



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul
Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia - FAENG



JHONNATTAN SILVA OLIVEIRA

**DESEMPENHO DE DIFERENTES ABORDAGENS
CLASSIFICADORAS DO USO E COBERTURA DO SOLO
URBANO**

Campo Grande, MS.

2025

**UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS E ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS AMBIENTAIS**

JHONNATTAN SILVA OLIVEIRA

**DESEMPENHO DE DIFERENTES ABORDAGENS
CLASSIFICADORAS DO USO E COBERTURA DO SOLO
URBANO**

Dissertação submetida ao Programa de Pós-graduação em Tecnologias Ambientais da Universidade Federal do Mato Grosso do Sul como requisito parcial a obtenção do título de Mestre em Tecnologias Ambientais, linha de pesquisa Diagnóstico e avaliação de impactos ambientais.

**Orientador: Prof. Dr. Antonio Conceição Paranhos Filho
Coorientador: Prof. Dr. Roberto Macedo Gamarra**

Aprovado em:
Banca Examinadora:

Prof. Dr. Antonio Conceição Paranhos Filho
Orientador PPGTA - UFMS

Prof. Dr. Roberto Macedo Gamarra
Coorientador PPGRN - UFMS

Prof. Dr. Alisson André Ribeiro
Universidade Federal de Mato Grosso do Sul

Prof. Dr. César Claudio Cáceres Encina
Universidade Federal de Mato Grosso do Sul

Prof. Dr. Fábio Veríssimo Gonçalves
Universidade Federal de Mato Grosso do Sul

Prof. Dr. Ariel Ortiz Gomes
Universidade Federal de Mato Grosso do Sul

**Campo Grande, MS.
2025**

DEDICATÓRIA

À minha mãe, Valéria, pelo amor incondicional e pelo exemplo de força e dedicação que sempre demonstrou.

À minha irmã e ao meu irmão, Jhennyfer e Matheus, por serem pilares de apoio e companheirismo em todas as fases da minha vida.

À minha esposa, Nathalia, cuja paciência, compreensão e encorajamento constante foram fundamentais para a conclusão desta jornada.

Sem o apoio de vocês, este sonho não teria se tornado realidade.

AGRADECIMENTOS

Ao meu orientador, Dr. Antonio Conceição Paranhos Filho, cuja orientação e conversas foram inestimáveis para o meu crescimento acadêmico e pessoal. Sua confiança no meu trabalho e sua disponibilidade constante foram um grande estímulo para mim.

Ao meu coorientador, Dr. Roberto Macedo Gamarra, agradeço pelos conhecimentos compartilhados, que enriqueceram de forma significativa minha pesquisa e formação.

Ao Laboratório de Geoprocessamento para Aplicações Ambientais (LABGIS), FAENG – UFMS, sou grato pelo acesso a recursos e pelo ambiente colaborativo que possibilitaram o avanço do meu trabalho.

Agradeço ao Programa de Pós-Graduação em Tecnologias Ambientais (PPGTA) da Faculdade de Engenharias, Arquitetura e Urbanismo (FAENG) da Fundação Universidade Federal de Mato Grosso do Sul (UFMS). Este trabalho foi realizado com o apoio da Fundação Universidade Federal de Mato Grosso do Sul - UFMS/MEC - Brasil.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pelo financiamento, Código de Financiamento 001, e pelo acesso ao Portal de Periódicos, que foi essencial para a realização deste trabalho.

Agradeço também à Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul (FUNDECT) pelo apoio ao projeto Cidades Inteligentes e Sustentáveis.

Finalmente, agradeço a todos os colegas e amigos que contribuíram direta ou indiretamente para a realização deste trabalho.

SUMÁRIO

LISTA DE FIGURAS	iv
LISTA DE TABELAS	v
LISTA DE SIGLAS	vi
RESUMO GERAL	vii
INTRODUÇÃO GERAL	1
 PRIMEIRO CAPÍTULO: PERSPECTIVAS BIBLIOMÉTRICAS SOBRE O SENSORIAMENTO REMOTO NA CLASSIFICAÇÃO DO SOLO URBANO	 3
1.1. Introdução	4
1.2. Material e Métodos	5
1.3. Resultados e Discussão	9
1.4. Conclusão	26
1.5. Referências	27
 SEGUNDO CAPÍTULO: AVALIAÇÃO DE ABORDAGENS CLASSIFICADORAS POR PIXEL E GEOBIA EM DIFERENTES RESOLUÇÕES ESPACIAIS	 30
2.1. Introdução	32
2.2. Material e Métodos	34
2.3. Resultados	42
2.4. Discussão	52
2.5. Conclusão	58
2.6. Referências	59
 CONSIDERAÇÕES FINAIS	 63
REFERÊNCIAS	65
ANEXO I	66
ANEXO II	68

LISTA DE FIGURAS

Figura 1.1. Fluxo sistemático da análise bibliométrica	8
Figura 1.2. Desempenho das publicações selecionadas	10
Figura 1.3. Distribuição geográfica das publicações científicas	11
Figura 1.4. Mapa de colaboração internacional em publicações científicas	12
Figura 1.5. Produção dos periódicos ao longo do tempo	16
Figura 1.6. Rede de acoplamento bibliográfico entre periódicos	17
Figura 1.7. Desempenho dos autores mais produtivos	19
Figura 1.8. Rede de coocorrência de palavras-chave	20
Figura 1.9. Frequência de palavras-chave ao longo do tempo	21
Figura 2.1. Mapa de localização de Campo Grande - MS.....	35
Figura 2.2. Fluxograma do estudo	36
Figura 2.3. Importância das bandas Landsat 8	43
Figura 2.4. Importância das bandas Sentinel-2.....	44
Figura 2.5. Importância das bandas WorldView 2	45
Figura 2.6. Comparação das abordagens de classificação.....	46
Figura 2.7. Matrizes de confusão para as abordagens classificadoras	47

LISTA DE TABELAS

Tabela 1.1. Distribuição geográfica das publicações científicas	11
Tabela 1.2. Produção científica de instituições globais	13
Tabela 1.3. Produtividade e impacto de periódicos.....	15
Tabela 1.4. Documentos publicados por autor	18
Tabela 2.1. Características das imagens de satélite utilizadas no estudo	36
Tabela 2.2. Bandas e características das imagens Landsat 8, Sentinel-2 e WorldView-2	37
Tabela 2.3. Descrição das amostras coletadas.....	39

LISTA DE SIGLAS

CAPES	Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
GEE	<i>Google Earth Engine</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
MEC	Ministério da Educação
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
OBIA	<i>Object-Based Image Analysis</i>
GEOBIA	<i>Geographic Object-Based Image Analysis</i>
WOS	<i>Web of Science</i>

RESUMO GERAL

OLIVEIRA, J. S. (2025). DESEMPENHO DE DIFERENTES ABORDAGENS CLASSIFICADORAS DO USO E COBERTURA DO SOLO URBANO. 2025. 69 p. Dissertação - Programa de Pós Graduação em Tecnologias Ambientais. Universidade Federal de Mato Grosso do Sul, Brasil.

Este trabalho apresenta uma análise comparativa do desempenho de diferentes abordagens classificadoras, especificamente métodos por pixel e GEOBIA, em ambientes urbanos de alta complexidade e variabilidade. A dissertação está estruturada em capítulos que irão se transformar em publicações, abordando desde uma perspectiva bibliométrica do uso do sensoriamento remoto na classificação do uso e cobertura do solo urbano até a avaliação prática dos métodos classificadores. No primeiro capítulo, a partir de uma análise bibliométrica e visualização de dados, mapeamos a produção científica na área de sensoriamento remoto aplicado à classificação do solo urbano, identificando padrões de publicação, principais autores, instituições e periódicos de destaque. O segundo capítulo focou na avaliação prática das técnicas de classificação em dados de alta e média resolução, utilizando imagens dos satélites Landsat 8, Sentinel-2 e WorldView-2, processadas na plataforma de computação em nuvem Google Earth Engine (Gorelick *et al.*, 2017). Foram aplicadas validações cruzadas e *holdout* para verificar a acurácia das classificações. Como resultado geral, esta pesquisa oferece um mapeamento da evolução do conhecimento científico na área, uma avaliação quantitativa das abordagens classificadoras e reforça a importância de técnicas combinadas para o planejamento urbano eficiente, contribuindo para o desenvolvimento de cidades inteligentes e sustentáveis.

Palavras-chave: Sensoriamento Remoto, Uso do solo, Cobertura do solo urbana, Classificação de imagens, Bibliometria

GENERAL ABSTRACT

OLIVEIRA, J. S. (2025). PERFORMANCE OF DIFFERENT APPROACHES FOR CLASSIFYING URBAN LAND USE AND LAND COVER. 2025. 69 p. Dissertation - Graduate Program in Environmental Technologies. Federal University of Mato Grosso do Sul, Brazil.

This study presents a comparative analysis of the performance of different classification approaches, specifically pixel-based and GEOBIA methods, in highly complex and variable urban environments. The dissertation is structured into chapters that will be turned into publications, covering both a bibliometric perspective on the use of remote sensing in urban land use and land cover classification and a practical evaluation of the classification methods. In the first chapter, through a bibliometric analysis and data visualization, we mapped the scientific production in the field of remote sensing applied to urban land classification, identifying publication patterns, leading authors, institutions, and prominent journals. The second chapter focused on the practical evaluation of classification techniques on high and medium-resolution data, using images from the Landsat 8, Sentinel-2, and WorldView-2 satellites, processed on the Google Earth Engine cloud computing platform. Cross-validation and holdout validation were applied to verify the accuracy of the classifications. Overall, this research provides a mapping of the evolution of scientific knowledge in the field, a quantitative evaluation of the classification approaches, and underscores the importance of combined techniques for efficient urban planning, contributing to the development of smart and sustainable cities.

Keywords: Remote Sensing, Land Use, Land Cover, Image Classification, Bibliometrics

INTRODUÇÃO GERAL

A classificação de imagens de satélite tem se tornado uma ferramenta indispensável para o monitoramento e análise do uso e cobertura do solo, especialmente em grandes centros urbanos (BLASCHKE *et al.*, 2014). Essa técnica é amplamente utilizada para mapear e monitorar mudanças na paisagem urbana, ajudando na tomada de decisões para o planejamento e a gestão urbana (LI *et al.*, 2014; GEORGANOS *et al.*, 2018; ZHANG *et al.*, 2020). A urbanização acelerada e a necessidade de monitoramento constante das áreas urbanas justificam a importância deste estudo (GORELICK *et al.*, 2017; GEORGANOS *et al.*, 2018).

A análise de imagens de satélite permite a detecção de mudanças no uso do solo, fornecendo informações para o planejamento e a gestão urbana (HU *et al.*, 2016; BASHEER *et al.*, 2022). Contudo, a complexidade dos ambientes urbanos, com sua grande heterogeneidade e variação espectral e espacial requer metodologias de classificação que possam lidar com essa diversidade e granularidade das informações (HUANG *et al.*, 2018; PHAN *et al.*, 2020).

Este estudo tem como objetivo avaliar se a abordagem de classificação e a resolução espacial de imagens multiespectrais influenciam a precisão e acurácia da identificação das classes de uso e cobertura do solo urbano. Este objetivo é apoiado por dois objetivos específicos, os quais serão desmembrados em dois capítulos distintos.

No primeiro capítulo, a partir de uma análise bibliométrica e visualização de dados, mapeamos a produção científica na área de sensoriamento remoto aplicado à classificação do solo urbano, identificando padrões de publicação, principais autores, instituições e periódicos de destaque. O segundo capítulo foca na avaliação prática das abordagens de classificação aplicadas a dados de alta e média resolução, utilizando

imagens dos satélites Landsat 8, Sentinel-2 e WorldView-2, processadas na plataforma de computação em nuvem Google Earth Engine (GORELICK *et al.*, 2017).

PERSPECTIVAS BIBLIOMÉTRICAS SOBRE O SENSORIAMENTO REMOTO NA CLASSIFICAÇÃO DO SOLO URBANO

RESUMO

Esta pesquisa aborda a evolução das metodologias e tecnologias na classificação do uso e cobertura do solo em áreas urbanas, utilizando sensoriamento remoto. A partir de uma análise bibliométrica sistemática, investigamos as tendências de publicação e inovação metodológica, foram identificados padrões de publicações, autores, instituições e periódicos notáveis no campo, utilizando métricas como índice-h e contagem de citações para avaliar a influência e impacto. Propomos direções para pesquisas futuras, enfatizando a importância do desenvolvimento de modelos e sistemas de monitoramento adaptativos para uma gestão urbana sustentável.

Palavras-chave: Sensoriamento Remoto, Uso do solo, Cobertura do solo, Classificação de imagens, Bibliometria

ABSTRACT

This research explores the evolution of methodologies and technologies in classifying land use and land cover in urban areas using remote sensing. Through a systematic bibliometric analysis, we investigated publication trends and methodological innovations, identifying patterns in publications, authors, institutions, and notable journals within the field. We utilized metrics such as the h-index and citation count to assess influence and impact. We propose directions for future research, emphasizing the importance of developing adaptive monitoring models and systems for sustainable urban management.

Keywords: Remote Sensing, Land Use, Land Cover, Image Classification, Bibliometrics

1.1. INTRODUÇÃO

A classificação do uso e cobertura do solo em áreas urbanas é fundamental para o planejamento urbano, gestão ambiental e desenvolvimento sustentável. A categorização precisa do uso e cobertura do solo em um contexto heterogêneo e complexo é um grande desafio, devido à presença de pixels mistos, características similares entre diferentes classes e alta variabilidade espectral (MOMENI *et al.*, 2016). Sendo sua investigação essencial, pois fundamenta a formulação de políticas e a tomada de decisões relacionadas à urbanização, conservação dos recursos naturais e elaboração de estratégias de gestão pública (GAUR *et al.*, 2023). A crescente demanda por terras urbanas, impulsionada por aumento populacional e uma expansão urbana acelerada, coloca em xeque a sustentabilidade do crescimento e a capacidade de resiliência dos ecossistemas urbanos (GU *et al.*, 2019).

O avanço contínuo das geotecnologias tem introduzido novos paradigmas metodológicos, que são constantemente desenvolvidos e implementados (GORELICK *et al.*, 2017; CARRANZA-GARCÍA *et al.*, 2019; HAN *et al.*, 2020; FAYAZ *et al.*, 2024). Esses avanços têm aprimorado substancialmente a acurácia e eficiência na classificação de áreas urbanas complexas. Tais tecnologias viabilizam a análise extensiva de grandes volumes de dados, proporcionando uma compreensão detalhada das dinâmicas urbanas e de suas inter-relações com o meio ambiente.

O acesso crescente a dados de sensoriamento remoto de alta resolução, combinado com avanços em algoritmos de aprendizado de máquina, tem revolucionado as práticas de mapeamento urbano. Contudo, apesar desses progressos tecnológicos, ainda persistem desafios relacionados à integração de diferentes tipos de dados e à necessidade de atualizações frequentes, que são exigências impostas pelo ritmo acelerado da urbanização (KURAS *et al.*, 2021; LING *et al.*, 2021).

