

Avaliação da área cultivada de soja em Abelardo Luz (SC) por classificação supervisionada usando imagens do satélite Sentinel-2

Gabriel Torresilha de Oliveira ^{(1)*}, Luiz Carlos Pittol Martini ⁽²⁾

⁽¹⁾ Acadêmico do curso de Agronomia do Centro de Ciências Agrárias da Universidade Federal de Santa Catarina. Rod. Ademar Gonzaga,1346, Bairro Itacorubi, Caixa Postal 476, CEP 8840-900, Florianópolis-SC, Brasil.

⁽²⁾ Professor, Depto. de Engenharia Rural, Centro de Ciências Agrárias da Universidade Federal de Santa Catarina. Rod. Ademar Gonzaga,1346, Bairro Itacorubi, Caixa Postal 476, CEP 8840-900, Florianópolis-SC, Brasil.

*Autor Correspondente - E-mail: gabrieltorresilhadeoliveira@gmail.com

Resumo

A classificação supervisionada dos usos da terra por imagens de satélite é um tema com crescente importância na agricultura, pois otimiza o processo de mapeamento dos cultivos e gera dados para o monitoramento de safras. Nessa linha, o trabalho teve como objetivo principal testar o algoritmo de classificação supervisionada Random Forest (RF) para o mapeamento de soja no município de Abelardo Luz (SC). Inicialmente, utilizou-se o software QGIS para processar imagens do satélite Sentinel-2 da safra 2022/2023 e obter um mapeamento manual da soja a partir da interpretação visual de imagem RGB composta pelas bandas 8, 11 e 4, respectivamente. Para classificação supervisionada dessa composição colorida, utilizou-se o algoritmo Random Forest disponível no complemento para QGIS denominado Dzetsaka Classification Tool. Estimou-se a acurácia de mapeamento comparando os resultados da classificação supervisionada com os resultados da classificação obtida manualmente. A classificação supervisionada alcançou uma acurácia global de 91% e índice kappa de 0,81, os quais implicam desempenho considerado excelente. O algoritmo RF mostrou-se eficiente na classificação de soja no município de Abelardo Luz (SC), indicando grande potencial para otimizar o mapeamento dessa cultura em escala territorial mais ampla.

Palavras-chave: Sensoriamento remoto; culturas anuais; SIG; estatística agrícola.

Abstract

The supervised classification of land use through satellite images is a topic of increasing importance in agriculture, as it optimizes the crop mapping process and generates data for crop monitoring. In this context, the main objective of this study was to test the Random Forest (RF) supervised classification algorithm for soybean mapping in the municipality of Abelardo Luz (SC). Initially, the software QGIS was used to process Sentinel-2 satellite images from the 2022/2023 harvest year and to obtain a manual mapping of soybean, from the visual interpretation of an RGB image composed of bands 8, 11, and 4, respectively. For the supervised classification of this colored composition, the Random Forest algorithm available in the QGIS plugin called Dzetsaka Classification Tool was used. The mapping accuracy was estimated by comparing the results of the supervised classification with the results of the manually obtained classification. The supervised classification achieved an overall accuracy of 91% and a kappa index of 0.81, which implies a performance considered excellent. The RF algorithm proved to be efficient in classifying soybean in the municipality of Abelardo Luz (SC), indicating great potential to optimize the mapping of this crop on a broader territorial scale.

Key-Words: Remote sensing; annual crops; SIG; agricultural statistics.

Introdução

O sensoriamento remoto orbital vem sendo cada vez mais utilizado como ferramenta para mapeamento dos usos das terras, tanto para fins de pesquisa como para monitoramento sistemático por organismos públicos ou privados. Além disso, a possibilidade de mapear áreas sem a necessidade de onerosos levantamentos de campo é um dos fatores que tornam essa ferramenta tão atraente para fins agrícolas.

No entanto, a qualidade do mapeamento realizado por sensoriamento remoto orbital é influenciada por diversos fatores, como diversidade de culturas, cobertura de nuvens e, principalmente, pela extensão da área cultivada. Nesse aspecto, a dimensão espacial da área de interesse pode requerer alta demanda de tempo e tamanho da equipe técnica necessária para realizar o mapeamento de forma manual. Para superar essas restrições, pode-se empregar técnicas e metodologias computacionais que aumentam a eficiência do mapeamento em grandes áreas.

Uma dessas técnicas é a classificação supervisionada de imagens de satélite, a qual consiste em separar diferentes classes de usos das terras utilizando um certo número de amostras para treinamento do modelo. Partindo-se de uma pequena área de treinamento, seleciona-se então um algoritmo capaz de aplicar os mesmos critérios de classificação das amostras a toda a extensão da imagem. Dessa forma, obtém-se uma otimização do processo de mapeamento para toda a região de interesse.

