








Geo-Sciences

Análise de acurácia do mapeamento do uso e ocupação do solo utilizando imagens Sentinel-2 e CBERS-4 no entorno de reservatórios

Accuracy analysis of mapping land use and occupation using Sentinel-2 and CBERS-4 images in the surroundings of a reservoirs

Juarez Antônio da Silva Júnior¹ , Ubiratan Joaquim da Silva Junior¹ ,
Débora Natália Oliveira de Almeida¹ , Anderson Luiz Ribeiro de Paiva¹ ,
Ester Milena dos Santos¹ , Sylvana Melo dos Santos¹ ,
Leidjane Maria Maciel de Oliveira¹ 

¹ Universidade Federal de Pernambuco, Recife, PE, Brasil

RESUMO

A detecção de mudanças na cobertura do solo ajuda os formuladores de políticas a entender a dinâmica das mudanças ambientais para garantir o desenvolvimento sustentável no bioma Caatinga. Assim, a identificação de características espaciais por Sensoriamento Remoto surgiu como um importante aspecto de pesquisa e, dessa forma, metodologia adequada e eficiente para o mapeamento de cobertura do solo necessárias é fator preponderante. Neste estudo, os dados do satélite Sentinel-2 e CBERS-4 capturados pelos sensores MultiSpectral Instrument (MSI) e a Câmera Pancromática e Multiespectral (PAN), respectivamente, foram usados para a classificação e análise de acurácia para cinco classes de cobertura da terra no entorno de Barragens localizados no município de Belo Jardim, Pernambuco. O algoritmo KNN (K-ésimo vizinho mais próximo) com um valor de $k=1$ foi utilizado para o treinamento e classificação das imagens. As recentes imagens de alta resolução do programa europeu WorldCover foram utilizadas como imagem de referência espacial e temática. Após a análise por Matrix Contingência entre os mapas de cobertura do solo e os dados de referência, foram obtidos uma acurácia global de 57,4% para o MSI e 54,5% para o produto PAN. Os resultados obtidos mostraram que o MSI apresentou mapas de cobertura da terra mais satisfatórias do que os dados PAN. Por outro lado, para a classe de vegetação arbustiva para o produto PAN apresentou r de 0,5 enquanto o MSI de 0,47. Características espaciais e espectrais das imagens foram os principais causadores das variabilidades encontradas nos coeficientes de acurácia temática.

Palavras-chave: Sensoriamento Remoto; Aprendizagem de Máquinas; Reservatório Pedro Mauro Junior

ABSTRACT

Detecting changes in land cover helps policymakers understand the dynamics of environmental changes to ensure sustainable development in the Caatinga biome. Thus, the identification of spatial characteristics by Remote Sensing has emerged as an important aspect of research, and, therefore, adequate and efficient methodology for mapping the necessary land cover is a preponderant factor. In this study, data from the Sentinel-2 and CBERS-4 satellites captured by the MultiSpectral Instrument (MSI) and Panchromatic and Multispectral Camera (PAN) sensors, respectively, were used for classification and accuracy analysis for five land cover classes around dams located in the municipality of Belo Jardim, Pernambuco. The KNN algorithm (K-th nearest neighbor) with a value of $k=1$ was used for image training and classification. Recent high-resolution images from the European program WorldCover were used as a spatial and thematic reference image. After the Contingency Matrix analysis between the land cover maps and the reference data, an overall accuracy of 57.4% was obtained for the MSI and 54.5% for the PAN product. The results obtained showed that the MSI presented more satisfactory land cover maps than the PAN data. On the other hand, for the shrubby vegetation class, the PAN product presented an r of 0.5, while the MSI had an r of 0.47. Spatial and spectral characteristics of the images were the main causes of the variability found in the thematic accuracy coefficients.

Keywords: Remote Sensing; Machine Learning; Pedro Mauro Junior Reservoir

1 INTRODUÇÃO

As mudanças no uso e cobertura da terra em áreas rurais e urbanas conectadas são uma das principais consequências da mudança ambiental global, que é impulsionada pelo crescimento populacional, colocando sob pressão o uso tradicional da terra, bem como a cobertura da terra e os serviços ecossistêmicos relacionados (Nguyen *et al.* 2023; Hu *et al.* 2021). O Nordeste do Brasil, particularmente a região Semiárida, está geralmente sujeito às variabilidades de regimes hidrológicos, o que pode proporcionar mudanças no cenário da vegetação decorrente da construção de reservatórios artificiais, responsáveis pelo armazenamento de água, amortecimento do rio, recarga de águas subterrâneas, retenção de sedimentos, purificação da água e regulação do microclima (Junk *et al.*, 2013). Esse fato ocorre com intensidade nestas áreas, devido principalmente as altas temperaturas e a elevada taxa de evapotranspiração (França *et al.* 2019). Sob condições extremas de seca, a falta de água pode afetar o ecossistema de tal forma que proporciona uma mudança de regime (desertificação) Hughes *et al.* (2013), e a ausência de cobertura vegetal.

Dados derivados de Sensoriamento Remoto tornam-se uma solução que possibilita o fornecimento de subsídios para detecção, monitoramento, modelagem e validação das informações da cobertura da terra de forma periódica e consistente a nível local e global (Mercier *et al.* 2020). Também, com os avanços significativos em modelagens computacionais, armazenamento e compartilhamento de informações em nuvem, mais estudos regionais e globais têm usado como fonte de informação de dados derivados de SR, através de produtos existentes, ou propondo novas modelagens, para atender perspectivas ainda não contempladas Naikoo *et al.* (2020), a exemplo das classificações de imagem por meio de aprendizagem por meio de algoritmos de máquina aplicadas a imagens de média resolução espacial.

Os algoritmos de classificação de imagens de satélite por aprendizado de máquina, como Máquina de Vetor de Suporte (SVM), Máquina de Aprendizado Extremo (ELM) e Máquina de Aprendizado Extremo de Kernel (KELM), tradicionalmente se baseiam apenas em informações espectrais dos sensores para cada alvo. No entanto, aprimorar a precisão da classificação requer a incorporação de informações espaciais e dados de referência oficiais, especialmente em ambientes complexos como as florestas sazonalmente secas, como a Caatinga. Nesses ambientes, a baixa precipitação pode resultar na perda de vigor da vegetação, levando a uma caracterização de mistura espectral entre pixels de vegetação e solo exposto. Por isso, a combinação de informações espectrais e espaciais pode ampliar significativamente a acurácia na determinação do pertencimento de um alvo a uma determinada classe.

As técnicas de aprendizado supervisionado têm se destacado nesse contexto, mostrando uma capacidade significativa de extrair informações espaciais de imagens brutas em regiões áridas e semiáridas (Liu *et al.*, 2019; Gibril *et al.*, 2016). Essas abordagens não só levam em consideração as características espectrais das imagens, mas também a distribuição espacial dos pixels, permitindo uma classificação mais precisa e detalhada dos diferentes alvos presentes na cena.

Dentre os estudos que realizaram processos de análises de mapeamento do

uso do solo, por meio de algoritmos de classificação por aprendizagem de máquina destacam-se: Nguyen *et al.* (2023), que analisaram a extensão das mudanças de uso e cobertura do solo das montanhas do Alto Atlas do Marrocos; Shrestha *et al.* (2023) que quantificaram a dinâmica de mudança da expansão urbana construída no Alabama ao longo das últimas décadas, centrando sua atenção nas dez cidades com as maiores populações e; Masoleli *et al.* (2021) que avaliaram o desempenho de várias abordagens de aprendizado profundo, em um conjunto de dados de teste realizado para classificar a vegetação após o desmatamento tropical, usando as informações espaciais e temporais de séries temporais densas de imagens do satélite Landsat na República do Congo.

Neste contexto os objetivos foram analisar a qualidade temática dos mapas de cobertura do solo obtidos por imagens multiespectrais das plataformas Sentinel-2/MSI e CBERS-4/PAN diante das respectivas diferenças técnicas e avaliar o efeito dos hiperparâmetros de entrada do Classificador *k-nearest neighbors* na classificação da cobertura da terra.

