

DETECÇÃO AUTOMÁTICA DE NUVENS E SOMBRAS EM IMAGENS DE SATÉLITE

Paulo Sergio Lima Mattos¹ e Thiago Statella²

Resumo

Este trabalho propõe um algoritmo para a detecção de nuvens e sombras em imagens de satélite, visando aprimorar a qualidade dos dados utilizados em monitoramento ambiental, agricultura de precisão e previsão do tempo. A abordagem integra múltiplos índices espectrais – NDVI, WI, HOT, WP e D – combinados com técnicas de processamento de imagens para criar máscaras específicas para nuvens e sombras. Desenvolvido em Python com a biblioteca GRASS GIS, o sistema automatiza o processamento de imagens Sentinel-2, gerando máscaras de nuvens a partir da interseção dos índices NDVI, WI e HOT, e máscaras de sombras a partir dos índices WP e D. Uma etapa de pós-processamento, fundamentada em análise de vizinhança, minimiza ruídos e refina a segmentação dos elementos de interesse. Os testes realizados demonstraram que a integração dos índices espectrais eleva significativamente a precisão da detecção, alcançando acurácia superior a 85% em comparação com dados de referência.

Palavras-chave: Algoritmo; GRASS GIS; Sentinel-2; Índices Espectrais; Pós-processamento.

AUTOMATIC DETECTION OF CLOUDS AND SHADOWS IN SATELLITE IMAGES

Abstract

This work proposes an algorithm for detecting clouds and shadows in satellite images, aiming to improve the quality of the data used in environmental monitoring, precision agriculture, and weather forecasting. The approach integrates multiple spectral indices – NDVI, WI, HOT, WP, and D – combined with image processing techniques to create specific masks for clouds and shadows. Developed in Python using the GRASS GIS library, the system automates the processing of Sentinel-2 images, generating cloud masks from the intersection of the NDVI, WI, and HOT indices, and shadow masks from the WP and D indices. A post-processing stage, based on neighborhood analysis, minimizes noise and refines the segmentation of the elements of interest. Tests have shown that the integration of spectral indices significantly increases detection accuracy, achieving an accuracy greater than 85% compared to reference data.

Keywords: Algorithm; GRASS GIS; Sentinel-2; Spectral Indices; Post-processing.

¹ Bacharelado em Ciências da Computação, IFSP, Cientista da computação e paulosergio_lm@hotmail.com.

² Doutor em Ciências Cartográficas, IFSP, Professor, Terra em bytes e thiago.statella@ifsp.edu.br.

DETECCIÓN AUTOMÁTICA DE NUBES Y SOMBRAS EN IMÁGENES SATELITALES

Resumen

Este trabajo propone un algoritmo para la detección de nubes y sombras en imágenes satelitales, con el objetivo de mejorar la calidad de los datos utilizados en el monitoreo ambiental, la agricultura de precisión y la previsión meteorológica. La metodología integra múltiples índices espectrales – NDVI, WI, HOT, WP y D – combinados con técnicas de procesamiento de imágenes para crear máscaras específicas para nubes y sombras. Desarrollado en Python utilizando la biblioteca GRASS GIS, el sistema automatiza el procesamiento de imágenes Sentinel-2, generando máscaras de nubes a partir de la intersección de los índices NDVI, WI y HOT, y máscaras de sombras a partir de los índices WP y D. Una etapa de postprocesamiento, basada en el análisis de vecindario, minimiza los ruidos y refina la segmentación de los elementos de interés. Las pruebas realizadas demostraron que la integración de los índices espectrales incrementa significativamente la precisión de la detección, alcanzando una exactitud superior al 85% en comparación con datos de referencia. Así, el algoritmo no solo reduce las distorsiones inherentes a las imágenes satelitales, sino que también contribuye a mejorar la confiabilidad de los datos.

Palabras-clave: Algoritmo; GRASS GIS; Sentinel-2; Índices Espectrales; Postprocesamiento.

Introdução

A análise de imagens de satélite desempenha um papel fundamental em diversas áreas, como no monitoramento ambiental, onde a observação contínua da superfície terrestre permite identificar desmatamentos, queimadas e mudanças no uso do solo. No entanto, a presença de nuvens pode ocultar regiões críticas, dificultando a análise. Na meteorologia, a detecção precisa de nuvens auxilia na previsão do tempo e no monitoramento de tempestades, pois diferentes tipos de nuvens influenciam as condições atmosféricas. Na agricultura de precisão, imagens de satélite são usadas para avaliar a saúde da vegetação e otimizar o uso de insumos agrícolas, mas a presença de nuvens e sombras pode interferir na interpretação dos índices espectrais. Já nos estudos climáticos, a análise da cobertura de nuvens ao longo do tempo é essencial para entender padrões de aquecimento global e mudanças na atmosfera. Para mitigar esses desafios, técnicas automatizadas de detecção de nuvens e sombras vêm sendo desenvolvidas, permitindo um processamento mais preciso e eficiente.

