



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2023/03.28.13.59-TDI

**PROCESSAMENTO DE IMAGENS DOS SATÉLITES
BRASILEIROS CBERS-4, CBERS-4A E AMAZONIA-1
PARA RESPOSTAS RÁPIDAS A DESASTRES**

Brenda Oliveira Rocha

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Thales Sehn Körting,
aprovada em 21 de março de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/48Q9KJE>>

INPE
São José dos Campos
2023

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2023/03.28.13.59-TDI

**PROCESSAMENTO DE IMAGENS DOS SATÉLITES
BRASILEIROS CBERS-4, CBERS-4A E AMAZONIA-1
PARA RESPOSTAS RÁPIDAS A DESASTRES**

Brenda Oliveira Rocha

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelo Dr. Thales Sehn Körting,
aprovada em 21 de março de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/48Q9KJE>>

INPE
São José dos Campos
2023

Dados Internacionais de Catalogação na Publicação (CIP)

Rocha, Brenda Oliveira.

R582p Processamento de imagens dos satélites brasileiros CBERS-4, CBERS-4a e Amazonia-1 para respostas rápidas a desastres / Brenda Oliveira Rocha. – São José dos Campos : INPE, 2023.

xxv + 105 p. ; (sid.inpe.br/mtc-m21d/2023/03.28.13.59-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2023.

Orientador : Dr. Thales Sehn Körting.

1. Desastres. 2. Deslizamentos. 3. Inundações. 4. Satélites brasileiros. 5. Processamento de imagens. I.Título.

CDU 528.852:504.2



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÃO



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
Serviço de Pós-Graduação - SEPGR

DEFESA FINAL DE DISSERTAÇÃO DE BRENDA OLIVEIRA ROCHA
REG. 810385/2021, BANCA Nº 036/2023

No dia 21 de março de 2023, de forma online, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestra em Sensoriamento Remoto, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

Título: "PROCESSAMENTO DE IMAGENS DOS SATÉLITES BRASILEIROS CBERS-4, CBERS-4A E AMAZONIA-1 PARA RESPOSTAS RÁPIDAS A DESASTRES"

Membros da banca:

Dr. Camilo Daleles Rennó – Presidente – INPE

Dr. Thales Sehn Körting – Orientador – INPE

Dr. Laercio Massaru Namikawa – Membro Interno – INPE

Dr. Antonio Geraldo Ferreira - Membro Externo - UFC



Documento assinado eletronicamente por **Thales Sehn Korting, Pesquisador**, em 22/03/2023, às 17:49 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Camilo Daleles Rennó, Tecnologista**, em 23/03/2023, às 05:58 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Laércio Massaru Namikawa, Tecnologista**, em 31/03/2023, às 09:41 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Antonio Geraldo Ferreira (E), Usuário Externo**, em 04/04/2023, às 14:05 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **10898043** e o código CRC **E22BC68E**.

*Dedico aos meus pais, Carlos e Gorete
e aos meus irmãos Breno, Bruno e Letícia.
Também em memória da minha avó Telina.
Com amor.*

AGRADECIMENTOS

Agradeço imensamente a Deus por ter me dado a oportunidade de realizar a pós-graduação no INPE e a todas as experiências associadas. Também agradeço por Ele ter sido tão presente e ter protegido a minha família durante esse meu tempo distante.

Ao Programa de Pós-Graduação em Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais (INPE) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo fornecimento dos recursos necessários para o desenvolvimento deste estudo.

Agradeço ao meu orientador Dr. Thales Sehn Körting por todo apoio fornecido, pela leveza, amizade e compreensão. Serei sempre grata pela oportunidade de trabalhar com você.

Agradeço aos professores Camilo Daleles Rennó, Laércio Massaru Namikawa e Antônio Geraldo Ferreira pela participação na minha banca de defesa e todas as contribuições realizadas. Também agradeço aos demais professores que colaboraram com o meu aprendizado durante esses dois anos.

Agradeço ao meu querido pai, Carlos, por sempre ter me incentivado a estudar e ser independente, por ter sido o primeiro a apoiar a minha vinda à São José dos Campos e por todo amor oferecido. Agradeço à minha querida mãe, Gorete, simplesmente por ser a pessoa mais incrível que eu conheço, nada que eu escreva irá dimensionar o meu amor por você.

Agradeço aos meus irmãos Breno, Bruno, Letícia, Camila e Rildson pelo apoio e alegria de sempre. Aos meus tios Francisca e Fábio, que são meus pais secundários. Às minhas primas Mariny, Mariany, Lidriana e Larissa, amo vocês. Às minhas tias que sempre cuidaram de mim com carinho. Aos amigos que sei que sempre estarão comigo, em especial: Ana Alice, Eduarda, Léo, Hillary, Rebeca, Júlia, Saulo, Igor, Ana Kelly, Isadora, Deila, Alisson, João Pedro e Vinícius. Nossos momentos fazem eu me sentir em casa, acolhida e protegida.

RESUMO

Dentre a pluralidade de desafios que surgem para a gestão de desastres naturais, a fase de resposta pós-desastre pode ser considerada a mais desafiadora, tendo em vista a necessidade do fornecimento rápido de informações que auxiliem nesse processo. Considerando as muitas vantagens do Sensoriamento Remoto (SR), as imagens de satélite podem contribuir para a análise da extensão das ocorrências e a identificação das áreas mais afetadas, através da utilização de técnicas de Processamento Digital de Imagens (PDI) que revelam áreas de interesse. O *International Charter "Space and Major Disasters"* (Carta) é a principal cooperação mundial entre agências espaciais para o fornecimento gratuito de dados de emergência. A cooperação conta com a contribuição do Brasil no processo de resposta aos chamados, quando a ocorrência se encontra dentro da área de cobertura dos satélites brasileiros. Dando importância tanto para os chamados da Carta quanto para outras eventuais solicitações de emergência, a presente pesquisa teve por objetivo utilizar dados oriundos dos satélites brasileiros e sistematizar técnicas de PDI para o apoio à gestão de desastres do tipo deslizamentos de terra e inundações regionais. A mineração de dados foi adotada para extrair os principais atributos obtidos a partir das técnicas de PDI aplicadas aos produtos dos sensores nacionais (WFI/CBERS-4, WFI/AMAZONIA-1, MUX/CBERS-4A e WPM/CBERS-4A). Com o apoio do algoritmo *Random Forest* (RF), foi realizada uma classificação supervisionada onde os três atributos de maior relevância para a classificação foram combinados no espaço de cores RGB para a identificação rápida das áreas atingidas. A metodologia foi testada em quatro casos de estudo, os quais são: 1) deslizamentos ocorridos no início de 2022 em Petrópolis (RJ); 2) deslizamentos ocorridos em maio de 2022 em Recife (PE); e as inundações regionais ocorridas em: 3) três grandes províncias do Paquistão em agosto de 2022; e 4) inundação nos municípios de Itamaraju e Prado (BA) em 2021. O mapeamento realizado pela Carta em cada caso de estudo foram utilizados como referência à avaliação quantitativa e qualitativa das composições finais sugeridas. Para os casos de deslizamentos, a composição proposta para Petrópolis foi (R=CP3, G=SAVI, B=HUE), com uma Acurácia Global (AG) de 81,82%, obtida a partir dos dados do MUX/CBERS-4A. Para o caso de Recife, a composição proposta foi (R=CP3, G=NDWI, B=CP4), com uma AG de 76,70%, com base nos dados do WPM/CBERS/4A. Sobre as inundações regionais, a composição sugerida para o Paquistão foi (R=NIR, G=CP1, B=CP2), com uma AG de 88,33%, utilizando imagens do WFI/CBERS-4. Para o caso das cidades da Bahia, a composição foi (R=NIR, G=CP1, B=EVI), com uma AG de 98,08%, alcançada a partir dos dados do WFI/AMAZONIA-1. A terceira componente principal (CP3) apresentou resultados relevantes no caso dos deslizamentos, assim como a banda do NIR para o caso das inundações regionais. Todas as áreas de interesse puderam ser evidenciadas nas composições sugeridas, com a observação de um melhor contraste entre os alvos sem a necessidade de aplicação de limiares.

Palavras-chave: Desastres. Deslizamentos. Inundações. Satélites brasileiros. Processamento de imagens. Carta.

IMAGE PROCESSING FROM THE BRAZILIAN SATELLITES CBERS-4, CBERS-4A AND AMAZONIA-1 FOR QUICK RESPONSES TO

ABSTRACT

Among the plurality of challenges that arise for the management of natural disasters, the post-disaster response phase can be considered the most challenging, in view of the need to quickly provide information that helps in this process. Considering the many advantages of Remote Sensing (RS), satellite images can contribute to the analysis of the extent of occurrences and the identification of the most affected areas, through the use of Digital Image Processing (DIP) techniques that reveal areas of interest. The International Charter "Space and Major Disasters" (Charter) is the world's leading cooperation between space agencies for the free provision of emergency data. The cooperation relies on Brazil's contribution in the process of responding to calls, when the occurrence is within the coverage area of Brazilian satellites. Giving importance to both the Charter calls and other possible emergency requests, the present research aimed to use data from Brazilian satellites and systematize DIP techniques to support the management of disasters such as landslides and regional floods. The data mining technique was adopted to extract the main attributes obtained from the PDI techniques applied to national sensor products (WFI/CBERS-4, WFI/AMAZONIA-1, MUX/CBERS-4A and WPM/CBERS-4A). With the support of the Random Forest (RF) algorithm, a supervised classification was performed where the three most relevant attributes for the classification were combined in the RGB color space for the quick identification of the affected areas. The methodology was tested in four case studies, which are: 1) landslides that occurred in early 2022 in Petrópolis (RJ); 2) landslides that occurred in May 2022 in Recife (PE); and the regional floods that occurred in: 3) three major provinces of Pakistan in August 2022; and 4) flooding in the municipalities of Itamaraju and Prado (BA) in 2021. The mapping carried out by the Charter in each case study was used as a reference for the quantitative and qualitative evaluation of the suggested final compositions. For cases of landslides, the composition proposed for Petrópolis was (R=CP3, G=SAVI, B=HUE), with a Global Accuracy (GA) of 81.82%, obtained from MUX/CBERS-4A data. For the case of Recife, the proposed composition was (R=CP3, G=NDWI, B=CP4), with an GA of 76.70%, based on WPM/CBERS/4A data. On regional flooding, the suggested composition for Pakistan was (R=NIR, G=CP1, B=CP2), with an GA of 88.33%, using images from WFI/CBERS-4. For the case of the cities in Bahia, the composition was (R=NIR, G=CP1, B=EVI), with an GA of 98.08%, obtained from WFI/AMAZONIA-1 data. The third principal component (CP3) presented relevant results in the case of landslides, as well as the NIR band for the case of regional floods. All areas of interest could be evidenced in the suggested compositions, with the observation of a better contrast between the targets without the need to apply thresholds.

