

Análise multitemporal da cobertura e do uso da terra do município de Itabirito (MG) para fins de gestão territorial

Multitemporal analysis of land cover and land use in the municipality of Itabirito (MG) for territorial management purposes

Hanna Aimée da Fraga Gonçalves

Universidade Federal de Viçosa, Viçosa, MG, Brasil

hannafraga@ufv.br

 <https://orcid.org/0000-0002-5908-9586>

Nilcilene Medeiros das Graças

Universidade Federal de Viçosa, Viçosa, MG, Brasil

nilcilene.medeiros@ufv.br

 <https://orcid.org/0000-0003-0839-3729>

Daniel Camilo de Oliveira Duarte

Universidade Federal de Viçosa, Viçosa, MG, Brasil

Daniel.duarte@ufv.br

 <https://orcid.org/0000-0002-1599-8956>

Wagner Dias de Souza

Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, Brasil

wagners@ufrj.br

 <https://orcid.org/0000-0001-9673-6511>

Darlan Miranda Nunes

Universidade Federal de Viçosa, Viçosa, MG, Brasil

darlan.nunes@ufv.br

 <https://orcid.org/0000-0001-5566-7919>

RESUMO

As múltiplas aplicabilidades do Sensoriamento Remoto em prol do desenvolvimento estão presentes em ações promovidas por meio de parcerias públicas e/ou privadas voltadas à inovação tecnológica atrelada ao progresso da pesquisa, exercendo um papel fundamental nas tomadas de decisões e análises geoespaciais relacionadas ao planejamento e ao desenvolvimento. Assim, este estudo tem por objetivo a classificação de imagens orbitais utilizando *machine learning* em uma ferramenta *open source*, para subsidiar análises geoespaciais multitemporais referentes ao município de Itabirito (MG). A metodologia aplicada neste estudo envolveu o uso do *plugin DZetsaka* no *software QGIS* versão 3.22 para a classificação das imagens de satélite, utilizando o algoritmo *random forest* como classificador. Para a validação, foi empregado o *plugin AcATAMa*, também incorporado ao *software QGIS* versão 3.22, juntamente com o método de amostras aleatórias estratificadas para avaliar a precisão dos mapas, tendo o quantitativo de 3.925 amostras de validação, divididas por ano. O cálculo do índice *Kappa* foi utilizado para avaliar a confiabilidade dos resultados, categorizando-os como 'substancial' e 'quase perfeito' nos anos analisados (2019-2022), no qual, obteve-se um índice *Kappa* entre 77% e 91%. A acurácia geral foi superior a 86%, indicando a precisão da classificação de uso e cobertura da terra no município de Itabirito (MG).

Palavras-chave: Sensoriamento remoto; Classificação de imagens; Uso da terra; Gestão territorial; *Open Source*.

ABSTRACT

The multiple applications of Remote Sensing for development are evident in actions promoted through public and/or private partnerships focused on technological innovation linked to research progress. These applications play a crucial

role in decision-making and geospatial analyses related to planning and development. Therefore, this study aims to classify orbital imagery using machine learning in an open-source tool to support multitemporal geospatial analyses for the municipality of Itabirito (MG). The methodology applied in this study involved the use of the DZetsaka plugin in QGIS version 3.22 for classifying satellite images, using the random forest algorithm as the classifier. For validation, the AcATAMa plugin, also integrated into QGIS version 3.22, was used along with the stratified random sampling method to evaluate the accuracy of the maps. A total of 3,925 validation samples were used, divided by year. The Kappa index calculation was employed to assess the reliability of the results, categorizing them as 'substantial' and 'almost perfect' for the years analyzed (2019-2022), with Kappa values ranging between 77% and 91%. The overall accuracy exceeded 86%, indicating the precision of land use and land cover classification in the municipality of Itabirito (MG).

Keywords: Remote sensing; Image classification; Land use; Territorial management; Open Source.

