

Análise de dados Harmonized Landsat Sentinel para mapeamento de uso e cobertura da terra em área de expansão agrícola no Cerrado

Analysis of Harmonized Landsat Sentinel data for land use and land cover mapping in areas of agricultural expansion in the Cerrado

Andressa Regina Penha

Universidade Estadual de Campinas, Campinas, SP, Brasil

andressa.penha@colaborador.embrapa.br

 <https://orcid.org/0000-0002-1082-4164>

Paulo Roberto Mendes Pereira

Universidade Estadual de Campinas, Campinas, SP, Brasil

p.roberto18@hotmail.com

 <https://orcid.org/0000-0002-8749-6699>

Édson Luis Bolfe

Embrapa Agricultura Digital / Universidade Estadual de Campinas, Campinas, SP, Brasil

edson.bolfe@embrapa.br

 <https://orcid.org/0000-0001-7777-2445>

Daniel de Castro Victoria

Embrapa Agricultura Digital, Campinas, SP, Brasil

daniel.victoria@embrapa.br

 <https://orcid.org/0000-0002-2281-5644>

Taya Cristo Parreiras

Universidade Estadual de Campinas, Campinas, SP, Brasil

tayacristo1@gmail.com

 <https://orcid.org/0000-0003-2621-7745>

RESUMO

Diferentes iniciativas de mapeamento de uso e da cobertura da terra por sensoriamento remoto orbital têm sido realizadas com objetivo de apoiar o planejamento agroambiental no Cerrado. No entanto, a complexa dinâmica agropecuária regional exige um maior detalhamento na discriminação dos usos agrícolas, tarefa que exige séries temporais de imagens de satélite. Este estudo objetivou avaliar se o uso integrado de dados Landsat 8 *Operational Land Imager* (OLI) e Sentinel-2 *Multispectral Instrument* (MSI) pode contribuir para o possível aumento da exatidão de classificações digitais de uso e cobertura da terra em região de expansão agrícola no Cerrado. Para isso, o município de Balsas, que possui relevante interesse econômico e agroambiental, foi escolhido como área de estudo para avaliar a performance de modelos *Random Forest* de classificação gerados com dados dos sensores OLI/Landsat 8 e MSI/Sentinel 2, de forma individual e integrada, por meio de uma base de dados inovadora *Harmonized Landsat Sentinel 2* (HLS). Os modelos MSI, HLS e OLI apresentaram performance semelhante, com Exatidão Global de 0,857, 0,844 e 0,832, e índice de Kappa de 0,819, 0,803 e 0,787, respectivamente. O Teste T indicou que esses resultados não são estatisticamente diferentes entre si. Apesar da performance do modelo, o mapa final elaborado com os dados OLI apresentou elevadas perdas de informações por ausência de *pixels* na série temporal. Os novos dados HLS mostraram-se aptos para mapeamento de uso e cobertura, mesmo em larga escala, em resolução de 30 m, com muito boa exatidão e tempo reduzido de processamento em relação aos dados MSI. Os resultados obtidos podem apoiar a tomada de decisão no planejamento e execução de novos mapeamentos agrícolas do Cerrado.

Palavras-chave: Sensoriamento Remoto, Multisensor, HLS, Agricultura, Balsas.

ABSTRACT

Different initiatives for mapping land use and land cover using orbital remote sensing have been carried out with the aim of supporting agri-environmental planning in the Brazilian Savanna (Cerrado). However, the complex regional agricultural dynamics require more detail in the discrimination of agricultural uses, which requires time series of satellite images (SITS). This study aimed to evaluate how the integrated use of Landsat 8 Operational Land Imager (OLI) and Sentinel-2 Multispectral Instrument data can contribute to digital land use and land cover mapping in medium spatial resolution. The municipality of Balsas, a region of agricultural expansion in the Cerrado of Maranhão State and relevant economic and agro-environmental interest, was chosen as a study area to evaluate the performance of Random Forest classification models generated with data from Landsat 8, Sentinel-2, and the Harmonized Landsat Sentinel 2 (HLS). The MSI, HLS, and OLI models presented similar performance, with Global precision of 0.857, 0.844, and 0.832, and Kappa index of 0.819, 0.803, and 0.787, respectively. The T-Test indicated that these results are not statistically different. However, despite the models' performance, the final map created with the OLI data showed a high loss of information due to the absence of pixels in the time series. The new HLS data proved suitable for land use and coverage mapping, even on a large scale, at a resolution of 30 m, with precision and reduced processing time compared to the MSI data. These results can support decision-making in the planning and execution of new agricultural mapping of the Cerrado Biome.

Keywords: Remote Sensing, Multisensor, HLS, Agriculture, Balsas.

1. INTRODUÇÃO

O Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2021) projeta que a produção de grãos no Brasil poderá ultrapassar o atual patamar de 270 milhões de toneladas na safra 2020/21 para 380 milhões de toneladas em 2030/31. Quanto à produção de carnes (frango, suína e bovina), essas projeções indicam um crescimento de 37%, passando de 27 milhões para 37 milhões de toneladas no mesmo período. Há, também, crescente demanda do mercado nacional e internacional por produtos como algodão, celulose, leite, açúcar e frutas. Estas projeções indicam ainda que a expansão da área agrícola deve ocorrer especialmente no bioma Cerrado. Bolfe *et al.* (2020), após análise da dinâmica agrícola do Cerrado nas últimas quatro décadas, enfatizam que a agropecuária foi o alicerce para o posicionamento do Brasil como um dos maiores produtores e exportadores mundiais de alimentos.

As mudanças no uso e cobertura da terra estão entre as modificações ambientais globais mais significativas. O monitoramento da velocidade, extensão e intensidade dessas mudanças possibilita a compreensão detalhada dos padrões de organização do espaço, sendo um instrumento basilar para a elaboração de políticas e ações de planejamento territorial (LAMBIN *et al.*, 2001). Santos *et al.* (2018) destacam que, em função da grande variabilidade de ambientes existentes no Cerrado, tanto antrópicos quanto naturais, é consenso da comunidade científica que existem dificuldades expressivas para a caracterização ampla das principais representações do uso e cobertura da terra, frente às limitações encontradas.

As pesquisas nessa temática se intensificaram a partir do desenvolvimento do sensoriamento remoto orbital, no qual a visão panorâmica e a repetitividade das imagens orbitais possibilitam a obtenção de informações históricas e atuais, permitindo a análise do uso e cobertura das terras, principalmente em regiões de grandes extensões, a um custo relativamente baixo (REID *et al.*, 2000; SRIVASTAVA *et al.*, 2011; LI *et al.*, 2016; SÁNCHEZ-ESPINOSA; SCHRÖDER, 2019). Dessa forma, as aplicações envolvem diferentes temáticas, como as mudanças no uso da terra (ZHENG *et al.*, 2015; ISLAM *et al.*, 2018), desmatamento e estimativa da vegetação (GRINAND *et al.*, 2013; RODRIGUES, 2018), expansão agrícola (SANO *et al.*, 2009; YAN *et al.*, 2019), inventários florestais (SANTOS *et al.*, 2018), análise de classificação digital (DURO; FRANKIN; DUBÉ, 2012), harmonização de imagens (CLAVERIE *et al.*, 2018; WULDER *et al.*, 2021, PARREIRAS *et al.*, 2022).

Das mais importantes fontes de imagens orbitais para monitoramento e mapeamento agroambiental na atualidade são os sistemas sensores Landsat 8-9 *Operational Land Imager* (OLI) e o Sentinel-2 *Multispectral Instrument* (MSI) A e B. Apesar de apresentarem diferentes características de resolução espacial, temporal, espectral e radiométrica (**Tabela 1**), as similaridades entre os instrumentos OLI e MSI possibilitam o uso integrado de suas imagens por meio de técnicas de harmonização (CLAVERIE *et al.*, 2018).