Esta análise bibliométrica é empreendida com o objetivo de examinar as tendências de pesquisa e a evolução metodológica na área de classificação do uso e cobertura do solo em áreas urbanizadas, identificando as principais abordagens e inovações técnicas, bem como destacando as lacunas ainda persistentes na literatura. A análise aprofunda-se na distribuição geográfica e evolução temporal das publicações, compilando uma síntese das contribuições.

Este estudo pontua os avanços e desafios e propõe direções de pesquisas futuras. Tais direções são fundamentais para aprimorar as técnicas de classificação do uso e cobertura do solo, além de destacar a importância de desenvolver modelos preditivos mais robustos e sistemas de monitoramento dinâmicos, capazes de se adaptar rapidamente às transformações urbanas e ambientais, garantindo uma gestão urbana mais resiliente e adaptativa.

1.2. MATERIAL E MÉTODOS

Este estudo emprega uma abordagem sistemática para analisar a literatura relacionada ao emprego do sensoriamento remoto na classificação da cobertura do solo em ambientes urbanos heterogêneos. Utilizando as bases de dados *Web of Science – WOS* (CLARIVATE, 2023) e *Scopus* (ELSEVIER BV, 2023), a pesquisa foi estruturada para explorar os desenvolvimentos recentes e as principais contribuições na área de estudo. Através de uma análise bibliométrica sistemática, identificamos os principais pesquisadores, as colaborações institucionais e as correntes temáticas predominantes, permitindo uma compreensão das dinâmicas e avanços na aplicação do sensoriamento remoto para análise de dados urbanos.

A coleta dos dados bibliométricos foi realizada em dezembro de 2023, utilizando o acesso proporcionado pelo Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES/MEC (2023). Esta iniciativa é uma colaboração entre a Universidade Federal de Mato Grosso do Sul e a CAPES, viabilizando o acesso às bases de dados necessárias para este estudo.

Optamos por não estabelecer limitações temporais na estratégia de busca, para capturar uma visão evolutiva do campo. A análise incluiu a totalidade dos documentos disponíveis até a data especificada, com ênfase em estudos publicados como revisões e artigos científicos escritos em inglês. Esta seleção assegura alto padrão de qualidade e o rigor científico.

Estratégia de busca nas bases de dados:

("remote sensing" OR "satellite") AND ("image classif*" OR "classif*" OR "feature extract*") AND ("urban*" OR "urban land cover" OR "urban land use" OR "lulc"))*

Para a análise dos dados coletados, adotamos uma abordagem integrada de técnicas de visualização de dados e metodologias de revisão bibliográfica. Utilizamos o *software* VOSviewer (VAN ECK *et al.*, 2010) e a ferramenta bibliometrix (ARIA *et al.*, 2017) para criar representações visuais das redes bibliométricas, facilitando a identificação de tendências, clusters e dados atípicos na literatura. Além disso, o EndNote 20 (REUTERS, 2020) foi utilizado no gerenciamento de referências e o MS-Excel (Microsoft 365, 2023) para análises preliminares dos dados.

Como método sistemático utilizamos o *ProKnow-C* (ENSSLIN *et al.*, 2010), assegurando dessa forma que a literatura selecionada seja de alta relevância e

qualidade. Após a busca inicial nas bases de dados *WOS* e *Scopus*, que resultou em um total de 6.442 e 7.135 artigos respectivamente.

Para assegurar a seleção daqueles de alta relevância e qualidade o método *ProKnow-C* orientou a filtragem dos artigos. Inicialmente, para assegurar a exclusividade dos dados analisados, removemos todos os artigos duplicados de nossa base inicial evitando assim redundâncias e garantindo a precisão nas etapas subsequentes de análise.

Posteriormente, a relevância dos estudos foi avaliada começando pela aderência dos títulos ao tema pesquisado. Essa análise preliminar resultou na seleção de 430 trabalhos cujos títulos refletiam diretamente o foco da pesquisa. A seguir, foi empregado o princípio de Pareto para identificar os artigos mais influentes, baseando-nos no volume de citações. Definimos um critério de corte que correspondia aos 80% das citações acumuladas, o que nos permitiu condensar a lista para 87 publicações de destaque no campo de estudo.

Reconhecendo a importância de incorporar os desenvolvimentos mais recentes, a revisão foi expandida para incluir 78 artigos publicados nos anos de 2022 e 2023. Essa inclusão assegurou que nossa análise refletisse as tendências e avanços atuais.

Além disso, realizamos uma seleção adicional focada nos autores que frequentemente apareciam nos estudos identificados pelo princípio de Pareto. Este passo adicional nos permitiu resgatar 79 publicações adicionais que, embora inicialmente não atendessem ao critério de citações, foram publicadas por autores de alto impacto no tema estudado. Por fim, analisamos os resumos dos 244 artigos selecionados, garantindo que cada um contribuísse significativamente para o tema de interesse.




Figura 1.1 - Fluxo sistemático da análise bibliométrica.

1.3. RESULTADOS E DISCUSSÃO

A partir da busca inicial foram identificados 13.577 artigos, o que reflete o grande interesse no tema pesquisado. Usando uma metodologia de análise sistemática, reduzimos este número para 244 artigos, que perfazem aproximadamente 1,8 % do montante inicial.

Evolução temporal das publicações

Inicialmente, observamos que o número de artigos publicados por ano aumentou de maneira significativa, especialmente a partir de 2012, quando comparado às décadas anteriores (Figura 1.2). Essa crescente produção acadêmica é acompanhada por um aumento no total de citações por ano, atingindo um pico em 2010 com uma média de citações por artigo extremamente alta, sugerindo que trabalhos influentes foram publicados neste ano.

No entanto, a partir de 2017, apesar do número crescente de artigos publicados, foi observada uma redução tanto no total de citações anuais quanto na média de citações por artigo. Esse fenômeno pode ser atribuído a uma possível saturação do campo com publicações de menor impacto, tornando desafiador para artigos individuais se destacarem e acumularem citações rapidamente. A abrupta queda na média de citações por artigo a partir de 2022 sugere uma tendência de declínio na influência recente dos trabalhos, o que pode impactar a direção futura das pesquisas e a necessidade de inovação e relevância.




Figura 1.2 - Desempenho das publicações selecionadas. Desempenho anual das publicações selecionadas entre 1986 e 2024. O gráfico de barras azul representa o número de artigos publicados por ano, enquanto as linhas preta e amarela indicam, respectivamente, o total de citações e a média de citações por artigo por ano.

Panorama global das publicações

A tabela 1.1 e a figura 1.3 apresentam o panorama global das publicações científicas em termos de documentos, citações totais, média de citações por documento e índice H. Os EUA lideram em termos de citações totais e média de citações por documento, refletindo alto reconhecimento na área de pesquisa. Embora a China tenha o maior número de documentos, sua média de citações por documento é menor que a dos EUA, indicando uma possível diferença na qualidade e impacto dessas publicações ou, eventualmente, uma dinâmica geopolítica de marginalização de pesquisas dessa região.

Tabela 1.1 - Distribuição geográfica das publicações científicas dos 15 países que mais contribuíram em termos de número de documentos, total de citações e média de citações por documento. O índice H correspondente é também apresentado, oferecendo uma perspectiva sobre a qualidade e impacto das pesquisas provenientes de cada país.

Países	Documentos	Citações totais	Média citações	Índice H
China	94	6594	70,15	37
EUA	57	9633	169,00	38
Índia	22	217	9,86	6
Alemanha	14	2712	193,71	11
Canadá	13	1319	101,46	12
Islândia	11	4159	378,09	11
Japão	11	685	62,27	10
Reino Unido	11	1906	173,27	10
Bélgica	10	1006	100,60	8
Itália	10	1555	155,50	8
França	9	2179	242,11	8
Hong Kong	7	803	114,71	6
Brasil	6	198	33,00	4
Irã	6	252	42,00	6
Espanha	6	593	98,83	6




Figura 1.3 – A figura ilustra a produção científica global por país, destacando variações na contribuição à pesquisa mundial. Os países são representados em diferentes tons de azul, onde tons mais escuros indicam uma maior produção científica.

A rede de coautoria gerada pelo VOSviewer (Van Eck et al., 2007) detalhou o infográfico de colaboração internacional, capturando a dinâmica entre diferentes países ao longo do tempo. Sendo composta por nós e linhas de diferentes

tamanhos, densidades e cores, representando a quantidade de documentos publicados e sua cronologia.

A análise das conexões de coautoria mostra o papel de alguns países na produção científica global e reflete como as políticas nacionais e as colaborações internacionais moldam o panorama da pesquisa (Figura 1.4). A Islândia, apesar de ter um número limitado de publicações, destaca-se como um hub europeu devido à alta relevância de seus trabalhos, que são amplamente citados. Este país serve como um exemplo de como foco em qualidade e especialização em nichos específicos pode projetar uma presença significativa no cenário global.




Figura 1.4 - Mapa de coautoria ilustrando a colaboração internacional em publicações científicas entre 1986 e 2024, destacando a China e Estados Unidos como hubs centrais. As linhas representam as conexões de coautoria, com cores variando de tons frios a quentes para indicar a progressão temporal das colaborações.

Os EUA demonstram grande produtividade e relevância, sendo caracterizado como um hub mundial de cooperação científica. O elevado número de conexões indica não apenas uma contínua troca de conhecimento com países

tradicionalmente fortes em pesquisa, como Alemanha, China e Reino Unido, mas também com países emergentes, como Índia e Brasil.

A China, representada com um grande volume de conexões, sugere um papel crescente e influente na comunidade científica global. Isso pode ser atribuído a políticas governamentais focadas em pesquisa e desenvolvimento, buscando colocar o país na vanguarda da ciência global. Além disso, o padrão de conexões sugere uma estratégia de fortalecimento de laços com uma variedade de países, potencialmente buscando diversificar suas colaborações.

Com um fluxo de publicação mais atual a Índia uma tendência crescente de publicações, apontando uma rápida expansão no desenvolvimento de pesquisas. No entanto, a média baixa de citações por documento sugere que, apesar do aumento da produção, o impacto dessas publicações ainda é limitado, indicando uma área de oportunidade para aumentar a qualidade e a influência global das pesquisas produzidas no país.

Tabela 1.2 – Análise detalhada da produção científica de instituições globais, organizada por número de documentos publicados, total de citações totais e média de citações por documento.

Organização	País	Documentos	Citações	Média citações
Chinese Academy of Sciences	China	23	1442	62,70
Wuhan University	China	19	1260	66,32
State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing	China	13	988	76,00
Haskoli Islands	Islândia	11	4164	378,55
China University of Geosciences	China	8	248	31,00
Tsinghua University	China	8	750	93,75
Ministry of Education of the People's Republic of China	China	7	1213	173,29
University of Chinese Academy of Sciences	China	7	171	24,43
Tongji University	China	7	258	36,86
Peking University	China	6	601	100,17
Sun Yat-Sen University	China	6	842	140,33
Nanjing University	China	6	538	89,67

Deutsches Zentrum für Luft- und Raumfahrt DLR	Alemanha	5	709	141,80
Indiana State University	EUA	5	1570	314,00
Instituto Nacional de Pesquisas Espaciais	Brasil	5	198	39,60

A tabela 1.2 fornece o panorama da distribuição global das 15 principais organizações mais produtivas, levando em consideração os documentos selecionados. A presença dominante de instituições chinesas, como a *Chinese Academy of Science* e *Tsinghua University*, demonstra o intenso foco da China em desenvolvimento científico e tecnológico. Todas as publicações da Islândia estão concentradas na *Haskoli Islands*, sendo a maior e mais antiga instituição de ensino do país. Apesar de um número reduzido de publicações, mostra uma média de citações extremamente alta, mostrando a influência e alta qualidade das pesquisas. *Indiana State University* dos EUA e *Deutsches Zentrum für Luft- und Raumfahrt* na Alemanha também se destacam pela alta média de citações, indicando que suas pesquisas possuem um alcance e reconhecimento na comunidade científica internacional.

Principais periódicos e autores

A análise quantitativa da relevância dos periódicos de acordo com a tabela 1.2 e figura 1.5 revela a concentração da produção científica no período. Esses periódicos são classificados de acordo com o número de artigos que publicaram. O periódico *Remote Sensing* lidera a lista com o maior número de documentos, concentrando cerca de 18% das publicações analisadas.

Tabela 1.3 - Produtividade e impacto de periódicos, listando informações como o número de documentos publicados, total de citações, média de citações por documento e índice H. Os periódicos são organizados em ordem decrescente de número de publicações, destacando aqueles com maior influência e contribuição para o campo.

Periódicos	Documentos	Citações	Média citações	Índice H
Remote Sensing	44	2828	64,27	23
International Journal of Remote Sensing	25	2429	97,16	21
Remote Sensing of Environment	22	6601	300,05	21
IEEE Transactions on Geoscience and Remote Sensing	18	5444	302,44	15
IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing	12	619	51,58	10
Geocarto International	10	279	27,90	6
Photogrammetric Engineering and Remote Sensing	10	1243	124,30	8
ISPRS Journal of Photogrammetry and Remote Sensing	8	4746	593,25	8
Earth Science Informatics	6	79	13,17	3
International Journal of Applied Earth Observation and Geoinformation	6	153	25,50	6
IEEE Geoscience and Remote Sensing Letters	5	712	142,40	5
Canadian Journal of Remote Sensing	3	178	59,33	3
ISPRS International Journal of Geo-information	3	137	45,67	3
Journal of Applied remote Sensing	3	17	5,67	2
Sensors	3	219	73,00	3

Os periódicos IEEE Transactions on Geoscience and Remote Sensing e Remote Sensing of Environment exibem médias de citações extremamente altas, destacando-se não apenas pela quantidade, mas principalmente pela qualidade e relevância de suas publicações.

A análise das publicações acumuladas na figura 1.5 destacou um crescimento exponencial do periódico Remote Sensing, partindo de 25 publicações acumuladas até 2021 para 44 em 2024 um aumento de aproximadamente 76 %.




Figura 1.5 - Evolução das publicações acumuladas de 1986 a 2024. As linhas representam a trajetória de crescimento de cada periódico ao longo do tempo.

A figura 1.6 destaca a estrutura da rede de acoplamento bibliográfico entre periódicos. Os nodos centrais, destacados pela densidade de conexões, incluem *Remote Sensing*, *IEEE Transactions on Geoscience and Remote Sensing* e *Remote Sensing of Environment*, se destacando como centros influentes de publicação e pesquisa.

Os clusters identificados na rede refletem comunidades de pesquisa com focos temáticos convergentes. O primeiro, que inclui *Canadian Journal of Remote Sensing*, *Earth Science Informatics*, *Geocarto International*, *International Journal of Applied Earth Observation and Geoinformation*, *ISPRS Journal of Photogrammetry and*

Remote Sensing e *Journal of Applied Remote Sensing*, concentra-se em publicações de aplicação e análises ambientais. O segundo cluster, composto pelos periódicos *Remote Sensing*, *International Journal of Remote Sensing*, *ISPRS International Journal of Geo-information*, *Photogrammetric Engineering and Remote Sensing*, *Remote Sensing of Environment* e *Sensors*, tem sua ênfase em inovações tecnológicas e no avanço de metodologias de sensoriamento remoto. O terceiro cluster, dominado por periódicos da *IEEE*, indica uma forte orientação para a engenharia e aplicações práticas, integrando técnicas no desenvolvimento de soluções para o monitoramento e gestão.