1. INTRODUÇÃO

Cada vez mais conceitos, métodos e tecnologias de sensoriamento remoto espacial são utilizados para, por exemplo, planejamento urbano (Ouchra; Belangour; Erraissi, 2022), desenvolvimento agrícola (Pande; Moharir, 2023), segurança nacional (Chipatiso, 2024), monitoramento ambiental (Turner; Spector; Gardiner, 2015), gestão de desastres naturais (Guha-Sapir; Hoyois; Below, 2016), análise de mudanças climáticas (IPCC, 2021), mapeamento de áreas de risco (Farhadi; Najafzadeh, 2021), gerenciamento de recursos hídricos (Duan *et al.*, 2021), exploração mineral (Shirmard *et al.*, 2022) e estudos de biodiversidade (PIMM, Jenkins e Abell 2014).

Atualmente, está ocorrendo um progresso rápido e constante na fabricação de satélites de sensoriamento remoto, chips de computadores e algoritmos baseados em Inteligência Artificial (Leutert *et al.*, 2024). A qualidade e a confiabilidade desses produtos estão em constante evolução, acompanhadas, em alguns casos, por uma redução nos custos de produção (Sassu *et al.*, 2021). No caso dos dados produzidos por satélites, observa-se um aumento significativo nas resoluções nas resoluções espaciais, espectrais e temporais, ampliando as possibilidades de análise e aplicação (Zhang *et al.*, 2022). Em relação aos chips, o poder de processamento está crescendo continuamente, permitindo análises de grandes bases de dados (Vaithianathan *et al.*, 2024). No campo da Inteligência Artificial, os softwares estão se tornando cada vez mais precisos e eficazes (Kaushik; Pandey; Bhardwai, 2023).

Os autores Pan *et al.* (2024) afirmam que o Processamento Digital de Imagens (PDI) apresenta vantagens em relação à tecnologia analógica, sendo amplamente aplicada em diversas áreas. Baseando-se em inteligência artificial e aprendizado profundo, os conceitos e princípios básicos dessa tecnologia são analisados, destacando suas vantagens e explorando métodos de aplicação na engenharia de comunicação (Han, Li e Jiang, 2021; Bo, Bingchuan e Xuefeng, 2023).

Segundo Britto (2020), para a detecção e monitoramento da vegetação com maior precisão, especialmente em áreas urbanas, as características espectrais e a resolução espacial das imagens são fatores determinantes. Nesse contexto, imagens de alta resolução espacial, como as do satélite Planet, foram analisadas por Gašparović *et al.* (2018), que realizaram uma fusão com imagens Sentinel-2 para avaliar a acurácia na detecção de vegetação em Zagreb, Croácia. Os resultados mostraram maior precisão na classificação das imagens fusionadas e nas imagens *PlanetScope* em relação às imagens Sentinel-2. Ainda segundo Britto (2020), "a resolução temporal das imagens Planet tem alto potencial para a detecção de mudanças no uso do solo, visto que a cada 24 horas uma imagem nova é disponibilizada."

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE, 2013), a concepção teórica sobre o uso da terra é também discutida nos estudos de Santos e Silveira (2004), que destacam a importância da relação entre o uso do território, a produção e o uso da informação.

Em concordância com (IBGE, 2013) e (Santos; Silveira, 2004):

"o uso do território está relacionado com a produção e com o uso de informação. Daí a necessidade de compreender as qualidades da informação, reconhecer os seus produtores e possuidores, decifrar os seus usos. Banal ou secreta, de abrangência global ou local, verticalizada por ser tributária de técnicas como os satélites ou horizontal por ser construída na co-presença: eis sua qualidade. Mas são os seus produtores e possuidores – empresas, estado, sociedade – que vão decidir dos seus usos" (Santos; Silveira, 2004, p. 93).

Além disso, o IBGE (2013) também afirma que é essencial considerar a relação entre o conhecimento técnico e a ação política, pois os usos da informação podem estar voltados tanto para fins lucrativos quanto para a defesa da soberania e dos recursos naturais.


