

## CLASSIFICAÇÃO SUPERVISIONADA DE ÁREA IRRIGADA UTILIZANDO ÍNDICES ESPECTRAIS DE IMAGENS LANDSAT-8 COM GOOGLE EARTH ENGINE

CÉSAR DE OLIVEIRA FERREIRA SILVA<sup>1</sup>

<sup>1</sup> Departamento de Engenharia Rural, Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista (UNESP) Campus de Botucatu. Avenida Universitária, n° 3780, Altos do Paraíso, CEP: 18610-034, Botucatu – SP, Brasil, e-mail: cesaroliveira.f.silva@gmail.com.

### 1 RESUMO

Identificar áreas de irrigação usando imagens de satélite é um desafio que encontra em soluções de computação em nuvem um grande potencial, como na ferramenta *Google Earth Engine* (GEE), que facilita o processo de busca, filtragem e manipulação de grandes volumes de dados de sensoriamento remoto sem a necessidade de softwares pagos ou de download de imagens. O presente trabalho apresenta uma implementação de classificação supervisionada de áreas irrigadas e não-irrigadas na região de Sorriso e Lucas do Rio Verde/MT com o algoritmo *Classification and Regression Trees* (CART) em ambiente GEE utilizando as bandas 2-7 do satélite Landsat-8 e os índices NDVI, NDWI e SAVI. A acurácia da classificação supervisionada foi de 99,4% ao utilizar os índices NDWI, NDVI e SAVI e de 98,7% sem utilizar esses índices, todas consideradas excelentes. O tempo de processamento médio, refeito 10 vezes, foi de 52 segundos, considerando todo o código-fonte desenvolvido desde a filtragem das imagens até a conclusão da classificação. O código-fonte desenvolvido é apresentado em anexo de modo a difundir e incentivar o uso do GEE para estudos de inteligência espacial em irrigação e drenagem por sua usabilidade e fácil manipulação.

**Keywords:** computação em nuvem, sensoriamento remoto, hidrologia, modelagem.

SILVA, C. O. F

### SUPERVISED CLASSIFICATION OF IRRIGATED AREA USING SPECTRAL INDEXES FROM LANDSAT-8 IMAGES WITH GOOGLE EARTH ENGINE

### 2 ABSTRACT

Identifying irrigation areas using satellite images is a challenge that finds great potential in cloud computing solutions as the *Google Earth Engine* (GEE) tool, which facilitates the process of searching, filtering and manipulating large volumes of remote sensing data without the need for paid software or image downloading. The present work presents an implementation of the supervised classification of irrigated and rain-fed areas in the region of Sorriso and Lucas do Rio Verde/MT with the *Classification and Regression Trees* (CART) algorithm in GEE environment using bands 2-7 of the Landsat-8 and the NDVI, NDWI and SAVI indices. The accuracy of the supervised classification was 99.4% when using NDWI, NDVI and SAVI indices and 98.7% without using these indices, which were considered excellent. The average processing time, redone 10 times, was 52 seconds, considering all the source code developed from the filtering of the images to the conclusion of the classification. The developed source

code is available in the appendix in order to disseminate and encourage the use of GEE for studies of spatial intelligence in irrigation and drainage due to its usability and easy manipulation.

**Keywords:** cloud computing, remote sensing, hydrology, modeling.

### 3 INTRODUÇÃO

A agricultura irrigada é o paradigma adotado na busca pelo aumento da produtividade das culturas dentro das fronteiras agrícolas já abertas, evitando supressão de vegetação nativa e aumentando a duração do período anual de plantios e a produção agrícola no local (GUIMARÃES e LANDAU, 2014). Com isso muitos produtores consideram primordial a implantação da irrigação para garantir segurança alimentar, estabilidade e diversificação da produção. Nesse contexto, o uso conjunto de técnicas de sensoriamento remoto com dados agrometeorológicos pode melhorar o manejo de água em diferentes escalas espaciais e temporais permitindo o monitoramento de grandes áreas irrigadas (SILVA et al., 2018).