Keywords: Disasters. Landslides. Floods. Brazilian satellites. Image processing. Charter.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Quantidade de desastres registrados (un.) e os danos materiais e prejuízos totais anuais no Brasil (R\$), no período entre 1995-2019.....	6
Figura 2.2 – Inundação na cidade de Raposos (MG). Anualmente os habitantes sofrem com a cheia do rio das Velhas, principalmente os moradores de áreas irregulares.....	8
Figura 2.3 – Uma das áreas atingidas por deslizamentos generalizados desencadeados em Recife (PE), em junho de 2022, após chuvas intensas.....	9
Figura 2.4 – Representação dos valores em novos eixos descorrelacionados.	15
Figura 2.5 – Representação do modelo de cores IHS em um plano circular....	20
Figura 2.6 – Representação esquemática do RF. Cada árvore apresenta o seu resultado com base nas combinações aleatórias realizadas pelo algoritmo, e o resultado final será a classe votada majoritariamente.....	22
Figura 2.7 - Número de ativações anuais da Carta, desde a sua criação até o ano de 2021.....	26
Figura 2.8 - Mancha de óleo em Sri-Lanka (Índia), detectada pelo CBERS-4..	28
Figura 3.1 - Localização dos 4 casos de estudo.....	32
Figura 3.2 – Uma das cicatrizes de deslizamentos desencadeadas na cidade de Petrópolis-RJ.....	33
Figura 3.3 – Cicatrizes de deslizamentos no bairro Barro (Recife-PE), mapeadas pela Carta a partir de imagens de altíssima resolução do HIRI/Pleiades-1B....	34
Figura 3.4 – Uma das áreas alagadas da província de Sindh, Paquistão.....	35
Figura 3.5 – Uma das áreas inundadas do município de Itamaraju (BA).....	36
Figura 4.1 – Fluxograma da metodologia.....	37
Figura 4.2 – Representação do sistema de coordenadas cartesianos dos componentes espectrais primários (a) e cubo de cores para uma composição de 24 bits (b).....	42

Figura 4.3 – Exemplo de combinações possíveis entre os três atributos mais relevantes na classificação do RF, para o estudo de caso do município de Petrópolis. Em (a): composição em cor verdadeira (765) do sensor MUX/CBERS-4A e algumas cicatrizes de deslizamento indicadas pelas setas vermelhas; em (b): CP3 extraída do empilhamento das quatro bandas do mesmo sensor avaliado; em (c): componente *Hue* extraída da transformação RGB-IHS das bandas (765). Todas as combinações possíveis entre os produtos CP3, SAVI e HUE estão destacadas nas imagens numeradas de 1 a 6.....44

Figura 5.1 – Ranqueamento de importância/relevância do empilhamento dos quinze atributos extraídos para o estudo de caso dos deslizamentos em Petrópolis (RJ), a partir da análise das amostras OOB..... 46

Figura 5.2 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor MUX/CBERS-4A para o estudo de caso dos deslizamentos em Petrópolis (RJ), a partir da análise das amostras OOB..... 46

Figura 5.3 – CP3 extraída das bandas (5678) do MUX/CBERS-4A, para o caso do município de Petrópolis. Em (a) e (b) cicatrizes de deslizamentos; em (c) área de solo exposto com mesma tonalidade dos deslizamentos.....48

Figura 5.4 – Atributo SAVI extraído a partir das bandas do MUX/CBERS-4A, para o caso de Petrópolis (RJ). Em (a) e (b) áreas de deslizamentos; em (c) área de solo..... 49

Figura 5.5 – Componente *Hue* resultante da transformação RGB-IHS a partir das bandas do MUX/CBERS-4A, para o caso do município de Petrópolis. Em (a) e (b) cicatrizes de deslizamentos; em (c) área de solo exposto com mesma tonalidade dos deslizamentos.....50

Figura 5.6 – Áreas de deslizamentos destacadas em tons de laranja na composição RGB (CP3, SAVI, HUE) sugerida a partir do ranqueamento OOB dos quinze atributos em comparação à composição em cor verdadeira (765) do sensor MUX/CBERS-4A..... 51

Figura 5.7 – Áreas de deslizamentos destacadas em tons de laranja na composição RGB sugerida (R= CP3, G= SAVI, B= HUE), em comparação com a composição RGB (765) do MUX/CBERS-4A. As setas pretas indicam o limite entre as classes..... 53

Figura 5.8 – Formatos distintos entre o conjunto de pixels que delimitam o solo exposto e o conjunto de pixels que delimitam as cicatrizes de deslizamentos no caso de Petrópolis (RJ), indicados pelas setas amarelas..... 55

- Figura 5.9 – Reclassificação dos produtos CP3 e *Hue*, posterior isolamento e vetorização das classes em que as cicatrizes foram melhor evidenciadas. Os polígonos roxos foram extraídos a partir da reclassificação da CP3; os polígonos amarelos foram extraídos a partir da reclassificação da componente *Hue*; os polígonos pretos são as cicatrizes de referência da Carta..... 56
- Figura 5.10 – Ranqueamento de importância/relevância do empilhamento dos quinze atributos extraídos para o estudo de caso dos deslizamentos em Recife (PE), a partir da análise das amostras OOB..... 59
- Figura 5.11 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor WPM/CBERS-4A para o estudo de caso de deslizamentos em Recife (PE), a partir da análise das amostras OOB..... 59
- Figura 5.12 – Atributos mais importantes/relevantes na classificação RF utilizando os quatro e os quinze atributos, para o caso dos deslizamentos em Recife (PE). As setas laranjas indicam áreas de deslizamentos; as setas azuis indicam áreas de corpos hídricos; as setas brancas indicam áreas de solo exposto..... 61
- Figura 5.13 – Composição cor verdadeira (321) e a falsa cor (413) do sensor WPM/CBERS-4A em comparação à composição RGB (CP3, NDWI, CP4) sugerida a partir do ranqueamento OOB dos quinze atributos. Setas laranjas: áreas de deslizamentos mapeadas pela Carta; setas azuis: corpos hídricos; setas brancas: áreas de solo exposto..... 63
- Figura 5.14 – Áreas de deslizamentos e de solo exposto nas três composições avaliadas para o caso dos deslizamentos em Recife (PE). Setas laranjas: áreas de deslizamentos; setas brancas: áreas de solo exposto..... 64
- Figura 5.15 – Composição em cor verdadeira (321) e em falsa-cor (413) do sensor WPM/CBERS-4A em comparação à composição RGB (CP3, NDWI, CP4), onde o contraste existente entre um corpo hídrico de elevada turbidez e um deslizamento de terra foi melhor evidenciado. Setas laranjas: cicatriz de deslizamento; setas azuis: corpo hídrico; setas brancas: solo exposto; setas amarelas: meio urbano..... 66
- Figura 5.16 – Visualização de área sombreada a partir das composições em cor verdadeira (321), em falsa-cor (413) e a sugerida pelo ranqueamento OOB de quinze atributos (R=CP3, G=NDWI, B=CP4), obtidas a partir de dados do sensor WPM/CBERS-4A..... 67

Figura 5.17 – Ranqueamento de importância/relevância dos quinze atributos extraídos para o estudo de caso da inundação regional no Paquistão, a partir da análise das amostras OOB.....	68
Figura 5.18 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor WFI/CBERS-4 para o estudo de caso da inundação regional em Sind, Balochistan e Punjab (Paquistão), a partir da análise das amostras OOB.....	69
Figura 5.19 – Composição RGB (NIR, CP1, CP2) sugerida a partir do ranqueamento OOB dos quinze atributos para o caso da inundação regional no Paquistão. Setas azuis: áreas inundadas; setas amarelas: áreas não-inundadas; setas vermelhas: rio principal.....	71
Figura 5.20 – Áreas inundadas destacadas em tons de azul na composição RGB (NIR, CP1, CP2) sugerida, em comparação com a composição RGB (15,14,13) do WFI/CBERS-4A sobreposta à vetorização realizada pela Carta. Setas azuis: áreas inundadas; setas amarelas: áreas não-inundadas.....	73
Figura 5.21 – Ranqueamento de importância/relevância do empilhamento dos quinze atributos extraídos para o estudo de caso da inundação regional em Itamaraju e Prado (BA), a partir da análise das amostras OOB.....	75
Figura 5.22 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor WFI/AMAZONIA-1 para o estudo de caso da inundação regional em Itamaraju e Prado (BA), a partir da análise das amostras OOB.....	75
Figura 5.23 – Áreas inundadas destacadas em tons escuros na composição RGB (R= NIR, G=EVI, B=CP1) sugerida a partir do ranqueamento de 15 atributos, em comparação com as composições em cor verdadeira de pré e pós-evento do WFI/CBERS-4A e do WFI/AMAZONIA-1. Setas azuis: áreas inundadas pós-evento; setas amarelas: localização das mesmas áreas na imagem pré-evento. Setas verdes: áreas densamente vegetadas; setas vermelhas: áreas com pouca ou nenhuma vegetação.....	77
Figura 5.24 – Áreas inundadas destacadas em tons escuros na composição RGB (R= NIR, G=EVI, B=CP1) sugerida a partir do ranqueamento de 15 atributos. As nuvens passaram a adquirir os mesmos tons de magenta das áreas com pouca ou nenhuma vegetação. Setas azuis: áreas inundadas pós-evento; setas amarelas: localização das mesmas áreas na imagem pré- evento.....	79
Figura 5.25 – Comparação entre a composição RGB sugerida (R=NIR, G=EVI, B=CP1); e as fotografias aéreas (MANU DIAS/GOVBA). Em a1 e b1: exemplos	

de áreas inundadas registradas por fotografias aéreas. Em a2 e b2: localização das mesmas áreas das fotografias, com base na composição sugerida pelo empilhamento de quinze atributos. Setas brancas: áreas de referência, setas azuis: áreas inundadas; seta vermelha: presença de nuvens.....81

