

COMPOSIÇÃO DE IMAGENS MULTISSENSOR PARA O MAPEAMENTO DO USO E COBERTURA DA TERRA

Multisensor Image Composition for Land Use and Cover Mapping

Danilo Marques de Magalhães

Doutorado em Geografia. Departamento de Geografia e Planejamento Ambiental da Universidade Estadual Paulista “Júlio de Mesquita Filho”

Orcid: <https://orcid.org/0000-0001-9306-4326>

danilo.magalhaes@unesp.br

RESUMO

Este trabalho propõe a utilização de imagens multisensor visando à melhoria da acurácia do mapeamento do uso e cobertura do solo. A proposta surge das observações empíricas dos erros encontrados para a classificação supervisionada de imagens do sensor WPM a bordo do satélite CBERS-4A com 2 m de resolução espacial. Entendendo-se o potencial fornecido por essa resolução espacial, mas que é limitado pela resolução espectral restrita ao espectro visível e infravermelho próximo, é proposta a adição das bandas do infravermelho de ondas curtas (SWIR1 e SWIR2) coletadas pelo satélite Landsat. Para isso, essas bandas foram reamostradas para 2 m pelo método de convolução cúbica. Foram realizadas classificações supervisionadas por meio do classificador SVM a partir das duas imagens geradas, que são a imagem original CBERS-4A com 4 bandas espectrais e a imagem com as 2 bandas do SWIR adicionadas, totalizando 6 bandas espectrais. Os resultados indicam uma maior Acurácia Global para a imagem com as bandas adicionadas (81,16%) em relação à imagem original (70,47%). As demais métricas de avaliação – Acurácia do Usuário, Acurácia do Produtor e Coeficiente Kappa – e a análise visual dos mapeamentos corroboram esse resultado, indicando uma maior assertividade do classificador a partir da adição das bandas. Conclui-se que o método é eficiente para a área de estudo testada e pode ser facilmente replicado para situações análogas, visando melhorar a acurácia das classificações das imagens do satélite sino-brasileiro.

Palavras-chave: Uso e Cobertura da Terra; Imagens Multisensor; CBERS-4.

ABSTRACT

This study proposes the integration of multisensor images to enhance the accuracy of land use and land cover mapping. The motivation arises from observed errors in the supervised classification of images from the WPM sensor aboard the CBERS-4A satellite, which has 2 meters spatial resolution. While this resolution offers potential, its effectiveness is constrained by limited spectral capabilities, confined to the visible and near-infrared spectrum. To address this, shortwave infrared bands (SWIR1 and SWIR2) from Landsat were incorporated, resampled to 2 m using cubic convolution. Supervised classifications were conducted using the SVM classifier on two datasets: the original CBERS-4A image with four spectral bands and the modified image with the additional SWIR bands, totaling six spectral bands. Results indicate a significant increase in Global Accuracy for the image with the added bands (81.16%) compared to the original (70.47%). Other metrics—User Accuracy, Producer Accuracy, and Kappa Coefficient—along with visual assessments, confirm this improvement, demonstrating enhanced classifier performance. In conclusion, this method proves effective for the study area and can be easily replicated in similar contexts to improve the accuracy of China-Brazil Earth Resources Satellite image classifications.

Keywords: Land Use and Land Cover; Multisensor Images; CBERS-4A.

1. INTRODUÇÃO

A utilização de composições de imagens geradas por diferentes sensores remotos orbitais vem sendo relatada na literatura especializada desde a década de 1980 (Foster; Hall, 1981). O interesse nessa técnica surge, principalmente, pela possibilidade de geração de imagens multiespectrais com melhor resolução espacial (Lindgren; Kilston, 1996). De modo geral, são empregadas técnicas de fusão de imagens a partir da transformação do espaço de cor da imagem de RGB (*Red, Green e Blue*) para IHS (*Intensity, Hue e Saturation*) (Azarang; Kehtarnavaz, 2021). Meneses e Almeida (2012) explicam que, nesse processo, os componentes H e S, que armazenam a informação espectral, são preservados e o componente I, que apresenta o brilho, é descartado. Na sequência, este é substituído pela imagem pancromática de mais alta resolução espacial. Neste processo, é realizada uma reamostragem dos componentes H e S para a resolução espacial da banda pancromática, gerando uma composição multiespectral com maior resolução espacial.

A técnica, inicialmente conhecida como *Band Sharpening* (Vrabel, 1996), é, ainda, objeto de interesse de investigação por parte de diversos pesquisadores do ramo do sensoriamento remoto. Estudos recentes demonstram que o emprego de aprendizagem profunda (*deep learning*), por meio de redes neurais convolucionais, podem gerar melhores resultados para os procedimentos de melhoria de resolução espacial, em relação aos métodos predecessores (Sustika *et al.*, 2024). Além disso, atualmente, é possível combinar imagens de alta resolução espacial com imagens hiperespectrais, gerando dados valiosos para uma grande gama de análises baseadas em dados de sensores remotos (Ciotola *et al.*, 2024).

De modo geral, a melhoria da resolução espacial de imagens multiespectrais contribui para uma melhor distinção visual dos elementos presentes nas imagens, mas, também, pode contribuir para uma melhoria da acurácia das classificações supervisionadas. França e Sano (2011) demonstram que, a partir da fusão de imagens Landsat-5 (TM) e CBERS-2B(HRC), por transformação IHS, foi possível mapear as áreas de Campo Limpo Úmido, presentes no Distrito Federal, com maior acurácia. Nessa mesma linha, Gonçalves *et al.* (2009) apresentam que a fusão de imagens Landsat-7 (ETM+) e RADARSAT-1 (W1) proporcionou uma melhor identificação de feições características do ambiente flúvio-estuarino da Amazônia, contribuindo para o mapeamento dessas áreas.