2 MATERIAIS E MÉTODOS

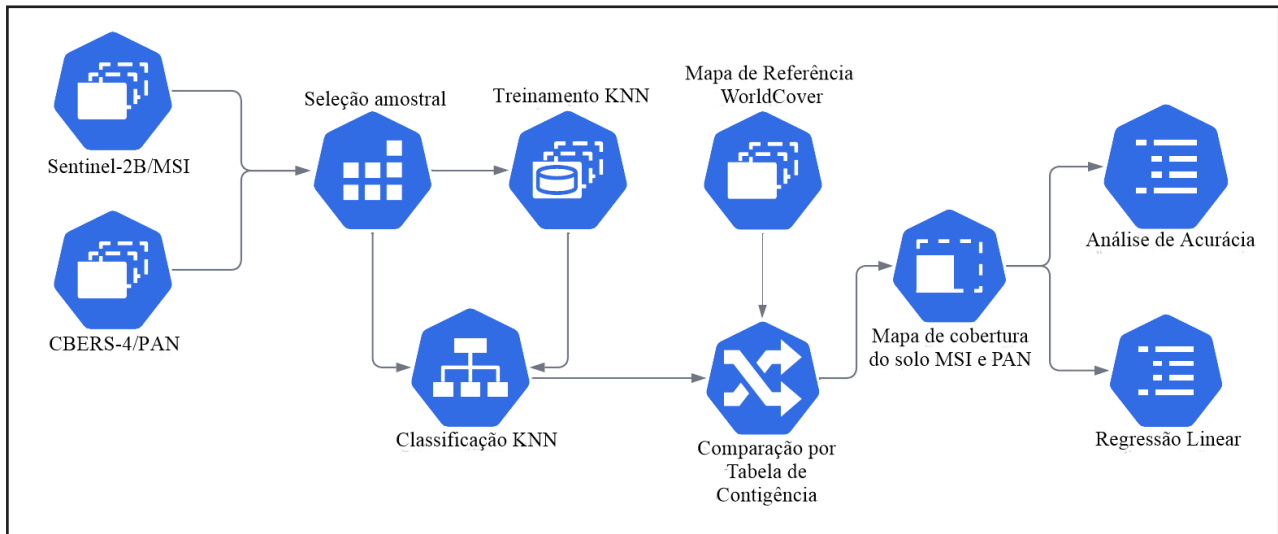
2.1 Fluxograma

A metodologia que compõe o desenvolvimento dos dados compreende as seguintes etapas: i. Aquisição dos dados orbitais; ii. Processamento iii. Análise da qualidade dos mapas. A Figura 1, apresenta o fluxograma metodológico.

2.1 Área de estudo

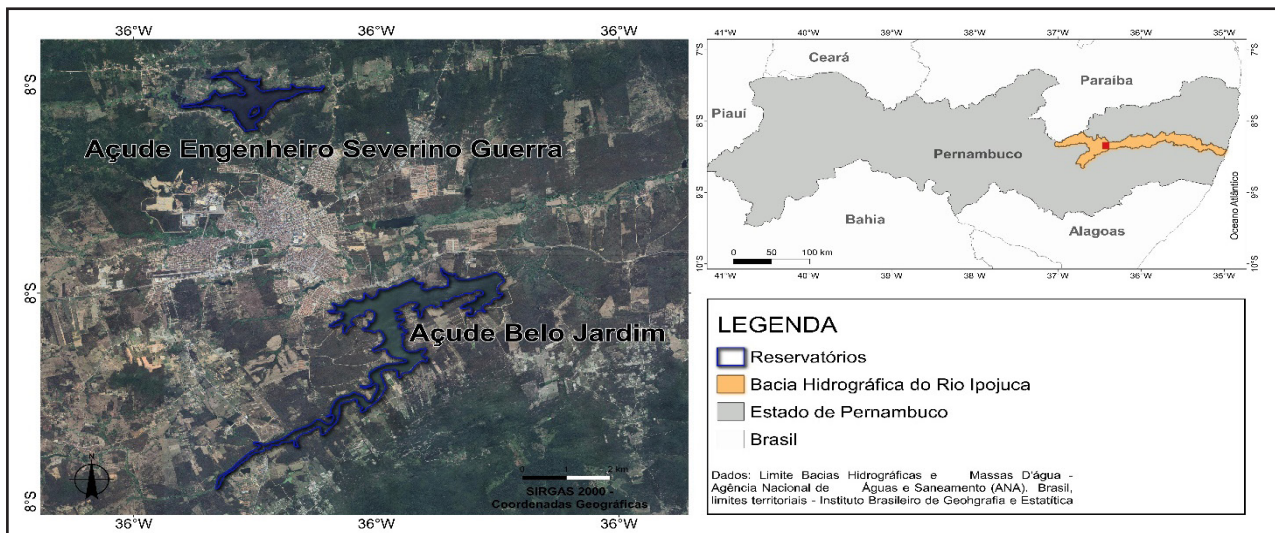
A área de estudo compreende a Barragem Pedro Moura Júnior (Figura 2), localizada na zona rural do município de Belo Jardim - Pernambuco - Brasil, foi construída em 1982 pelo Departamento de Obras Contra as Secas (DNOCS) tendo como finalidade inicial a irrigação de terras à montante e à jusante. O reservatório está inserido na bacia hidrográfica do Rio Ipojuca, possui uma área de 3.435,34 km², correspondendo a 3,49% da área do Estado (APAC, 2023).

Figura 1 – Fluxograma da classificação e análise dos mapas de cobertura do solo



Fonte: Autores (2023)

Figura 2 – Área de Estudo



Fonte: Autores (2023)

A bacia hidrográfica do Rio Ipojuca apresenta um elevado grau de degradação da sua vegetação, incluindo as margens de seus rios, nascentes e reservatórios. Estas áreas marginais são ocupadas frequentemente por cultivos de cana-de-açúcar, policultura e pecuária, além da ocupação urbana e industrial (Ramezan, 2021). Segundo

dados da ANA (2010), 50% do consumo do supracitado reservatório é destinado ao abastecimento humano, 22% a agricultura, 27% a pecuária e 1% a irrigação.

2.2 Dados Orbitais

Neste estudo foram utilizadas duas imagens orbitais datadas de 06 de novembro de 2022, sendo uma cena da Câmera Pancromática e Multiespectral (PAN) a bordo do satélite CBERS-4 e, outra cena do sensor MSI (MultiSpectral Instrument) a bordo do satélite Sentinel-2B. As referidas imagens foram obtidas por meio dos Catálogos de imagens do Instituto Nacional de Pesquisas Espaciais INPE, para o satélite CBERS-4 e da Agência Espacial Europeia (ESA) para o satélite Sentinel-2B. A cena Sentinel utilizada neste estudo possui processamento de Nível-2A que inclui uma classificação de cena e uma correção atmosférica aplicada a produtos de ortoimagem Top-of-Atmosphere (TOA) Nível-1C. A saída principal do nível 2A é um produto de refletância corrigida do fundo da atmosfera (BOA) da ortoimagem. O sensor PAN do satélite CBERS-4 com nível 2 de pré-processamento apresenta correção geométrica a partir das informações de órbita do satélite e correção radiométrica (Pinto, 2016).

A Tabela 1, apresenta o comparativo entre as características das bandas utilizadas, de ambos os sensores MSI e PAN.

Tabela 1 – Acurácia do Usuário e do Produtor para as classes de cobertura do solo MSI e PAN

Bandas	Resolução Radiométrica (nm)		Resolução Espacial		Resolução temporal	
	Sentinel-2B/MSI	CBERS-4/PAN	Sentinel-2B/MSI	CBERS-4/PAN	Sentinel-2B/MSI	CBERS-4/PAN
Azul	426 - 558	-	10	10		
Verde	523 - 595	510 - 850	10	10		
Vermelho	634 - 696	520 - 590	10	10	5 dias	5 dias
Infravermelho Próximo (NIR)	727 - 939	630 - 690	10	10		

Fonte: Autores (2023)

2.3 Classificação das imagens por classe de uso e cobertura do solo

A classificação dos elementos de uso e cobertura do solo foi realizada por meio do algoritmo *K-Nearest Neighbors* (KNN), que se trata de um classificador não paramétrico, onde atribui associação de classe às novas entradas de dados, com base em sua proximidade com os “k” dados de treinamento pré-rotulados mais próximos no espaço de recursos (Ramezan *et al.* 2021). Em contrapartida, o valor K é sensível ao agrupamento de dados escolhido e difere entre os conjuntos de dados (Shahabi *et al.* 2020). O K é o principal parâmetro de ajuste que determina em grande parte o desempenho do classificador: um K alto pode levar a sobre ajuste e instabilidade do modelo, enquanto um baixo produzirá um limite de decisão muito complexo (Noi; Kappas, 2017). Um valor apropriado deve ser selecionado para uma determinada aplicação, em que, um método simples é executar o algoritmo várias vezes com diferentes Ks e escolher aquele com melhor desempenho (Samaniego; Schulz, 2009).

Neste estudo, foram examinados K variando de 1 a 5 no intuito de identificar o valor ideal para todos os conjuntos de amostras de treinamento com base na raiz quadrada do erro médio (RMSE). Em seguida, foi realizado a classificação KNN nas imagens PAN e MSI utilizando o melhor valor K previamente estabelecido pelos dados de treinamento. A determinação do valor de K bem como a classificação, foi realizado no software RStudio Desktop 1.4.1717 de livre acesso, através do pacote ‘caret’, seguindo a metodologia adotada por Kuhn (2022).