Neste contexto, este trabalho propõe um algoritmo para a detecção automática de nuvens e sombras em imagens do satélite Sentinel-2. O algoritmo foi desenvolvido utilizando o software GRASS GIS e se baseia no cálculo de múltiplos índices espectrais para segmentação das áreas de interesse. São utilizados os seguintes índices:

- WP (Water Pixel): Identifica corpos d'água para reduzir falsos positivos.
- NDVI (Normalized Difference Vegetation Index): Distingue áreas vegetadas e não vegetadas, ajudando na separação entre solo exposto e nuvens.
- WI (Whiteness Index): Identifica pixels mais claros na imagem, isolando aqueles que podem corresponder a nuvens.
- HOT (Haze-Optimized Transformation): Destaca a presença de vapor d'água, auxiliando na segmentação de nuvens.
- D (Dark Pixel Mask): Detecta pixels escuros associados a sombras.

A máscara de nuvens é gerada a partir da interseção das máscaras NDVI, WI e HOT, enquanto a máscara de sombras é construída a partir do índice D, com um ajuste adicional

utilizando WP para evitar a inclusão de corpos d'água. Além disso, uma etapa de pós-processamento é aplicada para reduzir ruídos, utilizando análise de vizinhança para refinar a segmentação.

Para avaliar a eficiência do algoritmo, foi desenvolvida uma máscara de referência (Ground Truth) por interpretação visual, baseada na vetorização manual das nuvens e sombras visíveis nas imagens de satélite. Essa máscara serve como base para comparar os resultados do algoritmo e medir sua acurácia. Além disso, o desempenho do sistema também será comparado com as máscaras de nuvens fornecidas pelo Sentinel-2. Dessa forma, este estudo buscou aprimorar a detecção automática de nuvens e sombras em imagens orbitais.

Fundamentação Teórica

Trabalhos relacionados

A detecção automática de nuvens e sombras em imagens de satélite é fundamental para a otimização dos dados de sensoriamento remoto. Esse processo desempenha um papel crucial em diversas aplicações, assim cada vez mais formas de melhorar esse processo tem surgido. Segundo Jeppesen et al. (2019), os modelos de aprendizagem profunda, como a Rede de Sensoriamento Remoto (RS-Net) baseada na arquitetura U-net, demonstram captura de nuvens cenários desafiadores, como a presença de nuvens sobre neve e gelo. O uso de um modelo de aprendizado profundo para a detecção de nuvens em imagens de satélite mostra sua utilidade especialmente sobre biomas com cenas dificilmente distinguíveis.

Recentemente, Li et al. (2022) apresentaram um método híbrido de detecção de nuvens baseado na combinação sinérgica de Redes Generativas Adversárias (GAN) e um modelo physics-based cloud distortion model (CDM). Esse modelo visa a criação de nuvens de forma virtual ou gráfica para a criação de máscaras. O método proposto fornece uma detecção de nuvens em imagens do satélite Landsat.

A detecção precisa e automatizada de nuvens e sombras de nuvens é um componente-chave no processamento. Tarrio et al. (2020) afirmam que muitos algoritmos existentes de detecção de nuvens dependem de informações de temperatura para identificar nuvens, tornando a detecção difícil para sensores que não possuem uma banda térmica. Algoritmos que fazem tanto a detecção de nuvens quanto de sombra tendem a ter sua eficiência reduzida, detectando de forma eficiente um dos elementos, porém não os dois elementos sendo eles nuvens e sombra.

Além disso, Chen et al. (2023) propuseram uma rede de atenção espectro-espacial-contexto (SSCA-net), essa rede é um tipo de rede neural que combina a capacidade de atenção espacial com informações sobre o contexto que está inserida, com o objetivo de melhorar a precisão na detecção de nuvens em cenas de alta luminosidade, sem a necessidade de esforço manual na coleta de amostras a partir de um índice de nuvens usando dois níveis de corte, que são então expandidos para melhorar a precisão das máscaras de nuvens.

Muitas vezes as classificações incorretas de superfícies altamente refletivas, como estruturas feitas pelo homem ou neve e gelo, ocorrem usando métodos de classificação que utilizam imagens em diferentes períodos temporais. É possível reduzir esse problema, mas imagens da cena analisada sem a presença de nuvens são difíceis de obter. Para lidar com essa questão, Pang et al. (2023) criaram um algoritmo que fez uso de quatro modelos de Redes Neurais Convolucionais (CNN), demonstrando sua utilidade na detecção de nuvens em imagens do satélite Landsat-8.

