



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Classificação Supervisionada de Imagem Multiespectral para Mapeamento de Uso do Solo em Várzea Grande, Mato Grosso, Brasil: Dinâmicas Urbanas e Ambientais na Região

Luciana Oliveira da Silva Lima¹, Flávia Maria de Moura Santos², Marta Cristina de Jesus Albuquerque Nogueira³, Rodrigo Esteves Ascurra⁴, Elyander dos Santos Souza⁵

¹ Dra. em Física Ambiental e Professora do Departamento da Área de Eletroeletrônica do Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT), Campus Octayde, R. Zulmira Canavarros, 95 - Centro, Cuiabá - MT, 78005-390. luciana.silva@ifmt.edu.br (autor correspondente). ² Doutora em Física Ambiental e Professora Adjunta do Departamento de Arquitetura e Urbanismo da Universidade Federal de Mato Grosso. Av. Fernando Corrêa da Costa, nº 2367. Boa Esperança - Cuiabá - MT. flavia_mms@hotmail.com. ³ Doutora em Engenharia Civil e Professora Titular do Departamento de Arquitetura e Urbanismo da Universidade Federal de Mato Grosso. Av. Fernando Corrêa da Costa, nº 2367. Boa Esperança - Cuiabá - MT. mcjanp@gmail.com. ⁴ Doutor em Física Ambiental e Engenheiro Eletricista da Universidade Federal de Mato Grosso. Av. Fernando Corrêa da Costa, nº 2367. Boa Esperança - Cuiabá - MT. rodrigo.ascurra@ufmt.br. ⁵ Graduado em Sistemas da Informação cursando a especialização em Redes de Computadores no Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT), Campus Octayde. R. Zulmira Canavarros, 95 - Centro, Cuiabá - MT, 78005-390. elyander@gmail.com.

Artigo recebido em 29/05/2024 e aceito em 02/02/2025

RESUMO

Este estudo teve como objetivo analisar os impactos do desenvolvimento urbano desenfreado e das mudanças na cobertura vegetal no meio ambiente, destacando a necessidade de ferramentas eficazes para o monitoramento e planejamento urbano. O sensoriamento remoto se mostrou uma alternativa robusta para a classificação de uso do solo, fornecendo informações precisas e atualizadas sobre a superfície terrestre. A pesquisa aplicou a classificação supervisionada de imagens multiespectrais para mapear o uso do solo em Várzea Grande, Mato Grosso, Brasil, uma das cidades mais populosas do estado. Foram utilizadas imagens de satélite Landsat 5 e Landsat 9 para gerar mapas de uso do solo nos anos de 1985, 1992, 2003, 2011 e 2022. A análise espacial revelou um crescimento urbano acelerado, com significativa expansão das áreas urbanizadas e perda de cobertura vegetal. Os resultados fornecem subsídios valiosos para o planejamento urbano, gestão ambiental e monitoramento de mudanças na paisagem, contribuindo para o desenvolvimento sustentável da região.

Palavras-chave: Sensoriamento remoto, classificação supervisionada, uso do solo, crescimento urbano, mudanças ambientais.

Supervised Classification of Multispectral Images for Land Use Mapping in Várzea Grande, Mato Grosso, Brazil: Urban and Environmental Dynamics in the Region

ABSTRACT

The objective of this study was to analyze the impacts of unbridled urban development and changes in vegetation cover on the environment, highlighting the need for effective tools for urban monitoring and planning. Remote sensing has proven to be a robust alternative for land use classification, providing accurate and updated information about the Earth's surface. This research applied supervised classification of multispectral images to map land use in Várzea Grande, Mato Grosso, Brazil, one of the state's most populous cities. Landsat 5 and Landsat 9 satellite images were used to generate land use maps for the years 1985, 1992, 2003, 2011, and 2022. Spatial analysis revealed accelerated urban growth, with significant expansion of urbanized areas and loss of vegetation cover. The results provide valuable support for urban planning, environmental management, and monitoring of landscape changes, contributing to the sustainable development of the region.

Keywords: Remote sensing, supervised classification, land use, urban growth, environmental changes.

Introdução

O clima urbano em grandes cidades apresenta desafios crescentes, como o aumento das

ilhas de calor e a diminuição da qualidade do ar (Almeida et al., 2022; Errea et al., 2023; Ferreira et

al., 2022; Filho & Aleixo, 2023; Gourfi et al., 2022; Gulyanov et al., 2022; Hanafiah, 2019; Li et al., 2022). O sensoriamento remoto é muito utilizado em estudos do clima urbano (Almeida et al., 2022; Ferreira et al., 2022; Jardim et al., 2022), sendo comumente empregado para obter a temperatura superficial terrestre e outras características superficiais de grandes áreas (Kang & Im, 2024; Mushore et al., 2022; Silva, 2020; W. Zhang et al., 2024).

Sua larga utilização ocorre em grande parte devido à disponibilização gratuita de imagens de satélite com grande resolução espacial (Jardim et al., 2022; Shah & Patel, 2023; Zhu et al., 2021), possibilitando avaliar mudanças na paisagem de uma localidade, sua cobertura vegetal, uso do solo, dentre outros (Kotaridis & Lazaridou, 2021; Li et al., 2022; Pfeiff et al., 2020; Worsa-Kozak & Arsen, 2023).

No contexto da análise de imagens e sensoriamento remoto, a classificação de imagens desempenha um papel crucial. (Chen et al., 2022; Fitz, 2020; A. S. R. M. Santos et al., 2019; Souza et al., 2022). Através da classificação é possível identificar e categorizar objetos, terrenos e outras informações presentes na imagem (Ahmed et al., 2021; Huang et al., 2020; Malcoti et al., 2023; Mendes et al., 2022; Rai et al., 2023; Thanvisitthpon, 2023).

A classificação supervisionada de imagens multiespectrais é uma técnica que utiliza múltiplas bandas de uma imagem para identificar objetos ou terrenos de interesse (Asming et al., 2022; Nasiri et al., 2023; D. Zhang & Zhao, 2023). Essas bandas podem ser obtidas a partir de diferentes sensores, como o Landsat, o Sentinel e o MODIS, entre outros (Niang et al., 2020). A utilização de imagens multiespectrais permite uma melhor discriminação entre os diferentes objetos presentes na imagem, já que cada banda captura informações diferentes sobre a superfície terrestre (Espejo et al., 2020; Júnior & Pacheco, 2023; Pande & Banerjee, 2023).

Basicamente, existem dois métodos de classificação: a supervisionada e a não supervisionada. Na classificação supervisionada, são realizadas coletas de amostras de treinamento de classes (como área construída, água, vegetação e solo exposto, por exemplo) (Shakya et al., 2023; Shendy & Nalepa, 2024; Souza et al., 2022). Depois cada pixel da imagem é classificado segundo um algoritmo de supervisionado usando as amostras de treinamento, sendo que o pixel desconhecido da imagem é atribuído a uma classe que tenha a maior probabilidade de pertencer (Ahmed et al., 2021; Alito & Kerebih, 2024; Thakur & Panse, 2022; Vieira & Viana, 2021).