Figura A.1 – Áreas antigas de solo exposto em tons suaves em contraste às cicatrizes de deslizamentos na composição RGB (PC3, SAVI, HUE), em comparação à composição em cor verdadeira (765) do sensor MUX/CBERS-4A..... 102

Figura A.2 – Áreas de desmatamento recente identificadas com a mesma tonalidade dos deslizamentos na composição RGB (CP3, SAVI, HUE), em comparação à composição em cor verdadeira (765) do sensor MUX/CBERS-4A..... 103

Figura A.3 – Áreas de solo exposto nas três composições avaliadas no caso dos deslizamentos em Recife (PE), a partir de imagens do sensor WPM/CBERS-4A..... 104

Figura A.4 – Avaliação das áreas inundadas destacadas a partir da composição sugerida (R=NIR, G=CP1, B=CP2), baseando-se na vetorização realizada pela Carta utilizando imagens do VIIRS/NOAA e do MSI/SENTINEL-2. Devido ao tamanho do arquivo, apenas uma cena da inundaç o regional p de ser avaliada a partir da vetoriza o das imagens de 10 metros de resolu o espacial do MSI/SENTINEL-2..... 105

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 – Membros da Carta em 2020, fornecedores de imagens ópticas..	27
Tabela 2.2 – Principais características das câmeras do CBERS-4.....	29
Tabela 2.3 – Principais propriedades das câmeras do CBERS-4A.....	30
Tabela 2.4 – Principais propriedades da câmera do AMAZONIA-1.....	31
Tabela 4.1 – Datas referentes às ativações emergenciais da Carta após o início dos desastres avaliados, e as datas de aquisição das imagens utilizadas.....	38
Tabela 4.2 – Atributos de entrada para a classificação supervisionada RF.....	40
Tabela 5.1 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do sensor MUX/CBERS-4A para o caso dos deslizamentos em Petrópolis (RJ).....	47
Tabela 5.2 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes extraídas das bandas do sensor MUX/CBERS-4A.....	48
Tabela 5.3 – Comparação entre os polígonos gerados pelos produtos CP3 e Hue, em relação às 55 cicatrizes mapeadas manualmente pela Carta.....	57
Tabela 5.4 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do sensor WPM/CBERS-4A para o caso dos deslizamentos em Recife (PE).....	60
Tabela 5.5 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes extraídas das bandas do sensor WPM/CBERS-4A.....	62
Tabela 5.6 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do WFI/CBERS-4 para o caso da inundação regional em Sind, Balochistan e Punjab (Paquistão).....	70
Tabela 5.7 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes extraídas das bandas do sensor WFI/CBERS-4.....	70
Tabela 5.8 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes principais extraídas das bandas do sensor WFI/AMAZONIA-1..	76
Tabela 5.9 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do sensor WFI/AMAZONIA-1 para o caso da inundação regional em Itamaraju e Prado (BA).....	76

LISTA DE SIGLAS E ABREVIATURAS

ACP	Análise de Componentes Principais
AG	Acurácia Global
CBERS	<i>China-Brazil Earth Resources Satellite</i>
CEMADEN	Centro Nacional de Monitoramento e Alertas de Desastres Naturais
CEMS	<i>Copernicus Emergency Management Service</i>
CNES	Agência Espacial Francesa
COBRADE	Codificação Brasileira de Desastres
CP	Componente Principal
CSA	Agência Espacial Canadense
DOS	<i>Dark Object Subtraction</i>
ESA	Agência Espacial Européia
EVI	<i>Enhanced Vegetation Index</i> - Índice de Vegetação Aprimorado
F	F1-score
FN	Falso Negativo
FP	Falso Positivo
ICSMD	<i>International Carta Space and Major Disasters</i>
IHS	<i>Intensity, Hue, Saturation</i> - Intensidade, Matiz e Saturação
INPE	Instituto Nacional de Pesquisas Espaciais
IPT	Instituto de Pesquisas Tecnológicas
IRS	Imageador Multiespectral e Termal
MUX	Câmera Multiespectral
NC	Níveis de Cinza
NDVI	<i>Normalized Difference Vegetation Index</i> - Índice de Vegetação por Diferença Normalizada
NDWI	<i>Normalized Difference Water Index</i> - Índice de Água por Diferença Normalizada
NIR	Infravermelho próximo
OOB	<i>Out-of-Bag</i>
P	Erros de Precisão
PAN	Câmera Pancromática e Multiespectral
PDI	Processamento Digital de Imagens
S	Erros de Sensibilidade

RF	<i>Random Forest</i>
RGB	<i>Red, Green, Blue</i> – Vermelho, Verde, Azul
RL	Regressão Linear
ROI	<i>Region Of Interest</i> - Região de Interesse
RSGISLib	<i>Remote Sensing and Geographical Information Systems software Library</i>
SA	Sentinel Ásia
SAR	Radar de Abertura Sintética
SAVI	<i>Soil Adjusted Vegetation Index</i> - Índice de Vegetação Ajustado ao Solo
SIG	Sistemas de Informações Geográficas
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WFI	Câmera de Campo Largo
WPM	Câmera Multiespectral e Pancromática de Ampla Varredura

SUMÁRIO

1	INTRODUÇÃO.....	1
1.1	Objetivos	4
2	REFERENCIAL TEÓRICO	5
2.1	Desastres naturais	5
2.1.1	Inundações	7
2.1.2	Deslizamentos	9
2.2	Processamento digital de imagens no estudo de deslizamentos e inundações.....	10
2.2.1	Registro	10
2.2.2	Correção atmosférica	11
2.2.3	Realce	12
2.2.4	Índices espectrais	12
2.2.5	Análise de Componentes Principais (ACP)	15
2.2.6	Transformação RGB-IHS.....	18
2.2.7	Classificação supervisionada	21
2.3	Agências espaciais e serviços gratuitos de apoio à eventos extremos.....	25
2.3.1	<i>International Charter Space and Major Disasters</i>	25
2.4	Satélites brasileiros	29
2.4.1	CBERS-4	29
2.4.2	CBERS-4A.....	30
2.4.3	AMAZONIA-1	31
3	ESTUDOS DE CASO	32
3.1	Município de Petrópolis (RJ)	33
3.2	Município de Recife (PE).....	34
3.3	Províncias de Sind, Balochistan e Punjab (Paquistão)	35
3.4	Municípios de Itamaraju e Prado (BA).....	36
4	METODOLOGIA	37
4.1	Seleção das Imagens.....	38
4.2	RF e a seleção de atributos	39
4.3	Combinação dos produtos no espaço de cores RGB.....	42

5	RESULTADOS E DISCUSSÕES.....	45
5.1	Amostragem para o caso dos deslizamentos em Petrópolis (RJ)	45
5.1.1	Ranqueamento dos atributos a partir da classificação RF.....	45
5.1.2	Detecção de áreas de deslizamentos em Petrópolis (RJ)	50
5.1.3	Avaliação dos resultados com base nos dados de referência	55
5.2	Amostragem para o caso dos deslizamentos em Recife (PE)	58
5.2.1	Ranqueamento dos atributos a partir da classificação RF.....	58
5.2.2	Detecção das áreas de deslizamentos em Recife (PE).....	62
5.3	Inundação regional em Sind, Balochistan e Punjab (Paquistão).....	68
5.3.1	Ranqueamento dos atributos a partir da classificação RF.....	68
5.3.2	Detecção da inundação regional	71
5.4	Inundação regional em Itamaraju e Prado (Rio Jucuruçu-BA)	74
5.4.1	Ranqueamento dos atributos a partir da classificação RF.....	74
5.4.2	Detecção da inundação regional	77
6	CONCLUSÃO	82
	REFERÊNCIAS BIBLIOGRÁFICAS	85
	APÊNDICE A - OUTROS EXEMPLOS DE FIGURAS E TABELAS	102

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 (CASTRO, 1999; NOVELLINO et al., 2019). Segundo Gähler et al. (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 (CHMUTINA et al., 2019; SAUSEN et al., 2015; ZHOU et al., 2018).

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 (EM-DAT/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., 2017; STEFANOV et al., 2015; TAN et al., 2021).

Segundo Celik et al. (2010), as principais características dos grandes desastres incluem imprevisibilidade, disponibilidade de recursos limitados nas áreas atingidas e modificações no ambiente. Como aponta Sausen et al. (2015), se faz necessário a realização de tomadas de decisão, que normalmente seguem um ciclo de gestão contendo quatro etapas: i) mitigação (análise da vulnerabilidade da região); ii) preparação (planejamento de estratégias de ação pelos órgãos competentes); iii) respostas (esforços de emergência); e iv) recuperação (processo de reabilitação).

Assim, a comunidade científica e as entidades políticas se mostram cada vez mais interessadas em encontrar caminhos eficazes para a construção de sistemas de apoio à emergências, além da avaliação de projetos de prevenção

e resgate (HEIN et al., 2019; WANG et al., 2018; YU et al., 2018; ZHOU et al., 2018;). Dentre as técnicas em desenvolvimento relacionadas, o Sensoriamento Remoto (SR) se destaca, sendo hoje uma abordagem operacional comum no gerenciamento de desastres (MUNAWAR et al, 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 de satélites, 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 (DENIS et al., 2016; VOIGT et al., 2016).

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; JONES et al., 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). O AMAZONIA-1, satélite exclusivamente brasileiro (lançado em 2021), foi incluído no programa já no ano de 2022, estando disponível para os eventuais chamados da Carta. 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 nos quais os analistas enfrentam para o envio de respostas rápidas e eficientes, seja pela disponibilidade de dados (resolução temporal, organização e espaço computacional), 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, a presente pesquisa visa sugerir um fluxo de processamento aplicado às imagens do CBERS-4, CBERS-4A e AMAZONIA-1, com o propósito de agilizar o processo de resposta aos chamados da Carta, assim 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 aplicadas aos sensores brasileiros, de acordo com as suas características espectrais, com base no 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; LUCIAN, 2016). Logo, os três principais atributos de maior relevância na classificação serão combinados no espaço de cores RGB, com o objetivo de facilitar a identificação das 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 quatro casos de estudo, sendo eles: 1) Deslizamentos ocorridos no início de 2022 em Petrópolis (RJ); 2) Deslizamentos ocorridos em maio de 2022 em Recife (PE); Inundações regionais ocorridas em: 3) três grandes províncias do Paquistão em agosto de 2022; e 4)

nos municípios de Itamaraju e Prado (BA) em 2021. Para a validação dos resultados, os produtos gerados pela Carta em cada estudo de caso serão utilizados como referência, viabilizando a avaliação quantitativa e qualitativa das composições finais sugeridas.

