

## COMPARAÇÃO DA CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA EM IMAGENS LANDSAT-8 E SENTINEL-2 NO CERRADO MARANHENSE

COMPARISON OF THE CLASSIFICATION OF LAND USE AND COVERAGE IN LANDSAT-8 AND SENTINEL-2 IMAGES IN THE CERRADO MARENHENSE

COMPARACIÓN DE CLASSIFICACIÓN DE USO DE SUELO Y COBERTURA EM IMÁGENES LANDSAT-8 Y SENTINEL-2 EM EL CERRADO MARANHENSE

### RESUMO





Os mapas de uso e cobertura da terra são instrumentos basilares para a compreensão detalhada dos padrões da organização do espaço, instrumento essencial para o gerenciamento agroambiental. Este artigo objetivou comparar e avaliar a precisão da classificação digital de uso e cobertura da terra no cerrado maranhense, a partir de imagens OLI (*Operational Terra Imager*) do Landsat-8 e MSI (*Multispectral Instrument*) do Sentinel-2. As imagens analisadas são de 2021, as quais foram pré-processadas, segmentadas e classificadas utilizando o algoritmo *Random Forest*. As análises mostraram que ambas as classificações foram qualificadas como "muito bom", obtendo-se Índice Kappa com 0,706 e Exatidão Global em 76% para as imagens OLI e, Índice Kappa com 0,775 e Exatidão Global em 84% para as imagens MSI. Os resultados obtidos podem subsidiar o planejamento e execução de novos mapeamentos e monitoramentos agrícolas no Cerrado, contribuindo com as tomadas de decisão de grupos de pesquisa.

**Palavras-chave:** Classificação digital; cerrado; aprendizado de máquina; dados multifontes; Balsas-MA.

### ABSTRACT

Land use and land cover maps are basic tools for a detailed understanding of spatial organization patterns, an essential tool for agro-environmental management. This article aimed to compare and evaluate the accuracy of the digital classification of land use and land cover for the Cerrado of Maranhão, using OLI (Operational Terra Imager) images from Landsat-8 and MSI (Multispectral Instrument) from Sentinel-2. The analyzed images are from 2021, which were pre-processed, segmented and classified using the Random Forest algorithm. The analyzes showed that both classifications were qualified as "very good", obtaining Kappa Index (0.706) and Global Accuracy (76%) for the OLI images and Kappa Index (0.775) and Global Accuracy (84%) for the images MSI. The results obtained can support the planning and execution of new agricultural mapping and monitoring in the Cerrado, positively influencing the decision-making of research groups.

**Keywords:** Clasificación digital; cerrado; aprendizaje automático; datos de múltiples fuentes; Balsas-MA.

 Paulo Roberto Mendes Pereira <sup>a</sup>  
 Mariana Monteiro Navarro de Oliveira <sup>a</sup>  
 Edson Luis Bolfe <sup>b</sup>  
 Lucrêncio Silvestre Macarringue <sup>a</sup>

<sup>a</sup> Universidade Estadual de Campinas (UNICAMP), Campinas, São Paulo, Brasil

<sup>b</sup> Universidade Estadual de Campinas (UNICAMP), Campinas, São Paulo, Brasil. Empresa Brasileira de Pesquisa Agropecuária - Embrapa

DOI: 10.12957/geouerj.2023.66306

**Correspondência:** p.roberto18@hotmail.com; marimmno@gmail.com; edson.bolfe@embrapa.br; lusimac@gmail.com

**Recebido em:** 31 mar. 2022

**Revisado em:** 16 jul. 2022

**Aceito em:** 23 nov. 2022



## INTRODUÇÃO

As informações referentes as características de uso e cobertura da terra permitem compreender a organização do espaço, possibilitando as análises da distribuição dos remanescentes naturais e das atividades antrópicas que ocorrem na superfície terrestre, sendo considerado um instrumento basilar para a elaboração de políticas de ordenamento territorial, além de consistirem no passo básico para implantação de diversos estudos e ações de manejo (AMARAL et al., 2009; WULDER, 2021).

O desenvolvimento do sensoriamento remoto e de técnicas de análise e interpretação de fotografias aéreas e imagens orbitais ampliaram de maneira significativa o reconhecimento de padrões de uso da terra, sendo eficientes instrumentos para o mapeamento de cobertura da terra e as alterações provocadas nas paisagens em um determinado local (CALIXTO et al., 2017). A visão panorâmica e a repetibilidade das imagens permitem a obtenção de informações históricas e atuais, sendo consideradas importantes recursos para o monitoramento agroambiental, principalmente nas regiões de grande extensão (SANCHES-ESPINOSA; SCHRÖDER, 2019).

A disponibilidade de imagens multiespectrais de média e alta resolução, possibilitam o monitoramento com alta frequência temporal a um custo relativamente baixo, onde destaca-se o Landsat-8 e o Sentinel-2 (FREIRES et al., 2019; REX et al., 2018). O satélite Landsat-8 foi lançado em 2013 e carrega a bordo dois instrumentos de coleta, um multiespectral, o Operational Land Imager-OLI, e um que coleta informações na frequência do infravermelho termal, Thermal Infrared Sensor-TIRS (USGS, 2019). O sensor OLI possui sete bandas nas frequências do visível e do infravermelho, resolução especial de 30 metros com possibilidade de reamostragem para 15 metros por processo de fusão digital pela banda pancromática. A Landsat 8 possui 16 bits de resolução radiométrica, e revisita de 16 dias, recobrando uma área de 185 km, sendo distribuídas gratuitamente pela USGS (USGS, 2019).

O Sentinel-2 é formado por dois satélites complementares, Sentinel 2A e 2B, que foram lançados em 2015 e 2017 respectivamente e carregam o instrumento multiespectral-MSI que coletam informações de treze faixas espectrais, com resolução espacial de 10 metros no visível e infravermelho próximo, 20 metros para a borda do Vermelho (*Red Edge*) e infravermelho médio, e 60 metros para as bandas de correção atmosférica. Os produtos do Sentinel-2 apresentam resolução radiométrica de 12 bits, e faixa de revisita de 10 dias, porém pela complementariedade de imageamento entre o Sentinel-2A e Sentinel-2B, que possibilita um período de revisita de até cinco dias, que recobre área de 290 km, sendo disponibilizado de forma gratuita pela Agência Espacial Europeia-ESA (REX, 2018).

De acordo com Sanches-Espinosa e Schröder (2019) o MSI/Sentinel-2 foram projetados para permitir a continuidade dos dados do tipo SPOT e Landsat, com características do MERIS e do MODIS com um maior



número de bandas espectrais. Outro ponto é a capacidade de fornecer um período de revisitação de alta frequência, oferecendo uma maior disponibilidade para o monitoramento de agricultura, ecossistemas, manejo de florestas, sobretudo aqueles que ocorrem em curto período e, que não são frequentemente registrados pelo OLI/Landsat e seu ciclo de revisitação de 16 dias.

Apesar da significativa melhoria das imagens multiespectrais do MSI/Sentinel-2 em relação ao OLI/Landsat-8, sobretudo pelo aprimoramento da resolução espacial e temporal, pode não significar em resultados mais precisos, particularmente no mapeamento do uso e cobertura da terra, conforme Calixto et al. (2017) e Freires et al. (2019), que mostraram significativa compatibilidade entre os dados resultantes destes instrumentos. Moreira (2020) destaca que comparar dados multisensores é um desafio, principalmente pelas significativas diferenças de resoluções espectrais, radiométricas e espaciais dos sensores, além de variações ocasionadas pelas condições atmosféricas quando são adquiridas em diferentes datas.

Dentre os estudos que compararam imagens OLI/Landsat-8 e MSI/Sentinel-2, destacam-se Sánchez-Espinosa e Schröder (2019) que analisaram diferenças para o mapeamento de áreas úmidas no mediterrâneo. Wulder et al. (2021) testaram o uso harmonizado entre as imagens Landsat-8 e Sentinel-2, para o aumento da série temporal de dados da superfície para o Canadá.