Neste tipo de classificação, a melhor

precisão da classificação é obtida com a coleta de amostras de treinamento homogêneas (Ma et al., 2017).

No método de classificação não supervisionado ocorre o agrupamento de pixels em diferentes classes espectrais, definidas pelo algoritmo, sem um conhecimento prévio das mesmas, conforme regras estatísticas definidas, atribuindo a cada pixel da imagem a uma classe (Asming et al., 2022; Zhou et al., 2021).

Existem vários métodos para realizar a classificação supervisionada de imagem multiespectral, incluindo árvores de decisão, redes neurais, SVM (Support Vector Machine) e análise discriminante (Adegun et al., 2023). Cada método tem suas próprias vantagens e desvantagens, e a escolha do método a ser utilizado depende das características específicas do conjunto de dados e do objetivo da análise (Alghamdi et al., 2021; Wang et al., 2022). Dentre as várias técnicas a classificação de máxima verossimilhança se destaca por ser uma técnica robusta e com baixo percentual de erro (Belloli et al., 2022; Sisodia et al., 2014).

A precisão da classificação depende da qualidade da imagem e da escolha dos parâmetros do algoritmo de classificação, sendo um processo iterativo e que pode ser ajustado conforme necessário para melhorar a precisão (Baohui et al., 2022; K. Santos et al., 2019; Thirumaladevi et al., 2022).

Este artigo apresenta um estudo de caso de classificação supervisionada de imagens multiespectrais de uma cidade de grande porte, utilizando técnicas de aprendizado de máquina e análise de dados.

Material e métodos

Localização e Caracterização da Área Experimental

Várzea Grande, situada nas coordenadas 15°38'49" S e 56°07'58" W, é um município integrante da região metropolitana de Cuiabá, a capital do estado de Mato Grosso, Brasil. Com uma área total de 724,28 km², o município é dividido entre a macrozona urbana, que ocupa 164,93 km², e a região rural, que se estende por 559,35 km² (IBGE, 2022b).

Geograficamente, Várzea Grande está posicionada a oeste do meridiano de Greenwich e possui uma altitude média que não ultrapassa os 200 metros acima do nível do mar. Quanto aos limites territoriais, o município confina-se ao norte com as cidades de Acorizal, Rosário Oeste e Jangada; ao sul, faz fronteira com Poconé e Santo Antônio do Leverger; a leste, está adjacente à capital mato-grossense, Cuiabá; e a oeste, limita-se

com o município de Nossa Senhora do Livramento (Várzea Grande, 2021).

A Figura 1 ilustra o mapa de localização de

Várzea Grande, detalhando suas fronteiras e proximidades com áreas adjacentes.




Figura 1. Mapa de Localização de Várzea Grande-MT.

É a segunda cidade mais populosa do estado de Mato Grosso, com 315.711 habitantes, dos quais cerca de 98% da população vive na área urbana e 2% na área rural (IBGE, 2022a).

A economia de Várzea Grande é diversificada, com destaque para o setor de serviços, comércio e indústria. O município conta

com um polo industrial que abriga empresas de diversos setores, como alimentício, têxtil, químico, metalúrgico, entre outros. Além disso, a região é marcada por uma forte atividade agropecuária, com destaque para a produção de gado bovino, soja e milho. A Figura 2 mostra uma imagem aérea da área central da cidade.



Figura 2. Imagem aérea de Várzea Grande. Fonte: (Kililla, 2022).

O território municipal se divide em distritos. São eles: Bom Sucesso, Formigueiro, Limpo Grande, Pai André, Passagem da Conceição, Praia Grande, Souza Lima e Perímetro Urbano (Várzea Grande, 2021).

No Perímetro Urbano estão localizados uma variedade de bairros agrupados em cinco grandes regiões. Os bairros mais próximos da área central são dotados de infraestrutura urbana, como apresentado na Figura 3.




Figura 3. (A) Ordenamento Territorial de Várzea Grande e (B) Regiões do Perímetro Urbano de Várzea. Fonte: Adaptado de (Várzea Grande, 2021).

Nos bairros e empreendimentos imobiliários mais recentes nota-se um melhor planejamento do crescimento da cidade. Na região Norte se localiza o Polo Tecnológico, com a presença de campus universitários e na Região Central está estabelecido o Aeroporto Internacional Marechal Rondon.

No território de Grosso a temperatura é fortemente influenciada por elementos geográficos, como a latitude e a longitude, a continentalidade e pela circulação da atmosfera regional. A longa distância da costa brasileira condiciona a região a temperaturas elevadas por não possuir a atuação moderadora dos oceanos. As temperaturas amenas na região estão associadas às porções mais elevadas dos planaltos. O clima de Várzea Grande é do tipo tropical de savana semiúmido do tipo Aw, segundo a classificação de Köppen-Geiger, caracterizado por verão chuvoso e inverno seco (Lima et al., 2024).

A vegetação predominante na região é o cerrado, com algumas áreas de transição para a floresta amazônica. No entanto, ao longo dos anos,

a expansão das atividades humanas, como a agricultura e a pecuária, tem levado a uma diminuição significativa da cobertura vegetal original.

Verifica-se que o período seco corresponde a cerca cinco meses, com precipitação inferior a 60mm, correspondentes ao período de maio a setembro e o restante é caracterizado como período chuvoso. Setembro e outubro são os meses mais quentes do ano, com temperatura máxima acima dos 33°C e julho é o mês com temperaturas mais amenas, registrando mínima de 18,6°C.

Integra o relevo da Baixada do Rio Paraguai e calha do Rio Cuiabá, pertencente à Baixada Cuiabana ou Peri. A declividade predominante do terreno está abaixo dos 8%, podendo ser classificado como suavemente ondulado e plano, não se verificando a presença de regiões com declividade superior a 20%. Sua região não possui elevações notáveis, sendo a inclinação mais elevada a rampa chamada de Morro Vermelho, conforme mostra a Figura 4.




Figura 4. Mapa de Declividade e Hipsométrico de Várzea Grande-MT.

Ocorre com frequência a existência de chapadões cobertos de cerrado e alguns poucos capões, salvo a área marginal do Rio Cuiabá e do Rio Pari, seu afluente. Possui solo raso, com a ocorrência de níveis maior de resistência a mecanização e a penetração de raízes.

Sistema de Informação Geográfica (SIG)

O sistema formado por hardware, software, informação espacial, procedimentos computacionais que possibilita armazenar, processar, analisar e representar informações espaciais recebem o nome de SIG (Najla et al., 2020).

Os dados em um SIG podem ser vetoriais ou matriciais (*raster*), de acordo com a forma como são armazenados (Balieiro & Veloso, 2022). Os dados vetoriais possuem coordenadas geográficas, podendo ser expressos por meio de pontos, linhas ou polígonos. Os pontos podem ser representados por um par de coordenadas geográficas, para associar linhas e polígonos é preciso utilizar um conjunto de pares de coordenadas (Dias & Viera, 2023).

