



Processamento de Imagens dos Satélites Brasileiros CBERS-4 e CBERS-4A para Respostas Rápidas a Desastres

Image Processing of Brazilian Satellites CBERS-4 and CBERS-4A for Rapid Disaster Responses

Brenda Oliveira Rocha ¹, Thales Sehn Körting ², Laercio Massaru Namikawa ³

¹Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP, Brasil. brenda.rocha@inpe.br.
ORCID: <https://orcid.org/0000-0002-8286-4085>

²Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP, Brasil. thales.korting@inpe.br.
ORCID: <https://orcid.org/0000-0002-0876-0501>

³Instituto Nacional de Pesquisas Espaciais, São José dos Campos - SP, Brasil. laercio.namikawa@inpe.br.
ORCID: <https://orcid.org/0000-0001-7847-1804>

Recebido: 07.2023 | Aceito: 06.2024

Resumo: As imagens de satélite podem contribuir para a identificação e análise das áreas afetadas por desastres naturais, através da utilização de técnicas de Processamento Digital de Imagens (PDI) que ressaltam áreas de interesse. O *International Charter "Space and Major Disasters"* é a principal cooperação mundial entre agências espaciais para o fornecimento gratuito de dados de emergência e conta com o Brasil no processo de resposta aos chamados. Dando importância para as solicitações de emergência, a presente pesquisa propõe a utilização dos satélites brasileiros para sistematizar técnicas de PDI como auxílio à gestão de desastres do tipo deslizamentos de terra e inundações regionais. Apresentamos dois casos de estudo: os deslizamentos em Petrópolis (RJ), ocorridos em 2022, e as inundações regionais em três províncias do Paquistão, de 2022. A mineração de dados realizada com o apoio do algoritmo *Random Forest* (RF) foi adotada para extrair os principais atributos que posteriormente foram combinados no espaço de cores RGB para a identificação rápida das áreas atingidas. A composição de cores proposta para Petrópolis foi baseada na seleção de uma componente principal, índice de vegetação e componente matiz da transformação de cores IHS, com uma Acurácia Global (AG) de 81,82%, obtida a partir dos dados do MUX/CBERS-4A. A composição sugerida para o Paquistão foi baseada na seleção da banda NIR e da primeira e segunda componente principal, com uma AG de 88,33%, utilizando imagens do WFI/CBERS-4. Todas as áreas de interesse puderam ser evidenciadas com bom êxito a partir das composições sugeridas.

Palavras-chave: Deslizamentos. Inundações. Random Forest. Mineração de dados. RGB.

Abstract: Satellite images can contribute to the identification and analysis of areas affected by natural disasters, through the use of Digital Image Processing (DIP) techniques that highlight areas of interest. The International Charter "Space and Major Disasters" is the world's main cooperation between space agencies for the free provision of emergency data and relies on Brazil in the process of responding to calls. Giving importance to emergency requests, this research proposes the use of Brazilian satellites to systematize DIP techniques as an aid to the management of disasters such as landslides and regional floods. We present two case studies: the landslides in Petrópolis (RJ), which occurred in 2022, and the regional floods in three provinces of Pakistan, in 2022. Data mining performed with the support of the Random Forest (RF) algorithm was adopted to extract the main attributes that were later combined in the RGB color space for quick identification of affected areas. The proposed color composition for Petrópolis was based on the selection of a principal component, vegetation index and hue component of the IHS color transformation, with a Global Accuracy (GA) of 81.82%, obtained from MUX/CBERS-4A data. The suggested composition for Pakistan was based on the selection of the NIR band and the first and second principal components, with an GA of 88.33%, using WFI/CBERS-4 images. All areas of interest could be successfully highlighted based on the suggested compositions.

Keywords: Landslides. Floods. Random Forest. Data mining. RGB

1 INTRODUÇÃO

Os desastres podem ser caracterizados como fenômenos de grande impacto destrutivo, ocasionados tanto pelos processos físicos resultantes da dinâmica natural do planeta, quanto pela influência direta de atividades humanas no ambiente (NOVELLINO et al., 2019). Segundo Gähler e Marghany (2016), os desastres podem ser subdivididos entre naturais e antrópicos, de acordo com a principal fonte causadora do evento. Considerando o modo de vida humana e suas interferências insustentáveis, muitos desequilíbrios ambientais são intensificados pela relação antrópica com o meio, um fato diretamente relacionado ao comprometimento dos recursos naturais e de vidas humanas (ZHOU et al., 2018; CHMUTINA; VON MEDING, 2019).

Dentre os eventos frequentes e de grande impacto no Brasil, destacam-se as inundações e os deslizamentos de terra, cujo principal agente desencadeador são os eventos hidrológicos extremos. No ano de 2019, do total de óbitos causados por desastres no planeta, deslizamentos e enchentes foram responsáveis por cerca de 50% das mortes registradas (CRED, 2019). Todos os anos milhares de pessoas são direta ou indiretamente afetadas, contando ainda com os expressivos prejuízos financeiros na economia global (MARTINIS et al., 2018; TAN et al., 2021; CNM, 2022).

O Sensoriamento Remoto (SR) é uma abordagem operacional comum no gerenciamento de desastres (MUNAWAR; HAMMAD; WALLER, 2022). Pela facilidade de aquisição de dados de satélite, os produtos gerados podem ser utilizados em todas as diferentes fases de gestão (DENIS et al., 2016). Considerando a diversidade de sensores a bordo, abre-se caminho para uma análise ímpar dos desastres. Porém, quando são necessários dados de emergência em relação à fase de resposta do ciclo de gestão de desastres, o processo acaba sendo tecnicamente desafiador. É essencial uma coordenação eficiente da aquisição e tratamento dos dados, análise intrínseca da capacidade dos satélites atuais, juntamente com a comunicação entre as operadoras de satélites e organizações internacionais (VOIGT et al., 2016; WANG; YE, 2018; YU; YANG; LI, 2018; HEIN et al., 2019).

Com o objetivo de facilitar a aquisição de dados espaciais de emergência, o *International Charter "Space and Major Disasters"*, popularmente conhecido como a Carta, é uma colaboração mundial que oferece um sistema unificado de obtenção e entrega de dados espaciais de emergência. Há uma cooperação entre as agências mundiais para a disponibilização de imagens, sem custo para o requisitante, especificamente para atividades de resposta a eventos extremos (BOCCARDO; TONOLO, 2015). Desde 2011, o Brasil coopera com a Carta ao disponibilizar imagens dos satélites CBERS (*China-Brazil Earth-Resources Satellite*) 4 e 4A, e AMAZONIA-1 quando solicitadas, sendo o Instituto Nacional de Pesquisas Espaciais (INPE) a entidade responsável pela estruturação das contribuições nacionais (ICSMD, 2022). A partir da aplicação de técnicas de Processamento Digital de Imagens (PDI), os dados dos satélites brasileiros supracitados podem ser eficazes para a gestão dos desastres (NAMIKAWA, 2017; OLIVEIRA et al., 2019).

No entanto, quando as imagens de SR são requisitadas, há uma série de desafios enfrentados pelos analistas para o envio de respostas rápidas e eficientes, seja pela disponibilidade de dados (resolução temporal, organização e volume de dados), pela inevitável ocorrência de nuvens e sombras nas imagens, além da eventual necessidade de pré-processamentos ou cruzamentos de informações. Dependendo do desastre avaliado, diferentes metodologias são exigidas, aumentando a complexidade do processo e resultando em um maior tempo de entrega dos produtos gerados.