2.4 Seleção amostral

A seleção das amostras foi de forma aleatória através do método de fotointerpretação com base numa ortofoto de 1 m de resolução espacial disponibilizada gratuitamente pelo Programa Pernambuco Digital (PE3D) e imagens PlanetScope de 3m em composição RGB de falsa-cor, cobrindo integralmente toda a área de estudo. Um total de 250 amostras de treinamento, 50 amostras para cada classe, foram criadas para treinar o classificador. A distribuição amostral contemplou integralmente toda a

área de estudo afim enriquecer os dados de treinamento com as diferentes texturas de cada classe sem esgotar o poder de computação do classificador.

Levantamentos de campo e inspeção visual são os métodos ideais usados para selecionar amostras para obter alta precisão na classificação da cobertura do solo. Com finalidade de complementar os dados de validação, coletar informações detalhadas sobre a cobertura do solo e apoiar definição dos temas do mapa, foi realizado visitas em campo em janeiro de 2023 com coleta de fotografias em pontos específicos e registrados por um receptor GPS NAVAF30 portátil, como mostrado na Figura 3.

Figura 3 – Fotografias no entorno da Barragem Pedro Moura Júnior em Belo Jardim – PE – Brasil



Fonte: Autores (2023)

2.5 Dados de validação e Avaliação da precisão

O produto de referência espacial adotado nesta pesquisa foi o produto de cobertura do solo WorldCover desenvolvido pela ESA (2023). O WorldCover é um mapeamento do uso e cobertura do solo gerado em resolução de 10 m com base na combinação de dados Sentinel-1 e Sentinel-2, disponível em (<https://esa-worldcover.org/en>). Produzido em 2020-2022, numa cobertura temporal de 01 de janeiro a 31 de dezembro, a nível global, os mapas suprem informações importantes para aplicações como biodiversidade, segurança alimentar, avaliação de carbono e modelagem climática (Venter *et al.* 2022). Uma das etapas finais mais importantes no processo de classificação é a avaliação da precisão. O objetivo da avaliação da precisão é avaliar quantitativamente a eficácia com que os pixels foram amostrados nas classes corretas de cobertura do solo.

Para comparar as categorias de cobertura da terra mapeados pelas imagens dos sensores PAN e MSI, quatro medidas de precisão foram consideradas com base numa Tabela de Contingência (Tabela 2), essas medidas foram: Acurácia Global (AG), Acurácia do Usuário (AU), Acurácia do Produtor (AP), Coeficiente Sørensen–Dice (DC) para cada uma das cinco classes categorias pelo modelo kNN (Congalton, 1991).

Tabela 2 – Tabela de contingência para o caso de múltiplas classes em uma determinada região de estudo

Tabela de Contingência		Mapeamento previsto pelo método	
		Condição Positiva	Condição Negativa
Mapeamento de referência	Teste Positivo	VP = Verdadeiro Positivo	FP = Falso Positivo
	Teste Negativo	FN - Falso Negativo	VN = Verdadeiro Negativo

Fonte: Autores (2023)

A Acurácia Geral (AG) (Eq. 1), é a probabilidade de que um pixel seja classificado corretamente por um modelo. A Acurácia do Usuário (AU) (Eq. 2) é a

probabilidade de que um pixel estava previsto para estar em uma determinada classe corretamente. E a Acurácia do Produtor (AP) (Eq. 3) é a probabilidade de que um pixel em uma classe foi classificado corretamente (Congalton, 1991).

O Coeficiente de Dados (DC) (Eq. 4) é uma medida da sobreposição entre o mapa classificado e o mapa de referência, em termos do número de pixels comuns. Essa métrica de similaridade tem sido amplamente utilizada na avaliação de resultados de classificação de imagens, uma vez que as regiões de verdadeiros negativos não afetam a magnitude do coeficiente, desempenhando uma boa detecção ao desequilíbrio entre dois conjuntos de dados.

$$AG = \frac{VP + VN}{VP + FN + VN + FP} \quad (1)$$

$$AU = \frac{VP}{VP + FN} \quad (2)$$

$$AP = \frac{VP}{VP + FP} \quad (3)$$

$$DC = \frac{2}{2 + \left(\frac{1 - AP}{-AP} + \frac{1 - AU}{-AU} \right)} \quad (4)$$

A AG reflete de forma geral a concordância entre o produto classificado e o produto de referência variando de forma crescente de 0% a 100%, enquanto a AP e AU, fornecem valores de acurácia separadamente para cada classe. Neste cenário, DC torna-se uma ótima sobreposição entre o conjunto PAN e o MSI com os dados WorldCover. Ou seja, valores de DC próximos a 1, tem-se uma boa sobreposição, enquanto valores próximos a 0, tem-se uma sobreposição inadequada.

2.5 Regressão Linear

A relação linear entre os produtos classificados e o mapa de referência foi verificado por um grid de proporção espacial para cada classe de cobertura do solo. Com isso, uma grade de $0,5 \times 0,5$ km foi criada sobre a cobertura do MSI e PAN, em que, o Coeficiente de Correlação (r), angular e linear foi utilizado como parâmetro de análise. Esta mesma aplicação foi usada em análises anteriores desenvolvidos por Giglio *et al.* (2018). Em síntese, a fração das áreas de presença de classe em cada célula de grade na imagem WorldCover foi agregada, para assim comparar efetivamente a concordância espacial entre os produtos classificados derivados de menor resolução espacial.

3 RESULTADOS

3.1 Análise de ajuste do algoritmo

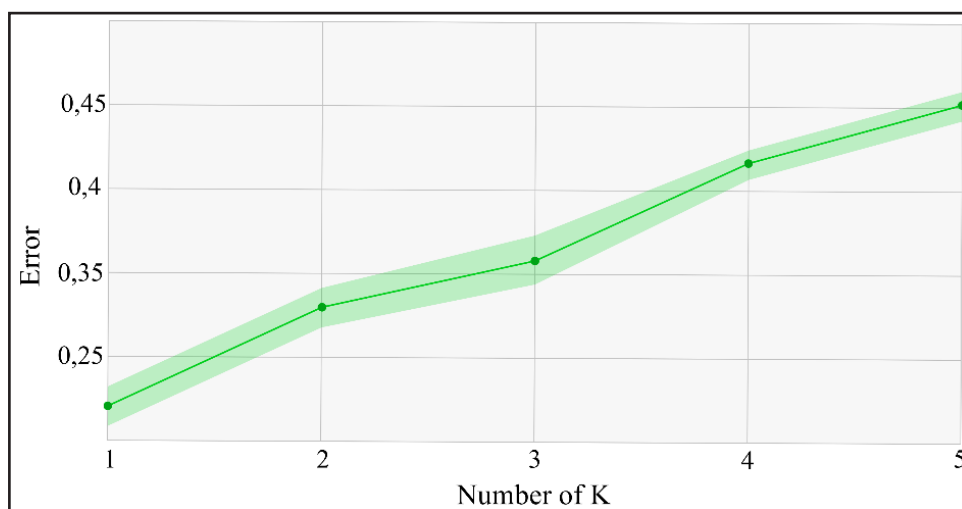
O teste de hiperparâmetro para determinar o melhor valor de K no modelo de classificação, teve por base amostras de treinamento extraídas dos dados espectrais PAN e MSI. Este tipo de análise de ajustamento do modelo de classificação permitiu conhecer e alterar simultaneamente a flexibilidade dos limites de classificação do modelo KNN (Figura 4).

Como resultado da análise, o modelo foi fortemente influenciado pelo valor de K . Em que, houve uma ascensão do RMSE correspondente ao crescente valor de K .

Considerando as dependências apresentadas na Figura 4, pode-se supor que a seleção do valor ótimo de K consiste nos quais o RMSE é o mais baixo para um modelo mais eficaz possível. Nesse caso, entre as configurações de menor RMSE de aprendizado, o melhor valor de acerto foi K igual a 1, portanto esse valor foi considerado ótimo e foi utilizado como parâmetro de entrada no processo de classificação. Segundo Noi e Kappas (2017), modelos KNN com $K=1$ são considerados dados consistentes, uma vez que num número de vizinhos muito alto, o modelo escolhe muitos valores que estão próximos

da amostra de dados, formando assim um limite de decisão complexo, acarretando a diminuição da generalização de pixels próximos e, conseqüentemente, numa classificação com resultados superestimados. Portanto, o valor de K realiza um papel importante no desempenho do KNN sendo o principal parâmetro de ajuste do algoritmo KNN.