Desse modo, o objetivo desta pesquisa é avaliar a precisão de classificações digitais das imagens OLI/Landsat-8 e MSI/Sentinel-2 no município de Balsas, Cerrado Maranhense. Buscou-se avaliar se as melhorias de resolução espectral e espacial da MSI/Sentinel-2 produzem respostas significativamente diferentes, quando comparados ao OLI/Landsat-8 na distinção dos alvos da superfície nessa região do Cerrado.

## **MATERIAIS E MÉTODOS**

Neste tópico serão descritas as características do município de Balsas no Cerrado Maranhense e a metodologia utilizada para a comparação de dados de classificação do uso e cobertura da terra, envolvendo as etapas do processamento digital das imagens de satélite utilizadas. Dentre as etapas será destacada a correção atmosférica, ampliação de contraste, segmentação e extração de atributos, amostragem, classificação e a avaliação de desempenho.

### **Área de Estudo**

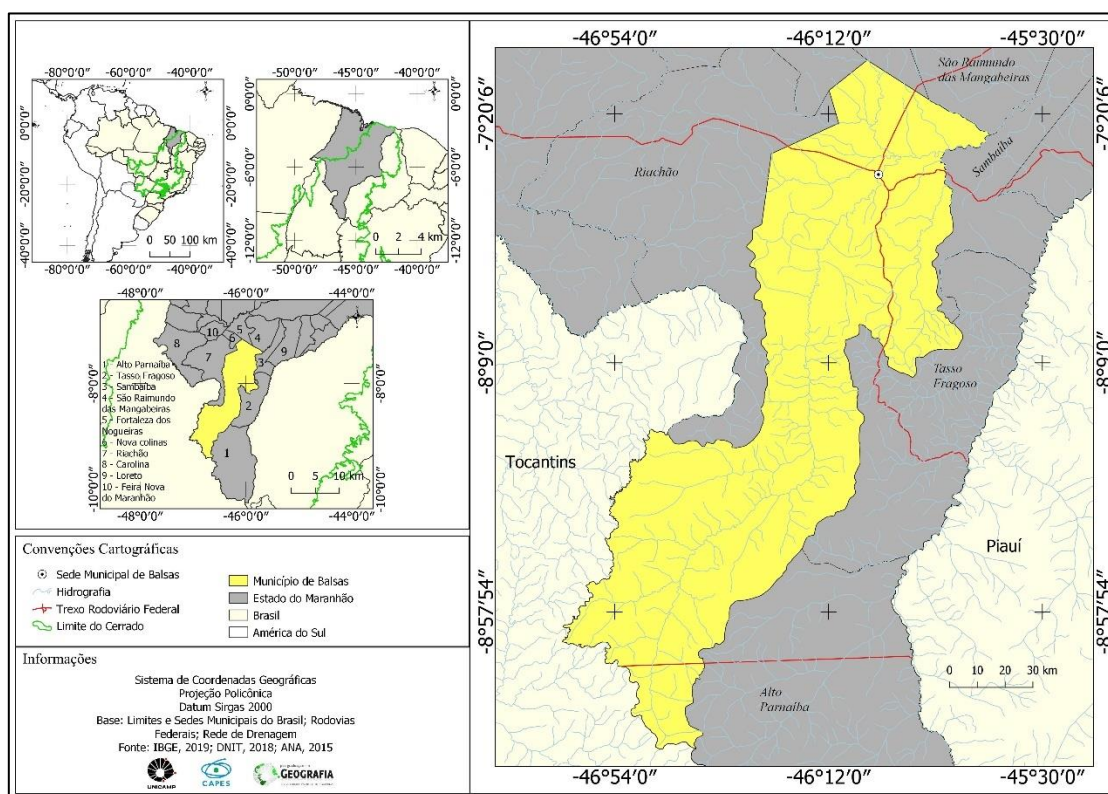
O município de Balsas está localizado na porção sul do estado do Maranhão, inserido na microrregião Gerais de Balsas, região nordeste do Brasil (Figura 1). Tem como limites os seguintes pares de coordenadas 7° 31' 39.24" S e 45° 40' 18.06" O; 9° 24' 43.37" S e 46° 2' 44.51" O. Possui extensão territorial de 13.142 km<sup>2</sup> e limita-se com os municípios de São Raimundo das Mangabeiras-MA e Fortaleza dos Nogueiras-MA a norte;



Alto Parnaíba-MA e Lizarda-TO a sul; Tasso Fragoso-MA e Sambaíba-MA a leste; e Riachão-MA, Campos Lindos-TO e Recursolândia-TO a oeste (IBGE, 2020).

De acordo com o IBGE (2012), o município de Balsas possuía em 2010 um total de 83.528 habitantes, com estimativa populacional para o ano de 2021 de 96.951 habitantes, com densidade demográfica de 6,36 hab/km<sup>2</sup>, e 87% da população residindo na zona urbana do município, uma área de 28 km<sup>2</sup>. Responsável por 3,5% do PIB do Maranhão, terceiro maior do estado, tem significativa contribuição para o agronegócio brasileiro, estando entre os 50 maiores produtores de commodities agrícolas do país, com destaque para a soja, milho e algodão (IBGE, 2021).

Figura 1. Localização do município de Balsas, cerrado maranhense (2021).



Fonte: IBGE, 2019; DNIT, 2018, ANA, 2015.

Quanto as características naturais, o município possui fitofisionomias associadas ao bioma cerrado (RIBEIRO; WALTER, 1998) com clima subúmido seco, de temperaturas superiores a 28°C, umidade inferior a 70%, caracterizado por dois períodos, um chuvoso (fevereiro a maio), com médias pluviométricas variando de 800 a 1200 mm anuais, e de estiagem (julho a novembro) com índices de precipitação que não ultrapassam os 50 mm anuais, apresentando deficiência hídrica na maior parte do ano (INMET, 2019).

A litoestratigrafia é composta por intercalações de folhelhos, arenitos, argilitos, sílex e derrames basálticas, das formações Corda, Piauí, Pedra de Fogo, Motuca e Sambaíba, caracterizado por uma topografia predominantemente plana, com altimetria variando entre 211 e 657 metros, composto por extensas



superfícies de aplainamentos, mesclados por colinas de topografia suavemente onduladas, formações tabuliformes residuais de topografia escarpada e vales fluviais entalhados (BATISTELLA et al. 2013).

A área apresenta a predominância de solos pobres, profundos e bem drenados, destacando-se Latossolos Amarelos e Vermelho-Amarelos distróficos, em menor proporção, Argissolos Vermelho-Amarelos distróficos, Plintossolos Háplicos distróficos, Neossolos Quartzarênicos órticos, e manchas de Gleissolos, apresenta um mosaico fitofisionômico composto por uma vegetação típica, com predomínios das formações savânicas (florestada e aberta), campestres, e formações florestais com espécies arbóreas e arborescentes, próximas aos leitos de rios e riachos presentes na área (BATISTELLA et al., 2013).

## Materiais

Neste estudo foram utilizadas as bandas referentes aos comprimentos de onda do azul, verde, vermelho e infravermelho próximo (tabela 1) dos satélites OLI/Landsat-8 e MSI/Sentinel-2. As imagens OLI/Landsat-8 possuem resolução espacial de 30 metros, resolução radiométrica de 16 bits, sendo localizadas nas Órbitas/pontos 221/65 e 221/66, e datadas de agosto de 2021, obtidas gratuitamente no catálogo de imagens do USGS. Já as imagens MSI/Sentinel-2A possuem resolução espacial de 10 metros, radiometria de 12 bits, sendo utilizadas as imagens das quadrículas 23MLN, 23MMN, 23MLM, 23MMM, 23LKL, 23LLL, 23KLL, 23LLK, adquiridas no mês de setembro de 2021.

**Tabela 1.** Características das imagens Landsat-8 e Sentinel-2 com destaque para o comprimento de onda, resolução espacial e radiometria das bandas utilizadas no estudo.

Imagens	$\mu\text{m}$			
	Azul	Verde	Vermelho	Infra. Próximo
Landsat - 8 (30 m)	Banda 2 0,483	Banda 3 0,561	Banda 4 0,654	Banda 5 0,864
Sentinel - 2 (10 m)	Banda 2 0,490	Banda 3 0,560	Banda 4 0,665	Banda 8 0,705

$\mu\text{m}$  = Comprimento de onda central.