A somar, Zioti, De Queiroz e Ferreira (2019) expressa que, o mapeamento da dinâmica do uso e cobertura da Terra é essencial para compreender os efeitos das atividades humanas sobre o planeta e gerar informações relevantes para diversas áreas, como gestão de recursos naturais,

monitoramento ambiental e mudanças climáticas, conforme já discutido por Foley *et al.* (2005). Nesse contexto, os dados espaciais desempenham um papel central, sendo que as imagens de sensoriamento remoto, por exemplo, tornaram-se uma fonte importante de informações utilizadas no monitoramento da Terra em escalas regionais e globais, conforme evidenciado por Zhu *et al.* (2021).

Com isto, têm-se como objetivo deste trabalho, aplicar o uso de PDI por intermédio de imagens orbitais pertencentes aos anos de 2019 e 2021, obtidas por meio da constelação de satélites *PlanetScope*. Vinculado a técnicas de classificação de imagens, visando a geração do uso e ocupação da terra dos anos supracitados, a extração métrica e validação, a fim de obter análises multitemporais no que acerca o uso e ocupação do Município de Itabirito (MG).

O município de Itabirito está localizado no Estado de Minas Gerais, tendo como coordenadas geográficas 20° 15' 11" Latitude Sul e 43° 47' 21" Longitude Oeste, com área de aproximadamente 542 km² (**figura 1**). A área apresenta diversificação dentre as classes de interesse, sendo: água, vegetação, solo exposto e área construída e a somar, atualmente a parceria entre o GENTE e o Município está ativa com demandas no que diz respeito à gestão territorial.

Figura 1: Mapa de localização do município de Itabirito, no estado de Minas Gerais



Fonte: Elaborado pelos autores, 2023.

O presente trabalho se justifica por meio da parceria entre a Prefeitura Municipal de Itabirito e o Grupo de Engenharia para Gestão Territorial da Universidade Federal de Viçosa (GENTE), visando a otimização no diagnóstico geoespacial por intermédio de técnicas de PDI como ferramenta auxiliar em tomadas de decisões no que tange a gestão territorial do Município de Itabirito (MG). Dessa forma, a motivação para essa pesquisa se dá pela possível tendência na interpretação referente a classificação do uso e cobertura da terra.

2. MATERIAL E MÉTODOS

O uso de Sensoriamento Remoto está presente no cotidiano da sociedade por meio de informações das imagens com o “olhar” além do visível. E partindo do princípio de que o Sensoriamento Remoto se trata de arte e ciência com objetivo obter dados e informações sobre um respectivo alvo sem contato direto (Jensen e Epiphanyo, 2009). O mapeamento por meio dessa tecnologia atende diferentes finalidades, tais como: monitoramentos ambientais (Lillesand, Kiefer e Chipman, 2014); análises multitemporais (Michalowska; Glowienka, 2022); diagnósticos de expansão urbana (Liu; Li; Nie, 2022); análises de atividades antrópicas.

O PDI visa o melhoramento visual das feições estruturais com o objetivo da otimização da análise humana, proporcionando uma melhor interpretação nas análises referentes à área de interesse (Jensen e Epiphanyo, 2009). Podendo então proporcionar a geração de produtos cartográficos, onde, espera-se atingir o padrão de confiabilidade temática do coeficiente *Kappa* (Mchugh, 2012; Congalton e Green, 2008).

Com base nos conceitos e técnicas de Sensoriamento Remoto e PDI, esse trabalho se desenvolveu usando a seguinte metodologia demonstrada na **figura 2**.

Para a extração de imagens orbitais utilizou-se produtos referente ao satélite *PlanetScope* (2016), tendo como nível de processamento o produto *PlanetScope Ortho Scene* com nível 3B, presente no **Quadro 1**. Obteve-se então as imagens orbitais provenientes do satélite *PlanetScope* (nível 3B) com cobertura terrestre de 100% e nuvens inferiores a 10% referentes ao ano de 2019, 2020, 2021 e 2022.


Adotando o critério com cobertura de nuvens inferior a 10% e mapeamento da área em 100%, obteve-se imagens orbitais referente aos anos de 2019 a 2022. Válido expressar que os anos escolhidos para o presente trabalho tem influência diretamente ligada ao ano de ativação do satélite e as condições de cobertura terrestre e de nuvens.