Diversas outras abordagens da utilização de imagens multissensores vêm sendo relatadas na literatura especializada. Duan *et al.* (2020) explicam que dados multissensores coletados numa mesma área fornecem informações complementares, o que é útil para melhorar a capacidade de discriminação dos classificadores. Os autores apresentam uma metodologia para extração de

informações em multiníveis a partir de dados hiperspectrais associados à LiDAR que proporciona maior acurácia para a discriminação dos objetos imageados em uma área urbana.

Prudente *et al.* (2022) destacam a importância do sensoriamento remoto no processo de mapeamento de uso e cobertura da terra e apresentam uma metodologia para classificação de imagens do estado de Roraima, área com frequente cobertura de nuvens, a partir de uma combinação de dados ópticos (MSI/Sentinel-2) e de micro-ondas (SAR/Sentinel-1). Os resultados demonstram avanços em relação àqueles obtidos por métodos de classificação supervisionada de imagens de reflectância da superfície, tendo como referência para avaliação dos resultados os produtos do projeto MapBiomias.

Li *et al.* (2020) demonstram que o processo de classificação supervisionada de imagens de sensoriamento remoto multissensor vem sendo consideravelmente melhorado a partir do emprego de técnicas de aprendizado profundo. Os autores propõem uma nova estrutura de fusão de imagens multissensor para realizar a classificação de imagens a partir de diversas fontes de dados de sensoriamento remoto. Os resultados indicam acurácia superior a 90% para os casos testados e demonstram como o emprego de dados multissensor, a partir de técnicas de aprendizado profundo, tem potencial para geração de mapeamentos de uso e cobertura da terra em altíssima resolução espacial e com elevada acurácia.

Esses estudos mostram como essa abordagem se mantém atual no campo do sensoriamento remoto, pois com o aumento da disponibilidade de dados de diferentes sensores, é interesse o desenvolvimento de métodos capazes de explorar o potencial oferecido pelos dados.

Nesse sentido, este trabalho buscou avaliar a classificação supervisionada de imagens do satélite CBERS-4A (WPM), com 2 metros de resolução espacial, associadas às bandas do infravermelho de ondas curtas do satélite Landsat-8 (OLI), com 30 m de resolução espacial. Tal abordagem é proposta a partir do interesse em aprimorar a acurácia dos mapeamentos de uso e cobertura da terra a partir das imagens CBERS-4A. Isso, pois se nota um grande potencial fornecido pela resolução espacial das imagens CBERS-4A que, em função da limitada resolução espectral, acaba não sendo eficaz para a distinção de alguns alvos.

As imagens CBERS começaram a ser geradas, para o território brasileiro e chinês, no final da década de 1990. Até o momento, 6 satélites da família CBERS já entraram em operação, gerando uma importante série histórica de imagens para o território nacional, que vem subsidiando programas de monitoramento do desflorestamento da Amazônia, de queimadas, de áreas canavieiras (Instituto Nacional de Pesquisas Espaciais, 2024), bem como várias pesquisas científicas realizada no país. Com o início da operação do CBERS-4A, surgiu a possibilidade de realização de análises em escala de maior detalhe, a partir da coleta de dados pela banda pancromática que possui 2 m de resolução espacial. Essa resolução nos permite distinguir objetos com área superior a 4 m², o que cria

possibilidades para a identificação de detalhes que nenhuma outra imagem de satélite gratuita oferece atualmente. Esses detalhes são relevantes, por exemplo, para o mapeamento de uso e cobertura da terra em escala municipal, pois, do ponto de vista espacial, é possível distinguir diferentes materiais construtivos das edificações, pistas de rolamento, vegetação presente em vias públicas, quintais, dentre outros.

Contudo, quanto maior for a resolução espacial de uma imagem, maior é o desafio para a classificação da imagem com satisfatória acurácia. Tal fato pode ser verificado ao se comparar a acurácia das classificações supervisionadas dessas imagens com as de sensores com resolução inferior, como realizado por Carnaúba (2021). A baixa acurácia encontrada na classificação dessas imagens, quando realizada em cenas complexas (em áreas amplas e com grande diversidade de tipologias de uso e cobertura da terra), pode ser explicada pela resolução espectral das imagens CBERS-4A, que operam somente na região da luz visível e do infravermelho próximo. Assim, alguns materiais que são morfologicamente diferenciáveis nas imagens, mas que apresentam respostas espectrais semelhantes nessa faixa em que o sensor opera – por exemplo, o solo exposto e as telhas de cerâmica, ou as telhas de fibrocimento e o asfalto – são praticamente indistinguíveis por técnicas tradicionais de classificação supervisionada de imagens. Portanto, percebe-se que o potencial de mapeamento do uso e cobertura da terra com base nessas imagens é subutilizado, uma vez que tem apresentado acurácia inferior às encontradas para a classificação de imagens Landsat (OLI - *Operational Land Imager*) ou Sentinel (MSI - *Multispectral Imager*).

É diante das questões expostas que este estudo é proposto. Busca-se, por meio do processo a ser apresentado, aprimorar a qualidade da classificação supervisionada de imagens CBERS-4A (WPM - Câmera Multiespectral e Pancromática de Ampla Varredura) a partir da associação dessas com as bandas do infravermelho de ondas curtas (SWIR-1 e SWIR-2 - *Short-Wave Infrared*), coletadas pelo Landsat (OLI), reamostradas para 2 m. Sobretudo, busca-se avaliar os benefícios e prejuízos da metodologia proposta, tendo em vista a simplicidade do método e dos erros inerentes a esse processo de associação de resoluções espaciais bastante distintas.