Observando a necessidade de otimização dos procedimentos, este artigo propõe um fluxo de processamento aplicado às imagens dos satélites brasileiros CBERS-4 e CBERS-4A, com o propósito de agilizar a resposta, tanto aos chamados da Carta como de outras eventuais solicitações de emergência. A mineração de dados será utilizada para extrair os principais atributos que podem ser obtidos a partir de técnicas de PDI, de acordo com as características espectrais dos alvos, por meio do algoritmo *Random Forest* (RF). Fundamentado em árvores de decisão, o RF se destaca pela velocidade de processamento de uma grande quantidade de dados e ainda pela capacidade de quantificar a importância de cada atributo no modelo (BELGIU; DRĂGUȚ, 2016). Logo, os três principais atributos para uma classificação de referência serão combinados no espaço de cores RGB, com o objetivo de facilitar a identificação das possíveis áreas atingidas por deslizamentos e inundações regionais, considerando o destaque dos alvos e geração de alertas visuais.

As técnicas de PDI que serão utilizadas, tais como: o registro, a correção atmosférica, o realce, a Análise de Componentes Principais (ACP), a transformação RGB-IHS, os índices de vegetação e de água, são

consolidadas na literatura e se mostram de eficaz utilidade para a exploração rápida de dados espaciais. A metodologia será aplicada em dois casos de estudo, sendo eles:

- a) Deslizamentos ocorridos no início de 2022 em Petrópolis (RJ);
- b) Inundação regional ocorrida em três grandes províncias do Paquistão em agosto de 2022.

Para a validação dos resultados, os produtos gerados pela Carta, de forma independente dessa pesquisa, serão utilizados como referência, viabilizando a avaliação quantitativa e qualitativa das composições finais sugeridas.

2 ÁREAS DE ESTUDO

2.1 Município de Petrópolis (RJ)

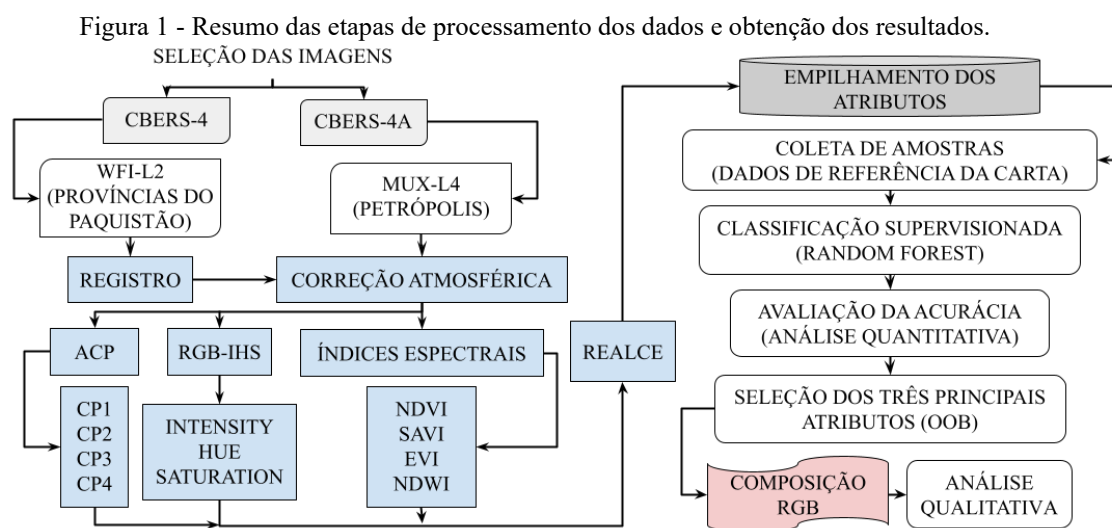
Localizada na região serrana do Rio de Janeiro, considerando os aspectos naturais de declividade do relevo e os aspectos climáticos, a cidade de Petrópolis já vinha se tornando muito vulnerável a eventos extremos (GUERRA; GONÇALVES; LOPES, 2007). Com o intenso desmatamento da região, juntamente com o desenvolvimento urbano vinculado às ocupações irregulares, segundo Torres, Carmo e Almeida Palmeira (2020), após os eventos meteorológicos, a ocorrência de deslizamentos é comum no município, assim como os eventos de inundações. Em 17 de fevereiro de 2022, após episódios de chuvas intensas, uma série anômala de grandes deslizamentos foi desencadeada na cidade, onde um total de 232 óbitos foram registrados, além de cerca de 1.117 pessoas desabrigadas (FOLHA DE SÃO PAULO, 2022).

2.2 Províncias de Sind, Balochistan e Punjab (Paquistão)

O Paquistão é um país de alto risco a desastres naturais, principalmente aqueles relacionados ao aquecimento global e eventos de precipitação extrema. Possuindo cerca de 60% de território montanhoso, a presença das grandes geleiras no país é responsável pelo abastecimento de água dos principais setores sociais e, ao mesmo tempo, estão provavelmente relacionadas às inundações eminentes no país. Isto pode ser explicado pelas mudanças na temperatura do planeta e consequente aumento do derretimento das geleiras (SHAH et al., 2020). Entre os meses de agosto e setembro de 2022, três províncias do Paquistão (Sind, Balochistan e Punjab) foram severamente atingidas por inundações, com mais de mil óbitos contabilizados e milhares de pessoas desabrigadas em cerca de um terço do país (UM SÓ PLANETA, 2022).

3 MATERIAIS E MÉTODOS

As etapas metodológicas da pesquisa estão estruturadas de acordo com o fluxograma da Figura 1.



Fonte: Os autores (2023).

3.1 Seleção das Imagens

As imagens disponíveis nas datas mais próximas às ativações da Carta, e com baixa porcentagem de nuvens (inferior a 30%), foram adquiridas no catálogo de imagens do INPE (Quadro 1). Dois sensores de satélites diferentes foram utilizados, ambos com características espaciais distintas, considerando o tipo de desastre e extensão de ocorrência. Para a análise dos deslizamentos, imagens de média resolução espacial já podem ser utilizadas, contanto que seja possível identificar a forma e a geometria da cicatriz. No caso das inundações regionais, pixels maiores são capazes de ressaltar as áreas de grandes extensões atingidas, trazendo vantagens pelo menor esforço computacional necessário.

Quadro 1 – Datas de ativações da Carta após o início dos desastres avaliados, e datas de aquisição das imagens.

Estudo de caso	Sensor/Satélite	Nível*	Resolução Espacial	Resolução Temporal	Ativação da Carta	Aquisição das imagens
Petrópolis (RJ)	MUX/CBERS-4A	L4	16,5 m	31 dias	16.02.2022	04.03.2022
Províncias do Paquistão	WFI/CBERS-4	L2	64 m	5 dias	30.08.2022	08.09.2022

*Nível L2: as imagens possuem ajustes na radiometria e na geometria baseados em parâmetros do satélite, porém não são totalmente isentas das distorções geométricas oriundas de erros de posicionamento.
*Nível L4: as imagens são ortorretificadas, onde a correção aplicada considera também as distorções atribuídas à geometria de imageamento do relevo (CASTEJON; FONSECA; FORSTER, 2015).

Elaboração: Os autores (2023).

3.2 Processamento Digital de Imagens

A linguagem Python foi utilizada para a correção atmosférica, devido à indisponibilidade de algoritmos voltados para os sensores do CBERS-4 e CBERS-4A nos softwares de Sistemas de Informações Geográficas (SIG) livres. A biblioteca utilizada foi a RSGISLib (*Remote Sensing and Geographical Information Systems Software Library*) desenvolvida por Bunting et al (2014), para a aplicação do método DOS (*Dark Object Subtraction*). Também contou-se com uma rotina de classificação de uso e ocupação do solo, desenvolvida pelo cientista de dados geoespaciais Holden (2017). Com a utilização da biblioteca *Scikit-Learn*, deu-se ênfase no algoritmo RF e nas métricas estatísticas. Os demais procedimentos (registro, Análise de Componentes Principais-ACP, transformação RGB-IHS, índices espectrais comumente utilizados para análise de desastres naturais, realce e combinação dos atributos no espaço de cores RGB) foram realizados no QGIS 3.22.6 e no TerraView 5.6.3. As técnicas aplicadas foram sumarizadas no Quadro 2.