Os dados raster são dispostos em uma estrutura matricial, chamada de grade. Esta grade é formada por uma matriz de linhas e colunas, com valores associados a cada célula, também chamada de pixel.

Atualmente, estão disponíveis diversos SIGs, entretanto dois se destacam fortemente: ArcGIS e QGIS.

O ArcGIS é um SIG proprietário desenvolvido pela ESRI, e possui uma vasta

coleção de ferramentas (toolbox) que viabilizam a análise e visualização de dados espaciais. Mesmo sendo um software proprietário, permite o compartilhamento de dados com outros SIGs e plataformas livres, o que o torna muito versátil (IMG Brasil, 2024).

Já o Quantum GIS (QGIS) é um software SIG livre e de código-fonte aberto, desenvolvido em Python. Outro ponto positivo ao seu favor refere-se à disponibilidade de sua interface em vários idiomas, o tornando mais acessível. Tem uma grande comunidade de apoio e desenvolvimento que contribuem para o aprimoramento do mesmo e elaboração de ferramentas (plugins) e funções que otimizam o trabalho (Hazra et al., 2024).

Na execução deste trabalho foi usado o ArcGIS (licenciado para estudante) na versão 10.8 e o QGIS 3.26.3 (Buenos Aires), de forma a extrair a melhor funcionalidade de cada um. Foi destacado ao longo do texto qual o SIG usado na execução de cada etapa de processamento.

Seleção e Aquisição das Imagens

Foram selecionadas cinco imagens de satélite Landsat-5 e Landsat-9, órbita-ponto 226/071, para os meses que possuem temperaturas elevadas e baixa nebulosidade, correspondente aos dias 16/05/1985, 14/07/1992, 05/07/2003, 11/07/2011 e 01/07/2022, obtidas gratuitamente do Serviço Geológico dos Estados Unidos (USGS - US Geological Survey), no site <https://earthexplorer.usgs.gov/>.

Cada imagem retrata as características da superfície terrestre no horário em que foram

coletadas, de forma que, de agora em diante, serão mencionadas apenas pelo ano em que foram coletadas. Desta forma, a imagem de 16/05/1985 será enunciada por 1985 e assim sucessivamente.

Junto com a imagem é fornecido um arquivo de metadados que contém o horário em que o centro da imagem foi capturado, com o fuso

horário GMT (Tempo Médio de Greenwich).

Na Tabela 1 é apresentado o horário de coleta de cada imagem no fuso horário GMT e corrigido para o horário local de Cuiabá.

Uma amostra das imagens brutas, sem processamento, é apresentada na Figura 5.

Tabela 1. Horário de coleta das imagens.

Satélite	Órbita / Ponto	Resolução	Data de Coleta	Horário de Coleta da Imagem	
				GMT	Cuiabá (GMT-4)
Landsat 5	226/071	30m	1985 (16/05/1985)	13:15:44	09:15:44
Landsat 5	226/071	30m	1992 (14/07/1992)	12:53:34	08:53:34
Landsat 5	226/071	30m	2003 (05/07/2003)	13:21:52	09:21:52
Landsat 5	226/071	30m	2011 (11/07/2011)	13:34:47	09:34:47
Landsat 9	226/071	30m e 15m (Pancromática)	2022 (11/07/2022)	13:45:29	09:45:29

Fonte: USGS. Adaptado pelos Autores.




Figura 5. Amostra das imagens selecionadas.

O formato das imagens obtidas foi o *GeoTiff*, que é um sistema de metadados com as informações das coordenadas geográficas embutidas em um arquivo de imagem *Tiff*. O critério fundamental para a escolha das imagens foi o índice de cobertura de nuvens inferior a 10%, e a não incidência de nuvens sobre a área de estudo. Os dados adquiridos já estavam corrigidos para os

efeitos atmosféricos, não sendo necessário realizar nenhum procedimento neste sentido.

Classificação do Uso do Solo

O processamento das imagens para a definição do uso do solo foi realizado segundo as etapas apresentadas na Figura 6.




Figura 6. Etapas para obtenção da estimativa de expansão urbana.

Pré-Processamento

Esta é a etapa inicial, onde foi verificada o sistema de coordenadas e a qualidade das imagens de satélite obtidas. As imagens de satélite estavam no Sistema Geodésico Mundial 84 (WGS84 - *World Geodetic System*) e foram reprojetadas através de ferramenta de georreferenciamento do ArcGis para o Sistema de Projeção Universal Transversa de Mercador (UTM), correspondente a Zona 21 Sul, vinculadas ao Sistema de Referência (SIRGAS 2000).

Embora se tenha selecionado imagens de satélite com menos de 10% de nebulosidade, foi utilizado o QGIS, onde através do plugin *Cloud Masking* é possível analisar o conjunto de bandas da imagem de satélite obtida, através do algoritmo *F-mask*, identificar e mascarar a presença de nuvens e sombras de nuvens. A Figura 7 apresenta o resultado de processamento das imagens de satélite por meio do mascaramento de nuvens e sombras de nuvens.




Figura 7. Resultado do Cloud Masking.

Nota-se a presença de nuvens nas imagens de 1985, 2011 e 2022, mas em regiões fora da área de estudo. Devido à ausência de cobertura de nuvens sobre a região em análise, foi possível utilizar integralmente todas as imagens de satélite adquiridas.

Composição RGB

A composição RGB (*Red, Green, Blue*) é uma técnica de processamento de imagem que combina três imagens em tons de cinza, cada uma correspondente a um dos canais de cor vermelho, verde e azul. A combinação desses três canais em uma única imagem colorida permite visualizar as informações de cor da cena capturada pelo satélite.

A composição em questão foi efetuada utilizando o software ArcGIS, especificamente por meio da funcionalidade denominada "Bandas Compostas". Tal procedimento permitiu a criação de um arquivo de imagem no formato RGB, mediante a atribuição da banda 7 ao canal vermelho, da banda 5 ao canal verde e da banda 3 ao canal azul.

Esta metodologia resultou na formação da

composição RGB 753 para as imagens provenientes do satélite Landsat 5, bem como sua correspondente aplicada às imagens obtidas pelo Landsat 9. A Figura 8 ilustra este processo para a imagem de 2011.




Figura 8. Exemplo de composição RGB 753

utilizando a imagem de 2011.

Após a composição das imagens é necessário fazer o ajuste do contraste para "porcentagem de recorte" a fim de evidenciar os diferentes tipos de cobertura do solo, como apresentado na Figura 9.




Figura 9. Composição RGB para as imagens de satélite.

Coleta de Amostras de Treinamento

Esta é uma etapa importante no processo de treinamento de algoritmos de aprendizado de máquina que visa classificar imagens automaticamente. A coleta de amostras de treinamento foi realizada por meio da caixa de ferramentas "classificação de imagens" no ArcGis, sendo realizada para cada imagem composta.

Foram coletadas amostras de pixels da imagem para a identificação das classes de uso do solo, sendo definidas cinco classes principais: Área Construída, Solo Exposto, Corpo d'água, Vegetação Densa e Vegetação Rasteira.