O *Google Earth Engine* (GEE) é uma plataforma de serviço de computação intrinsecamente paralelo de alto desempenho para análise espacial em grande escala utilizando as capacidades computacionais do Google para realizar o cruzamento de dados socioambientais especializados, como desmatamento, seca, desastres, doenças, segurança alimentar, gerenciamento de água, monitoramento climático e proteção ambiental (DUONG et al., 2018; KUMAR e MUTANGA, 2018; TSAI et al., 2018). Esse sistema utiliza uma interface de programação de aplicativos (API) acessível pela Internet e um ambiente de desenvolvimento interativo (IDE) associado para a criação de protótipos e a visualização rápida dos resultados.

O GEE está em uso em uma ampla variedade de disciplinas, abrangendo

tópicos como mudança global de florestas (HANSEN et al., 2013), estimativa de rendimento de culturas (LOBELL et al., 2015), mapeamento urbano (ZHANG et al., 2015), monitoramento de queimadas (SOULARD et al., 2016), dentre outros. No Brasil, entretanto, seu uso ainda é incipiente, dentre os atualmente em curso destaca-se o projeto MapBiomass (2019) é uma grande iniciativa de monitoramento da dinâmica do uso da terra que utiliza o GEE em imagens Landsat-5, 7 e 8, gerando mapas anuais de uso da terra de 1985 aos dias atuais. Além de uma extensa série temporal de imagens de diferentes sensores, o GEE disponibiliza um conjunto atual de classificadores pixel-a-pixel que podem ser utilizados para mapeamento de uso da terra. Na irrigação o conhecimento da evapotranspiração é essencial ao correto manejo da água no solo, e a ferramenta The Earth Engine Evapotranspiration Flux (EEFLUX, 2017) automatizou o modelo *Mapping Evapotranspiration at high Resolution with Internal Calibration* (METRIC) para imagens Landsat 7 e 8 também em ambiente GEE, mostrando a versatilidade dessa ferramenta, nesse contexto, a aplicação de computação em nuvem é interessante para gerar informação sobre a área irrigada no Brasil, subsidiando uma melhor gestão dos recursos hídricos. Foi desenvolvida pela Agência Nacional de Águas (ANA) uma implementação do modelo *Operational Simplified Surface Energy Balance* (SSEBop) para imagens Landsat 7 e 8 em todo o Brasil (ANA, 2019), onde destaca-se a obtenção facilitada de séries temporais de evapotranspiração real modelada, essa ferramenta está em fase experimental mas apresenta grande

potencial para uso no manejo da irrigação em escala de propriedade rural.

Essa nota científica apresenta uma implementação de classificação supervisionada de áreas irrigadas na região de Sorriso e Lucas do Rio Verde/MT com o algoritmo *Classification And Regression Trees* (CART) em ambiente GEE utilizando as bandas 2-7 do satélite Landsat-8 e os índices NDVI, NDWI e SAVI conjuntamente.