Figura 4 – Relação entre o erro e o valor k para os parâmetros (1 a 5) do classificador KNN obtido da abordagem dos subconjuntos dos dados de amostra de treinamento



Fonte: Autores (2023)

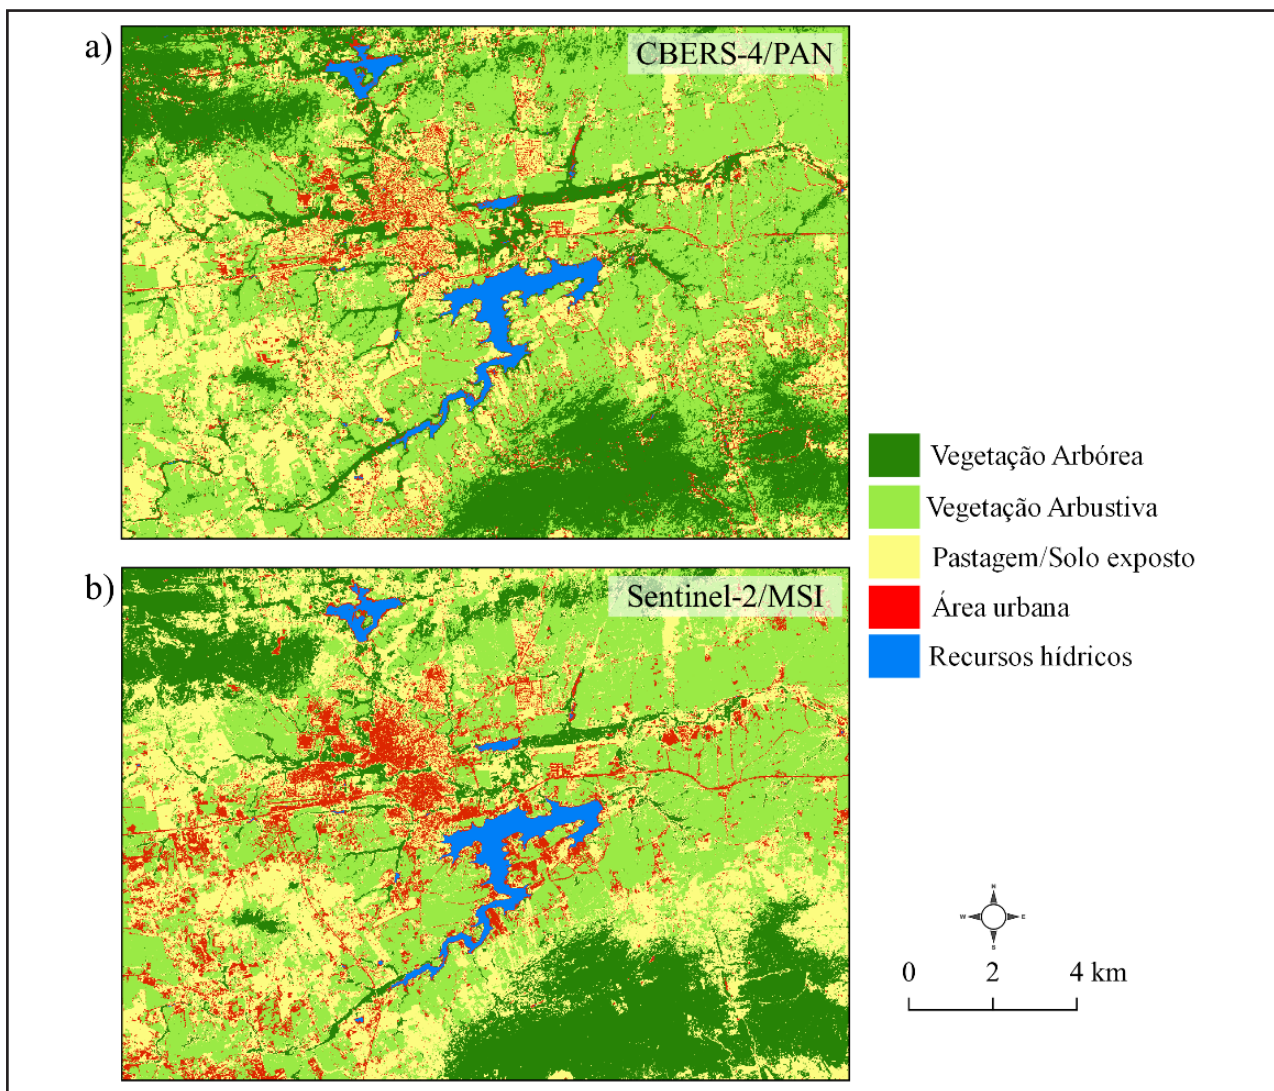
3.2 Mapeamento de uso e cobertura do solo

Na Figura 5 detalhou-se o resultado do mapeamento de cobertura do solo no entorno da Barragem Pedro Moura Júnior obtido por meio da classificação KNN nas imagens PAN e MSI.

Através da análise do mapeamento gerado, a classe de Vegetação arbórea para o sensor PAN, mostrou uma maior presença espacial (PAN: 76,5 Km²) por outro lado, o MSI apresentou um valor de área próximo ao produto de referência (MSI: 51,7 Km²; WC: 49,8 Km²). A classe de Vegetação arbustiva, como mostrado visualmente nos mapas da Figura5 (a,b), apresentaram as menores feições de área, destaque para o sensor MSI 101,3 Km² enquanto o PAN foi de 92,4Km² e WorldCover com 111,9 Km². A

classe de Pastagem/solo exposto para ambos os sensores, apresentaram diferenças excessivas em relação ao WorldCover (PAN: 53,5 Km²; MSI: 96,6 Km² e WC: 19 Km²), o contrário para a classe de Área urbana, onde foi possível observar valores próximos comparados ao mapa de referência principalmente para o MSI (27,6 Km²) e o PAN com aproximadamente 15,4 Km² e o WorldCover de 29,2 Km². O MSI e o PAN apresentaram valores de área próximos entre si (MSI: 4,4 Km²; PAN: 4,5 Km² para a classe de Recursos hídricos, embora o mapa de referência apresentou menor estimativa (WC: 3,4 Km²).

Figura 5 – Mapa de Cobertura do Solo no entorno da Barragem Pedro Moura Júnior. a) Cena PAN - CEBS-4 b) MSI - Sentinel-2



Fonte: Autores (2023)

3.3 Análise de acurácia

Para determinar a precisão de cada classificação, uma Matriz de Contingência foi criada com base nos produtos classificados (PAN e MSI) e de referência (WorldCover), onde foi possível determinar os coeficientes de Acurácia do Produtor (AP) e Acurácia do Usuário (AU) mostrados na Tabela 3.

Tabela 3 – Acurácia do Usuário e do Produtor para as classes de cobertura do solo MSI e PAN

		Vegetação Arbórea	Vegetação Arbustiva	Pastagem/ Solo exposto	Área urbana	Recursos Hídricos
PAN	AP (%)	55.6	61.9	82.0	17.5	95.2
	AU (%)	62.6	75.8	29.5	33.7	73.7
MSI	AP (%)	58.7	48.4	87.5	45.3	97.2
	AU (%)	83.8	60.1	22.7	61.1	75.5

Fonte: Autores (ano)

Observou-se na Tabela 3, para a classe de vegetação arbórea, o MSI ressaltou melhor em relação ao PAN, com destaque para a Acurácia do Usuário chegando a aproximadamente 83.8%, embora os valores de Acurácia do Produtor apresentem uma pequena variação de 3.1%. Já na classe de vegetação arbustiva, houve um comportamento inverso, o mapa gerado pelo sensor PAN apresentou ligeiramente melhor desempenho em ambos os parâmetros de acurácia.

A classe de pastagem/solo exposto apresentou valores de Acurácia do Produtor acima de 80%, porém o MSI ainda se sobressaiu com uma vantagem de 5,5%, enquanto para a acurácia do usuário, o sensor PAN mostrou um rendimento melhor, com valor de aproximadamente 29.5 e o MSI de 22,7%. As estimativas de Acurácia do Produtor e do Usuário foram maiores para a classificação MSI na classe de área urbana, embora cerca de 16 Km² foram incorretamente classificados enquanto para o PAN foi de aproximadamente 24 Km². Por outro lado, a aderência espacial dos dados MSI com o mapa de referência gerou uma área corretamente classificada de 13.1 Km² e o PAN de 5,11 Km². A classe de

recursos hídricos apresentou as melhores estimativas de acurácia entre as outras classes e em ambos os sensores. Porém o MSI se sobressaiu em relação ao PAN com vantagem de aproximadamente 2% onde ambas classificaram corretamente 3.33 Km² e 3.24 Km² respectivamente. No geral o MSI apresentou as melhores estimativas de acurácia com AP e AU médio de 67.4% e 60.6%, enquanto o PAN foi de 62.5% e 56.6% respectivamente. Esses valores concordam com as estimativas de acurácia global (MSI: 57.4%; PAN: 54.5%).