Para se obter um resultado melhor de classificação, buscou-se amostras de treinamento dentro da área de estudo, que ao serem avaliadas

através do gráfico de dispersão, se apresentem bem delimitadas, com pouca sobreposição e com contagem superior a 1000 pixels para cada classe.

Classificação das Imagens

Foi realizada a classificação supervisionada, através das amostras definidas pelo analista com base nas classes selecionadas por meio de análise

visual. Foi empregado o classificador de Probabilidade Máxima, que executa a classificação com a utilização do arquivo de assinatura, através de um algoritmo estatístico, que realiza a classificação pixel a pixel, culminando na ponderação das distancias médias dos níveis digitais de cada classe anteriormente amostrada, segundo a Figura 10.




Figura 10. Princípio de funcionamento do Método da Probabilidade Máxima.

Pós-Processamento

O refinamento da classificação ocorre nesta etapa. Através da ferramenta “Filtro Predominante” (*Majoritary*), para remoção de pixels isolados, ou ruídos da classificação, conforme a Figura 11.




Figura 11. Funcionamento do Filtro predominante. Fonte: Adaptado de (ArcGis Pro, 2022).

Posteriormente a imagem resultante é processada através da ferramenta Suavização dos Limites (*Smooth*), para suavizar as bordas irregulares dos limites de classe. A Figura 12 mostra um exemplo de aplicação da ferramenta.




Figura 12. Exemplo de aplicação da Suavização dos Limites. Fonte: Adaptado de (ArcGIS Desktop, 2022)

Para poder mensurar a área ocupada por cada classe, as imagens foram recortadas para o limite do município de Várzea Grande, e a imagem resultante foi convertida de um arquivo de imagem

do tipo *raster* para um arquivo vetorial de polígonos, chamado de *shapefile*. Durante o processo de conversão utilizou-se a ferramenta “Raster para polígono” e foi habilitada a caixa de seleção “simplificar polígono” e “criar feições de múltiplas partes”.

Acurácia da Classificação

A acurácia da classificação foi verificada através do software QGIS, por meio do complemento AcATaMa, onde foi gerado uma

amostragem aleatória estratificada empregando proporção baseada em área (Olofsson et al., 2013).

O tamanho geral da amostra e o número de pontos para cada estrato são calculados de acordo com a proporção da área de cada classe no mapa, o erro padrão da precisão geral estimado que alcançará e o desvio padrão de cada estrato. A Figura 13 traz a configuração realizada no plugin AcATaMa para a geração de amostras para a verificação do nível de precisão da classificação realizada em cada imagem.




Figura 13. Configuração do plugin AcATaMa para geração de amostras de determinação de precisão.

Após a definição do tamanho da amostra por classe, na caixa de diálogo de classificação, é realizada a configuração das classes utilizadas, e o software permite utilizar duas telas simultâneas, onde na primeira mostra o ponto segundo a classificação realizada e na segunda tela exibe a imagem de satélite composta empregada para a

classificação da imagem. Desta forma, o operador pode escolher visualmente em qual classe o ponto realmente se encontra. A

Figura 14 ilustra as configurações efetuadas na caixa de diálogo para análise da qualidade da classificação.




Figura 14. Caixa de diálogo de classificação.

Depois da classificação visual de todas as amostras geradas, o complemento exibe a matriz de confusão que possibilita a visualização do desempenho do algoritmo de classificação para cada imagem.

Resultados e Discussão

Após a realização da classificação do uso do solo por meio das imagens de satélite foi criado um mapa temático das imagens das classes de uso do solo, apresentados na Figura 15.




Figura 15. Classificação de Uso do Solo da Cidade de Várzea Grande.

Através do mapa temático é possível afirmar a ocorrência da expansão de área construída ocorrida no período de 1985 para 1992. Um dos motivos dessa notável expansão foi a pavimentação das principais ruas e avenidas de Várzea Grande, que em 1985 eram de terra batida, com poucas ruas calçadas. Isso fez com que as áreas que outrora eram de Solo Exposto passaram a agregar a classe Área Construída.

Para se ter uma maior precisão das mudanças ocorridas dentre as cinco classes utilizadas na classificação de uso do solo, a área correspondente a cada classe e o seu percentual foi contabilizado e tabelado, expresso na Tabela 2 e onde Variação (%) corresponde à diferença do percentual da área ocupada por cada classe do período final e inicial, respectivamente.

Os dados apresentados se referem à variação das áreas ocupadas pelas cinco classes de uso do solo em quatro momentos diferentes (1985, 1992, 2003, 2011 e 2022) e a variação percentual entre cada período.

Observa-se um aumento significativo da Área Construída entre 1985 e 1992, com uma variação de 151%. Após esse período, permaneceu relativamente estável com pequenas variações, mantendo-se em torno de 10,67% do total em 2022, evidenciando a expansão urbana na região.

Já a classe de Solo Exposto teve uma diminuição de 46% entre 1985 e 1992, seguida por um aumento de 100% até 2003 e um crescimento de 13% até 2011. No entanto, entre 2011 e 2022, houve uma redução significativa de 65%, resultando em uma diminuição geral de 57% em relação a 1985.

Entretanto, a classe Corpo D'água apresentou uma redução de 45% entre 1985 e 1992, depois um aumento de 69% até 2003, e variações negativas subsequentes de 2% e 8% nos períodos seguintes, resultando em uma diminuição total de 17% ao longo do período analisado.

A vegetação Densa teve uma variação negativa mínima de 1% entre 1985 e 1992, seguida por um aumento de 4% até 2003 e um crescimento mais expressivo de 27% até 2011. Entre 2011 e 2022, houve um aumento de 5%, totalizando um crescimento de 37%.

Tabela 2. Área e percentual de alterações nas classes de Uso do Solo para Várzea Grande.

Classes	1985		1992		2003		2011		2022	
	km ²	%	km ²	%	km ²	%	km ²	%	km ²	%
1	29,56	4,08	74,34	10,27	76,98	10,64	77,25	10,67	77,24	10,67
2	60,09	8,30	32,44	4,48	64,83	8,96	73,33	10,13	25,80	3,57
3	11,55	1,60	6,30	0,87	10,63	1,47	10,44	1,44	9,64	1,33
4	66,83	9,23	66,01	9,12	68,80	9,51	87,05	12,03	91,83	12,69
5	555,76	76,78	544,68	75,25	502,55	69,43	475,70	65,72	519,25	71,74
Variação (%)	1985-1992		1992-2003		2003-2011		2011-2022		1985-2022	
1	151%		4%		0%		0%		161%	
2	-46%		100%		13%		-65%		-57%	
3	-45%		69%		-2%		-8%		-17%	
4	-1%		4%		27%		5%		37%	
5	-2%		-8%		-5%		9%		-7%	

■ 1 – Área Construída ■ 2 – Solo Exposto ■ 3 – Corpo D'água
■ 4 – Vegetação Densa ■ 5 – Vegetação Rasteira

A Vegetação Rasteira é a mais presente em todos os anos, representando mais de 70% da área total em todos os anos. No entanto, essa classe apresentou uma diminuição de 7% da área total entre 2011 e 2022.