2. ÁREA DE ESTUDO

O estudo foi realizado a partir da demanda de mapeamento do uso e cobertura da terra do município de Caldas (Minas Gerais), local onde é desenvolvido um Projeto de Extensão que visa dar suporte aos gestores públicos municipais para a preservação de locais de interesse ambiental, como picos e cachoeiras.

O município está localizado na região Sul do estado de Minas Gerais (Figura 1) e no seu território se desenvolvem, principalmente, atividades de agricultura, silvicultura, pecuária,

mineração, além dos núcleos urbanos da sede municipal e dos distritos. São encontradas, ainda, regiões compostas por fragmentos de mata atlântica em estágio médio a avançado de regeneração natural, sobretudo nas bordas da Serra da Pedra Branca (Figura 2).




Figura 1 – Fragmento de mata atlântica junto ao Pico da Pedra Branca. Ao fundo, nota-se o predomínio de pastagens.
Fonte: IBGE (2022) e Imagem CBERS-4A (maio/2023). Elaborado pelo autor.

A partir da compreensão da relevância ambiental desse local, a câmara municipal aprovou a lei n.º 1973, de 29 de dezembro de 2006 (Caldas, 2006), que cria a Área de Preservação Ambiental (APA) do Santuário Ecológico da Pedra Branca, e a Lei Orgânica do Município, em 2007, (Caldas, 2007) que determina que um conjunto de cachoeiras e as “pedras” (picos) do município devem ser imunes à degradação ambiental.

Embora o arcabouço legal defina claramente as áreas a serem preservadas, o município não dispõe da delimitação dessas áreas. Tampouco há uma infraestrutura de dados espaciais ou estudos do meio físico que deem suporte à delimitação dessas áreas. Visando colaborar nesse sentido, uma equipe de docentes e discentes do Departamento de Geografia e Planejamento Ambiental (DGPA) da Unesp de Rio Claro vem dando suporte para o mapeamento dessas áreas de interesse em conservação ambiental. Dentre outras atividades do grupo, notou-se a necessidade da elaboração de um mapeamento do uso e cobertura da terra do município em escala de detalhe, que é um dado base para o diagnóstico ambiental que vem sendo realizado. A partir desse mapeamento, associado a outros dados, será possível avaliar a qualidade ambiental da área, os principais agentes causadores do

desmatamento no município e, sobretudo, discutir as condições das áreas de preservação permanente no município.



Figura 2 – Fragmento de mata atlântica junto ao Pico da Pedra Branca. Ao fundo, nota-se o predomínio de pastagens.
Fonte: Acervo pessoal, 2024.

3. MATERIAIS E MÉTODOS

Inicialmente, foram selecionadas as imagens do satélite CBERS-4A (WPM), disponibilizadas pela Divisão de Geração de Imagens (DGI) do Instituto Nacional de Pesquisas Espaciais (INPE), coletadas em maio de 2023. Esse sensor dispõe de 4 bandas multiespectrais (*Blue, Green, Red e Near Infrared* – RGB e NIR), com 8 m de resolução espacial, mais a banda 0, pancromática, com 2 m de resolução espacial.

De posse das imagens, foi realizado procedimento de fusão das imagens a partir da técnica de *pansharpening*. Essa técnica combina informações de detalhes espaciais extraídas da banda pancromática do sensor visando a produzir uma imagem de mais alta resolução, preservando as informações espectrais das bandas multiespectrais (Yang *et al.*, 2017). Esse procedimento foi realizado por meio do plugin CBERS4A *downloader*, disponível no software QGIS, que permite, além da seleção e download das imagens, realizar a composição das bandas RGB+NIR e o procedimento *pansharpening* aplicando a transformação de Brovey (Klippel, 2021). O resultado desse processo gerou uma imagem multiespectral da região visível e infravermelho próximo com 2 m de resolução espacial.

Essa imagem foi submetida a um processo de classificação supervisionada utilizando-se o software ArcGIS Pro e por meio do algoritmo *Support Vector Machine* (SVM), conforme descrito

por Magalhães (2024). A partir da observação da baixa acurácia dessa classificação supervisionada, foi realizada a associação da imagem CBERS-4A (RGB+NIR), com 2 m de resolução espacial, às bandas do infravermelho de ondas curtas do satélite Landsat-8 (OLI), com 30 m de resolução espacial. A intenção desse processo é a de adicionar informação espectral à imagem de modo a contribuir para uma melhor condição de distinção das classes por parte do algoritmo classificador, que opera no campo espectral da imagem.

Para tanto, foram baixadas as bandas 6 e 7 do satélite Landsat-8 (OLI), conhecidas como bandas SWIR-1 (1,57 – 1,65 μm) e SWIR-2 (2,11 – 2,29 μm), do mesmo mês e ano da imagem CBERS-4A (maio/2023). Esses dados foram reamostrados para 2 m, testando-se os métodos vizinho mais próximo, bilinear, majoritário e convolução cúbica. Os dois primeiros métodos mantêm o aspecto visual da imagem, criando somente uma divisão dos pixels maiores em parcelas menores. O terceiro gera uma imagem com aspecto de filtragem espacial, onde as bordas são destacadas. Já o quarto, considerado um método mais complexo de reamostragem, gera novos valores a partir da interpolação dos valores encontrados nos 16 pixels vizinhos àquele de análise (ESRI, 2024). Como resultado, é gerada uma imagem com aparência gráfica mais suave, na qual as formas da imagem original (Landsat) se aproximaram mais das formas identificadas nas imagens CBERS-4A, o que favoreceu a criação de uma composição final com menores distorções. A Figura 3 apresenta o aspecto das imagens a partir dos processos de reamostragem mencionados.