Tabela 1: Características gerais de resolução dos sistemas sensores Landsat 8 OLI e Sentinel-2 MSI

Sistema Sensor	Espacial*	Temporal	Espectral	Radiométrica
Landsat - 8 /OLI	30, 15 e 60 m	16 dias*	435-2.294 nm (8 bandas)	16 bits
Sentinel-2 A e B	10, 20 e 60 m	5 dias	490-2.190 nm (13 bandas)	12 bits

Fonte: Elaborado pelos autores com base em NASA (2018) e ESA (2013).

Desde 2018, a *National Aeronautics and Space Administration* (NASA) tem disponibilizado imagens OLI e MSI harmonizadas por meio da iniciativa inovadora de *Harmonized Landsat Sentinel 2* (HLS) (CLAVERIE *et al.*, 2018; NASA, 2018a). O projeto HLS visa gerar imagens de média resolução espacial com período de revisita de 2 a 3 dias, disponibilizadas gratuitamente (NASA, 2018a). Para isso, as imagens OLI e MSI são submetidas a algoritmos de correção atmosférica, co-registro espacial, normalização da Função de Distribuição de Reflectância Bidirecional (BRDF),

ajuste de passagem de bandas para normalização dos ângulos de visada e iluminação, promovendo o ajuste linear entre bandas equivalentes (CLAVERIE *et al.*, 2018). Dentre os produtos resultantes desse processo, estão o *Landsat Operational Land Imager Surface Reflectance and TOA Brightness Daily Global 30m*, doravante HLS.L30, e o *Sentinel-2 Multi-spectral Instrument Surface Reflectance Daily Global 30m*, doravante HLS.S30, que podem ser usados de forma integrada, além de formar uma série temporal única e mais densa (PARREIRAS *et al.*, 2022).

Em regiões tropicais como o Cerrado, o monitoramento dos processos da dinâmica agrícola é severamente comprometido pela elevada ocorrência de nuvens que compromete a disponibilidade de imagens “limpas”, principalmente de sensores de média resolução espacial, dificultando ou inviabilizando a obtenção de informações válidas em períodos-chave (PRUDENTE *et al.*, 2020). O uso integrado de dados multisensores, como o HLS, pode melhorar consideravelmente o número de observações válidas em uma série temporal, aumentando a cobertura temporal, o que representa uma importante estratégia de superação dos desafios no monitoramento do uso e cobertura da terra (QUINTANO *et al.*, 2018). Séries temporais mais densas geradas pelo HLS são úteis para análises temporais de fenômenos naturais e antrópicos, bem como apresentam elevado potencial para o mapeamento e monitoramento de cultivos agrícolas (PARREIRAS *et al.*, 2022).

Segundo maior bioma do Brasil, com aproximadamente 2 milhões de km² recobrindo cerca de 23,93% do território brasileiro, o Cerrado é estratégico, principalmente, por suas características ambientais, biodiversidades, recursos hídricos e serviços ecossistêmicos. Considerada a “última fronteira agrícola do Brasil”, o Cerrado envolve 58% da área agrícola do país, com destaque para a produção de soja, milho, algodão e cana-de-açúcar (IBGE, 2021). Apesar da extensão agrícola, o bioma possui apenas 13,29% de sua área legalmente protegida, sendo 8,50% por unidades de conservação, 4,54% por terras indígenas e 0,25% em áreas quilombolas. Apenas 2,74% do Cerrado é protegido integralmente por unidades de conservação, e 5,76% da área do bioma é ocupado por unidades de conservação de uso sustentável (MMA, 2020).

Essa baixa proteção tem influenciado diretamente nas elevadas taxas de supressão da vegetação que o Cerrado vem apresentando nos últimos anos. Dados do TerraClass Cerrado indicam que até 2013 aproximadamente 43,6% das áreas de vegetação natural do Cerrado foram convertidas em outros usos, sobretudo pastagens (29,5%), culturas temporárias e permanentes (11,7%) e silvicultura (1,5%) (SCARAMUZZA *et al.*, 2017). Assis *et al.* (2019) apontam que o desmatamento no Cerrado, entre 2015 e 2022, foi de aproximadamente 66.447,78 km², com destaque para os estados do Maranhão, Tocantins e Bahia, líderes nacionais de desmatamento no recorte temporal destacado. Estes estados compõem, junto com o Piauí, a região denominada de “Matopiba”, que abrange cerca de 35% da área do Cerrado e é considerada a nova frente de expansão agrícola do Brasil, estando no centro dos debates recentes sobre desenvolvimento econômico e preservação ambiental (BOLFE *et al.*, 2016).

O Matopiba concentrou aproximadamente 62% de toda área desmatada do Cerrado entre os anos de 2015 e 2022, com destaque para o Maranhão e o Tocantins, estados que lideram as estatísticas de desmatamento do Cerrado (INPE, 2022). No Maranhão, o Cerrado cobre aproximadamente 217 mil km² distribuídos em 119 municípios (IBGE, 2019). O Cerrado maranhense tem passado por intensas transformações espaciais, principalmente pela expansão da agropecuária sobre área de vegetação natural, processo intensificado a partir de 2008. Dados do INPE (2023) mostram que somente entre o ano de 2019 e 2022 o estado do Maranhão concentrou 24,98% de toda vegetação natural suprimida, o que corresponde a uma área de 8.356,10 km², sendo o município de Balsas o líder nacional de supressão da vegetação nos últimos três anos.

Esse processo intenso e dinâmico tornou o município de Balsas o principal polo de produção agrícola do Maranhão e responsável por aproximadamente 30% de toda a produção do estado (IBGE, 2022). Assim, o município se torna uma região propícia para estudos que visem desenvolver e aprimorar metodologias de monitoramento da expansão de áreas antropizadas com uso de imagens orbitais, sendo importantes ferramentas para a gestão territorial. Bolfe *et al.* (2020) avaliam que as,


apesar dos desafios ainda existentes, análises geoespaciais de uso e cobertura da terra, baseadas em sensoriamento remoto, são fundamentais para melhorar a compreensão dos processos de transição, expansão, retração, diversificação, conversão e intensificação agrícola, assim, para o planejamento do desenvolvimento sustentável da agricultura (BOLFE *et al.*, 2020). Neste contexto, o objetivo deste estudo foi avaliar a performance de dados OLI, MSI e HLS em modelos *Random Forest* de classificação de uso e cobertura da terra em região de expansão agrícola no Cerrado. A principal hipótese é de que a resolução temporal aprimorada do HLS contribui para elevar a exatidão do mapeamento. Ademais, também foi avaliado se a resolução espacial e a temporal do MSI, maiores em relação ao OLI, resultam em mapeamento mais acurado e detalhado do uso e cobertura da terra.

2. MATERIAIS E MÉTODOS

2.1. Área de Estudo

O município de Balsas possui extensão territorial de 13.141,64 km², encontra-se localizado na porção sul do estado do Maranhão, Brasil, tendo como coordenadas limítrofes 7°31'39.24"S e 9°24'43.37"S; 45°40'18.06"O e 46°02'44.51" (Figura 1). A população estimada em 2020 foi de 95.929 habitantes, com densidade demográfica 6,36 hab./km², sendo que 87% residem na zona urbana (IBGE, 2012). Balsas tem como principal atividade econômica o setor de produtos e serviços que correspondem a 65,9% do PIB municipal. O município apresenta Índice de Desenvolvimento Humano de 0,687, classificado como médio, e mesmo possuindo elevado Produto Interno Bruto (terceiro do Maranhão em 2019), caracteriza-se por elevada taxa de pobreza, com cerca de 40% da população apresentando rendimento médio de até meio salário-mínimo, com apenas 20% da população ocupada (IBGE, 2021).

Figura 1: Localização do município de Balsas, Maranhão (2020).



Fonte: Adaptado de IBGE (2021).