Para a cobertura de toda área de interesse foi realizado o mosaico das cenas orbitais com quatro bandas (RGB e NIR), resolução espacial de 3 m e somado ao contraste com o método de corte cumulativo. Onde tem-se como fundamento os limites de padrões de extensão das imagens então trabalhadas. Após isto, ocorreu a junção do mosaico e o recorte pelo limite municipal de Itabirito segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2018).

No que tange às coletas de treinamento, definiu-se as seguintes classes: vegetação; água; solo exposto; área construída; área rochosa; vegetação rasteira. A definição de das classes foi baseada nos elementos presentes nas respectivas imagens orbitais do ano de 2019, 2020, 2021 e 2022 do município de Itabirito. A fim de facilitar o entendimento sobre o que tange a definição das classes então expressadas treinamento (**Quadro 2**) além da quantificação das amostras de treinamento (**Tabela 1**), tem-se as seguintes tabela abaixo.

Ressalta-se que estão presentes nas imagens orbitais diferentes pigmentações referentes às classes, tais como na água apresentando colorações mais escuras e claras, o solo exposto e área construída por conta dos distintos tipos de telhados. Importante salientar que além da atribuição visual para a categorização das classes, foi usado o Índice de Diferença Normalizada de Vegetação (NDVI) para a delimitação das classes de vegetação e vegetação rasteira e o Índice de Diferença Normalizada da Água (NDWI) para identificação das amostras de água. Tais índices espectrais foram gerados e entregues juntamente com os mosaicos de 2019, 2020, 2021 e 2022 do município de Itabirito.

Figura 2: Fluxograma Metodológico



Fonte: Elaborado pelos autores, 2023.

Quadro 1: Níveis de Processamento de Produto - *PlanetScope*

Nome	Descrição/Nível
Produto <i>PlanetScope Basic Scene</i>	Enquadramento baseado em cena e não é projeto para uma projeção cartográfica - Nível 1B
Produto <i>PlanetScope Ortho Scene</i>	Enquadramento baseado em cena e projetado para uma projeção cartográfica - Nível 3B
Produto <i>PlanetScope Ortho Tile</i>	Ortorretificadas e projetadas para uma projeção UTM - Nível 3ª

Fonte: Planet, 2016.

Quadro 2: Amostras das classes coletadas

Classes	Amostras
Vegetação	
Água	
Solo Exposto	
Área Construída	
Área Rochosa	
Vegetação Rasteira	

Fonte: Elaborado pelos autores, 2023.

Tabela 1: Amostras de treinamento

Ano	Amostras de Treinamento
2019	515
2020	599
2021	589
2022	641
Total:	2.344

Fonte: Elaborado pelos autores, 2023.

Na etapa de classificação das imagens foi utilizado o *plugin Dzetsaka* por meio do *software* QGIS versão 3.22. O algoritmo chamado *random forest* foi utilizado como modelo de treinamento, seguindo as recomendações descritas nos trabalhos de Breiman (2001) e Fraga (2021). Este algoritmo de *machine learning* é usado para classificação supervisionada, sendo reconhecido por sua flexibilidade e facilidade de uso (Donges, 2021).

Para a validação dos produtos, foi utilizado o *plugin AcATAMa*, que também está acoplado ao *software* QGIS versão 3.22, cuja finalidade é a avaliação e a precisão de mapas, Llano, XC (2022). Para as amostras de validação, foi utilizado o método de amostras aleatórias estratificadas, ou seja, amostras proporcionalmente as classes presentes nas imagens de uso e ocupação do solo, tendo tal quantificação (**Tabela 2**). No somatório de todas as amostras realizadas, totalizam-se: 3.925 amostras, sendo divididas por ano em respectiva **Tabela 3**.

Tabela 2: Amostras de validação

Ano	Amostras de Validação
2019	395
2020	395
2021	395
2022	395

Fonte: Elaborado pelos autores, 2023.