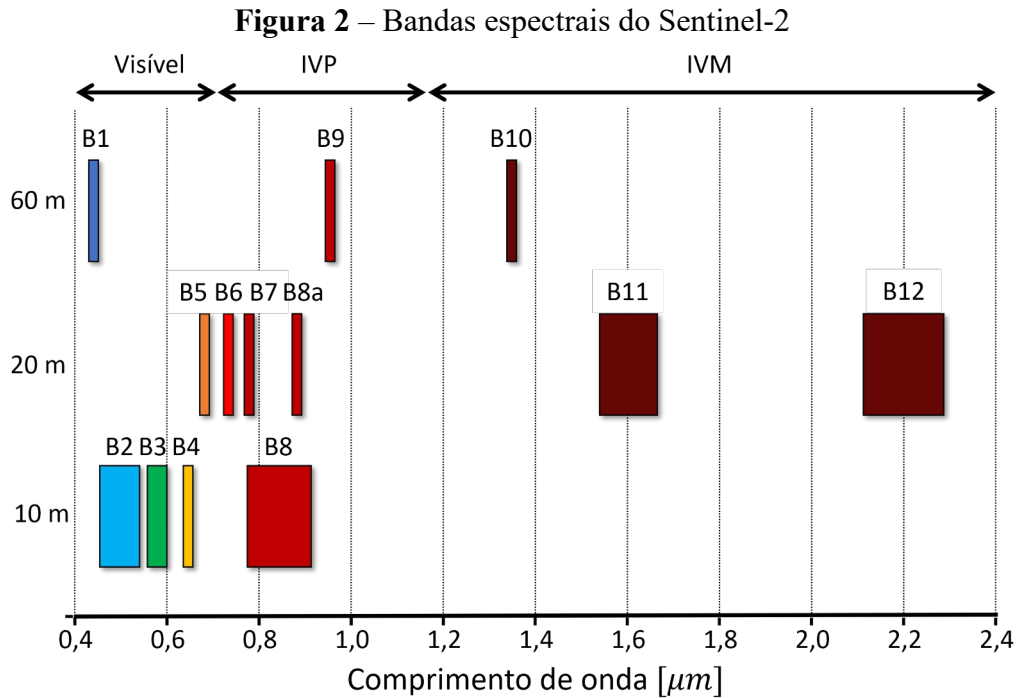
Foram apresentados por Bulgin et al. (2023) novas abordagens para a utilização da reflectância em sensoriamento remoto da temperatura da superfície do mar (TSM) pelo Radiômetro de Temperatura da Superfície do Mar e da Terra (SLSTR). Usando imagens de reflectância na detecção de nuvens com resolução térmica, os estudos foram feitos em zonas costeiras sobre águas brilhantes e ao redor de frentes oceânicas.

Avanços significativos têm sido alcançados na melhoria da detecção desses elementos. Um método proposto por Silva e Liporace (2016) foca na detecção automática de nuvens e sombras, utilizando parâmetros como NDVI, WI e HOT para desenvolver uma máscara de nuvens a partir de imagens do sensor AWFII do satélite AMAZONIA-1. Esses parâmetros desempenham um papel crucial na segmentação eficaz desses elementos e serão utilizados como base para criar uma alternativa, utilizando bandas presentes no Sentinel-2, satélite utilizado nesta pesquisa.

Índices espectrais

Foram combinados três índices espectrais para a identificação de nuvens: NDVI, WI e HOT. Para a detecção de sombras, foi utilizado o índice espectral D, que permite a criação da máscara de sombras. No entanto, um problema comum nesse tipo de análise é a detecção errônea de corpos d'água, pois esses elementos podem apresentar características espectrais semelhantes às sombras de nuvens. Para corrigir essa inconsistência, foi incorporada a máscara de pixels de água (WP), que atua como um filtro, removendo pixels de água indesejados das máscaras geradas. Todos os cálculos são realizados a partir das bandas do

Sentinel-2, que são Aerossol (B1), Azul (B2), Verde (B3), Vermelho (B4), Infravermelho Próximo (B8), Infravermelho Médio (B11) e Infravermelho Médio (B12). A Figura 2 mostra as bandas espectrais e suas resoluções espaciais do satélite Sentinel-2.



Fonte: Autores.

Máscara de nuvens

A máscara WP se baseia em Filipponi (2018), e é definida na equação 1. Um pixel é considerado como pertencente à classe água se $\wp < 0$:

$$\wp = \frac{(B1+B2+B3)+(B8+B11+B12)}{(B1+B2+B3)-(B8+B11+B12)} < 0 \quad (1)$$

O índice NDVI (SILVA & LIPORACE, 2016), é definido na equação 2, em que B8 é a reflectância no IVP e B4 é a reflectância no Vermelho. O NDVI tem a vantagem de reduzir efeitos causados por diferenças no ângulo zenital solar, sombras de nuvens e, até certo ponto, efeitos atmosféricos e algumas variações de brilho causadas por relevo. Os valores desse índice variam no intervalo [0, 1]. Valores próximos de 1 indicam atividade de vegetação saudável, valores entre 0 e 0,5 normalmente correspondem a solo exposto e valores negativos ocorrem em pixels de sombra ou água. Como a reflectância das nuvens nas bandas do Vermelho e IVP tendem a ser altas, o NDVI tende ao valor zero para pixels deste tipo de alvo.

Portanto, será selecionado um intervalo ao redor de zero, definido pelos valores de NDVI mínimo igual a -0,25 e NDVI máximo igual a 0,15, para identificação de pixels de nuvens, conforme expressão apresentada na equação 3. Estes valores são definidos empiricamente.

$NDVI = \frac{B_8 + B_4}{B_8 - B_4}$	(2)
$NDVI_{min} < NDVI < NDVI_{max}$	(3)

Da aplicação do processo de fatiamento de valores segundo equação 3, resulta um dado matricial em que pixels de nuvens são rotulados com valor 1 (verdadeiro), e os demais com valor 0 (falso) ou nulo (pixels com valor nulo não são representados em tela pelo sistema de informações geográficas).

O uso do NDVI apresenta frequentemente falsos positivos, incluindo corpos d'água na detecção das nuvens. Para contornar esse problema, pode-se subtrair o resultado do WP do NDVI, melhorando o sucesso na utilização deste último.

As equações 4 e 5 são utilizadas para calcular o índice WI, proposto por Silva e Liporace (2016), que utiliza as bandas Azul, Verde e Vermelho para identificar pixels na imagem que não são brancos, isolando aqueles que são possivelmente nuvens.

