

MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO UTILIZANDO A PLATAFORMA DO GOOGLE EARTH ENGINE

THALIS DIAS VASCONCELOS¹, EDUARDO RODRIGUES PINTO², CARLOS
HENRIQUE WACHHOLZ DE SOUZA³

¹ Engenheiro Agrícola, Universidade Federal do Paraná, tdvdias@gmail.com

² Graduando em Engenharia Agrícola, Universidade Federal do Paraná, eduardorodrg.ea@gmail.com

³ Professor do Magistério Superior, Universidade Federal do Paraná, carlossouza@ufpr.br

Apresentado no
LII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2023
18 a 21 de outubro de 2023 – Ribeirão Preto - SP, Brasil

RESUMO: Uma maneira de obter mapas de uso e ocupação do solo de forma automática e sem a necessidade de grande capacidade computacional é através do uso de plataformas de processamento em nuvem, como o Google Earth Engine (GEE). Esta ferramenta permite a criação de algoritmos com interface amigável e dinâmica, gerando resultados em tempo real à medida que os scripts são desenvolvidos. Por meio de classificadores supervisionados, como Random Forest, Support Vector Machine e Classification and Regression Trees, é possível produzir mapas que automatizam todo o processo e suas etapas através de linhas de código. Isso possibilita a realização de análises ambientais em larga escala com resultados confiáveis. O objetivo deste estudo é criar um mapa de uso e ocupação do solo com suas respectivas áreas, além de testar diferentes classificadores no mapeamento do território do Vale do Ivaí – PR, utilizando a plataforma GEE em imagens Landsat 8. A eficiência dos classificadores na região de estudo foi avaliada por meio de métricas de acurácia, resultando em mapas temáticos de uso e ocupação do solo. Os algoritmos avaliados apresentaram ótimo desempenho nas análises de acurácia, com destaque para o classificador Support Vector Machine, que obteve uma eficiência média de 98%.

PALAVRAS-CHAVE: geoprocessamento, sensoriamento remoto, landsat 8

MAPPING OF LAND USE AND COVER USING THE GOOGLE EARTH ENGINE PLATFORM

ABSTRACT: One way to obtain land use and occupancy maps automatically and without the need for large computational capacity is through the use of cloud processing platforms, such as Google Earth Engine (GEE). This tool allows the creation of algorithms with a friendly and dynamic interface, generating real-time results as scripts are developed. Through supervised classifiers, such as Random Forest, Support Vector Machine, and Classification and Regression Trees, it is possible to produce maps that automate the entire process and its stages through lines of code. This enables large-scale environmental analyses with reliable results. The aim of this study is to create a land use and occupancy map with their respective areas, in addition to testing different classifiers in mapping the territory of Vale do Ivaí – PR, using the GEE platform in Landsat 8 images. The efficiency of the classifiers in the study region was evaluated through accuracy metrics, resulting in thematic maps of land use and occupancy. The evaluated algorithms performed excellently in the accuracy analyses, with the Support Vector Machine classifier standing out, which achieved an average efficiency of 98%.

KEYWORDS: geoprocessing, remote sensing, landsat 8

INTRODUÇÃO: O sensoriamento remoto por meio de processamentos digitais visa fornecer informações contidas em imagens de satélites, facilitando a interpretação dos dados e consequentemente a tomada de decisões relevantes. O mapeamento do uso e ocupação do solo é uma dessas informações que permite a compreensão da distribuição espacial de diferentes classes, como solo exposto, culturas, corpos d'água e áreas florestais. Isso possibilita o estudo de variáveis críticas como a erosão do solo, o desmatamento e a degradação de pastagens (ALO e PONTIUS, 2008). O monitoramento de vastas áreas demanda recursos computacionais significativos, que podem ser atendidos pela plataforma Google Earth Engine (GEE), a qual faz uso dos servidores Google e proporciona uma interface interativa para a criação de algoritmos que otimizam o processamento computacional (GEE, 2020). Nesse contexto, os classificadores supervisionados Random Forest (RF), Support Vector Machine (SVM) e Classification and Regression Trees (CART) são métodos de classificação que podem ser empregados na plataforma para o mapeamento do uso e ocupação do solo (ADELABU et al., 2013; ROSA et al., 2017; PINHEIRO et al., 2019). O propósito deste trabalho é a utilização da plataforma Google Earth Engine para a elaboração de um sistema automatizado de mapeamento da cobertura e interpretação do uso do solo.