As bandas SWIR 1 e 2, reamostradas para 2 m por meio da convolução cúbica, foram associadas às bandas espectrais da imagem CBERS-4A, gerando uma composição multiespectral com 6 bandas, sendo 3 da região visível, 1 do IR próximo e 2 do SWIR.

Foram realizados testes de composições coloridas de falsa cor, buscando evidenciar os ganhos e prejuízos obtidos a partir da técnica empregada. De modo geral, percebeu-se a proposta como vantajosa, pois permitiu distinguir um número maior de tipologias de uso e cobertura da terra a partir da inserção das bandas do SWIR.

As tipologias de uso e cobertura da terra foram identificadas a partir da inspeção visual da imagem, considerando coloração, textura e contexto, e foram validadas a partir da comparação com imagens de maior resolução espacial disponíveis para visualização gratuita via web. As tipologias identificadas estão organizadas no Quadro 1.


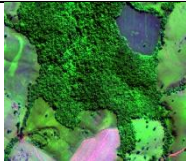
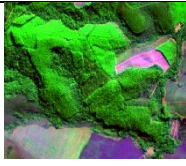

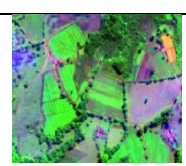
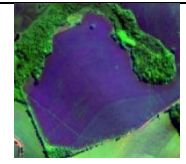
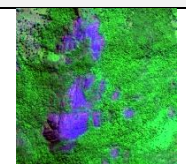

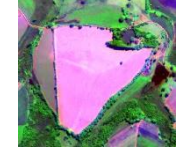




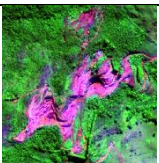




Figura 3 – Processo de reamostragem da imagem Landsat. (A) Imagem original; (B) Vizinho mais próximo; (C) Bilinear; (D) Majoritário; (E) Convolução Cúbica.

Fonte: Elaborado pelo autor.

Quadro 1: Tipologias de uso e cobertura da terra identificadas.

ID	Classe	Imagem (RGB-346; RGB-321; RGB-412)	Características
Grupo Vegetação			
11	Vegetação Nativa Arbórea		Verde escuro, rugosidade
12	Silvicultura		Verde claro, liso, volume
13	Pastagem		Verde claro, liso, rasteiro
14	Cultivos Agrícolas		Verde claro, liso, linhas geométricas
15	Plantio Colheita		Roxo escuro, liso, volume
Grupo Terrenos Expostos			
21	Afloramento Rochosos		Azul-lilás, formas irregulares, picos das serras
22	Solo Exposto Amarelo		Amarelo, linhas de plantio em fase inicial, mescla de plantio e solo, formas geométricas
23	Solo Exposto Rosa Claro		Rosa claro, liso, formas variadas

24	Solo Exposto Lilás		Lilás, liso, formas variadas
Grupo Áreas antropizadas			
31	Área Urbana – Cerâmica		Marrom, pequenos telhados
32	Área Urbana – Concreto		Branco, formas geométricas
33	Área Urbana – Asfalto		Cinza escuro, formas geométricas lineares
34	Mineração		Rosa-vermelho forte, formas geométricas
Grupo Corpos d'Água			
41	Água Limpa		Azul mais escuro, absortância no IR
42	Água Turva		Azul mais claro, reflectância no IR

Fonte: Elaborado pelo autor.

O procedimento de classificação supervisionada foi novamente realizado, conforme os mesmos parâmetros mencionados anteriormente, porém, neste momento, para a imagem com as 6 bandas compostas. Os resultados das classificações de ambas as imagens (RGB-NIR e RGB-NIR-SWIR) foram submetidos a um processo de verificação de acurácia utilizando-se das métricas Acurácia do Produtor (AP), Acurácia do Usuário (AU), Acurácia Global (AG) e Coeficiente Kappa. Isso foi realizado com auxílio da criação de pontos aleatórios, através da estratégia randômica estratificada, e da construção de matriz de confusão.

A verdade terrestre (*ground truth*), utilizada para verificar a acurácia dos dados, foi criada para cada ponto supramencionado, utilizando-se como referência as imagens CBERS-4A e de dados coletados em campo, além de imagens de melhor resolução espacial e imagens de *Street View*, disponíveis gratuitamente na web.

Considerando a grande quantidade de classes mapeadas, a semelhança entre algumas classes e visando tornar a apresentação dos resultados mais concisa e objetiva, foi realizado um agrupamento das classes de uso e cobertura da terra. Assim, os resultados são apresentados para nove classes, que são: Vegetação Arbórea, Áreas agrícolas, Plantios em Senescência, Afloramento Rochoso, Solo Exposto, Área Urbana, Mineração, Água Limpa e Água Turva. Os resultados são apresentados e discutidos a seguir.

4. RESULTADOS E DISCUSSÕES

Um dos principais alvos de interesse a ser identificado, no âmbito do projeto de extensão, são os afloramentos rochosos, pois representam os picos a serem preservados. Essas áreas ganharam forte destaque na nova composição gerada, o que proporciona uma melhor orientação para o usuário coletar as amostras de treinamento do algoritmo classificador, bem como para uma distinção mais eficaz pelo algoritmo (Figura 4).

A figura evidencia que a utilização das bandas adicionais da região do SWIR proporcionou uma melhor distinção visual de diferentes classes de uso e cobertura da terra. De modo simplificado, percebe-se o surgimento de novas cores nas imagens, o que significa uma melhor condição para distinguir os alvos presentes.