Tabela 4 – Coeficientes DC para as classes de cobertura do solo MSI e PAN

	Vegetação Arbórea	Vegetação Arbustiva	Pastagem/Solo exposto	Área urbana
MSI	0.74	0.32	0.22	0.55
PAN	0.50	0.50	0.15	0.23

Fonte: Autores (2021)

Os valores de DC evidenciados na Tabela 4 detalharam as melhores estimativas para o mapeamento gerado pelo MSI com destaque para a classe de vegetação arbórea e Recursos hídricos, onde mostram a maior discrepância em relação as estimativas para o PAN. A classe de vegetação arbustiva para a classificação PAN apresentou um comportamento isolado, um coeficiente DC ligeiramente maior que o MSI. Esta vantagem está relacionada a maior sobreposição espacial com os dados de referência onde o sensor PAN classificou corretamente 69,2 Km² e o MSI de 60,7 Km². Apesar disso, a estimativa DC mostrou-se com valores baixos (DC>0.5) para as classes de vegetação arbustiva e pastagem, enquanto a classe de Recursos hídricos apresentou altos valores de DC (DC>0,7) segundo a literatura (Annathurai *et al.* 2022).

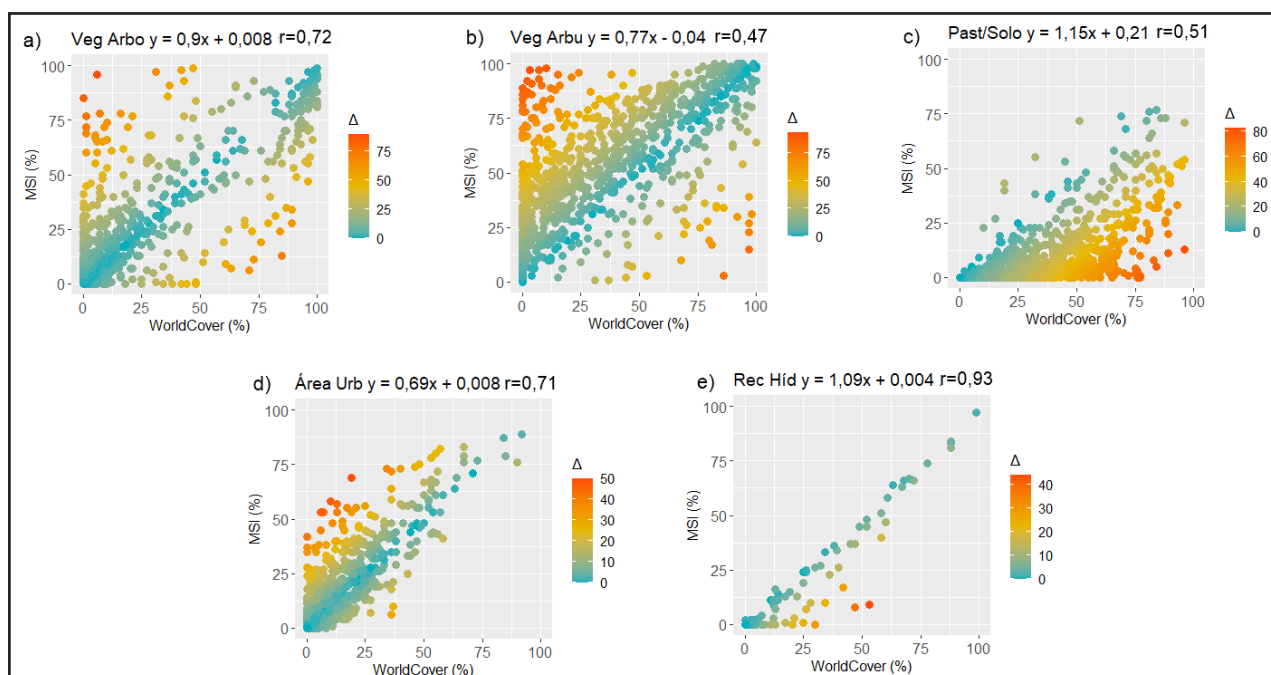
3.4 Análise de Regressão

As Figuras 6 e 7 relataram os gráficos de dispersão obtidos pela combinação de células com proporção de 0,5x0,5 Km entre os produtos MSI e PAN em relação aos mapas de referência para cada classe de cobertura do solo.

A análise mostra que a classificação MSI apresentou uma precisão ligeiramente

maior em relação ao PAN para a classe de Vegetação arbórea, bem como um menor coeficiente linear, apontando uma maior subestimação desta classe no mapa PAN. Já a classe de Vegetação arbustiva, não apresentou uma diferença significativa em nenhum dos coeficientes, mesmo com a vantagem do produto PAN, o que mostrou uma leve melhora na detecção e uma menor influência da exatidão temática com sensores de mesma resolução espacial.

Figura 6 – Gráficos de dispersão das proporções de células de grade de 0,5km rotuladas como classe de presença pelo produto MSI em relação à proporção rotulada como mapa de referência WorldCover

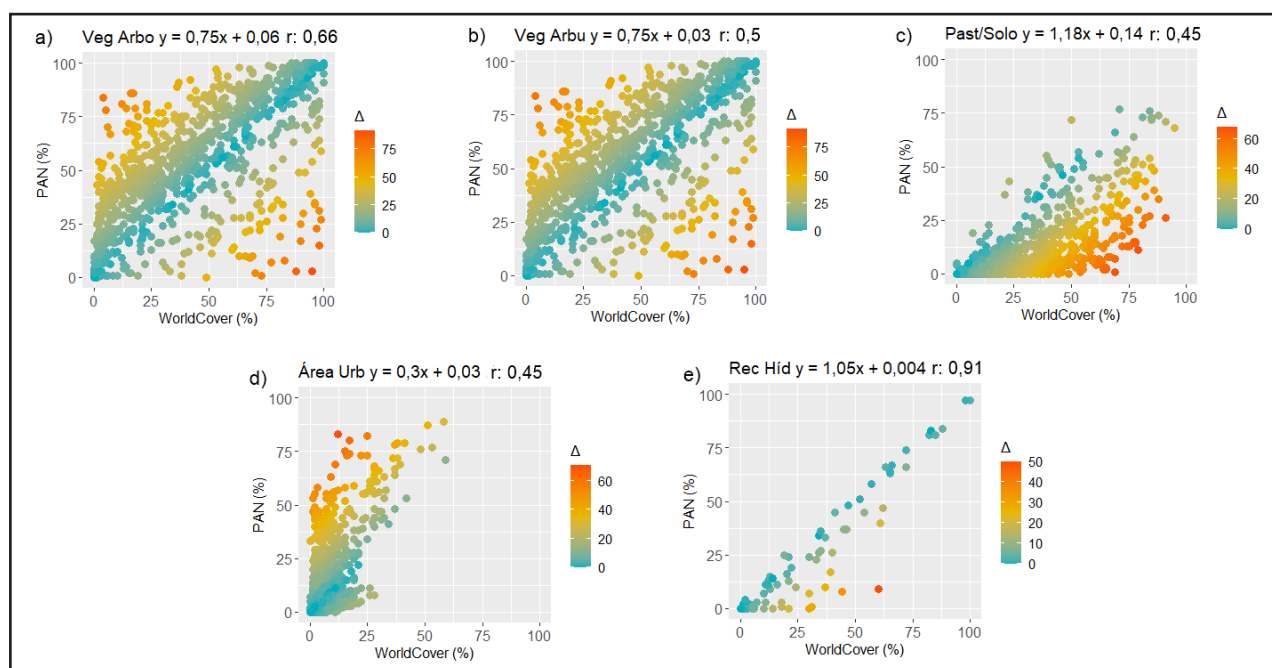


Fonte: Autores (2023)

No geral, as classes de Pastagem/Solo exposto e Área urbana mostram melhor desempenho para a classificação MSI com valores de r moderadamente maiores. A alta distribuição de pixels omissos para o produto PAN na classe de Área urbana, podem ter causado o aumento significativo do coeficiente linear quando comparado ao produto MSI, embora, as superestimações mostradas na Tabela 3 foram capazes de reduzir o coeficiente angular de 0,69 (MSI) para 0,3 (PAN). Enquanto a classe de Pastagem/

Solo exposto, devido a variações pequenas na distribuição pixels classificados erroneamente em outras classes entre os sensores, apresentaram coeficiente angular próximos (PAN: 1,18; MSI 1,15) correspondente a diferença entre precisões ($r_{PAN} = 0,45$; $r_{MSI} = 0,51$) e de coeficiente DC mostrado na Tabela 4. Assim como visto nas verificações anteriores, a classe de recursos hídricos na análise de regressão linear apresentou boa performance em ambos os produtos, com precisão $r > 0,9$, coeficientes lineares e angulares com alta proximidade. Apesar disso, o MSI apresentou maior precisão e o produto PAN abriu uma vantagem de 0,02 no coeficiente angular, porém essas variações podem se tornar insignificantes em feitos práticos.