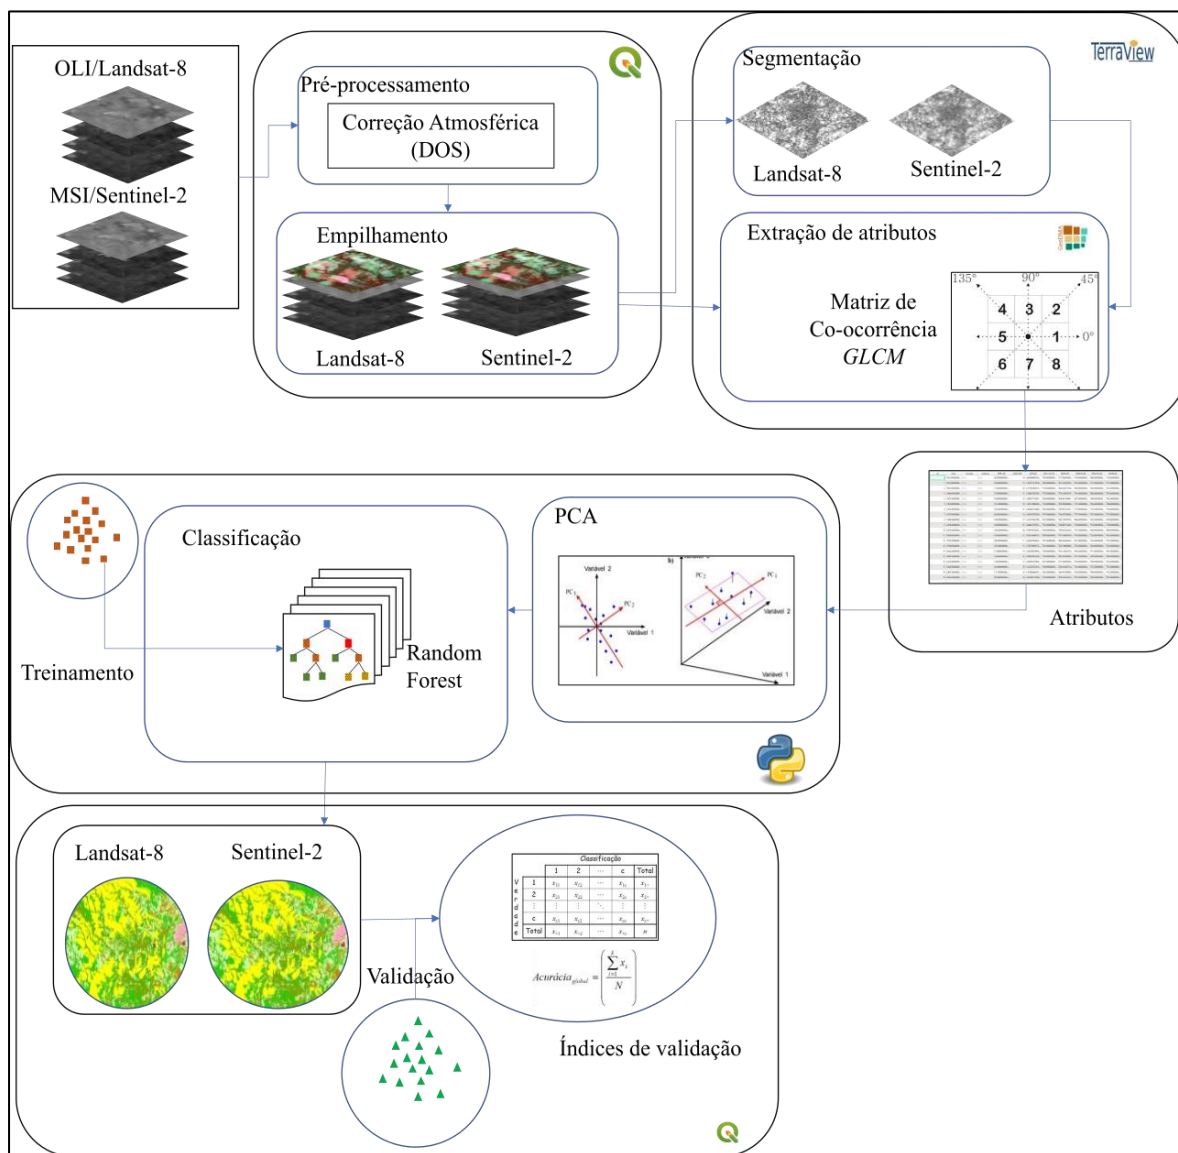
Fonte: USGS (2015), ESA (2016), Embrapa (2020).

A escolha desses grupos de imagens está relacionada às características espectrais semelhantes, à média resolução que ambas apresentam, possibilitando mapeamento detalhado de grandes áreas, a resolução temporal, que permite mapeamento em períodos curtos, com escala aceitável. Não foi realizada etapas de correção geométrica e/ou de reamostragem de pixels, uma vez que ambas as imagens já são georreferenciadas (NASA, 2021; ESA, 2021), e o foco é avaliar se a melhoria da resolução espacial da MSI/Sentinel-2 proporciona uma melhor exatidão em mapeamentos de uso e cobertura da terra quando comparados aos dados de OLI/Landsat-8. O critério de seleção das datas das imagens foi o percentual de cobertura de nuvens sobre a cena e área de estudo, sendo escolhida imagens adquiridas entre os meses de agosto a outubro, período de menor incidência de nuvens. Sendo assim, foram escolhidas imagens com taxa



de cobertura inferior à 5% por cena, e com até 1% de cobertura sobre o limite do município. O fluxograma (figura 2) sintetiza as etapas de processamento digital de imagens, destacando os principais softwares e linguagens de programação utilizados.

Figura 2. Fluxograma das etapas do processamento das imagens de satélite em Balsas, cerrado maranhense (2021).



Fonte: Os Autores

### Correção Atmosférica

Para reduzir o efeito da dispersão atmosférica nas imagens, foi realizada a correção atmosférica, sendo utilizada a técnica de Subtração de Objeto Escuro - DOS (CHAVES JR et al., 1988), para tanto, utilizou-se o algoritmo de correção atmosférica DOS do *Semi-Automatic Classification Plugin* (CONGEDO, 2017), implementada no QGIS 2.16.1®.



O DOS tem como princípio utilizar apenas parâmetros relacionados ao número digital da imagem, sem depender de parâmetros atmosféricos coletados na data da aquisição da imagem. Na correção atmosférica DOS é assumida a existência de pixels com valores nulos, como sombras causadas por topografia ou nuvens, que apresentam valores superiores ao esperado, como resultado do efeito da dispersão atmosférica, e que tem referência para a correção da dispersão atmosférica a partir da subtração desses valores pela imagem (MAIA et al., 2017).

### Ampliação de contraste

Com intuito de reduzir os efeitos do agrupamento de pixels em determinadas regiões do histograma e aprimorar as características visuais entre as feições, aplicou-se um filtro de contraste linear 2%, para tanto foi utilizado o algoritmo de expansão de contraste linear 2% implementado no TerraView 5.6.1. O contraste linear realiza uma distribuição dos valores de níveis de cinza a partir do espalhamento linear, modificando a escala de cinza, onde o novo valor está associado ao valor inicial do pixel, segundo a função linear (MENESES; ALMEIDA, 2012) (eq. 1).

$$Y = (x - \min) * \left( \frac{2^n - 1}{\max - \min} \right) \quad (1)$$

Onde, o valor Y representa o valor do pixel no novo histograma; x corresponde ao valor de nível cinza da imagem original; n representa a resolução radiométrica do sensor e o mínimo e o máximo são os limites originais dos valores no histograma.

### Segmentação e Extração de Atributos

Os conjuntos de imagens foram segmentadas utilizando o algoritmo de segmentação por Crescimento de Regiões - CR (BAATZ; SCHAPE, 2000) implementado no TerraView 5.6.1. O CR corresponde a uma técnica de agregação, iniciada em um conjunto de pixels “sementes” e a partir de parâmetros pré-definidos de similaridade e área realiza a agregação ou não de um pixel, na qual, valores inferiores ao limiar de similaridade serão agrupados formando regiões maiores (ZANOTTA; ZORTEA; FERREIRA, 2019).

