

## 15º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2024

### Detecção automática de nuvens em imagens de satélite

Paulo S. L Mattos<sup>1</sup>, Thiago Statella<sup>2</sup>.

<sup>1</sup> Graduando em Bacharelado em Ciência da Computação, IFSP, Campus Presidente Epitácio, paulo.l@aluno.ifsp.edu.br.

<sup>2</sup> Docente, IFSP, Câmpus Presidente Epitácio, Thiago.statella@ifsp.edu.br.

Área de conhecimento (Tabela CNPq): 1.03.03.05-7 Processamento Gráfico (Graphics)

**RESUMO:** Este trabalho apresenta uma abordagem para a detecção automática de nuvens em imagens de satélite. A detecção automática de nuvens é crucial para aplicações como monitoramento ambiental, agricultura de precisão e previsão do tempo, pois nuvens podem distorcer os dados de satélite e levar a interpretações errôneas. Portanto, um sistema de detecção eficiente é vital para garantir a precisão dos dados derivados dessas imagens. Entre os principais índices espectrais utilizados na detecção, serão adotados o NDVI (*Normalized Difference Vegetation Index*), utilizado para monitorar a vegetação, ajudando a distinguir áreas vegetadas de não vegetadas; o WI (*Whiteness Index*), utilizado para conseguir identificar pixels na imagem que não são brancos, podendo assim isolar aqueles que não pertencem às nuvens; O HOT (*Haze Optimized Transformation*), utilizado para realçar o vapor de água. A criação de uma máscara de nuvem envolve a aplicação de técnicas de processamento de imagem e análise de padrões espectrais, integrando informações dos índices espectrais (NDVI, WI e HOT) para melhorar a precisão da detecção. O algoritmo teve sua implementação e teste em um conjunto de dados de imagens de satélite. Pretende-se demonstrar que, ao integrar múltiplos índices espectrais é possível desenvolver um sistema automatizado que melhore significativamente a exatidão na identificação de nuvens em imagens de satélite.

**PALAVRAS-CHAVE:** Algoritmo; Imagem; Máscara de nuvens; Processamento de imagens; Sensoriamento Remoto.

### Automatic detection of clouds and shadows in satellite images

**ABSTRACT:** This work presents an approach for the automatic detection of clouds and shadows in satellite images. Automatic detection of clouds and shadows is crucial for applications such as environmental monitoring, precision agriculture, and weather forecasting, as clouds and shadows can distort satellite data and lead to erroneous interpretations. Therefore, an efficient detection system is vital to ensure the accuracy of data derived from these images. Among the main spectral indices used in detection, the NDVI (*Normalized Difference Vegetation Index*) will be adopted to monitor vegetation, helping to distinguish vegetated areas from non-vegetated ones; the WI (*Whiteness Index*) will be used to identify non-white pixels in the image, thus isolating those that do not belong to clouds; and the HOT (*Haze Optimized Transformation*) will be used to highlight water vapor. The creation of a cloud mask involves the application of image processing techniques and spectral pattern analysis, integrating information from the spectral indices (NDVI, WI, and HOT) to improve detection accuracy. The algorithm was implemented and tested on a dataset of satellite images. So far, only cloud detection has been developed. It is intended to demonstrate that by integrating multiple spectral indices, it is possible to develop an automated system that significantly improves the accuracy of cloud and shadow identification in satellite images.

**KEYWORDS:** Algorithm; Image; Cloud mask; Image processing; Remote sensing.

## INTRODUÇÃO

A detecção automática de nuvens em imagens de satélite é fundamental para a adequada interpretação dos dados de Sensoriamento Remoto, especialmente ao empregar abordagens automatizadas para a extração de informações. Nuvens presentes nas imagens podem dificultar a análise dos dados, prejudicando a extração de informações importantes. Por isso, métodos mais eficientes para detecção de nuvens são continuamente desenvolvidos.