Figura 7 – Gráficos de dispersão das proporções de células de grade de 0,5 km rotuladas como classe de presença pelo produto PAN em relação à proporção rotulada como mapa de referência WorldCover



Fonte: Autores (2023)

3.5 Análise de configurações temáticas sensíveis a resolução espectral

A faixa de comprimento de onda das bandas espectrais do MSI e o PAN são ligeiramente diferentes e, como mostrado na Tabela 1, o MSI fornece a banda do azul

e outras bandas mais estreitas, o que favorece a obtenção de informações espectrais e melhor discriminação da variabilidade entre as classes de cobertura do solo. Por exemplo, como mostrado na Tabela 3, a maior acurácia do usuário para a classe de Vegetação Arbórea foi provavelmente resultantes da maior sensibilidade espectral do MSI em caracterizar diferentes tipos de cobertura vegetal e também da atribuição de estrutura físico-química de arbusto caracterizado por alta densidade foliar quando comparado a outras vegetações (Gonçalves *et al.* 2021). Por outro lado, uso da banda do azul presente apenas no sensor MSI bem como a sua capacidade de fácil absorção pela clorofila nas plantas, boa penetração de água e sensível a variação de umidade do solo também pode ser um fator para o bom desempenho da classificação comparado ao sensor PAN (Metternicht; Zinck, 2003). Wang *et al.* (2018) relataram que a banda do azul está entre o canal de entrada de dados mais importantes no mapeamento de tipos de vegetação, principalmente as típicas do Semiárido, devido à baixa refletância sobre o dossel da vegetação relacionada à forte absorção de clorofila que é vital para o monitoramento da vegetação usando dados de sensoriamento remoto.

A classe de Vegetação arbustiva mostrou um resultado isolado nos parâmetros de acurácia com vantagem para o sensor PAN. Devido as semelhanças visuais de reconhecimento de padrões entre as classes Vegetação arbustiva e Pastagem/Solo exposto nas imagens PAN e MSI, podem acarretar erros de classificação significativos em áreas de transição, onde a sensibilidade espectral é um fator determinante no processo de discriminação em cenas de mesmo tamanho de pixel (FENG *et al.* 2022). Além disso, a alta homogeneidade espacial dos dados WorldCover na classe de Vegetação arbustiva, também foi uma variável importante para a boa aderência com a classificação mais generalizada dos dados PAN.

A classe de área urbana foi relativamente detectada com precisão menor para ambos os sensores. A alta distribuição de pequenos conjuntos de pixels nesta classe, colaborou para as menores estimativas de qualidade temática, pois além da mancha urbana, pequenos vilarejos podem ser vistos dispersos na área de estudo,

tais elementos cruciais para a ocorrência desta limitação. Além disso, as classes de área urbana e solo exposto, ambas de alto reflectância, possuem fortes semelhanças visuais e espectrais já conhecidas na literatura devido a sua coloração esbranquiçada (Silva *et al.* 2021; Nguyen *et al.* 2023). A dificuldade em distinguir entre essas duas classes foi atribuída à predominância de argilas em ambas, o que resultou em respostas espectrais semelhantes tanto de telhas quanto de solo exposto. É hipotetizado que essas classes têm assinaturas espectrais semelhantes devido às suas proximidades nos parâmetros de textura, cores e morfologias, o que podem causar confusões até nos mais robustos classificadores.

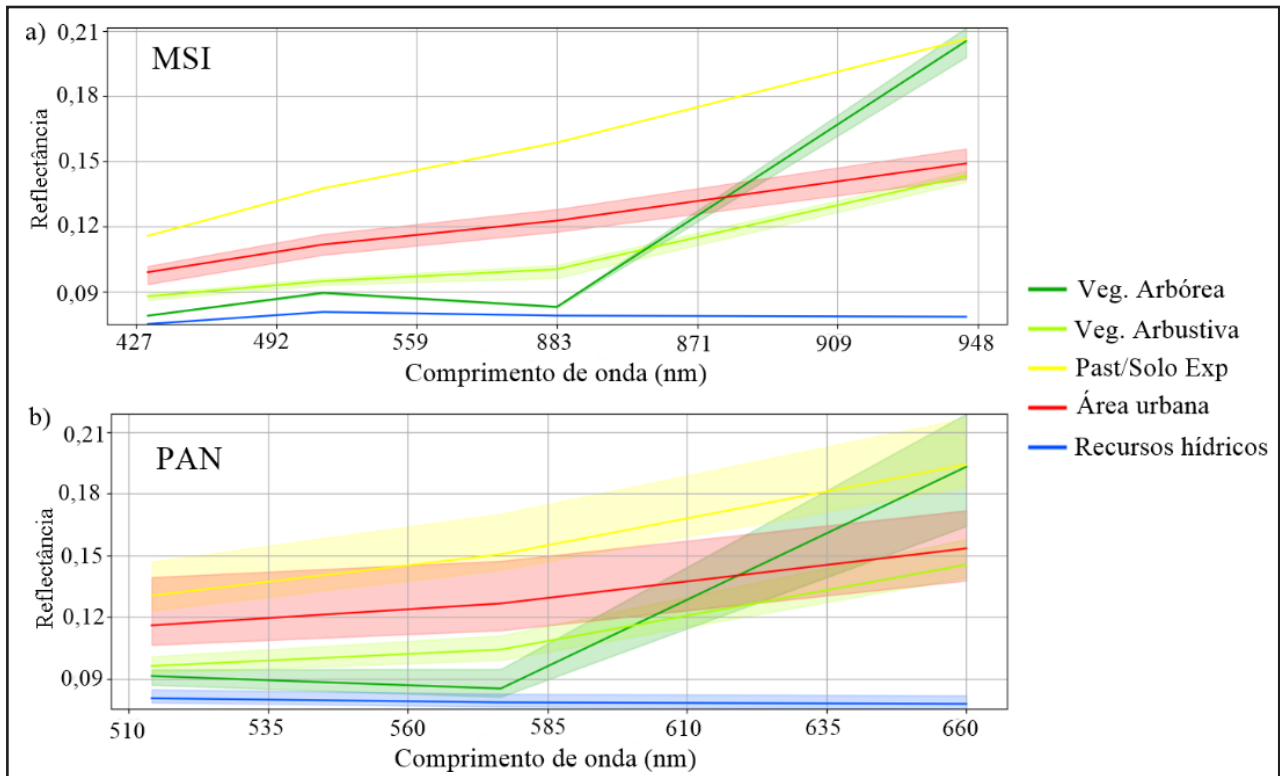
As precisões para a classe de recursos hídricos foram altas. As áreas úmidas são facilmente classificadas por conta de suas características espectrais peculiares, caracterizadas por alto poder de absorção, além de sua formação homogênea do polígono do espelho d'água que causa diminuição de erros de omissão e comissão. Classes com feições mais compactas possibilita ao classificador alocar corretamente com os dados de referência, sobressaindo-se aos erros relacionados a pixels isolados de outras classes, aliviando o problema de classificação colocado por pixels espectralmente misturados muitos presentes nas bordas dessas feições. No estudo de Qu *et al.* (2021), foi constatado um desempenho elevado na classificação de corpos hídricos em uma região de planície na China. De acordo com os autores, as imagens Sentinel-2 apresentam uma capacidade de realçar as características de água escura, turva e com eutrofização, além de discriminarem com maior precisão as áreas sombreadas que apresentam perfis espectrais semelhantes aos da água. Bangira *et al.* (2019) afirmaram que, mesmo com poucas amostras e dados complexos, como imagens UAV, os classificadores de aprendizado de máquina e de aprendizado profundo detectam com precisão os pixels de água.

3.6 Implicações do mapa de cobertura do solo no entorno do Reservatório

Pedro Moura Junior

No geral, há muitas fitofisionomias na área de estudo, para um bom desempenho na classificação por imagens orbitais, é importante que a configuração de entrada seja espectralmente preciso, para identificar a variabilidade da faixa de valores das classes de cobertura da terra com maior dessemelhança entre classes possível. A informação espectral de três bandas do PAN, podem ser reduzidas quando comparadas com as quatro bandas 10 m fornecidas pelo MSI, indicando que os modelos de banda mais estreita exploram regiões espectrais específicas e sensíveis às características das classes de uso do solo e reduzem as regiões espectrais redundantes ou insignificantes, enquanto os modelos de banda larga (principalmente a banda do azul do sensor PAN) fazem a média das informações em regiões espectrais maiores, aumentando assim a generalização e erros de comissão (Silva Junior *et al.* 2022). Um exemplo disso foi mostrado na Figura 8, apesar das semelhanças entre as assinaturas espectrais obtidas pelas amostras de treinamento, onde foi possível identificar que as assinaturas do sensor PAN possuem intervalos de confiança mais amplo entre as classes, diminuindo a decorrelação entre as classes e causando consequentemente confusões no algoritmo classificador, enquanto as assinaturas espectrais do MSI possuem maior separabilidade interclasse.