$M = 0,25 B_2 + 0,37 B_3 + 0,37 B_4$	(4)
$WI = \sum_{i=1}^3 \left \frac{B_i - M}{M} \right < WI_{max}$	(5)

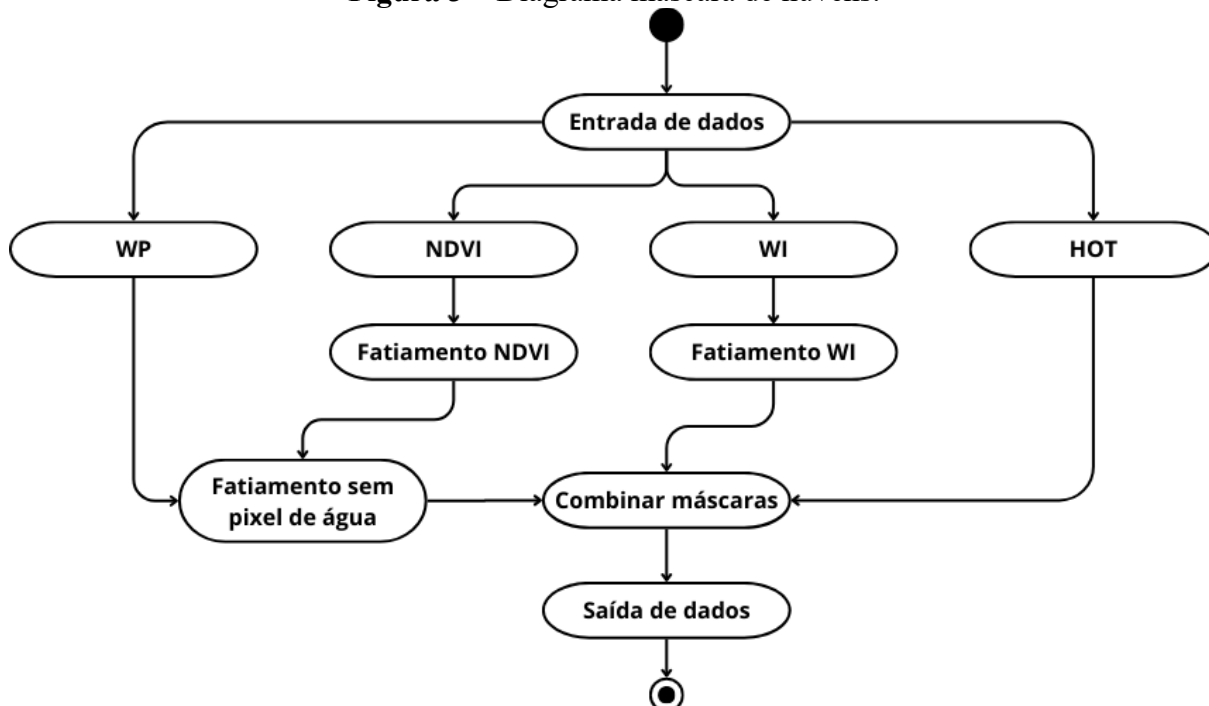
Na equação 4, são adicionados pesos para cada uma das bandas (valores 0,25 e 0,37), usados para reduzir os efeitos de espalhamento e absorção atmosféricos. Estes valores são escolhidos empiricamente. Na equação 5, um limiar é empregado para segmentar os pixels brancos (valor 16.000), definido também de forma empírica.

O índice HOT baseado na proposta de Silva e Liporace (2016), definido na equação 6, utiliza as bandas do Azul e o Vermelho para realçar a resposta espectral do vapor de água.

$HOT = B_2 - 0,45 B_4 - 0,08 > HOT_{min}$	(6)
---	-----

Os resultados dos três índices são combinados por uma operação de intersecção, a fim de aumentar a exatidão da detecção dos pixels de nuvens. Isto quer dizer que, no resultado, um pixel presente na máscara de nuvens é aquele que foi identificado nos três índices como apresentado na Figura 3.

Figura 3 – Diagrama máscara de nuvens.



Máscara de sombras


Para a máscara de sombra empregou-se o índice D (SILVA & LIPORACE, 2016), em que os pixels escuros são extraídos a partir das reflectâncias das bandas B2 e B4.

$D2 = B2 < (B2_{min} \cdot 0,1) \quad D4 = B4 < (B4_{min} \cdot 0,16)$ $D = D2 \wedge D4$	(7)
---	-------

Na equação 7, $B2_{min}$ e $B4_{min}$ correspondem às menores reflectâncias encontradas para as bandas B2 e B4, respectivamente. Multiplicados pela reflectância respectiva de cada banda analisada. Os pixels aprovados nos dois testes definem a máscara D.

O resultado da equação 7 frequentemente apresenta pixels de água que muitas vezes são confundidos com sombra. Para contornar esse problema, subtrai-se a máscara WP do índice D a fim de aumentar a exatidão da detecção dos pixels de sombra. Isto quer dizer que, no resultado, um pixel presente na máscara de sombra é aquele que foi identificado no índice D como apresentado na Figura 4.

Figura 4 - Diagrama máscara de sombras.