Quadro 2 – Sumarização das técnicas de PDI aplicadas às imagens dos sensores MUX/CBERS-4A E WFI/CBERS-4 (continua).

Processamentos	Cálculos	Ferramentas
Registro ou Georreferenciamento Consiste no alinhamento geométrico entre duas imagens, com seus objetos espacialmente equivalentes, resultando em ambas projetadas no mesmo sistema de coordenadas (CROSTA, 1992).	Procedimento necessário para a manipulação de imagens em nível L2 do WFI/CBERS-4, aplicado a partir da transformação Polinomial 1 e reamostragem por vizinho mais próximo.	“Georreferenciador” (QGIS 3.22.6).
Correção Atmosférica DOS - <i>Dark Object Subtraction</i> Subtração do valor constante identificado no pixel escuro de todos os outros pixels da imagem (GILMORE; SALEEM; DEWAN, 2015).	$g(x) = f(x) - NDmin$ Onde: $f(x)$ é a imagem original, $NDmin$ é o menor número digital identificado no histograma e $g(x)$ é a nova imagem corrigida.	Biblioteca RSGISLib (Python)

Elaboração: Os autores (2023).

Quadro 2 – Sumarização das técnicas de PDI aplicadas às imagens dos sensores MUX/CBERS-4A E WFI/CBERS-4 (conclusão).

Processamentos	Cálculos	Ferramentas
<p>Índices Espectrais NDVI - <i>Normalized Difference Vegetation Index</i> (ROUSE et al, 1973). SAVI - <i>Soil Adjusted Vegetation Index</i> (HUETE; JACKSON, 1988). EVI - <i>Enhanced Vegetation Index</i> (HUETE, 1997). NDWI - <i>Normalized Difference Water Index</i> (MCFEETERS, 1996).</p>	$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$ $SAVI = \frac{(NIR - RED)}{(NIR + RED + 1)} (1 + L)$ $EVI = 2.5 \frac{(NIR-RED)}{(NIR + C_1 \times RED - C_2 \times BLUE + L)} (1 + L)$ <p>Para uma densidade de vegetação intermediária, um valor de $L = 0.5$ é adotado. Os demais valores empíricos são: $C_1 = 6, C_2 = 7.5$.</p> $NDWI = \frac{(GREEN - NIR)}{(GREEN + NIR)}$	Calculadora Raster (QGIS 3.22.6)
<p>Análise de Componentes Principais (ACP) Ressalta a redundância existente, por meio de uma transformação matemática ortogonal em um conjunto de dados correlacionados, em novos componentes não correlacionados. A primeira componente é posicionada na direção de máxima variabilidade dos dados, gerando um novo produto com informações comuns entre as bandas e, a partir da segunda componente, gerando informações não correlacionadas. Os autovetores e os autovalores inicialmente devem ser extraídos dos valores dos pixels originais, calculados a partir da variância e covariância do conjunto de dados. Os autovetores são definidos pela direção ortogonal de maior variância dos dados de cada banda e os autovalores pelas variâncias medidas em cada uma das direções das componentes produzidas (PEARSON, 1901).</p>	$C_x = \frac{1}{n-1} \sum_{i=1}^n (X_i - M)(X_i - M)^T$ <p>*Onde C_x é a matriz de variância-covariância, n o número de pixels, X a variável N-dimensional e M o vetor médio.</p> $Y_i = a_1 X_1 + a_2 X_2 + \dots + a_{NJ} X_N = a^T X$ <p>*Onde Y é a componente principal e a^T é a transposição dos autovetores da matriz de variância-covariância de C_x de X.</p> $C_y = AC_x A^T$ <p>*Onde C_y é a matriz de variância-covariância de Y.</p>	“PCA” (TerraView 5.6.3)
<p>Transformação RGB-IHS Definida pela conversão do espaço tradicional RGB (Red, Green, Blue) para um novo espaço IHS (do inglês <i>Intensity - I, Hue - H, Saturation - S</i>; Intensidade, Matiz e Saturação), o qual separa o atributo I das informações relacionadas à percepção das cores (H e S) em uma imagem colorida (LEONARDI et al., 2009).</p>	$I = \frac{(r + g + b)}{3}$ $S = 1 - 3 \min(r, g, b)$ <p>*Quando $b < g$:</p> $H = \cos^{-1} \frac{(r - g) + (r - b)}{2\sqrt{(r - g)^2 + (r - b) + (g - b)}}$ <p>*Quando $b > g$:</p> $H = 360^\circ - H$	“i.rgb.hsi” (GRASS - QGIS 3.22.6).
<p>Realce Modifica valores dos níveis de cinza (NC's) dos pixels da imagem a partir de equações de ajuste (RICHARDS, 2012).</p>	$I_{nova} = gI + o$ <p>*Onde a nova imagem é o aumento do ganho (g) da imagem original (I) somado ao offset (o).</p>	“Contraste” (QGIS 3.22.6).

Elaboração: Os autores (2023).

3.3 Classificação Supervisionada

3.3.1 RANDOM FOREST (RF)

O RF é um algoritmo de aprendizagem supervisionada comumente utilizado em SR, que produz diversas árvores de decisão, a partir da seleção aleatória da amostragem de dados. Cada árvore de decisão é produzida a partir de um subconjunto das amostras de treinamento através de um sorteio aleatório com reposição, denominado *Bagging (Bootstrap Aggregating)*. Dois hiperparâmetros são definidos pelo analista: a

quantidade de variáveis que serão avaliadas (escolhidas aleatoriamente) pelo modelo para cada nó da árvore (*Mtry*) e o número de árvores que irão compor a floresta. Como todas as árvores são diferentes, por serem construídas a partir de sorteios aleatórios, a correlação entre elas tende a ser reduzida. Logo, para definir a classe de uma amostra, o algoritmo obtém as previsões para cada árvore e seleciona a melhor opção por votação, sendo a classe mais votada a escolhida como resultado final (BREIMAN, 2001; GUO et al., 2017).

O RF também é uma técnica de mineração de dados que proporciona selecionar e classificar os atributos de maior relevância na discriminação dos alvos (POLIKAR, 2012). Considerando que os dados de SR possuem uma alta dimensionalidade e a mineração de dados pode elevar o potencial de exploração dos dados, a aplicação do RF torna-se vantajosa, tanto pela sua velocidade de processamento, quanto pela menor subjetividade e predisposição a erros na classificação (BELGIU; DRĂGUȚ, 2016).

3.3.2 AMOSTRAGEM

Para as classificações supervisionadas, foram utilizados o arquivo, contendo o empilhamento dos 15 atributos, relativo a cada caso de estudo juntamente com o arquivo ROI (*Region Of Interest*-“Região de Interesse”) contendo as amostras coletadas aleatoriamente. Estas foram identificadas como “0” (referente a áreas de não-ocorrência), e “1” (referente a áreas de ocorrência). As amostras identificadas como “1” foram coletadas aleatoriamente dentro dos polígonos de deslizamento e a vetorização regional de inundação mapeados pela Carta. As amostras identificadas como “0” foram coletadas fora dos polígonos de referência também de forma aleatória. Para a aplicação do RF as amostras foram divididas, sendo 70% utilizadas como treinamento e 30% como teste. Um total de 500 árvores de decisão foram geradas para o caso dos deslizamentos, como sugerido por Belgiu e Drăguț (2016), e 200 árvores para o caso da inundação.

