

# SENSORIAMENTO REMOTO APLICADO À IDENTIFICAÇÃO DE PLÁSTICOS NA AGRICULTURA

**Palavras-Chave:** SENSORIAMENTO REMOTO, PLASTICULTURA, MACHINE-LEARNING

**Autores:**

**MURILO HENRIQUE SOUZA DE OLIVEIRA, FEAGRI – UNICAMP**

**Prof. Dr. RUBENS AUGUSTO CAMARGO LAMPARELLI (orientador), NIPE - UNICAMP**

**Dr. MARLON FERNANDES DE SOUZA (coorientador), NIPE - UNICAMP**

---

## INTRODUÇÃO:

O uso de plásticos na agricultura é comumente chamado pelo termo "Plasticultura" e refere-se ao uso extensivo de materiais plásticos na agricultura, englobando práticas como, a cobertura do solo com filmes plásticos (mulching) e a utilização de estufas plásticas. Essas práticas são adotadas principalmente devido ao custo-benefício, à capacidade de economia de água e ao aumento da produtividade agrícola (Levin et al., 2007; Briassoulis et al., 2016; Wang, 2022). No entanto, a popularização da plasticultura tem levantado preocupações sobre o acúmulo de resíduos plásticos no solo, que podem causar diversos danos socioambientais a longo prazo. Este estudo tem como objetivo estudar e desenvolver modelos de machine learning (ML) no mapeamento de áreas com plasticultura, utilizando sensoriamento remoto para identificar os tipos de uso e extensão das áreas cobertas. Avaliando a viabilidade do uso de tecnologia de sensoriamento remoto para monitorar o uso de plásticos na agricultura, identificar os fatores que podem limitar a eficácia desse método. Este trabalho busca responder às seguintes perguntas: é possível identificar os tipos de plástico utilizados em estufas e no mulching? É possível determinar o nível de degradação desses plásticos? Será possível estimar a quantidade ou concentração desses materiais?

## METODOLOGIA:

O material fundamental empregado na execução do projeto inclui a interface do Google Earth Engine (GEE) (Google, 2024), que possibilita trabalho na nuvem e acesso a coleções de imagens provenientes do Copernicus Sentinel-2 (European Space Agency - ESA, 2023), a plataforma da Planet Labs PBC para obtenção de imagens de alta resolução da constelação de satélites PlanetScope (PLANET, 2024), o programa ArcGIS PRO para delimitação dos polígonos de amostragem, a plataforma Jupyter e Google Colab para acesso e processamento em Python 3, com destaque para a biblioteca scikit-learn (Pedregosa et al., 2011) para a aplicação de modelos de ML. Além disso, as áreas de estudo foram validadas por visitas e por análises utilizando imagens de alta resolução espacial de 30 cm acessadas pelo Google Earth (Google, 2024).

### Delimitação das áreas de estudo

As áreas de estudo escolhidas contemplam regiões com grande concentração de estufas e mulching. Porém devido à distância entre as regiões escolhidas e limitações do GEE, essas áreas foram separadas em duas. Ambas estão localizadas na região metropolitana de Campinas (RMC) no estado de São Paulo, sendo a região de estufas focada no município de Holambra e a de mulching em Sumaré e Monte Mor. Ambas as áreas possuem aproximadamente 330 km<sup>2</sup> e foram divididas ao meio em área de obtenção de amostras para treino e validação. Todas essas informações podem ser constatadas na Figura 1.