A importância da classificação supervisionada de imagens tem crescido nos últimos anos devido ao aumento da oferta de imagens de satélites com melhores resoluções espectrais, espaciais e temporais. No entanto, a classificação supervisionada possui algumas restrições, como sombreamento pelo relevo, presença de nuvens e similaridade espectral das coberturas de terra. Conforme descrito no trabalho de Machado *et al.* (2010), essas restrições podem comprometer a acurácia do mapeamento. Por outro lado, trabalhos mais recentes, como o de Silva (2020), exibem resultados animadores, com uma acurácia global na ordem de 80% a 89%. Assim, para identificar metodologias mais eficientes, torna-se relevante testar e avaliar métodos para classificação supervisionada de imagens em diferentes regiões, para diferentes cultivos e sob diferentes condições de manejo.

Considerada a principal *commodity* brasileira, a soja é a cultura agrícola que ocupa a maior extensão em nível nacional (IBGE, 2022). A importância da cultura para o país gerou toda uma cadeia de mercado em seu entorno, a qual demanda grande volume de dados produtivos, como área plantada, distribuição no território, produtividade e expansão anual, entre outros. Estes dados são consumidos para diversos propósitos e por diversos agentes, como bancos, seguradoras agrícolas, órgãos governamentais e investidores. O levantamento de dados de soja no país é realizado principalmente pelo Instituto Brasileiro de Geografia Estatística (IBGE), muitas vezes com parceria de órgãos estaduais, como é o caso do Cepa/Epagri – Centro de Socioeconomia e Planejamento Agrícola, da Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (KREUTZFELD; ANDRADE; MARTINI, 2023). Essas fontes geralmente utilizam dados secundários para realizar as estimativas, o que gera uma certa incerteza e fragilidade nos resultados obtidos.

Portanto, considerando as limitações das estimativas de órgãos oficiais, o objetivo deste trabalho foi realizar o mapeamento de soja no município de Abelardo Luz (SC) utilizando técnicas de sensoriamento remoto baseadas na interpretação visual e na classificação supervisionada. Os resultados de ambos os métodos de mapeamento foram comparados entre si, para avaliação da qualidade da classificação supervisionada. Os resultados obtidos por

sensoriamento remoto foram também confrontados com estimativas oficiais realizadas por organismos oficiais de estatística, os quais empregam metodologias convencionais para levantamento das safras agrícolas.

Material e Métodos

Local e Imagens

O trabalho foi realizado no município de Abelardo Luz, localizado no oeste de Santa Catarina (Figura 1). O oeste catarinense é a região de maior produção de soja no estado, sendo o município de Abelardo Luz o maior produtor da região (CEPA/EPAGRI, 2024).