3.3.3 VALIDAÇÃO

A matriz de confusão, comumente usada para a identificação das confusões mais relevantes entre as classes, é caracterizada pela tabulação dos acertos e erros do modelo preditivo, para o cálculo posterior das métricas estatísticas. Diferentemente da exatidão OOB, métricas como a Acurácia Global (AG), a Precisão (P) e a Sensibilidade (S) são calculadas a partir de conjuntos distintos de treinamento e teste, sendo a exatidão calculada com base em dados de teste, que não foram utilizados durante o treinamento do modelo preditivo.

A AG é definida pela razão entre a soma do número de pixels corretamente classificados pelo número total de pixels das amostras de teste (Eq. 1) (CONGALTON, 2001):

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

onde o Verdadeiro Positivo (VP) é a classe positiva prevista corretamente; o Verdadeiro Negativo (VN) é a classe negativa prevista corretamente; o Falso Positivo (FP) é a classe negativa prevista incorretamente; e o Falso Negativo (FN) é a classe positiva prevista incorretamente.

A métrica P é definida pela probabilidade de um pixel atribuído a uma classe ser corretamente pertencente a esta classe (Eq. 2). Já a métrica S é definida pela probabilidade de um pixel de uma classe estabelecida ser classificado corretamente (Eq. 3) e a média harmônica entre os erros configuram o *F1-score* (Eq. 4).

$$P = \frac{VP}{VP + FP} \quad (2)$$

$$S = \frac{VP}{VP + FN} \quad (3)$$

$$F1 - score = 2x \frac{P \times S}{P+S} \quad (4)$$

3.4 Seleção de atributos - Out-Of-Bag (OOB)

Pela amostragem com reposição, cerca de um terço das amostras de treinamento não serão utilizadas para a construção do modelo preditivo RF. A separação aleatória dessas amostras, conhecida como *Out-of-bag* (OOB, “fora do saco”), é posteriormente utilizada para a avaliação da performance da classificação (erro OOB), além da obtenção da ordem de importância das variáveis (BREIMAN, 2001; ADAM et al., 2014).

Para a identificação dos atributos mais relevantes para o modelo, utilizando-se as amostras OOB, a permutação aleatória entre os valores de uma variável é realizada, possibilitando a avaliação detalhada da perda da capacidade preditiva. Se a acurácia diminuir significativamente após a permutação, indica-se que a variável é importante para a previsão correta das classes. Tal processo é repetido para cada variável e a sua contribuição para a acurácia do modelo é calculada, sendo uma propriedade muito utilizada em aplicações de SR, devido à possibilidade de selecionar os recursos mais relevantes para a classificação de imagens (BREIMAN, 2001; LIAW; WIENER, 2002). Essa característica do OOB foi explorada para a seleção dos três atributos mais importantes para a classificação de áreas de deslizamentos e de inundações. No total, 11 produtos foram extraídos das bandas dos sensores e, juntamente com as quatro bandas originais, formaram o conjunto contendo os quinze produtos empilhados (Quadro 3), para a posterior seleção de atributos.

Quadro 3 - Atributos de entrada para a classificação supervisionada RF dos dois casos de estudo.

Bandas Originais	Componentes Principais*	Índices Espectrais	Transformação RGB-IHS**
RED (0,63-0,69 μ m)	CP1	NDVI	INTENSITY HUE SATURATION
GREEN (0,52-0,59 μ m)	CP2	SAVI	
BLUE (0,45-0,52 μ m)	CP3	EVI	
NIR (0,77-0,89 μ m)	CP4	NDWI	
* Componentes principais extraídas a partir das quatro bandas originais de cada sensor utilizado.			
** Transformação realizada a partir das bandas RED, GREEN e BLUE de cada sensor utilizado.			

Elaboração: Os autores (2023).

3.5 Combinação dos produtos no espaço de cores RGB

No espaço RGB, qualquer imagem multiespectral pode ser combinada em seus componentes espectrais primários do Red, Green e Blue com base em um sistema de coordenadas cartesianas. O modelo pode ser representado através de um cubo de cores, no qual os valores RGB primários são os três principais vértices, e a combinação entre eles (cores secundárias) representada pelos demais pontos no cubo (GONZALEZ; WOODS, 2009). Para uma composição RGB apropriada, a qual evidencie as informações espectrais desejadas, é necessário o conhecimento prévio das bandas espectrais dos sensores selecionados, assim como a experiência empírica em relação ao comportamento espectral dos alvos. Ademais, um cubo de cores RGB tridimensional pode combinar diferentes produtos de SR, a depender do entendimento do analista. Tal abordagem foi aplicada em cada estudo de caso da pesquisa para análises qualitativas, onde os três principais atributos selecionados pelo RF foram combinados no espaço RGB de cores, sendo selecionada a composição de melhor correspondência visual dos alvos de interesse.

4 RESULTADOS E DISCUSSÕES

Na apresentação dos resultados, a quantidade de amostras aleatórias coletadas com base nos dados de referência da Carta será comentada inicialmente. Para análise quantitativa, o ranqueamento dos atributos a partir de amostras OOB será analisado, seguido pelos resultados das métricas estatísticas obtidas a partir da classificação RF. Para análise qualitativa, a composição RGB de melhor correspondência visual dos alvos será avaliada e as vantagens e desvantagens em cada caso serão discutidas.

4.1 Amostragem para o caso dos deslizamentos em Petrópolis (RJ)


Após o pré-processamento (correção atmosférica), foram coletadas aleatoriamente 165 amostras a partir dos 55 polígonos de referência (3 amostras por polígono), e 165 amostras aleatórias localizadas fora

destes polígonos para a posterior classificação. Ressalta-se que a vetorização realizada pela Carta durante o evento foi baseada em imagens de altíssima resolução espacial do HIRI/Pleiades-1B, de 50 centímetros.

4.1.1 RANQUEAMENTO DOS ATRIBUTOS A PARTIR DA CLASSIFICAÇÃO RF

Com uma exatidão de 83,11% calculada usando-se as amostras OOB, o ranqueamento dos quinze atributos (Figura 2) foi obtido. Para a cena avaliada, a CP3, o SAVI e o HUE foram os atributos de maior relevância na classificação binária.


Figura 2 - *Ranking* de importância dos atributos a partir da análise das amostras OOB para Petrópolis (RJ).



Fonte: Os autores (2023).

De modo comparativo, a classificação supervisionada foi aplicada apenas aos quatro atributos referentes aos canais espectrais originais do sensor MUX/CBERS-4A (RED, GREEN, BLUE e NIR). Como indicado na Figura 3, com uma exatidão de 80,95% calculada usando-se as amostras OOB, a banda RED foi o atributo de maior contribuição, seguida por BLUE, GREEN e NIR.

Figura 3 - *Ranking* de importância das bandas originais a partir da análise das amostras OOB para Petrópolis (RJ).



Fonte: Os autores (2023).

No ranqueamento com base nos quinze atributos (Figura 2), a banda RED ocupou o sétimo lugar em relação aos demais atributos, demonstrando a relevância da exploração e integração mais específica das técnicas de PDI ao algoritmo. Isso se comprova com os valores de acurácia obtidos nos dois casos (Quadro 4). Nas métricas estatísticas avaliadas a partir das amostras de teste (calculadas com base na matriz de confusão), a utilização de quatro atributos também apresentou valores menores do que a utilização de quinze.

Quadro 4 - Valores de acurácia da classificação RF utilizando quatro e quinze atributos (MUX/CBERS-4A).