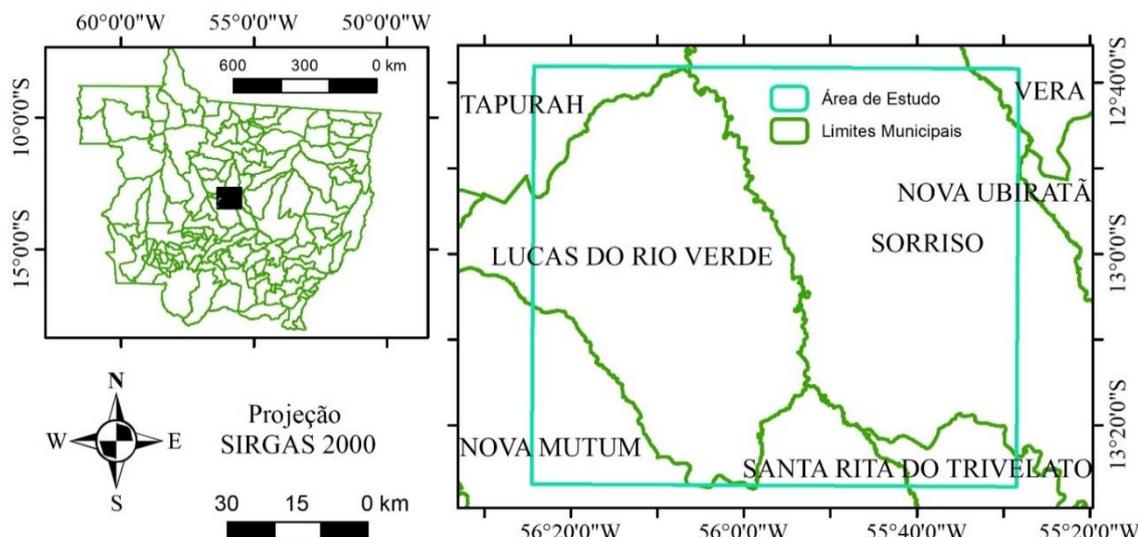
#### 4 MATERIAL E MÉTODOS

A área de estudo, apresentada na Figura 1, é a região no entorno do município de Lucas do Rio Verde (estando localizado entre os paralelos de 12°40'0''S e

13°20'0''S, e entre os meridianos de 55°25'0''W e 56°20'0''W, as margens da BR-163, distante 350 km da capital Cuiabá) e possui uma classificação climática do tipo Aw (Tropical de Savana), com inverno seco e verão chuvoso, temperatura média anual oscilando entre 20 e 25 °C e média pluviométrica anual acima de 1500 mm (CRUZ et al., 2017).

Segundo Beckmann e Oliveira (2010), a região de Lucas do Rio Verde, e municípios vizinhos como Sinop e Sorriso, tem sua economia baseada na agricultura e suas características geoclimáticas favorecem, mais do que no restante do país, o cultivo de uma segunda safra, normalmente milho (popularmente conhecida como safrinha de milho).

**Figura 1.** Localização geográfica da área de estudo.



A Figura 2 apresenta o procedimento de classificação do uso da terra adotado no presente trabalho em ambiente GEE. As imagens de satélite foram filtradas de acordo com sua porcentagem de cobertura de nuvens e compostas em mosaicos das bandas espectrais para geração dos índices. Por ser uma classificação supervisionada, onde há o conhecimento prévio da área por parte do

usuário, foram coletadas amostras de pixels de cada classe para que sejam geradas suas respectivas assinaturas espectrais para realizar a classificação de todos os outros pixels da imagem. O algoritmo CART gerou uma classificação supervisionada utilizando as amostras fornecidas e a partir delas foi extraído um valor de acurácia geral. O sensor orbital utilizado no presente trabalho, assim como o equacionamento

dos índices e da métrica de acurácia geral são apresentadas a seguir.

**Figura 2.** Fluxograma da classificação do uso da terra com ênfase na diferenciação entre área irrigada e sem irrigação.



O satélite LANDSAT-8 foi lançado em 2013 e é proveniente de uma parceria entre o USGS (*United States Geological Survey*) e a NASA (*National Aeronautics and Space Administration*) (USGS, 2013), sendo ocupado por dois sensores: OLI (*Operational Land Imager*), com nove bandas, e TIRS (*Thermal Infrared Sensor*), com duas bandas (USGS, 2013). Os dados

provenientes desses dois sensores fornecem dados e informações muito importantes, e que podem ser utilizadas em estudos ambientais destinados para tomadas de decisões (LOBELL et al., 2015; ZHANG et al., 2015; SOULARD et al., 2016; NASA, 2019). A Tabela 1 apresenta as características das imagens do sensor OLI do satélite LANDSAT-8.

**Tabela 1.** Características das imagens do sensor OLI do satélite LANDSAT-8.

Banda	Espectro	Abreviatura	Comprimento de onda (µm)
2	Azul	BLUE	0,45-0,51
3	Verde	GREEN	0,53-0,59
4	Vermelho	RED	0,64-0,67
5	Infravermelho Próximo	NIR	0,85-0,88
6	Infravermelho de Ondas Curtas 1	SWIR 1	1,57-1,65
7	Infravermelho de Ondas Curtas 2	SWIR 2	2,11-2,29

Fonte: USGS (2013)

O índice NDVI (*Normalized Difference Vegetation Index*) proposto por Rouse et al. (1973) é apresentado na Equação 1, com as abreviaturas de bandas do Landsat-8 apresentados na Tabela 1.