1.1 Objetivos

O objetivo desta pesquisa é sistematizar os dados de SR obtidos pelos satélites brasileiros CBERS-4, CBERS-4A e AMAZONIA-1, através da aplicação de técnicas de PDI e mineração de dados, que darão auxílio à gestão de desastres causados por deslizamentos e inundações regionais. Os objetivos específicos estão detalhados abaixo:

- Identificar na literatura o conjunto de métodos e procedimentos mais utilizados em SR para a detecção e caracterização de deslizamentos e inundações regionais;
- Aplicar a classificação supervisionada RF para a seleção dos atributos mais relevantes na identificação de áreas de deslizamentos e inundações extraídos a partir de técnicas de PDI;
- Combinar os três principais atributos ranqueados pela classificação RF numa visualização falsa cor (espaço RGB de cores) para a geração de alertas visuais de áreas potencialmente atingidas;
- Avaliar os resultados de forma quantitativa e qualitativa através das métricas estatísticas obtidas pelo RF e das composições sugeridas em RGB, tendo como referência os dados da Carta.

2 REFERENCIAL TEÓRICO

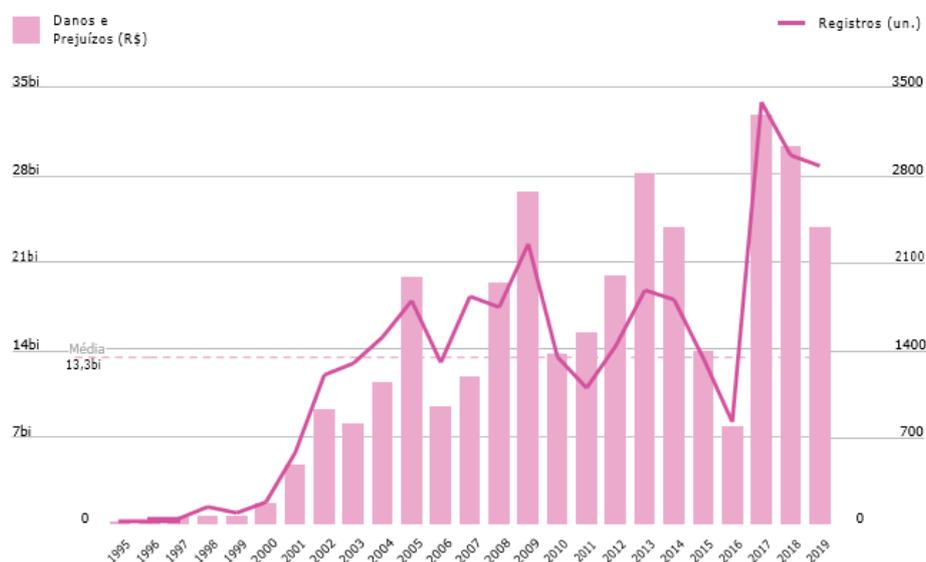
Este capítulo introduz os conceitos relevantes que serão considerados no desenvolvimento da pesquisa. As definições e as características dos desastres recorrentes no Brasil serão apresentadas e atreladas às aplicações do SR como ferramenta de análise. Posteriormente, as principais técnicas de PDI serão descritas e os aspectos da Carta e sua importância para uma rápida avaliação espacial de áreas atingidas por eventos extremos serão discutidos. Por fim, serão retratadas as principais características dos satélites brasileiros CBERS-4, CBERS-4A e AMAZONIA-1.

2.1 Desastres naturais

Nos últimos 60 anos, a quantidade de eventos extremos apresentou um comportamento crescente em todo o planeta, no qual o número de pessoas afetadas aumentou de 2,84 milhões em 1960 para 100,17 milhões em 2019 (CHEN et al., 2021). Somente no primeiro semestre de 2022, cerca de 72 bilhões de dólares foram perdidos em prejuízo às catástrofes induzidas pelo clima no planeta. No Brasil, o número de óbitos para esse mesmo período é aproximadamente 57% maior do que o registrado em todo o ano de 2021 (SWISS RE GROUP, 2022; CNM, 2022).

De acordo com o Relatório de Danos Materiais e Prejuízos Decorrentes de Desastres Naturais no Brasil: 1995-2019, o governo brasileiro reconheceu 64.429 registros de eventos entre 1995 e 2019. Por consequência, um elevado prejuízo financeiro na economia nacional foi avaliado, totalizando 333 bilhões de reais nos mesmos 25 anos de observação. A Figura 2.1 apresenta a distribuição de danos e prejuízos contabilizados anualmente no país, com destaque para o ano de 2017, com um montante de aproximadamente 28 bilhões de reais (BANCO MUNDIAL, 2020).

Figura 2.1 – Quantidade de desastres registrados (un.) e os danos materiais e prejuízos totais anuais no Brasil (R\$), no período entre 1995-2019.



Fonte: Banco Mundial (2020).

A Codificação Brasileira de Desastres (COBRADE), classifica os desastres naturais em cinco grupos, os quais são: geológico (terremoto, movimento de massa, erosão e emanção vulcânica); hidrológico (inundação, enxurrada e alagamento); meteorológico (tempestades e tempestades extremas); climatológico (seca); e biológico (epidemia e pragas). Os deslizamentos de terra (um dos tipos de movimento de massa) e as inundações, ambos descritos nos próximos tópicos, são caracterizados como desastres naturais de grande destaque no Brasil devido ao elevado número de óbitos provocados anualmente.

Logo, diante da necessidade de uma análise ampla da área afetada, da extensão e intensidade dos danos e da perspectiva sinótica, a aplicação do SR é classificada como uma ferramenta essencial para a gestão desses eventos, considerando o elevado grau de complexidade do cenário pós-evento. A rápida integração com outros dados georreferenciados e as muitas técnicas que revelam os alvos de interesse também podem ser cruciais para as respostas de emergência (GHAFFARIAN et al., 2018; MARTINIS et al., 2017; ROBINSON et al., 2019).

2.1.1 Inundações

As inundações, definidas como o transbordamento natural da água dos leitos de rios, lagos ou córregos, são provocadas por chuvas contínuas e intensas, além de serem intensificadas pelo desmatamento, práticas inadequadas de uso do solo, sedimentação de leitos e obstruções de canais (SAUSEN et al., 2015). Mesmo possuindo um elevado poder destrutivo no meio social, como afirma Domeneghetti et al. (2019), a compreensão e o desenvolvimento de modelagens da dinâmica das inundações ainda são tênues por consequência da indisponibilidade de medições e dados auxiliares.

Sendo o desastre natural mais comum dentre os registros mundiais, nos últimos vinte anos o número de grandes inundações no planeta passou de 1389 (1980-1999) para 3254 (2000-2019) (UNDRR, 2020). Muitos autores afirmam que o aumento da frequência de desastres naturais tem relação direta com as mudanças climáticas (AZADI et al. 2022; DIMITRIADIS et al., 2016; DENIS et al., 2016; HEIN et al., 2019; POURSANIDIS et al. 2017). São preocupantes os números atuais de inundações, ciclones tropicais e grandes tempestades, em um planeta severamente impactado pelo aquecimento global (UNDRR, 2020).

Em relação ao Brasil, segundo o Anuário da Sala de Situação do CEMADEN, somente no ano de 2017 ocorreram 457 eventos hidrológicos no país (Figura 2.2), considerando os casos de inundações, de enxurradas (caracterizadas como o transbordamento de água concentrado, de alta energia e de curta duração) e de alagamentos (caracterizados como a extrapolação do sistema de drenagem urbana). Ainda, mais de 8 milhões de pessoas no país se encontram em áreas de risco, considerando apenas 872 municípios monitorados (CEMADEN, 2020).

Figura 2.2 – Inundação na cidade de Raposos (MG). Anualmente os habitantes sofrem com a cheia do rio das Velhas, principalmente os moradores de áreas irregulares.



Fonte: CBH Rio das Velhas, ECOA (2022).

Sobre a aplicação do SR, comumente os dados de sensores ativos de microondas como Radar de Abertura Sintética (SAR) são utilizados para o mapeamento de inundações (MASON et al. 2021), devido a possibilidade de obtenção de dados sob condições climáticas adversas, apesar da necessidade de um maior tempo de processamento (HUANG et al., 2015; MA et al., 2016). Pela produção de dados em diversas resoluções temporais e pela maior facilidade de obtenção, dados de sensores ópticos também podem produzir resultados eficazes a partir da aplicação apropriada das técnicas de PDI (COLTIN et al., 2016; KHAN et al., 2022). Na presente pesquisa, o uso de imagens ópticas para a identificação de áreas inundadas será retratado, por estas serem obtidas pelos sensores presentes nos satélites brasileiros.

2.1.2 Deslizamentos

Segundo Zhao e Lu (2018), os deslizamentos de terra são caracterizados como movimentos de blocos, detritos ou terra em uma encosta, desencadeados por chuvas intensas e tremores. São importantes processos erosivos e deposicionais modeladores do relevo e, pelo modo de ocupação humana, suas condições estritamente naturais acabam incorporando as interferências antrópicas e os impactos negativos associados (BIGARELLA et al., 2003; SAUSEN et al., 2015).

Classificado como um tipo de evento natural, os deslizamentos passam a ser caracterizados como desastre quando vidas humanas são diretamente ameaçadas. Em relação aos dados mundiais, foram registradas 376 ocorrências desse tipo de desastre no período entre 2000 e 2019 (UNDRR, 2020). No Brasil, a existência de ocupações irregulares em áreas de risco (Figura 2.3) é um dos grandes gatilhos para a ocorrência de grandes deslizamentos, com registro de 3458 mortes no período entre 1998 e 2017 (IPT, 2018).

Figura 2.3 – Uma das áreas atingidas por deslizamentos generalizados desencadeados em Recife (PE), em junho de 2022, após chuvas intensas.



Fonte: Wellington Lima/JC Imagem (2022).