Figura 1.6 - Rede de acoplamento bibliográfico entre periódicos. Os nodos representam periódicos, com "Remote Sensing", "IEEE Transactions on Geoscience and Remote Sensing", e "Remote Sensing of Environment" posicionados como centros principais devido à alta densidade de conexões, indicando influência e papel central na disseminação de pesquisas. Os clusters na rede destacam grupos de periódicos com temas de pesquisa convergentes.

Tabela 1.4 - Desempenho acadêmico de autores. A tabela lista o número de documentos publicados, total de citações recebidas, e índice H para cada autor, junto com sua afiliação institucional e país.

Autores	Documentos	Citações	Índice H	Organização	País
Benediktsson, Jón Atli	11	4164	94	University of Iceland	Islândia
Huang, Xin	8	831	59	Wuhan University	China
Chanussot, Jocelyn	6	2050	93	Grenoble Alps University	França
Abd Samat, Ahmad Asri	6	474	37	The MARA Technological University	Malásia
Zhang, Liangpei	6	730	119	Wuhan University	China
Du, Shihong	5	589	32	Peking University	China
Liu, Sicong	5	490	29	Tongji University	China
Weng, Qihao	5	1570	72	Hong Kong Polytechnic University	Hong Kong
Du, Peijun	4	493	49	Nanjing University	China
Fauvel, Mathieu	4	1623	25	University of Toulouse	França
Gong, Peng	4	899	103	University of Hong Kong	Hong Kong
Li, Erzhu	4	139	17	Jiangsu Normal University	China
Li, Jiayi	4	123	27	Wuhan University	China
Murayama, Yuji	4	310	41	University of Tsukuba	Japão
Myint, Soe Win	4	1144	44	Texas State University	EUA
Tong, Xiaohua	4	143	49	Tongji University	China
Wolff, Eleonore	4	552	21	Université libre de Bruxelles	Bélgica

A tabela 1.4 demonstra a relação entre o número de documentos publicados citações totais e seus índices H.

Entre os autores analisados, Jón Atli Benediktsson da Universidade da Islândia e Jocelyn Chanussot da Universidade dos Alpes em Grenoble se destacam com elevado número de citações , mostrando que seus trabalhos são frequentemente referenciados. Este padrão se repete em outros autores como Qihao Weng, Mathieu Fauvel e Soe Win Myint que apesar de poucos artigos possuem elevado número de citações.




Figura 1.7 - Gráfico de dispersão detalhando a relação entre o número de documentos publicados e o índice H. O eixo horizontal representa o número de documentos, enquanto o eixo vertical mostra o índice H de cada autor.

O gráfico de dispersão explora a relação entre o número de publicações e o índice H. Autores como Jón Atli Benediktsson, Jocelyn Chanussot, Liangpei Zhang, Qihao Weng, Peng Gong, Xiaohua Tong e Soe Win Myint se destacam não só pela quantidade de documentos produzidos, mas também pelo alto índice H. Eles estão posicionados acima da linha de tendência linear, indicando que sua produção e impacto são maiores em comparação com outros no estudo.

Identificação e frequência de palavras-chave

A rede de coocorrência de palavras-chave detalha as interações entre as áreas de pesquisa em classificação de imagens de áreas urbanas (Figura 1.8), evidenciando conexões entre tecnologias e aplicações práticas.




Figura 1.8 - Rede de coocorrência de palavras-chave com no mínimo 5 ocorrências, ilustra as inter-relações entre conceitos-chave. Cada nó representa uma palavra-chave, e as linhas entre eles indicam a frequência de coocorrência em documentos acadêmicos. Clusters de cores diferentes destacam grupos temáticos com conexões estreitas, refletindo áreas de pesquisa concentradas e suas interdependências.

O cluster que inclui *machine learning*, *deep learning* e *convolutional neural network* mostra a fusão de inteligência artificial com técnicas de sensoriamento remoto. Esta integração sugere uma transformação nos métodos de processamento de dados, melhorando a extração de características e a classificação de imagens.

A conexão entre *high resolution image* e *hyperspectral image* com métodos como *feature extraction* e *image segmentation* mostra a exploração de múltiplas fontes de dados. O uso combinado dessas imagens enriquece os modelos de classificação.

Ligações entre *supervised Classification*, *Support vector machines*, *decision trees* e *random forest* refletem o desenvolvimento de métodos de classificação. Combinadas com *machine learning*, essas técnicas aprimoram as abordagens tradicionais.

A associação do termo *google earth engine* com *landsat*, *random forest*, *Support vector machine*, *machine learning*, *land cover*, *land use* e *change detection* reflete o uso da plataforma de computação em nuvem na monitoração de mudanças de cobertura do solo e detecção de mudanças, aproveitando seu extenso banco de dados e facilidade em processar e analisar grandes volumes de dados geoespaciais.

A figura 1.9 oferece uma visão abrangente da evolução das palavras-chave, onde determinados conceitos têm ganhado destaque e se tornado mais relevantes com o passar dos anos.




Figura 1.9 - Frequência de palavras-chave ao longo do tempo, destacando a evolução e a crescente relevância de conceitos específicos. Este gráfico visualiza as mudanças nas direções de pesquisa e as inovações tecnológicas, com ênfase especial na ascensão de plataformas como o Google Earth Engine e métodos como o Deep Learning.

A ascensão recente de temáticas como *Google Earth Engine*, *deep learning* e *Support vector machine* indica uma crescente utilização de inovação tecnológica e técnicas avançadas de análise de dados, transformando a maneira como dados de sensoriamento remoto são processados e aplicados.

O aumento na frequência dos termos *Urbanization*, *land cover Classification* e *land use classification* demonstra ênfase na aplicação do sensoriamento remoto para entender e gerenciar a expansão urbana e as mudanças no uso e cobertura do solo, sendo relevante para questões de planejamento urbano e desenvolvimento sustentável.

Dos termos destacados, *feature selection* e *urban remote sensing* são termos com uma longa tendência de pesquisa. Essa continuidade mostra a importância de metodologias refinadas para o processamento e análise de dados urbanos complexos. A seleção de características corretas é essencial para reduzir a dimensionalidade dos dados, melhorar a eficiência computacional e aumentar a precisão do modelo ao focar em variáveis significativas.

Avaliação crítica dos principais artigos científicos

Nesta seção, analisaremos detalhadamente os artigos mais citados a cada década para sumarizar os principais temas de pesquisa, identificar limitações e sugerir futuras direções de investigação.

Análise textural na classificação de cenas urbanas

ULABY *et al.* (1986) foram pioneiros ao demonstrar a eficácia das estatísticas espaciais de segunda ordem, tais como contraste e estatísticas de momento inverso, na melhoria da precisão da classificação quando combinadas com dados de tonalidade, alcançando precisão superior a 90%. MOLLER-JENSEN (1990) introduziu conhecimento contextual e textural por meio de sistemas especialistas. Este método se mostrou particularmente promissor para o planejamento urbano em países em desenvolvimento, onde a rápida expansão urbana requer ferramentas eficazes de monitoramento.

Em um avanço metodológico, ZHANG (1999) concentrou esforços na detecção de edificações urbanas, utilizando uma abordagem híbrida que incorpora classificação multiespectral e filtragem de textura. HEROLD *et al.* (2003) demonstrou que tanto as métricas espaciais quanto as texturais são indispensáveis para distinguir categorias de uso e cobertura do solo urbano. Com as métricas espaciais sendo particularmente úteis para classes construídas, enquanto parâmetros de textura agregaram um valor discriminatório adicional.

Classificação orientada a objetos

A análise de imagens de satélite baseada em objetos (OBIA) tem se consolidado como metodologia essencial em imagens de alta resolução, principalmente em ambientes urbanos, devido à heterogeneidade com grande mistura espectral. BLASCHKE (2010) forneceu uma visão geral do desenvolvimento de métodos OBIA, revisando mais de 820 artigos acerca do tema. A pesquisa abordou questões conceituais

importantes no sensoriamento remoto e destacou a tendência de automatização no processamento de imagens.

MYINT *et al.* (2011a) focam na eficácia de classificadores baseados em OBIA na identificação de classes urbanas usando imagens de alta resolução, comparando-os com classificadores per-pixel tradicionais. Os resultados mostraram que a abordagem OBIA é superior quando comparada a classificadores tradicionais, alcançando maior precisão global.

Extração de características e classificação de cenas urbanas

Benediktsson *et al.* (2003, 2005) destacam a superioridade das abordagens baseadas em perfis morfológicos estendidos, que quando comparadas com métodos estatísticos convencionais, mostram-se superiores em termos de precisão de classificação. A técnica incorpora múltiplos componentes principais, melhorando a acurácia ao considerar informações espaciais juntamente com informações espectrais. Ampliando a abordagem, FAUVEL *et al.* (2008) propuseram a fusão de informações espaciais e espectrais usando SVMs e perfis morfológicos, alcançando excelentes resultados em dados urbanos de alta resolução.

UDDIN; MAMUN; *et al.* (2021) exploraram a redução de características baseada na análise de componentes principais (PCA) para a classificação de imagens hiperespectrais. Destacando a técnica de filtro de máximo ruído fracional (MNF) como mais precisa, embora tenha maior custo computacional. A análise de componentes principais fracionada (FPCA) mostrou-se como a técnica mais equilibrada, proporcionando resultados satisfatórios com uma complexidade temporal e espacial reduzida.

Métodos avançados de classificação para mapeamento de uso e cobertura do solo urbano

A evolução das metodologias de classificação denota a constante busca por melhorar os métodos utilizados em contextos urbanos de alta complexidade. PAOLA *et al.* (1995) investigaram a aplicabilidade de redes neurais de retropropagação em comparação com os classificadores de máxima verossimilhança. Mostrando que apesar de as redes neurais requererem um período de treinamento mais longo, mostraram maior precisão especialmente em áreas urbanas heterogêneas.

ZHANG *et al.* (1998) utilizaram a classificação fuzzy, que se destacou ao lidar com a imprecisão inerente aos dados de sensoriamento remoto, oferecendo melhor manuseio e precisão dos dados. LU *et al.* (2004) avaliaram a análise de misturas espectrais na melhora da classificação da cobertura e uso do solo urbano. Com alta eficácia ao caracterizar padrões de paisagem urbana e sua expansão.

Ao implementarem um *ensemble* de máquinas de vetores de suporte (SVM) HUANG *et al.* (2013) integraram características espectrais, estruturais e semânticas. A inclusão de regras semânticas no processo de pós-processamento foi uma grande inovação, aumentando a precisão da classificação.

Mapeamento multitemporal do uso e cobertura do solo urbano

YUAN *et al.* (2005) desenvolveram uma abordagem metodológica para investigar mudanças na cobertura do solo de áreas urbanas utilizando imagens Landsat. Seus resultados mostraram alta eficiência ao avaliar a dinâmica temporal da urbanização.

LIU *et al.* (2018) utilizaram a plataforma de computação em nuvem *Google Earth Engine* (GORELICK *et al.*, 2017) para desenvolver mapas urbanos globais multitemporais. A análise que abrangeu o período de 1990 a 2010 revelou um aumento considerável de área urbana em escala global, com amplo crescimento em países como China, Estados Unidos e Índia.

1.4. CONCLUSÃO

Foi observado um aumento expressivo na quantidade de publicações a partir de 2012, refletindo um interesse acadêmico crescente e a expansão de aplicações práticas em planejamento urbano e gestão ambiental. O emprego de algoritmos de aprendizado de máquina, aprendizado profundo, plataformas de computação em nuvem e o acesso a dados de alta resolução têm revolucionado as práticas de mapeamento, melhorando a precisão e eficiência dos processos de classificação de imagens.

A análise demonstrou um padrão claro de contribuição internacional, identificando países que dominam o campo em termos de produção científica e impacto. Além disso, as instituições e periódicos de maior produtividade e impacto foram identificados, mapeando centros de excelência e influência na disseminação de conhecimento.

Apesar dos avanços, a tendência de saturação por estudos de menor impacto aponta para a necessidade de inovações contínuas e de pesquisas que não apenas avancem no aspecto técnico, mas também ofereçam contribuições para o desenvolvimento de políticas sustentáveis e gestão urbana eficaz.

Recomenda-se que futuras pesquisas se concentrem no desenvolvimento de modelos preditivos e sistemas de monitoramento adaptativos, capazes de gerenciar

efetivamente as transformações urbanas e ambientais. Destaca-se, ainda, a importância de uma abordagem interdisciplinar e colaborativa, essencial para superar desafios técnicos e integrar de forma eficiente as novas tecnologias ao planejamento urbano e às práticas de sustentabilidade.

1.5. REFERÊNCIAS

ARIA, M.; CUCCURULLO, C. <i>bibliometrix</i>: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, 11, n. 4, p. 959-975, Nov 2017. Article.

BENEDIKTSSON, J. A.; PALMASON, J. A.; SVEINSSON, J. R. Classification of hyperspectral data from urban areas based on extended morphological profiles. **IEEE Transactions on Geoscience and Remote Sensing**, 43, n. 3, p. 480-491, 2005. Conference Paper.

BENEDIKTSSON, J. A.; PESARESI, M.; ARNASON, K. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations. **IEEE Transactions on Geoscience and Remote Sensing**, 41, n. 9 PART I, p. 1940-1949, 2003. Article.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, 65, n. 1, p. 2-16, 2010. Short Survey.

CAPES. Periódicos CAPES, Online Database, 2023. Disponível em: <https://www-periodicos-capes-gov-br.ez51.periodicos.capes.gov.br/>. Acesso em: 06/12/2023.

CARRANZA-GARCÍA, M.; GARCÍA-GUTIÉRREZ, J.; RIQUELME, J. C. A Framework for Evaluating Land Use and Land Cover Classification Using Convolutional Neural Networks. **Remote Sensing**, 11, n. 3, p. 23, Feb 2019. Article.

ENSSLIN, L et al. **Proknow-C, Knowledge Development Process** – Constructivist: processo técnico com patente de registro pendente junto ao INPI. Brasil: [s.n.], 2010a.

FAUVEL, M.; BENEDIKTSSON, J. A.; CHANUSSOT, J.; SVEINSSON, J. R. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. **IEEE Transactions on Geoscience and Remote Sensing**, 46, n. 11, p. 3804-3814, 2008. Article.

FAYAZ, M.; NAM, J.; DANG, L. M.; SONG, H. K. *et al.* Land-Cover Classification Using Deep Learning with High-Resolution Remote-Sensing Imagery. **Applied Sciences-Basel**, 14, n. 5, p. 15, Mar 2024. Article.

GAUR, S.; SINGH, R. A Comprehensive Review on Land Use/Land Cover (LULC) Change Modeling for Urban Development: Current Status and Future Prospects. **Sustainability**, 15, n. 2, p. 12, Jan 2023. Review.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, 202, p. 18-27, Dec 2017. Article.

GU, Y. Y.; QIAO, X. N.; XU, M. J.; ZOU, C. X. *et al.* Assessing the Impacts of Urban Expansion on Bundles of Ecosystem Services by Dmsp-Ols Nighttime Light Data. **Sustainability**, 11, n. 21, p. 17, Nov 2019. Article.

HAN, Z. M.; DIAN, Y. Y.; XIA, H.; ZHOU, J. J. *et al.* Comparing Fully Deep Convolutional Neural Networks for Land Cover Classification with High-Spatial-Resolution Gaofen-2 Images. **Isprs International Journal of Geo-Information**, 9, n. 8, p. 13, Aug 2020. Article.