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (01)$$

O NDVI tem sido empregado para detectar os efeitos da sazonalidade, o estágio fenológico da vegetação, duração do período de crescimento, pico de verde e variações fisiológicas das folhas (PONZONI e SHIMABUKURO, 2009). Valores mais elevados correspondem à vegetação sadia, com maior densidade de biomassa verde (entre 0,10 e 1). E os valores mais baixos (entre 0,10 e -1) ocorrem em locais com vegetação estressada e degradada, de porte pequeno representando pouca biomassa. Índices extraídos de bandas espectrais de imagens de sensoriamento remoto são de interesse na identificação de padrões espaciais na presença de vegetação e corpos hídricos, como em Minhoni et al. (2017) que utilizaram o NDVI para distinguir macrófitas aquáticas no reservatório da Usina Hidrelétrica de Barra Bonita (SP).

O índice NDWI (*Normalized Difference Water Index*) foi proposto por Gao (1996) utilizando as bandas espectrais do infravermelho próximo (0,86  $\mu\text{m}$ ) e infravermelho médio (1,24  $\mu\text{m}$ ) com o intuito de delinear feições na água. Como é visto na Tabela 1, essa faixa não é contemplada pelo satélite, por isso utilizou-se a banda no comprimento de onda do verde no cálculo do NDWI por conseguir distinguir satisfatoriamente áreas secas de áreas úmidas (PONZONI e SHIMABUKURO, 2009). A Equação 2 apresenta a formulação matemática do NDWI utilizando as bandas do Landsat-8, com as abreviaturas apresentadas na Tabela 1.

$$NDWI = \frac{GREEN-NIR}{GREEN+NIR} \quad (02)$$

Já para avaliar coberturas vegetais com espaços abertos, ou seja, com interferência de solo exposto, Huete (1988) desenvolveu o Índice de Vegetação Ajustado para o Solo (SAVI – *Soil-Adjusted Vegetation Index*), expresso pela Equação 3 utilizando as bandas do Landsat-8, com as abreviaturas apresentadas na Tabela 1.

$$SAVI = \frac{NIR-RED}{NIR+RED+L} (1 + L) \quad (03)$$

Para cobertura vegetal muito baixa, Huete (1988) sugere o fator L de 1,0; para cobertura vegetal intermediária, fator 0,5, e para altas densidades de vegetação, fator 0,25. Utilizou-se o fator 0,5 (PONZONI e SHIMABUKURO, 2009). Os três índices de vegetação apresentados foram aplicados utilizando as bandas do sensor OLI do satélite Landsat-8 e utilizados, em conjunto com as bandas 2 a 7 do mesmo sensor, como dados de entrada na classificação supervisionada de áreas irrigadas e sem irrigação na área de estudo.

A acurácia geral (Equação 4) foi obtida calculando a razão entre o número de pixels onde o uso da terra modelado pelo algoritmo CART foi o mesmo da amostra correspondente ( $A_C$ ) e o número total de amostras ( $A_T$ ).

$$A_G = \frac{\sum A_C}{\sum A_T} \quad (04)$$

A acurácia geral foi calculada tanto para a classificação supervisionada utilizando os índices espectrais, conforme apresentado nessa seção, como para a classificação utilizando apenas as bandas espectrais (bastando apenas excluir as linhas do código-fonte onde são calculados e adicionados ao dataset “imagem” e “clip”).