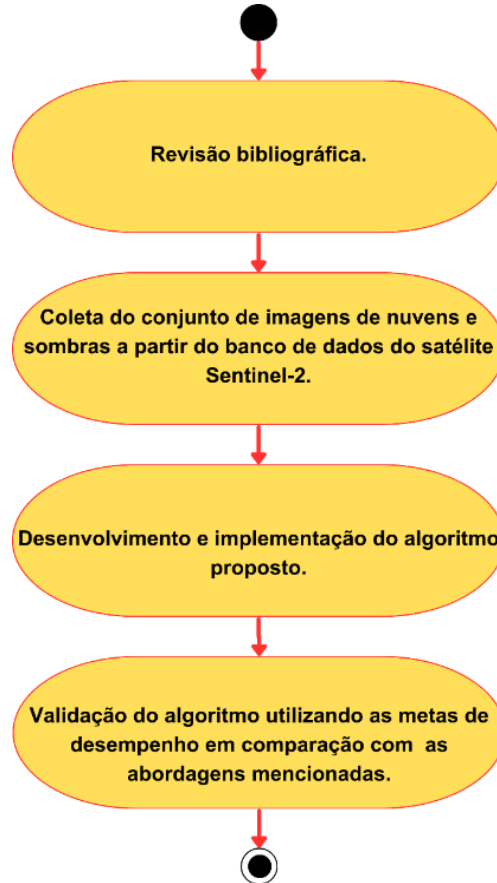
Metodologia

As principais etapas para o desenvolvimento da proposta, são exibidas na Figura 5. Em termos gerais, a metodologia envolve a aplicação dos métodos destacados na seção anterior para a detecção de sombras e nuvens em um conjunto selecionado de imagens contendo estas classes espectrais. O algoritmo desenvolvido foi implementado na linguagem Python e possui dependência da biblioteca do GRASS GIS para Python, que permite chamar o software de forma remota e realizar operações diretamente no ambiente do GRASS. A execução do código é automatizada, desde que os dados estejam devidamente preparados antes do processamento. O ambiente de execução é composto por:

- Sistema Operacional: Windows 10.
- Linguagem de Programação: Python 3.12.
- Software Utilizado: GRASS GIS 8.4.

- Dependências: Biblioteca do GRASS GIS para Python.

Figura 5 - Principais etapas para o desenvolvimento da proposta



Por fim, realizou-se a etapa de validação do sistema, na qual se avaliou o algoritmo desenvolvido por meio de métricas quantitativas e qualitativas. Esse processo se baseou na comparação do sistema com outras referências, sendo elas a porcentagem detectada de nuvens pelo satélite Sentinel-2 e imagens de referência (Ground Truth) obtidas a partir da interpretação das cenas e vetorização manual dos alvos de interesse. A acurácia é calculada conforme a equação 8, na qual TP são os positivos verdadeiros, TN são os negativos verdadeiros e n é o número total de pixels da imagem.

$\text{Acurácia} = (TP + TN) / n$	(8)
-----------------------------------	------------

Resultados

Detecção de nuvens

Para os testes, foram selecionadas 6 imagens Sentinel-2 com nuvens e sombras de nuvens. Junto com as bandas espectrais, o Sentinel-2 disponibiliza máscaras de nuvens e de sombra de nuvens, obtidas por algoritmos próprios do sistema. Essas máscaras serão comparadas com os resultados do algoritmo na detecção proposto. Além disso, serão empregadas imagens de referência (Ground Truth) para estimativa da acurácia da detecção obtida pelo algoritmo.

A porcentagem de nuvens identificada pelo satélite Sentinel-2, presente em cada uma das 6 imagens selecionadas, é informada na Tabela 1, juntamente com a data de aquisição. As imagens foram selecionadas no sistema Copernicus com as seguintes identificações: *Relative orbit number* único de 124 a todas as imagens e um *Tile id* variante de 21KZR, 22KCA, 22KCB e 22KCC.

Utilizando a linguagem de programação Python, juntamente com a biblioteca de desenvolvimento Grass, que auxilia na automação de comandos do *software* de Geoprocessamento Grass Gis, foi possível desenvolver um algoritmo que calcula as máscaras WP, NDVI, WI, HOT e D e aplica limiares de binarização para gerar máscaras de nuvens e de sombras. As máscaras foram ainda pós-processadas para correção de erros de classificação. Para tanto, empregou-se uma análise de vizinhança que verifica se um número pré-definido de vizinhos de um pixel recebeu a mesma classificação. Caso contrário, o pixel é tratado como ruído e a classificação é desconsiderada.

Para a análise de resultados é possível comparar a porcentagem de pixels da máscara de nuvens com o dado fornecido pelo Sentinel-2 e com as imagens de referência. Estas imagens foram obtidas a partir da vetorização manual dos pixels de nuvem e sombra de nuvem, identificados por interpretação visual. Para mensurar o desempenho de cada método, foi utilizada a métrica de acurácia. Essa métrica indica a proporção de pixels que foram corretamente identificados em relação ao total presente no Ground Truth. Em outras palavras, a acurácia é calculada dividindo a porcentagem de nuvens ou sombras corretamente detectadas pelo método (Sentinel-2 ou algoritmo) pela porcentagem apresentada no Ground Truth, e multiplicando o resultado por 100. Esses resultados são mostrados na Tabela 1.

Tabela 1 - Comparação da porcentagem de nuvens nas imagens e a forma de adquiri-las.