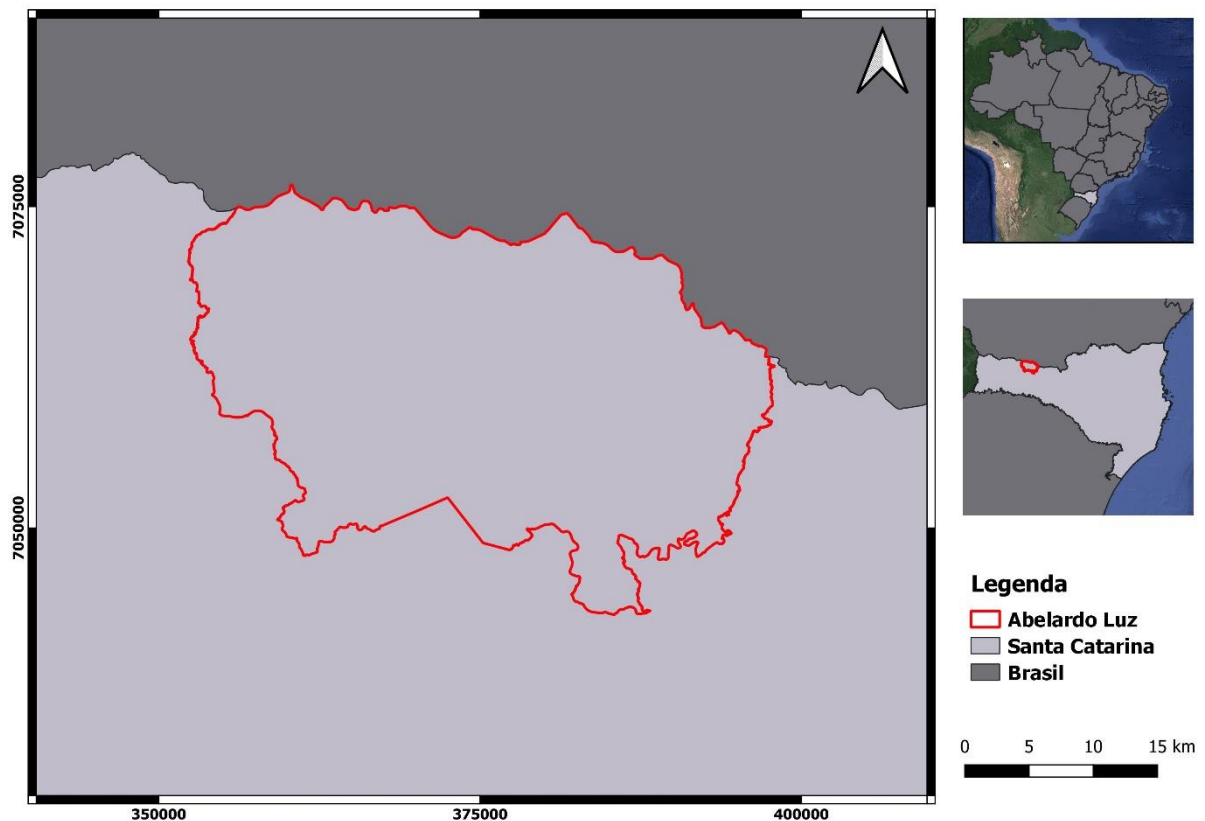


Figura 1. Localização do município de Abelardo Luz.

Fonte: Autor (2024)

O calendário agrícola de plantio de soja em Santa Catarina inicia em setembro e finaliza em janeiro (CONAB, 2022), fazendo com que a maior cobertura do solo pela cultura seja atingida no período entre novembro a abril, a depender da data de plantio. Dessa forma, esse foi o período de pesquisa de imagens orbitais para fins de mapeamento da soja. Uma vez que possui a combinação mais adequada de resolução espacial e tempo de revisita, optou-se por

utilizar imagens obtidas pelo sensor MSI do satélite Sentinel-2. As imagens armazenadas nos provedores oficiais foram descarregadas por meio do plugin para QGIS denominado SCP – *Semi-Automatic Classification Plugin* (CONGEDO, 2021).

Foi utilizado um recorte retangular da órbita ponto 22JCR do satélite Sentinel-2, com coordenadas latitude/longitude no canto inferior esquerdo de -26.74492479/-52.53399682 do e -26.40931662/-51.93657619 no canto superior direito. Foram selecionadas as imagens com menor cobertura de nuvens de cada mês, com nível de processamento L2A (Tabela 1).

Tabela 1. Parâmetros das imagens do satélite Sentinel-2 utilizadas no mapeamento de soja através de classificação manual e supervisionada.

Órbita ponto	Bandas espectrais	Datas das imagens	Cobertura de nuvens (%)
22JCR	Vermelho (4) Infravermelho próximo (8) Infravermelho de ondas curtas (11)	28/11/2022	3
		13/12/2022	0
		07/01/2023	2
		27/01/2023	0
		06/02/2023	7
		11/02/2023	0
		08/03/2023	6
		18/03/2023	0
		02/04/2023	0
		22/04/2023	0

Fonte: ESA, 2023.

Para análise e interpretação da presença de plantio de soja, foi utilizada uma composição colorida utilizando-se as bandas 4 (vermelho), 8 (infravermelho próximo) e 11 (infravermelho de ondas curtas) no padrão RGB R8G11B4, que destaca a soja em tons de amarelo e laranja. Esta composição colorida é comumente utilizada para distinção de culturas agrícolas (FORMAGGIO; SANCHES, 2017).

Software e mapeamento manual

Para mapeamento e processamento dos dados, utilizou-se o Sistema de Informação Geográfica livre e aberto QGIS versão 3.24 (QGIS Development Team, 2024). Manteve-se no

projeto do QGIS o sistema de referência de coordenadas original das imagens (EPSG 32722), que consiste no datum WGS84 e projeção Universal Transversa de Mercator (UTM), no fuso 22 do hemisfério sul (WGS84 / UTM zone 22S). Os limites do município foram extraídos a partir da camada vetorial de municípios do Brasil disponibilizada pelo IBGE (2019).

O mapeamento manual das áreas cultivadas com soja consistiu na vetorização de polígonos utilizando ferramentas de desenho disponíveis no QGIS. As áreas cultivadas foram identificadas visualmente, utilizando principalmente combinações coloridas no padrão R8G11B4 geradas com imagens do Sentinel-2 das datas de 11 de fevereiro de 2023 e 22 de abril de 2023. As imagens capturadas nessas datas apresentam pouca cobertura de nuvens e permitem visualizar adequadamente o cultivo da soja em período fenológico chave, a fase inicial do período reprodutivo, atingida aproximadamente 2 meses após o plantio. O cálculo da área dos talhões cultivados com soja também foi realizado usando ferramentas disponíveis no QGIS. A Figura 2 mostra um exemplo de área cultivada com soja que foi identificada e delimitada usando como base o padrão visual da composição colorida R8G11B4 do Sentinel-2.