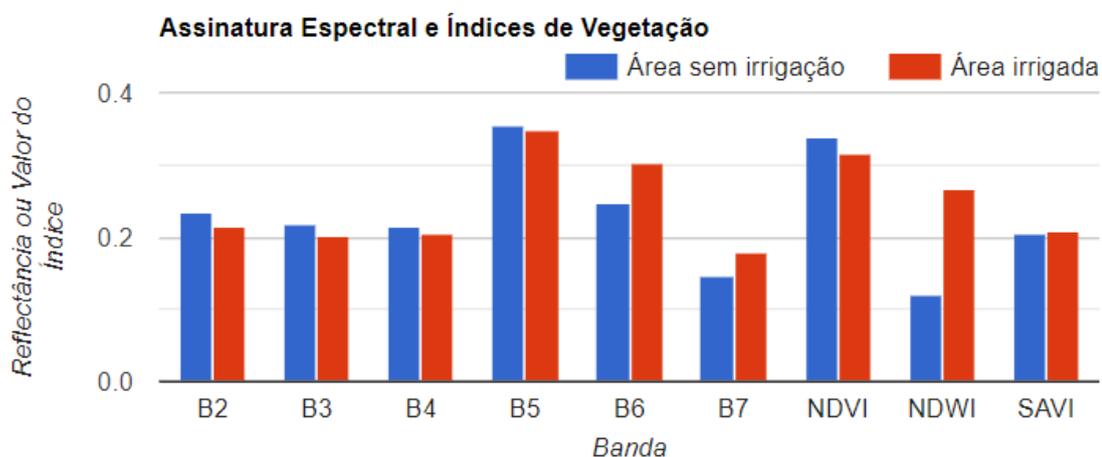
## 5 RESULTADOS E DISCUSSÃO

Foram importados os conjuntos de dados de imagens digitais do Landsat-8 com correção atmosférica TOA (*Top of Atmosphere*) nomeado como “landsat” (seu ImageCollection ID no GEE é “LANDSAT/LC08/C01/T1\_TOA”) e foram amostrados 746 pontos (pixels) de área irrigada (compondo o FeatureCollection chamado “irriga”) e 876 de área não irrigada (“não\_irriga”), composta por vegetação nativa, mata ciliar, eucalipto, solo exposto e pastagem.

O Anexo 1 apresenta o link para a versão final do código aplicado na plataforma de editor de código do GEE com todas as etapas necessárias, nessa ordem:

importação das imagens do satélite Landsat-8 na área de estudo em Lucas do Rio Verde/MT com menos de 0,5% de cobertura de nuvens; a composição do mosaico com essas imagens; a criação de funções que calculam os índices NDVI, NDWI e SAVI e adicionam-nos como novas bandas do mosaico; união das amostras de pixels de área irrigada e não irrigada; função do algoritmo CART para classificação supervisionada; geração de indicadores de acurácia; geração do gráfico de assinatura espectral e média dos índices de vegetação (Figura 3) e exportação da modelagem do NDVI (Figura 4a), NDWI (Figura 4b), SAVI (Figura 4c) e classificação gerada (Figura 4d) em GeoTIFF.

**Figura 3.** Comportamento espectral de áreas irrigadas e sem irrigação na região de Lucas do Rio Verde/MT em fevereiro de 2018.



É notável que a utilização das bandas do visível e infravermelho por si só não distingue áreas irrigadas de áreas sem irrigação. Apenas as bandas do infravermelho de ondas curtas (6 e 7) possibilitaram uma distinção mais clara. SAVI teve pouca efetividade em encontrar essa diferença. O NDVI possibilitou uma diferenciação um pouco melhor, porém ainda baixa. O índice mais efetivo foi o NDWI, que distingue claramente áreas irrigadas de áreas não irrigadas.

A Figura 4 apresenta os índices de vegetação e a identificação de áreas irrigadas na região de estudo.