MUX/CBERS-4A	Exatidão OOB	Métricas / Matriz de Confusão			
		AG	P	S	F1- score
Empilhamento de quatro atributos	80,95%	77,7%	0,776	0,777	0,776
Empilhamento de quinze atributos	83,11%	81,8%	0,819	0,822	0,818

Elaboração: Os autores (2023).

O atributo de maior relevância na classificação RF do empilhamento de quinze atributos foi a CP3. Este resultado pode ser explicado pela feição espectral singular dos deslizamentos de terra expostos recentemente em comparação aos demais alvos presentes na imagem. Em benefício ao aspecto exploratório de dados da ACP, as informações espectrais redundantes entre as quatro bandas originais são reduzidas a cada CP sucessiva, restando no terceiro conjunto de saída (CP3) características espectrais mais específicas e descorrelacionadas (CROSTA, 1992; ESTORNELL et al., 2013). Como retratado no Quadro 5, a terceira componente explica 0,3395% da variância total dos dados. Em termos quantitativos, o conteúdo de informação decresce para as últimas componentes mas, em termos qualitativos, contém informações relevantes na ênfase de alvos particulares.


Quadro 5 - Autovalores e autovetores das 4 componentes extraídas do sensor MUX/CBERS-4A para a cena avaliada.

Componentes Principais	Autovalores (%)	Autovetores			
		BLUE	GREEN	RED	NIR
CP1	88,52	0,566	0,548	0,524	0,319
CP2	11,07	-0,209	-0,139	-0,205	0,945
CP3	0,33	0,689	0,015	0,723	0,006
CP4	0,05	-0,399	0,824	-0,397	-0,053

Elaboração: Os autores (2023).

Em sequência, o SAVI apresentou o segundo melhor desempenho na distinção das áreas identificadas como deslizamentos e não-deslizamentos. Na composição RGB posteriormente proposta (Seção 4.1.2), seu posicionamento no canal verde de visualização também facilitou a obtenção do contraste entre as áreas vegetadas e os demais alvos relevantes. A componente *Hue* da transformação RGB-IHS, em terceiro lugar no ranqueamento, proporcionou a separabilidade dos alvos com base nas suas cores características. Como os deslizamentos de terra possuem uma coloração específica dentre os demais alvos da cena avaliada, o atributo foi capaz de melhor evidenciá-los. Ressalta-se que o *Hue* não é influenciado pelos distintos níveis de reflectância causados por diferenças de iluminação e sombra (LIU; MOORE, 1990). Os três produtos de maior relevância na classificação estão apresentados na Figura 4.

Figura 4 - Os três atributos mais relevantes na classificação RF de Petrópolis (RJ). Em 1) composição em cor verdadeira do MUX/CBERS-4A; 2) polígonos de deslizamentos mapeados pela Carta; 3) CP3; 4) SAVI; 5) *Hue*.




Fonte: Os autores (2023).

4.1.2 DETECÇÃO DE ÁREAS DE DESLIZAMENTOS EM PETRÓPOLIS (RJ)

As três primeiras bandas mais relevantes do empilhamento de melhor desempenho quantitativo (Figura 2) foram combinadas no espaço de cores RGB (R=CP3, G=SAVI, B=HUE), de acordo com a melhor correspondência visual dos alvos. Logo, alertas visuais de possíveis deslizamentos foram gerados (Figura 5).

Figura 5 - Áreas de deslizamentos destacadas em tons de laranja na composição RGB (linha superior) sugerida (R=CP3, G= SAVI, B= HUE), em comparação à composição em cor verdadeira do MUX/CBERS-4A (linha do meio) e às cicatrizes de referência sobrepostas (linha inferior).



Fonte: Os autores (2023).

As possíveis cicatrizes de deslizamentos foram destacadas em um tom de laranja com o posicionamento da CP3 no canal vermelho e do SAVI no canal verde de visualização. Como a cor laranja resulta da combinação “vermelho + amarelo”, e o amarelo por sua vez resulta da combinação “vermelho + verde”, pode-se afirmar que existe uma influência majoritária da CP3 e do SAVI na coloração adquirida pelo alvo principal. As áreas vegetadas passaram a adquirir tons de verde, indicando a predominância do SAVI na resposta da vegetação. Já o meio urbano passou a adquirir os tons de vermelho, azul e magenta (dependendo da tonalidade dos telhados e das áreas de mistura espectral), apontando uma similar participação da CP3 e da componente *Hue*. Na composição em cor verdadeira do MUX/CBERS-4A, a diferenciação entre os deslizamentos e áreas urbanas é comprometida pela baixa sensibilidade do sensor em captar as pequenas variações radiométricas entre os alvos. Esse fato acaba gerando vários “clarões” visuais quando o realce é aplicado. Já na composição sugerida (R=CP3, G=SAVI, B=HUE), esse efeito é minimizado pelo melhor contraste estabelecido entre as cores. Comparando as duas composições, os pixels mais claros presentes passaram a adquirir a cor vermelha (telhado vermelho), azul (lajes), magenta (áreas de mistura espectral) ou laranja (deslizamentos) na composição falsa cor sugerida, a depender do tipo de alvo. Ainda, observa-se que os principais alertas visuais gerados em laranja coincidiram com a localização dos polígonos em vermelho delimitados pela Carta.

Algumas áreas mais antigas de solo exposto também foram diferenciadas, havendo a identificação da assinatura espectral individualizada de um solo mais úmido e exposto recentemente, de áreas já evidenciadas ou desmatadas em um momento passado, também como aponta o trabalho de Pike (1988). Com a diferença de 15 dias entre a data de aquisição da imagem e a data de ativação da Carta, o contraste entre estas duas classes pôde ser evidenciado. As demais áreas destacadas em laranja que não foram caracterizadas como deslizamentos pela Carta, foram identificadas como áreas de desmatamento recente, baseando-se em imagens do *Google Satellites* pré-evento. Tais alvos apresentam um comportamento espectral semelhante, sendo comumente confundidos em trabalhos equivalentes.

4.2 Inundação regional em Sind, Balochistan e Punjab (Paquistão)


Após os procedimentos de pré-processamento (registro das imagens em nível L2 e correção atmosférica) e das técnicas de PDI selecionadas, o cubo de dados contendo os quinze atributos derivados do sensor WFI/CBERS-4 foi classificado pelo RF. Um total de 300 amostras foram coletadas aleatoriamente

dentro do polígono caracterizado como regiões inundadas (808.882 km²) pela Carta, e 300 amostras aleatórias coletadas fora desta grande área. Destaca-se que não foi adotado um mesmo padrão de número de amostras para os dois estudos de caso analisados tanto devido às diferentes resoluções espaciais utilizadas (16.5 e 64 metros), quanto pela diferença de escala entre as áreas atingidas. Logo, três vetorizações foram realizadas pela Carta no período do evento da inundação a partir de imagens de diferentes satélites, sendo eles: o NOAA-20/VIIRS (375 metros); o MSI/Sentinel-2 (10 metros); e o *Planet* (3 metros). Na presente pesquisa, o polígono de inundação utilizado como referência principal foi o extraído a partir da imagem obtida pelo NOAA-20/VIIRS, devido à capacidade de processamento de dados de uma área tão extensa.

4.2.1 RANQUEAMENTO DOS ATRIBUTOS A PARTIR DA CLASSIFICAÇÃO RF

O ranqueamento dos quinze atributos para o caso do Paquistão foi obtido com uma exatidão OOB de 87,76% (Figura 6). Na cena avaliada, a banda do NIR, a CP1 e a CP2 foram os atributos de maior relevância na classificação.