HEROLD, M.; LIU, X. H.; CLARKE, K. C. Spatial metrics and image texture for mapping urban land use. **Photogrammetric Engineering and Remote Sensing**, 69, n. 9, p. 991-1001, Sep 2003. Article.

HUANG, X.; ZHANG, L. An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery. **IEEE Transactions on Geoscience and Remote Sensing**, 51, n. 1, p. 257-272, 2013. Article.

KURAS, A.; BRELL, M.; RIZZI, J.; BURUD, I. Hyperspectral and Lidar Data Applied to the Urban Land Cover Machine Learning and Neural-Network-Based Classification: A Review. **Remote Sensing**, 13, n. 17, p. 39, Sep 2021. Review.

LING, J.; ZHANG, H. S.; LIN, Y. Y. Improving Urban Land Cover Classification in Cloud-Prone Areas with Polarimetric SAR Images. **Remote Sensing**, 13, n. 22, p. 19, Nov 2021. Article.

LIU, X.; HU, G.; CHEN, Y.; LI, X. *et al.* High-resolution multi-temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform. **Remote Sensing of Environment**, 209, p. 227-239, 2018. Article.

LU, D.; WENG, Q. Spectral mixture analysis of the urban landscape in Indianapolis with Landsat ETM+ imagery. **Photogrammetric Engineering and Remote Sensing**, 70, n. 9, p. 1053-1062, 2004. Review.

MOLLER-JENSEN, L. Knowledge-based classification of an urban area using texture and context information in Landsat-TM imagery. **Photogrammetric Engineering & Remote Sensing**, 56, n. 6, p. 899-904, 1990.

MOMENI, R.; APLIN, P.; BOYD, D. S. Mapping Complex Urban Land Cover from Spaceborne Imagery: The Influence of Spatial Resolution, Spectral Band Set and Classification Approach. **Remote Sensing**, 8, n. 2, p. 23, Feb 2016. Article.

MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S. *et al.* Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. **Remote Sensing of Environment**, 115, n. 5, p. 1145-1161, 2011. Article.

PAOLA, J. D.; SCHOWENGERDT, R. A. A Detailed Comparison of Backpropagation Neural Network and Maximum-Likelihood Classifiers for Urban Land Use Classification. **IEEE Transactions on Geoscience and Remote Sensing**, 33, n. 4, p. 981-996, 1995. Article.

UDDIN, M. P.; MAMUN, M. A.; HOSSAIN, M. A. PCA-based Feature Reduction for Hyperspectral Remote Sensing Image Classification. **IETE Technical Review (Institution of Electronics and Telecommunication Engineers, India)**, 38, n. 4, p. 377-396, 2021. Review.

ULABY, F. T.; KOUYATE, F.; BRISCO, B.; LEE WILLIAMS, T. H. Textural Information in SAR Images. **IEEE Transactions on Geoscience and Remote Sensing**, GE-24, n. 2, p. 235-245, 1986. Article.

VAN ECK, N. J.; WALTMAN, L. Software survey: VOSviewer, a computer program for bibliometric mapping. **Scientometrics**, 84, n. 2, p. 523-538, Aug 2010.

YUAN, F.; SAWAYA, K. E.; LOEFFELHOLZ, B. C.; BAUER, M. E. Land cover classification and change analysis of the Twin Cities (Minnesota) metropolitan area by multitemporal Landsat remote sensing. **Remote Sensing of Environment**, 98, n. 2-3, p. 317-328, 2005. Article.

ZHANG, Y. Optimisation of building detection in satellite images by combining multispectral classification and texture filtering. **ISPRS Journal of Photogrammetry and Remote Sensing**, 54, n. 1, p. 50-60, 1999. Article.

ZHANG, J.; FOODY, G. M. A fuzzy classification of sub-urban land cover from remotely sensed imagery. **International Journal of Remote Sensing**, 19, n. 14, p. 2721-2738, 1998. Article.

AVALIAÇÃO DE ABORDAGENS CLASSIFICADORAS POR PIXEL E GEOBIA EM DIFERENTES RESOLUÇÕES ESPACIAIS

RESUMO

Este estudo avalia a eficácia de métodos por pixel e GEOBIA na classificação do uso e cobertura do solo urbano, utilizando dados dos satélites Landsat 8, Sentinel-2 e WorldView-2 processados na plataforma *Google Earth Engine*. Foram aplicadas validações cruzadas e *holdout* para verificar a acurácia das classificações. Os resultados indicam que a abordagem por pixel tem maior precisão em imagens de alta resolução, enquanto a GEOBIA é mais eficaz na identificação de padrões texturais complexos. A combinação de ambas as técnicas é recomendada para otimizar a classificação em ambientes urbanos, adaptando a escolha da técnica à resolução dos dados e à complexidade do ambiente analisado.

Palavras-chave: Sensoriamento Remoto, GEOBIA, Uso e cobertura do solo, Planejamento Urbano

ABSTRACT

This study evaluates the effectiveness of pixel-based and GEOBIA methods in classifying urban land use and land cover, using data from the Landsat 8, Sentinel-2, and WorldView-2 satellites processed on the Google Earth Engine platform. Cross-validation and holdout validation were applied to verify classification accuracy. The results indicate that the pixel-based approach provides higher accuracy for high-resolution images, while GEOBIA is more effective in identifying complex textural patterns. Combining both techniques is recommended to optimize classification in urban environments, adapting

the choice of method to the data resolution and the complexity of the analyzed environment.

Keywords: Remote Sensing, GEOBIA, Land Use/Land Cover, Classification, Urban Planning

2.1.INTRODUÇÃO

O crescimento acelerado das áreas urbanas nas últimas décadas trouxe à tona uma série de desafios ambientais, sociais e de planejamento (MCDONALD *et al.*, 2011; SETO *et al.*, 2012; FENG *et al.*, 2021). O aumento da densidade populacional seguido por uma expansão desordenada são algumas das questões enfrentadas pelas cidades contemporâneas (LAMBIN *et al.*, 2011; AFFAIRS, 2019; WANG *et al.*, 2020). Logo, o monitoramento eficaz de áreas urbanizadas e em rápida expansão é indispensável (PAULEIT *et al.*, 2000). O sensoriamento remoto como fonte de dados permite uma compreensão detalhada das transformações urbanas, auxiliando na gestão e planejamento do espaço urbano (JENSEN, 2009; PARANHOS FILHO *et al.*, 2021), além de possibilitar a obtenção de informações em tempo quase real.

O sensoriamento remoto oferece uma ampla gama de possibilidades para a análise e estudo do ambiente urbano (KADHIM *et al.*, 2016). Permite a obtenção de informações sobre a superfície terrestre sem a necessidade de deslocamento, o que é útil em áreas de difícil acesso ou em situações em que a segurança é uma preocupação. Imagens de satélite de alta resolução possibilitam a identificação de detalhes finos da cobertura do solo, como edificações, vias e vegetação urbana (MYINT *et al.*, 2011b; GUAN *et al.*, 2022). Além disso, capturam dados em múltiplos espectros eletromagnéticos, o que permite a análise de diferentes aspectos do ambiente urbano, desde a saúde da vegetação até a caracterização de materiais de construção.

A classificação de imagens em áreas urbanas é uma tarefa complexa devido à heterogeneidade e à grande variabilidade espectral dos elementos presentes no solo (MYINT *et al.*, 2004; SMALL, 2005; LU *et al.*, 2007). A diversidade de materiais, texturas e formas encontrados nas cidades, combinada com a alta densidade de objetos, torna a distinção entre diferentes classes de cobertura do solo um grande desafio (XIAN

et al., 2005). Métodos tradicionais de classificação normalmente encontram grande dificuldade em capturar essa complexidade.

O uso de técnicas avançadas, como a segmentação utilizada em metodologias OBIA, que cria segmentos homogêneos com base na similaridade espectral e espacial (BLASCHKE, 2010; MYINT *et al.*, 2011b; BLASCHKE *et al.*, 2014; HOSSAIN *et al.*, 2019), algoritmos de classificação baseados em aprendizado de máquina, como o *Random Forest*, que constrói múltiplas árvores de decisão para melhorar a classificação (BELGIU *et al.*, 2016; OUMA *et al.*, 2023) e a análise de componentes principais, que ajuda a extrair características relevantes da imagem, simplificando o processo de classificação e melhorando a eficiência computacional, têm se mostrado eficaz (DENG *et al.*, 2008; UDDIN; AL MAMUN; *et al.*, 2021). Além disso, o uso de métricas texturais melhora a discriminação de classes em áreas urbanas, onde a variabilidade dos materiais é alta (HEROLD *et al.*, 2003; HERNANDEZ *et al.*, 2018). Essas abordagens permitem uma melhor identificação e distinção dos diferentes elementos urbanos, melhorando a acurácia e precisão da classificação.

O *Google Earth Engine* (GEE) é uma plataforma de computação em nuvem para a análise de dados geoespaciais em larga escala (GORELICK *et al.*, 2017). A capacidade de processamento em nuvem e em paralelo do GEE permite a análise de grandes volumes de dados de forma eficiente, eliminando as limitações de *hardware* e *software* comuns em sistemas tradicionais. O GEE oferece uma vasta biblioteca de dados, incluindo imagens de satélite, dados climáticos, dados geofísicos e populacionais, além de uma grande variedade de algoritmos para processamento e análise de dados (TAMIMINIA *et al.*, 2020). A integração desses recursos facilita a execução de análises complexas, como estudos sobre a dinâmica urbana.

Estudos recentes demonstram que a integração de dados de alta resolução e técnicas avançadas de processamento podem proporcionar uma compreensão aprofundada da estrutura e dinâmica de áreas urbanas (QIAO *et al.*, 2019; ZHANG *et al.*, 2019; SUN *et al.*, 2020; ZHAO *et al.*, 2023).

Este estudo visa desenvolver e avaliar abordagens para a classificação de cobertura do solo em áreas urbanas, utilizando imagens de satélite e a plataforma *Google Earth Engine*.

2.2.MATERIAL E MÉTODOS

2.2.1. Área de estudo

Campo Grande, capital do Estado de Mato Grosso do Sul, está localizada na região Centro-Oeste do Brasil, com coordenadas geográficas aproximadas de 20° 26' 34'' S, 54° 38' 47'' W. A cidade possui uma área urbana de cerca de 359 km², caracterizada por terrenos planos e suavemente ondulados, típicos do Cerrado, com solos predominantemente latossolos. O clima tropical (Aw, segundo Köppen) apresenta uma estação chuvosa de outubro a abril, e uma seca de maio a setembro, com temperaturas médias anuais de 23°C e precipitação média anual de aproximadamente 1.300 mm.

A hidrografia é marcada por rios e córregos, como o Anhanduí, Prosa e Segredo, essenciais para a drenagem urbana. A vegetação predominante é típica do Cerrado. Com aproximadamente 900 mil habitantes, a cidade vem experimentando um rápido crescimento urbano nas últimas décadas, transformando áreas de Cerrado em zonas residenciais, comerciais e industriais. Este crescimento urbano acelerado torna Campo Grande um local ideal para estudos de classificação da cobertura do solo, visando

compreender as dinâmicas de uso e ocupação do solo em um ambiente urbano em expansão.




Figura 2.1 - A figura apresenta a posição estratégica da cidade, situada no centro do Estado, evidenciando as áreas urbanizadas e a distribuição de espaços verdes. A imagem principal mostra a malha urbana detalhada de Campo Grande, enquanto os mapas adicionais destacam a localização de Mato Grosso do Sul no Brasil e a posição de Campo Grande dentro do Estado. O contorno amarelo delimita a área urbana da cidade (Fonte: IBGE, 2022; Qgis, 2023; Landsat 9, 2023).

2.2.2. Delineamento do estudo

O delineamento do estudo está representado de forma esquemática no fluxograma da figura 2.2, que detalha as principais etapas realizadas. Todo o processo foi implementado utilizando o ambiente do *Google Earth Engine*.




Figura 2.2 – O fluxograma detalha o fluxo de trabalho. A composição do conjunto de dados inclui a seleção de imagens dos satélites Landsat 8, Sentinel-2 e WorldView 2, seguida de índices espectrais, métricas de textura GLCM e bandas espectrais são extraídos. As amostras são então coletadas e divididas em conjuntos de treinamento e teste para dois métodos de classificação: GEOBIA e baseada em pixels. Após o treinamento do algoritmo, a classificação é realizada e validada. A precisão dos resultados é avaliada por meio de matrizes de confusão, resultando nos cálculos de acurácia do produtor, do usuário e acurácia global.

2.2.3. Fontes de Dados

Para a realização deste estudo, foram utilizadas imagens de três diferentes fontes, todas do ano de 2019 e correspondentes ao período seco, garantindo assim a homogeneidade temporal dos dados e a redução de interferências atmosféricas. As três imagens com suas diferentes resoluções e características espectrais proporcionam uma base sólida para a análise. As características detalhadas das imagens utilizadas são apresentadas na tabela 2.1.

Tabela 2.1 - Características das imagens de satélite utilizadas no estudo, provenientes dos satélites Landsat 8, Sentinel-2 e WorldView-2, todas capturadas no ano de 2019 durante o período seco. As imagens do Landsat 8 e Sentinel-2 são acessíveis gratuitamente via *Google Earth Engine* (GEE), enquanto a imagem do WorldView-2 requer compra.

Característica	Landsat 8	Sentinel-2	WorldView-2
Ano	2019	2019	2019
Período	Seco	Seco	Seco
Cobertura de Nuvens	Menor que 1%	Menor que 1%	Menor que 10%
Resolução Radiométrica	8 bits	12 bits	11 bits
Resolução Espacial	30 metros	10 metros	0,5 metros
Órbita/Ponto	225/74	MGRS 21KYT	N/A
Bandas Espectrais	Multiespectral (11)	Multiespectral (12)	Multiespectral (8)
Cobertura Espacial	180 x 185 km ²	290 x 290 km ²	16,4 x 16,4 km ²
Propósito Principal	Análise geral	Análise intermediária	Análise detalhada
Intervalo de Revisita	16 dias	5 dias	1,1 dias
Disponibilidade de Dados	Gratuito (via GEE)	Gratuito (via GEE)	Requer compra

2.2.4. Conjunto de dados

Para complementar a análise das imagens de forma a melhorar a acurácia da classificação da cobertura do solo, foram calculados diversos dados auxiliares a partir das imagens

iniciais. Entre esses dados estão índices espectrais, métricas de textura a partir da matriz de coocorrência de níveis de cinza - GLCM e os Componentes Principais - PCA.

Os índices espectrais como o NDVI e NDWI (ROUSE *et al.*, 1973; McFEETERS *et al.*, 1996) são úteis para diferenciar entre vegetação, áreas construídas e corpos de água. As métricas de textura fornecem informações sobre a variação espacial dos valores dos pixels, ajudando a identificar padrões e estruturas que não são evidentes apenas com os valores de refletância (HARALICK *et al.*, 1973; CONNERS *et al.*, 1984). A análise de PCA é utilizada para reduzir a dimensionalidade dos dados, destacando as bandas mais informativas e eliminando a redundância (INGEBRITSEN *et al.*, 1985; LI *et al.*, 1998).