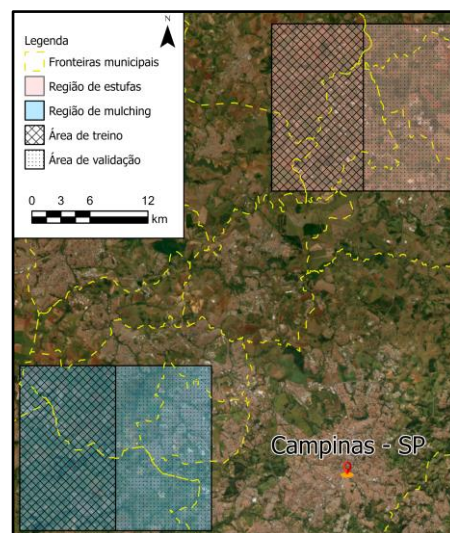


Figura 1. Apresentação das áreas de estudo.

### Delimitação das amostras

A delimitação das áreas de amostra foi realizada através de polígonos georreferenciados com apoio de imagens de alta resolução e dos dados de visita local. Essa etapa resultou em duas classes de polígonos: homogênea e buffer. A Figura 2 ilustra esse processo para o mulching, a classe homogênea é representada pelos polígonos em ciano, que abrangem toda a gleba, enquanto a classe buffer é representada pelos polígonos em vermelho, que delimitam um talhão específico. Esse processo também foi aplicado para as estufas.



Figura 2. Exemplo da metodologia de definição das áreas de amostragem.

### Coleção de imagens

A escolha das imagens de satélites considerou diversos fatores, como o volume de imagens disponíveis, quantidade de bandas espectrais, presença de nuvens nas imagens e principalmente a resolução por pixel. As coleções utilizadas neste estudo foram as do Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A obtidas e tratadas dentro do GEE e as da constelação PlanetScope obtidas pela plataforma da Planet. As imagens do PlanetScope têm uma resolução espacial superior, variando de 3 a 5 metros por pixel, enquanto as imagens do Sentinel-2 apresentam uma resolução de 10 a 60 metros por pixel. No entanto, as imagens do PlanetScope são de acesso pago.

### Confusão urbana e séries temporais

Além da limitação da resolução espacial e espectral das imagens, existe a proximidade das áreas de cultivo com centros urbanos, que em alguns casos são extremos como na Figura 3, o que causa elevada confusão entre a classificação das coberturas plásticas com telhados (Zhang et al., 2022). Por isso, é necessário um controle maior da quantidade de amostras extraídas em algumas delimitações específicas como a área urbana.



Figura 3. Estufas em conjunto com a área urbana na cidade de Holambra - SP.

Existe também a utilização de séries temporais na redução da confusão urbana (Lu et al., 2018; Aguilar et al., 2016), dos quais se destaca o aumento na acurácia na identificação de mulching, já que ele não é contínuo no tempo ao contrário das estufas, como demonstrado na Figura 4, onde em cima está uma área onde foi utilizado mulching ao longo do tempo e embaixo estufas nesse mesmo período. Por esse motivo, as



Figura 4. Ilustração do ciclo do mulching VS estufa para o mesmo período.

coleções de imagens utilizadas cobriram uma parcela significativamente maior de tempo, permitindo maior flexibilidade na escolha das imagens, além de possuírem subdivisões temporais.

### **Amostragem**

Responsável pela aquisição dos dados que alimentarão os modelos de ML utilizados. Essa etapa foi realizada na interface do GEE, onde tanto a área de estudo, as áreas de amostragem e as imagens foram importadas no code editor. Nesta etapa através da geração de pontos aleatórios por classe, foram obtidas informações de cada pixel da imagem e associado à respectiva classe, dessa forma em uma área combinada de mais de 660 km<sup>2</sup>, utilizando as imagens do Sentinel 2 foram coletados mais de 500 mil disponíveis para treino-teste e 300 mil para validação. As questões relacionadas à quantidade de amostras não são discutidas neste trabalho. Utilizando as imagens do PlanetScope, devido às limitações na aquisição dessas imagens, foram adquiridas 230 mil para treino teste e 200 mil para validação.