Figura 6 - *Ranking* de importância dos atributos a partir da análise das amostras OOB para o Paquistão.



Fonte: Os autores (2023).

A classificação supervisionada também foi aplicada às quatro bandas originais do sensor WFI/CBERS-4 (RED, GREEN, BLUE e NIR). De acordo com o ranqueamento OOB (Figura 7), a banda NIR apresentou um desempenho significativo para a identificação de áreas inundadas, assim como no ranqueamento de quinze atributos (Figura 7).

Figura 7 - *Ranking* de importância das bandas originais a partir da análise das amostras OOB para o Paquistão.



Fonte: Os autores (2023).

A relevância da banda do NIR nos dois casos (empilhamento de quatro e quinze atributos) pode ser atribuída à predominância de água na cena avaliada, que absorve majoritariamente a radiação eletromagnética nesta faixa espectral. Logo, o RF foi capaz de identificar um melhor desempenho na separabilidade entre as duas classes (água e não-água) a partir do atributo NIR no empilhamento de dados. Sobre as métricas calculadas, o empilhamento de quinze atributos resultou em valores de acurácia relativamente maiores e uma composição de melhor correspondência visual dos alvos de interesse (Quadro 6).

Quadro 6 - Valores de acurácia da classificação RF utilizando quatro e quinze atributos (WFI/CBERS-4).

WFI/CBERS-4	Exatidão OOB	Métricas / Matriz de Confusão			
		AG	P	S	F1- score
Empilhamento de quatro atributos	87,77%	87,5 %	0,87750	0,87654	0,875
Empilhamento de quinze atributos	88,33%	88,3 %	0,88000	0,88140	0,877

Elaboração: Os autores (2023).

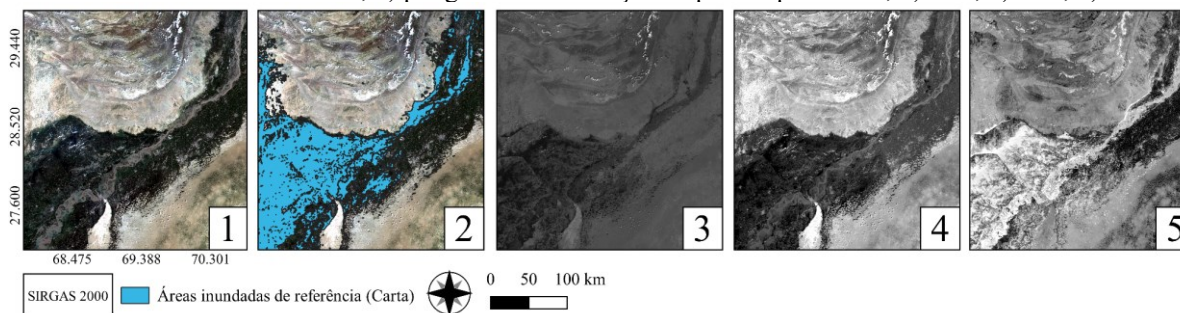
Sobre a ordem de importância dos demais atributos do empilhamento de quinze, a CP1 e a CP2 ocuparam o segundo e terceiro lugar, respectivamente. A CP1, como sendo o primeiro conjunto de saída da ACP, contém as informações espectrais comuns a todas as quatro bandas originais. O segundo conjunto de saída, a CP2, contém as informações mais significativas do conjunto. Como os resultados da ACP são dependentes das características espectrais da cena avaliada, as informações de interesse da classificação nesse caso se concentraram já nas primeiras componentes pela predominância de pixels de água no recorte analisado. Como indicado no Quadro 7, a CP1 e a CP2 explicam 82,93% e 15,19% da variância total dos dados. Os três produtos de maior relevância na classificação estão apresentados na Figura 8.

Quadro 7 - Autovalores e autovetores das 4 componentes extraídas do sensor WFI/CBERS-4 para a cena avaliada.

Componentes Principais	Autovalores (%)	Autovetores			
		BLUE	GREEN	RED	NIR
CP1	82,9389	0,439	0,438	0,635	0,460
CP2	15,1955	-0,262	-0,198	-0,323	0,886
CP3	1,7799	-0,767	-0,119	0,629	-0,023
CP4	0,0857	-0,386	0,868	-0,308	-0,032

Elaboração: Os autores (2023).

Figura 8 - Os três atributos mais relevantes na classificação RF no caso do Paquistão. Em 1) composição em cor verdadeira do WFI/CBERS-4; 2) polígonos de inundação mapeados pela Carta; 3) NIR; 4) CP1; 5) CP2.

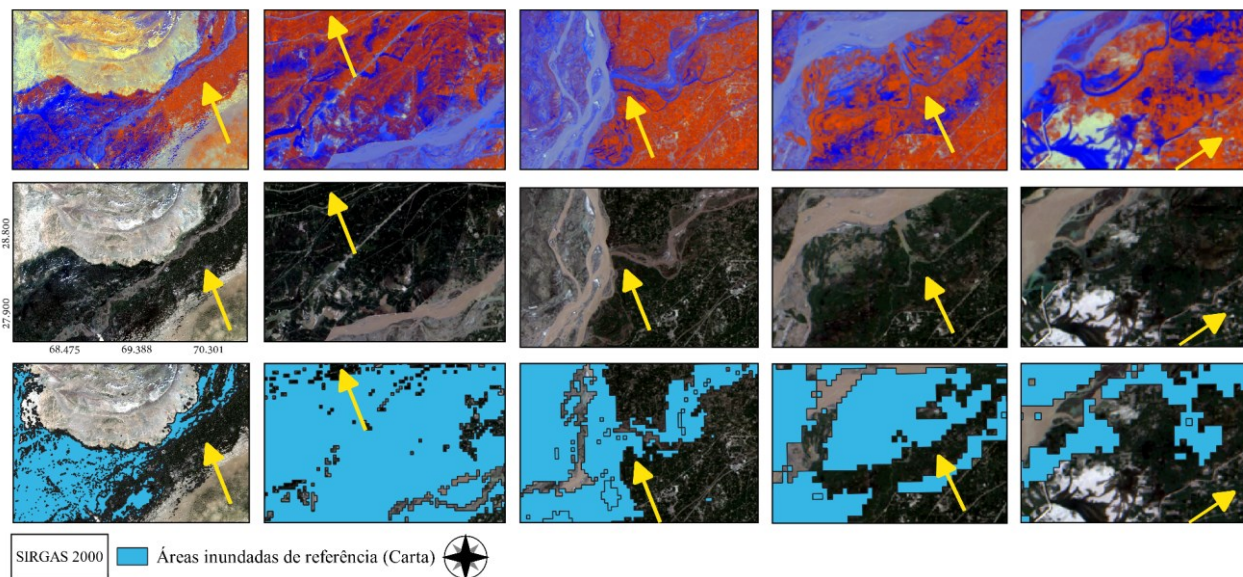


Fonte: Os autores (2023).

4.2.2 DETECÇÃO DA INUNDAÇÃO REGIONAL EM SIND, BALOCHISTAN E PUNJAB (PAQUISTÃO)

Para a geração de alertas visuais de possíveis áreas inundadas, os três primeiros atributos do ranqueamento dos quinze foram combinados no espaço de cores RGB (R=NIR, G=CP1, B=CP2) de melhor correspondência visual dos alvos de interesse. A vetorização de referência foi sobreposta à composição em cor verdadeira do sensor WFI/CBERS-4 (Figura 9).

Figura 9 - Áreas inundadas destacadas em azul e áreas não-inundadas em laranja na composição RGB sugerida (R=NIR, G=CP1, B=CP2) (linha superior), em comparação à composição em cor verdadeira do WFI/CBERS-4 (linha central) e com sobreposição dos polígonos de referência (linha inferior).