Quanto às características ambientais, Balsas possui embasamento geológico predominantemente sedimentar, composto por rochas das formações Corda, Piauí, Pedra de Fogo, Motuca, Sambaíba e coberturas cenozoicas, onde dominam intercalações de folhelhos mesclados a


arenitos, argilitos, sílex e derrames basálticos. A topografia é majoritariamente plana, variando entre 211 metros e 657 metros de altitude, sendo o relevo composto por extensas superfícies de aplainamentos mesclados por colinas de topografia suavemente onduladas, formações tabuliformes residuais de topografia escarpada e vales fluviais entalhados. Na região, prevalecem os Latossolos Amarelos e Vermelho-Amarelos distróficos, em menor proporção, Argissolos Vermelho-Amarelos distróficos, Plintossolos Háplicos distróficos, Neossolos Quartzarênicos órticos, e manchas de Gleissolos (BATISTELLA *et al.*, 2013).

O município caracteriza-se por clima subúmido seco com médias anuais pluviométricas variando entre 800 e 1200 mm, com dois períodos relativamente bem definidos, um chuvoso, de outubro a março, na qual se tem maiores índices de precipitação, e um seco de abril a setembro, com índices de precipitações que não ultrapassam os 50 mm para este período. Apresenta temperatura média mensal mínima de 26°C e temperatura média mensal máxima de 38°C, com umidade relativa do ar que varia entre 60 e 80%. Os fatores pedo-geomorfológicos em associação com as características climáticas condicionam a formação de uma rica e complexa estrutura fitofisionômica, composta por um conjunto de árvores adaptadas às condições ambientais, troncos tortos, cobertos por uma cortiça grossa, cujas folhas são geralmente grandes e rígidas, agrupadas em três formações distintas: florestais, savânicas e campestres (RIBEIRO; WALTER, 2008).

2.2. Procedimentos Metodológicos

A metodologia seguiu diferentes rotinas de tratamento digital de imagem de satélite, sintetizadas em cinco etapas conforme ilustradas no fluxograma metodológico (**Figura 2**).

Figura 2: Fluxograma metodológico utilizado para o mapeamento de uso e cobertura das terras no município de Balsas, Maranhão



Fonte: Elaborado pelos autores (2022).

2.2.1. Base de Dados

Para aquisição das imagens de satélite, foram adotados os seguintes critérios de seleção: i) período de aquisição entre março e outubro de 2021; ii) limite de cobertura de nuvens inferior a 10%.

Os dados Landsat 8 *Operational Land Imager* (OLI), de 30 m de resolução espacial, foram adquiridos via *Google Earth Engine* (GEE). As imagens foram obtidas do acervo *Landsat 8 Level 2, Collection 2, Tier 1*. Os dados Sentinel-2 *Multispectral Instrument* (MSI) *Level 2-A*, com 10 m de resolução espacial, também foram obtidos no GEE. Todas as imagens OLI e MSI foram baixadas do GEE após a filtragem pela cobertura máxima de nuvens, mosaicagem, recorte para a área de interesse, aplicação das bandas de qualidade para remoção de *pixels* contaminados.

Os dados HLS, por sua vez, foram adquiridos por meio da plataforma *Application for Extracting and Exploring Analysis Ready Samples* (AppEEARS) (NASA, 2022). Essas imagens foram adquiridas dos mesmos períodos referentes aos dados OLI e MSI, de modo que a série temporal HLS fosse composta pelas imagens harmonizadas MSI (ou HLS.S30), e OLI (ou HLS.L30), ambas em 30 m de resolução espacial. Na AppEEARS, os dados são disponibilizados já mosaicados, recortados para área de estudo, em valores de reflectância, bem como em sistema de coordenadas geográficas no Datum WGS84. Para todas as fontes de dados, foram adquiridas imagens nas bandas do azul, verde, vermelho e infravermelho próximo, que são as bandas 2, 3 e 4, nos três casos, e as bandas 5 (OLI), 8 (MSI) e 8A (HLS), respectivamente.

Salienta-se que não foi realizada técnica de reamostragem de *pixels* para os conjuntos de imagens utilizadas, uma vez que o objetivo desse estudo é avaliar se o nível de exatidão no mapeamento de diferentes classes de uso e cobertura realizado por meio de imagens harmonizadas Landsat Sentinel 2 apresenta diferença significativa em relação aos resultados obtidos com dados Landsat e Sentinel 2 individualmente.

2.2.2. Amostragem e definição das classes

Para treinar o classificador *Random Forest*, foram utilizados 3.280 pontos amostrais, sendo que 168 foram coletados em atividade de campo no mês de julho de 2021, e 3.112 foram criados aleatoriamente, utilizando a ferramenta *random points* presente no Terra View 5.1. Os pontos aleatórios foram identificados e rotulados a partir de interpretação visual, conforme características visualmente perceptíveis (cor, textura e forma), utilizando uma composição falsa-cor com realce no vermelho, RGB 432, tendo como base imagens Sentinel-2, sendo consideradas neste estudo: i) formações florestais; ii) formações savânicas; iii) formações campestres; iv) pastagens; v) culturas temporárias. A **Tabela 2** e a **Figura 3** mostram a distribuição dos pontos amostrais e a chave de interpretação para a identificação por classe de uso e cobertura.


Tabela 2: Total de amostras coletadas por classe

Classe	Nº de amostras
Formações florestais	789
Formações savânicas	755
Formações campestres	575
Pastagens	424
Culturas temporárias	737

Fonte: Elaborado pelos autores (2022).

Corpos hídricos, silvicultura e áreas não vegetadas não foram mapeadas neste estudo, uma vez que ocupam uma porção muito pequena do município. Para isolar *pixels* referentes a esses usos na elaboração do mapa final, foi gerada uma máscara binária, em formato *raster*, a partir de dados da sétima coleção do MapBiomas (MAPBIOMAS, 2022), na qual a presença de quaisquer dessas classes era representada pelo valor 1, e a ausência, por 0.

Figura 3: Principais classes de uso e cobertura da terra do município de Balsas, Maranhão (2021)



Fonte: Elaborado pelos autores (2022).

2.2.3. Modelagem, classificação e análise de performance

As classificações foram elaboradas utilizando o algoritmo de aprendizado de máquina *Random Forest* (RF). O RF utiliza estratégias inteligentes de classificação, criando um grande conjunto de árvores de decisão geradas de forma independente e aleatória que quando combinadas produzem resultados com elevada precisão (BREIMAN, 2001; MAXWELL; WARNER; FANG, 2018; ZHANG; YANG, 2020). O RF é amplamente utilizado em estudos e mapeamentos de uso e cobertura da terra e, em geral, apresenta alta performance em diferentes escalas e níveis hierárquicos de classificação.

Os modelos RFs foram gerados em ambiente R (R versão 4.2.2) utilizando recursos dos pacotes *randomForest* (LIAW; WIERNER, 2022) e *caret* (KUHN, 2022). Previamente à geração dos

modelos, foi realizada a divisão aleatória do banco de dados amostral em dois subconjuntos, de treinamento e teste, em uma razão de 70% e 30%, respectivamente. O algoritmo necessita da definição de dois parâmetros básicos, o número de variáveis aleatoriamente amostradas como candidatas em cada divisão (*mtry*) e o número máximo de árvores de decisão a ser criado (*ntree*). O *mtry* foi definido, por padrão, como a raiz quadrada no número de variáveis. O *ntree*, por sua vez, foi determinado como o menor número de árvores a partir do qual ocorre a estabilização do erro, entre 100 e 500.

Para avaliar a performance dos modelos OLI, MSI e HLS foram considerados o coeficiente de Kappa (**Equação (1)**) e a Exatidão Global (**Equação (2)**), além dos erros de inclusão ou comissão (**Equação (3)**) e de omissão (**Equação (4)**) para avaliar a precisão das classes, calculados a partir da matriz de confusão. A matriz de confusão corresponde a um modelo clássico e binário elaborado a partir de tabulação cruzada de dados de classificação de imagens de satélite e informações corretamente classificadas (CONGALTON, 1991).