### **Treino, teste e validação do modelo**

Utilizando Python 3, foi realizado o treinamento dos modelos através do classificador Multi-layer Perceptron do pacote Scikit-Learn. Os dados de treino e teste obtidos de ambas as coleções de imagens foram utilizados ao máximo, e os modelos foram posteriormente aplicados aos respectivos conjuntos de validação para verificar sua acurácia e coletar dados para análise.

## **RESULTADOS E DISCUSSÃO:**

O modelo resultante com base nas imagens Sentinel 2, quando aplicado no conjunto de validação, apresentou uma acurácia geral de 0,9787, acurácia balanceada de 0,9665 e Kappa de 0,9369. Enquanto o modelo com utilização de imagens do PlanetScope apresentaram acurácia geral de 0,9907, acurácia balanceada de 0,9737 e Kappa de 0,9170. Foi construída então matrizes de confusão para identificar entre quais classes houve confusão nos modelos. Esse resultado pode ser visualizado na Tabela 1.

Tabela 1. Matriz de confusão dos modelos finais aplicados no conjunto de validação.

Utilizando coleção de imagens Sentinel 2					Utilizando coleção de imagens PlanetScope						
		Predito			Erro de omissão			Predito			Erro de omissão
		Mulching	Estufa	Outros				Mulching	Estufa	Outros	
Observado	Mulching	15633	1	444	0,9723	Observado	Mulching	4092	0	115	0,9727
	Estufa	0	45608	2862	0,9410		Estufa	0	7207	332	0,9560
	Outros	45	3462	252519	0,9863		Outros	1	1495	196070	0,9924
Erro de inclusão		0,9971	0,9294	0,9871	0,9787	Erro de inclusão		0,9998	0,8282	0,9977	0,9900

A partir da leitura dos resultados, é evidente que para ambos os modelos, a identificação entre mulching e estufa foi realizada com notável sucesso. Apresentando confusões próximas a 0% entre Mulching e Estufa apesar de suas semelhanças. A classe ‘outros’, que é composta por uma diversidade muito grande de elementos, acabou por ter uma confusão significativa para ambos os modelos. Considerando esses resultados, a maior dificuldade encontrada está na separação entre as classes ‘outros’ e estufas. O que ressalta a necessidade de ser realizada uma avaliação da qualidade das amostras e expansão das áreas de estudos. Essas tarefas podem ajudar no desenvolvimento de um conjunto de dados mais precisos para amostragens em larga escala. A divisão da classe ‘outros’ também possibilitaria uma maior compreensão e localização das fontes de confusão para os modelos.

Embora tenham sido elaborados modelos com duas coleções de imagens distintas, a comparação é desafiadora devido aos resultados similares e às limitações diferentes que complicam a padronização da coleta de amostras. As imagens Sentinel-2 são práticas pela acessibilidade e variedade de bandas, mas têm uma frequência de revisita menor (10 dias) em comparação com as imagens PlanetScope, que possuem revisitas diárias e maior resolução (3 a 5 metros por pixel), embora com bandas limitadas e maior dificuldade de obtenção.

Aplicando o modelo treinando com Sentinel-2 em imagens pré-tratadas (com máscara de nuvem e composição temporal) das áreas de validação para diferentes datas, que possuem juntas 330 km<sup>2</sup> foi realizada a identificação das áreas cobertas por mulching e estufas entre 2020 ao início de 2024. Os resultados dessa identificação estão apresentados na Tabela 2.

Tabela 2. Resultado do modelo na identificação das de mulching e estufa nas áreas de validação em km<sup>2</sup>.

Data	1º Semestre 2020	2º Semestre 2020	1º Semestre 2021	2º Semestre 2021	1º Semestre 2022	2º Semestre 2022	1º Semestre 2023	2º Semestre 2023	1º Semestre 2024
Estufa	2,6093	2,708	2,7421	3,0222	3,0425	3,5231	3,8415	3,2408	4,3064
Mulching	0,7262	0,6564	0,5167	0,5018	0,5660	0,7292	0,7917	0,4708	0,3497

A obtenção de informações desse modo possibilita uma compreensão rápida das mudanças da ocupação da terra para a plasticultura, fornecendo dados essenciais para políticas públicas e o planejamento territorial. Contudo, a aplicação do modelo fora da área de estudo ainda deve ser analisada com cautela, principalmente por meio de uma comparação dos resultados com imagens e visitas, para garantir a sua validação.