Tabela 3: Amostra/ano

Ano	Amostras/ano
2019	910
2020	995
2021	984
2022	1.036
Total:	3.925

Fonte: Elaborado pelos autores, 2023.

Adotou-se então o erro padrão geral esperado de 0.5% com significância 95% do nível de confiança em relação à probabilidade entre as amostras geradas das imagens classificadas e as amostras de validação derivadas do método aleatório extrativista. Após a operação de validação, gerou-se o relatório contendo a matriz de confusão que fornece a avaliação em relação a medição de desempenho da *machine learning* das imagens classificadas de cobertura e uso da terra.

Assim sendo, se adquiriu também a acurácia do usuário (Hord *et al.*, 1976; Rosenfield e Fitzpatrick-Lins, 1986; Congalton, 1991) e do produtor (Rosenfield e Fitzpatrick-Lins, 1986; Story *et al.*, 1986), onde ambas resultam na relação entre a quantificação de acerto da classe representada, ou seja, a probabilidade de acerto. Porém, ambas se distinguem, pois a acurácia do usuário está relacionada com o erro de comissão e do produtor em relação ao erro de omissão. E acrescentado a isto, a acurácia geral que define em porcentagem a proporção da área mapeada corretamente, conforme Olofsson *et al.* (2013).

Posteriormente foi realizado o cálculo do índice *Kappa*, referenciado por Cohen, (1960) como um método de avaliação em relação ao nível de confiabilidade de determinado produto gerado. Atrélado a isto, Landis e Koch (1977) atribuiu intervalos para o índice *Kappa*, **Tabela 4**.

Tabela 4: Índice *Kappa*


Estatística <i>Kappa</i>	Concordância
< 0.00	Ruim
0.00 – 0.20	Pouco
0.21 – 0.40	Justo
0.41 – 0.60	Moderado
0.61 – 0.80	Substancial
0.81 – 1.00	Quase perfeito

Fonte: Traduzido de Landis e Koch, 1977.

3. RESULTADOS E DISCUSSÕES


Procedendo então a classificação da cobertura e uso da terra com a inserção das amostras de treinamento e do classificador *random forest*, onde foram gerados tais produtos, **figuras 3, 4, 5 e 6**. É importante relatar que após o processamento de cada classificação, aplicou-se a filtragem referente a substituição de células baseando-se em sua majoritariedade vizinhas.

Figura 3: Uso da Terra - 2019




Fonte: Elaborado pelos autores, 2023.

Figura 4: Uso da Terra - 2020




Fonte: Elaborado pelos autores, 2023.

Figura 5: Uso da Terra - 2021



Fonte: Elaborado pelos autores, 2023.

Figura 6: Uso da Terra - 2022



Fonte: Elaborado pelos autores, 2023.

Após a operação de validação, gerou-se o relatório contendo a matriz de confusão que fornece a avaliação em relação a medição de desempenho da *machine learning* das imagens classificadas da cobertura e uso da terra e a amostra de validação. Tendo a presente fundamentação do índice *Kappa* e com a matriz de confusão, foram gerados os índices de cada uso e ocupação produzido, as métricas estão presentes na **Tabela 5**.

Tabela 5: Matriz de Confusão e *Kappa*

Ano	Acurácia Global (%)	<i>Kappa</i> (%)
2019	86	77
2020	91	85
2021	95	91
2022	91	84


Fonte: Elaborado pelos autores, 2023.

Nota-se então que nos quatro casos da validação o índice *Kappa* apresentou resultados “substancial”, ou seja, considerável no ano de 2019 e em 2020, 2021 e 2022 foi categorizado como “quase perfeito”, conforme visto na **Tabela 4**. Isto significa que, ambos produtos estão validados conforme as fundamentações então expressadas neste trabalho. Além disso, a acurácia apresentou resultados acima de 86%, ou seja, apresentou 86% de proporção do acerto da classificação de uso e ocupação da terra.