Um desses métodos foi proposto por Silva e Liporace (2016), focando na detecção automática de nuvens utilizando índices como NDVI, WI e HOT para desenvolver máscaras de nuvem. Originalmente, esse método foi aplicado a imagens do sensor AWFI do satélite AMAZONIA-1.

A detecção de nuvens enfrenta desafios, como a classificação incorreta de superfícies altamente refletivas que não são nuvens, como estruturas feitas pelo homem, neve e gelo, que muitas vezes se assemelham a nuvens. Para mitigar esses problemas, podem ser utilizadas diferentes bandas termais ou até modelos de Redes Neurais Convolucionais (CNN) (Bulgin et al., 2023; Pang et al., 2023).

Esse trabalho utiliza a abordagem proposta por Silva e Liporace (2016) para a detecção automática de nuvens, utilizando os índices NDVI, WI e HOT. O método foi aplicado a imagens do satélite Sentinel-2 sobre uma área de estudo que abrange a Área de Preservação Ambiental da Chapada dos Guimarães, no estado do Mato Grosso.

## MATERIAIS E MÉTODOS

Para a detecção de nuvens foram empregados os índices espectrais NDVI, WI e HOT, implementados em linguagem Python, em conjunto com o Sistema de Informações Geográficas GRASS. As imagens utilizadas foram adquiridas pelo satélite Sentinel-2. A Figura 1 mostra um fluxograma com as etapas seguidas para a criação de uma máscara de nuvens.

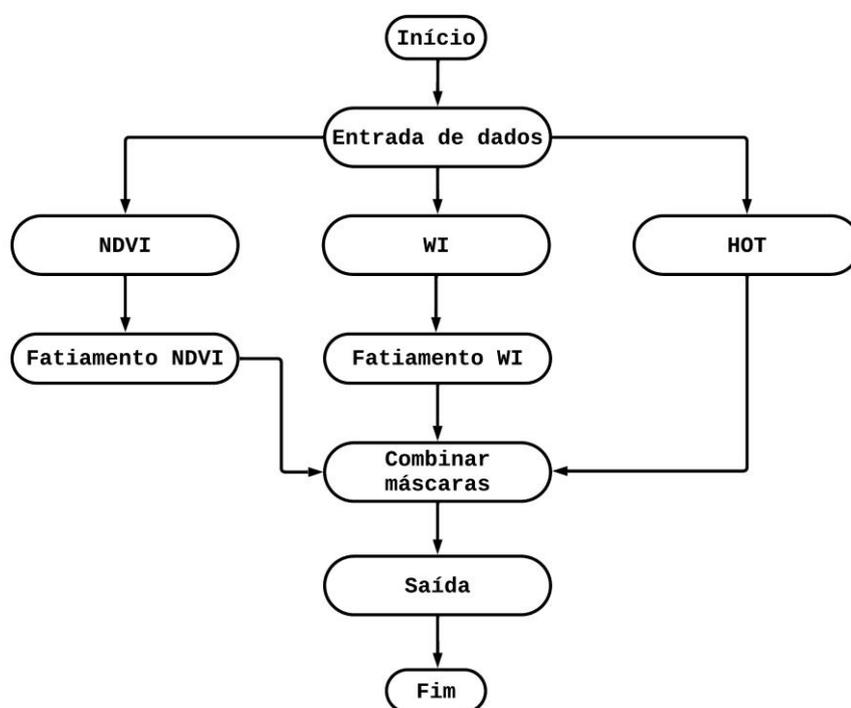


FIGURA 1. Fluxograma do método.

## FUNDAMENTAÇÃO TEÓRICA

O uso dos índices espectrais NDVI, WI e HOT, contribuem com informações únicas que, quando integradas, permitem uma detecção mais precisa das áreas encobertas por nuvens. Todos os cálculos são realizados a partir das bandas do Sentinel-2, que são Azul (B2), Verde (B3), Vermelho (B4) e Infravermelho Próximo (B8).