Fonte: Os autores (2023).

Na composição em cor verdadeira, comparada com a vetorização das áreas inundadas mapeadas pela Carta, nota-se que as regiões indicadas pelas setas amarelas não apresentam tonalidades diferentes que possam distingui-las de áreas não-inundadas. A partir da aplicação da composição sugerida (R=NIR, G=CP1, B=CP2), a visualização do padrão da inundação regional é observado, sendo: as áreas em vermelho-alaranjado indicativas de regiões não-inundadas (maior representação da banda do NIR posicionada na faixa vermelha de visualização); as áreas em azul escuro indicativas de inundação (maior representação da CP2 posicionada na faixa azul de visualização); as áreas em azul terroso indicativas da extensão do rio principal (influência da CP2 e do NIR); e as demais combinações de cores indicativas da preponderância do Grande Deserto Indiano. Ainda, pela diferença da resolução espacial entre o NOAA20/VIIRS (375 m) e o WFI/CBERS-4 (64 m), percebe-se um melhor nível de detalhamento entre os alvos na composição sugerida pelos atributos extraídos das imagens obtidas pelo sensor brasileiro, a depender da escala de visualização.

Comprova-se que, para desastres da ordem de milhares de quilômetros quadrados, a utilização de uma imagem de resolução espacial mais detalhada pode ser vantajosa. A resolução espacial utilizada não permite a visualização de detalhes, porém possibilita uma rápida visão geral da área inundada, a identificação das áreas de risco, além do monitoramento do progresso da inundação e seu direcionamento. Destaca-se que, considerando a resolução temporal tanto do MUX/CBERS-4A (31 dias) e do WFI/CBERS (5 dias), o tempo de execução imediata do fluxo de processamento dos dados corresponde à disponibilização das imagens e o tempo de execução do código em Python (estimado em 30 segundos, incluindo apenas as etapas de pré-processamento, a extração dos atributos e as suas possíveis combinações no espaço RGB).

5 CONCLUSÕES

Os resultados apresentados confirmam a utilidade dos sensores brasileiros para análises de deslizamentos e de inundações regionais, tendo-se um conhecimento prévio das técnicas de PDI disponíveis. A aplicação das composições propostas (R=CP3, G=SAVI e B=HUE para o caso dos deslizamentos e R=NIR, G=CP1 e B=CP2 para o caso da inundação) obtidas a partir de bons resultados da exatidão OOB e das métricas AG, P, S e F1-score avaliadas, propiciaram a exploração de dados adicionais às quatro bandas originais dos sensores disponíveis. Destaca-se que, para a avaliação de desastres equivalentes, pode ser preciso revisar e adaptar as composições sugeridas. Trabalhos futuros incluem análises de outras regiões e de testes com mais atributos empregando imagens pré e pós-desastre. Os resultados dessa pesquisa estão sendo aplicados no contexto da participação do INPE na Carta, por meio da geração de produtos com as composições propostas.

Agradecimentos

Agradecemos ao Instituto Nacional de Pesquisas Espaciais (INPE) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio fornecido ao longo desta pesquisa de mestrado (número do processo: 140426/2023-0). Aos revisores do artigo pelas relevantes contribuições.

Contribuição dos autores

Conceitualização: B. O. R e T. S. K. Metodologia: B. O. R e T. S. K. Redação: B. O. R. Ilustração: B. O. R. Supervisão: T. S. K. Revisão: B. O. R., T. S. K e L. M. N.

Conflitos de interesse

Não há conflitos de interesse.

Referências

- ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, v. 35, n. 10, p. 3440-3458, 2014.
- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24-31, 2016.
- BOCCARDO, P.; TONOLO, F. G. Remote sensing role in emergency mapping for disaster response. In: LOLLINO, G.; MANCONI, A.; GUZZETTI, F.; CULSHAW, M.; BOBROWSKY, P.; LUINO, F. (Ed.). *Engineering geology for society and territory*. Cham: Springer, 2015. p.17-24. DOI: 10.1007/978-3-319-09048-1_3.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, p. 5-32, 2001.
- BUNTING, P., CLEWLEY, D., LUCAS, R.M.; GILLINGHAM, S. The remote sensing and GIS software library (RSGISLib). *Computers & Geosciences*, v. 62, p.216.226, 2014. Disponível em: <https://doi.org/10.1016/j.cageo.2013.08.007>.
- CASTEJON, E. F.; FONSECA, L. M. G.; FORSTER, C. H. Q. Melhoria do processo de correção geométrica de imagens cbers-ccd pelo uso de amostras georreferenciadas classificadas. **Boletim de Ciências Geodésicas**, v. 21, p. 658-673, 2015 DOI: <http://dx.doi.org/10.1590/S1982-21702015000400038>.
- CENTRE FOR RESEARCH ON EPIDEMIOLOGY OF DISASTERS (CRED). Natural disasters in 2019. Report of the centre for research on the epidemiology of disasters. 2019. Disponível em: <https://www.cred.be/publications>.
- CHMUTINA, K.; VON MEDING, J. A Dilemma of language: “natural disasters” in academic literature. *International Journal of Disaster Risk Science*, v. 10, n. 3, p. 283-292, 2019. 2. DOI: <https://doi.org/10.1007/s13753-019-00232-2>.
- CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS (CNM). Mais de 25% das mortes por chuvas no Brasil nos últimos 10 anos ocorreram em 2022. Agência CNM de Notícias. Maio/ 2022. Disponível em: <https://www.cnm.org.br/comunicacao/noticias/mais-de-25-das-mortes-por-chuvas-no-brasil-nos-ultimos-10-anos-ocorreram-em-2022>.
- CONGALTON, R. G. Accuracy assessment and validation of remotely sensed and other spatial information. *International Journal of Wildland Fire*, v. 10, p. 321-328, 2001. Disponível em: <https://doi.org/10.1071/WF01031>. Acesso em: 31 ago. 2021.
- CROSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. UNICAMP/Instituto de Geociências, 1992.