2.2 Processamento digital de imagens no estudo de deslizamentos e inundações

A interpretação de imagens dos sensores ópticos como auxílio à gestão de deslizamentos e inundações pode ser facilitada através de técnicas específicas de PDI (RAHMAN et al., 2017; SAUSEN et al., 2015). Tendo em vista a necessidade de otimização do tempo de resposta a eventos extremos, o conhecimento prévio de tais aplicações, intrínsecas para cada tipo de desastre e diretamente relacionadas com a qualidade de cada mapeamento, pode garantir o sucesso no destaque de informações (GUZZETTI et al, 2012). As técnicas mais consolidadas e aplicáveis às propriedades dos sensores brasileiros serão descritas posteriormente.

2.2.1 Registro

O registro ou georreferenciamento consiste no alinhamento geométrico entre duas imagens, com seus objetos espacialmente equivalentes, resultando em ambas projetadas no mesmo sistema de coordenadas. Esse processo de reposicionamento dos pixels pode ser realizado em imagens obtidas em datas e sensores diferentes, garantindo a eliminação de distorções causadas pelo processo da aquisição da imagem, tais como: o movimento de rotação e curvatura da terra, as diferenças do ângulo de visão e a imprecisão dos dados de posicionamento e velocidade da plataforma (CROSTA, 1999; FONSECA et al., 2009; MARQUES FILHO; NETO, 1999; SCHOWENGERDT, 2006).

Para a definição do modelo matemático de correção, é fundamental a seleção de pontos de controle, devidamente distribuídos por toda a imagem e com informações precisas de localização. Estes podem ser coletados manualmente, ou automaticamente, por meio da aplicação de janelas de máxima correlação cruzada, janelas de mínima diferença absoluta e ainda algoritmos computacionais de extração de feições (GONZALEZ; WOODS, 2009; ZANOTTA et al., 2019).

2.2.2 Correção atmosférica

Considerando as interferências causadas pela atmosfera na resposta espectral medida pelos sensores, uma melhor estimativa da reflectância de superfície pode ser calculada por métodos físicos fundamentados na modelagem de transferência radiativa, ou por métodos de aproximações genéricas mais simples. Já que a radiação sofre espalhamento e absorção ao longo da sua trajetória de entrada e saída da atmosfera, a correção permite o ajuste dessas influências nos valores registrados pelos pixels (LATORRE, 2002; ZHANG et al., 2010).

O método de subtração do pixel escuro (*Dark Object Subtraction* - DOS) é uma alternativa empírica da correção atmosférica, não sendo necessário o acesso aos parâmetros mais complexos dos modelos de transferência radiativa. Assumindo que os pixels relacionados às áreas onde os níveis de cinza teoricamente deveriam ser iguais a zero, como corpos d'água límpidos e regiões sombreadas, sem a correção, os valores registrados pelos sensores assumem uma quantidade de radiação constante para essas mesmas áreas, então atribuída aos efeitos atmosféricos (CHAVEZ JR, 1988; BERNARDO et al., 2017).

O preceito consiste na subtração desse valor identificado no pixel escuro de todos os outros pixels, o que resulta na remoção de um efeito de névoa presente na imagem. A operação é dada por $f(x)$ como sendo a imagem original, ND_{min} o menor número digital identificado no histograma da imagem, e $g(x)$ a nova imagem corrigida (Equação 2.1):

$$g(x) = f(x) - ND_{min} \quad (2.1)$$

Apesar de sua facilidade, o método é limitado quando não é possível identificar um pixel escuro e ao considerar apenas a correção da radiância espalhada pela atmosfera. Essas condições acabam ignorando os outros desvios que a radiação pode sofrer (GILMORE et al., 2015; GAIDA et al., 2020).

2.2.3 Realce

Os métodos de realce radiométrico modificam diretamente os valores dos níveis de cinza (NC's) dos pixels da imagem, com o objetivo de facilitar a distinção de feições. Através da manipulação do histograma (distribuição de frequência dos NC's), o valor de cada pixel pode ser alterado a partir da aplicação de equações de ajuste.

Dentre algumas operações, o contraste linear é comumente utilizado, definido pelo reposicionamento dos NC's com base na expansão dos valores de mínimo e máximo, o que resulta em uma melhor distribuição dos valores dos NC's ao longo de sua escala. A operação de realce é dada pelo aumento do ganho (g) da imagem original (I), somado ao *offset* (o) aplicado a cada valor do pixel da matriz (Equação 2.2).

$$I_{nova} = gI + o \quad (2.2)$$

Onde I_{nova} é a nova imagem gerada, com valores diferentes de brilho e contraste (RICHARDS, 2012; MATHER; KOCH, 2011).

2.2.4 Índices espectrais

Segundo Yan et al. (2010), mais de 40 índices espectrais já foram desenvolvidos para a caracterização da água e da vegetação. Em destaque, o NDVI (do inglês *Normalized Difference Vegetation Index* - Índice de Vegetação por Diferença Normalizada), o SAVI (do inglês *Soil Adjusted Vegetation Index* - Índice de Vegetação Ajustado ao Solo) e o EVI (do inglês *Enhanced Vegetation Index* - Índice de Vegetação Aprimorado), são índices de vegetação amplamente utilizados para monitorar a distribuição espacial e quantificar as condições da vegetação.

O NDVI, proposto por Rouse et al (1973), é caracterizado pela razão entre a diferença e soma da banda do infravermelho próximo (NIR) e do vermelho (RED), como descreve a Equação 2.3:

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (2.3)$$

O índice SAVI, derivado do NDVI e proposto por Huete (1988), apresenta a incorporação de um fator de ajuste (L) para a minimização das influências do solo na resposta espectral da vegetação. A Equação 2.4 descreve a formulação matemática para a obtenção do índice.

$$SAVI = \frac{(NIR-RED)}{(NIR+RED+L)} \cdot (1 + L) \quad (2.4)$$

Onde os valores de L variam de 0 a 1, de acordo com a biomassa da área analisada (PONZONI; SHIMABUKURO, 2009).

O índice EVI, proposto por Huete (1997), além de ter como objetivo minimizar as influências do solo, também considera a redução da influência dos efeitos atmosféricos na resposta espectral da vegetação (Equação 2.5):

$$EVI = 2.5 \frac{(NIR-RED)}{(NIR+ C_1*RED- C_2 *BLUE + L)} \cdot (1 + L) \quad (2.5)$$

Onde os fatores e seus valores empíricos são: $C_1 = 6$, $C_2 = 7.5$ e $L = 0.5$.

Ambos os índices supracitados são considerados relevantes para a avaliação de desastres naturais (BHANDARI et al., 2012; SALLEH et al, 2019). Em relação aos deslizamentos de terra, destaca-se que os índices de vegetação comumente os confundem com áreas de solo exposto, o que pode ser um erro diretamente associado à data de aquisição das imagens. Quanto mais distante da data de ocorrência do evento, menor a quantidade de umidade no solo e menor ainda o contraste entre os deslizamentos e os demais alvos (SALLEH et al, 2018).

Ainda, muitos trabalhos utilizam os índices espectrais para a detecção das cicatrizes com base na avaliação da remoção da vegetação durante as ocorrências. No trabalho de Yang, Wang e Shi (2013), a partir de uma série temporal de oito dias de imagens do MODIS/TERRA de baixa resolução espacial, os deslizamentos puderam ser identificados com base nas variações anormais e repentinas do NDVI. Já Behling et al. (2014) utilizaram imagens do RapidEye para a detecção de deslizamentos, também fundamentada nas mudanças da trajetória temporal de NDVI. Essas variações serviram de base para a segmentação de objetos candidatos a escorregamentos, considerando as taxas de regeneração da vegetação pós-evento e parâmetros topográficos. Outras diversas aplicações dos índices espectrais e detecção de deslizamentos são aprofundadas em Li et al. (2017), Ma et al. (2016), Roessner et al. (2014), Lissak et al. (2020) e Huang et al. (2019).

Para ressaltar os corpos hídricos em detrimento a outros alvos presentes nas imagens, os índices espectrais da água são aplicados para a análise da variação da radiação do infravermelho, por ser a sua faixa de maior absorção. Logo, a manipulação desta banda facilita o destaque dos corpos hídricos ao adquirirem tons escuros nas imagens (NOVO, 2010). Dentre os índices mais utilizados, o NDWI (do inglês *Normalized Difference Water Index* - Índice de Água por Diferença Normalizada) é popularmente conhecido. Calculado a partir das respostas espectrais do NIR e do verde (GREEN) (Equação 2.6), o NDWI auxilia na delimitação dos corpos hídricos e monitoramento das áreas inundáveis (MCFEETERS, 1996; RICHARDS, 1999).

$$NDWI = \frac{(GREEN - NIR)}{(GREEN + NIR)} \quad (2.6)$$

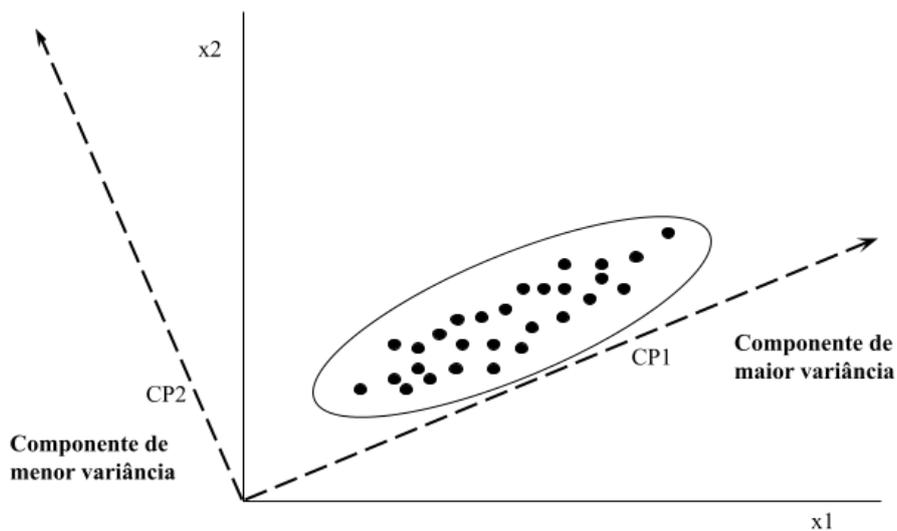
Como abordagem de mapeamento emergencial, Huang, Wang e Li (2018) integraram informações geográficas voluntárias, tais como *tweets* relacionados à inundações, com os dados de NDWI extraídos do EO-1 *Advanced Land Imager* (ALI). Baseando-se em cada *tweet*, um algoritmo de densidade de probabilidade de inundações foi desenvolvido, no qual atribui os níveis de confiança a partir

das distribuições de NDWI na imagem pós-evento. Várias possibilidades de manipulação dos índices para a avaliação da extensão das áreas inundadas e suas dinâmicas são aprofundadas em Notti et al. (2018), Munasingue et al. (2018), Brubacher (2016), Amarnath (2014), Ji, Zhang e Wylie (2009) e Rahman e Di (2017).