Em resumo, pode-se observar que houve um

aumento significativo na Área Construída e na Vegetação Densa, enquanto houve uma diminuição nas demais classes ao longo do período estudado.

Ajustando o foco para o perímetro urbano de Várzea Grande, foi gerado o mapa temático de uso do solo desta localidade, conforme a




Figura 16 – Classificação de Uso do Perímetro Urbano de Várzea Grande.

Quando a região do perímetro urbano fica em evidência é possível notar a Área Construída, cercada de Solo Exposto e Vegetação Rasteira em 1985, se propagar sobre as áreas que a cercam nos

anos subsequentes, se intensificando na área central, em torno da área do Aeroporto.

Tabela 3. Área e percentual de alterações nas diferentes classes de Uso do Solo para o perímetro urbano de Várzea Grande.

Classes	1985		1992		2003		2011		2022	
	km ²	%	km ²	%	km ²	%	km ²	%	km ²	%
 1	20,53	12,61	48,25	29,62	59,14	36,31	64,25	39,45	68,78	42,22
 2	19,52	11,99	17,38	10,67	12,02	7,38	12,38	7,60	10,95	6,72
 3	3,37	2,07	2,44	1,50	2,79	1,71	2,67	1,64	2,25	1,38
 4	14,27	8,76	10,12	6,21	13,19	8,10	16,12	9,90	17,69	10,86
 5	105,19	64,58	84,69	51,99	75,75	46,51	67,46	41,42	63,22	38,81
Variação (%)	1985-1992		1992-2003		2003-2011		2011-2022		1985-2022	
 1	135%		23%		9%		7%		235%	
 2	-11%		-31%		3%		-12%		-44%	
 3	-27%		14%		-4%		-16%		-33%	
 4	-29%		30%		22%		10%		24%	
 5	-19%		-11%		-11%		-6%		-40%	

 1 – Área Construída  2 – Solo Exposto  3 – Corpo D'água

 4 – Vegetação Densa  5 – Vegetação Rasteira

Analisando o recorte feito para o perímetro urbano de Várzea Grande, A Área Construída cresceu ao solo ao longo dos anos. Em 1985, ocupava apenas 29,56 km², mas em 2022, já dominava 77,24 km² da paisagem, um crescimento de 161%! Essa expansão urbana, impulsionada pelo desenvolvimento e pelo aumento da população.

Em contraste com a expansão urbana, o Solo Exposto encolheu consideravelmente. Em 1985, ocupava 60,09 km², mas em 2022, sua área se reduziu a apenas 25,80 km², uma queda de 57%. Essa mudança pode ser atribuída à recuperação da vegetação ou à ocupação por outras classes de uso do solo, como a área construída.

Os Corpos D'água, também sofreram com a transformação. Em 1985, ocupavam 11,55 km², mas em 2022, sua área diminuiu para 9,64 km²,

uma perda de 17%. Como as imagens analisadas são referentes ao período de estiagem das chuvas na região, a diminuição desta classe pode ser devido à variação hídrica.

Em meio à crescente urbanização, a Vegetação Densa aumentou. Em 1985, ocupava 66,83 km², mas em 2022, sua área se expandiu para 91,83 km², um aumento de 37%.

Em contrapartida, a Vegetação Rasteira diminuiu gradativamente. Em 1985, ocupava 555,76 km², mas em 2022, sua área se reduziu para 519,25 km², uma perda de 7%. Essa mudança pode ser explicada pela conversão para outras classes de uso do solo.

Com relação à acurácia da classificação supervisionada, obteve-se a matriz de confusão para cada imagem classificada, apresentadas nas Tabelas 4.

Tabela 4. Matriz de Confusão da classificação das imagens.

1985	 1	 2	 3	 4	 5	Total	Acurácia do Usuário
 1 – Área Construída	11	1	2	0	0	14	0,7857
 2 – Solo Exposto	0	31	1	0	2	34	0,9118
 3 – Corpo D'água	0	0	5	0	0	5	1,0000
 4 – Vegetação Densa	0	0	1	36	0	37	0,9730
 5 – Vegetação Rasteira	0	0	2	12	291	305	0,9541
Total	11	32	11	48	293	395	
Acurácia do Classificador	1	0,9688	0,4546	0,7500	0,9932		0,94684
1992	 1	 2	 3	 4	 5	Total	Acurácia do Usuário
 1 – Área Construída	39	0	0	0	0	39	1
 2 – Solo Exposto	0	18	0	0	0	18	1
 3 – Corpo D'água	0	0	3	0	0	3	1
 4 – Vegetação Densa	0	0	0	37	0	37	1
 5 – Vegetação Rasteira	2	4	0	3	290	299	0,9699
Total	41	22	3	40	290	396	
Acurácia do Classificador	0,9512	0,8182	1	0,925	1		0,97727
2003	 1	 2	 3	 4	 5	Total	Acurácia do Usuário
 1 – Área Construída	39	1	1	0	0	41	0,95122
 2 – Solo Exposto	0	35	0	0	0	35	1
 3 – Corpo D'água	0	0	5	0	0	5	1
 4 – Vegetação Densa	0	0	1	36	0	37	0,97297
 5 – Vegetação Rasteira	0	3	0	1	274	278	0,98561
Total	39	39	7	37	274	396	
Acurácia do Classificador	1	0,8974	0,7143	0,9730	1		0,98232
2011	 1	 2	 3	 4	 5	Total	Acurácia do Usuário
 1 – Área Construída	35	1	1	0	0	37	0,94595
 2 – Solo Exposto	1	41	0	0	0	42	0,97619
 3 – Corpo D'água	0	0	5	0	0	5	1
 4 – Vegetação Densa	0	0	0	48	0	48	1
 5 – Vegetação Rasteira	0	1	0	2	262	265	0,98868
Total	36	43	6	50	262	397	
Acurácia do Classificador	0,9722	0,9535	0,8333	0,96	1		0,98489

Continua

Cont. Tabela 4.

2022	 1	 2	 3	 4	 5	Total	Acurácia do Usuário
 1 – Área Construída	38	0	1	0	0	39	0,97436
 2 – Solo Exposto	1	13	0	0	0	14	0,92857
 3 – Corpo D'água	0	0	5	0	0	5	1
 4 – Vegetação Densa	0	0	0	51	0	51	1
 5 – Vegetação Rasteira	0	0	0	6	281	287	0,97909
Total	39	13	6	57	281	396	
Acurácia do Classificador	0,9744	1	0,8333	0,8947	1		0,9798

A Tabela 5 exibe a classificação do nível de precisão de classificação, de acordo com o índice kappa.

Tabela 5. Qualidade da Classificação das imagens conforme índice kappa.