Nota-se que a adição dessas bandas fez com que os afloramentos rochosos assumissem uma nova coloração, tornando-os visivelmente diferentes dos solos expostos, o que não se pode observar na imagem original. A baixa variabilidade de cores compromete a identificação correta das classes por parte do usuário e limita a separação delas por parte do classificador, pois algoritmos como o SVM operam sobre a informação espectral das imagens. Assim, uma maior disponibilidade de dados espectrais implica em melhores condições para a separação das classes.

A mesma situação é observada nos plantios em fase inicial de crescimento, locais ainda com baixa cobertura do solo. Na imagem original, vários desses locais apareciam com a mesma tonalidade de solos expostos (rosa claro). Já na imagem com as bandas adicionadas, esses locais aparecem em tons amarelados, indicando a variação da classe analisada. Além disso, essa imagem mostra novas variações de tonalidade das cores rosa e roxa, o que indica a possibilidade de se identificar outros tipos de solos e/ou cobertura dos solos.

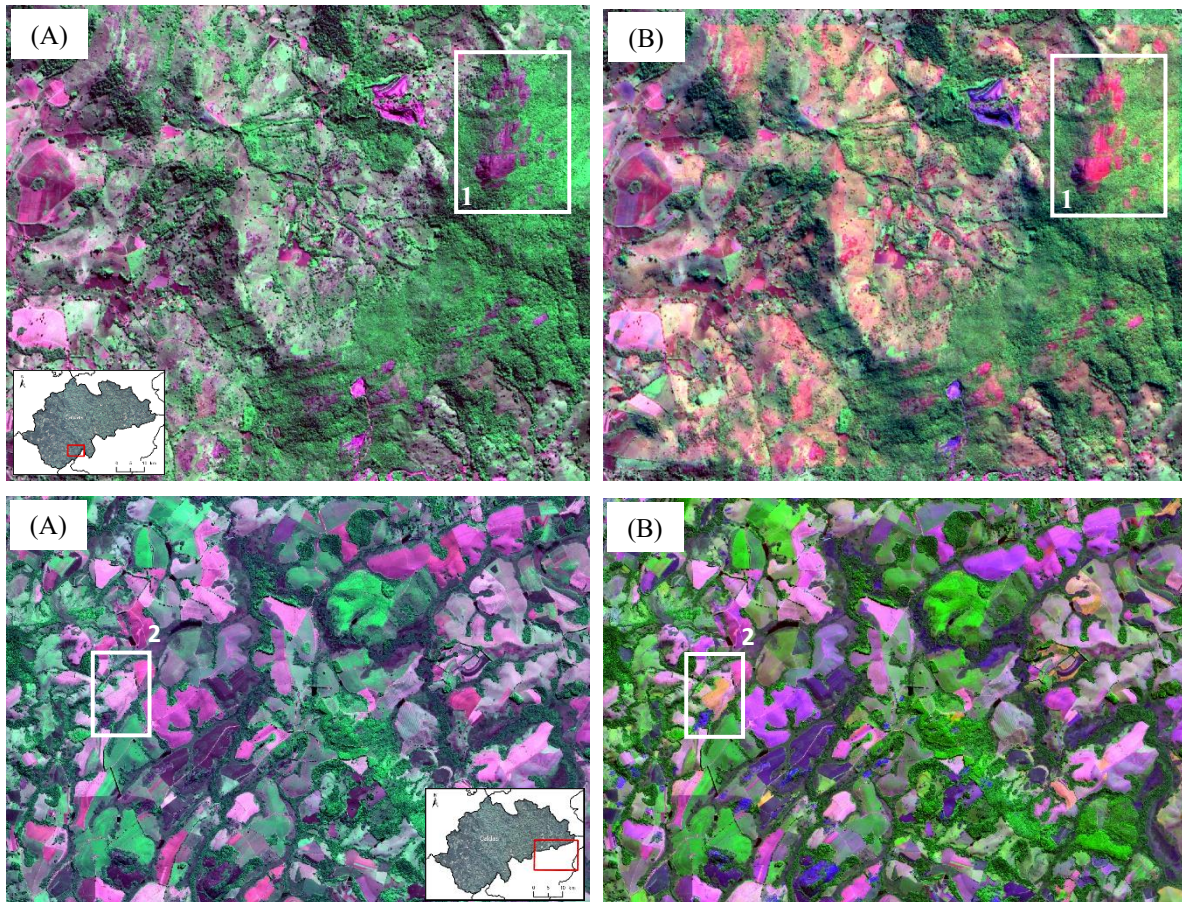


Figura 4 – Comparação das composições coloridas. (A) CBERS-4A (RGB-342). (B) CBERS-4A + Landsat (RGB-346). Em 1, destaque para os afloramentos rochosos. Em 2, destaque para as áreas de plantio em fase inicial de crescimento.

Fonte: Elaborado pelo autor.

Por outro lado, ao realizar o zoom na imagem para observar os detalhes, nota-se que as bandas do Landsat comprometem a definição espacial proporcionada pela imagem CBERS. Sobretudo nos locais de maior concentração de objetos pequenos e de maior diversidade de elementos, como nas áreas urbanizadas. Nesses locais, a mescla das imagens promoveu a criação de um efeito “esfumaçado”, reduzindo a definição dos elementos e comprometendo a separação dessas classes de modo preciso (Figura 5).

