institute for Development Studies, 2012. (Discussion paper series, no. 2012-12)

MACÁRIO, C. G. do N.; ESQUERDO, J. C. D. M.; COUTINHO, A. C.; SPERANZA, E. A.; SILVA, J. dos S. V. da; ANTUNES, J. F. G.; VENDRUSCULO, L. G.; CRUZ, S. A. B. da. Geotecnologias

na agricultura digital. In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; OLIVEIRA, S. R. de M.; MEIRA, C. A. A.; LUCHIARI JUNIOR, A.; BOLFE, E. L. (Ed.). **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília, DF: Embrapa, 2020. cap. 4, p. 94-118. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1126226/1/LV-Agricultura-digital-2020-cap4.pdf>. Acesso em: 8 ago. 2025

PLANET. **Introduction to PlanetScope**. Disponível em: <https://university.planet.com/intro-to-planetscope/>. Acesso em: 22 out. 2025.

PYTORCH. Disponível em: <https://pytorch.org/>. Acesso em: 24 ago. 2025.

REDMON, J.; FARHADI, A. YOLO9000: better, faster, stronger. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 30., 2016, Honolulu. **Proceedings** [...]. Los Alamitos: IEEE, 2017. p. 6517-6526. DOI: <https://doi.org/10.1109/CVPR.2017.690>.

SIRKO, W.; KASHUBIN, S.; RITTER, M.; ANNKAH, A.; BOUCHARED, Y. S. E.; DAUPHIN, Y.; KEYSERS, D.; NEUMANN, M.; CISSE, M.; QUINN, J. **Continental-scale building detection from high resolution satellite imagery**. 2021. Disponível em: <https://arxiv.org/abs/2107.12283>. Acesso em: 24. ago. 2025.

STEWART, A. J.; ROBINSON, C.; CORLEY, I. A.; ORTIZ, A.; FERRES, J. M. L.; BANERJEE, A. TorchGeo: deep learning with geospatial data. In: ACM SIGSPATIAL INTERNATIONAL CONFERENCE ON ADVANCES IN GEOGRAPHIC INFORMATION SYSTEMS, 30., 2022,

Seattle. **Proceedings** [...]. New York: The Association for Computing Machinery, 2022. Editors: Matthias Renz, Mohamed Sarwat, Mario A. Nascimento, Shashi Shekhar, Xing Xie. DOI: <https://doi.org/10.1145/3557915.3560953>.

THE OPEN SOURCE GEOSPATIAL FOUNDATION. **TorchGeo**. Disponível em: <https://www.osgeo.org/projects/torchgeo/>. Acesso em: 24 ago. 2025.

ULTRALYTICS. **Detecção de objetos**. Disponível em: <https://docs.ultralytics.com/pt/tasks/detect/>. Acesso em: 24. ago. 2025a.

ULTRALYTICS. **Documentação Ultralytics YOLO**. Disponível em: <https://docs.ultralytics.com/pt/>. Acesso em: 24. ago. 2025b.

VIEIRA FILHO, J. E. R. (org.). **Diagnóstico e desafios da agricultura brasileira**. Rio de Janeiro: IPEA, 2019.

WORLDVIEW 3. 2023. Disponível em: <https://www.eoportal.org/satellite-missions/worldview-3#eop-quick-facts-section>. Acesso em: 24 ago. 2025

YU, Q.; HU, Q.; WU, H.; WU, W. View from above: farmland infrastructure and its impacts on agricultural landscapes. **The Innovation Geoscience**, v. 3, n. 1, 100107, Feb. 2025. DOI: <https://doi.org/10.59717/j.xinn-geo.2024.100107>.

XIAO, J.; AGGARWAL, A. A.; DUC, N. H.; ARYA, A.; RAGE, U. K.; AVTAR, R. A review of remote sensing image spatiotemporal fusion: challenges, applications and recent trends. **Remote Sensing Applications: Society and Environment**, v. 32, 101005, Nov. 2023. DOI: <https://doi.org/10.1016/j.rsase.2023.101005>.

Embrapa Agricultura Digital

Av. Dr. André Tosello, 209 - Cidade Universitária
Campinas, SP, Brasil
CEP. 13083-886
www.embrapa.br
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações

Presidente: *Júlio Esquerdo*
Secretária-executiva: *Sônia Ternes*
Membros: *Adauto Mancini, Alan Nakai, Carla Osawa, Geraldo Cançado, Graziella Galinari, Joice Bariani, Juliana Yassitepe, Luiz Cunha, Magda Cruciol e Paula Falcão*

Comunicado Técnico 142

e-ISSN 2764-7412
Dezembro, 2025

Revisão de texto: *Graziella Galinari*
Normalização bibliográfica: *Carla Osawa*,
CRB-8/10421
Projeto gráfico: *Leandro Sousa Fazio*
Diagramação: *Magda Cruciol*
Publicação digital: PDF



Ministério da
Agricultura e Pecuária

Todos os direitos reservados à Embrapa.