Valor de Kappa (k)	Desempenho
<0,00	Péssimo
$0,00 < k \leq 0,20$	Mau
$0,20 < k \leq 0,40$	Razoável
$0,40 < k \leq 0,60$	Bom
$0,60 < k \leq 0,80$	Muito Bom
$0,80 < k \leq 1,00$	Excelente

Fonte: Adaptado de (Congalton & Green, 2019).

Segundo os resultados obtidos, a classificação das imagens foi excelente, onde todas as imagens obtiveram índice kappa superior a 0,94.

Essa classificação de uso do solo é importante para poder se relacionar a TST com o tipo de uso do solo, verificando-se assim em qual deles ocorrem as maiores temperaturas superficiais.

Conclusão

A classificação supervisionada de imagens multiespectrais demonstrou ser uma ferramenta poderosa para a análise de cidades de grande porte, proporcionando a identificação precisa de diferentes classes de objetos e infraestrutura urbana. A incorporação de técnicas de aprendizado de máquina mostrou-se fundamental para melhorar a precisão e a eficiência desta metodologia, tornando-a ainda mais valiosa para a análise de dinâmicas urbanas e ambientais.

Neste estudo, a utilização de imagens de satélite Landsat 5 e Landsat 9 permitiu a realização da classificação supervisionada de uso do solo, onde, a partir de uma amostra de treinamento efetuada pelo usuário em cada imagem, foi possível classificar toda a imagem com excelente desempenho, atingindo um índice kappa de aproximadamente 0,95 para a imagem de 1985 e superior a 0,98 para todas as outras imagens.

Os resultados demonstram claramente a viabilidade e a eficácia da classificação supervisionada de imagens multiespectrais para a análise de grandes cidades e destacam a importância do uso de técnicas de aprendizado de máquina para otimizar a precisão e a eficiência da classificação. Com o aumento contínuo do sensoriamento remoto e a crescente urbanização global, esta técnica continuará a desempenhar um papel crucial no planejamento urbano e na gestão ambiental.

A análise revelou a expansão da malha urbana de Várzea Grande, evidenciada pela pavimentação das ruas principais e o adensamento

das edificações na região central. Esta expansão foi impulsionada pela migração populacional para o setor industrial, em expansão devido às políticas públicas de incentivo à instalação de indústrias na região. A alta demanda por moradia levou à criação de vários loteamentos e empreendimentos imobiliários, ocupando as áreas anteriormente vazias no centro comercial da cidade.

Além disso, é crucial que o poder público utilize esses e outros estudos como subsídios valiosos para o planejamento urbano. A aplicação dessas ferramentas e conhecimentos pode orientar políticas e decisões mais assertivas, que contribuirão significativamente para a melhoria da qualidade de vida e a preservação ambiental na região.

Referências

- Adegun, A., Viriri, S., & Tapamo, J.-R. (2023). Review of deep learning methods for remote sensing satellite images classification: Experimental survey and comparative analysis. *Journal of Big Data*, 10. <https://doi.org/10.1186/s40537-023-00772-x>
- Ahmed, K. R., Akter, S., Marandi, A., & Schüth, C. (2021). A simple and robust wetland classification approach by using optical indices, unsupervised and supervised machine learning algorithms. *Remote Sensing Applications Society and Environment*, 23. <https://doi.org/10.1016/j.rsase.2021.100569>
- Alghamdi, A., Alzhrani, A., & Alanazi, H. (2021). Local Climate Zones and Thermal Characteristics in Riyadh City, Saudi Arabia. *Remote Sensing*, 13, 4526. <https://doi.org/10.3390/rs13224526>
- Alito, K., & Kerebih, M. (2024). Spatio-temporal assessment of agricultural drought using remote sensing and ground-based data indices in the Northern Ethiopian Highland. *Journal of Hydrology: Regional Studies*, 52, 101700. <https://doi.org/10.1016/j.ejrh.2024.101700>
- Almeida, C., Furst, L., Gonçalves, A., & Teodoro, A. (2022). Remote Sensing Image-Based Analysis of the Urban Heat Island Effect in Bragança, Portugal. *Environments*, 9, 98. <https://doi.org/10.3390/environments9080098>
- Asming, M., Mohd Ibrahim, A., & Abir, I. M. (2022). Processing and classification of landsat and sentinel images for oil palm

- plantation detection. *Remote Sensing Applications: Society and Environment*, 26, 100747. <https://doi.org/10.1016/j.rsase.2022.100747>
- Balieiro, B. T. de S., & Veloso, G. A. (2022). Análise multitemporal da cobertura do solo da Terra Indígena Ituna-Itatá através da classificação supervisionada de imagens de satélites. *Revista Cerrados*, 20(02), Artigo 02. <https://doi.org/10.46551/rc2448269220227>
- Baohui, M., Zhao, X., Zhao, J., Naijing, L., Si, L., Wang, Q., Sun, N., Sun, M., Guo, Y., & Zhao, S. (2022). Quantitatively Assessing the Impact of Driving Factors on Vegetation Cover Change in China's 32 Major Cities. *Remote Sensing*, 14, 839. <https://doi.org/10.3390/rs14040839>
- Belloli, T., Guasselli, L., Kuplich, T., Ruiz, L., & Simioni, J. (2022). Classificação Baseada em Objeto de Tipologias de Cobertura Vegetal em Área Úmida Integrando Imagens Ópticas e SAR. *Revista Brasileira de Cartografia*, 74, 67–83. <https://doi.org/10.14393/rbcv74n1-61277>
- Chen, P., Huang, H., & Shi, W. (2022). Reference-free method for investigating classification uncertainty in large-scale land cover datasets. *International Journal of Applied Earth Observation and Geoinformation*, 107, 102673. <https://doi.org/10.1016/j.jag.2021.102673>
- Congalton, R., & Green, K. (2019). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Third Edition*. <https://doi.org/10.1201/9780429052729>
- Dias, G. D. O., & Viera, E. M. (2023). Análise multitemporal das áreas desmatadas e da regeneração florestal na Microbacia do Córrego dos Macacos (BH-MG), empregando técnicas de Sensoriamento Remoto. *Revista Brasileira de Geografia Física*, 16(1214–1230), 1214–1230. <http://dx.doi.org/10.26848/rbgf.v16.3.p1214-1230>
- Errea, C. L., Almeida, C. R. de, Gonçalves, A., & Teodoro, A. C. (2023). Remote Sensing Analysis of the Surface Urban Heat Island Effect in Vitoria-Gasteiz, 1985 to 2021. *Remote Sensing*, 15(12), Artigo 12. <https://doi.org/10.3390/rs15123110>
- Espejo, A., Federici, S., Green, C., Olofsson, P., Sanz-Sanchez, M.-J., Waterworth, R., aguilar-amuchastegui, N., d'Annunzio, R., Balzter, H., Brack, C., Brewer, C., Birigazzi, L., Cabrera, E., Carter, S., Chand, N., Donoghue, D., Eggleston, S., Kleinn, C., Kurz, W., & Wulder, M. (2020). *Methods and Guidance from the Global Forest Observations Initiative Integration of remote-sensing and ground-based observations for estimation of emissions and removals of greenhouse gases in forests—Global Forest Observations Initiative Edition 3.0*.
- Ferreira, B., Estevam, A., & Maia, D. (2022). Clima Urbano e Ilhas de Calor no Miolo Urbano na Cidade de Salvador (BA). *Revista Brasileira de Geografia Física*, 15, 2768–2780. <https://doi.org/10.26848/rbgf.v15.6.p2768-2780>
- Filho, L. A., & Aleixo, N. C. R. (2023). As Tendências climáticas e ilhas de calor urbanas no Brasil: Revisão da literatura. *REVISTA GEONORTE*, 14(43), Artigo 43. <https://doi.org/10.21170/geonorte.2023.V.14.N.43.01.16>
- Fitz, P. R. (2020). Classificação de imagens de satélite e índices espectrais de vegetação: Uma análise comparativa. *Geosul*, 35(76), Artigo 76. <https://doi.org/10.5007/2177-5230.2020v35n76p171>
- Gourfi, A., TAÏBI, A. N., Salhi, S., EL Hannani, M., & Boujrouf, S. (2022). The Surface Urban Heat Island and Key Mitigation Factors in Arid Climate Cities, Case of Marrakesh, Morocco. *Remote Sensing*, 14. <https://doi.org/10.3390/rs14163935>
- Gulyanov, S., Limprasert, W., Songmuang, P., & Kongkachandra, R. (2022). *Data Generation for Satellite Image Classification Using Self-Supervised Representation Learning*. <https://doi.org/10.48550/arXiv.2205.14418>
- Hanafiah, N. A. (2019). Urban Heat Island Phenomenon in Penang Island, Malaysia. *Journal of Advanced Applied Scientific Research*, 6. <https://doi.org/10.53555/nnas.v6i7.764>
- Hazra, S., Bora, K., & Singh, P. A. (2024). Mapping World: A Comparative Analysis of Functionality and Usability between QGIS and ArcGIS. *Recent Advances in Computer Science and Communications*, 17.