Embora essa perda de definição possa comprometer a qualidade do mapeamento dessas áreas, são poucas as áreas urbanizadas do município, logo as vantagens do emprego da técnica se mostraram superiores em relação às desvantagens para a área de estudo. Essa avaliação é realizada, efetivamente, a partir da comparação dos resultados das classificações supervisionadas das imagens. A Figura 6 apresenta a comparação de um trecho das classificações, onde se pode observar uma maior definição das classes geradas para imagem com as bandas adicionadas.




Figura 5 – Imagem CBERS-4A + Landsat (RGB-346) da área urbana de Caldas (MG). Observa-se o efeito esfumado da imagem, que reduz a definição dos elementos presentes.

Fonte: Elaborado pelo autor.

A Figura 6 evidencia uma grande diferença na definição das classes. A imagem com as bandas adicionadas (6-C) proporcionou um resultado com menor quantidade de ruídos, onde os limites das classes estão visivelmente mais bem definidos. Nessa imagem, percebe-se também uma menor quantidade de pixels classificados isoladamente, o que causa o efeito “salpicado” da imagem original (6-B). Em 6-C, há uma maior coesão das classes, diferentemente do primeiro resultado (6-B), onde percebe-se uma maior mescla de cores nos mesmos espaços. Sobretudo, nota-se uma maior assertividade do classificador na definição da tipologia a ser mapeada para cada local. O vermelho escuro representa, por exemplo, a classe mineração, que foi identificada erroneamente na imagem original nos locais onde há o solo exposto. Além disso, o rosa, que representa as áreas de afloramentos rochosos, está presente nos locais de solos expostos que deveriam ser classificados como solo exposto. Essas situações foram menos presentes na imagem com as bandas adicionadas, o que indica uma melhor acurácia dos resultados utilizando a adição de bandas proposta.

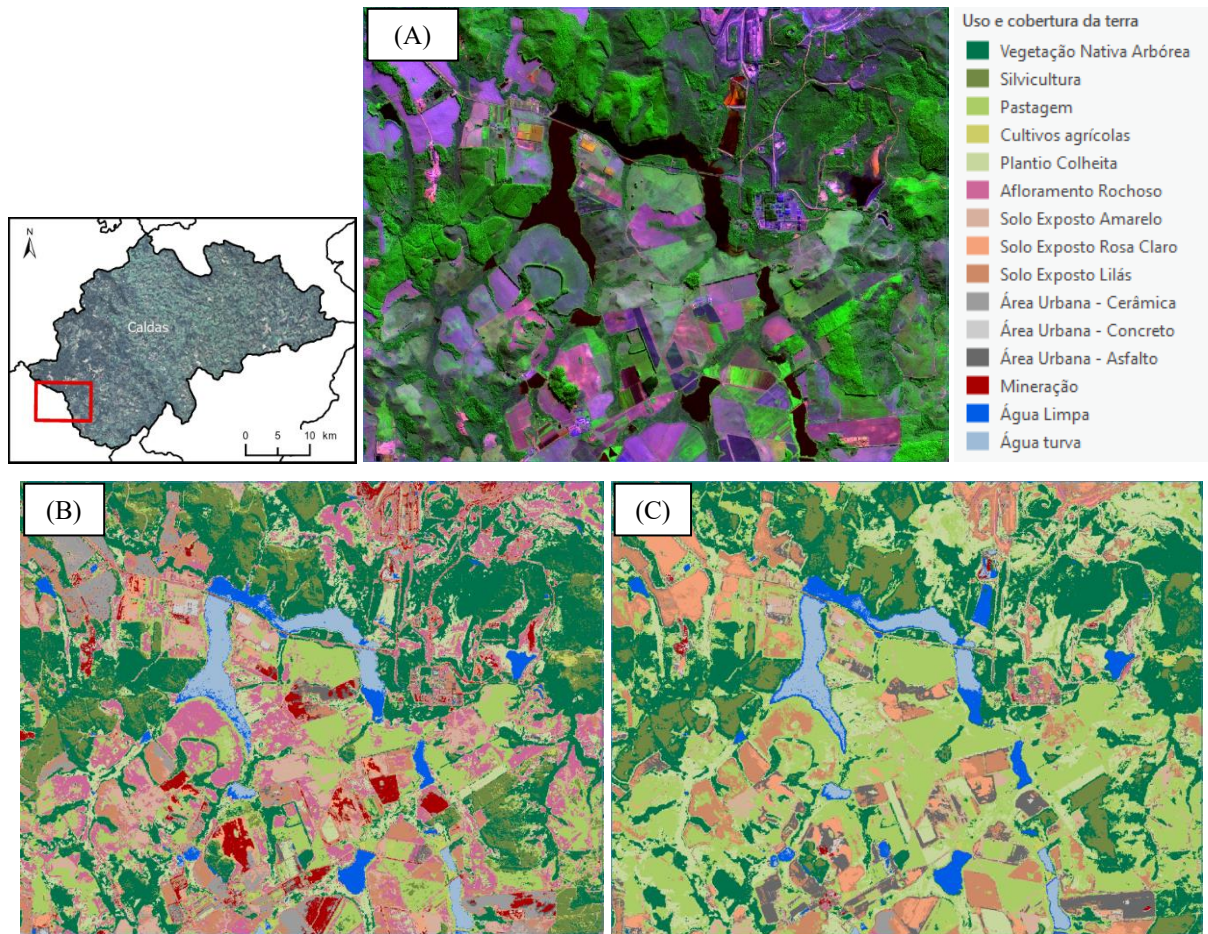


Figura 6 – Comparação de resultados em um trecho da classificação supervisionada das imagens. (A) Composição RGB-346. (B) Resultado da classificação a partir da imagem original. (C) Resultado da classificação a partir da imagem com bandas adicionadas.