Figura 8 – Assinaturas espectrais das classes de cobertura do solo nos sensores a) MSI e b) PAN



Fonte: Autores (2023)

A comparação dos mapas gerados por classificação com o mapa de referência é imprescindível, uma vez que imagem de satélite utilizada afeta diretamente os resultados finais e, portanto, esta é uma das etapas principais na produção de mapas de cobertura da terra. O tipo de pixel a ser classificado não depende apenas das características espectrais da própria célula, mas também dos tipos de pixels circundantes. A influência desses pixels se potencializa quando a sua resolução espacial possibilita a generalização dos sinais espectrais gerados pelos diferentes tipos de cobertura do solo dentro da área do pixel, ocasionando erros graves na classificação das imagens. É importante observar que a classificação da imagem depende de muitos fatores diferentes, como sistema de classificação, cobertura da área de estudo, tipo de sensor, natureza das classes selecionadas, resolução radiométrica, resolução espectral, variação de tamanhos de objetos dentro de cada classe e tamanho mínimo do objeto em uma classe que normalmente contém objetos menores (por exemplo,

edifícios) (Silva Junior *et al.* 2022).

Neste estudo, nas análises de acurácia e regressão linear, a resolução espacial de 10 m de ambos os sensores foi importante para o equilíbrio dos parâmetros de qualidade atenuando problemas de mistura espectral e, conseqüentemente, previsão ineficiente, principalmente para as classes de feições de menor extensão e heterogêneas (Acharki *et al.* 2022). Por fim, as bandas espectrais mais estreitas do Sentinel-2 forneceram uma variedade de informações espectrais, que contribuem para toda a classificação. É compreensível que um conjunto de dados com diferentes atributos tenha maior capacidade no reconhecimento das classes de cobertura do solo, o que facilita a melhora da precisão geral da classificação.

A acurácia geral resultante mostrou que o algoritmo não paramétrico kNN ofereceu uma boa classificação para ambos os conjuntos de dados. A robustez do kNN na classificação da cobertura do solo pode ser explicada pela capacidade do algoritmo de operar eficientemente com conjuntos de dados multicolineares e multiespectrais (YUH *et al.* 2023). Esse recurso permitiu maior estabilidade do classificador, pois o algoritmo consegue discriminar pequenas variações nos dados de entrada, aumentando a precisão da classificação.

4 CONSIDERAÇÕES FINAIS

As estimativas de acurácia obtidas pela classificação MSI e PAN foram consistentes e ofereceram uma boa confiabilidade para uso geral no monitoramento da cobertura do solo no reservatório e seu entorno. Este estudo demonstrou que a diferença nas resoluções entre as imagens não teve impacto significativo, embora, o MSI tenha sido capaz de melhorar a detecção da vegetação Arbórea, Pastagem/Solo exposto, Área urbana e Recursos hídricos. O ajuste do modelo KNN sendo o valor ótimo de $k=1$ foi aplicado com a finalidade de adaptar o classificador com os dados de treinamento e seu efeito na previsão. Com isso, acurácia Global para o MSI foi de 57,4% e 54,5% para o PAN.

O método proposto tem desempenho promissor para ser amplamente empregado

no mapeamento de cobertura do solo auxiliando como fonte de informações e base de dados no gerenciamento espacial, sendo útil para pesquisadores formuladores de políticas e tomadores de decisão. No futuro, com o aumento contínuo dos dados de imagens como por exemplo das plataformas CBERS-4A e Amazônia-1, mais áreas de teste e períodos de tempo mais longos devem ser incluídas, a fim de investigar melhor as diferenças entre os dois conjuntos de dados e fornece suporte técnico para sua aplicação colaborativa.

REFERÊNCIAS

ACHARKI, Siham. PlanetScope contributions compared to Sentinel-2, and Landsat-8 for LULC mapping. **Remote Sensing Applications: Society and Environment**, [S.L.], v. 27, p. 100774, ago. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2022.100774>

APAC. **Agência Pernambucana de Águas e Clima**. Disponível em: <http://www.sirh.srh.pe.gov.br/apac/>, 2019.

ANNATHURAI, Kalyana Saravanan; ANGAMUTHU, Tamilarasi. Sorensen-dice similarity indexing based weighted iterative clustering for big data analytics. **Int. Arab J. Inf. Technol.**, v. 19, n. 1, p. 11-22, 2022.

BANGIRA, Tsitsi; ALFIERI, Silvia Maria; MENENTI, Massimo; VAN NIEKERK, Adriaan. Comparing Thresholding with Machine Learning Classifiers for Mapping Complex Water. **Remote Sensing**, [S.L.], v. 11, n. 11, p. 1351, 5 jun. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11111351>

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

ESA. **European Space Agency. Sentinel-2: Resolution and Swath, 2021**. Available online: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swath>

FENG, Senyao; LI, Wenlong; XU, Jing; LIANG, Tiangang; MA, Xuanlong; WANG, Wenying; YU, Hongyan. Land Use/Land Cover Mapping Based on GEE for the Monitoring of Changes in Ecosystem Types in the Upper Yellow River Basin over the Tibetan Plateau. **Remote Sensing**, [S.L.], v. 14, n. 21, p. 5361, 26 out. 2022. MDPI AG. <http://dx.doi.org/10.3390/rs14215361>

GIBRIL, Mohamed Barakat A.; BAKAR, Suzana A.; YAO, Kouame; IDREES, Mohammed Oludare; PRADHAN, Biswajeet. Fusion of RADARSAT-2 and multispectral optical remote sensing data for LULC extraction in a tropical agricultural area. **Geocarto International**, [S.L.], v. 32, n. 7, p. 735-748, 15 abr. 2016. Informa UK Limited. <http://dx.doi.org/10.1080/10106049.2016.1170893>

GIGLIO, Louis; BOSCHETTI, Luigi; ROY, David P.; HUMBER, Michael L.; JUSTICE, Christopher O.. The Collection 6 MODIS burned area mapping algorithm and product. **Remote Sensing of Environment**, [S.L.], v. 217, p. 72-85, nov. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2018.08.005>

GONÇALVES, Rogério Victor S.; CARDOSO, João Custódio F.; OLIVEIRA, Paulo Eugênio; OLIVEIRA, Denis Coelho. Changes in the Cerrado vegetation structure: insights from more than three decades of ecological succession. **Web Ecology**, [S.L.], v. 21, n. 1, p. 55-64, 30 mar. 2021. Copernicus GmbH. <http://dx.doi.org/10.5194/we-21-55-2021>

HU, Bin; XU, Yongyang; HUANG, Xiao; CHENG, Qimin; DING, Qing; BAI, Linze; LI, Yan. Improving Urban Land Cover Classification with Combined Use of Sentinel-2 and Sentinel-1 Imagery. **ISPRS International Journal Of Geo-Information**, [S.L.], v. 10, n. 8, p. 533, 9 ago. 2021. MDPI AG. <http://dx.doi.org/10.3390/ijgi10080533>.

KUHN, Max. **The caret package**. R Foundation for Statistical Computing, Vienna, Austria. URL [https://cran.r-project.org/package= caret](https://cran.r-project.org/package=caret), 2012.

LI, Congcong; WANG, Jie; WANG, Lei; HU, Luanyun; GONG, Peng. Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. **Remote Sensing**, [S.L.], v. 6, n. 2, p. 964-983, 24 jan. 2014. MDPI AG. <http://dx.doi.org/10.3390/rs6020964>

LIU, Qingsheng; SONG, Hongwei; LIU, Gaohuan; HUANG, Chong; LI, He. Evaluating the Potential of Multi-Seasonal CBERS-04 Imagery for Mapping the Quasi-Circular Vegetation Patches in the Yellow River Delta Using Random Forest. **Remote Sensing**, [S.L.], v. 11, n. 10, p. 1216, 22 maio 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11101216>

METTERNICHT, G.I; ZINCK, J.A. Remote sensing of soil salinity: potentials and constraints. **Remote Sensing of Environment**, [S.L.], v. 85, n. 1, p. 1-20, abr. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0034-4257\(02\)00188-8](http://dx.doi.org/10.1016/s0034-4257(02)00188-8)

NASA. **National Aeronautics and Space Administration**. Spectral Response of the Operational Land Imager In-Band, Band-Average Relative Spectral Response, 2021. Available online: <https://landsat.gsfc.nasa.gov/preliminary-spectral-response-of-the-operational-land-imager-in-band-band-average-relative-spectral-response/>

NGUYEN, C. T.; CHIDTHAISONG, A.; DIEM, P. K.; HUO, Lian-Zhi. A Modified Bare Soil Index to Identify Bare Land Features during Agricultural Fallow-Period in Southeast Asia Using Landsat 8. **Land**, [S.L.], v. 10, n. 3, p. 231, 25 fev. 2021. MDPI AG. <http://dx.doi.org/10.3390/land10030231>.

NOI, Phan Thanh; KAPPAS, Martin. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors**, [S.L.], v. 18, n. 2, p. 18, 22 dez. 2017. MDPI AG. <http://dx.doi.org/10.3390/s18010018>

NAIKOO, Mohd Waseem; RIHAN, Mohd; ISHTIAQUE, Mohammad; SHAHFAHAD. Analyses of land use land cover (LULC) change and built-up expansion in the suburb of a metropolitan city: spatio-temporal analysis of delhi ncr using landsat datasets. **Journal of Urban Management**,

[S.L.], v. 9, n. 3, p. 347-359, set. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.jum.2020.05.004>

PAL, M.; MATHER, P. M.. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, [S.L.], v. 26, n. 5, p. 1007-1011, mar. 2005. Informa UK Limited. <http://dx.doi.org/10.1080/01431160512331314083>.