Data	% nuvens (Sentinel-2)	% nuvens (Algoritmo)	% nuvens (Ground Truth)	Acurácia do Sentinel-2	Acurácia do Algoritmo
01/10/2024	4,22%	2,61%	2,37%	56,2%	91,6%
01/10/2024	5,91%	2,10%	2,47%	41,8%	85,0%
12/09/2024	12,56%	6,04%	6,55%	52,2%	92,2%
15/03/2024	1,49%	0,40%	0,87%	58,4%	46,0%
29/02/2024	19,40%	0,02%	0,07%	0,36%	28,6%
27/09/2023	1,13%	0,64%	0,61%	54,0%	95,1%

Na Tabela 1, imagens com datas repetidas são de regiões de interesse distintas. As Figuras de 5 a 10 mostram as imagens de cada data presente na Tabela 1 e a máscara de nuvens gerada pelo algoritmo, pelo Sentinel e seu *Ground Truth*.

Figura 5 – (A) Imagem 1 do dia 01/10/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.

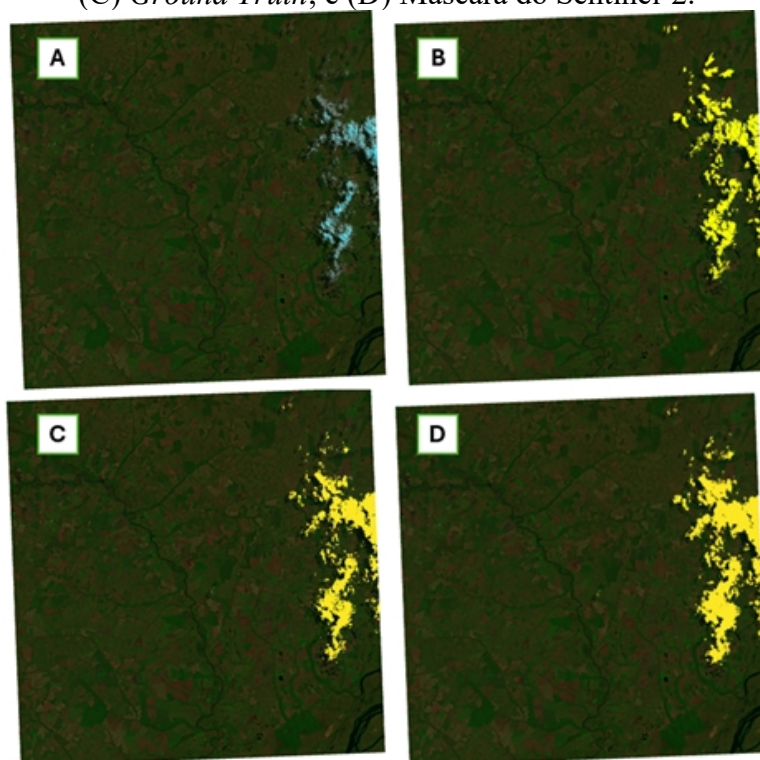


Figura 6 - (A) Imagem 2 do dia 01/10/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.




Figura 7 – (A) Imagem do dia 12/09/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.




Figura 8 – (A) Imagem do dia 15/03/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.




Figura 9 – (A) Imagem do dia 29/02/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.





Figura 10 – (A) Imagem do dia 27/09/2023; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.



O algoritmo proposto obteve uma acurácia média de 73,08%, calculada pela soma das acurácias individuais dividida pelo número de amostras (6), contra acurácia média de 43,83% dos dados informados pelo Sentinel-2. Embora o valor médio do algoritmo seja superior, apenas quatro das seis amostras atingiram a acurácia satisfatória ($\geq 85\%$), enquanto o Sentinel-2 não apresentou nenhum caso acima do limiar, demonstrando uma melhoria na detecção de nuvens nas áreas de estudo.

Detecção de sombras

A Tabela 2 apresenta os resultados obtidos e permite compará-los com o método usado pelo Sentinel-2 para detecção de sombras. As figuras 11-16 mostram as cenas originais, pixels de nuvem detectados pelo algoritmo proposto, o respectivo *Ground Truth* e pixels de nuvem detectados pelo Sentinel.

Tabela 2 - Comparação da porcentagem de sombras nas imagens e acurácia.

Data	% sombras (Sentinel-2)	% sombras (Algoritmo)	% sombras (Ground Truth)	Acurácia do Sentinel-2	Acurácia do Algoritmo
01/10/2024	1,11%	5,42%	1,56%	71,2%	28,8%
01/10/2024	0,34%	0,75%	1,89%	18,0%	39,7%
12/09/2024	0,52%	0,87%	0,73%	71,2%	80,8%
15/03/2024	1,46%	1,58%	1,26%	86,3%	80,0%
29/02/2024	0,15%	0,05%	0,10%	66,7%	50,0%
27/09/2023	0,70%	0,84%	0,76%	92,1%	91,7%

Figura 11 – (A) Imagem 1 do dia 01/10/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.




Figura 12 – (A) Imagem 2 do dia 01/10/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.




Figura 13 – (A) Imagem do dia 12/09/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.