O conjunto de dados para classificação foi preparado com base no conjunto original de bandas das imagens selecionadas (Tabela 2.2). Em seguida, com base na importância das bandas na classificação inicial, selecionamos apenas aquelas com peso $\geq 2,5\%$ para compor o conjunto final.

Tabela 2.2 – Bandas e características das imagens Landsat 8, Sentinel-2 e WorldView-2 utilizadas na classificação da cobertura do solo. As bandas multiespectrais, texturas, gradientes, índices espectrais e componentes principais de análise (PCA) são detalhadas para cada tipo de imagem de satélite.

Característica	Imagem Landsat 8	Imagem Sentinel-2	Imagem WorldView-2
Multiespectral	B1 – Blue Coastal	B1 – Aerosols	B1 – Blue Coastal
Multiespectral	B2 – Blue	B2 - Blue	B2 - Blue
Multiespectral	B3 – Green	B3 - Green	B3 - Green
Multiespectral	B4 – Red	B4 - Red	B4 - Yellow
Multiespectral	B5 – Near Infrared	B5 – Red Edge 1	B5 – Red
Multiespectral	B6 – Swir Infrared 1	B6 – Red Edge 2	B6 – Red Edge
Multiespectral	B7 – Swir Infrared 2	B7 – Red Edge 3	B7 – Near Infrared 1
Multiespectral	B8 - Panchromatic	B8 – Near Infrared	B8 – Near Infrared 2
Multiespectral	B9 - Cirrus	B8A – Red Edge 4	-
Multiespectral	-	B9 – Water Vapor	-
Multiespectral	-	B11 – Swir Infrared 1	-
Multiespectral	-	B12 – Swir Infrared 2	-
Multiespectral	-	-	-
Termal	B10 – Thermal Infrared 1	-	-
Termal	B11 – Thermal Infrared 2	-	-
Textura	B5_asm	B8_asm	b7_asm
Textura	B5_contrast	B8_contrast	b7_contrast

Característica	Imagem Landsat 8	Imagem Sentinel-2	Imagem WorldView-2
Textura	B5_corr	B8_corr	b7_corr
Textura	B5_dent	B8_dent	b7_dent
Textura	B5_diss	B8_diss	b7_diss
Textura	B5_dvar	B8_dvar	b7_dvar
Textura	B5_ent	B8_ent	b7_ent
Textura	B5_idm	B8_idm	b7_idm
Textura	B5_imcorr1	B8_imcorr1	b7_imcorr1
Textura	B5_imcorr2	B8_imcorr2	b7_imcorr2
Textura	B5_inertia	B8_inertia	b7_inertia
Textura	B5_maxcorr	B8_maxcorr	b7_maxcorr
Textura	B5_prom	B8_prom	b7_prom
Textura	B5_savg	B8_savg	b7_savg
Textura	B5_sent	B8_sent	b7_sent
Textura	B5_shade	B8_shade	b7_shade
Textura	B5_svar	B8_svar	b7_svar
Textura	B5_var	B8_var	b7_var
Gradiente	Gradiente_NDVI	Gradiente_NDVI	Gradiente_NDVI
Índice Espectral	NDVI	NDVI	NDVI
Índice Espectral	NDWI	NDWI	NDWI
PCA	pc1	pc1	pc1
PCA	pc2	pc2	pc2
PCA	pc3	pc3	pc3
PCA	pc4	pc4	pc4
PCA	pc5	pc5	pc5

2.2.5. Coleta de amostras

A etapa de coleta de amostras é uma das mais importantes em um estudo de classificação de cobertura e uso do solo, pois afeta diretamente a acurácia dos resultados.

Utilizamos uma imagem WorldView-2 com resolução espacial de 0,5 m, o que permite identificar com precisão as diferentes classes de cobertura do solo. As classes foram determinadas com base nas características observáveis na imagem e na relevância para o estudo. As categorias selecionadas refletem os principais tipos de uso e cobertura do solo na área de estudo. Coletamos 510 amostras para cada classe, totalizando 3.570 amostras (Tabela 2.3).

As amostras foram selecionadas manualmente, com base em conhecimento prévio e interpretação visual da imagem, considerando a clareza e homogeneidade das áreas amostradas. Para evitar vieses e assegurar a representatividade, as amostras foram coletadas em diversos pontos da imagem. Após a seleção inicial, as amostras foram validadas por meio de inspeção visual para confirmar que cada ponto amostrado correspondia corretamente à classe designada.

Tabela 2.3 – Descrição detalhada das amostras coletadas. As amostras foram coletadas a partir de uma imagem WordView-2 com resolução espacial de 0,5 m. Foram coletadas sete classes distintas de cobertura do solo, cada classe possui 510 amostras, totalizando 3.570 amostras.

Classe	Número de amostras	Descrição
Água	510	Áreas cobertas por corpos d'água como rios, lagos e reservatórios.
Vegetação Rasteira	510	Áreas com vegetação rasteira e/ou herbácea.
Vegetação Arbórea	510	Áreas com vegetação arbórea.
Pavimento Asfáltico	510	Superfícies pavimentadas com asfalto.
Edificações	510	Estruturas construídas como prédios e casas.
Solo Exposto	510	Áreas onde o solo está exposto, sem cobertura vegetal ou edificações.
Sombra	510	Regiões sombreadas, geralmente adjacentes a estruturas elevadas ou vegetação densa.

2.2.6. Algoritmo classificador

O *Random Forest* é um classificador amplamente utilizado em estudos de sensoriamento remoto. É um método de aprendizado de máquina que opera construindo múltiplas árvores de decisão durante o treinamento. Cada árvore é construída a partir de uma amostra aleatória com reposição dos dados de treinamento. Durante a construção das árvores, em cada nó de decisão, um subconjunto aleatório das características é considerado para determinar a divisão. Esse processo de aleatoriedade e amostragem múltipla reduz a variância geral do modelo. O algoritmo fornece estimativas internas da

precisão do modelo e da importância de cada variável, facilitando a interpretação dos resultados e a identificação das características mais relevantes para a classificação.

2.2.7. Avaliação das previsões

A avaliação da acurácia foi realizada com base em matrizes de confusão, utilizamos dois métodos distintos de validação: a validação holdout e a validação cruzada k-fold com 5 dobras.

A validação *holdout* divide o conjunto de dados de amostras em dois subconjuntos: um conjunto de treinamento e um conjunto de teste. Neste estudo utilizamos 70% das amostras para treinar o modelo e os 30% restantes para testá-lo. Esta técnica permite avaliar a capacidade do modelo de generalizar para novos dados não vistos durante o treinamento. A precisão do modelo é calculada ao comparar as previsões feitas pelo modelo com as classes reais das amostras no conjunto de teste.

A validação cruzada *k-fold* é uma técnica que divide os dados em k subconjuntos de tamanho aproximadamente igual e com classes estratificadas, garantindo que a distribuição das classes em cada dobra seja representativa da distribuição original dos dados. O processo de validação *k-fold* tem a seguinte sequência:

- a) Divisão dos dados em 5 subconjuntos.
- b) Utilização de 4 subconjuntos para treinar o modelo e o subconjunto restante para teste.
- c) Repetição do processo 5 vezes, cada vez utilizando um subconjunto diferente para teste.
- d) Cálculo da média das métricas de desempenho obtidas em cada uma das 5 iterações.

2.3. RESULTADOS

Com a configuração ótima dos parâmetros obtida por meio de otimização do algoritmo classificador, foram calculadas a acurácia global (OA), a acurácia do usuário (UA), a acurácia do produtor (PA) e o *F-score* para comparar o desempenho do algoritmo entre três diferentes conjuntos finais diferentes e duas abordagens de classificação para cada fonte de dados (Anexo 1). Os conjuntos de dados utilizados foram: (1) todas as bandas disponíveis para cada imagem, (2) apenas as bandas do visível e do infravermelho próximo, e (3) bandas selecionadas a partir da classificação do conjunto 1, nas quais a importância de cada variável foi calculada e selecionadas aquelas com no mínimo 2,5% de relevância (Anexo 2).

2.3.1. Avaliação das previsões

A comparação entre as variáveis do Landsat 8 entre os métodos de classificação por pixel e GEOBIA mostrou variações distintas de importância (Figura 2.3). As bandas do espectro visível apresentam uma ligeira predominância de importância no método baseado em pixel, com a banda do infravermelho de ondas curtas (2.11 - 2.29 μm) apresentando a maior relevância entre todas as variáveis analisadas. Os índices NDVI e NDWI também demonstram maior relevância sob o método por pixel. Quanto às métricas de textura, observa-se uma tendência geral de maior importância no método GEOBIA; as componentes principais apresentam variações menos pronunciadas, sendo ligeiramente mais importantes para o método por pixel.




Figura 2.3 - Importância das variáveis do Landsat 8 entre os métodos de classificação Pixel e GEOBIA. As variáveis estão dispostas ao longo do perímetro, com texturas derivadas da banda do infravermelho próximo e componentes principais. As áreas preenchidas indicam a magnitude da importância atribuída por cada método, destacando variações específicas nas variáveis analisadas.

Para as variáveis do Sentinel-2 (Figura 2.4) alguns padrões se mantêm, com as bandas do espectro do visível tendo maior importância para o método pixel, porém com a banda do *Red Edge 1* com uma maior importância para o método GEOBIA. Os índices NDVI e NDWI também foram mais importantes para o método por pixel. Para as métricas de textura, observou-se uma tendência de importância maior no método GEOBIA. Já as componentes principais exibiram variações menos acentuadas, sendo ligeiramente mais relevantes para o método GEOBIA.




Figura 2.4 - Importância das variáveis do Sentinel-2 entre os métodos de classificação Pixel e GEOBIA. As variáveis estão dispostas ao longo do perímetro, com texturas derivadas da banda do infravermelho próximo e componentes principais. As áreas preenchidas indicam a magnitude da importância atribuída por cada método, destacando variações específicas nas variáveis analisadas.

A comparação entre as variáveis do WorldView 2 mostrou um padrão ligeiramente diferente (Figura 2.5), com as bandas do vermelho e infravermelho próximo tendo grande importância para o método GEOBIA, assim como as métricas de textura. As componentes principais mostraram significativa importância para o método por pixel.

Ao analisar os resultados de forma conjunta entre as diferentes fontes de dados, temos que as bandas do visível são geralmente mais importantes no método por pixel para o Landsat 8 e Sentinel-2, mas no método GEOBIA para o WorldView 2. Os índices são mais relevantes para o método *pixel-based* para todas as fontes de dados. Com as métricas de textura apresentando maior relevância para o método GEOBIA, especialmente no Sentinel-2 e WorldView 2. As componentes principais apresentam variações menores, com leve predominância do método de classificação *pixel-based*.




Figura 2.5 - Importância das variáveis do Sentinel-2 entre os métodos de classificação Pixel e GEOBIA. As variáveis estão dispostas ao longo do perímetro, com texturas derivadas da banda do infravermelho próximo e componentes principais. As áreas preenchidas indicam a magnitude da importância atribuída por cada método, destacando variações específicas nas variáveis analisadas.

2.3.2 Desempenho global

Para o conjunto de dados 3, relativo aos dados do satélite Landsat 8, a acurácia global do método baseado em pixel foi de 0,81 na validação *holdout* e de 0,85 na validação cruzada *k-fold 5*, enquanto a abordagem GEOBIA apresentou acurácia global de 0,74 na validação *holdout* e de 0,84 na validação cruzada *k-fold 5*. Para os dados do satélite Sentinel-2, a acurácia global da abordagem em pixel foi de 0,90 para a validação *holdout* e também para a validação cruzada *k-fold 5*, enquanto a abordagem GEOBIA apresentou acurácia global de 0,85 para a validação *holdout* e 0,84 para a validação cruzada *k-fold 5*. Para os dados WorldView 2, a acurácia global para a abordagem por pixel foi de 0,96 tanto para a validação *holdout* quanto para a validação cruzada *k-fold 5*, enquanto a abordagem GEOBIA apresentou uma acurácia global de 0,95 na validação *holdout* e de 0,96 na validação cruzada *k-fold 5*.



Figura 2.6 - Comparação dos Métodos de Classificação por Pixel e Geobia para os dados dos satélites Landsat 8, Sentinel-2 e WorldView 2. A figura apresenta a classificação de uso e cobertura do solo da área urbana de Campo Grande – MS. As variáveis de entrada para o algoritmo classificador incluem as bandas espectrais com importância acima de 2.5%.

2.3.3 Matriz de confusão

As matrizes de confusão fornecem uma visão do desempenho das abordagens de classificação, permitindo a avaliação da acurácia e dos erros de classificação para cada classe de forma individual. Para o conjunto de dados otimizado e para cada abordagem classificadora, foram geradas matrizes de confusão para a validação *holdout*.




Figura 2.7 - Matrizes de confusão para as abordagens classificadoras, utilizando o conjunto de dados otimizado.

Landsat 8

A matriz de confusão para o Landsat 8 mostrou que a abordagem GEOBIA apresentou confusão ao classificar a classe "água", principalmente confundida com "vegetação rasteira" e "vegetação arbórea". As classes "vegetação rasteira" e "vegetação arbórea" mostraram mais confusões entre si, enquanto a classe "edificações" teve muitos erros, sendo frequentemente confundida com "pavimento asfáltico". Na abordagem por pixel, o desempenho geral na classe "água" foi melhor, com menos confusões. As classes "vegetação rasteira" e "vegetação arbórea" apresentaram confusões, mas ainda mantiveram uma boa precisão. As classes "pavimento asfáltico" e "edificações" tiveram distribuições de erro semelhantes às da abordagem GEOBIA.

Sentinel-2

Para os dados do Sentinel-2, a abordagem GEOBIA demonstrou maior número de erros na classificação da classe "água", confundindo-a principalmente com "vegetação arbórea" e "pavimento asfáltico". As classes "vegetação rasteira" e "vegetação arbórea" apresentaram boas precisões, apesar de algumas pequenas confusões. A classe "pavimento asfáltico" teve consideráveis confusões com "solo exposto" e "edificações". Já a abordagem por pixel apresentou um desempenho melhor na classe "água", com menos confusões. As classes "vegetação rasteira" e "vegetação arbórea" mantiveram alta precisão, com pequenas confusões. No entanto, "edificações" e "pavimento asfáltico" mostraram distribuições de erro similares às da abordagem GEOBIA.

WorldView-2

A análise das matrizes de confusão para o satélite WorldView-2 mostrou que a abordagem GEOBIA apresentou uma alta precisão na classificação da classe

"água", com apenas 8 erros classificados como "sombra". Da mesma forma, as classes "vegetação rasteira" e "vegetação arbórea" mostraram altos índices de acurácia, com pouquíssimas confusões. No entanto, a classe "edificações" apresentou confusões com "solo exposto", indicando um desafio na distinção entre essas classes. A abordagem por pixel também apresentou alta precisão para a classe "água", com apenas 7 erros, e mostrou bons resultados para "vegetação rasteira" e "vegetação arbórea", com confusões mínimas. Entretanto, a classe "edificações" teve alguns erros atribuídos a "solo exposto" e "sombra".