O índice NDVI se baseia nas bandas do Infravermelho Próximo (IVP) e na banda do Vermelho, e é definido na equação 1, 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  $-0,025$  e NDVI máximo igual a  $0,15$ , para identificação de pixels de nuvem, conforme expressão apresentada na equação 2. Estes valores são definidos empiricamente.

$$NDVI = \frac{B8 - B4}{B8 + B4}. \quad (1)$$

$$NDVI_{min} < NDVI < NDVI_{max}. \quad (2)$$

Da aplicação do processo de fatiamento de valores segundo equação 2, resulta um dado matricial em que pixels de nuvem 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).

As equações 3 e 4 são utilizadas para calcular o índice WI, que utiliza as bandas Azul (B2), Verde (B3) e Vermelho (B4) para identificar pixels na imagem que não são brancos, isolando aqueles que são possivelmente nuvens.

$$M = 0,25B2 + 0,37B3 + 0,37B4. \quad (3)$$

$$WI = \sum_{i=1}^3 \left| \frac{Bi - M}{M} \right| < WI_{max} \quad (4)$$

Na equação 3, 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. Neste caso, foram adotados pesos já empregados na literatura.

Na equação 4, um limiar é empregado para segmentar os pixels brancos (valor 16.000), definido também de forma empírica.

O índice HOT, definido na equação 5, utiliza as bandas do Azul (B2) e o Vermelho (B4) para realçar a resposta espectral do vapor de água.

$$HOT = B2 - 0,45B4 - 0,08 > HOT_{min} \quad (5)$$

Os resultados dos três índices são combinados por uma operação de intersecção, a fim de aumentar a exatidão da detecção dos pixels de nuvem. Isto quer dizer que, um pixel dado como verdadeiro para nuvem na máscara de nuvem é aquele que foi identificado como nuvem nas três máscaras.

## RESULTADOS E DISCUSSÃO

Para testar a eficiência do método foram utilizadas 10 cenas com presença de nuvens. Estas imagens são fornecidas sem custo pelo Copernicus Data Space Ecosystem (CDSE), que também disponibiliza informação sobre a porcentagem de cobertura de nuvens em seus dados usando algoritmo próprio.

A Tabela 1 apresenta uma comparação entre as porcentagens de cobertura de nuvens reportadas pelo CDSE e calculadas com base na metodologia proposta para o banco de imagens.

TABELA 1. Comparação de porcentagens de nuvens em imagens com nuvens analisadas.

Data da imagem	Porcentagem de nuvens Sentinel 2	Porcentagem de nuvens algoritmo
02/01/2024	51,52%	11,04%
10/01/2024	17,97%	4,29%
30/01/2024	70,61%	1,50%
09/02/2024	47,37%	17,45%
19/02/2024	70,98%	29,41%
29/02/2024	19,40%	0,02%
05/03/2024	32,08%	9,22%
15/03/2024	1,49%	0,42%
20/03/2024	40,14%	0,0%
30/03/2024	29,37%	10,49%

A Tabela 1 mostra que existe uma grande discrepância entre as porcentagens de cobertura. O algoritmo do CDSE tende a superestimar a quantidade de pixels de nuvem, incluindo muitos falsos positivos. Isso pode ser percebido pela análise da Figura 2, que mostra o resultado da aplicação do método proposto, segundo o qual a imagem apresenta 11,04% de cobertura de nuvens, enquanto, segundo o CDSE, a imagem deveria apresentar 51,52%.