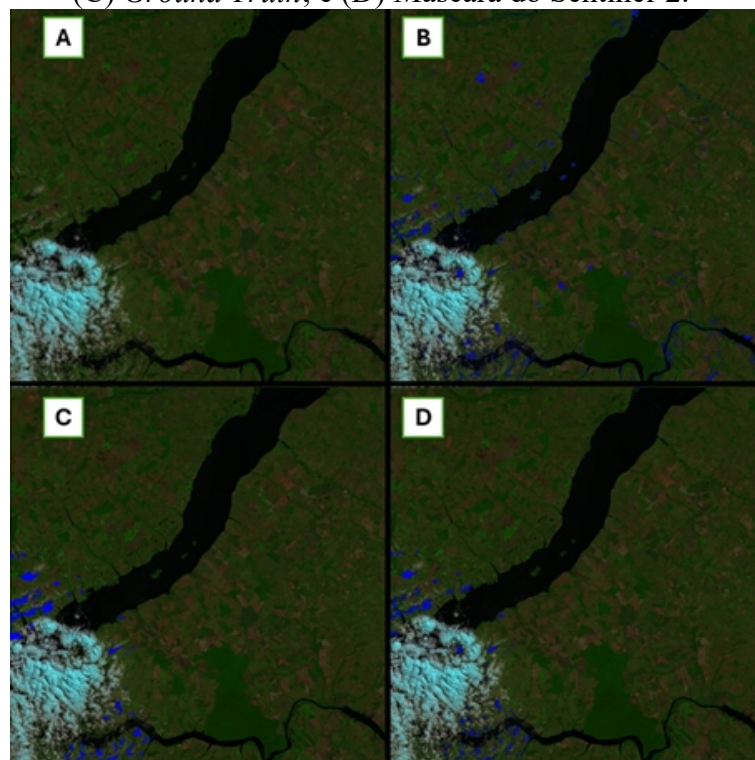


Figura 14 – (A) Imagem do dia 15/03/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.

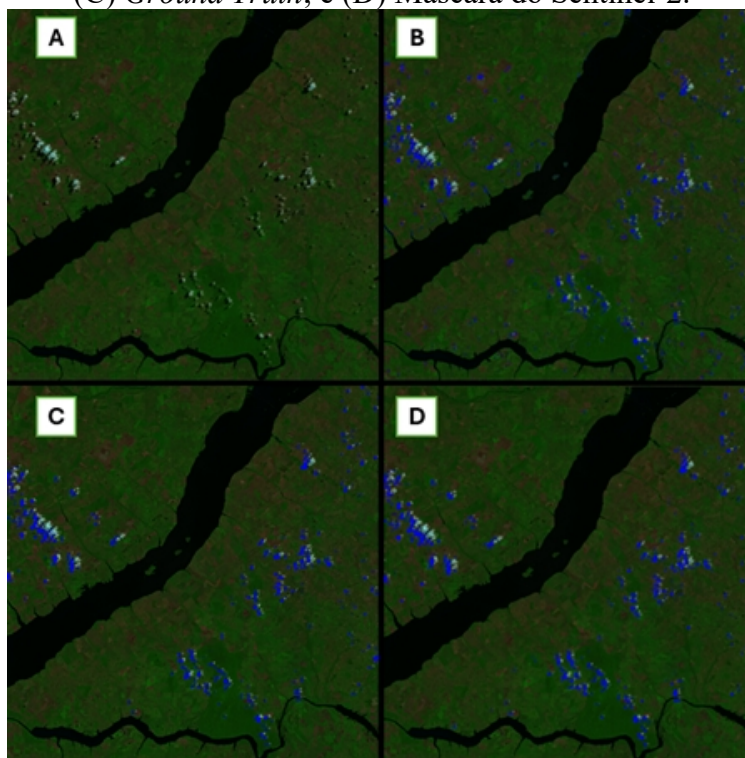


Figura 15 – (A) Imagem do dia 29/02/2024; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2..


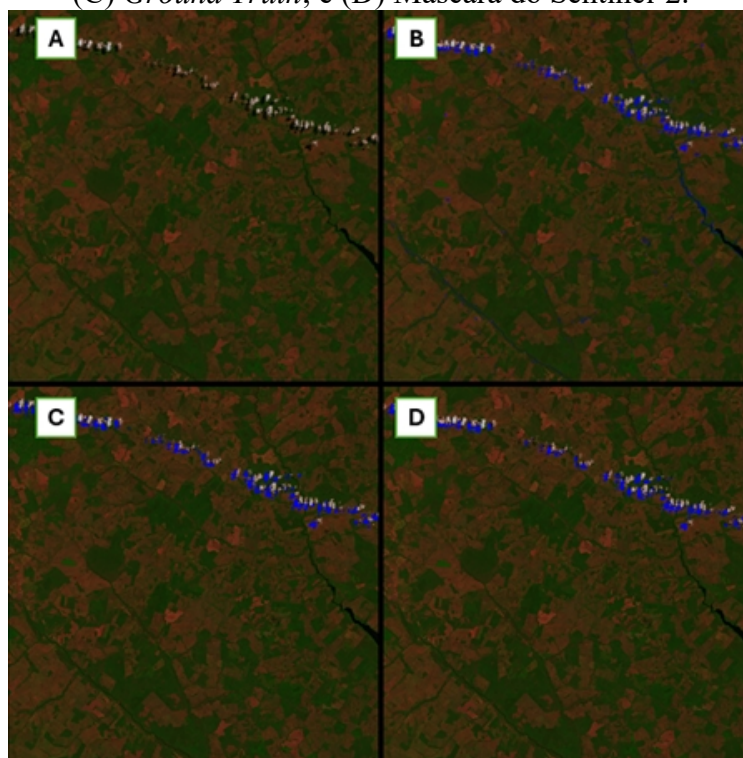


Figura 16 – (A) Imagem do dia 27/09/2023; (B) Resultado obtido pelo algoritmo proposto; (C) *Ground Truth*; e (D) Máscara do Sentinel-2.