As análises das matrizes de confusão demonstram que as abordagens por pixel geralmente apresentaram uma precisão ligeiramente superior em classes como "água" e "vegetação rasteira". Por outro lado, a abordagem GEOBIA mostrou desempenho competitivo, especialmente em classes como "vegetação arbórea" e "sombra", dependendo do sensor utilizado. A classe "edificações" foi frequentemente confundida com "solo exposto" e "pavimento asfáltico", indicando um desafio em distinguir materiais construídos com características espectrais semelhantes. A classe "pavimento asfáltico" teve confusões significativas com "edificações" e "solo exposto".

Além disso, a análise comparativa entre os sensores mostrou que o WorldView 2, com sua resolução espacial mais alta, proporcionou melhores resultados em geral, com menos confusões entre classes. Em contrapartida, os sensores Sentinel-2 e Landsat 8, com resoluções mais baixas, apresentaram maiores confusões, especialmente em classes que exigem detalhes espaciais finos para distinção.

2.3.4 Classes de Uso e Cobertura do Solo

Os resultados de acurácia do produtor (PA), acurácia de usuário (UA) e *F-score* proporcionam uma visão detalhada do desempenho dos métodos de classificação para diferentes classes de uso e cobertura do solo.

Água: Ambas as abordagens apresentaram PA e UA elevadas, com valores acima de 0,90 para todos os satélites, indicando uma alta precisão na detecção de corpos d'água. No Landsat 8, a abordagem por pixel teve um *F-score* de 0,951, enquanto a abordagem GEOBIA apresentou um *F-score* de 0,923. No Sentinel-2, a abordagem por pixel também teve um *F-score* superior (0,958) à abordagem GEOBIA (0,923). No WorldView-2, ambas as abordagens foram altamente precisas, com a abordagem por pixel obtendo um *F-score* de 0,965 e a abordagem GEOBIA de 0,954.

Vegetação Rasteira: No Landsat 8, a abordagem por pixel mostrou melhor desempenho com um *F-score* de 0,833, enquanto a abordagem GEOBIA teve um *F-score* de 0,718. No Sentinel-2, a abordagem por pixel apresentou um *F-score* de 0,927, comparado à abordagem GEOBIA com *F-score* de 0,718. No WorldView-2, ambas as abordagens apresentaram alta precisão, mas a abordagem GEOBIA teve uma leve vantagem com um *F-score* de 0,979, refletindo a capacidade de capturar detalhes texturais finos.

Vegetação Arbórea: Esta classe apresentou melhores resultados com a abordagem por pixel no Landsat 8, com um *F-score* de 0,747, enquanto a abordagem GEOBIA teve um *F-score* de 0,639. No Sentinel-2, a abordagem por pixel também foi superior com um *F-score* de 0,907, comparado à abordagem GEOBIA com *F-score* de 0,639. No

WorldView-2, a abordagem GEOBIA mostrou um desempenho ligeiramente melhor com um *F-score* de 0,984, em comparação à abordagem por pixel com *F-score* de 0,975.

Pavimento Asfáltico: No Landsat 8, a abordagem por pixel teve um desempenho superior com um *F-score* de 0,650, enquanto a abordagem GEOBIA apresentou um *F-score* de 0,494. No Sentinel-2, a abordagem por pixel teve um *F-score* de 0,897, superior à abordagem GEOBIA com *F-score* de 0,494. No WorldView-2, ambas as abordagens apresentaram desempenhos excelentes, com *F-scores* de 0,989 para ambas as abordagens.

Edificações: Os resultados para esta classe foram mistos. No Landsat 8, a abordagem por pixel foi mais precisa com um *F-score* de 0,705, enquanto a abordagem GEOBIA teve um *F-score* de 0,585. No Sentinel-2, a abordagem por pixel apresentou um *F-score* superior de 0,848, comparado à abordagem GEOBIA com *F-score* de 0,585. No WorldView-2, a abordagem por pixel foi novamente superior com um *F-score* de 0,939, enquanto a abordagem GEOBIA apresentou um *F-score* de 0,916. Essa variação sugere que a eficácia de cada abordagem pode depender da resolução espacial e das características espectrais do sensor utilizado.

Solo Exposto: Esta classe apresentou alta precisão em ambas as abordagens para todos os satélites. No Landsat 8, a abordagem por pixel teve um *F-score* de 0,876, enquanto a abordagem GEOBIA teve um *F-score* de 0,871. No Sentinel-2, a abordagem por pixel apresentou um *F-score* de 0,909, comparado à abordagem GEOBIA com *F-score* de 0,871. No WorldView-2, ambas as abordagens mostraram excelente consistência, com *F-score* de 0,943 para a abordagem por pixel e 0,927 para a abordagem GEOBIA.

Sombra: A classe sombra apresentou altos valores de PA e UA, com pequenas variações entre as abordagens e satélites. No Landsat 8, a abordagem GEOBIA foi ligeiramente melhor com um *F-score* de 0,930, comparado à abordagem por pixel com *F-score* de 0,913. No Sentinel-2, a abordagem por pixel apresentou um *F-score* de 0,903, enquanto a abordagem GEOBIA teve um *F-score* de 0,930. No WorldView-2, a abordagem por pixel e a abordagem GEOBIA tiveram desempenhos similares, com *F-score* de 0,967 e 0,958, respectivamente.

2.4. DISCUSSÃO

Os resultados da análise comparativa dos métodos de classificação por pixel e GEOBIA para os satélites Landsat 8, Sentinel-2 e WorldView-2 indicaram que, em geral, a abordagem por pixel apresentou melhor desempenho global, especialmente em dados de alta resolução como os do WorldView-2. No entanto, a abordagem GEOBIA mostrou-se competitiva na identificação de padrões texturais complexos e contextos espaciais. Esses resultados sugerem que a abordagem por pixel é mais eficaz para classes de uso e cobertura do solo homogêneas e bem definidas, como corpos d'água.

Os achados indicam que a vantagem da abordagem pixel-based se torna mais pronunciada quando a dimensão característica dos alvos urbanos se aproxima do tamanho do pixel, situação em que a heterogeneidade intra-pixel é mínima. Nessas condições, cada amostra espectral representa quase integralmente um único objeto, reduzindo a ambiguidade temática e elevando a acurácia global. Em contraste, em cenários nos quais a escala do objeto excede o pixel, surge mistura espectral substancial

e padrões texturais complexos; nesse contexto, a superioridade do método por pixel tende a se reduzir ou, em casos extremos, inverter-se em favor de técnicas orientadas a objetos.

Esse comportamento pode ser explicado pela natureza das duas abordagens: a abordagem por pixel se beneficia diretamente da resolução espacial dos sensores, proporcionando alta precisão em áreas homogêneas. Em dados de alta resolução, como os do WorldView-2, onde cada pixel representa um objeto pequeno, a classificação por pixel pode minimizar erros gráficos ao classificar diretamente cada pixel com alta precisão. A abordagem GEOBIA, utilizando segmentos de imagem e variáveis contextuais, é mais adequada para capturar a heterogeneidade textural e estrutural das paisagens urbanas. Em imagens de alta resolução, a GEOBIA pode ajustar melhor os segmentos às fronteiras reais dos objetos, capturando características texturais e contextuais detalhadas. No entanto, em dados de resolução moderada a baixa, como os do Sentinel-2 e Landsat 8, a precisão da GEOBIA pode diminuir devido à dificuldade em segmentar pequenos objetos, uma vez que muitos detalhes se perdem na resolução mais grossa.

O desempenho inferior do GEOBIA em Sentinel-2 e Landsat-8 pode ser atribuído, principalmente, à granularidade limitada desses sensores. A segmentação multirresolução gerou objetos que, na maioria dos casos, englobam pixels de múltiplas classes temáticas, resultando em sobre-segmentação ou, inversamente, em objetos superdimensionados que diluem as diferenças espectrais internas. Esse artefato compromete a atribuição correta de rótulos, sobretudo em superfícies urbanas heterogêneas. Adicionalmente, a calibração fina dos parâmetros de escala, forma e compacidade torna-se menos efetiva quando a variação espectral intra-classe é alta e o contraste inter-classe é baixo. Cabe ressaltar, ainda, que a segmentação de altíssima

resolução (WorldView-2) impôs demanda computacional significativamente maior, o que pode limitar a aplicação operacional em cenários com infraestrutura restrita.

Relevância dos Satélites e Metodologias

Os satélites Landsat 8, Sentinel-2 e WorldView-2, com suas diferentes resoluções espaciais, mostraram-se eficazes em distintos contextos de análise. O Landsat 8, com resolução espacial de 30 metros, é adequado para monitoramentos de larga escala, permitindo a identificação de mudanças no uso do solo em extensas áreas urbanas com um custo computacional relativamente baixo. Já o Sentinel-2, com resolução espacial de 10 metros, proporciona um balanço entre detalhe e cobertura, sendo ideal para análises em nível intermediário. O WorldView-2, com resolução espacial de 0,5 metros, captura detalhes finos, sendo particularmente eficaz para estudos que exigem alta precisão e detalhamento, como a classificação de elementos urbanos específicos.

Comparabilidade das Acurácias

A comparação direta das acurácias entre os diferentes sensores indica uma tendência esperada: sensores de alta resolução espacial apresentam melhor acurácia na classificação do uso e cobertura do solo. No entanto, é fundamental considerar que cada sensor oferece vantagens e limitações contextuais. Sensores de alta resolução, apesar de mais precisos, possuem maiores custos de aquisição, processamento e também introduzem maior ruído a cena de estudo. Sensores de menor resolução, como o Landsat 8, oferecem uma visão mais generalista, que pode ser perfeitamente adequada para determinadas aplicações, como o monitoramento de longo prazo e em larga escala de áreas urbanas.

Abordagens de Classificação: Pixel e GEOBIA

As abordagens metodológicas empregadas, Pixel e GEOBIA, demonstraram desempenhos distintos conforme a resolução das imagens utilizadas. A classificação baseada em pixel, tradicionalmente utilizada, trata cada pixel individualmente, considerando apenas suas características espectrais. Esta abordagem mostrou-se eficaz em resoluções mais baixas, mas tende a ser menos precisa em imagens de alta resolução devido ao fenômeno da variabilidade espectral dentro de uma mesma classe de uso e cobertura do solo.

Por outro lado, a abordagem GEOBIA segmenta a imagem em objetos ou regiões que possuem características homogêneas, integrando informações espectrais, espaciais, texturais e contextuais. Esta metodologia apresentou superioridade em imagens de alta resolução, como as do sensor WorldView-2, capturando de maneira mais precisa os elementos urbanos.

Aplicabilidade e Integração de Dados

Os resultados deste estudo ressaltam a importância de selecionar o sensor adequado com base no objetivo específico da análise. Para estudos que demandam alta precisão, como a identificação de tipos específicos de cobertura do solo em áreas urbanas densamente povoadas, sensores de alta resolução são indispensáveis. Por outro lado, para análises que envolvem grandes extensões territoriais e necessitam de uma visão mais generalista, sensores como o Landsat 8 são mais apropriados.

2.4.1 Comparação com Estudos Anteriores

Estudos anteriores demonstraram a eficácia e as limitações dos métodos de classificação por pixel e por objeto em diferentes contextos e com diferentes tipos de sensores.

Jebur et al. (2014) conduziram um estudo utilizando imagens SPOT 5 para comparar métodos de classificação baseados em pixels e orientados a objetos. Eles encontraram que a abordagem orientada a objetos produziu uma acurácia geral mais alta (81,25%) em comparação com a abordagem baseada em pixels (76,67%). Esse estudo destacou que embora a abordagem por pixel seja eficaz, a GEOBIA aproveita melhor a capacidade de análise de características contextuais e espaciais dos dados de alta resolução, resultando em maior precisão, especialmente em áreas urbanas complexas onde a heterogeneidade espectral e espacial é muito alta.

Estoque et al. (2015) também compararam os métodos de classificação por pixel e GEOBIA utilizando imagens de alta e média resolução espacial em paisagens urbanas e suburbanas. Eles observaram que a GEOBIA apresentou um desempenho superior, especialmente em imagens de alta resolução como as do QuickBird, devido à sua capacidade de integrar informações contextuais e reduzir o efeito de “sal e pimental” típico das classificações por pixel. Também notaram que a precisão da GEOBIA pode diminuir em imagens de resolução moderada, como as do Landsat 8, alinhando-se com nossos resultados que indicam uma menor eficiência da GEOBIA em dados de resolução mais grossa. Este comportamento é atribuído à dificuldade de segmentar pequenos objetos em imagens de menor resolução, onde detalhes importantes podem se perder.

Adicionalmente, estudos como os de Myint et al. (2011) e Blaschke et al. (2014) têm mostrado que a classificação orientada a objetos é particularmente útil em aplicações urbanas onde a heterogeneidade das classes de uso e cobertura do solo é alta.

Por exemplo, Myint et al. (2011) encontraram que a abordagem orientada a objetos melhorou a acurácia na classificação de superfícies impermeáveis em áreas urbanas densamente construídas, uma classe que geralmente sofre com a confusão espectral em métodos baseados em pixel. Sendo a possibilidade de considerar tanto a forma quanto a textura dos objetos uma grande vantagem na diferenciação de características urbanas complexas. Blaschke et al. (2014) argumentaram que a abordagem baseada em objetos é mais robusta para análise de dados de alta resolução porque permite a incorporação de variáveis adicionais, como textura e forma, que são importantes para a distinção de classes de uso do solo em ambientes urbanos. Eles destacam que a segmentação de imagens em objetos facilita a inclusão de conhecimento especializado e a utilização de regras contextuais, que são difíceis de implementar em classificações baseadas apenas em pixels.

Ao partimos para dados de resolução moderada, como os do Landsat, estudos como o de Duro et al. (2012) mostraram que, embora a abordagem baseada em objetos possa oferecer certas vantagens, a sua eficácia pode ser limitada pela resolução espacial dos dados. Em áreas rurais e menos heterogêneas a abordagem por pixel pode, de fato, ser mais adequada devido à sua simplicidade e menor necessidade de processamento. Estudos como o de Liu e Xia (2010) indicaram que a abordagem por pixel pode ser eficaz em ambientes homogêneos, onde as classes de uso do solo são bem definidas e possuem pouca variabilidade interna. Isso se alinha com nossos resultados para classes como corpos d'água, onde a abordagem por pixel demonstrou alta acurácia devido à homogeneidade espectral dessa classe.

Portanto, nossos resultados não apenas confirmam a literatura existente, mas também fornecem uma análise detalhada do desempenho relativo das abordagens por pixel e por objetos em diferentes cenários. Sugerindo que a escolha do método de

classificação deve considerar a resolução espacial e as características espectrais do sensor, bem como a heterogeneidade da paisagem alvo. A abordagem por pixel tende a ser mais eficiente para classes de uso e cobertura do solo homogêneas e bem definidas, enquanto a abordagem baseada em objetos se destaca em contextos em que a captura de detalhes texturais e estruturais é possível. Dessa forma, nossos resultados contribuem para um melhor entendimento das aplicações práticas e limitações de cada abordagem, auxiliando na tomada de decisão para o uso apropriado de técnicas de classificação em estudos de uso e cobertura do solo.

2.4.2 Limitações e direções futuras

Uma limitação chave relaciona-se à resolução espacial dos dados. A comparação direta entre imagens de diferentes resoluções espaciais pode ser complexa, pois as características detectadas e classificadas em imagens de alta resolução podem não ser visíveis em imagens de resolução mais baixa. Como observado a eficácia das abordagens varia com a resolução espacial do sensor, porém, quanto melhor a resolução mais ruído é introduzido na imagem.