Os parâmetros de similaridade e área são definidos por tentativa e erro, sendo estabelecido área mínima de 1 (um) hectare, que corresponde a 12 pixels para OLI/Landsat-8, e 100 pixels para MSI/Sentinel-2. Para ambos os conjuntos de dados foi definido valores de similaridade de 0,08, valor que melhor definiu a separabilidade das diferentes classes.

Após a segmentação, realizou-se a etapa de extração de atributos das imagens, na qual foram valores de média, mediana, desvio padrão, variância, máximo e mínimo para cada uma das quatro bandas que compõe



o conjunto de imagens, totalizando 24 atributos em cada conjunto, para tanto, utilizou-se a matriz de co-ocorrência de níveis de cinza presente no plugin Geodma e implementado no TerraView 5.3.3.

### Processamento dos dados

A fim de remover as diferenças de grandezas entre os atributos extraídos, os dados foram padronizados em um intervalo de valores comuns. Para tanto, foi desenvolvido um script em ambiente de programação Python 3, utilizando a biblioteca de aprendizado de máquina *Scikit-Learn*, na qual empregou-se o pacote *preprocessing*, utilizando o algoritmo *StandardScaler*, que realiza o processo de padronização, a partir dos valores de média e desvio padrão (eq. 2).

$$Y = \left( \frac{x - \mu}{\sigma} \right) \quad (2)$$

Onde  $x$  corresponde ao valor da célula,  $\mu$  é a média da coluna a ser padronizada,  $\sigma$  corresponde ao desvio padrão da coluna a ser padronizada.

Para reduzir a elevada correlação que os atributos apresentaram entre si, aplicou-se a técnica de análise de componentes principais - ACP, que corresponde a uma análise exploratória multivariada que transforma um conjunto de variáveis correlacionadas em um conjunto menor de variáveis independentes, sendo considerada uma forma simples e eficaz de reunir as informações mais importantes dos atributos, formando um volume menor de dados para análise, e assim possibilita uma maior precisão dos resultados (MAROCO, 2007).

Para tanto, criou-se uma rotina de programação no Python 3, utilizando o pacote PCA, presente na biblioteca de aprendizado de máquina *scikit-learn*. Desse modo, foram criadas nove componentes principais, que correspondem a 93% de toda a variância dos dados originais, sendo a primeira componente responsável por 54% de toda a variância dos dados.

### Amostragem

Para a etapa de treinamento foram utilizadas 2.383 amostras identificadas a partir de interpretação visual e subsequente identificação subsidiada por chave de interpretação (quadro 1, 2), seguindo características visualmente perceptíveis na imagem (cor, textura, padrão e forma), como descritos por Rosa (2009), sendo identificadas seis classes de uso e cobertura da terra divididas em três grupos, conforme o sistema de classificação do IBGE (2006).

O primeiro grupo denominado de áreas de vegetação natural é formado pelas fisionomias da vegetação, organizadas em três categorias: as formações florestais, as formações savânicas e as formações














campestres; o segundo grupo corresponde as áreas antrópicas agrícolas, contemplando as áreas de uso para a produção de alimentos, fibras ou outras matérias-primas, sendo definida duas subclasses: as pastagem e lavouras temporárias; e o terceiro grupo corpos hídricos, considerando os corpos d'água naturais e antrópicos.

As chaves de interpretação foram criadas a partir do uso das imagens Landsat-8 e Sentinel-2, sendo utilizado para ambas uma composição falsa cor com padrão no vermelho, que melhor realça a vegetação fotossinteticamente ativa, e assim permitindo a diferenciação destas para outras classes. Para tanto, foram utilizadas nos canais RGB as bandas 5, 4 e 3 para a imagem Landsat-8 e as bandas 8, 4 e 3 para a imagem Sentinel-2, que correspondem a região do espectral do infravermelho próximo, vermelho, e verde respectivamente.

**Quadro 1.** Chave de interpretação para áreas de vegetação natural em Balsas, cerrado maranhense (2021).

Nível 1 – Áreas de vegetação natural				
Nível II	Características	Imagem Landsat-8	Imagem Sentinel-2	Fotografia em campo
Formações Florestais	Apresentam cor avermelhada, variando do vermelho escuro ao vermelho médio, um padrão heterogêneo, textura rugosa e sem forma definida de áreas de vegetação densa a média.			
Formações Savânicas	Correspondem a vegetação de porte médio, com textura rugosa, padrão variando entre média/média-baixa, sem forma definida, cor variando do magenta, a verde azulado, com menor densidade de árvores, sendo estas com um porte mais baixo, visualizar o solo.			
Formações Campestres	Apresentaram coloração variando do verde ao verde azulado e marrom, padrão heterogêneo e textura rugosa sem forma definida, podendo também apresentar pigmentação de manchas avermelhadas.			

Fonte: dados de pesquisa, 2021.

**Quadro 2.** Chave de interpretação para áreas antrópicas agrícolas e corpos hídricos em Balsas, cerrado maranhense (2021).

Nível I- Áreas antrópicas agrícolas				
Nível II	Características	Imagem Landsat-8	Imagem Sentinel-2	Fotografia em campo
Pastagens	Cor variando do magenta (solo preparado ou pastagem seca) ao verde claro (pastagens plantadas densa e verde) ao cinza, textura variando entre lisa (pastagem plantada) a intermediária (ligeiramente rugosa, quando associada a pasto sujo), forma regular, geralmente associada a um tipo de espécie.			
Culturas Temporárias	Apresentam padrões homogêneos, forma regular bem definida e textura lisa, apresentando coloração que varia do azul ao marrom, podendo também apresentar tons avermelhados, magenta ou branco, dependendo do estágio vegetativo da cultura			
Nível I- Corpos hídricos				
Corpos Hídricos	Apresentam coloração escura, forma sinuosa associadas a canais de drenagem, ou definida a lagos, lagoas e açudes, possui textura lisa, apresentando ou não cobertura vegetal densa.			

Fonte: dados de pesquisa, 2021.

As classes área construída e silvicultura apesar de presente na área, foram vetorizadas manualmente, por não apresentarem representatividade significativa para o município, correspondendo a menos de 1% da cobertura total, e devido à elevada confusão na classificação automatizada que estas classes apresentaram com as culturas temporárias, pastagens, formações campestres e formações florestais, sendo utilizadas como máscara de recorte para as áreas correspondentes.

### Classificação

A etapa de classificação dos dados foi realizada em ambiente de programação Python 3, utilizando a biblioteca de aprendizado de máquina *Scikit-Learn*, na qual foram elaboradas as rotinas das classificações, utilizando o algoritmo *Random Forest* (RF). Proposto por Breiman (2001), o RF é um classificador supervisionado do tipo árvore de decisão, que utiliza dados regionalizados (segmentos) e seus atributos utilizam estratégias inteligentes de classificação, considerando diferentes amostras de treinamentos, as quais



são selecionadas aleatoriamente, com base em uma técnica determinística, selecionando um conjunto aleatório de variáveis e uma amostra aleatória dos dados de treinamento para criar um conjunto grande de árvores de decisão, que combinados, fornecem precisão elevada (ZHANG; YANG, 2020).

Ao executar o RF faz-se necessário definir dois parâmetros: i) os números de variáveis (mtry) que corresponde ao número máximo de atributos que formarão cada nó e folha dentro da análise, sendo usualmente utilizada a raiz quadrada do número total de atributos, e o (ntree) que indica o número máximo de árvores de decisão a serem formadas na análise (ZANOTTA; ZORTEA; FERREIRA, 2019).

### Avaliação do Desempenho

A exatidão dos mapas temáticos foram analisadas a partir da criação da matriz de confusão e pelos índices derivados: Índice Kappa (eq. 3) e Exatidão Global (eq. 4). Além disso, foi mensurada a precisão de cada classe mapeada, utilizando os erros de inclusão (eq. 5) e de omissão (eq. 6) presentes nas classificações.

$$K = \frac{n \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_i x_{+i})}{n^2 - \sum_{i=1}^c (x_{+i} x_{xi+})} \quad (3)$$

$$E_g = \left( \frac{\sum_{i=1}^r x_{ii}}{n} \right) \quad (4)$$

$$K_p = \left( \frac{n * n_{ii} - n_{ii} * n_{+i}}{n * n_{i+} - n_{+i} * n_{i+}} \right) \quad (5)$$

$$K_u = \left( \frac{n * n_{ii} - n_{+i} * n_{+i}}{n * n_{i+} - n_{+i} * n_{i+}} \right) \quad (6)$$

Onde n é o total de amostras; 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;  $\sum_{i=1}^r (x_i x_j)$  representa o produto da soma da linha pelas colunas de cada classe representativa;  $n_{ii}$  número total de amostras corretamente classificadas da classe;  $n_{i+}$  número total de amostras classificadas da classe



$k$ ;  $n_{+i}$  é o número total de amostras coletadas da classe  $k$ .