## CONCLUSÕES:

Retomando as perguntas iniciais, é possível identificar áreas de plasticultura por meio de sensoriamento remoto. Os modelos de ML mostraram resultados com altas acurácias (97 a 99%), especialmente na distinção entre mulching e estufa. A estimativa da quantidade de áreas pode ser realizada a partir das análises dos resultados de identificação, embora sejam necessários mais estudos para avaliar a possibilidade de analisar os níveis de degradação. A distinção entre mulching e estufas foi feita com sucesso, mas ainda há algumas imprecisões. No entanto, os resultados são promissores e indicam a viabilidade desses métodos para estudos futuros. A aplicação do modelo em áreas adicionais além das usadas para validação permitirá obter conclusões mais claras sobre sua eficácia.

O monitoramento e mapeamento das áreas de plasticultura são fundamentais para a realização e implementação de políticas públicas de planejamento territorial. Essas informações são essenciais para a gestão adequada dos resíduos gerados, permitindo a minimização dos impactos ambientais causados pelo uso de plásticos na agricultura, ao mesmo tempo em que se preservam as vantagens dessa prática. A possibilidade de utilização de modelos de ML para criar mapas dessa categoria, permitiria um grande avanço nas políticas de logística reversa em território nacional.

## BIBLIOGRAFIA

- AGUILAR, Manuel A. et al. Object-based greenhouse mapping using very high resolution satellite data and Landsat 8 times series. **Remote Sensing**, v. 8, n. 6, p. 513, 2016. DOI: 10.3390/rs8060513
- BRIASSOULIS, Demetres et al. Analysis of the collapse of a greenhouse with vaulted roof. **Biosystems Engineering**, v. 151, p. 495-509, 2016. DOI: 10.1016/j.biosystemseng.2016.10.018
- European Space Agency - ESA. (2023). **Sentinel-2: Missions - Sentinel Online**. Copernicus. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>. Accessed 23 October 2023
- GOOGLE. (2024). **Code Editor**. Earth Engine | Google for Developers. Versão 0.1.406. Serviço e plataforma de análise geoespacial na nuvem. <https://earthengine.google.com/platform/>
- LEVIN, N. et al. Remote sensing as a tool for monitoring plasticulture in agricultural landscapes. **International journal of remote sensing**, v. 28, n. 1, p. 183-202, 2007. DOI: 10.1080/01431160600658156
- PLANET. (2024). **PlanetScope Data**. Planet Developers. Versão 1.2. Plataforma de dados de observação da Terra. <https://developers.planet.com/docs/data/planetscope/>
- PEDREGOSA, Fabian et al. Scikit-learn: Machine learning in Python. **The Journal of machine Learning research**, v. 12, p. 2825-2830, 2011. DOI: 10.48550/arXiv.1201.0490
- LU, Lizhen et al. Large-scale subpixel mapping of landcover from MODIS imagery using the improved spatial attraction model. **Journal of applied remote sensing**, v. 12, n. 4, p. 046017-046017, 2018. Doi: 10.1117/1.jrs.12.046017
- WANG, L., et al. Does plastic mulching reduce water footprint in field crops in China? A meta-analysis. **Agricultural Water Management**, v. 260, p. 107293, 2022. DOI: 10.1016/j.agwat.2021.107293
- ZHANG, Peng et al. A novel index for robust and large-scale mapping of plastic greenhouse from Sentinel-2 images. **Remote Sensing of Environment**, v. 276, p. 113042, 2022. DOI: 10.1016/j.rse.2022.113042