MATERIAL E MÉTODOS: A área de estudo abrange o Vale do Ivaí-PR, situado na região sul do Brasil, norte do Paraná, com uma extensão de 7.385,05 km², composta por 26 municípios. O trabalho foi desenvolvido no editor de códigos do GEE, um Ambiente Integrado de Desenvolvimento (IDE) online que se utiliza da linguagem de programação JavaScript. A interface do usuário presente no IDE facilita a criação do algoritmo, desde a chamada de arquivos auxiliares até a exportação de resultados. A construção do algoritmo se deu em oito etapas principais: seleção de imagens, criação do mosaico, delimitação da área de estudo, amostragem, classificação, mapa de uso e ocupação, exportação do mapa no formato .TIF e exportação das métricas no formato .CSV. Para a seleção de imagens, foi utilizada a coleção de imagens do Landsat 8, obtidas diretamente do catálogo presente no GEE, filtradas entre os dias 01 de dezembro de 2018 e 30 de maio de 2019. Para abranger todo o Vale do Ivaí, são necessárias duas imagens do Landsat 8, demandando assim a criação de um mosaico, seguido do recorte para a região de estudo. Para a amostragem, foram coletadas amostras de oito classes de interesse: reflorestamento, mata nativa, corpos d'água, solo exposto, pastagem, milho, cana-de-açúcar e soja. As amostras foram selecionadas através de interpretação visual nas imagens e referências de campo, procurando pixels puros no centro dos polígonos usando as composições RGB das bandas do Landsat 8 para facilitar a identificação das classes. Coletaram-se aproximadamente 100 amostras por classe, distribuídas aleatoriamente dentro da área de estudo; duas amostragens foram realizadas, sendo uma usada para treinar o algoritmo e a outra para testes. Os algoritmos classificadores já estão disponíveis no GEE, sendo necessário apenas implementá-los no código; foram usados o RF, SVM e o CART. Para analisar a acurácia, utilizou-se o método de matriz de confusão, que é uma tabela exibindo a frequência de classificação para cada classe (CONGALTON, 1991). Após isso, calcula-se a Exatidão Global (EG), que representa a proporção total de acertos do algoritmo em relação às amostras de teste, que segundo FOODY (2002), o valor mínimo aceito é de 85%. O índice Kappa (LANDIS E KOCH, 1977) afirma que valores acima de 0,8 indicam uma boa classificação. As métricas são processadas dentro do próprio GEE, junto com o cálculo da área de cada classe, e são exportadas juntamente com a imagem classificada para o Google Drive. A construção dos mapas foi realizada no software QGIS.

RESULTADOS E DISCUSSÃO: O mapa com as imagens classificadas está presente na Figura 1. É possível perceber que o classificador CART apresenta uma concentração de cana-de-açúcar na região oeste, onde estão localizados os municípios com maior área plantada dessa cultura (IBGE/SIDRA, 2017). Os três classificadores mostram alta concentração de pastagem no sul do mapa, o que ocorre devido à irregularidade do terreno da região, que dificulta a produção de outras culturas. Já a classe corpos hídricos teve praticamente a mesma área em todas as imagens, devido às características de refletância da água. Os classificadores RF e SVM apresentaram quantidades de áreas de milho similares, localizadas abaixo da concentração de cana-de-açúcar, na região oeste.