Figura 2. resposta espectral da soja (em tons alaranjados) em fase inicial do período fenológico reprodutivo. Essa composição colorida RGB foi formada pelas bandas 8, 11 e 4 do satélite Sentinel-2, respectivamente, com data de aquisição 11/02/2023. A imagem é um recorte do município de Abelardo Luz (SC).

Adicionalmente, utilizou-se como suporte ao mapeamento a série do índice de vegetação EVI (*Enhanced Vegetation Index*), obtida com dados de sensores do satélite MODIS e disponível na plataforma online SATVeg (EMBRAPA, 2024). Devido à sazonalidade da cultura da soja, a Figura 3 apresenta um gráfico característico da cultura na forma de uma linha temporal do índice de vegetação, mostrando valores baixos de EVI no início e fim do ciclo (plantio e pós-colheita) e o valor máximo quando a cultura está em máximo vigor vegetativo. Para o caso da soja, o gráfico apresenta início e fim em um período com duração entre 3 a 4 meses, a depender da variedade de soja plantada.

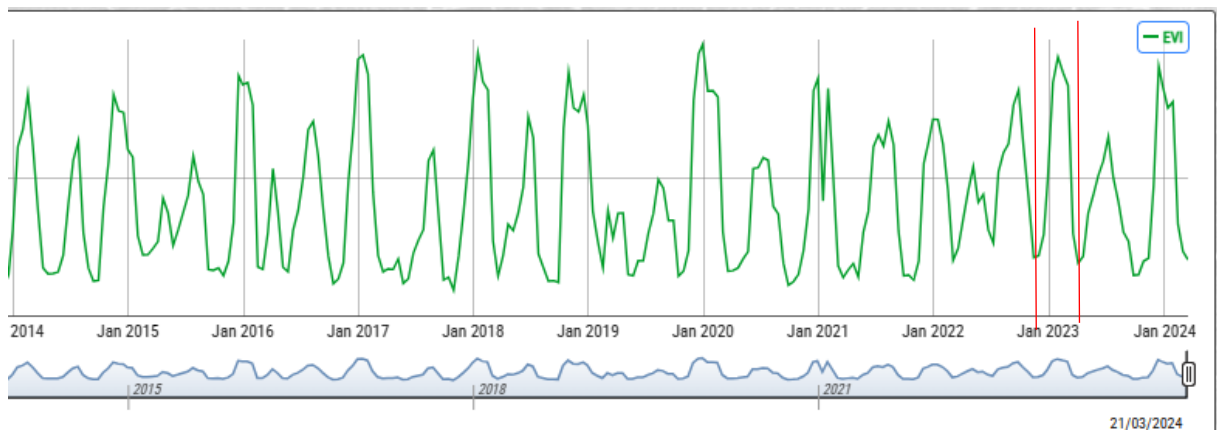


Figura 3. Gráfico temporal de índice de vegetação EVI (*Enhanced Vegetation Index*) característico para a cultura da soja na primeira safra, destacado entre linhas vermelhas. Fonte: EMBRAPA (2024).

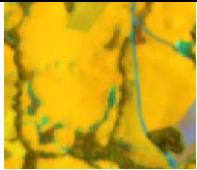
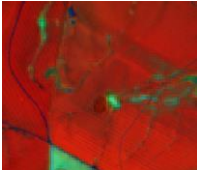
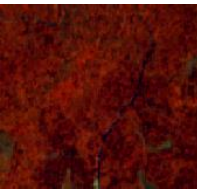
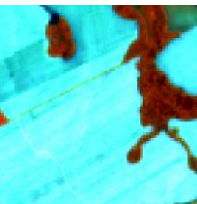
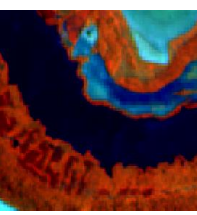
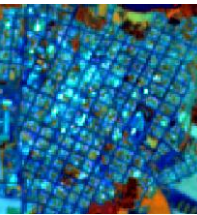
Classificação supervisionada

Para classificação supervisionada das imagens empregadas no estudo, utilizou-se o complemento para QGIS denominado *Dzetsaka classification tool* (KARASIAK, 2016). Este complemento contém módulos com alguns algoritmos de classificação baseados em aprendizado de máquina, dentre eles o algoritmo *Random Forest (RF)*. Neste trabalho, selecionou-se o RF para obtenção da classificação supervisionada das áreas de soja porque este algoritmo mostrou bons resultados em alguns trabalhos similares, como o de Cho *et al.* (2021), que obteve acurácia global de 84% na diferenciação de áreas de agricultura anual e demais usos do solo. De maneira semelhante, Silva (2020) obteve uma acurácia global de 90,3% na diferenciação de cultivos utilizando esse algoritmo.