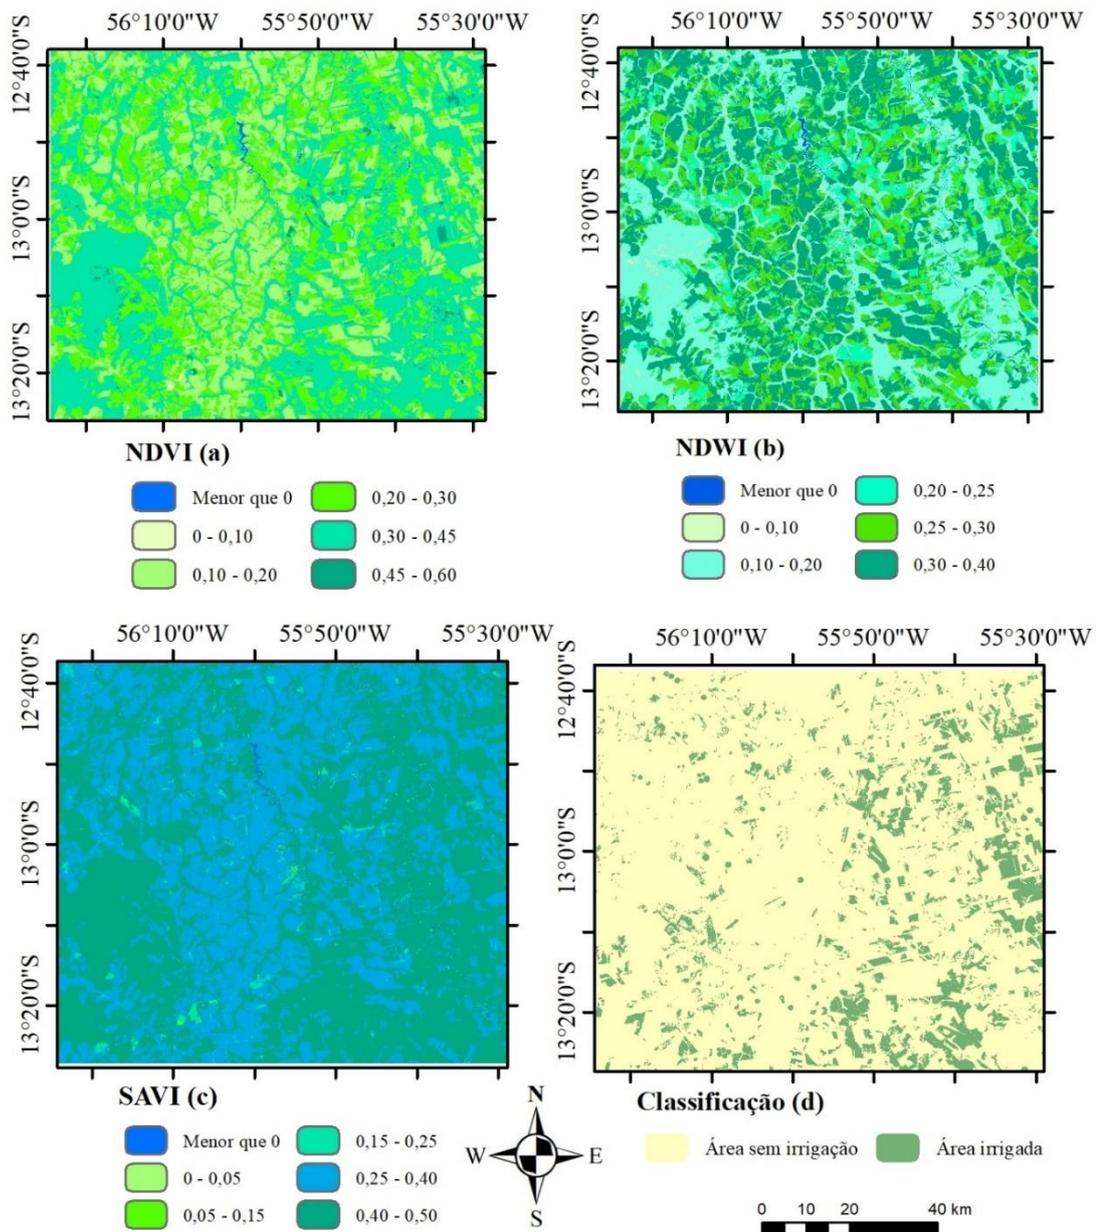
Os corpos hídricos são claramente indicados em tons escuros de azul. Áreas em tons claros de verde são áreas de vegetação sadia, enquanto tons mais escuros são compostas por vegetação baixa ou áreas de solo exposto (sendo preparadas para o plantio).

Comparando NDVI e NDWI verifica-se que apresentam valores similares, porém o NDWI tem maior

distinção entre áreas irrigadas, com maiores valores em áreas de mata ciliar, menores valores em área com solo exposto e valores medianos bem definidos (entre 0,15 e 0,25) em pivôs centrais. Já o NDVI é mais difuso, com áreas irrigadas e de mata ciliar confundidas no mesmo intervalo (entre 0,15

e 0,60). O SAVI apresentou baixa capacidade de distinção entre áreas irrigadas e não irrigadas pela homogeneidade da vegetação, já que não havia vegetação esparsa na região de estudo.