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, que possibilita avaliar o nível de precisão da classificação, que corresponde às probabilidades relacionadas à precisão de comissão e omissão relatada de um determinado mapa temático (CONGALTON; GREEN, 1999).

O índice kappa avalia a concordância ou reprodutibilidade dos conjuntos de dados, a partir da diferença estatística entre um conjunto de dados classificados e um conjunto de validação, os resultados são qualificados segundo os valores de desempenho: péssimo ( $< 0,000$ ); ruim ( $0,00 - 0,200$ ); regular ( $0,201-0,400$ ); bom ( $0,401-0,600$ ); muito bom ( $0,601-0,800$ ); e excelente ( $> 0,801$ ), conforme Landis e Koch (1977).

De acordo com Silva Júnior et al. (2014), o Índice Kappa apresenta vantagens sobre a acurácia global, uma vez que incorpora todos os elementos da matriz de confusão, sendo sensível às variações de erros do consumidor e do produtor. Para avaliar as diferenças estatísticas dos Índices Kappa foi utilizado o teste Z (eq. 7) (CONGALTON; GREEN, 1999), que avalia o nível de significância estatística e avalia se existe significância ou não entre os resultados. O cálculo da  $\sigma^2$  (eq. 8) utiliza as equações como descrita em Amaral et al (2009).

$$z = \frac{k_2 - K_1}{\sqrt{\sigma_{k_2}^2 + \sigma_{K_1}^2}} \quad (7)$$

$$\sigma^2 = \frac{1}{n} \left[ \frac{\theta(1 - \theta_1)}{(1 - \theta_2)^2} + \frac{2(1 - \theta_1)(2\theta_1\theta_2 - \theta_3)}{(1 - \theta_2)^3} + \frac{(1 - \theta_1)^2(\theta_4 - 4\theta_2^2)}{(1 - \theta_2)^4} \right] \quad (8)$$

Onde:  $K_1$  é valor do kappa da classificação 1 e  $K_2$  corresponde ao valor do índice kappa 2; é a variância do índice kappa referente as classificações 1 e 2. Se  $Z \geq Z_{\alpha/2}$  a classificação é significativamente melhor que uma distribuição aleatória;  $\alpha/2$  é o nível de confiança nos dois lados da curva no teste Z é o número de graus de liberdade é assumido ser infinito (FIGUEREDO; VIEIRA, 2007), já os valores de  $\theta_1, \theta_2, \theta_3$  e  $\theta_4$  são descritos em Silva Júnior et al. (2014).

Para a elaboração da matriz de confusão e posterior determinação dos valores do Índice Kappa e da Exatidão Global foram utilizados 277 pontos, sendo 200 pontos coletados em atividade de campo realizado entre os dias 22 e 30 de julho de 2021, 77 pontos foram coletados a partir da análise de imagens disponíveis no *Google Earth*, e também imagens do satélite CBERS-4A, resolução de 8 metros, do período de agosto de



2020 (defasagem de 1 ano) disponibilizada de maneira gratuita pelo INPE (2020), fusionada para 2 metros utilizando o algoritmo *pansharpening*, implementado no SIG OTB, tendo como base o conhecimento dos intérpretes com apoio da segmentação realizada durante a etapa de análise dos dados.

## RESULTADOS E DISCUSSÕES

Esse item apresenta os resultados das análises comparativas realizadas entre as classificações digitais obtidas via imagem do satélite Landsat-8 e do satélite Sentinel-2, utilizando o algoritmo *Random Forest* em ambiente computacional *Python*. A discussão dos resultados foi pautada e referenciada a partir das métricas de Exatidão Global e do Índice Kappa. Adicionalmente, analisou-se o padrão visual dos mapas resultantes das classificações de uso e cobertura da terra geradas.

### Exatidão das Classificações Digitais

As tabelas 2 e 3 apresentam as matrizes de confusão das classificações geradas e mostram que a classificação resultante da imagem MSI/Sentinel-2 apresentou Exatidão Global de 84% e Índice Kappa de 0,805, ficando no patamar de excelente. A resultante das imagens OLI/Landsat-8 apresentou Exatidão Global de 80% e Kappa de 0,760, sendo qualificado como muito bom.

**Tabela 2.** Matriz de confusão para OLI/Landsat-8 em Balsas, cerrado maranhense (2021).

Landsat-8		Referência					
		FF	FS	FC	PA	CT	CH
Classificação	FF	0.89	0.13	0.00	0.00	0.02	0.10
	FS	0.03	0.80	0.05	0.06	0.00	0.00
	FC	0.00	0.00	0.80	0.24	0.08	0.00
	PA	0.02	0.03	0.05	0.59	0.10	0.00
	CT	0.05	0.00	0.07	0.06	0.79	0.00
	CH	0.02	0.04	0.02	0.06	0.02	0.90

Onde: FF = Formações Florestais, FS = Formações Savânicas, FC = Formações Campestres, PA = Pastagens, CT = Culturas Temporárias e CH = Corpos Hídricos

Fonte: dados de pesquisa, 2021

**Tabela 3.** Matriz de confusão para MSI/Sentinel-2 em Balsas, cerrado maranhense (2021).

Landsat-8		Referência					
		FF	FS	FC	PA	CT	CH
Classificação	FF	0.90	0.09	0.00	0.00	0.02	0.08
	FS	0.05	0.81	0.00	0.23	0.00	0.08
	FC	0.00	0.03	0.83	0.15	0.02	0.00



PA	0.00	0.04	0.10	0.62	0.08	0.00
CT	0.02	0.00	0.05	0.00	0.88	0.00
CH	0.03	0.03	0.02	0.00	0.00	0.85

Onde: FF = Formações Florestais, FS = Formações Savânicas, FC = Formações Campestres, PA = Pastagens, CT = Culturas Temporárias e CH = Corpos Hídricos

Fonte: dados de pesquisa, 2021

**Tabela 4.** Desempenho dos algoritmos de classificação em Balsas, cerrado maranhense (2021).

	Kappa	Exatidão Global	Var. Kappa	Qualidade
Landsat-8/OLI	0.760	80.87	0.000855287	Muito bom
Sentinel-2/MSI	0.805	84.48	0.000724433	Excelente

Fonte: dados de pesquisa, 2021

**Tabela 5.** Teste Z das classificações digitais realizadas em Balsas, cerrado maranhense (2021).

	Landsat-8	Sentinel-2
Landsat-8	25.9909	
Sentinel-2	1.13	29.9211

Fonte: dados de pesquisa, 2021.

Apesar do Índice Kappa e da Exatidão Global (tabela 4) apresentarem valores superiores na classificação da imagem MSI/Sentinel-2, não se observou diferença estatisticamente significativa, quando comparado a imagem OLI/Landsat-8, a um nível de significância de 95%, calculado pelo teste Z, em que Z calculado < Z crítico (< 1.96) (tabela 5). Estes dados indicam que o aumento da resolução espacial do sensor MSI/Sentinel-2 não gerou maior precisão para a separação de diferentes classes nesse estudo.

A imagem OLI/Landsat-8, demonstra ser mais adequada a estudos com menores níveis de detalhes nas escalas regionais ou com alvos mais homogêneos, já as imagens Sentinel-2 apresentaram melhor desempenho para identificação da classe vegetação.

Os resultados encontrados neste estudo corroboram com os resultados encontrados por Sanches-Espinosa e Schöder (2019), que mostram discreta superioridade da MSI/Sentinel-2 (0.807) em relação a OLI/Landsat-8 (0.800) para o mapeamento de áreas úmidas no sul da Espanha. 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 entre São Paulo e Minas Gerais, onde obtiveram ligeira superioridade da imagem OLI/Landsat-8 (Kappa de 0.867) em relação a MSI/Sentinel-2 (Kappa de 0.860).