A exatidão global indica a porcentagem de acertos a partir do número total de amostras classificadas corretamente e sua relação com o número total de amostras utilizadas. Como representa o nível de precisão geral da classificação, a exatidão global é diretamente interpretável, dado que corresponde às probabilidades gerais de um *pixel*, aleatoriamente escolhido, ser corretamente classificado. Também possibilita avaliar erros de comissão (produtor) e omissão (usuário) referentes às diferentes classes encontradas em um determinado mapa temático (CONGALTON, 1991). Já o índice Kappa possibilita avaliar a diferença estatística das classificações. Segundo Silva Júnior *et al.* (2014), esse índice apresenta vantagens sobre a exatidão global, visto que incorpora todos os elementos da matriz de erro, os objetos classificados corretamente ou não. Além disso, avalia a exatidão temática porque é mais sensível às variações dos erros de comissão e omissão.

$$K = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{n(n-1)} \quad (1)$$

$$E_g = \left(\frac{\sum_{i=1}^r x_{ii}}{n} \right) \quad (2)$$

$$K_p = \quad (3)$$

$$K_u = \quad (4)$$

Onde *n* é número total de amostras utilizadas; *k* é o valor do Índice Kappa; *E_g* é o Índice Global da classificação; *K_p* representa a exatidão do produtor por classe; *K_u* é a acurácia de usuário por classe; $\sum_{i=1}^r x_{ii}$ é a soma da diagonal principal; $\sum_{i=1}^r x_{i+} x_{+i}$ representa o produto da soma da linha pelas colunas de cada classe representativa; *n_{ii}* número total de amostras corretamente classificadas da classe; *k*; *n_{i+}* número total de amostras classificadas da classe *k*; *n_{+i}* é o número total de amostras coletadas da classe *k*.

Para verificar se há diferenças estatisticamente significativas entre as performances dos modelos com dados OLI, MSI e HLS, foi realizado, nos valores de Exatidão Global e Kappa, o teste *Student's t-test*, ou teste T, considerando um intervalo de confiança de 95%. Para isso, foram utilizados os recursos do pacote *Basic Statistics and Data Analysis (BSDA)* (ARNHOLT; EVANS, 2021).

3. RESULTADOS E DISCUSSÕES

3.1. Disponibilidade de imagens

Como previamente discutido, um dos mais importantes desafios do mapeamento de uso e cobertura da terra em regiões tropicais é a elevada presença de nuvens, que impacta diretamente na

disponibilidade de imagens orbitais do espectro óptico, principalmente aquelas geradas por sistemas sensores de baixa ou média resolução temporal, como é o caso do Landsat 8 (PRUDENTE *et al.*, 2020). Nesse sentido, a harmonização de dados OLI e MSI (HLS) surge como uma importante estratégia para aprimorar o volume de dados disponíveis, com grande potencial para melhorar a qualidade do monitoramento e mapeamento de uso e cobertura da terra no Brasil (PARREIRAS *et al.*, 2022). Como este estudo foi realizado utilizando dados do ano de 2021, a coleção Landsat ainda não contava com as imagens capturadas com o satélite Landsat 9. Dessa forma, a resolução temporal do Landsat 8 disponível foi de 16 dias. Assim, considerando o limite de cobertura de nuvens e o período de estudo adotados, foram observadas apenas 5 datas com dados OLI nesses critérios.

Por outro lado, considerando uma resolução de 5 dias entre os satélites Sentinel-2 A e B, o número médio de observações por *pixel* foi de 21, ou seja, 4 vezes superior ao OLI. Considerando todas as datas MSI + OLI, a série temporal dados harmonizados (HLS.S30 + HLS.L30) contou com 26 datas entre março e outubro de 2021. É importante ressaltar que, devido à grande extensão do município de Balsas, são necessárias 2 datas consecutivas para preencher um único mosaico completo do município, sendo necessário obter imagens MSI de 9 *tiles*. Assim, apesar de terem sido observadas 37 datas para MSI, no total, em sua grande maioria, os mosaicos representavam apenas metade da área de estudo. Os dados HLS.S30, originados pelo MSI, foram disponibilizados como mosaicos completos para duas datas de passagem consecutivas, formando um único arquivo.

3.2. Classificações Digitais e Análise de Acurácia

Os resultados dos modelos OLI, MSI e HLS são exibidos na **Tabela 3**.

Tabela 3: Resultados de Exatidão Global, coeficiente de Kappa e nível de significância dos modelos *Random Forest* de classificação de uso e cobertura da terra em Balsas-MA, gerados com dados Landsat 8 (OLI), Sentinel-2 (MSI) e *Harmonized Landsat Sentinel-2* (HLS)

Fonte/Métrica	Exatidão Global	Kappa	p-valor
Landsat 8 (OLI)	0.8318	0.7875	< 2.2 ^{e-16}
Sentinel-2 (MSI)	0.8568	0.8195	< 2.2 ^{e-16}
HLS (S30 + L30)	0.8443	0.8034	< 2.2 ^{e-16}

Fonte: Elaborado pelos autores (2022).

As **tabelas 4, 5 e 6** trazem a matriz de confusão dos modelos OLI, MSI e HLS, respectivamente, juntamente com a acurácia do produtor (A.P.) e do usuário (A.U.) de cada uma das classes mapeadas.

Tabela 4: Matriz de confusão e acurácia do produtor (A.P.) e do usuário (A.U), obtidos com modelos *Random Forest* de classificação de uso e cobertura da terra em Balsas-MA, gerado com dados Landsat 8 (OLI)

Classes	FF	FS	FC	PAS	CT
FF	204	9	1	0	1
FS	13	201	16	8	1
FC	1	11	123	12	8
PAS	0	2	13	84	20
CT	0	0	8	37	184
A.U.	0,9488	0,8410	0,7935	0,7059	0,8035
A.P.	0,9358	0,9013	0,7639	0,5957	0,8598

FF- Formações florestais; FS- Formações savânicas; FC- Formações campestres; PAS- Pastagens; CT-Culturas temporárias

Fonte: Elaborado pelos autores (2022).

Tabela 5: Matriz de confusão e acurácia do produtor (A.P.) e do usuário (A.U), obtidos com modelos *Random Forest* de classificação de uso e cobertura da terra em Balsas-MA, gerado com dados Sentinel-2 (MSI)

Classes	FF	FS	FC	PAS	CT
FF	207	13	1	0	1
FS	10	190	10	7	1
FC	1	13	129	10	10
PAS	0	6	8	103	11
CT	0	1	13	21	191
A.U.	0,9324	0,8715	0,7914	0,8047	0,8451
A.P.	0,9495	0,8520	0,8012	0,7305	0,8925

FF- Formações florestais; FS- Formações savânicas; FC- Formações campestres; PAS- Pastagens; CT-Culturas temporárias

Fonte: Elaborado pelos autores (2022).

Tabela 6: Matriz de confusão e acurácia do produtor (A.P.) e do usuário (A.U), obtidos com modelos *Random Forest* de classificação de uso e cobertura da terra em Balsas-MA, gerado com dados *Harmonized Landsat Sentinel-2* (HLS)

Classes	FF	FS	FC	PAS	CT
FF	206	12	1	1	1
FS	10	198	14	2	1
FC	1	11	128	11	8
PAS	1	2	9	89	17
CT	0	0	9	38	187
A.U.	0,9321	0,88	0,8050	0,7542	0,7991
A.P.	0,9449	0,8878	0,7950	0,6312	0,8738

FF- Formações florestais; FS- Formações savânicas; FC- Formações campestres; PAS- Pastagens; CT-Culturas temporárias

Fonte: Elaborado pelos autores (2022).