**Figura 4.** Representação do índice de vegetação NDVI (a), NDWI (b), SAVI (c) e a área irrigada (d) classificada na região de Lucas do Rio Verde/MT em fevereiro de 2018.



A acurácia da classificação supervisionada foi de 99,4% ao utilizar os índices NDWI, NDVI e SAVI e de 98,7%

sem utilizar esses índices, ambas consideradas excelentes. O processamento médio, feito 10 vezes, durou o tempo médio

de 52 segundos, considerando todo o código-fonte desenvolvido desde a filtragem das imagens até a conclusão da classificação. É notável a economia de tempo, já que não é necessário realizar o download das imagens, nem os processos de composição e classificação supervisionada em softwares convencionais de geoprocessamento, que podem durar horas.

A presente aplicação se diferenciou também por utilizar não só as bandas 2-7 do Landsat-8, como também os índices NDVI, NDWI e SAVI, para dar suporte ao algoritmo CART. Esse procedimento não é feito de forma trivial em softwares de geoprocessamento mais difundidos. No presente caso o acréscimo de índices extraídos das bandas espectrais não gerou melhora significativa na classificação pelo fato de serem apenas diferenças normalizadas (e corrigidas, no caso do SAVI) dessas mesmas bandas espectrais. Porém, ressalta-se nessa nota científica que, além da facilidade e rapidez do processamento, também é possível com o GEE incluir modelos e produtos de sensoriamento remoto, como vários disponíveis no catálogo de bases de dados do GEE, dentro de uma classificação supervisionada, assim como outras potenciais aplicações dentro do ambiente GEE, como data fusion, krigagem, interpolação espacial e algoritmos de

aprendizado de máquina e inteligência artificial (GORELICK et al., 2017).

## 6 CONCLUSÃO

A classificação supervisionada utilizando o GEE apresentou resultados excelentes utilizando os índices NDWI, NDVI, SAVI e as bandas espectrais 2-7 do Landsat-8. A ferramenta flexibiliza tanto a criação, quanto a utilização de algoritmos de classificação de imagens. Essa flexibilidade permitiu que no procedimento de classificação supervisionada também fossem incluídos índices extraídos das bandas espectrais.

Vários procedimentos que demandam maior tempo, como o download de imagens de satélite, filtragem de nuvens e criação de mosaicos, foram automatizados para serem realizados em nuvem (ou seja, sem a necessidade de utilizar armazenamento local) com rapidez, permitindo que o usuário invista a maior parte do tempo em realizar uma amostragem detalhada para subsidiar a classificação assim como a interpretação dos resultados.

O código-fonte desenvolvido no GEE foi apresentado em anexo de modo a difundir e incentivar o uso do GEE para estudos de inteligência espacial em irrigação e drenagem por sua usabilidade e fácil manipulação.

## 7 REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **SSEBop BR**. Brasília: ANA, 2019. Disponível em: <<https://ssebop.users.earthengine.app/view/ssebop>>. Acesso em: 25 nov. 2019.

BECKMANN, E. OLIVEIRA, A. M. Levantamento e análise do potencial agroindustrial dos municípios mato-grossenses de Sinop, Sorriso e Lucas do Rio Verde. **Revista de Estudos Sociais**, Cuiabá, n. 24, v. 2, p. 105-128, 2010.

CRUZ, G. H. T.; SANTOS, L. C.; SILVA, S. M. C.; REIS, E. F. Desempenho de métodos de estimativa da evapotranspiração de referência para o município de Rio Verde-GO. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v. 11, n.6, p. 1854-1861, 2017.

DUONG, P.; TRUNG, T.; NASAHARA, K.; TADONO, JAXA, T. High-resolution land use/land cover map for central Vietnam in 2007 and 2017. **Remote Sensing**, Basel, v. 10, n. 9, p. 1406-1429, 2018.

EEFLUX. **METRIC-EEFLUX**. Kimberly: University of Idaho, 2017. Disponível em <<http://eeflux-level1.appspot.com/>>. Acesso 17 jun. 2019.