Em geral, o mapa de uso e cobertura da terra resultante das imagens Landsat-8 apresentou resultados inferiores ao Sentinel-2, exceto a classe Corpos Hídricos, que apresentaram melhores valores de acurácia de produtor e menor erro comissão em relação a Sentinel-2.

Os erros de comissão e omissão mostram que, tanto o mapa das imagens MSI/Sentinel-2 quanto o mapa das OLI/ Landsat-8 (tabela 5) apresentaram em maior ou menor proporção, superestimação das classes Formações Campestres, Formações Florestais e Cultura temporárias, e subestimação das classes Pastagens e Corpos Hídricos, porém, a classificação OLI/Landsat-8 apresentou erros de omissão superiores ao MSI/Sentinel-2, indicando que a imagem Sentinel-2 conseguiu definir melhor as classes analisadas.

**Tabela 6.** Exatidão de produtor e usuário para OLI/Landsat-8 e MSI/Sentinel-2 em Balsas, cerrado maranhense (2021).

Classe	Landsat-8				Sentinel-2			
	PR	OM	US	CO	PR	OM	US	CO
Formações florestais	0.89	0.11	0.83	0.17	0.90	0.10	0.88	0.12
Formações Savânicas	0.80	0.20	0.90	0.10	0.81	0.19	0.89	0.11
Formações Campestres	0.80	0.20	0.83	0.17	0.83	0.17	0.91	0.09
Pastagens	0.59	0.41	0.45	0.55	0.62	0.38	0.36	0.64
Culturas Temporárias	0.79	0.21	0.86	0.14	0.88	0.12	0.93	0.07
Corpos Hídricos	0.90	0.10	0.56	0.44	0.85	0.15	0.69	0.31

PR = Produtor, OM = Omissão, US = Usuário, CO = Comissão.

Fonte: dados de pesquisa, 2021.

No mapa resultante da imagem OLI/Landsat-8 os maiores acertos para as classes Corpos Hídricos, Formações Florestais, Formações Savânicas e Campestres, com taxas de acerto variando entre 80% e 90%, sendo os Corpos Hídricos a classe com maior taxa de exatidão com 90%, os resultados inferiores foram observados para as classes Pastagens e Culturas Temporárias 59% e 79%, respectivamente, indicando que estas classes apresentaram elevada taxa de confusão.

Na classificação referente as imagens MSI/Sentinel-2 as classes Formações Florestais, Culturas temporárias, Corpos Hídricos, Formações Campestres e Savânicas apresentaram taxas de acerto superior a 80%, sendo as formações florestais com a maior taxa de acerto, 90%. As pastagens apresentaram o maior erro de omissão da análise, com 62%, sendo superior a taxa de acerto da classificação resultante da OLI/Landsat-8 para esta classe.

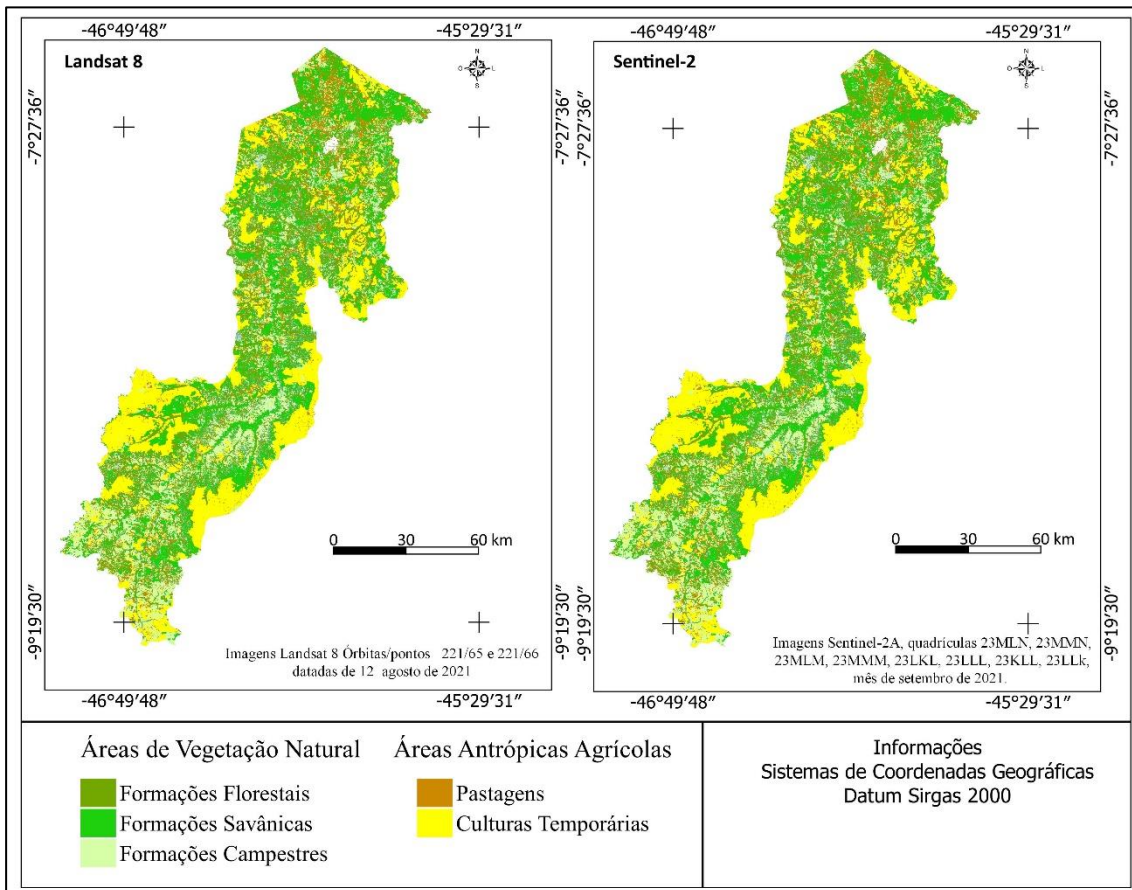
### Padrão Visual de Uso e Cobertura da Terra

Visualmente (figura 3) as classificações resultantes não apresentaram diferenças significativas entre si, apesar das imagens MSI/Sentinel-2 apresentarem melhor resolução espacial, não significou melhor



desempenho da classificação para essa área de estudo, como mostrado pela tabulação cruzada dos mapas, na qual se obteve taxa de concordância entre ambas de 72,38% (figura 4), sendo as principais divergências entre as culturas temporárias, formações savânicas e campestres.