Apesar do Índice Kappa e da Exatidão Global revelarem valores de performance superiores para o conjunto de dados MSI, o teste T não apontou diferença estatisticamente significativa entre nenhum dos 3 modelos em um nível de significância de 95%. A maior resolução espacial do sensor MSI (10 metros) não resultou em maior precisão na separação das diferentes classes de uso e cobertura analisadas neste estudo. Estes resultados corroboram com os que foram observados por Sanches-Espinosa e Schöder (2019), que mostram discreta superioridade da MSI/Sentinel-2 (0,807) em relação a OLI/Landsat-8 (0,800) no mapeamento de áreas úmidas no sul da Espanha. Parreiras et al. (2022), em um processo de classificação hierárquica de ambientes agrícolas e naturais no Cerrado, também observaram performance sem diferença estatisticamente diferentes entre modelos OLI, MSI e HLS em níveis hierárquicos superiores (áreas agrícolas x vegetação natural). Por outro lado, Freires et al. (2019), ao mapear os padrões de cobertura da terra do maciço de Uruburetama, ambiente de Caatinga, também indicaram melhor desempenho dos dados MSI/Sentinel-2 (Kappa de 0,833) em comparação a OLI/Landsat-8 (Kappa de 0,426). Já Calixto et al. (2017) utilizou o classificador não supervisionado *K-means* para identificar diferentes classes de uso e cobertura entre São Paulo e Minas Gerais, no qual obtiveram ligeira superioridade da imagem OLI/Landsat-8 (Kappa de 0,867) em relação à MSI/Sentinel-2 (Kappa de 0,860).

No que diz respeito à precisão das classes para as áreas de vegetação natural mapeadas com o maior nível de precisão, observa-se que os três conjuntos de dados performaram em nível semelhante. Dentre as três classes de vegetação natural, as formações campestres (FC) obtiveram os menores níveis de acurácia de produtor e usuário. A classe que mais gerou erros de classificação para as FC foi a de pastagens. Ao mapear o uso e cobertura da terra no Cerrado, Sano et al. (2020) reportaram que a separação entre essas classes foi a mais desafiadora. Dentre os fatores que ajudam

a explicar as confusões ocorridas na classificação das pastagens, Sano *et al.* (2009) afirmam que as pastagens apresentam distintos padrões espectrais que variam de acordo com o estágio de desenvolvimento, espécie e solo onde se encontram, como nos casos das pastagens nativas e cultivadas. Além disso, as áreas de campo conduzidas como pastagens se assemelham às feições naturais do Cerrado, como os campos e as savanas, apresentando textura intermediária e coloração variante do marrom ao magenta. Já as pastagens cultivadas, que possuem, em certos casos, vegetações exóticas e mais produtivas, apresentam textura lisa, com a manutenção regular dos pastos e cores variantes do verde ao azul, similares às áreas de culturas temporárias (SANO *et al.*, 2009).

Assim como o que foi observado por Oldoni *et al.* (2019) e Parreiras *et al.* (2022), a classe de pastagens foi a que apresentou pior desempenho entre todas as analisadas. Diferentemente das áreas agrícolas, as pastagens são áreas sem padrão de forma e manejo, em geral menores que talhões agrícolas, cuja vegetação gramínea pode ser confundida com formações campestres e algumas culturas temporárias, como a cana-de-açúcar. Isso pode justificar considerável melhora no desempenho do classificador para essa classe trazida pelo conjunto de dados MSI (10 m).

3.3. Mapas Digitais de Uso e Cobertura da Terra

Após as etapas de treinamento e validação dos modelos, foram gerados os mapas finais das classificações utilizando a função *predict* do pacote *terra* (HIJMANS *et al.*, 2023), sobre as séries temporais empilhadas de *rasters* OLI, MSI e HLS. Como foi mencionado previamente, foi aplicada uma máscara binária para isolar *pixels* referentes aos corpos hídricos, áreas não vegetadas (áreas urbanas e outras) e silvicultura. Apesar de serem exibidas nos mapas finais, a extensão dessas classes foi gerada na coleção 7 do MapBiomias (MAPBIOMIAS, 2022).

Embora a série temporal OLI tenha contado apenas com 5 datas com cobertura de nuvens inferior a 10%, o teste T mostrou que sua performance não foi significativamente inferior ao MSI e HLS. Por outro lado, como o que foi observado em Parreiras *et al.* (2022), a baixa disponibilidade de dados produz impactos negativos na última etapa do processo: a geração do mapa final. A **Tabela 7** mostra que mapeamento gerado com dados OLI estimou 11.024 km² de área distribuídos entre as cinco classes do estudo. Considerando a área que foi mascarada com dados do MapBiomias (corpos hídricos, silvicultura e áreas não vegetadas), que totalizam 942,15 km², o modelo com dados OLI levou a um mapa com 1.175 km² de *pixels* não classificados, ou, **8,95%** da área total do município. Isso fica evidente na **Figura 4**, e possivelmente foi ocasionado por *pixels* com pouco ou nenhum dado válido (contaminação por nuvens) ao longo da série temporal.


Tabela 7: Total de área mapeada por meio de classificações digitais com algoritmo *Random Forest* gerados com dados Landsat 8 (OLI), Sentinel-2 (MSI) e *Harmonized Landsat Sentinel-2* (HLS), no município de Balsas-MA, em 2021

Classes de uso e cobertura da terra		OLI		HLS		MapBiomias	
		km ²	%	km ²	%	km ²	%
Coberturas Naturais	Formações florestais	1.265	9,63	1.642	12,49	1.234	9,39
	Formações savânicas	4.146	31,56	4.431	33,72	6.668	50,74
	Formações campestres	1.756	13,37	2.803	21,33	1.983	15,09
	Pastagens	909,00	6,92	897	6,82	75,38	0,57
Usos Antrópicos	Culturas temporárias	2.945	22,42	3.337	25,39	3.061	23,29
	Corpos hídricos	-	-	-	-	5,07	0,04
	Áreas não-vegetadas	-	-	-	-	44,45	0,34
	Silvicultura	-	-	-	-	892	6,79

Corpos hídricos, silvicultura e áreas não-vegetadas foram obtidos em MapBiomias Coleção 7, ano 2021 (2022).

Fonte: Elaborado pelos autores (2022).

Figura 4: Classificações digitais de uso e cobertura da terra do município de Balsas, Maranhão (2021)



Fonte: Elaborado pelos autores (2022).

Outro fator importante para consideração é que o HLS oferece a possibilidade de mapeamento com elevada cobertura temporal em resolução espacial de 30 m, que é a resolução adotada, por exemplo, pelo projeto MapBiomias (2022). As imagens Sentinel-2 utilizadas neste estudo possuem 10 m de resolução e, embora possam ser pré-processadas em velocidade quase instantânea no GEE, as etapas de *download* e processamento são consideravelmente mais pesadas e longas; portanto, pressupõem maior custo computacional de armazenamento e tempo, como também foi observado por Moreira *et al.* (2020). Dessa forma, os dados HLS se apresentam como uma solução eficiente para mapeamentos, principalmente, em média e larga escala. (PARREIRAS *et al.*, 2022).

Nota-se nas classificações o predomínio de formações savânicas, indicando uma cobertura de aproximadamente 32% da área do município de Balsas. Comparando com dados do MapBiomias (2022), ocorreu uma diferença de mais de 2 mil km² estimados dessas formações, ou seja, cerca de 33% a menos, enquanto OLI e HLS estimaram uma área de pastagens cerca de 12 vezes superior. Convém ressaltar que o mapeamento anual elaborado pelo MapBiomias é um produto técnico resultante de parceria multi-institucional, que utiliza variáveis e densidade de série temporal diferentes daquelas adotadas neste estudo, cujo principal objetivo é avaliar a performance de diferentes conjuntos de dados.