A análise foi limitada a um pequeno número de classes de uso e cobertura do solo. A inclusão de mais classes, especialmente em áreas urbanas que há grande variabilidade espectral, é limitada em sensores multiespectrais. O uso de variáveis auxiliares, como dados SAR e LIDAR como também informações de sensores hiperespectrais, podem aumentar a acurácia da classificação. A integração desses dados auxiliares pode fornecer informações adicionais sobre a estrutura vertical e composição espectral das classes de uso e cobertura do solo, potencialmente melhorando o desempenho tanto da abordagem baseada em pixel quanto da abordagem baseada em

objeto. Pesquisas futuras devem explorar a integração de múltiplas fontes de dados e inclusão de classes adicionais para enriquecer o processo de classificação.

2.5. CONCLUSÃO

Este estudo contribuiu para o entendimento das aplicações práticas e limitações dos métodos de classificação através de abordagens baseada em pixel e em GEOBIA. A análise detalhada de diferentes classes de uso e cobertura do solo, mostrou que a abordagem baseada em pixel tende a ser mais eficaz em classes homogêneas e bem definidas, enquanto a abordagem baseada em objetos é mais adequada para a captura de detalhes texturais e estruturais em paisagens complexas. A escolha do método de classificação deve ser feita com base na resolução espacial do sensor e nas características específicas da paisagem alvo.

Avanços futuros na integração de técnicas híbridas e o uso de dados auxiliares, tem a capacidade para melhorar a eficiência e acurácia das classificações. Esses desenvolvimentos não apenas aprimorarão as ferramentas para o planejamento e gestão ambiental, mas também contribuirão para um entendimento mais profundo das dinâmicas do uso e cobertura do solo em áreas urbanas em rápida transformação. Com a evolução contínua das tecnologias de sensoriamento remoto e dos algoritmos de classificação, espera-se que futuras pesquisas possam abordar as limitações atuais e expandir as aplicações dessas metodologias em diferentes contextos geográficos e ecológicos.

Os códigos utilizados nas análises de cobertura e uso do solo são escritos em JavaScript e estão disponíveis gratuitamente em https://code.earthengine.google.com/?accept_repo=users/Jhonnattan_Oliveira/Mestrado

2.6. REFERÊNCIAS

AFFAIRS, U. N. D. O. E. A. S. **World Urbanization Prospects: The 2018 Revision**. 2019.

BELGIU, M.; DRAGUT, L. Random forest in remote sensing: A review of applications and future directions. **Isprs Journal of Photogrammetry and Remote Sensing**, 114, p. 24-31, Apr 2016. Review.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, 65, n. 1, p. 2-16, 2010. Short Survey.

BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S. *et al.* Geographic Object-Based Image Analysis - Towards a new paradigm. **Isprs Journal of Photogrammetry and Remote Sensing**, 87, p. 180-191, Jan 2014. Article.

CONNERS, R. W.; TRIVEDI, M. M.; HARLOW, C. A. SEGMENTATION OF A HIGH-RESOLUTION URBAN SCENE USING TEXTURE OPERATORS. **Computer Vision Graphics and Image Processing**, 25, n. 3, p. 273-310, 1984.

DENG, J. S.; WANG, K.; DENG, Y. H.; QI, G. J. PCA-based land-use change detection and analysis using multitemporal and multisensor satellite data. **International Journal of Remote Sensing**, 29, n. 16, p. 4823-4838, 2008. Article.

DURO, D. C.; FRANKLIN, S. E.; DUBÉ, M. G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, v. 118, p. 259-272, 2012. Article.

ESTOQUE, R. C., MURAYAMA, Y., & AKIYAMA, C. M. (2015). Pixel-based and object-based classifications using high- and medium-spatial-resolution imageries in the urban and suburban landscapes. **Geocarto International**, 30(10), 1113–1129. Article.

FENG, B. Y.; ZHANG, Y.; BOURKE, R. Urbanization impacts on flood risks based on urban growth data and coupled flood models. **Natural Hazards**, 106, n. 1, p. 613-627, Mar 2021. Article.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, 202, p. 18-27, Dec 2017. Article.

GUAN, H. Y.; LEI, X. D.; YU, Y. T.; ZHAO, H. H. *et al.* Road marking extraction in UAV imagery using attentive capsule feature pyramid network. **International Journal of Applied Earth Observation and Geoinformation**, 107, p. 13, Mar 2022. Article.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. TEXTURAL FEATURES FOR IMAGE CLASSIFICATION. **Ieee Transactions on Systems Man and Cybernetics**, SMC3, n. 6, p. 610-621, 1973. Article.

HEROLD, M.; LIU, X. H.; CLARKE, K. C. Spatial metrics and image texture for mapping urban land use. **Photogrammetric Engineering and Remote Sensing**, 69, n. 9, p. 991-1001, Sep 2003. Article.

HERNANDEZ, I. E. R.; SHI, W. Z. A Random Forests classification method for urban land-use mapping integrating spatial metrics and texture analysis. **International Journal of Remote Sensing**, 39, n. 4, p. 1175-1198, 2018. Article.

HOSSAIN, M. D.; CHEN, D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. **Isprs Journal of Photogrammetry and Remote Sensing**, 150, p. 115-134, Apr 2019. Review.

INGEBRITSEN, S. E.; LYON, R. J. P. PRINCIPAL COMPONENTS-ANALYSIS OF MULTITEMPORAL IMAGE PAIRS. **International Journal of Remote Sensing**, 6, n. 5, p. 687-696, 1985. Article.

JEBUR, M. N., MOHD SHAFRI, H. Z., PRADHAN, B., & TEHRANY, M. S. (2013). Per-pixel and object-oriented classification methods for mapping urban land cover extraction using SPOT 5 imagery. **Geocarto International**, 29(7), 792–806. Article.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective 2/e**. Pearson Education, 2009. 9788131716809.

KADHIM, N.; MOURSHED, M.; BRAY, M. Advances in remote sensing applications for urban sustainability. **Euro-Mediterranean Journal for Environmental Integration**, 1, 09/22 2016.

LAMBIN, E. F.; MEYFROIDT, P. Global land use change, economic globalization, and the looming land scarcity. **Proceedings of the National Academy of Sciences of the United States of America**, 108, n. 9, p. 3465-3472, Mar 2011. Article.

LI, X.; YEH, A. G. O. Principal component analysis of stacked multi-temporal images for the monitoring of rapid urban expansion in the Pearl River Delta. **International Journal of Remote Sensing**, 19, n. 8, p. 1501-1518, May 1998. Article.

LIU, D., & XIA, F. (2010). Assessing object-based classification: advantages and limitations. **Remote Sensing Letters**, 1(4), 187–194. Article.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, 28, n. 5, p. 823-870, 2007. Review.

MCDONALD, R. I.; GREEN, P.; BALK, D.; FEKETE, B. M. *et al.* Urban growth, climate change, and freshwater availability. **Proceedings of the National Academy of Sciences of the United States of America**, 108, n. 15, p. 6312-6317, Apr 2011. Article.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425-1432, 1996.

MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S. *et al.* Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. **Remote Sensing of Environment**, 115, n. 5, p. 1145-1161, 2011. Article.

MYINT, S. W.; LAM, N. S. N.; TYLER, J. M. Wavelets for urban spatial feature discrimination: Comparisons with fractal, spatial autocorrelation, and spatial co-occurrence approaches. **Photogrammetric Engineering and Remote Sensing**, 70, n. 7, p. 803-812, Jul 2004. Article.

OUMA, Y. O.; KEITSILE, A.; NKWAE, B.; ODIRILE, P. *et al.* Urban land-use classification using machine learning classifiers: comparative evaluation and post-classification multi-feature fusion approach. **European Journal of Remote Sensing**, 56, n. 1, p. 21, Dec 2023. Article.

PARANHOS FILHO, A.; MIOTO, C.; PESSI, D.; GAMARRA, R. *et al.* **Geotecnologias para Aplicações Ambientais**. 2021. 9786586010626.

PAULEIT, S.; DUHME, F. Assessing the environmental performance of land cover types for urban planning. **Landscape and Urban Planning**, 52, n. 1, p. 1-20, Nov 2000. Article.

QIAO, L.; HUANG, H. P.; TIAN, Y. C. The Identification and Use Efficiency Evaluation of Urban Industrial Land Based on Multi-Source Data. **Sustainability**, 11, n. 21, p. 17, Nov 2019. Article.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: **Proceedings of the Third Earth Resources Technology Satellite-1 Symposium**, Washington, D.C., p. 309-317, 1974. NASA SP-351.

SUN, J.; WANG, H.; SONG, Z. L.; LU, J. B. *et al.* Mapping Essential Urban Land Use Categories in Nanjing by Integrating Multi-Source Big Data. **Remote Sensing**, 12, n. 15, p. 18, Aug 2020. Article.

SETO, K. C.; GÜNERALP, B.; HUTYRA, L. R. Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. **Proceedings of the National Academy of Sciences of the United States of America**, 109, n. 40, p. 16083-16088, Oct 2012. Article.

SMALL, C. A global analysis of urban reflectance. **International Journal of Remote Sensing**, 26, n. 4, p. 661-681, Feb 2005. Article; Proceedings Paper.

TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M.; QUACKENBUSH, L. *et al.* Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **Isprs Journal of Photogrammetry and Remote Sensing**, 164, p. 152-170, Jun 2020. Review.

UDDIN, M. P.; AL MAMUN, M. A.; HOSSAIN, M. A. PCA-based Feature Reduction for Hyperspectral Remote Sensing Image Classification. **Iete Technical Review**, 38, n. 4, p. 377-396, Jul 2021. Review.

UNITED NATIONS, Department of Economic and Social Affairs, Population Division. World Urbanization Prospects: The 2018 Revision (ST/ESA/SER.A/420). New York: United Nations, 2019.

WANG, X. X.; SHI, R. T.; ZHOU, Y. Dynamics of urban sprawl and sustainable development in China. **Socio-Economic Planning Sciences**, 70, p. 13, Jun 2020. Article.

XIAN, G.; CRANE, M. Assessments of urban growth in the Tampa Bay watershed using remote sensing data. **Remote Sensing of Environment**, 97, n. 2, p. 203-215, Jul 2005. Article.

ZHANG, Y. T.; LI, Q. Q.; TU, W.; MAI, K. *et al.* Functional urban land use recognition integrating multi-source geospatial data and cross-correlations. **Computers Environment and Urban Systems**, 78, p. 11, Nov 2019. Article.

ZHAO, X.; XIA, N.; LI, M. C.; XU, Y. Y. Mapping urban land type with multi-source geospatial big data: a case study of Shenzhen, China. **Journal of Maps**, 19, n. 1, p. 11, Dec 2023. Article.

CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma análise comparativa do desempenho de diferentes abordagens classificadoras, especificamente os métodos por pixel e GEOBIA, em ambientes urbanos de alta heterogeneidade e complexidade. A dissertação abordou tanto uma perspectiva bibliométrica do uso do sensoriamento remoto na classificação do uso e cobertura do solo urbano quanto uma avaliação prática dos métodos classificadores.

A análise comparativa demonstrou que a resolução espacial das imagens influencia a acurácia das classificações, com sensores de resolução espacial mais alta proporcionando classificações mais precisas. Este resultado é coerente com a literatura existente, que aponta a resolução espacial como um fator determinante na captura de detalhes necessários para uma representação mais fiel da verdade de campo.

O estudo explorou como as abordagens por pixel e GEOBIA se comportam em ambientes urbanos, destacando as vantagens e limitações de cada método, e fornece uma base científica para a escolha da abordagem mais adequada para ambientes urbanos, contribuindo para o desenvolvimento de técnicas precisas e eficientes para a gestão urbana.

A principal contribuição científica deste trabalho reside na comparação detalhada entre as abordagens por pixel e GEOBIA, utilizando dados de alta e média resolução dos satélites Landsat 8, Sentinel-2 e WorldView-2. A análise bibliométrica realizada no primeiro capítulo mapeou a produção científica na área, identificando padrões de publicação, principais autores, instituições e periódicos de destaque, o que fornece uma visão do estado atual da pesquisa em sensoriamento remoto aplicado à classificação do uso e cobertura do solo urbano.

No segundo capítulo, a avaliação prática das técnicas de classificação demonstrou que a abordagem por pixel tende a apresentar maior precisão em imagens de alta resolução, enquanto a GEOBIA é mais eficaz na identificação de padrões texturais em ambientes urbanos complexos. Essa dualidade sugere que a combinação de ambas as técnicas pode otimizar a classificação do uso e cobertura do solo em contextos urbanos.

REFERÊNCIAS

- BASHEER, S.; WANG, X. Q.; FAROOQUE, A. A.; NAWAZ, R. A. *et al.* Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. **Remote Sensing**, 14, n. 19, p. 18, Oct 2022.
- BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S. *et al.* Geographic Object-Based Image Analysis - Towards a new paradigm. **Isprs Journal of Photogrammetry and Remote Sensing**, 87, p. 180-191, Jan 2014. Article.
- GEORGANOS, S.; GRIPPA, T.; VANHUYSSE, S.; LENNERT, M. *et al.* Very High Resolution Object-Based Land Use-Land Cover Urban Classification Using Extreme Gradient Boosting. **Ieee Geoscience and Remote Sensing Letters**, 15, n. 4, p. 607-611, Apr 2018.
- GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, 202, p. 18-27, Dec 2017. Article.
- HU, T. Y.; YANG, J.; LI, X. C.; GONG, P. Mapping Urban Land Use by Using Landsat Images and Open Social Data. **Remote Sensing**, 8, n. 2, p. 18, Feb 2016.
- HUANG, B.; ZHAO, B.; SONG, Y. M. Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery. **Remote Sensing of Environment**, 214, p. 73-86, Sep 2018.
- LI, C. C.; WANG, J.; WANG, L.; HU, L. Y. *et al.* Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. **Remote Sensing**, 6, n. 2, p. 964-983, Feb 2014.
- PHAN, T. N.; KUCH, V.; LEHNERT, L. W. Land Cover Classification using Google Earth Engine and Random Forest Classifier-The Role of Image Composition. **Remote Sensing**, 12, n. 15, p. 22, Aug 2020.
- ZHANG, F.; YANG, X. J. Improving land cover classification in an urbanized coastal area by random forests: The role of variable selection. **Remote Sensing of Environment**, 251, p. 14, Dec 2020.