Assim sendo, se adquiriu também a acurácia do usuário e do produtor, onde ambas resultam na relação entre a quantificação de acerto da classe representada, ou seja, a probabilidade de acerto. Porém ambas se distinguem, pois a acurácia do usuário está relacionada com o erro de comissão e do produtor em relação ao erro de omissão. E acrescentado a isto, a acurácia geral que define em porcentagem a proporção da área mapeada corretamente, conforme Olofsson *et al.* (2013).


Para melhor explicitar a quantificação das classes em relação à cobertura e uso da terra perante os anos de 2019, 2020, 2021 e 2022, procedeu-se com a porcentagem estatística de cada classe em relação ao uso e ocupação total, no qual foi possível obter através da **figura 7**. Acrescentado a isto, para melhor explicitação e comparação visual em relação ao período analisado, tem-se como ilustração a **figura 8**.

Figura 7: Gráfico em as Classes x Ano



Fonte: Elaborado pelos autores, 2023.

Figura 8: Gráfico em Relação ao Período



Fonte: Elaborado pelos autores, 2023.

Com base em tais informações, é possível observar com base nas imagens orbitais, que durante esses quatro anos ocorreu o aumento no índice vegetação. No que tange as classes área construída, água e solo exposto, nota-se variações, porém tendenciando ao padrão, diferentemente da área rochosa que declinou e da vegetação rasteira, ambas podem ser justificadas por influência da época climática que foi realizado a captura das imagens orbitais.

Faz-se pertinente expressar que o percentual menor das classes água e área construída estão diretamente ligados em relação ao total do uso e ocupação de terra de Itabirito, ou seja, sua maior abrangência é de vegetação, seguida da vegetação rasteira, solo exposto, área rochosa, área construída e água. A somar, fundamentando nesta produção, pode-se observar que o município apresentou equilíbrio entre a vegetação e as áreas construídas.

4. CONCLUSÕES

Portanto, com o presente trabalho, foi possível atingir o objetivo de realizar classificação de imagens por meio de *open source*, alcançando o coeficiente *Kappa* superior a 77% e análise geoespacial e multitemporal em relação ao uso e ocupação da terra do município de Itabirito.

Logo, ressalta-se a importância da parceria público privada com fins de desenvolvimento ordenado, onde este estudo atrela-se a parceria inovadora e tecnológica entre a Prefeitura Municipal de Itabirito e o Grupo de Engenharia para Gestão Territorial. Tendo como influência positivas voltadas às ações da gestão territorial da Cidade bem como, o cadastro territorial multifinalitário, regularização fundiária urbana, plano diretor, zoneamento, monitoramento ambiental, expansão urbana, planejamento urbano, enfim vertentes que tendem a proporcionar melhorias na qualidade de vida para a população.

Em suma, pode-se expressar também que o Sensoriamento Remoto é uma alternativa de expansão para o entendimento do Universo com vasta benfeitoria para a Sociedade, onde o mesmo atua em distintas linhas de pesquisa. Esta multiaplicabilidade é uma das fontes para a busca de compreensão no que diz respeito à origem e evolução da Sociedade.

AGRADECIMENTOS

Os Autores agradecem a Universidade Federal de Viçosa, ao Grupo de Engenharia para Gestão Territorial (GENTE), a Fundação Arthur Bernardes (FUNARBE) pelo investimento científico e a Prefeitura Municipal de Itabirito pela parceria ímpar em prol da gestão territorial.

REFERÊNCIAS

BO, L.; BINGCHUAN, B.; XUEFENG, Z. Vision-based structural displacement measurement under ambient-light changes via deep learning and digital image processing. **Measurement**, [S.L] v. 208, p. 112480, fev.2023. Elsevier BV. <http://dx.doi.org/10.1016/j.measurement.2023.112480>.

BREIMAN, L. Random forests. **Machine Learning**, Statistics Department, University of California, Berkeley -USA, v. 45, n. 1, p. 5–32, 2001.

BRITTO, Marcela Dupont. **Potencialidade dos dados planetscope para a identificação da interferência antrópica em elementos do ciclo hidrológico no Campus Darcy Ribeiro**. 2020. 69 f., il. Dissertação (Mestrado em Geociências Aplicadas) - Universidade de Brasília, Brasília, 2020.