Dentre as classes antrópicas agropecuárias, destacam-se as culturas temporárias que representam, aproximadamente, 24% da área total do município, correspondendo a segunda maior classe em área em todas as imagens classificadas, fração semelhante àquela levantada pelo MapBiomias. A elevada ocorrência das culturas temporárias está diretamente associada ao modelo de econômico vigente de produção de Balsas, a qual é pautada na produção de *commodities* agrícolas, setor responsável por aproximadamente 28,5% do PIB do municipal. O município foi o segundo maior produtor agrícola do Estado em 2021 estando entre os 40 maiores produtores de grãos do Brasil,

sendo responsável por cerca de 609.025 toneladas, onde se destacam a soja (1.951,61 km²), o milho (1.076,7 km²) e o algodão (109 km²) (IBGE, 2022; IMESC, 2021).

Essa condição dos usos antrópicos deriva do processo histórico de uso e ocupação do Cerrado maranhense, intensificado a partir dos anos de 1990, quando o estado passou a fazer parte das frentes de expansão agrícola nacional, inicialmente com a inserção da pecuária, seguido por programas de reflorestamento para a produção do carvão vegetal e mais recente a expansão de culturas agrícolas com destaque para soja, milho, cana-de-açúcar e algodão. Entre 2015 e 2020, Balsas apresentou aumento significativo de novas áreas destinadas à produção de grãos, com expansão de 64% de área plantada (IBGE, 2022). Lumbreras *et al.* (2015) destacam que a região do Matopiba possui aproximadamente 26 milhões de hectares ou 35% de terras com potencial para o desenvolvimento de agricultura intensiva, ocorrendo grande variedade de solos, sob condições climáticas diversas, com reflexos em qualidades e vulnerabilidades distintas para o uso agrícola. No Maranhão, houve importantes incentivos na última década, especialmente na melhoria da infraestrutura rodoviária e apoio ao crédito e investimentos tecnológicos que, associados a valorização dos preços da soja nos mercados internacionais, ajudaram a transformar a estrutura agrária tradicional de subsistência em uma estrutura agrária tecnificada.

De maneira geral, as culturas anuais podem ser efetivamente mapeadas com imagens OLI, MSI e HLS, com acurácias do produtor entre 0,85 e 0,89, com melhores resultados atingidos com os dois últimos. Parreiras *et al.* (2022) observaram níveis de acurácia semelhantes para o mapeamento de culturas anuais utilizando conjuntos de dados multiespectral (0,87 com OLI, e 0,93 com HLS). Os autores observaram que a adição de índices de vegetação aos modelos, como o *Normalized Difference Vegetation Index* (NDVI), é uma alternativa para melhorar o desempenho do RF. Em contrapartida, em um nível hierárquico mais elevado e em pleno período chuvoso (setembro a março), no qual ocorreu a necessidade de distinção de classes em nível de cultura no oeste da Bahia, também no Matopiba, o HLS superou significativamente o Landsat 8 e o Sentinel-2.

4. CONCLUSÕES

O *Harmonized Landsat Sentinel-2* (HLS), que possibilita o uso integrado de dados Landsat 8 com dados Sentinel-2 A e B, aumentou o número de observações (datas) para cada *pixel* em uma série temporal de 6 meses, de 5 (Landsat 8) e ~21 (Sentinel-2) para 26. Essa melhora na disponibilidade de dados não resultou em modelos *Random Forest* significativamente melhores que aqueles gerados com Landsat 8 e Sentinel-2. Por outro ângulo, a baixa disponibilidade de imagens com menos de 10% de cobertura de nuvens levou a uma taxa de cerca de 9% de *pixels* não mapeados com o conjunto de dados Landsat 8. Dessa forma, o HLS se mostrou uma importante alternativa para mapeamento do uso e cobertura da terra em regiões tropicais, principalmente em média e larga escala, uma vez que os dados Sentinel-2, em maior resolução espacial, exigem maior capacidade computacional e tempo de processamento. A resolução espacial aprimorada do Sentinel-2 se torna indicada para mapeamento de áreas menores e mais fragmentadas, como as pastagens, e pode ser utilizada em sistemas hierárquicos de classificação com uso de dados multisensor.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) - Projeto n. 2019/26222, da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS BIBLIOGRÁFICAS

ARNHOLT, Alan; EVANS, Ben. **BSDA**: Basic Statistics and Data Analysis. 2021. Disponível em: <https://cran.r-project.org/web/packages/BSDA/index.html>. Acesso em 20 jan. 2023.

ASSIS, Luiz Fernando; FERREIRA, Karine Reis; VINHAS, Lubia; MAURANO, Luis; ALMEIDA, Claudio; CARVALHO, Andre; RODRIGUES, Jether; MACIEL, Adeline; CAMARGO, Claudinei. TerraBrasilis: a spatial data analytics infrastructure for large-scale thematic mapping. **ISPRS - International Journal of Geo-Information**, [S.L.], v. 8, n. 11, p. 513, 12 nov. 2019. MDPI AG. <https://doi.org/10.3390/ijgi8110513>.

BATISTELLA, Mateus; BOLFE, Edson Luis; VICTORIA, Daniel de Castro; ARAÚJO, Luciana Spinelli (org.). **Diagnóstico do Macrozoneamento Ecológico-Econômico do Estado do Maranhão**. Campinas: Embrapa, 2013. 445 p. Embrapa Monitoramento por Satélite / Relatório Técnico, v. 1 - CDD 333.70981.

BOLFE, Édson Luis; SANO, Edson Eyji; CAMPOS, Silvia Kanadani (ed.). **Dinâmica agrícola no Cerrado: análises e projeções**. Brasília: Embrapa, 2020. 308 p.

BOLFE, Édson Luis; VICTÓRIA, Daniel de Castro; CONTINI, Elisio; BAYMA-SILVA, Gustavo; SPINELLI-ARAUJO, Luciana; GOMES, Daniel. Matopiba em crescimento agrícola aspectos territoriais e socioeconômicos. **Revista de Política Agrícola**, [S.L.], v. 25, n. 4, p. 38-62, out. 2016.

BREIMAN, Leo. Random Forest. **Machine Learning**, [S.L.], v. 1, n. 45, p. 5-32, abr. 2001.

CALIXTO, Daiane David; GUIMARÃES, Fernanda Dias; CALIXTO, Leidiane David; CREMON, Édipo Henrique. Análise comparativa em imagens OLI/Landsat 8 e MSI/Sentinel 2 no mapeamento do uso e cobertura da terra. In: IV SIMPÓSIO BRASILEIRO DE GEOMÁTICA – SBG2017, 4., 2017, Presidente Prudente. **Anais [...]**. Presidente Prudente, 2017. p. 180 – 185.

CLAVERIE, Martin; JU, Junchang; MASEK, Jeffrey G.; DUNGAN, Jennifer L.; VERMOTE, Eric F.; ROGER, Jean-Claude; SKAKUN, Sergii V.; JUSTICE, Christopher. The Harmonized Landsat and Sentinel 2 surface reflectance data set. **Remote Sensing of Environment**, [S.L.], v. 219, p. 145-161, dez. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2018.09.002>.

CONGALTON, Russell G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, [S.L.], v. 37, n. 1, p. 35-46, jul. 1991. Elsevier BV. [http://dx.doi.org/10.1016/0034-4257\(91\)90048-b](http://dx.doi.org/10.1016/0034-4257(91)90048-b).

DURO, Dennis C.; FRANKLIN, Steven E.; DUBÉ, Monique G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, [S.L.], v. 118, p. 259-272, mar. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2011.11.020>.

ESA. European Space Agency. **Sentinel 2**. 2013. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/Sentinel2>. Acesso em: 03 jan. 2022.