2.2.5 Análise de Componentes Principais (ACP)

Com o objetivo de reduzir a dimensionalidade dos dados, a ACP (PEARSON, 1901) resalta a redundância existente, por meio de uma transformação matemática ortogonal em um conjunto de dados correlacionados, em novos componentes não correlacionados (Figura 2.6). A primeira componente é posicionada na direção de máxima variabilidade possível dos dados (maior variância), gerando um novo produto com informações comuns entre as bandas e, a partir da segunda componente, gerando informações não correlacionadas (CROSTA, 1999; MARQUES FILHO; NETO, 1999).

Figura 2.4 – Representação dos valores em novos eixos descorrelacionados.



Fonte: Richards (2013).

Para a obtenção das ACPs, 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 caracterizados pela direção ortogonal (baseado no sistema de coordenadas) de maior variância dos dados de cada banda, e os autovalores relacionados às variâncias medidas em cada uma das direções das componentes produzidas (HOTELLING, 1933; MENESES et al., 2012; CHUVIECO; HUETE, 2002). Então, as variâncias obtidas e as covariâncias entre todos os pares de variáveis, compõem a matriz de variância-covariância (C_x) (RICHARDS, 1999), que pode ser estimada a partir da Equação 2.7:

$$C_x = \frac{1}{n-1} \sum_{i=1}^n (X_i - M)(X_i - M)^T \quad (2.7)$$

onde n é o número de pixels, X é a variável N -dimensional e M é o vetor médio. Cada componente principal (Y) é expressa por:

$$Y_i = a_1 X_1 + a_2 X_2 + \dots + a_N X_N \quad (2.8)$$

$$= a^T X \quad (2.9)$$

onde a^T é a transposição dos autovetores da matriz de variância-covariância C_x de X . Logo, a matriz de covariância C_y de Y é:

$$C_y = A C_x A^T \quad (2.10)$$

cujo os elementos diagonais são os autovalores λ de C_x , onde $\lambda_1 > \dots > \lambda_N$:

$$C_y = \begin{bmatrix} \lambda_1 & & & 0 \\ & \lambda_2 & & \\ & & \ddots & \\ 0 & & & \lambda_N \end{bmatrix} \quad (2.11)$$

De acordo com Weng (2012), a ACP pode melhorar a interpretação visual ao serem destacadas as informações espectrais menos frequentes (quando utilizadas as últimas componentes), sendo então extraídas para o uso posterior em processos de classificação digital. Também como alternativa de detecção de mudanças na cobertura do solo, a ACP é frequentemente utilizada em conjuntos de bandas espectrais de antes e depois do fenômeno analisado, de modo a serem identificadas as mudanças nas informações e conseqüentemente, das áreas alteradas (GERENTE et al., 2017; DENG et al., 2008).

Mondini et al (2011), aplicaram a técnica de Detecção de Múltiplas Mudanças (MCD), com base em imagens do FORMOSAT-2, caracterizada pela avaliação de diferenças entre pré e pós-evento do NDVI, do ângulo espectral, das ACP's e da Análise de Componentes Independentes (ACI). Os autores utilizaram os produtos derivados da MCD, ACP's e ACI como entrada para a classificação não-supervisionada, e alcançaram bons resultados para a distinção entre deslizamentos novos, antigos e heterogêneos. Já Ramos-Berna et al. (2018), aplicaram técnicas como a Regressão Linear (RL) e a Transformação Qui-Quadrado nas ACPs extraídas de imagens ASTER e aos dados do NDVI pré e pós-evento, para a identificação de deslizamentos. Também com a utilização de dados complementares de declividade, máscaras de nuvens, de pixels isolados e do estabelecimento de limiares, o produto RL/NDVI foi a melhor imagem diferença obtida.

Pensando apenas na manipulação de dados espaciais referentes à fase pós-desastre, a ACP nesta pesquisa será aplicada apenas ao conjunto de dados disponíveis logo após o registro das ocorrências. A perspectiva tradicional de comparação entre as componentes de pré e pós-evento não será abordada em decorrência ao objetivo de extração máxima de informações utilizando apenas imagens pós-desastre (como tentativa de otimização do processo).

2.2.6 Transformação RGB-IHS

Como sendo um outro método de representação de cores, a transformação RGB-IHS é definida pela conversão do espaço tradicional RGB (*Red, Green, Blue*) para um novo espaço IHS (do inglês *Intensity, Hue, Saturation* - Intensidade, Matiz e Saturação), o qual separa o atributo *intensity* das informações relacionadas à percepção das cores (*Hue* e *Saturation*) em uma imagem colorida. Essa abordagem facilita a descrição das cores para a interpretação humana, possibilitando a manipulação individual das três componentes, pois não estão diretamente relacionadas como no espaço RGB (LEONARDI et al., 2009; MATHER, 2011).

Com isso, após a normalização das cores (RICHARDS, 2012):

$$r = \frac{R}{R+G+B} \quad (2.12)$$

$$g = \frac{G}{R+G+B} \quad (2.13)$$

$$b = \frac{B}{R+G+B} \quad (2.14)$$

para a componente *I*, calcula-se:

$$I = \frac{(R+G+B)}{3} \quad (2.15)$$

para a componente *H*, quando $b < g$:

$$H = \cos^{-1} \frac{(r-g)+(r-b)}{2\sqrt{(r-g)^2+(r-b)(g-b)}} \quad (2.16)$$

quando $b > g$:

$$H = 360^\circ - H \quad (2.17)$$

para a componente S :

$$S = 1 - 3\min(r, g, b) \quad (2.18)$$

O processo inverso (IHS-RGB) também pode ser calculado (RICHARDS, 2013).

Para $0 \leq H < 120^\circ$:

$$r = \frac{1}{3} \left[1 + \frac{S \cos H}{\cos(60-H)} \right] \quad (2.19)$$

$$b = \frac{1-S}{3} \quad (2.20)$$

$$g = 1 - b - r \quad (2.21)$$

Para $120^\circ \leq H < 240^\circ$:

$$g = \frac{1}{3} \left[1 + \frac{S \cos(H-120)}{\cos(180-H)} \right] \quad (2.22)$$

$$r = \frac{1-S}{3} \quad (2.23)$$

$$b = 1 - r - g \quad (2.24)$$

Para $240^\circ \leq H < 360^\circ$:

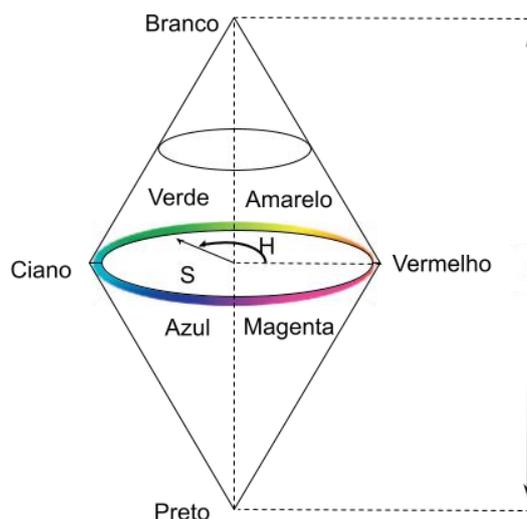
$$b = \frac{1}{3} \left[1 + \frac{S \cos(H-240)}{\cos(300-H)} \right] \quad (2.25)$$

$$g = \frac{1-S}{3} \quad (2.26)$$

$$r = 1 - g - b \quad (2.27)$$

O atributo *Hue*, definido como um ângulo entre 0° e 360° acerca da relação geométrica entre os sistemas RGB-HSI (Figura 2.5), oferece a percepção visual da composição espectral da cor (LEDLEY, BUAS e GOLAB, 1990). Dessa forma, os valores de *Hue* são distintos para cada tipo de cobertura do solo, diferentemente de *Saturation* e *Intensity*, em que a variação dos valores pode estar relacionada à mesma cobertura mas com diferentes concentrações de constituintes (PEKEL et al., 2014). Como uma alternativa mais simples e de menor esforço computacional, é possível destacar alvos a partir da manipulação da componente *Hue*, como mostram Lodhi (2011) e Namikawa, Korting e Castejon (2016).

Figura 2.5 – Representação do modelo de cores IHS em um plano circular.



Fonte: Adaptado de Gonzalez e Woods (2009).

A utilização da transformação RGB-IHS é uma boa abordagem para o desenvolvimento de algoritmos de processamento de imagens, em vista à praticidade de interpretação humana. Ainda, é amplamente utilizada para a melhora da resolução espacial de imagens pelo processo de fusão. Este processo pode ser realizado a partir da substituição da componente *Intensity* pela banda pancromática no processo de retorno ao domínio RGB, resultando em uma imagem colorida de alta resolução espacial (SCHETSELAAR, 1998; MATHER, 2011; GONZALEZ; WOODS, 2009).