CHIPATISO, E. Application of Geographic Information Systems and Remote Sensing in Military Operations: A Systematic Review. **Authorea Preprints**, University of Zimbabwe (UZ), Faculty of Engineering and Built Environment, Department of Geo-Informatics and Surveying, Harare, Zimbabwe, v. 1, n. 1p.11, 2024.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, Broken Sound Parkway NW, USA, v. 20, n. 1, p. 37–46, 1960.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data**. Remote Sensing of Environment, Department of Forestry and Resource Management, University of California, Berkeley, v. 37, n. 1, p. 35–46, 1991.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**, Broken Sound Parkway NW, USA, 2nd ed, p. 210, 2008.

DONGES, N. **Random Forest classifier: A complete guide to how it works in machine learning**. Builtin.com, 2021. Disponível em: <https://builtin.com/data-science/random-forest-algorithm>. Acesso em: 15 jan. 2025.

DUAN, W. *et al.* Recent advancement in remote sensing technology for hydrology analysis and water resources management. **Remote sensing**, Basileia, Suíça, v. 13, n. 6, p. 1097, 2021.

FARHADI, H.; NAJAFZADEH, M. Flood risk mapping by remote sensing data and random forest technique. **Water**, Toosi University of Technology, Irã, v. 13, n. 21, p. 3115, 2021.

FOLEY, J. A. *et al.* Global consequences of land use. **Science**, Center for Sustainability and the Global Environment (SAGE), University of Wisconsin, 1710 University Avenue, Madison, USA, v. 309, n. 5734, p. 570-574, 2005.

FRAGA, H. A. F. G. **Análise Comparativa da Classificação de Ortofoto ARP e Imagens de Sentinel-2A com Orfeo Toolbox em Figueira da Foz**. 2021. 81 f. TCC (Graduação) - Curso de

Engenharia de Agrimensura e Cartográfica, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2021.

GAŠPAROVIĆ, Mateo *et al.* Fusion of sentinel-2 and planetscope imagery for vegetation detection and monitoring. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Hannover, Alemanha, v. 42, p. 155-160, 2018.

GUHA-SAPIR, D.; HOYOIS, P.; BELOW, R. Annual disaster statistical review 2016: The numbers and trends. **Centre for Research on the Epidemiology of Disasters (CRED)**, Université Catholique de Louvain, Bélgica, v.1, p. 91,2016.

HAN, M. Y.; LI, L. R.; JIANG, K. Retinex low-illumination image enhancement algorithm based on light image estimation. **Computer Engineering**, USA, v. 47, n. 10, p. 201-206, 2021.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Cidades**, 2018. Disponível em: <https://cidades.ibge.gov.br/brasil/mg/itabirito/panorama>.

IBGE. **Manual técnico de uso da terra**. Rio de Janeiro: IBGE, 2013.

IPCC - INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Climate Change 2021: The Physical Science Basis**. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, 2021.

JENSEN, J. R.; EPIPHANIO, J. C. N. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora, SP, 2009.

KAUSHIK, A.; PANDEY, S.; BHARDWAI, E. Improvements in Satellite Navigation, Artificial Intelligence, as well as Deep Learning for Recognition, Prediction and Evaluation of Ocean Oil Spillages. In: **2023 1st DMIHER International Conference on Artificial Intelligence in Education and Industry 4.0 (IDICAIEI)**. IEEE, 2023. p. 1-6.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **International Biometric Society**, Washington, DC, USA, v. 33, n. 1, p. 159–174, 1977.

LEUTERT, F. *et al.* AI-enabled Cyber–Physical In-Orbit Factory-AI approaches based on digital twin technology for robotic small satellite production. **Acta Astronautica**, York University, Toronto, Ontario, Canada, v. 217, p. 1-17, 2024.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 7th ed. John Wiley & Sons, 2014.

LIU, G.; LI, J.; NIE, P. Tracking the history of urban expansion in Guangzhou (China) during 1665–2017: Evidence from historical maps and remote sensing images. **Land Use Policy**, Florida State University College of Law. USA, v. 112, p. 105773, 2022.