A fim de obter uma boa separação entre lavouras de soja e outras áreas, foram selecionadas 6 classes de uso do solo para treinamento da classificação supervisionada. As

classes de uso do solo foram definidas a partir dos usos visualmente mais significativos no município, sendo elas: soja, outras culturas, mata, solo exposto, água e perímetro urbano, vetorizadas a partir da chave de interpretação presente na tabela 2. A Tabela 3 apresenta o número de amostras em cada classe de uso das terras e a área total das amostras.

Tabela 2. Chave de interpretação de diferentes usos e coberturas do solo em Abelardo Luz, em composição falsa-cor R8G11B4 do Sentinel-2.

Classe	Elementos de interpretação	Recorte da imagem
Soja	Cor amarelada/alaranjada, textura lisa e uniforme e ciclo definido*	
Outras culturas	Cores diferentes de amarelo/laranja, textura lisa e uniforme e ciclo definido*	
Mata	Cores avermelhadas com textura rugosa	
Solo exposto	Cor azul claro de textura lisa e uniforme	
Corpos hídricos	Cor azul escuro com textura lisa e uniforme	
Área urbana	Cores azuladas com textura rugosa e quadriculada	

* Ciclo definido significa que a área em questão apresenta resposta de solo exposto no início e fim da safra da cultura em questão, em decorrência do plantio e colheita na área. A resposta de

solo exposto pode ser observada em imagens de datas anteriores e posteriores às datas onde a cultura aparece em pleno vigor vegetativo.

Tabela 3. Quantidade e tamanho das áreas utilizadas como treinamento para o modelo de classificação supervisionada.

Data	Classe	Amostras de treinamento	área total (ha)
11/02/2023	Soja	29	729
	Outras culturas	8	94
	Mata	20	1141
	Solo exposto	8	122
	Corpos hídricos	15	42
	Área urbana	8	33
	Total	88	2161
	22/04/2023	Soja	26
Outras culturas		0	0
Mata		16	1125
Solo exposto		16	229
Corpos hídricos		11	58
Área urbana		8	48
Total		77	1726

O procedimento de classificação empregando o algoritmo RF foi realizado duas vezes, a primeira vez para a imagem do dia 11 de fevereiro de 2023 e a segunda para o dia 22 de abril de 2023. Isso permitiu obter a área de soja implantada em diferentes épocas de semeadura. Os arquivos raster (imagens) gerados pela classificação nessas duas épocas foram posteriormente convertidos em formato vetorial (shapefile). Em seguida, realizou-se a fusão desses dois *shapefiles*, removendo-se as sobreposições entre épocas para gerar um mapa da área total cultivada com soja.

A análise de acurácia da classificação supervisionada foi realizada através de matriz de confusão, acurácia global (%) e índice kappa. Para esta análise, foi utilizado o mapa gerado através de classificação manual como referência em relação ao mapa gerado através de classificação supervisionada, os índices de acurácia foram calculados através do Geographic Resource Analysis Support System (GRASS, 2013), presente no *software* QGIS como complemento.

Resultados e Discussão

Obteve-se uma área de 39.112 hectares a partir do mapeamento manual de soja em Abelardo Luz (Figura 4.). De maneira similar, a área de soja no município calculada pela CONAB (2023) foi de 39.937 hectares, resultando em uma diferença de aproximadamente 2% para a mesma safra. Por outro lado, outras fontes oficiais de dados apresentaram dados mais discrepantes. O IBGE (2023) registrou 50.000 hectares de soja para o ano de 2022, valor parecido com o encontrado pelo Cepa/Epagri (2024), de 51.000 hectares. Os resultados dos órgãos estatísticos superestimaram a área de soja em Abelardo Luz quando comparados com o mapeamento por satélite obtido por classificação manual, na ordem de 22 % e 23 %, respectivamente.