- <https://doi.org/10.2174/0126662558332529240919063643>
- Huang, H., Wang, J., Liu, C., Liang, L., Li, C., & Gong, P. (2020). The migration of training samples towards dynamic global land cover mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 161, 27–36. <https://doi.org/10.1016/j.isprsjprs.2020.01.010>
- IBGE. (2022a). *Censo Demográfico 2022*. Instituto Brasileiro de Geografia e Estatística. <https://www.ibge.gov.br/estatisticas/sociais/populacao/22827-censo-demografico-2022.html?edicao=35938&t=resultados>
- IBGE. (2022b). *Várzea Grande—Panorama*. Instituto Brasileiro de Geografia e Estatística. <https://cidades.ibge.gov.br/brasil/mt/varzea-grande/panorama>
- IMG Brasil. (2024). *O que é GIS: Visão Geral*. <https://www.img.com.br/pt-br/o-que-e-gis/visao-geral>
- Jardim, A. M. da R. F., Araújo Júnior, G. do N., Silva, M. V. da, Santos, A. dos, Silva, J. L. B. da, Pandorfi, H., Oliveira-Júnior, J. F. de, Teixeira, A. H. de C., Teodoro, P. E., de Lima, J. L. M. P., Silva Junior, C. A. da, Souza, L. S. B. de, Silva, E. A., & Silva, T. G. F. da. (2022). Using Remote Sensing to Quantify the Joint Effects of Climate and Land Use/Land Cover Changes on the Caatinga Biome of Northeast Brazilian. *Remote Sensing*, 14(8), Artigo 8. <https://doi.org/10.3390/rs14081911>
- Júnior, J., & Pacheco, A. (2023). Uso do classificador Support Vector Machines para o mapeamento da cobertura do solo usando imagens de Sensoriamento Remoto. *Revista Brasileira de Geografia Física*, 16, 1304. <https://doi.org/10.26848/rbgf.v16.3.p1304-1319>
- Kang, Y., & Im, J. (2024). Mitigating underestimation of fire emissions from the Advanced Himawari Imager: A machine learning and multi-satellite ensemble approach. *International Journal of Applied Earth Observation and Geoinformation*, 128, 103784. <https://doi.org/10.1016/j.jag.2024.103784>
- Kililla. (2022, abril 19). *Panorâmica de Várzea Grande MT*. https://commons.wikimedia.org/wiki/File:Imagem_A%C3%A9rea_de_V%C3%A1rzea_Grande_MT.png
- Kotaridis, I., & Lazaridou, M. (2021). SEGMENTATION ON SENTINEL-3 DATA FOR SURFACE HEAT ISLAND DETECTION. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2021, 67–73. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2021-67-2021>
- Li, X., Zhang, G., Zhu, S., & Xu, Y. (2022). Step-By-Step Downscaling of Land Surface Temperature Considering Urban Spatial Morphological Parameters. *Remote Sensing*, 14, 3038. <https://doi.org/10.3390/rs14133038>
- Lima, R. F. de, Aparecido, L. E. de O., Torsoni, G. B., & Rolim, G. de S. (2024). Climate Change Assessment in Brazil: Utilizing the Köppen-Geiger (1936) Climate Classification. *Revista Brasileira de Meteorologia*, 38, e38230001. <https://doi.org/10.1590/0102-77863810001>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., & Liu, Y. (2017). A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Malcoti, M. D., Zia, H., & Kabre, C. (2023). Heat Stress Vulnerability of Populations and Role of Urban Heat Island. *Current World Environment, Volume 18*(Issue 1), 297–310.
- Mendes, J., Armond, N., & Silva, L. (2022). Ilhas de calor urbanas de superfície, ondas de calor e de frio no município do Rio de Janeiro – RJ (2015—2019). *Revista Brasileira de Climatologia*, 30, 133–155. <https://doi.org/10.55761/abclima.v30i18.14908>
- Mushore, T. D., Odindi, J., & Mutanga, O. (2022). “Cool” Roofs as a Heat-Mitigation Measure in Urban Heat Islands: A Comparative Analysis Using Sentinel 2 and Landsat Data. *Remote Sensing*, 14, 4247. <https://doi.org/10.3390/rs14174247>
- Najla, T., Gardes, T., & Hidalgo, J. (2020). A GIS plugin to model the near surface air temperature from urban meteorological networks. *Urban Climate*, 34, 100692. <https://doi.org/10.1016/j.uclim.2020.100692>
- Nasiri, V., Hawryło, P., Janiec, P., & Socha, J. (2023). Comparing Object-Based and