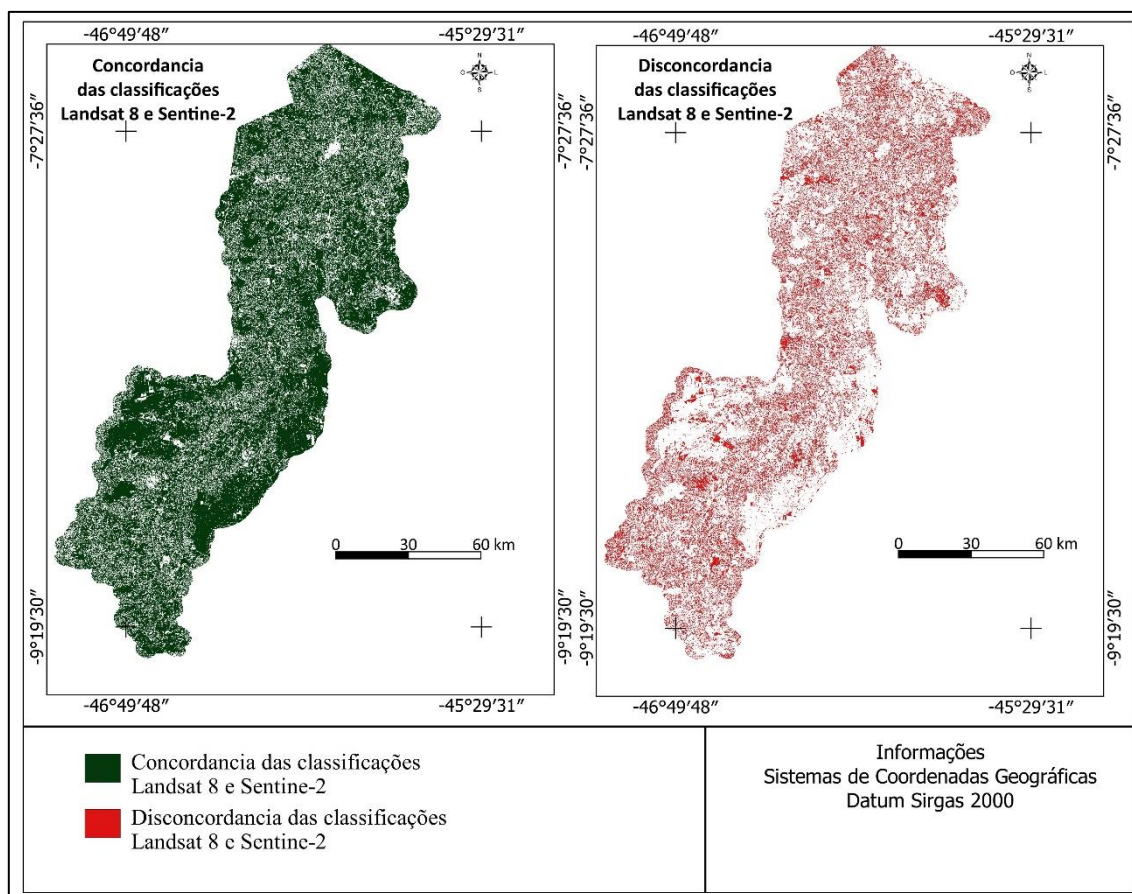
**Figura 3.** Resultado dos mapeamentos de uso e cobertura da terra para as imagens MSI/Sentinel-2 e OLI/Landsat-8 em Balsas, cerrado maranhense (2021).



Fonte: dados de pesquisa, 2021.



**Figura 4.** Concordância e discordância entre as classificações resultantes do MSI/Sentinel-2 e OLI/Landsat-8 em Balsas, cerrado maranhense (2021).



Fonte: dados de pesquisa, 2021.

Ambas as classificações apresentaram o predomínio das Áreas de Vegetação Natural, com taxas de cobertura relativamente próximas, esta classe cobriu e 68,29% na OLI/Landsat-8, no entanto a classificação resultante da MSI/Sentinel-2 recobriu 69,04%. As classes coberturas antrópicas apresentaram diferenças quando comparados os resultados, enquanto a classificação resultante da OLI/Landsat-8 esta classe representou 29,58% do total mapeado, na classificação da MSI/Sentinel-2 esta classe representou 26,19%. Os corpos hídricos apresentaram área de 4,77% e 2,14% para a OLI/Landsat-8 e MSI/Sentinel-2 respectivamente.

**Tabela 7.** Área de cobertura da terra para o nível I.

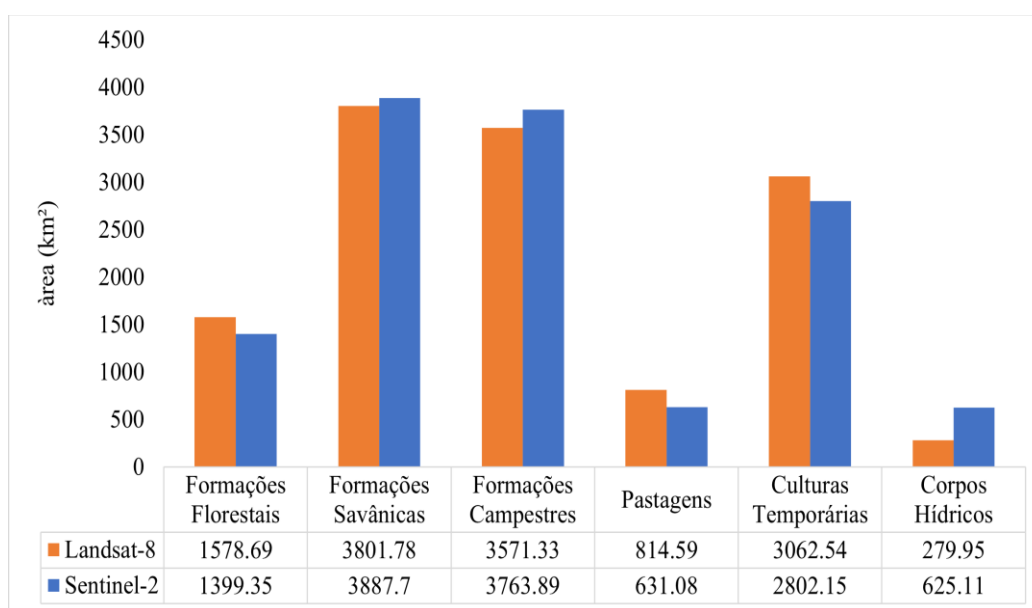
Imagem	Áreas de vegetação natural	Áreas antrópicas agrícolas	Corpos hídricos
Landsat-8	9050.94 km <sup>2</sup>	3433.23 km <sup>2</sup>	625.11 km <sup>2</sup>
Sentinel-2	8951.8 km <sup>2</sup>	3877.13 km <sup>2</sup>	279.95 km <sup>2</sup>

Fonte: dados de pesquisa, 2021.



Quanto ao padrão de cobertura e uso da terra por subclasse, as formações savânicas apresentaram área de cobertura relativamente próximas entre os mapas gerados, com diferenças inferiores a 1%. Para as formações florestais, formações campestres, culturas temporárias, pastagens e corpos hídricos apresentaram taxas de cobertura com diferenças de área mapeada entre os mapas gerados com taxa variando entre 1,3% e 2,6%. O gráfico apresentado na figura 5 mostra o padrão de distribuição do uso e cobertura da terra por classe temática.

Figura 5. Área de uso e cobertura da terra em Balsas, cerrado maranhense (2021).



Fonte: dados de pesquisa, 2021.

Em ambas as classificações predominou as formações savânicas que cobriram aproximadamente 29% no mapa resultante da OLI/Landsat-8 e 29,66% para o mapa resultante da MSI/Sentinel-2. As formações campestres corresponderam a segunda maior classe para o município de Balsas, estas apresentaram taxas de cobertura diferentes quando comparados os mapas gerados, enquanto na classificação resultante da imagem OLI/Landsat-8 esta classe correspondeu a 29%, no mapa referente a MSI/Sentinel-2 representou 23% da área total. É importante destacar que estas classes apresentaram em maior ou menor proporção superestimação, com taxa de confusão de até 15%.

A terceira maior classe, em área de cobertura, mapeados em ambas as imagens foram as culturas temporárias, com média de área de aproximadamente 22% da cobertura mapeada para o município, obtendo a maior taxa de cobertura no mapa resultante da imagem OLI/Landsat-8, onde representou 23,36%. Já para a MSI/Sentinel-2 esta classe apresentou taxa de 21,38%. Dados da Pesquisa Agrícola Municipal (IBGE, 2021), indicam que o município teve a produção de 609.025 toneladas de grãos na safra 2020/21 em uma área plantada de 3.137,31 km<sup>2</sup>, equivalendo aproximadamente 24% da área total do município.



As formações florestais apresentaram significativa variação de área, quando observados os resultados gerados, enquanto essa classe representou 10,67% da área mapeada na imagem OLI/Landsat-8, para a classificação resultante da MSI/Sentinel-2 esta classe representou 12,04% da área total. As pastagens não apresentaram um valor representativo em ambas as classificações, apresentando a segunda menor taxa de cobertura para a área. Isso indica a subestimação dessa classe tanto para a classificação resultante da OLI/Landsat-8, onde cobriu 6,21%, quanto para o mapa referente a MSI/Sentinel-2, com taxa de cobertura de 4,81%. Os corpos hídricos apresentaram cobertura inferior a 5%, sendo 2,14 para a OLI/Landsat-8 e 4,77 para a MSI/Sentinel-2.