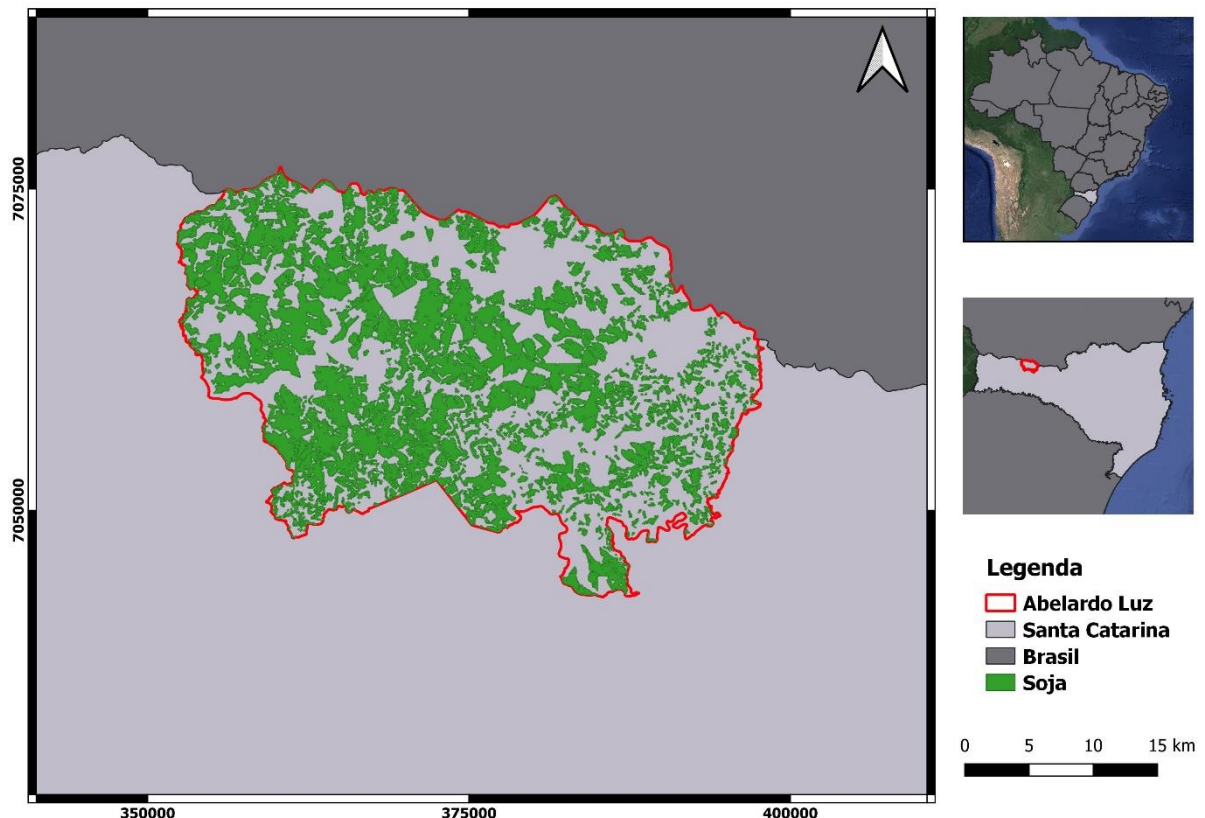


Figura 4. Área de soja plantada em Abelardo Luz (polígonos em verde) no ano safra 2022/2023.

Diferenças significativas também foram constatadas no trabalho de Betta *et al.* (2022), que obtiveram diferenças de 23% na área plantada de soja para a safra 2012/2013 e 6% para a safra 2020/2021, em relação aos dados oficiais da Epagri/Cepa. De maneira semelhante, Paludo *et al.* (2020) encontraram uma diferença de 20% na área de soja comparando-se o mapeamento por sensoriamento remoto e dados do IBGE. Além disso, a diferença foi de 4,3% para o milho, na safra de 2016/2017.

As discrepâncias e semelhanças com os dados oficiais podem ser explicadas pela metodologia de coleta dos dados. A CONAB utilizou metodologia de mapeamento através de sensoriamento remoto, o que explica a similaridade de dados com este trabalho. Em contrapartida, o IBGE e Cepa/Epagri encontraram valores similares de área plantada entre si, porém consideravelmente discrepantes do encontrados por sensoriamento remoto, resultado esperado devido às suas metodologias basearem-se em dados secundários, fator que limita a precisão da estimativa.

Como discutido no trabalho de Kreutzfeld, Andrade e Martini (2023), no qual foram encontradas diferenças de 33% na área plantada de cebola em relação à Epagri/Cepa e 27% em relação ao IBGE, o mapeamento por imagens de satélite pode ser considerado um tipo de censo, ao passo que levantamentos tradicionais de informações podem gerar dados enviesados, uma vez que as fontes de informação não são necessariamente oficiais, sendo utilizados dados declaratórios, contatos profissionais de agroindústrias e cooperativas, fornecedores de insumos e etc.

Por sua vez, a classificação supervisionada através do algoritmo RF resultou em uma área plantada de 37.627 hectares de soja, uma diferença de 3,80% para o mapa classificado manualmente. A acurácia global atingida pela classificação supervisionada através do algoritmo RF foi 91%, com um índice Kappa de 0,814, classificado como excelente conforme Landis e Koch (1977) (Tabela 3).