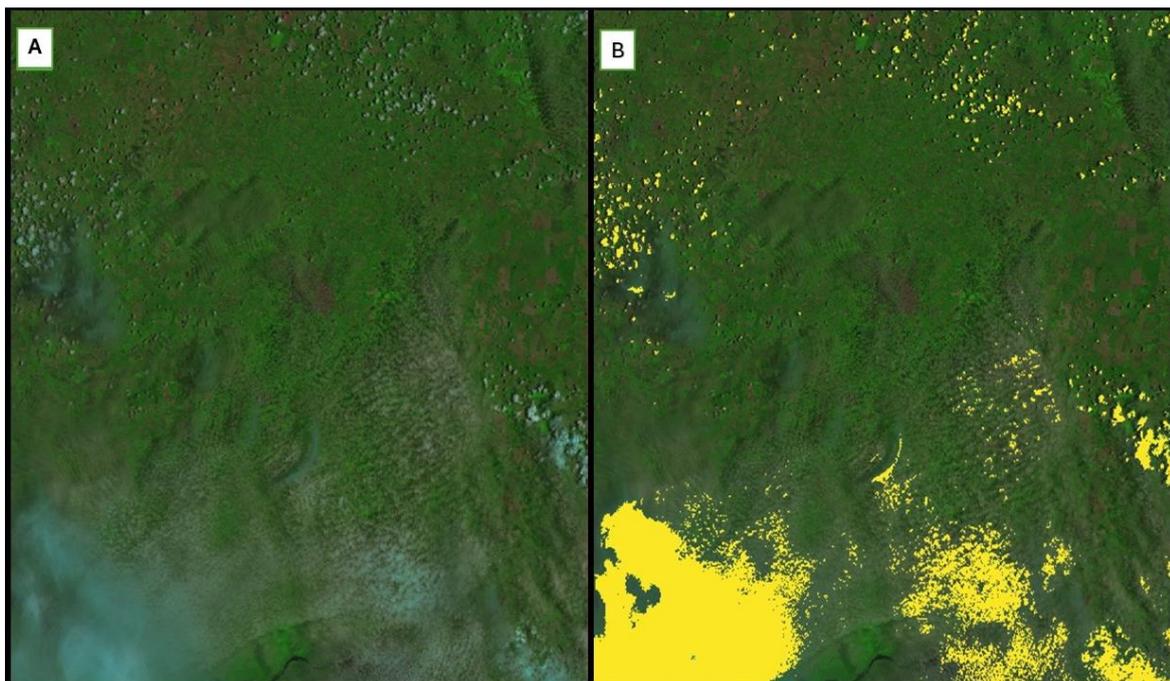


FIGURA 2. A imagem (A) demonstra a primeira imagem com nuvem da Tabela 1. A imagem (B) demonstra a máscara de nuvem gerada pelo algoritmo proposto.

## CONCLUSÕES

Fazendo uma análise qualitativa, é possível concluir que a máscara de nuvem obteve maior sucesso para nuvens mais densas. No entanto, quando comparado com o percentual informado pelo CDSE, o resultado obtido pelo método proposto é mais preciso. A metodologia proposta está sob aprimoramento e uma análise quantitativa deverá ser realizada nos próximos trabalhos.

## CONTRIBUIÇÕES DOS AUTORES

Paulo Sergio Lima Mattos Contribuiu com a análise dos dados, redação do trabalho e experimentos. Paulo Sergio Lima Mattos e Thiago Statella Contribuíram com a curadoria e metodologia. Todos os autores contribuíram com a revisão do trabalho e aprovaram a versão submetida.

## AGRADECIMENTOS

Os autores agradecem ao IFSP – Câmpus Presidente Epitácio pela infraestrutura e suporte fornecidos.

## REFERÊNCIAS

BULGIN, C. E.; FAULKNER, A.; MERCHANT, C. J.; CORLETT, G. K.; MCCARROLL, N.; EMBURY, O.; POLEHAMPTON, E.; MCGURK, C. 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.

NETELER, M; MITASOVA, H. *Open Source GIS: a Grass GIS Approach*. Springer, 2008.

PANG, S; SUN L.; TIAN Y.; MA Y.; WEI J. 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, M. A. O. da; LIPORACE, F. dos S. Detecção automática de nuvem e sombra de nuvem em imagens de sensoriamento remoto. *Boletim de Ciências Geodésicas*, p. 369-388, abr-jul. 2016.