GAO, B. NDWI - Normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, New York, USA, v. 58, n.3, p. 257-266, 1996.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, Amsterdã, v. 202, n. 1, p. 18–27, 2017.

KUMAR, D. P.; LANDAU, E. C. **Levantamento da agricultura irrigada por pivôs Centrais no Brasil em 2013**. Sete Lagoas: Embrapa Milho e Sorgo, 2014. (Boletim de Pesquisa e Desenvolvimento, 106).

HANSEN, M.C.; POTAPOV, P.V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S.A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; KOMMAREDDY, A.; EGOROV, A.; CHINI, L.; JUSTICE, C. O.; TOWNSHEND, J. R. G. High-resolution global maps of 21st-century forest cover change. **Science**, Washington, v.342, n. 6160, p. 850-853, 2013.

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, Amsterdã, v. 25, n. 3, p.205-309, 1988.

KUMAR, L.; MUTANGA, O. Google Earth Engine applications since inception: usage, trends, and potential. **Remote Sensing**, Basel, v. 10, n. 1, p. 1509-1524, 2018.

LOBELL, D.; THAU, D.; SEIFERT, C.; ENGLE, E.; LITTLE, B. A scalable satellite-based crop yield mapper. **Remote Sensing of Environment**, Amsterdã, v.164, n. 1, p. 324-333, 2015.

MAPBIOMAS. **Monitoramento anual de uso da terra – Coleção 4**. Brasília: MapBiomass, 2019. Disponível em <<http://mapbiomas.org/>>. Acesso 17 jun. 2019.

MINHONI, R. T. A.; PINHEIRO, M. P. M.; FILGUEIRAS, R.; ZIMBACK, C. R. L. Sensoriamento remoto aplicado ao monitoramento de macrófitas aquáticas no reservatório de Barra Bonita, SP. **Irriga**, Botucatu, v. 22, n. 2, p. 330-342, 2017.

NASA. **The Landsat Program**. Washington: NASA, 2019. Disponível em: <<http://landsat.gsfc.nasa.gov/>>. Acesso em: 17 jun. 2019.

PONZONI, F.J., SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2009.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources Technology Satellite Symposium, 3., 1973. **Proceedings** [...]. Washington: NASA, 1973. v. 1, p. 309-317.

SILVA, C. O. F.; MANZIONE, R. L.; ALBUQUERQUE FILHO, J. L. Large-scale spatial modeling of crop coefficient and biomass production in agroecosystems in Southeast Brazil. **Horticulturae**, Basel, v. 4, n. 4, 44-64, 2018.

SOULARD, C.E.; ALBANO, C.M.; VILLARREAL, M.L.; WALKER, J.J. Continuous 1985–2012 Landsat monitoring to assess fire effects on meadows in Yosemite National Park, California. **Remote Sensing**, Basel, v.8, n. 5, p. 371-98, 2016.

TSAI, Y.H.; STOW, D.; CHEN, H.L.; LEWISON, R.; AN, L.; SHI, L. Mapping vegetation and land use types in Fanjingshan National Nature Reserve using Google Earth Engine. **Remote Sensing**, Basel, v. 10, p. 927-941, 2018.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 8: Fact Sheet 2013-3060**. Reston: U.S. Department of the Interior, 2013. Disponível em: <<http://pubs.usgs.gov/fs/2013/3060/pdf/fs2013-3060.pdf>>. Acesso em: 8 mai. 2020.

ZHANG, Q.; LI, B.; THAU, D.; MOORE, R. Building a better urban picture: combining day and night remote sensing imagery. **Remote Sensing**, Basel, v.7, n. 9, p. 11887-11913, 2015.

## 8 ANEXO

**Anexo 1.** Código-fonte da identificação de área irrigada em Lucas do Rio Verde em ambiente Google Earth Engine aplicando índices de vegetação em imagens Landsat-8

Utilizando uma conta no Google, acesse o código-fonte e os pontos amostrados (de área irrigada e não irrigada) utilizados para subsidiar a classificação supervisionada, pelo link a seguir: <https://code.earthengine.google.com/6e33caa27417199683943d8741968eaa?noload=true>