ANEXO I

Landsat 8		Conjunto de dados 1						Conjunto de dados 2						Conjunto de dados 3					
		Pixel			Geobia			Pixel			Geobia			Pixel			Geobia		
		Acurácia global holdout		0,81	Acurácia global holdout		0,74	Acurácia global holdout		0,73	Acurácia global holdout		0,67	Acurácia global holdout		0,81	Acurácia global holdout		0,74
		Acurácia global K-fold		0,80	Acurácia global K-fold		0,74	Acurácia global K-fold		0,72	Acurácia global K-fold		0,72	Acurácia global K-fold		0,85	Acurácia global K-fold		0,84
Cobertura do solo		PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore
Água	Holdout	0,931	0,944	0,937	0,91	0,943	0,926	0,883	0,895	0,889	0,897	0,897	0,897	0,938	0,964	0,951	0,904	0,942	0,923
	K-fold	0,935	0,962	0,948	0,950	0,933	0,941	0,895	0,929	0,912	0,893	0,919	0,906	0,941	0,968	0,954	0,935	0,956	0,945
Vegetação Rasteira	Holdout	0,894	0,808	0,849	0,76	0,662	0,708	0,845	0,816	0,830	0,760	0,658	0,705	0,866	0,803	0,833	0,774	0,670	0,718
	K-fold	0,819	0,821	0,819	0,728	0,743	0,735	0,790	0,830	0,809	0,789	0,829	0,807	0,844	0,855	0,849	0,836	0,845	0,840
Vegetação Arbórea	Holdout	0,727	0,794	0,759	0,572	0,659	0,612	0,656	0,689	0,672	0,548	0,659	0,598	0,727	0,769	0,747	0,614	0,666	0,639
	K-fold	0,704	0,746	0,724	0,545	0,626	0,579	0,664	0,672	0,668	0,666	0,675	0,670	0,843	0,862	0,852	0,837	0,863	0,850
Pavimento	Holdout	0,660	0,634	0,647	0,506	0,531	0,518	0,626	0,602	0,614	0,380	0,401	0,390	0,640	0,662	0,650	0,453	0,544	0,494
Asfáltico	K-fold	0,685	0,661	0,671	0,554	0,533	0,541	0,539	0,557	0,546	0,546	0,549	0,546	0,761	0,739	0,748	0,765	0,737	0,748
Edificações	Holdout	0,664	0,715	0,688	0,600	0,608	0,604	0,457	0,507	0,481	0,421	0,472	0,445	0,685	0,727	0,705	0,600	0,571	0,585
	K-fold	0,699	0,713	0,706	0,610	0,604	0,605	0,482	0,519	0,497	0,486	0,530	0,504	0,746	0,765	0,753	0,737	0,766	0,747
Solo Exposto	Holdout	0,887	0,868	0,878	0,887	0,857	0,871	0,838	0,767	0,801	0,859	0,835	0,847	0,901	0,853	0,876	0,887	0,857	0,871
	K-fold	0,866	0,841	0,852	0,885	0,860	0,872	0,844	0,794	0,818	0,830	0,795	0,811	0,866	0,872	0,869	0,866	0,866	0,866
Sombra	Holdout	0,915	0,903	0,909	0,96	0,901	0,930	0,823	0,823	0,823	0,882	0,758	0,815	0,934	0,893	0,913	0,960	0,901	0,930
	K-fold	0,937	0,897	0,916	0,934	0,896	0,914	0,873	0,769	0,817	0,861	0,763	0,808	0,954	0,897	0,925	0,942	0,889	0,915

Figura 1 - Comparação da acurácia de classificação de uso e cobertura do solo entre os métodos por pixel e GEOBIA utilizando dados do satélite Landsat 8.

Sentinel 2		Conjunto de dados 1						Conjunto de dados 2						Conjunto de dados 3					
		Pixel			Geobia			Pixel			Geobia			Pixel			Geobia		
		Acurácia global holdout		0,90	Acurácia global holdout		0,83	Acurácia global holdout		0,81	Acurácia global holdout		0,76	Acurácia global holdout		0,90	Acurácia global holdout		0,85
		Acurácia global K-fold		0,90	Acurácia global K-fold		0,90	Acurácia global K-fold		0,80	Acurácia global K-fold		0,80	Acurácia global K-fold		0,90	Acurácia global K-fold		0,84
Cobertura do solo		PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore
Água	Holdout	0,938	0,978	0,958	0,931	0,964	0,947	0,897	0,942	0,919	0,876	0,948	0,911	0,945	0,971	0,958	0,904	0,942	0,923
	K-fold	0,957	0,980	0,968	0,955	0,978	0,966	0,899	0,943	0,920	0,909	0,943	0,926	0,957	0,980	0,968	0,935	0,956	0,945
Vegetação Rasteira	Holdout	0,950	0,906	0,927	0,929	0,904	0,916	0,964	0,856	0,907	0,894	0,819	0,855	0,959	0,906	0,927	0,774	0,670	0,718
	K-fold	0,930	0,920	0,925	0,920	0,914	0,917	0,923	0,857	0,888	0,919	0,873	0,895	0,934	0,915	0,924	0,836	0,845	0,840
Vegetação Arbórea	Holdout	0,891	0,93	0,910	0,867	0,842	0,854	0,867	0,894	0,88	0,801	0,847	0,823	0,891	0,925	0,907	0,614	0,666	0,639
	K-fold	0,926	0,882	0,903	0,922	0,891	0,906	0,884	0,882	0,883	0,892	0,873	0,882	0,920	0,889	0,904	0,837	0,863	0,850
Pavimento	Holdout	0,860	0,889	0,874	0,800	0,750	0,774	0,753	0,719	0,736	0,706	0,650	0,677	0,880	0,916	0,897	0,453	0,544	0,494
Asfáltico	K-fold	0,877	0,875	0,875	0,882	0,879	0,879	0,802	0,742	0,767	0,805	0,736	0,765	0,887	0,874	0,879	0,765	0,737	0,748
Edificações	Holdout	0,835	0,818	0,826	0,671	0,728	0,698	0,628	0,671	0,649	0,464	0,507	0,485	0,857	0,839	0,848	0,600	0,571	0,585
	K-fold	0,835	0,827	0,831	0,848	0,828	0,838	0,653	0,690	0,670	0,628	0,693	0,657	0,852	0,835	0,843	0,737	0,766	0,747
Solo Exposto	Holdout	0,887	0,919	0,903	0,866	0,897	0,881	0,894	0,846	0,869	0,838	0,815	0,826	0,915	0,902	0,909	0,887	0,857	0,871
	K-fold	0,888	0,921	0,904	0,888	0,913	0,900	0,849	0,853	0,851	0,855	0,841	0,847	0,891	0,935	0,912	0,866	0,866	0,866
Sombra	Holdout	0,947	0,873	0,909	0,908	0,896	0,902	0,686	0,744	0,714	0,777	0,767	0,772	0,915	0,891	0,903	0,960	0,901	0,930
	K-fold	0,895	0,905	0,899	0,887	0,902	0,894	0,655	0,699	0,675	0,660	0,702	0,679	0,890	0,906	0,897	0,942	0,889	0,915

Figura 2 - Comparação da acurácia de classificação de uso e cobertura do solo entre os métodos por pixel e GEOBIA utilizando dados do satélite Sentinel-2.

WorldView 2		Conjunto de dados 1						Conjunto de dados 2						Conjunto de dados 3					
		Pixel			Geobia			Pixel			Geobia			Pixel			Geobia		
		Acurácia global holdout		0,95	Acurácia global holdout		0,95	Acurácia global holdout		0,95	Acurácia global holdout		0,95	Acurácia global holdout		0,96	Acurácia global holdout		0,95
		Acurácia global K-fold		0,96	Acurácia global K-fold		0,96	Acurácia global K-fold		0,95	Acurácia global K-fold		0,96	Acurácia global K-fold		0,96	Acurácia global K-fold		0,96
Cobertura do solo		PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore	PA	UA	Fscore
Água	Holdout	0,938	0,971	0,954	0,938	0,978	0,958	0,958	0,939	0,949	0,972	0,934	0,953	0,965	0,965	0,965	0,938	0,971	0,954
	K-fold	0,940	0,972	0,955	0,944	0,972	0,957	0,958	0,974	0,966	0,962	0,973	0,967	0,958	0,976	0,967	0,956	0,976	0,966
Vegetação Rasteira	Holdout	0,971	0,978	0,975	0,978	0,972	0,975	0,957	0,971	0,964	0,978	0,978	0,978	0,985	0,958	0,972	0,985	0,972	0,979
	K-fold	0,972	0,984	0,978	0,970	0,988	0,979	0,972	0,980	0,976	0,980	0,986	0,983	0,976	0,978	0,977	0,972	0,984	0,978
Vegetação Arbórea	Holdout	0,981	0,976	0,978	0,975	0,987	0,981	0,975	0,970	0,972	0,981	0,987	0,984	0,963	0,987	0,975	0,981	0,987	0,984
	K-fold	0,986	0,979	0,982	0,988	0,981	0,984	0,980	0,977	0,979	0,986	0,984	0,985	0,982	0,981	0,982	0,988	0,979	0,984
Pavimento Asfáltico	Holdout	0,980	0,986	0,983	0,973	0,986	0,979	0,960	0,979	0,969	0,946	0,986	0,965	0,980	1	0,989	0,980	1	0,989
	K-fold	0,980	0,994	0,987	0,978	0,989	0,983	0,978	0,987	0,982	0,974	0,989	0,982	0,980	0,990	0,985	0,978	0,992	0,985
Edificações	Holdout	0,935	0,922	0,929	0,907	0,900	0,903	0,900	0,947	0,923	0,900	0,919	0,909	0,942	0,936	0,939	0,900	0,933	0,916
	K-fold	0,941	0,926	0,933	0,931	0,923	0,926	0,915	0,925	0,919	0,927	0,936	0,930	0,939	0,926	0,932	0,945	0,929	0,936
Solo Exposto	Holdout	0,929	0,936	0,932	0,922	0,909	0,916	0,964	0,907	0,935	0,950	0,906	0,927	0,943	0,943	0,943	0,943	0,911	0,927
	K-fold	0,932	0,938	0,935	0,938	0,931	0,934	0,934	0,917	0,925	0,945	0,929	0,936	0,933	0,942	0,937	0,937	0,948	0,942
Sombra	Holdout	0,973	0,943	0,958	0,980	0,943	0,961	0,967	0,973	0,970	0,954	0,973	0,963	0,973	0,961	0,967	0,980	0,937	0,958
	K-fold	0,983	0,944	0,963	0,979	0,949	0,964	0,980	0,961	0,970	0,980	0,963	0,971	0,983	0,960	0,971	0,987	0,958	0,972

Figura 3 - Comparação da acurácia de classificação de uso e cobertura do solo entre os métodos por pixel e GEOBIA utilizando dados do satélite WorldView 2.

ANEXO II

Landsat 8				Sentinel 2				WorldView 2			
Bandas	Pixel	Bandas	Geobia	Bandas	Pixel	Bandas	Geobia	Bandas	Pixel	Bandas	Geobia
B7	4,178	B1	3,432	NDWI	4,312	B12	4,149	B3	6,766	B5	7,105
B11	3,658	B11	3,375	B12	4,187	NDWI	3,845	B5	6,493	B1	6,625
B1	3,582	B10	3,319	NDVI	4,175	NDVI	3,8	B1	6,442	B3	6,122
B6	3,538	B7	3,252	B1	4,117	B2	3,74	B2	6,21	B2	5,644
B8	3,519	B2	3,158	B11	3,781	Gradiente	3,676	pc1	5,763	B4	5,316
NDVI	3,465	B5_savg	3,121	B4	3,754	B11	3,62	B4	5,377	pc1	5,145
B10	3,453	NDVI	3,099	B2	3,723	B1	3,523	NDVI	4,585	NDVI	4,478
NDWI	3,372	B6	3,096	B8A	3,528	B4	3,509	pc5	4,484	B6	4,185
B3	3,371	B5_shade	3,078	B9	3,396	B5	3,407	pc2	4,271	pc2	3,95
B4	3,362	B5	3,054	B7	3,333	B3	3,376	B6	4,162	pc5	3,903
B2	3,329	B4	3,037	B3	3,299	B9	3,333	pc4	3,696	NDWI	3,614
B5_savg	3,272	Gradiente	3,019	Gradiente	3,287	pc2	3,208	pc3	3,577	pc4	3,428
B5	3,217	NDWI	3,009	B8_savg	3,281	B8A	3,085	NDWI	3,363	pc3	3,422
pc5	3,109	B3	2,938	B5	3,22	B8_savg	2,996	B7_savg	3,006	B7	3,094
pc2	2,998	B9	2,937	B8	3,218	B6	2,984	B7	2,681	B8	3,053
Gradiente	2,84	B8	2,913	pc2	2,973	B8	2,964	B8	2,601	B7_savg	2,989
B5_shade	2,759	pc5	2,894	B6	2,957	B8_corr	2,845	Gradiente	2,32	Gradiente	2,412
B5_corr	2,697	pc2	2,839	B8_dvar	2,917	B7	2,805	B7_dvar	1,852	B7_corr	1,767
pc4	2,563	B5_corr	2,748	pc3	2,89	pc4	2,761	B7_shade	1,803	B7_diss	1,749
B5_dvar	2,526	B5_idm	2,696	B8_shade	2,858	B8_shade	2,74	B7_var	1,766	B7_dvar	1,72
B9	2,497	B5_sent	2,695	B8_diss	2,684	B8_idm	2,723	B7_corr	1,703	B7_inertia	1,702
pc3	2,478	B5_dvar	2,626	pc4	2,614	pc5	2,658	B7_imcorr	1,688	B7_imcorr	1,7
pc1	2,457	B5_dent	2,618	B8_inertia	2,605	pc3	2,6	B7_prom	1,636	B7_contra	1,696
B5_diss	2,449	B5_imcorr	2,567	pc1	2,556	B8_dvar	2,586	B7_svar	1,601	B7_shade	1,693
B5_prom	2,418	pc4	2,547	pc5	2,551	B8_diss	2,528	B7_diss	1,504	B7_imcorr	1,645
B5_var	2,415	B5_var	2,513	B8_svar	2,537	pc1	2,515	B7_idm	1,486	B7_ent	1,56
B5_idm	2,413	B5_asm	2,487	B8_idm	2,533	B8_inertia	2,51	B7_imcorr	1,446	B7_sent	1,558
B5_svar	2,384	B5_imcorr	2,397	B8_contra	2,503	B8_var	2,479	B7_inertia	1,376	B7_idm	1,555
B5_imcorr	2,257	B5_svar	2,392	B8_prom	2,502	B8_contra	2,476	B7_dent	1,373	B7_var	1,544
B5_contra	2,235	B5_inertia	2,351	B8_var	2,456	B8_prom	2,448	B7_ent	1,344	B7_prom	1,493
B5_inertia	2,202	B5_ent	2,327	B8_corr	2,385	B8_svar	2,307	B7_contra	1,338	B7_dent	1,438
B5_dent	2,119	pc3	2,31	B8_imcorr	1,375	B8_dent	1,198	B7_asm	1,173	B7_asm	1,39
B5_imcorr	1,98	B5_diss	2,308	B8_imcorr	0,421	B8_imcorr	1,119	B7_sent	1,113	B7_svar	1,304
B5_asm	1,748	pc1	2,304	B8_asm	0,357	B8_imcorr	1,04	B7_maxco	0	B7_maxco	0
B5_ent	1,608	B5_contra	2,285	B8_dent	0,333	B8_asm	0,966				
B5_sent	1,533	B5_prom	2,261	B8_ent	0,237	B8_ent	0,7731				
B5_maxco	0	B5_maxco	0	B8_sent	0,142	B8_sent	0,748				
				B8_maxco	0	B8_maxco	0				

Figura 4 - Comparação das Importâncias das Bandas e Variáveis Derivadas para Classificação de Uso e Cobertura do Solo nos Satélites Landsat 8, Sentinel-2 e WorldView 2 utilizando Métodos por Pixel e GEOBIA.