## CONCLUSÕES

Os mapas temáticos gerados a partir das classificações digitais com o algoritmo *Random Forest* no mapeamento de uso e cobertura da terra na região de Balsas (MA), apresentaram resultados considerados satisfatórios, com Índice Kappa e Exatidão Global qualificados como muito bom e excelente para as imagens OLI/Landsat-8 e MSI/Sentinel-2 respectivamente.

As classificações resultantes do MSI/Sentinel-2 e OLI/Landsat-8, considerando a área de estudo e as datas analisadas, não apresentaram diferença estatística significativa como mostrado pelo teste z que apresentou uma taxa de significância de 95% de confiança.

Visualmente, ambos os resultados das classificações, apresentaram em maior ou menor proporção, alguma diferença, indicando a necessidade de maior aprofundamento e novas análises em relação aos parâmetros de ajuste para as características da região do cerrado maranhense.

Em novos estudos, sugere-se a utilização de métodos de classificação digital que utilizam outros critérios de separabilidade de classes, como agregação de índices espectrais, para analisar e comparar a acurácia dos dados a serem obtidos a partir do uso de imagens OLI/Landsat-8 e MSI/Sentinel-2.

## AGRADECIMENTOS

A presente pesquisa foi realizada com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP (Projeto n. 2019/26222) e de Bolsa de Doutorado da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

## REFERÊNCIAS

AMARAL, M. V. F.; SOUZA, A. L. de.; SOARES, V. P.; SOARES, C. P. B.; LEITE, H. G.; MARTINS, S. V.; FERNANDES FILHO, E. I.; LANA, J. M. de. avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. *Revista Árvore*, Viçosa-MG, v.33, n.3, p.575-582, 2009.

ARAUJO, H. B.; PEREIRA, P. R. M.; RODRIGUES, T. C. S.; COSTA JUNIOR, E. P. B. da. Mudança de cobertura da terra nos municípios de Chapadinha e Buriti – MA, entre os anos de 1990 a 2017. *Revista GEONORTE, s.l, v.q0, N.36, p.194-214, 2019*  
DOI: <https://doi.org/10.21170/geonorte.2019.V.10.N.36.A194.214>



BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. **Journal of Photogrammetry and Remote Sensing**, *s.l*, v.58, n. 1, p. 12-23. 2000.  
doi:10.12691/jgg-6-3-2

BATISTELLA, M. BOLFE, E. L.; VICENTE, L. E.; VICTORIA, D. C.; ARAÚJO, L. S. **Relatório do Diagnóstico do Macrozoneamento Ecológico-Econômico do Estado do Maranhão**. Campinas, SP: Embrapa, 2013. 445 p.: il. (Embrapa Monitoramento por Satélite / Relatório Técnico, v. 1 - CDD 333.70981).

BREIMAN, L. Random Forests. **Machine Learning**, *s.l*, v. 45, n. 1, p. 5-32, Abr 2001.

CALIXTO, D.; GUIMARÃES, F. D.; CALIXTO, L. D.; CREMON, É. H. Análise comparativa em imagens OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento do uso e cobertura da terra, **Anais do IV Simpósio Brasileiro de Geomática – SBG2017 II Jornadas Lusófonas - Ciências e Tecnologias de Informação Geográfica - CTIG2017** Presidente Prudente - SP, 2017, p. 24-26.

CHAVEZ JR., P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, n. 24 pp. 459-479, 1988. Doi: Doi.org/10.1016/0034-4257(88)90019-3

CONGALTON, R. G.; GREEN, K. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**. *s.l*, v. 49, n. 12. p. 1671-1678. 1999. Doi: doi.org/10.1016/0034-4257(91)90048-B

EUROPEAN SPATIAL AGENCY - ESA. **Sentinel-2**. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 22 mar. 2021.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do Sensoriamento Remoto. **Anais do XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil: INPE 2007 p. 21-26.

FREIRES, E. V.; SILVA NETO, C. Â da.; CUNHA, D. S. R.; DUARTE, C. R.; VERÍSSIMO, C. U. V. GOMES, D. D. M. 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**. Rio de Janeiro, v. 42, n. 4, p. 427-442. 2019. DOI: [http://dx.doi.org/10.11137/2019\\_4\\_427\\_442](http://dx.doi.org/10.11137/2019_4_427_442)

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Produção Agrícola Municipal -PAM**. Rio de Janeiro: IBGE. 2018-2020. disponível em: <https://sidra.ibge.gov.br/tabela/5457>. Acesso em: 23 de outubro de 2021

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Panorama do município de Balsas**. Disponível em <https://cidades.ibge.gov.br/brasil/ma/balsas/panorama>. Acesso em: 26/12/2020

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual Técnico de Uso da Terra**. 2 ed. Rio de Janeiro: Biblioteca IBGE, 2006.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Censo demográfico de 2010, resultado geris da amostra**, 2012. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9662-censo-demografico-2010.html?edicao=9748&t=sobre>. Acesso: 12/12/2021

IMESC - Instituto Maranhense de Estudos Socioeconômicos e Cartográficos. **PIB dos municípios do Estado do Maranhão**. São Luís: IMESC, v. 15, n. 1, jan./dez. 2021.

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

MAROCO, J. **Análise estatística: com a utilização do SPSS**. 3 ed. Lisboa: Edições Silabo, 2007.

MAIA, M. A.; RODRIGUES, N. B.; RITCHER M.; RUBIM, I. Modelos de correção atmosférica aplicados em imagens do sensor OLI/ Landsat 8 a partir do uso de programas gratuitos: uma análise comparativa. *In: Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto – SBSR*. 2017. p. 4888-4895.

MENESES, P. R.; ALMEIDA T. de. **Introdução ao processamento de imagens de Sensoriamento Remoto**. Universidade de Brasília – UNB. Brasília. 2012. Disponível em <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>. Acesso em 24/06/2019.

MOREIRA, E. P.; RODRIGUES, T. G.; OLIVEIRA, C. G. De.; SILVA JUNIOR, J. A. da. Análise de dados OLI/Landsat-8 e MSI/Sentinel-2 com diferentes níveis de processamento. **Brazilian Journal of Develop**. Curitiba, v. 6, n. 6, p. 35820-35831 jun. 2020.



NATIONAL AERONAUTICS AND SPACE ADMINISTRATION - NASA. **Landsat-8**. Disponível em: <  
<https://landsat.gsfc.nasa.gov/satellites/landsat-8/>>. Acesso em: 28 mar. 2021.

RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma Cerrado In: SANO, S. M.; ALMEIDA, S. P. (ed.). **Cerrado: ambiente e flora**. Brasília: Embrapa Cerrados, 1998. p. 87-166.

REX, F. E.; KÄFER, P. S.; DEBASTIANI, A. B.; KAZAMA, V. S. Potencial de imagens MSI (Sentinel-2) para a classificação do uso da terra. **Enciclopédia Biosfera, Centro Científico Conhecer**. Goiânia. v. 15, n. 27, p. 2018  
DOI: 10.18677/EnciBio\_2018A67

SÁNCHEZ-ESPINOSA, A.; SCHÖDER, C. 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. 2019.  
Doi: <https://doi.org/10.1016/j.jenvman.2019.06.084>

SILVA JUNIOR, C. A., FRANK, T., RODRIGUES, T. 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. 44-5. 2014  
[doi.org/10.1590/S1415-43662014000100007](https://doi.org/10.1590/S1415-43662014000100007)

UNITED STATES GEOLOGICAL SURVEY - USGS. **Landsat 8 (L8) data users handbook**. 2016. 98 p, disponível em: [arthexplorer.usgs.gov](http://arthexplorer.usgs.gov).  
Acesso em: 23/12/2021

WULDER, M. A.; HERMOSILLA, T.; WHITE, J. C.; HOBART, G.; MASEK, J. G. Augmenting Landsat time series with Harmonized Landsat Sentinel-2 data products: Assessment of spectral correspondence. *Science of Remote Sensing* 4 (2021) 100031.  
<https://doi.org/10.1016/j.srs.2021.100031>

ZANOTTA, D.; ZORTEA, M.; FERREIRA, M. **Processamento de imagens de Satélites**. São Paulo: Oficina de Textos, 2019. 320p.

ZHANG, F. YANG, X. 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 n. 1, p. 112105. 2020. Doi: <https://doi.org/10.1016/j.rse.2020.112105>