- Pixel-Based Machine Learning Models for Tree-Cutting Detection with PlanetScope Satellite Images: Exploring Model Generalization. *International Journal of Applied Earth Observation and Geoinformation*, 125, 1–13. <https://doi.org/10.1016/j.jag.2023.103555>
- Niang, A., Hermas, E., Alhazmi Alharbi, O., & Mohammed Al-Shaery, A. (2020). Monitoring landscape changes and spatial urban expansion using multi-source remote sensing imagery in Al-Aziziyah Valley, Makkah, KSA. *Egyptian Journal of Remote Sensing and Space Science*, 23. <https://doi.org/10.1016/j.ejrs.2018.06.001>
- Olofsson, P., Foody, G., Herold, M., Stehman, S., Woodcock, C., & Wulder, M. (2013). Good Practices for Assessing Accuracy and Estimating Area of Land Change. *Remote Sensing of Environment*, 148. <https://doi.org/10.1016/j.rse.2014.02.015>
- Pande, S., & Banerjee, B. (2023). Self-supervision assisted multimodal remote sensing image classification with coupled self-looping convolution networks. *Neural Networks*, 164. <https://doi.org/10.1016/j.neunet.2023.04.019>
- Pfeiff, G., Mota, M., & Lima, A. (2020). Revisão Sistemática atual sobre Sensoriamento Remoto aplicado a detecção de Ilhas de Calor Urbanas. *Periódico Eletrônico Fórum Ambiental da Alta Paulista*, 16. <https://doi.org/10.17271/1980082716520202641>
- Rai, A., Mandal, N., Singh, K. K., & Izonin, I. (2023). Satellite Image Classification Using a Hybrid Manta Ray Foraging Optimization Neural Network. *Big Data Mining and Analytics*, 6, 44–54. <https://doi.org/10.26599/BDMA.2022.9020027>
- Santos, A. S. R. M., Mauro, T. L., Souza, L. A., Senigalia, R. L. C., Castro, D. A., & Santos, E. S. (2019). Métodos de Classificação Supervisionada Aplicados no Uso e Ocupação do Solo no Município de Presidente Médice – RO. *Biodiversidade*, 18(1), Artigo 1. <https://periodicoscientificos.ufmt.br/ojs/index.php/biodiversidade/article/view/8242>
- Santos, K., Guimarães, R., Silva, B., Pontes, A., & Morales, G. (2019). Uso de geotecnologias para identificação de ilhas de calor no município de Belém (PA). *Revista Ibero-Americana de Ciências Ambientais*, 9, 178–186. <https://doi.org/10.6008/CBPC2179-6858.2018.008.0016>
- Shah, P., & Patel, C. (2023). Integration of Remote Sensing and Big Data to Study Spatial Distribution of Urban Heat Island for Cities with Different Terrain. *International Journal of Engineering*, 36, 71–77. <https://doi.org/10.5829/IJE.2023.36.01A.09>
- Shakya, A. K., Ramola, A., Singh, S., & Vidyarthi, A. (2023). Optimum supervised classification algorithm identification by investigating PlanetScope and Skysat multispectral satellite data of Covid lockdown. *Geosystems and Geoenvironment*, 2(2), 100163. <https://doi.org/10.1016/j.geogeo.2022.100163>
- Shendy, R., & Nalepa, J. (2024). Few-shot satellite image classification for bringing deep learning on board OPS-SAT. *Expert Systems with Applications*, 251, 123984. <https://doi.org/10.1016/j.eswa.2024.123984>
- Silva, C. de O. F. (2020). Classificação supervisionada de área irrigada utilizando índices espectrais de imagens Landsat-8 com Google Earth Engine. *IRRIGA*, 25, 160–169. <https://doi.org/10.15809/irriga.2020v25n1p160-169>
- Sisodia, P., Tiwari, V., & Kumar, A. (2014). Analysis of Supervised Maximum Likelihood Classification for remote sensing image. *International Conference on Recent Advances and Innovations in Engineering, ICRAIE 2014*. <https://doi.org/10.1109/ICRAIE.2014.6909319>
- Souza, C. A. de, Guaraldo, E., & Filho, A. C. P. (2022). Remote sensing applied to classification of local climate zones. *Rev. Sítio Novo*, 6(Edição Especial), 127–138.
- Thakur, R., & Panse, P. (2022). ELSET: Design of an Ensemble Deep Learning Model for improving satellite image Classification Efficiency via Temporal Analysis. *Measurement: Sensors*, 24, 100437. <https://doi.org/10.1016/j.measen.2022.100437>
- Thanvisitthpon, N. (2023). Statistically Validated Urban Heat Island Risk Indicators for UHI Susceptibility Assessment. *International Journal of*

- Environmental Research and Public Health*, 20, 1172.
<https://doi.org/10.3390/ijerph20021172>
- Thirumaladevi, S., Swamy, K., & Sailaja, M. (2022). Remote sensing image scene classification by transfer learning to augment the accuracy. *Measurement: Sensors*, 25, 100645.
<https://doi.org/10.1016/j.measen.2022.100645>
- Várzea Grande. (2021). *Lei Complementar nº 4.695, de 2021: Institui o Plano Diretor do Município de Várzea Grande*.
<https://leismunicipais.com.br/a/mt/v/varzea-grande/lei-complementar/2021/470/4695/lei-complementar-n-4695-2021-institui-o-plano-diretor-do-municipio-de-varzea-grande-estado-de-mato-grosso-da-outras-providencias>
- Vieira, C. V., & Viana, P. A. (2021). Avaliação da Acurácia de Algoritmos de Classificação de Imagens Orbitais na Baía da Babitonga, Nordeste de Santa Catarina. *Revista Brasileira de Geografia Física*, 14, 3577.
<https://doi.org/10.26848/rbgf.v14.6.p3599-3613>
- Wang, Y., Albrecht, C., Ait Ali Braham, N., Mou, L., & Zhu, X. (2022). Self-Supervised Learning in Remote Sensing: A Review. *IEEE Geoscience and Remote Sensing Magazine*, PP, 2–36.
<https://doi.org/10.1109/MGRS.2022.3198244>
- Worsa-Kozak, M., & Arsen, A. (2023). *Groundwater Urban Heat Island in Wrocław, Poland*. 12, 658.
<https://doi.org/10.3390/land12030658>
- Zhang, D., & Zhao, Y. (2023). *Research on Urban Expansion Based on Remote Sensing and Analysis of its Driving Forces-Taking Qingdao as an Example* (p. 947).
<https://doi.org/10.1109/PEEEEC60561.2023.00184>
- Zhang, W., Yang, X., Yuan, Z., Chen, Z., & Xu, Y. (2024). A Framework for Fine-Grained Land-Cover Classification. *Remote Sensing*, 16, 390.
<https://doi.org/10.3390/rs16020390>
- Zhou, M., Lu, L., Guo, H., Cao, S., Zhang, S., & Li, Q. (2021). Urban Sprawl and Changes in Land-Use Efficiency in the Beijing–Tianjin–Hebei Region, China from 2000 to 2020: A Spatiotemporal Analysis Using Earth Observation Data. *Remote Sensing*, 13, 2850.
<https://doi.org/10.3390/rs13152850>
- Zhu, W., Sun, J., Yang, C., Liu, M., Xu, X., & Ji, C. (2021). How to Measure the Urban Park Cooling Island? A Perspective of Absolute and Relative Indicators Using Remote Sensing and Buffer Analysis. *Remote Sensing*, 13, 3154.
<https://doi.org/10.3390/rs13163154>