Fonte: Elaborado pelo autor.

As Tabelas 1 e 2, a seguir, apresentam os resultados da avaliação da acurácia dos dados.

Tabela 1: Acurácia da classificação da imagem original.

Classes	Veg. Arbórea	Agricultura	Colheita	Afl. Rochoso	Solo Exposto	A. Urbana	Mineração	Água Limpa	Água Turva	Total	U. Acc.	Kappa
Veg. Arbórea	160	25	0	0	0	0	0	0	0	185	0,8649	0,6087
Agricultura	9	148	0	0	2	0	0	0	0	159	0,9308	
Colheita	5	18	14	2	1	0	0	0	1	41	0,3415	
Afl. Rochoso	0	22	11	2	12	0	0	0	0	47	0,0426	
Solo Exposto	1	12	5	0	38	6	1	0	0	63	0,6032	
A. Urbana	0	0	0	0	14	8	0	0	0	22	0,3636	
Mineração	0	0	0	0	3	12	2	0	0	17	0,1176	
Água Limpa	0	0	0	0	0	1	0	9	0	10	0,9000	
Água Turva	0	0	0	0	0	0	0	0	8	8	1,0000	
Total	175	225	30	4	70	27	3	9	9	552	0,0000	
P. Acc.	0,9143	0,6578	0,4667	0,5000	0,5429	0,2963	0,6667	1,0000	0,8889	0,0000	0,7047	
Kappa												

Fonte: Elaborado pelo autor.

Tabela 2: Acurácia da classificação da imagem com bandas adicionadas.

Classes	Veg. Arbórea	Agricultura	Colheita	Afl. Rochoso	Solo Exposto	A. Urbana	Mineração	Água Limpa	Água Turva	Total	U_Acc.	Kappa
Veg. Arbórea	149	13	0	0	0	0	0	0	0	162	0,9198	0,7417
Agricultura	11	193	1	0	7	0	0	0	0	212	0,9104	
Colheita	12	16	25	1	6	0	0	0	0	60	0,4167	
Afl. Rochoso	2	1	0	3	1	2	0	0	0	9	0,3333	
Solo Exposto	1	2	4	0	42	2	0	0	0	51	0,8235	
A. Urbana	0	0	0	0	14	16	0	0	0	30	0,5333	
Mineração	0	0	0	0	0	7	3	0	0	10	0,3000	
Água Limpa	0	0	0	0	0	0	0	9	1	10	0,9000	
Água Turva	0	0	0	0	0	0	0	0	8	8	1,0000	
Total	175	225	30	4	70	27	3	9	9	552	0,0000	
P_Acc.	0,8514	0,8578	0,8333	0,7500	0,6000	0,5926	1,0000	1,0000	0,8889	0,0000	0,8116	
Kappa												

Fonte: Elaborado pelo autor.

A verificação da acurácia das classificações corrobora as impressões obtidas a partir da análise visual. Nota-se uma significativa melhoria na assertividade do classificador a partir da adição das bandas de infravermelho de ondas curtas. Tal fato está expresso em uma maior acurácia global para a imagem com bandas adicionadas (81,16%) em relação à imagem original (70,47%). Essa métrica é reforçada por um resultado mais expressivo, também, do coeficiente Kappa, que avança de 60,87%, da imagem original, para 74,17%, na imagem com as bandas adicionadas.

Nota-se uma melhoria da acurácia do mapeamento de praticamente todas as classes e em ambos os parâmetros analisados, que são a Acurácia do Usuário (U_Acc) e Acurácia do Produtor (P_Acc). Essas métricas indicam, para cada classe, a capacidade do algoritmo para prever corretamente uma classe, conforme a referência terrestre adotada. Nesse sentido, a inclusão das novas bandas se mostrou eficiente para a melhoria do mapeamento do uso e cobertura da terra, reduzindo, com isso, a demanda por correções manuais e procedimentos de pós-classificação.

5. CONCLUSÕES

Este estudo apresentou um método simples para a adição de bandas espectrais à imagem CBERS-4A com intuito de promover uma melhoria na acurácia da classificação supervisionada dessa imagem. A proposta se originou a partir da observação de importantes erros de classificação dessa imagem, a partir de classificadores de Machine Learning como o SVM. Sobretudo, a proposta busca melhorar as condições de mapeamento do uso e cobertura da terra a partir dessas imagens, tendo em vista o potencial fornecido por sua resolução espacial de 2 m, que é limitado pela baixa resolução espectral.

Os resultados se mostraram eficazes para a área de estudo testada e contemplam aos objetivos propostos. É importante destacar que o município é composto por grandes áreas homogêneas, como os plantios agrícolas, a silvicultura e as pastagens. Tais características contribuíram para os bons resultados encontrados, uma vez que a generalização da informação espacial promovida pelas bandas

do Landsat pouco comprometeu os resultados. Acredita-se que a técnica proposta não seja adequada para o mapeamento de grandes áreas urbanizadas, pois nesses locais há uma grande diversidade de elementos menores, próximos uns dos outros.

Enfatiza-se aqui a simplicidade do método proposto e a utilização de dados gratuitos de ambos os sensores, o que viabiliza a replicação para estudos semelhantes. A proposta contribuiu para uma menor intervenção do usuário nos processos de pós-classificação, o que contribui para uma maior agilidade e eficácia dos mapeamentos. É importante lembrar que o dado de uso e cobertura da terra é basal para um amplo conjunto de análises espaciais e pode subsidiar ações de gestão e planejamento territorial, sobretudo em municípios que não dispõem de uma infraestrutura de dados espaciais ou de levantamento de dados sistemáticos.