Da análise das figuras e dos dados na Tabela 2, nota-se que o algoritmo proposto obteve acurácia média de 61,83%, obtida a partir do somatório das acurácias individuais dividida pelo número de amostras, contra acurácia média de 67,58% dos resultados obtidos pelo Sentinel-2. Considerando o critério de satisfação ($\geq 85\%$), o algoritmo teve apenas uma amostra com acurácia satisfatória, enquanto o Sentinel-2 apresentou duas. Em ambos os casos, observa-se predomínio de resultados abaixo do limiar de 85%, o que sugere a necessidade de ajustes metodológicos e reavaliação dos parâmetros de segmentação. Neste caso, o algoritmo proposto teve um desempenho ligeiramente pior.

Conclusão

Este trabalho apresentou uma abordagem para a detecção automática de nuvens e sombras em imagens de satélite, com foco na utilização do sensor Sentinel-2. A pesquisa explorou a combinação de múltiplos índices espectrais para melhorar a precisão na identificação desses elementos. A implementação do algoritmo mostrou-se eficiente na detecção de nuvens, apresentando acurácia média superior à obtida pelo Sentinel-2. Embora apenas quatro das seis amostras tenham atingido o limiar de 85% considerado satisfatório, esse resultado representa mais da metade das amostras analisadas, em contraste com nenhuma

amostra satisfatória obtida pelo Sentinel-2. Por outro lado, na detecção de sombras, o algoritmo apresentou acurácia média ligeiramente inferior à do Sentinel-2, com predominância de resultados abaixo do limite satisfatório em ambos os métodos, sendo que o algoritmo obteve apenas uma amostra satisfatória, enquanto o Sentinel-2 apresentou duas.

A metodologia proposta para a detecção de nuvens mostrou um desempenho superior na identificação de nuvens mais densas. A análise qualitativa sugere que, quando as nuvens são mais espessas, o algoritmo é capaz de gerar máscaras que se aproximam mais da realidade, refletindo uma maior precisão na detecção.

Além disso, o trabalho destacou a relevância da automatização nesse contexto, não apenas para a análise de imagens, mas também para aplicações práticas em monitoramento por satélites.

Referências

BULGIN, Claire E.; FAULKNER, Agnieszka; MERCHANT, C. J.; CORLETT, Gary K.; MCCARROLL, Niall; EMBURY, Owen; POLEHAMPTON, Edward; MCGURK, Connor. **Improving the combined use of reflectance and thermal channels for ocean and coastal cloud detection for the Sea and Land Surface Temperature Radiometer (SLSTR).** Remote Sensing of Environment, v. 271, p. 111-131, 2023.

CHEN, Yang; TANG, Luliang; HUANG, Wumeng; GUO, Jianhua; YANG, Guang. **A novel spectral indices-driven spectral-spatial context attention network for automatic cloud detection.** IEEE Geoscience and Remote Sensing Letters, v. 20, n. 5, p. 847-854, 2023.

FILIPPONI, Federico. **BAIS2: Burned Area Index for Sentinel-2.** Sensors, MDPI, v. 3, 22 mar. 2018.

JEPPESSEN, Jacob Høxbroe; JACOBSEN, Rune Hylsberg; INCEOGLU, Fadil; TOFTEGAARD, Thomas Skjødeberg. **A cloud detection algorithm for satellite imagery based on deep learning.** Pattern Recognition Letters, v. 128, p. 109-115, 2019.

LI, Jun; WU, Zhaocong; SHENG, Qinghong; WANG, Bo; HU, Zhongwen; ZHENG, Shaobo; CAMPS-VALLS, Gustau; MOLINIER, Matthieu. **A hybrid generative adversarial network for weakly-supervised cloud detection in multispectral images.** Remote Sensing, v. 14, n. 10, p. 2089, 2022.

PANG, Shulin; SUN, Lin; TIAN, Yanan; MA, Yutiao; WEI, Jing. **Convolutional neural network-driven improvements in global cloud detection for Landsat 8 and transfer learning on Sentinel-2 imagery**. Journal of Applied Remote Sensing, v. 17, n. 3, p. 1-14, 2023.

SILVA, Marco Aurélio Oliveira da; LIPORACE, Frederico dos Santos. **Deteção automática de nuvens e sombra de nuvens em imagens de sensoriamento remoto**. Boletim de Ciências Geodésicas, p. 369-388, abr.-jul. 2016.

SPACE AGENCY EUROPEAN. **Level-1C Cloud Masks – Sentinel-2 MSI Technical Guide – Sentinel Online**. Sentinel Online, 2024. Disponível em: <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/level-1c/cloud-masks>. Acesso em: 10 nov. 2024.

TARRIO, Katelyn; TANG, Xiaojing; MASEK, Jeffrey G.; CLAVERIE, Martin; JU, Junchang; QIU, Shi; ZHU, Zhe; WOODCOCK, Curtis E. **Comparison of cloud detection algorithms for Sentinel-2 imagery**. Remote Sensing, v. 12, n. 145, p. 123-136, 2020.