FREIRES, Eduardo Viana; SILVA NETO, Cláudio Ângelo da; CUNHA, Dominick Sávio Rocha; DUARTE, Cynthia Romariz; VERÍSSIMO, César Ulisses Vieira; GOMES, Daniel Dantas Moreira. Comparação de Imagens OLI/Landsat 8 e MSI/Sentinel 2 no Mapeamento de Cobertura e Uso da Terra no Maciço de Uruburetama, Ceará. **Anuário do Instituto de Geociências - UFRJ**, [S.L.], v. 42, n. 4, p. 427-442, 12 dez. 2019. Instituto de Geociências - UFRJ. http://dx.doi.org/10.11137/2019_4_427_442.

GRINAND, Clovis; RAKOTOMALALA, Fety; GOND, Valéry; VAUDRY, Romuald; BERNOUX, Martial; VIEILLEDENT, Ghislain. Estimating deforestation in tropical humid and dry forests in

Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier. **Remote Sensing of Environment**, [S.L.], v. 139, p. 68-80, dez. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2013.07.008>.

HIJMANS, Robert; BIVAND, Robert; PEBESMA, Edzer; SUMMER, Michael. **Terra: Spatial Data Analysis**. 2023. Disponível em: <https://cran.r-project.org/web/packages/terra/index.html>. Acesso em 20 jan. 2023.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Censo Brasileiro de 2010**. Rio de Janeiro: IBGE, 2012.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Biomass e Sistema Costeiro-Marinho do Brasil**. 2019. Disponível em: <https://www.ibge.gov.br/apps/biomass/#/home/>. Acesso em: 23 jan. 2023.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Panorama do município de Balsas**. 2021. Disponível em: <https://cidades.ibge.gov.br/brasil/ma/balsas/panorama>. Acesso em: 12 dez. 2021.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal**. 2022. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pam/tabelas>. Acesso em: 23 dez. 2022.

IMESC. Instituto Maranhense de Estudos Socioeconômicos e Cartográficos. **Produto Interno Bruto dos Municípios do Estado do Maranhão**. v.15, n.1. São Luís: Imesc, 2021. 56 p.

INPE. Instituto Nacional de Pesquisas Espaciais. Coordenação Geral de Observação da Terra. **Programa de monitoramento da Amazônia e demais biomas: Bioma Cerrado**. 2022. Disponível em: <http://terrabrasilis.dpi.inpe.br/downloads>. Acesso em: 19 jan. 2022.

INPE. Instituto Nacional de Pesquisas Espaciais. Coordenação Geral de Observação da Terra. **Incremento anual de área desmatada no Cerrado Brasileiro**. 2023. Disponível em: <http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/cerrado/increments>. Acesso em: 05 jan. 2023.

ISLAM, Kamrul; JASHIMUDDIN, Mohammed; NATH, Biswajit; NATH, Tapan Kumar. Land use classification and change detection by using multi-temporal remotely sensed imagery: the case of chunati wildlife sanctuary, bangladesh. **The Egyptian Journal of Remote Sensing and Space Science**, [S.L.], v. 21, n. 1, p. 37-47, abr. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.ejrs.2016.12.005>.

KUHN, Max. **Caret: Classification and Regression Training**. 2022. Disponível em: <https://cran.r-project.org/web/packages/caret/index.html>. Acesso em: 20 jan. 2023.

LAMBIN, Eric F.; TURNER, B.L.; GEIST, Helmut J.; AGBOLA, Samuel B.; ANGELSEN, Arild; BRUCE, John W.; COOMES, Oliver T.; DIRZO, Rodolfo; FISCHER, Günther; FOLKE, Carl. The causes of land-use and land-cover change: moving beyond the myths. **Global Environmental Change**, [S.L.], v. 11, n. 4, p. 261-269, dez. 2001. Elsevier BV. [http://dx.doi.org/10.1016/s0959-3780\(01\)00007-3](http://dx.doi.org/10.1016/s0959-3780(01)00007-3).

LI, Xianju; CHEN, Weitao; CHENG, Xinwen; WANG, Lizhe. A Comparison of Machine Learning Algorithms for Mapping of Complex Surface-Mined and Agricultural Landscapes Using ZiYuan-3 Stereo Satellite Imagery. **Remote Sensing**, [S.L.], v. 8, n. 6, p. 514, 18 jun. 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8060514>.

LIAW, Andrew; WIERNER, Matthew. **randomForest**: Breiman and Cutler's Random Forests for Classification and Regression. 2022. Disponível em: <https://cran.r-project.org/web/packages/randomForest/index.html>. Acesso em 20 jan. 2023.

LUMBRERAS, José Francisco; CARVALHO FILHO, Amaury de; MOTTA, Paulo Emilio Ferreira da; BARROS, Alexandre Hugo Cezar; AGLIO, Mario Luiz Diamante; DART, Ricardo de Oliveira; SILVEIRA, Hilton Luis Ferraz da; QUARTAROLI, Carlos Fernando; ALMEIDA, Rodrigo Estevam Munhoz de; FREITAS, Pedro Luiz de. **Aptidão Agrícola das Terras do Matopiba**. Rio de Janeiro: Embrapa Solos, 2015. 49 p.

MAPA. Ministério da Agricultura Pecuária e Abastecimento Secretaria de Política Agrícola. **Projeções do Agronegócio Brasil 2020/21 a 2030/31 Projeções de Longo Prazo**. Brasília: Mapa, 2021. 102 p.

MAPBIOMAS. **Coleções MapBiomias**. 2022. Disponível em: https://mapbiomas.org/colecoes-mapbiomas-1?cama_set_language=pt-BR. Acesso em 20 jan. 2023.

MAXWELL, Aaron E.; WARNER, Timothy A.; FANG, Fang. Implementation of machine-learning classification in remote sensing: an applied review. **International Journal of Remote Sensing**, [S.L.], v. 39, n. 9, p. 2784-2817, 2 fev. 2018. Informa UK Limited. <http://dx.doi.org/10.1080/01431161.2018.1433343>.

MMA. Ministério do Meio Ambiente. **Áreas Especiais**. Ministério do Meio Ambiente, servidor de mapas para consulta pública. 2020. Disponível em: <http://mapas.mma.gov.br/i3geo/datadownload.htm>. Acesso em: 12 jan. 2020.

MORE. **Mecanismo online para referências, versão 2.0**. Florianópolis: UFSC: Rexlab, 2013. Disponível em: <http://www.more.ufsc.br/>. Acesso em: 23 ago 2022.

MOREIRA, Eder Paulo; RODRIGUES, Thiago Gonçalves; OLIVEIRA, Cleber Gonzales; SILVA JUNIOR, José Antônio; OLIVEIRA, Vania Maria. Análise de dados OLI/Landsat-8 e MSI/Sentinel-2 com diferentes níveis de processamento. **Brazilian Journal of Development**, [S.L.], v. 6, n. 6, p. 35820-35831, 2020. Brazilian Journal of Development. <http://dx.doi.org/10.34117/bjdv6n6-209>.

NASA. National Aeronautics and Space Administration. Application for Extracting and Exploring Analysis Ready Samples (**AppEEARS**). 2022. Disponível em: <https://appeears.earthdatacloud.nasa.gov/>. Acesso em 19 jan 2022.

NASA. National Aeronautics and Space Administration. **Landsat 8**. 2018. Disponível em: [https://landsat.gsfc.nasa.gov/satellites/Landsat 8/](https://landsat.gsfc.nasa.gov/satellites/Landsat%208/). Acesso em: 03 jan. 2022.

NASA. National Aeronautics and Space Administration. **Harmonized Landsat Sentinel 2 (HLS)**. 2018a. Disponível em: <https://hls.gsfc.nasa.gov/>. Acesso em: 03 jan. 2022.

OLDONI, Lucas Volochen; CATTANI, Carlos Eduardo Vizzotto; MERCANTE, Erivelto; JOHANN, Jerry Adriani; ANTUNES, João Francisco Gonçalves; ALMEIDA, Luiz. Annual cropland mapping using data mining and OLI Landsat-8. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 12, p. 952-958, dez. 2019. <http://dx.doi.org/10.1590/1807-1929/agriambi.v23n12p952-958>.