Por fim, acredita-se que novos estudos podem ser realizados a partir dos resultados encontrados, como o mapeamento de alvos específicos e o monitoramento das transformações temporais do uso da terra, a fim de verificar se há ganhos em outras áreas. Sobretudo, acredita-se que o emprego de técnicas de aprendizado profundo possa promover resultados ainda mais acurados para a classificação do conjunto de dados proposto, uma vez que a literatura especializada tem demonstrado o potencial dessas técnicas para a classificação de cenas complexas.

REFERÊNCIAS

AZARANG, A.; KEHTARNAVAZ, N. **Image Fusion in Remote Sensing: Conventional and Deep Learning Approaches**. Cham: Springer International Publishing, 2021. 93p.

CALDAS. Prefeitura Municipal. **Lei n.º 1973, de 29 de dezembro de 2006**. Cria a Área de Proteção Ambiental do Município de Caldas "Santuário Ecológico da Pedra Branca", regulamenta o uso e ocupação do solo e o exercício de atividades pelo setor público e privado. Câmara Municipal de Caldas, 2006.

CALDAS. Câmara Municipal. **Lei Orgânica do Município de Caldas**. Diário Oficial do Município, 28/07/2007.

CARNAÚBA, E. A. A. **Mapeamento do uso e ocupação da terra utilizando os satélites Landsat-8, Sentinel 2B e CBERS-4A em área de agricultura no município de Limoeira do Norte-CE**. 2021. 55 f. Monografia (Trabalho de Conclusão de Curso em Ciências Ambientais). Universidade Federal do Ceará, Fortaleza, 2021.

CIOTOLA, M.; GUARINO, G.; VIVONE, G.; POGGI, G.; CHANUSSOT, J.; PLAZA, A.; SCARPA, G. Hyperspectral Pansharpening: Critical Review, Tools and Future Perspectives. **ArXiv**, v.1, p. 1-22, 2024.

DUAN, P.; KANG, X.; GHAMISI, P.; LIU, Y. Multilevel Structure Extraction-Based Multi-Sensor Data Fusion. **Remote Sensing**, v. 12, n. 24, p. 4034, 2020.

- ESRI. **Resample**. 2024. Disponível em: <https://pro.arcgis.com/en/pro-app/latest/tool-reference/data-management/resample.htm>. Acesso em: 2 nov. 2024.
- FOSTER, J. L.; HALL, D. K. Multisensor analysis of hydrologic features with emphasis on the SEASAT SAR. Eng. **Remote Sensing**, v. 47, n. 5, p. 655-664, 1981.
- FRANÇA, A. M. S.; SANO, E. E. Mapeamento de áreas de campo limpo úmido no Distrito Federal a partir de fusão de imagens multiespectrais. **Sociedade & Natureza**, v. 23, n. 2, p. 197-209, 2011.
- GONÇALVES, F. D.; SOUZA FILHO, P. W. M.; PARADELLA, W. R.; MIRANDA, F. P. Fusão de dados multisensor para a identificação e o mapeamento de ambientes fluvio-estuarinos da Amazônia. **Revista Brasileira de Geofísica**, v. 27, p. 57-67, 2009.
- INPE - INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Satélite Sino-Brasileiro de Recursos Terrestres**. 2024. Disponível em: <https://www.gov.br/inpe/pt-br/programas/cbers>. Acesso em: 1 nov. 2024.
- KLIPPEL, S. **CBERS4A Downloader**. QGIS Plugin. Disponível em: <https://github.com/sandroklippel/cbers4a>. Acesso em: 28 mar. 2022.
- LI, H.; GHAMISI, P.; RASTI, B.; WU, Z.; SHAPIRO, A.; SCHULTZ, M.; ZIPF, A. A Multi-Sensor Fusion Framework Based on Coupled Residual Convolutional Neural Networks. **Remote Sensing**, v. 12, n. 12, p. 2067, 2020.
- LINDGREN, J. E.; KILSTON, S. A projective pan sharpening algorithm. Multispectral Imaging for Terrestrial Applications. **Proceedings of SPIE**, v. 2818, p. 128-137, 1996.
- MAGALHÃES, D. M. Avaliação da acurácia da classificação supervisionada de imagens de sensoriamento remoto utilizando o software ArcGIS Pro. In: LADWIG, N. I.; SUTIL, T.; SILVA, C. H. R.; GIACCOM, B. **Planejamento e Gestão Territorial**. São Carlos: Pedro & João Editores, 2024.
- MENESES, P. R.; ALMEIDA, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: CNPq, 2012. 45p.
- PRUDENTE, V. H. R.; SKAKUN, S. S.; OLDONI, L. V.; XAUD, H. A. M.; XAUD, M. R.; ADAMI, M. A.; SANCHES, I. D. A. S. Multisensor approach to land use and land cover mapping in Brazilian Amazon. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 189, p. 95-109, 2022.
- SUSTIKA, R.; SUKSMONO, A. B.; DANUDIRDJO, D.; WIKANTIKA, K. Remote Sensing Image Pansharpening using Deep Internal Learning with Residual Double-Attention Network. **IEEE Access**, v. 11, p. 1-14, 2024.
- VRABEL, J. Multispectral Imagery Band Sharpening Study. **Photogrammetric Engineering & Remote Sensing**, v. 62, p. 1075-1083, 1996.
- YANG, Y.; WAN, W.; HUANG, S. H.; LIN, P.; QUE, Y. A Novel Pan-Sharpener Framework Based on Matting Model and Multiscale Transform. **Remote Sensing**, v. 9, n. 4, p. 391, 2017.