Tabela 3. Qualidade da classificação em relação ao índice Kappa

Índice Kappa	Qualidade da classificação
0.00	Péssima
0.01 a 0.20	Ruim
0.21 a 0.40	Razoável
0.41 a 0.60	Boa
0.61 a 0.80	Muito boa
0.81 a 1.00	Excelente

Fonte: Landis & Koch (1977, p.165).

Parte da diferença entre a classificação manual e supervisionada pode ser explicada pelas datas utilizadas nas classificações, visto que para a classificação manual foram utilizadas todas as imagens presentes na Tabela 1, enquanto para a classificação supervisionada foram utilizadas apenas as duas imagens mais importantes da safra, sendo as de 11/02/2023 e 22/04/2023, o que gerou omissão de áreas de soja plantadas no início do calendário (Figura 5).

Área de soja

- Classificação automática
- Classificação manual




Figura 5. Imagem em falsa-cor do dia 13/12/2022. As áreas classificadas como soja (áreas em tons alaranjados) manualmente, mas não classificadas pelo algoritmo RF estão contornadas em azul.

Apesar de apresentar diferenças em relação ao mapa de referência, a classificação supervisionada apresentou um bom resultado, sendo que, para a utilização de um maior número de imagens da safra no treinamento do algoritmo, é esperado um maior valor de acurácia.

Conclusão

O algoritmo *Random Forest* aplicado à classificação supervisionada de imagens do Sentinel-2 foi eficiente no mapeamento de soja em Abelardo Luz. A pequena diferença entre os resultados da classificação supervisionada e manual indica a viabilidade de uso da classificação supervisionada, possibilitando o mapeamento de grandes áreas com otimização de tempo e equipe. Desde que a cobertura de nuvens permita, resultados mais precisos podem ser obtidos utilizando-se imagens do Sentinel-2 com passagem em outras épocas ao longo do ciclo da soja.

Referências

- BETTA, Marina Marly dalla *et al.* (2022). Mapeamento da soja por meio de imagens Landsat e Sentinel-2 nos municípios de Lages e Capão Alto em Santa Catarina, *In, Agropecuária Catarinense*, [S.L.], v. 35, n. 2, p. 68-73, 31 ago. 2022. Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina. <http://dx.doi.org/10.52945/rac.v35i2.1347>. Disponível em: <https://publicacoes.epagri.sc.gov.br/rac/article/view/1347>. Acesso em: 12 mar. 2024.
- BUECHEL, Sally W. *et al.* (1989). The effects of a complex environment on crop separability with landsat TM, *In, Remote Sensing Of Environment*, [S.L.], v. 27, n. 3, p. 261-271, mar. 1989. Elsevier BV. [http://dx.doi.org/10.1016/0034-4257\(89\)90087-4](http://dx.doi.org/10.1016/0034-4257(89)90087-4). Disponível em: https://www.sciencedirect.com/science/article/abs/pii/0034425789900874?fr=RR-2&ref=pdf_download&rr=869a40a49c8a7e0d. Acesso em: 23 mar. 2024.
- CEPA/EPAGRI (2024). **Acompanhamento de safras**. Disponível em: <https://cepa.epagri.sc.gov.br/index.php/produtos/acompanhamento-de-safras/>. Acesso em: 04 mai. 2024.
- CHO, Davi Fernando *et al.* (2021). Desempenho do Algoritmo de Classificação de Imagens Random Forest para Mapeamento do Uso e Cobertura do Solo no Cerrado Brasileiro, *In, Anuário do Instituto de Geociências*, Rio de Janeiro, v. 44, 31 ago. 2021. Universidade Federal do Rio de Janeiro. http://dx.doi.org/10.11137/1982-3908_2021_44_37979. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/1136276>. Acesso em: 01 mai. 2024.
- CONAB. Companhia Nacional de Abastecimento (2022). **Calendário de Plantio e Colheita de Grãos no Brasil 2022**. Disponível em: https://www.conab.gov.br/outras-publicacoes/item/download/45710_77f0a5ee35e765e2248999f4c61e70c8. Acesso em: 14 abr. 2024.
- CONAB. Companhia Nacional de Abastecimento (2023). **Portal de informações agropecuárias**. Disponível em: <https://portaldeinformacoes.conab.gov.br/mapeamentos-agricolas-downloads.html>. Acesso em: 04 fev. 2024.
- CONGEDO, Luca (2021). Semi-Automatic Classification Plugin: a python tool for the download and processing of remote sensing images in qgis. **Journal Of Open Source Software**, [S.L.], v. 6, n. 64, p. 3172, 27 ago. 2021. The Open Journal. <http://dx.doi.org/10.21105/joss.03172>. Acesso em: 10 dez. 2023.
- EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária (2024). SATVeg - Sistema de Análise Temporal da Vegetação. Disponível em: <http://www.satveg.cnptia.embrapa.br>. Acesso em: 28 abr. 2024.
- ESA. European Space Agency (2023). **Copernicus Browser**. Disponível em: https://browser.dataspace.copernicus.eu/?zoom=5&lat=50.16282&lng=20.78613&themeId=D EFAULT-THEME&visualizationUrl=https%3A%2F%2Fsh.dataspace.copernicus.eu%2Fogc%2Fwms%2Fa91f72b5-f393-4320-bc0f-990129bd9e63&datasetId=S2_L2A_CDAS&demSource3D=%22MAPZEN%22&cloudCoverage=30&dateMode=SINGLE. Acesso em: 27 nov. 2023.