- DENIS, G.; BOISSEZON, H.; HOSFORD, S.; PASCO, X.; MONTFORT, B.; RANERA, F. The evolution of Earth Observation satellites in Europe and its impact on the performance of emergency response services. *Acta Astronautica*, v. 127, p. 619-633, 2016. DOI: <https://doi.org/10.1016/j.actaastro.2016.06.012>.
- ESTORNELL, J. et al. Principal component analysis applied to remote sensing. *Modelling in Science Education and Learning*, v. 6, p. 83-89, 2013.
- FOLHA DE SÃO PAULO. Sobe para 232 o total de pessoas mortas em tragédia em Petrópolis. 2022. Disponível em: <https://www1.folha.uol.com.br/cotidiano/2022/03/sobe-para-232-total-de-pessoas-mortas-em-tragedia-em-petropolis.shtml>. Acesso em: 8 ago. 2022.
- GÄHLER, M.; MARGHANY, M. Remote sensing for natural or man-made disasters and environmental changes. In: *Environmental applications of remote sensing*. InTech, 2016. p. 309-338.
- GILMORE, S.; SALEEM, A; DEWAN, A. Effectiveness of DOS (Dark-Object Subtraction) method and water index techniques to map wetlands in a rapidly urbanising megacity with Landsat 8 data. *Research@Locate'15*, p. 100-108, 2015. Disponível em: <https://espace.curtin.edu.au/handle/20.500.11937/43918>.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento digital de imagens*. [S.l.]: Pearson Educación, 2009.
- GUERRA, A. J. T.; GONÇALVES, L. F. H.; LOPES, P. B. M. Evolução histórico-geográfica da ocupação desordenada e movimentos de massa no município de Petrópolis, nas últimas décadas. *Revista Brasileira de Geomorfologia*, v. 8, n. 1, 2007. DOI: <https://doi.org/10.20502/rbg.v8i1.84>.
- GUO, M.; LI, J.; SHENG, C.; XU, J.; WU, L. A review of wetland remote sensing. *Sensors*, v. 17, n. 4, p. 1–36, 2017.
- HEIN, W.; WILSON, C.; LEE, B.; RAJAPAKSA, D.; de MOEL, H.; ATHUKOROLA, W.; MANAGI, S. Climate change and natural disasters: government mitigation activities and public property demand response. *Land Use Policy*, v. 82, p. 436-443, 2019. DOI: <https://doi.org/10.1016/j.landusepol.2018.12.026>.
- HOLDEN, C. Classification of land cover. 2017. Disponível em: https://ceholden.github.io/open-geo-tutorial/python/chapter_5_classification.html#Chapter-5:-Classification-of-land-cover. Acesso em: 5 ago. 2021.
- HUETE, A. R.; JACKSON, R. D. Soil and atmosphere influences on the spectra of partial canopies. *Remote Sensing of Environment*, v. 25, n. 1, p. 89-105, 1988. DOI: [https://doi.org/10.1016/0034-4257\(88\)90043-0](https://doi.org/10.1016/0034-4257(88)90043-0).
- HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, v.59, p.440-451, 1997.
- INTERNATIONAL CHARTER ON SPACE AND MAJOR DISASTERS (ICSMD) History. 2022. Disponível em: <https://disastersCarta.org/web/guest/history>.
- LEONARDI, F.; OLIVEIRA, C. G.; FONSECA, L. M. G.; ALMEIDA, C. D. Fusão de imagens cbers 2b: Ccd-hrc. In: *SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO*, 14., 2009. Proceedings... São José dos Campos: INPE, 2009. p.6951-6958. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.16.12.28/doc/6951-6958.pdf>.
- LIAW, A.; WIENER, M. Classification and regression by randomForest. *R News*, v. 2/3, p. 18- 22. 2002.
- LIU, J. G.; MOORE, J. McM. Hue image RGB colour composition: a simple technique to suppress shadow and enhance spectral signature. *International Journal of Remote Sensing*, v. 11, n. 8, p. 1521-1530, 1990.
- MARTINIS, S. et al. DLR'S contributions to emergency response within the International Charter 'Space and Major Disasters'. In: *IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS)*, 2018. Proceedings... IEEE, 2018. p.6540-6543. Disponível em: https://ieeexplore.ieee.org/abstract/document/8517910?casa_token=DnVVvdJS78wAAAAA:pCn3nhHCbt_HTdFOPwW8ZdEm6e5LuIrO_oJTMZ3G_str2_0Zo3P7PwNgvvpv5RYpFvRjN_SOdWss.
- MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), v. 17, n.7, p.1425-1432, 1996. DOI: <https://doi.org/10.1080/01431169608948714>.

- MUNAWAR, H. S.; HAMMAD, A. W. A.; WALLER, S. T. Remote sensing methods for flood prediction: a review. *Sensors*, v. 22, n. 3, p. 960, 2022. DOI: <https://doi.org/10.3390/s22030960>.
- NAMIKAWA, L. M. Mapeamento para emergências com CBERS-4: um exemplo de aplicação do sensor PAN. 2017. Disponível em: <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2017/10.27.13.05/doc/61625.pdf>.
- NOVELLINO, A.; JORDAN, C.; AGER, G.; BATESON, L.; FLEMING, C.; CONFUORTO, P. Remote sensing for natural or man-made disasters and environmental changes. DURRANI, T.; WANG, W.; FORBES, S. (Ed.). *Geological disaster monitoring based on sensor networks*. Singapore: Springer, 2019. DOI: https://doi.org/10.1007/978-981-13-0992-2_3.
- OLIVEIRA, T. R.; OLIVEIRA, V. S.; PONTES, M.; LIBÓRIO, M. P.; HADAD, R. M.; LAUDARES, S. (2019). Metodologia para análise de danos ambientais do rompimento da Barragem de Fundão em Bento Rodrigues (MG). *HOLOS*, 7, 1-17. DOI: <https://doi.org/10.15628/holos.2019.6187>.
- PEARSON, K. On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, v. 2, n.11, p.559-572, 1901. DOI: <https://doi.org/10.1080/14786440109462720>.
- PIKE, R. J. The geometric signature: quantifying landslide-terrain types from digital elevation models. *Mathematical Geology*, v. 20, p.491-511, 1988. DOI: <https://doi.org/10.1007/BF00890333>.
- POLIKAR, R. Ensemble learning. *Ensemble Machine Learning*, p. 1–34, 2012.
- RICHARDS, J. A. Remote sensing digital image analysis. Berlin: Springer, 2012.
- ROUSE, J.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with erts. *NASA Special Publication*, v. 351, n. 1974, p.309–317, 1973.
- SHAH, A. A.; GONG, Z.; PAL, I.; SUN, R.; ULLAH, W.; WANI, G. F. Disaster risk management insight on school emergency preparedness—a case study of Khyber Pakhtunkhwa, Pakistan. *International Journal of Disaster Risk Reduction*, v. 51, e 101805, 2020. DOI: <https://doi.org/10.1016/j.ijdr.2020.101805>.
- TAN, L.; GUO, J.; MOHANARAJAH, S.; ZHOU, K. Can we detect trends in natural disaster management with artificial intelligence? A review of modeling practices. *Natural Hazards*, v. 107, n.3, 2021. DOI: <https://doi.org/10.1007/s11069-020-04429-3>.
- TORRES, G. P.; DO CARMO, L. F. R.; DE ALMEIDA PALMEIRA, A. C. P. Estudo da relação entre precipitação e deslizamentos no município de Petrópolis–RJ. *Sistemas & Gestão*, v. 15, n. 1, p. 38-45, 2020. DOI: <https://doi.org/10.20985/1980-5160.2020.v15n1.1611>.
- UM SÓ PLANETA. Derretimento de geleiras pode ter piorado inundações que deixaram um terço do Paquistão debaixo d'água. 31 ago. 2022. Disponível em: <https://umsoplaneta.globo.com/clima/noticia/2022/08/31/derretimento-de-geleiras-pode-ter-piorado-inundacoes-que-deixaram-um-terco-do-paquistao-debaixo-dagua.ghtml>.
- VOIGT, S. et al. Global trends in satellite-based emergency mapping. *Science*, v. 353, n. 6296, p. 247-252, 2016.
- WANG, Z.; YE, X. Social media analytics for natural disaster management. *International Journal of Geographical Information Science*, v. 32, n. 1, p. 49-72, 2018.
- YU, M.; YANG, C.; LI, Y. Big data in natural disaster management: a review. *Geosciences*, v. 8, n. 5, p. 165, 2018.
- ZHOU, L.; WU, X.; XU, Z.; FUJITA, H. Emergency decision making for natural disasters: An overview. *International Journal of Disaster Risk Reduction*, v. 27, p. 567-576, 2018.

Biografia do autor principal



Brenda Oliveira Rocha é doutoranda em Sensoriamento Remoto no Instituto Nacional de Pesquisas Espaciais (INPE). Ela recebeu seu diploma de bacharel em Ciências Ambientais pela Universidade Federal do Ceará (UFC) e seu mestrado em Sensoriamento Remoto pelo INPE em 2021 e 2023, respectivamente. Ela é membro da equipe de pesquisadores brasileiros da Carta Internacional "Space and Major Disasters", com o objetivo de fornecer mapas de emergência de áreas potencialmente afetadas por eventos extremos.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original