LLANO, X. C. AcATAMa - plugin qgis para avaliação de precisão de mapas temáticos. **QGIS Plugins Repository**, 2022. Disponível em: <https://plugins.qgis.org/plugins/AcATAMa/>.

MCHUGH, M. L. Interrater reliability: the kappa statistic. **Biochemia Medica**, Zagreb, Croácia, v. 22, n. 3, p. 276–282, 2012.

MICHALOWSKA, K.; GLOWIENKA, E. Multi-Temporal Analysis of Changes of the Southern Part of the Baltic Sea Coast Using Aerial Remote Sensing Data. **Remote Sensing**, Basileia, Suíça, v. 14, n. 5, p. 1212, 2022.

OLOFSSON, P.; FOODY, G. M.; STEHMAN, S. V.; WOODCOCK, C. E. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. **Remote Sensing of Environment**, USA, v. 129, p. 122–131, 2013.

OUCHRA, H.; BELANGOUR, A.; ERRAISSI, A. A comprehensive study of using remote sensing and geographical information systems for urban planning. **Internetworking Indonesia Journal**, Indonésia, v. 14, n. 1, p. 15-20, 2022.

PAN, L. *et al.* Combine deep learning and artificial intelligence to optimize the application path of digital image processing technology. In: **Proceedings of the 2024 Guangdong-Hong Kong-Macao Greater Bay Area International Conference on Digital Economy and Artificial Intelligence**. 2024. p. 516-519.

PANDE, C. B.; MOHARIR, K. N. Application of hyperspectral remote sensing role in precision farming and sustainable agriculture under climate change: A review. **Climate Change Impacts on Natural Resources, Ecosystems and Agricultural Systems**, p. 503-520, 2023.

PIMM, S. L.; JENKINS, C. N.; ABELL, R. **The biodiversity of species and their rates of extinction, distribution, and protection**. *Science*, New York, v. 344, n. 6187, p. 1246752, 2014.

PLANETSCOPE. **Planet imagery product specification**: PlanetScope & RapidEye. Technical Report. PlanetLabs: San Francisco, CA, USA, 2016.

ROSENFELD, G.H.; Fitzpatrick-Lins, K. **A coefficient of agreement as a measure of thematic classification accuracy**. *Photogrammetric Engineering Remote Sensing*, U.S. Geological Survey, Reston, VA, USA, v.52, n. 2, p.223-227, Feb. 1986.

SANTOS, M.; SILVEIRA, M. L. **O Brasil: território e sociedade no início do século XXI**. São Paulo: Record, 2004.

SASSU, A. *et al.* Advances in unmanned aerial system remote sensing for precision viticulture. **Sensors**, Basileia, Suíça, v. 21, n. 3, p. 956, 2021.

SHIRMARD, H. *et al.* A review of machine learning in processing remote sensing data for mineral exploration. **Remote Sensing of Environment**, USA, v. 268, p. 112750, 2022.

TURNER, W.; SPECTOR, S.; GARDINER, N. Remote sensing for biodiversity science and conservation. **Trends in Ecology & Evolution**, Maryland Heights, MO, USA, v. 18, n. 6, p. 306–314, 2015.

VAITHIANATHAN, M. *et al.* Integrating AI and Machine Learning with UVM in Semiconductor Design. **ESP International Journal of Advancements in Computational Technology (ESP-IJACT)**, India, v. 2, p. 37-51, 2024.

ZHANG, B. *et al.* Progress and challenges in intelligent remote sensing satellite systems. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, China, v. 15, p. 1814-1822, 2022.

ZHU, Qiqi *et al.* Land-use/land-cover change detection based on a Siamese global learning framework for high spatial resolution remote sensing imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, Hannover, Alemanha, v. 184, p. 63-78, 2022.

ZIOTI, F.; DE QUEIROZ, G. R.; FERREIRA, K. R. Análise de ferramentas para processamento de grandes volumes de dados espaço-temporais. In: **GEOINFO**. São José dos Campos, SP, p. 255-260, 2019.



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.