FORMAGGIO, Antonio Roberto; SANCHES, Ieda Del´arco (2017). Interpretação visual de imagens obtidas por sensores remotos orbitais para análise de alvos agrícolas: cor, *In*: FORMAGGIO, Antonio Roberto; SANCHES, Ieda Del´arco. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017. Cap. 4. p. 125-129. Disponível em: <https://books.google.com.br/books?id=hk88DwAAQBAJ&printsec=frontcover&hl=pt-BR#v=onepage&q&f=false>. Acesso em: 25 abr. 2024.

GRASS-PROJECT (2013). **Geographic resource analysis support system**. Disponível em: <http://grass.osgeo.org> . Acesso em: 12 fev. 2024.

IBGE. Instituto Brasileiro de Geografia Estatística (2022). **Produção Agrícola Municipal**. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html>. Acesso em: 23 mar. 2024.

IBGE. Instituto Brasileiro de Geografia Estatística (2019). **Malha municipal**. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>. Acesso em: 03 dez. 2023.

IBGE Instituto Brasileiro de Geografia Estatística (2023). **Produção agrícola municipal: culturas temporárias e permanentes**. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html?=&t=destaques>. Acesso em: 04 mai. 2024.

KARASIAK, Nicolas. (2016) Dzetsaka Qgis Classification plugin. Disponível em: <https://github.com/nkarasiak/dzetsaka>. DOI: 10.5281/zenodo.2552284. Acesso em: 20 fev. 2024.

KREUTZFELD, Lucas; ANDRADE, Caio Bustani; MARTINI, Luiz Carlos Pittol (2023). Estimativa da área de cebola por meio de imagens de satélites para os municípios de Ituporanga e Imbuia, SC, Brasil, *In: Agropecuária Catarinense*, [S.L.], v. 36, n. 1, p. 30-36, 16 mar. 2023. Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina. <http://dx.doi.org/10.52945/rac.v36i1.1458>. Disponível em: <https://publicacoes.epagri.sc.gov.br/rac/article/view/1458/1474>. Acesso em: 23 mar. 2024.

LANDIS, J.R.; KOCH, G.G (1977). The measurement of observer agreement for categorical data, *In: Biometrics*, v. 33, n. 1, p. 159-174.

MACHADO, Marley Lamounier *et al* (2010) MAPEAMENTO DE ÁREAS CAFEEIRAS (*Coffea arabica* L.) DA ZONA DA MATA MINEIRA USANDO SENSORIAMENTO REMOTO, *In: Coffee Science*, Lavras, v. 5, n. 2, p. 113-122, maio 2010. Disponível em: <http://www.sbicafe.ufv.br/handle/123456789/3917>. Acesso em: 24 mar. 2024.

PALUDO, Alex *et al* (2020). Mapping summer soybean and corn with remote sensing on Google Earth Engine cloud computing in Parana state – Brazil. *In: International Journal Of Digital Earth*, [S.L.], v. 13, n. 12, p. 1624-1636, 5 jun. 2020. Informa UK Limited. <http://dx.doi.org/10.1080/17538947.2020.1772893>. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/17538947.2020.1772893>. Acesso em: 14 mar. 2024.

QGIS Development Team (2024). QGIS Geographic Information System, *In: Open Source Geospatial Foundation Project*. Disponível em: https://qgis.org/pt_BR/site/. Acesso em: 12 abr. 2024.

SILVA, Inês de Carvalho Fernandes Martins da. (2020). **Avaliação de metodologias de aprendizagem automática na classificação de culturas agrícolas com base em imagens do Sentinel-2**. 75 f. Dissertação (Mestrado) - Curso de Sistemas de Informação Geográfica, Departamento de Engenharia Geográfica, Geofísica e Energia, Universidade de Lisboa, Lisboa. Disponível em: <http://hdl.handle.net/10451/45514>. Acesso em: 24 mar. 2024.