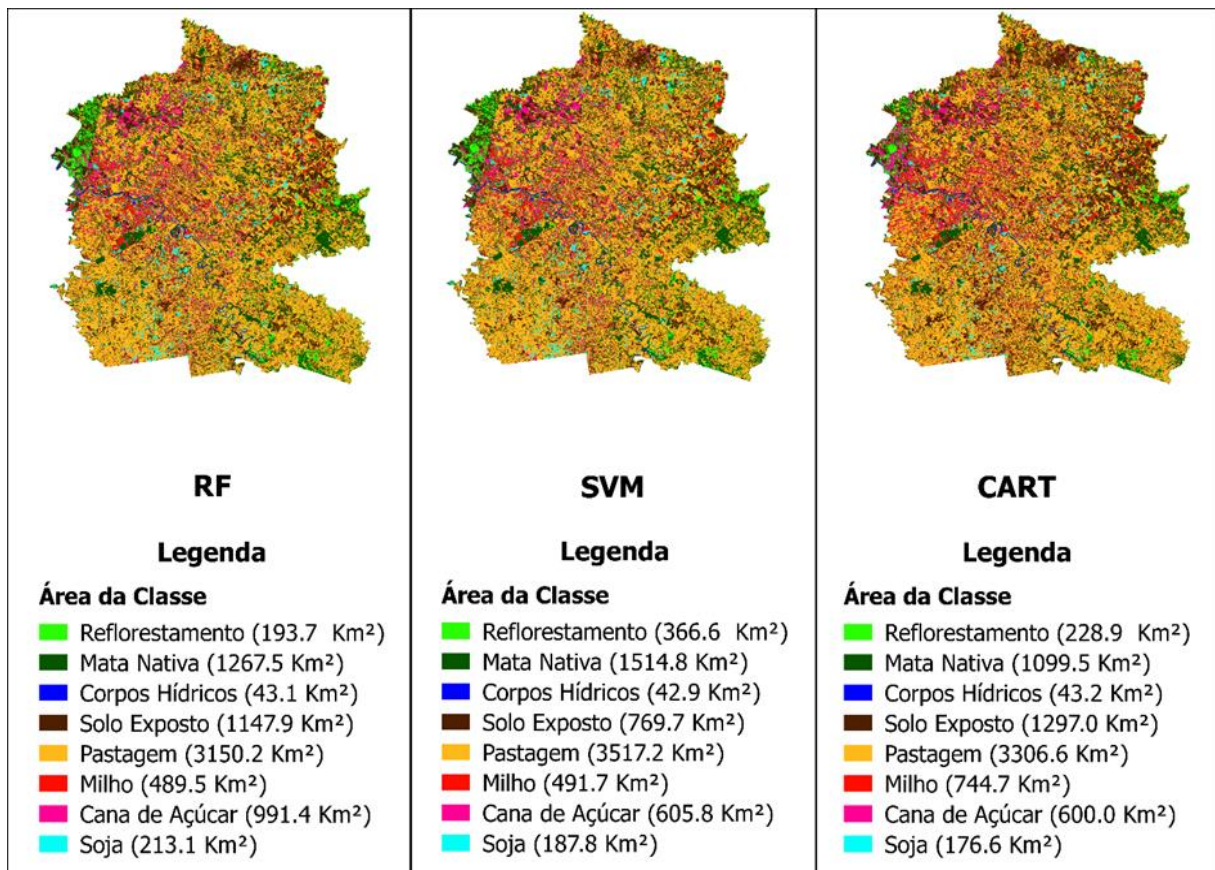


FIGURA 1. Resultado da classificação e área gerada utilizando os algoritmos Random Forest (RF), Support Vector Machine (SMV) e Classification and Regression Tree (CART).

A Tabela 1 apresenta os resultados das métricas de acurácia das classificações realizadas, que incluem o Índice Kappa, a Exatidão Global (EG), a Acurácia do Produtor (AP) e a Acurácia do Usuário (AU). Os três métodos utilizados apresentaram Índices Kappa e Exatidão Global acima de 85%, o que indica uma boa correspondência com a realidade do terreno. Segundo Landis e Koch (1977), um coeficiente Kappa acima de 0,8 é considerado uma classificação muito boa. Portanto, os resultados dos classificadores testados podem ser considerados satisfatórios. A EG mede o desempenho geral da classificação do mapa, sendo que valores mais altos são obtidos com classificadores otimizados. A AP indica a probabilidade de um pixel ser corretamente classificado no mapa, enquanto a AU mostra com que frequência a classe presente no mapa corresponde à realidade do terreno.

Tabela 1. Métricas de acurácia para os classificadores.

Classificadores Otimizados	Índice Kappa	EG (%)	AP (%)	AU (%)
<i>Random Forest</i>	0.96	96	97	97
<i>Support Vector Machine</i>	0.98	98	98	98
<i>Classification and Regression Tree</i>	0.94	95	96	95

CONCLUSÕES: Os resultados demonstraram que o Google Earth Engine é uma ferramenta eficaz e amigável, que permite acesso a um extenso banco de dados em nuvem e o processamento rápido de imagens. Entre os três métodos de classificação testados, o que apresentou melhor desempenho foi o SVM, com um índice Kappa de 0,98 e o menor erro de comissão e omissão, seguido do RF com 0,96 e do CART com 0,94. Os mapas gerados pelos diferentes classificadores apresentaram variações nas áreas classificadas, destacando a importância de avaliar as métricas de acurácia e exatidão para escolher o método mais adequado para cada caso de estudo. Portanto, conclui-se que o Google Earth Engine é uma plataforma confiável e útil para a realização de classificações supervisionadas e a produção de mapas de uso e ocupação do solo.

REFERÊNCIAS:

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, n. 1, p. 185–201, 2002.

GEE – Google Earth Engine Developers. **Sobre o Google Earth Engine**. Disponível em: <<https://developers.google.com/earth-engine>>. Acesso em: 07 de fev. 2020.

IBGE/SIDRA – Produção Agrícola Municipal (PAM). **Áreas plantadas, colhidas, quantidade produzidas, rendimento médio e valor de produção das lavouras**. Disponível em: <<https://sidra.ibge.gov.br/pesquisa/pam/tabelas>>. Acesso em: 09 de ago. 2020.

CONGALTON, R. G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. **Remote Sensing of Environment**, v. 37, p. 35–46, 1991.

ADELABU, S.; MUTANGA, O.; ADAM, E.; CHO, M. A. Exploiting machine learning algorithms for tree species classification in a semiarid woodland using RapidEye image. **Journal of Applied Remote Sensing**, v. 7, n. 1, p. 073480, 2013.

PINHEIRO, É. C. C.; RAMOS, A. P. M.; MARCATO JUNIOR, J. Remote sensing applied to the environmental regularization of rural properties in mato grosso do sul. **Anuário do Instituto de Geociências**, v. 42, n. 3, p. 145–153, 2019.

ROSA, M. R.; CRUZ, B. B.; MACHADO, C. A. S.; et al. **Comparação de algoritmos: Software comercial X Google Earth Engine**. Anais do XXVII Congresso Brasileiro de Cartografia v. 202, p. 166–176, 2017.

ADELABU, S.; MUTANGA, O.; ADAM, E.; CHO, M. A. Exploiting machine learning algorithms for tree species classification in a semiarid woodland using RapidEye image. **Journal of Applied Remote Sensing**, v. 7, n. 1, p. 073480, 2013.

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