PARREIRAS, Taya Cristo; BOLFE, Édson Luis; CHAVES, Michel Eustáquio Dantas; SANCHES, Ieda Del'arco; SANO, Edson Eyji; VICTORIA, Daniel de Castro; BETTIOL, Giovana Maranhão;

VICENTE, Luiz Eduardo. Hierarchical Classification of Soybean in the Brazilian Savanna Based on Harmonized Landsat Sentinel Data. **Remote Sensing**, [S.L.], v. 14, n. 15, p. 3736, 4 ago. 2022. MDPI AG. <http://dx.doi.org/10.3390/rs14153736>.

PRUDENTE, Victor Hugo Rohden; MARTINS, Vitor Souza; VIEIRA, Denis Corte; SILVA, Nildson Rodrigues de França e; ADAMI, Marcos; SANCHES, Ieda Del'Arco. Limitations of cloud cover for optical remote sensing of agricultural areas across South America. **Remote Sensing Applications Society and Environment**, [S.L.], v. 20, p. 100414, 15 set. 2020. Elsevier BV. <https://doi.org/10.1016/j.rsase.2020.100414>.

QUINTANO, Carmen; FERNÁNDEZ-MANSO, Alfonso; FERNÁNDEZ-MANSO, Oscar. Combination of Landsat and Sentinel 2 MSI data for initial assessing of burn severity. **International Journal of Applied Earth Observation and Geoinformation**, [S.L.], v. 64, p. 221-225, fev. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2017.09.014>.

REID, Robin S.; KRUSKA, Russell L.; MUTHUI, Nyawira; TAYE, Andoualem; WOTTON, Sara; WILSON, Cathleen J.; MULATU, Woudyalew. Land-use and land-cover dynamics in response to changes in climatic, biological and socio-political forces: the case of southwestern Ethiopia. **Landscape Ecology**, [S.L.], v. 15, n. 4, p. 339-355, maio 2000.

RIBEIRO, José Felipe; WALTER, Bruno Machado Teles. As Principais Fitofisionomias do Bioma Cerrado. In: SANO, Sueli Matiko; ALMEIDA, Semíramis Pedrosa de; RIBEIRO, José Felipe (ed). **Cerrado Ecologia e Flora**. Brasília: Embrapa Informação Tecnológica, 2008. V.1 – capítulos 1 a 14, v. 2 – capítulo 15, Checklist com 12.356 espécies.

RODRIGUES, Taíssa Caroline Silva. **Estudo da cobertura e uso da terra na microrregião do Gurupi, Amazônia maranhense, entre os anos de 1976 – 2016 por meio da aplicação do sensoriamento remoto e SIG's**. 2018. 183 f. Tese (Doutorado) - Curso de Geografia, Geografia, Universidade Estadual Paulista Júlio de Mesquita Filho, Presidente Prudente, 2018.

SÁNCHEZ-ESPINOSA, Antonio; SCHRÖDER, Christoph. Land use and land cover mapping in wetlands one step closer to the ground: sentinel-2 versus landsat 8. **Journal Of Environmental Management**, [S.L.], v. 247, p. 484-498, out. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.jenvman.2019.06.084>.

SANO, Edson. Eyji; ROSA, Roberto; BRITO, Jorge Luis Silva; FERREIRA, Laerte Guimarães; BEZERRA, Heleno da Silva. Mapeamento da cobertura vegetal natural e antrópico do bioma cerrado por meio de imagens Landsat ETM. In: XIV Simpósio Brasileiro de Sensoriamento Remoto, 14, 2009, Natal. **Anais [...]**. Natal: INPE, 2009. p. 1199-1206.

SANO, Edson. Eyji; BETTIOL, Giovana Maranhão; MARTINS, Eder de Souza; COUTO JÚNIOR, Antônio Felipe; VASCONCELOS, Vinícius; BOLFE, Edson Luís; VICTÓRIA, Daniel de Castro Características gerais da paisagem do Cerrado. In: BOLFE, E. L.; SANO, E. E.; CAMPOS, S. K. **Dinâmica agrícola do Cerrado: análises e projeções**. Brasília: Embrapa, 2020, p. 21-37.

SANTOS, Pablo Santana; FERREIRA, Laerte Guimarães; LENZI, Ítalo Luiz Corrêa. Caracterização biofísica das pastagens na bacia hidrográfica do Rio Vermelho (go), bioma Cerrado, Brasil. **Boletim de Geografia**, [S.L.], v. 36, n. 3, p. 53, 20 nov. 2018. Universidade Estadual de Maringá. <http://dx.doi.org/10.4025/bolgeogr.v36i3.35269>.

SCARAMUZZA, Carlos Alberto de Mattos; SANO, Edson Eyi; ADAMI, Marcos; BOLFE, Edson Luis; COUTINHO, Alexandre Camargo; ESQUERDO, Júlio César Dalla Mora; MAURANO, Luís Eduardo Pinheiro; NARVAES, Igor da Silva; OLIVEIRA FILHO, Francisco José Barbosa de; ROSA, Roberto; SILVA, Elaine Barbosa da; VALERIANO, Dalton de Morrison; VICTORIA, Daniel de Castro; BAYMA, Adriana Panhol; OLIVEIRA, Gustavo Henrique de; BAYMA-SILVA, Gustavo. Land-use and land-cover mapping of the brazilian Cerrado based mainly on Landsat-8 satellite images. **Revista Brasileira de Cartografia**, [S.L.], v. 69, n. 6, p. 1041-1051, jun. 2017.

SILVA JÚNIOR, Carlos A. da; FRANK, Thiago; RODRIGUES, Taíssa C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S.L.], v. 18, n. 1, p. 44-53, jan. 2014. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1415-43662014000100007>.

SRIVASTAVA, Prashant K.; GUPTA, Manika; MUKHERJEE, Saumitra. Mapping spatial distribution of pollutants in groundwater of a tropical area of India using remote sensing and GIS. **Applied Geomatics**, [S.L.], v. 4, n. 1, p. 21-32, 24 dez. 2011. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12518-011-0072-y>.

WULDER, Michael A.; HERMOSILLA, Txomin; WHITE, Joanne C.; HOBART, Geordie; MASEK, Jeffrey G. Augmenting Landsat time series with Harmonized Landsat Sentinel 2 data products: assessment of spectral correspondence. **Science of Remote Sensing**, [S.L.], v. 4, p. 100031, dez. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.srs.2021.100031>.

YAN, Jining; WANG, Lizhe; SONG, Weijing; CHEN, Yunliang; CHEN, Xiaodao; DENG, Ze. A time-series classification approach based on change detection for rapid land cover mapping. **Isprs Journal of Photogrammetry and Remote Sensing**, [S.L.], v. 158, p. 249-262, dez. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.isprsjprs.2019.10.003>.

ZHANG, Fang; YANG, Xiaojun. Improving land cover classification in an urbanized coastal area by random forests: the role of variable selection. **Remote Sensing of Environment**, [S.L.], v. 251, p. 112105, dez. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2020.112105>.

ZHENG, Baojuan; MYINT, Soe W.; THENKABAIL, Prasad S.; AGGARWAL, Rimjhim M. A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. **International Journal of Applied Earth Observation and Geoinformation**, [S.L.], v. 34, p. 103-112, fev. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2014.07.002>.



Informações sobre a Licença

Este é um artigo de acesso aberto distribuído nos termos da Licença de Atribuição Creative Commons, que permite o uso irrestrito, distribuição e reprodução em qualquer meio, desde que o trabalho original seja devidamente citado.

License Information

This is an open access article distributed under the terms of the Creative Commons Attribution License, which allows for unrestricted use, distribution and reproduction in any medium, as long as the original work is properly cited.