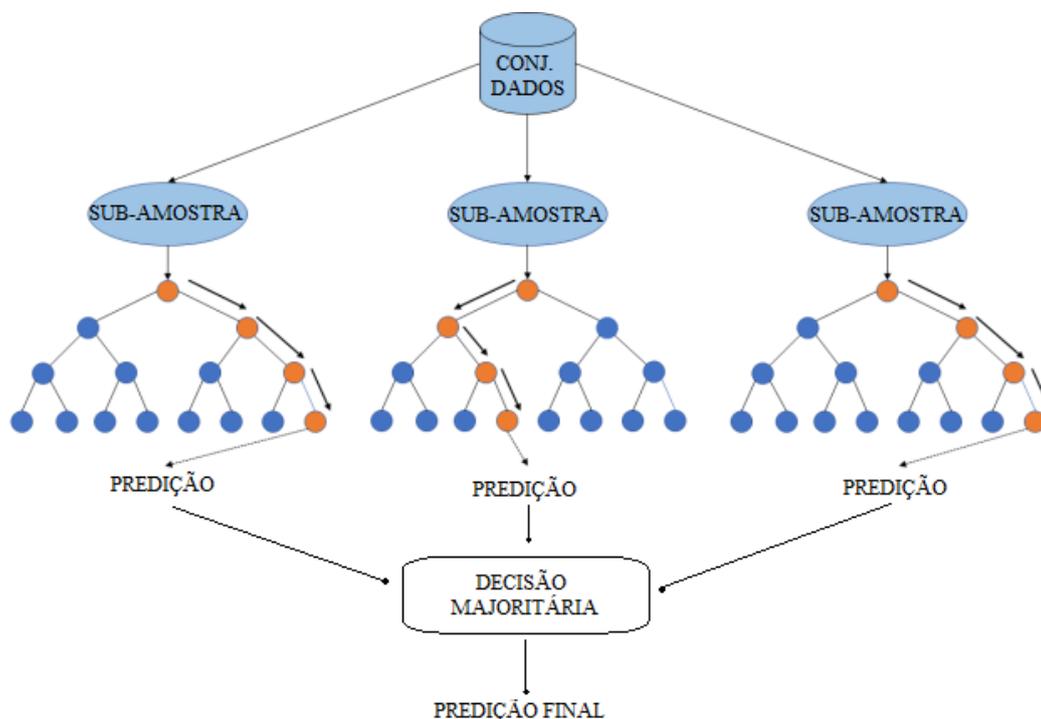
2.2.7 Classificação supervisionada

Como análise quantitativa, a classificação supervisionada consiste na rotulação de pixels de uma imagem, baseando-se na representação das classes específicas de cobertura do solo. Considerando as características distintas da resposta espectral dos alvos, a partir de dados de treinamento coletados pelo analista, o algoritmo escolhido realiza o agrupamento dos pixels segundo os seus valores digitais (RICHARDS, 2005; MENESES; ALMEIDA, 2012). Os algoritmos são subdivididos em paramétricos (envolvem parâmetros da distribuição dos dados como o vetor de médias e a matriz de covariância, definidos para o classificador MAXVER gaussiano), e não paramétricos (os modelos de distribuição não são levados em consideração, tais como o *Support Vector Machine* - SVM e o RF).

2.2.7.1 Classificador *Random Forest* (RF)

O RF é um algoritmo de aprendizagem supervisionada comumente utilizado em SR (SOUZA MENDES et al., 2019), que produz diversas árvores de decisão (floresta), a partir da seleção aleatória da amostragem de dados. Cada árvore de decisão (Figura 2.6) 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 pequena. Logo, para definir a classe de uma amostra, o algoritmo obtém as predições para cada árvore e seleciona a melhor opção por votação, sendo a classe mais comum escolhida como resultado final (BREIMAN, 2001; GUO et al., 2021).

Figura 2.6 – Representação esquemática do RF. Cada árvore apresenta o seu resultado com base nas combinações aleatórias realizadas pelo algoritmo e o resultado final será a classe votada majoritariamente.



Fonte: Padovese (2019).

A princípio, para a aplicação do modelo, a divisão do conjunto amostral em 70% para treinamento e 30% para teste é comumente utilizada. A primeira divisão é destinada à obtenção das árvores que irão compor a floresta aleatória e a segunda objetiva realizar a avaliação independente dos resultados.

Muitos trabalhos apontam a eficiência do RF para análises diversas do uso e ocupação do solo. É comum o desenvolvimento de modelos preditivos para a identificação de áreas suscetíveis a deslizamentos e inundações, principalmente que integrem as variáveis geomorfológicas da área (CHENG et al., 2021; ZHANG et al., 2017). Ainda, devido à baixa correlação entre as árvores de decisão produzidas pelo algoritmo, sua sensibilidade ao *Overfitting* é reduzida em comparação aos outros modelos, o que pode favorecer a obtenção de melhores valores de acurácia na classificação dos alvos de interesse (BELGIU; LUCIAN, 2016).

2.2.7.2 Out-Of-Bag (OOB) e ranqueamento dos atributos

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 como *Out-of-bag* (OOB, “fora do saco”), poderá ser 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).

Logo, 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. Essa propriedade métrica é muito utilizada em aplicações de SR devido à possibilidade de selecionar os recursos mais relevantes para a classificação de imagens (BREIMAN, 2001; LIAW e WIENER, 2002; GISLASON, BENEDIKTSSON e SVEINSSON, 2006).

2.2.7.3 Validação

Algumas medidas de acurácia podem ser utilizadas para a análise do desempenho das classificações. 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. Essa característica pode levar a uma estimativa mais realista da capacidade preditiva do modelo em dados não analisados anteriormente.

A AG é definida pela razão entre a soma do número de pixels corretamente classificados pelo número total de pixels das amostras de teste (Equação 2.28), sendo uma das métricas que podem ser extraídas da matriz de confusão (CONGALTON, 2001):

$$AG = \frac{VP+VN}{VP+VN+FN+FP} \quad (2.28)$$

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 (Equação 2.29):

$$P = \frac{VP}{VP+FP} \quad (2.29)$$

A métrica S é definida pela probabilidade de um pixel de uma classe estabelecida ser classificado corretamente (Equação 2.30):

$$S = \frac{VP}{VP+FN} \quad (2.30)$$

A média harmônica entre os erros configuram o F1-score (Equação 2.31):

$$F1 - score = 2 \times \frac{P \times S}{P+S} \quad (2.31)$$

2.3 Agências espaciais e serviços gratuitos de apoio à eventos extremos

Observando o cenário preocupante pós-desastre e ainda as evidências de aumento no número de eventos nos últimos tempos, algumas agências espaciais e parcerias criaram serviços gratuitos de apoio à eventos extremos. Iniciativas como a Carta, a multiagência SERVIR, Sentinel Ásia (SA) e o *Copernicus Emergency Management Service* (CEMS), são exemplos de importantes mecanismos de fornecimento de informações espaciais, acionados frequentemente, como auxílio na gestão de desastres (DENIS et al., 2016; GANLER, 2016; ZHAO; LU, 2018).

De acordo com Voig et al. (2016), pelas contribuições de alcance global, a Carta é a organização de apoio a desastres mais ativa do mundo. Pela sua grande notoriedade, pela presença de importantes contribuições brasileiras e seus desafios, suas características serão posteriormente aprofundadas.

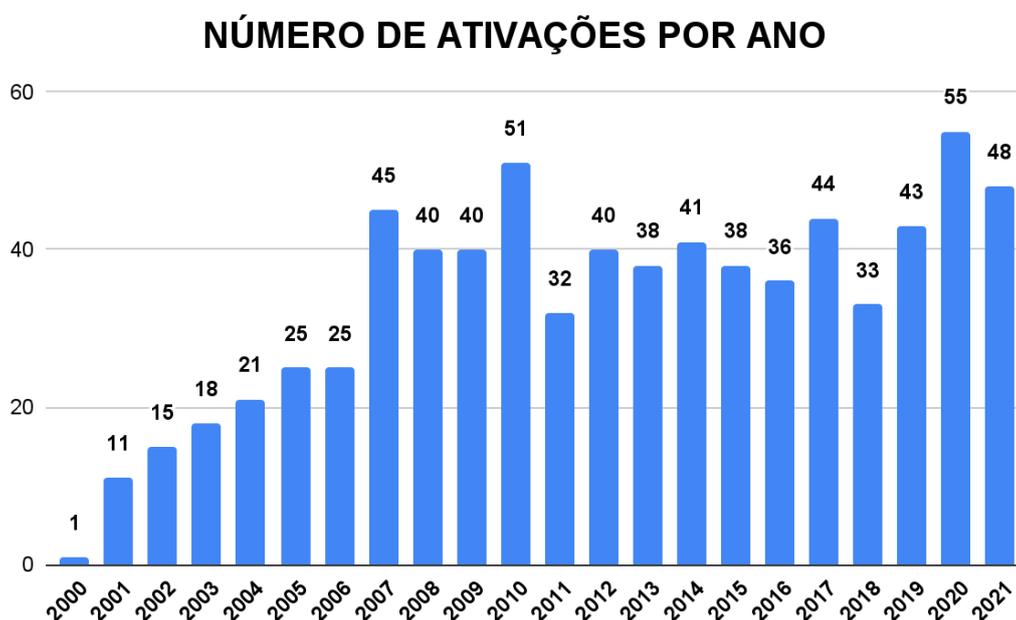
2.3.1 *International Charter Space and Major Disasters*

A Carta surgiu após a conferência UNISPACE II, em 2000, por iniciativa da Agência Espacial Européia (ESA), Agência Espacial Francesa (CNES) e a Agência Espacial Canadense (CSA), como auxílio na gestão de eventos extremos (DENIS et al., 2016; STEFANOV; EVANS, 2015). Sendo uma das organizações mais representativas na condução de crises, a Carta integra dados de várias agências espaciais em prol da obtenção de melhores resultados na fase de resposta pós-desastre, o que exige a obtenção e manipulação de dados imediatos (VOIGT et al., 2016).

No momento atual, 17 membros contribuem voluntariamente no fornecimento de imagens, incluindo agências e operadores de sistemas espaciais, além de outras organizações parceiras que fornecem dados para locais específicos ou produzem mapas para avaliação do evento (ICSMD, 2022; MARTINIS et al., 2017; SANTOS, 2018). Para a gestão da organização geral da Carta, há um revezamento entre os membros para a função de agência principal, que será responsável pela supervisão e coordenação da administração, comunicação e relações externas, por um período de seis meses (ICSMD, 2022). Então, quando

um país membro solicita auxílio à produção de mapas emergenciais quando exposto a algum tipo de evento extremo, a agência principal avalia o “chamado” e, caso a Carta seja “ativada”, as agências-membro fornecem dados de satélite gratuitos das áreas atingidas. Com isso, existe um trabalho integrado e contínuo para a resposta dos chamados anuais (Figura 2.7), com o objetivo de otimizar os processos e oferecer resultados eficientes.

Figura 2.7 - Número de ativações anuais da Carta, desde a sua criação até o ano de 2021.



Fonte: ICSMD (2022).

Dependendo das características do desastre ocorrido, os dados fornecidos pela Carta são direcionados da melhor maneira possível, levando em consideração a escolha e a disponibilidade de sensores ópticos ou de radar, além das resoluções temporal e espacial apropriadas (JOYCE et al., 2009). Normalmente, a avaliação do evento é realizada por meio de comparações entre imagens pós-evento e imagens de referência, que são essenciais em casos de eventos extremos (MAHAMOOD, 2012). Os colaboradores do ano de 2020 e os seus sensores ópticos estão indicados na Tabela 2.1.