PINTO, Cibele; PONZONI, Flávio; CASTRO, Ruy; LEIGH, Larry; MISHRA, Nischal; AARON, David; HELDER, Dennis. First in-Flight Radiometric Calibration of MUX and WFI on-Board CBERS-4. **Remote Sensing**, [S.L.], v. 8, n. 5, p. 405, 11 maio 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8050405>

QU, Le'an; CHEN, Zhenjie; LI, Manchun; ZHI, Junjun; WANG, Huiming. Accuracy Improvements to Pixel-Based and Object-Based LULC Classification with Auxiliary Datasets from Google Earth Engine. **Remote Sensing**, [S.L.], v. 13, n. 3, p. 453, 28 jan. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13030453>

RAMEZAN, Christopher A.; WARNER, Timothy A.; MAXWELL, Aaron E.; PRICE, Bradley S.. Effects of Training Set Size on Supervised Machine-Learning Land-Cover Classification of Large-Area High-Resolution Remotely Sensed Data. **Remote Sensing**, [S.L.], v. 13, n. 3, p. 368, 21 jan. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13030368>

SHAHABI, Himan; SHIRZADI, Ataollah; GHADERI, Kayvan; OMIDVAR, Ebrahim; AL-ANSARI, Nadhir; CLAGUE, John J.; GEERTSEMA, Marten; KHOSRAVI, Khabat; AMINI, Ata; BAHRAMI, Sepideh. Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: hybrid intelligence of bagging ensemble based on k-nearest neighbor classifier. **Remote Sensing**, [S.L.], v. 12, n. 2, p. 266, 13 jan. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12020266>

SAMANIEGO, Luis; SCHULZ, Karsten. Supervised Classification of Agricultural Land Cover Using a Modified k-NN Technique (MNN) and Landsat Remote Sensing Imagery. **Remote Sensing**, [S.L.], v. 1, n. 4, p. 875-895, 9 nov. 2009. MDPI AG. <http://dx.doi.org/10.3390/rs1040875>

SILVA, Murilo Schramm da; VIBRANS, Alexander Christian; NICOLETTI, Adilson Luiz. BACKDATING OF INVARIANT PIXELS: comparison of algorithms for land use and land cover change (lucc) detection in the subtropical brazilian atlantic forest. **Boletim de Ciências Geodésicas**, [S.L.], v. 27, n. 3, p. 100-112, 2021. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1982-21702021000300018>.

SILVA JUNIOR, Juarez Antonio da; PACHECO, Admilson da Penha; RUIZ-ARMENTEROS, Antonio Miguel; HENRIQUES, Renato Filipe Faria. Evaluation of the Ability of SLSTR (Sentinel-3B) and MODIS (Terra) Images to Detect Burned Areas Using Spatial-Temporal Attributes and SVM Classification. **Forests**, [S.L.], v. 14, n. 1, p. 32, 24 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/f14010032>.

SILVA JUNIOR, Juarez Antonio da; PACHECO, Admilson da Penha. Análise do Modelo Linear de Mistura Espectral na Avaliação de Incêndios Florestais no Parque Nacional do Araguaia, Tocantins, Brasil: imagens eo-1/hyperion e landsat-7/etm+. **Anuário do Instituto de**

Geociências, [S.L.], v. 43, n. 4, p. 340-450, 18 dez. 2020. Instituto de Geociencias - UFRJ. http://dx.doi.org/10.11137/2020_4_440_450

SILVA JÚNIOR, Juarez Antonio da; SILVA JÚNIOR, Ubiratan Joaquim da; PACHECO, Admilson da Penha. Análise de acurácia para o mapeamento de áreas queimadas utilizando uma cena VIIRS 1Km e classificação por Random Forest. **Revista Brasileira de Geografia Física**, [S.L.], v. 14, n. 6, p. 3225, 31 dez. 2021. <http://dx.doi.org/10.26848/rbgf.v14.6.p3225-3240>

SHRESTHA, Megha; MITRA, Chandana; RAHMAN, Mahjabin; MARZEN, Luke. Mapping and Predicting Land Cover Changes of Small and Medium Size Cities in Alabama Using Machine Learning Techniques. **Remote Sensing**, [S.L.], v. 15, n. 1, p. 106-120, 25 dez. 2022.

VENTER, Zander S.; BARTON, David N.; CHAKRABORTY, Tirthankar; SIMENSEN, Trond; SINGH, Geethen. Global 10 m Land Use Land Cover Datasets: a comparison of dynamic world, world cover and esri land cover. **Remote Sensing**, [S.L.], v. 14, n. 16, p. 4101, 21 ago. 2022. MDPI AG. <http://dx.doi.org/10.3390/rs14164101>.

YUH, Yisa Ginath; TRACZ, Wiktor; MATTHEWS, H. Damon; TURNER, Sarah E.. Application of machine learning approaches for land cover monitoring in northern Cameroon. **Ecological Informatics**, [S.L.], v. 74, p. 101955, maio 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.ecoinf.2022.101955>

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

ZHAO, Ruifeng; CHEN, Yaning; SHI, Peiji; ZHANG, Lihua; PAN, Jinghu; ZHAO, Haili. Land use and land cover change and driving mechanism in the arid inland river basin: a case study of tarim river, xinjiang, china. **Environmental Earth Sciences**, [S.L.], v. 68, n. 2, p. 591-604, 21 jun. 2012. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12665-012-1763-3>.

WANG, Bing; JIA, Kun; LIANG, Shunlin; XIE, Xianhong; WEI, Xiangqin; ZHAO, Xiang; YAO, Yunjun; ZHANG, Xiaotong. Assessment of Sentinel-2 MSI Spectral Band Reflectances for Estimating Fractional Vegetation Cover. **Remote Sensing**, [S.L.], v. 10, n. 12, p. 1927, 30 nov. 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10121927>.

CONTRIBUIÇÕES DE AUTORIA

1 – Juarez Antônio da Silva Júnior

Universidade Federal de Pernambuco, Mestre em Engenharia Civil
<https://orcid.org/0000-0002-2898-0309> • juarez.silvajunior@ufpe.br

Contribuição: Conceituação, curadoria de dados, obtenção de financiamento, investigação, metodologia, recursos, software, supervisão, validação, escrita - primeira redação, escrita - revisão e edição

2 – Ubiratan Joaquim da Silva Junior

Universidade Federal de Pernambuco, Mestre em Ciências Geodésicas e Tecnologias da Geoinformação

<https://orcid.org/0000-0001-7995-6416> • ubiratan.joaquim@ufpe.br

Contribuição: Curadoria de dados, investigação, metodologia, validação, escrita - primeira redação

3 – Débora Natália Oliveira de Almeida

Universidade Federal de Pernambuco, Doutoranda em Engenharia Civil

<https://orcid.org/0000-0001-6000-6138> • debora.noalmeida@ufpe.br

Contribuição: Investigação, recursos, visualização

4 – Anderson Luiz Ribeiro de Paiva

Universidade Federal de Pernambuco, Doutor em Engenharia Civil

<https://orcid.org/0000-0003-3475-1454> • anderson.paiva@ufpe.br

Contribuição: Conceituação, análise formal, recursos, visualização

5 – Ester Milena dos Santos

Universidade Federal de Pernambuco, Doutoranda em Engenharia Civil

<https://orcid.org/0000-0001-8937-3767> • ester.santos@ufpe.br

Contribuição: Análise formal, recursos, visualização

6 – Sylvana Melo dos Santos

Universidade Federal de Pernambuco, Doutora em Engenharia Civil

<https://orcid.org/0000-0003-3106-5301> • sylvana.santos@ufpe.br

Contribuição: Conceituação, administração do projeto, supervisão, visualização

7 – Leidjane Maria Maciel de Oliveira

Universidade Federal de Pernambuco, Doutora em Engenharia Civil

<https://orcid.org/0000-0003-1251-6998> • leidjane.oliveira@ufpe.br

Contribuição: Conceituação, análise formal, metodologia, administração do projeto, supervisão, escrita - revisão e edição

Como citar este artigo

SILVA JÚNIOR, J. A. da; SILVA JUNIOR, U. J. da; ALMEIDA, D. N. O. de; PAIVA, A. L. R. de.; SANTOS, E. M. dos; SANTOS, S. M. dos; OLIVEIRA, L. M. M. de. Análise de acurácia do mapeamento do uso e ocupação do solo utilizando imagens sentinel-2 e cbers-4 no entorno de reservatórios. **Ciência e Natura**, v.46, e84730, 2024. <https://doi.org/10.5902/2179460X84730>