Tabela 2.1 – Membros da Carta em 2020, fornecedores de imagens ópticas.

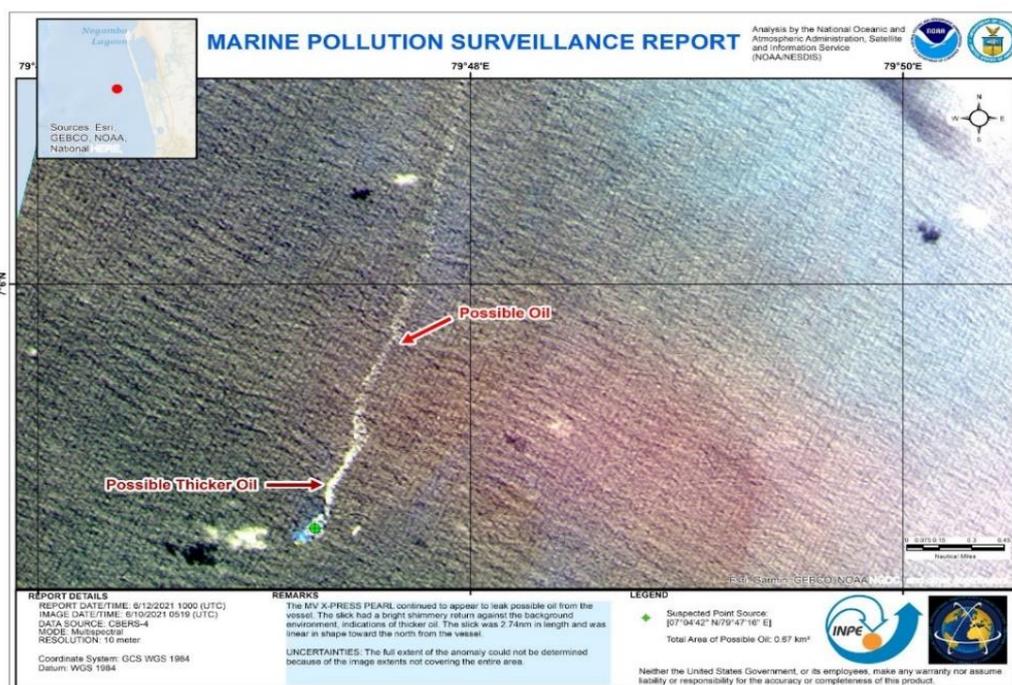
IMAGENS ÓPTICAS	AGÊNCIA	SATÉLITE OPERACIONAL
Resolução Espacial Alta ou Muito Alta	ABAE	VRSS-1; VRSS-2
	CNES	PLEIADES 1A/1B; SPOT-6; SPOT-7
	CNSA	GF-1/2/4; FY-2H; FY-4A; KOMPSAT-5; FY-3D/3C
	ESA	SENTINEL-2A/1B
	ISRO	RESOURCESAT-2; RESOURCESAT-2A; CARTOSAT-2E
	KARI	KOMPSAT-3; KOMPSAT-3A
	PLANET	PLANETSCOPE
	ROSCOSMOS	KANOPUS-V; RESURS-P; KANOPUS-V-IK
	UAESA	DUBAISAT-2; KHALIFASAT
	UKSA	ALSAT-1B; VISION-1
	USGS	WORLDVIEW-1/2/3; GEOEYE-1; LANDSAT 7/8
	INPE	CBERS-4A
Resolução Espacial Média ou Baixa	EUMETSAT	METOP SERIES; METEOSAT MSG
	NOAA	POES GF-3 SUOMI NPP
	ROSCOSMOS	METEOR-M
	INPE	CBERS-4; AMAZONIA-1

Fonte: *International Charter "Space & Major Disasters"* (2020).

Ressalta-se que os sensores ópticos, pela variedade de satélites e conseqüentemente a produção de dados em diversas resoluções espectrais e temporais, são amplamente usados para a identificação dos perigos, delimitação das áreas afetadas e classificação de imagens. A principal problemática envolvida é a limitação de uso quando possuem uma alta cobertura de nuvens (MELACK et al., 1994; JENSEN, 1986; RASHID; PRAMANIK, 1993; RAHMAN et al., 2016).

Em relação ao Brasil, no ano de 2021, as imagens ópticas dos satélites brasileiros foram disponibilizadas 23 vezes, incluindo eventos de inundação, deslizamentos, incêndios florestais e ciclones, em vários países do mundo. Como exemplo de aplicação, em outubro de 2021, o CBERS-4 forneceu imagens pós-desastre das manchas de óleo em Sri-Lanka, localizada no sul da Índia (Figura 2.8), sendo uma das possibilidades de análise emergencial disponíveis.

Figura 2.8 - Mancha de óleo em Sri-Lanka (Índia), detectada pelo CBERS-4.



Fonte: *International Charter Space and Major Disasters* (2021).

Dentre os desafios do Brasil para o envio de dados espaciais de emergência à Carta, levando em consideração a certeza de que as informações serão realmente úteis e intuitivas, a presença de nuvens, a resolução temporal dos sensores, a aplicação de um conjunto de técnicas de PDI, além de uma equipe bem coordenada são questões relevantes para a minimização do tempo total da realização das operações (MARTINIS et al., 2017; ROBINSON et al., 2019). Diante do seu papel nas solicitações de dados de emergência quando as ocorrências estão presentes nas áreas de cobertura dos seus sensores, os satélites nacionais serão caracterizados nos próximos tópicos.

2.4 Satélites brasileiros

2.4.1 CBERS-4

O Programa CBERS surgiu em 1988 em uma parceria entre Brasil e China, em prol da criação de satélites avançados com o desenvolvimento de um sistema eficiente de SR à nível internacional. Em busca da independência e monitoramento espacial dos seus recursos naturais, crescimento urbano e uso do solo, os dois países se uniram em uma sociedade de responsabilidades divididas (FONSECA et al., 2014; INPE, 2018).

Sobre a série CBERS desenvolvida, os CBERS 1 e 2 foram os satélites pioneiros, seguido pelo CBERS-2B e, após alguns anos, CBERS 3 e 4, dando continuidade ao programa após o final da vida útil dos três primeiros satélites. Os satélites CBERS 3 e 4 se diferenciavam pela implementação de quatro câmeras, além de melhoras em relação à resolução radiométrica e desempenho geométrico, trazendo um progresso na qualidade dos dados (EPIPHANIO, 2011). Atualmente, o CBERS-4 ainda está em operação, com suas principais características descritas na Tabela 2.2.

Tabela 2.2 – Principais características das câmeras do CBERS-4.

Características (CBERS-4)	MUX	PAN	IRS	WFI
Bandas Espectrais	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)	0,51-0,85 μ m (Pan) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)	0,50-0,90 μ m (Pan) 1,55-1,75 μ m (SWIR) 2,08-2,35 μ m (SWIR) 10,40-12,50 μ m (TH)	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)
Resolução	20 m	5 m / 10 m	40 m / 80 m (TIR)	64 m
Largura da Faixa Imageada	120 km	60 km	120 km	866 km
Revisita	26 dias	52 dias	26 dias	5 dias
Quantização	8 bits	8 bits	8 bits	10 bits
Visada Lateral do Espelho	-	$\pm 32^\circ$	-	-

Fonte: INPE (2019).

2.4.2 CBERS-4A

Lançado em 2019, o CBERS-4A é o sexto satélite do programa e com vida útil de, no mínimo, cinco anos. Possuindo os mesmos objetivos de toda a série, o CBERS-4A possui câmeras com resoluções espaciais melhoradas e ainda, a inclusão da Câmera Multiespectral e Pancromática de Ampla Varredura (WPM) em substituição da Câmera Pancromática e Multiespectral (PAN) e do Imageador Multiespectral e Termal (IRS) do CBERS-4. No mais, a Câmera Multiespectral (MUX) e a Câmera de Campo Largo (WFI) continuaram presentes, porém com suas propriedades aprimoradas (Tabela 2.3) (INPE, 2019; VRABEL et al., 2021).

Tabela 2.3 – Principais propriedades das câmeras do CBERS-4A.

Características (CBERS-4A)	WPM	MUX	WFI
Bandas Espectrais	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR) 0,45-0,90 μ m (PAN)	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)
Resolução	2 m 8 m	16,5 m	55 m
Largura da Faixa Imageada	92 km	95 km	684 km
Revisita	31 dias	31 dias	5 dias
Quantização	10 bits	8 bits	10 bits
Visada Lateral do Espelho	$\pm 16^\circ$	$\pm 16^\circ$	$\pm 16^\circ$

Fonte: INPE (2019).

2.4.3 AMAZONIA-1

Sendo o primeiro satélite exclusivamente brasileiro, o AMAZONIA-1 foi lançado em 2021 na Índia, após um período de mais de 40 anos de pesquisa e fortalecimento do setor espacial nacional. Com o propósito principal de monitorar o desmatamento na Amazônia, em complemento ao programa CBERS, o AMAZONIA-1 possui uma resolução espacial de 65 metros e um menor tempo de revisita em relação aos outros satélites com contribuições brasileiras. Logo, a resolução temporal é de suma importância para os objetivos da missão, tendo em vista a disponibilidade de imagens da mesma região a cada cinco dias (MOUTINHO, 2021; SILVA et al 2022).

Em relação à sua câmera, o AMAZONIA-1 é equipado com a WFI e foi pioneiro na utilização da Plataforma Multimissão (PMM) do INPE. Esta agrupa todos os equipamentos necessários para a operação do satélite, responsável pelo suporte à carga útil, formada por um sistema de geração de energia, gerenciamento de dados e de telecomunicação.

Outro diferencial do AMAZONIA-1 é a faixa de largura de imageamento da câmera WFI, capaz de cobrir 850 km (Tabela 2.4). Ademais, como no caso de todos os sensores do CBERS-4A e o sensor PAN do CBERS-4, pelo satélite ser estabilizado em três eixos, a câmera pode ser direcionada para qualquer ponto desejado da superfície da terra em casos especiais (INPE, 2022).

Tabela 2.4 – Principais propriedades da câmera do AMAZONIA-1.

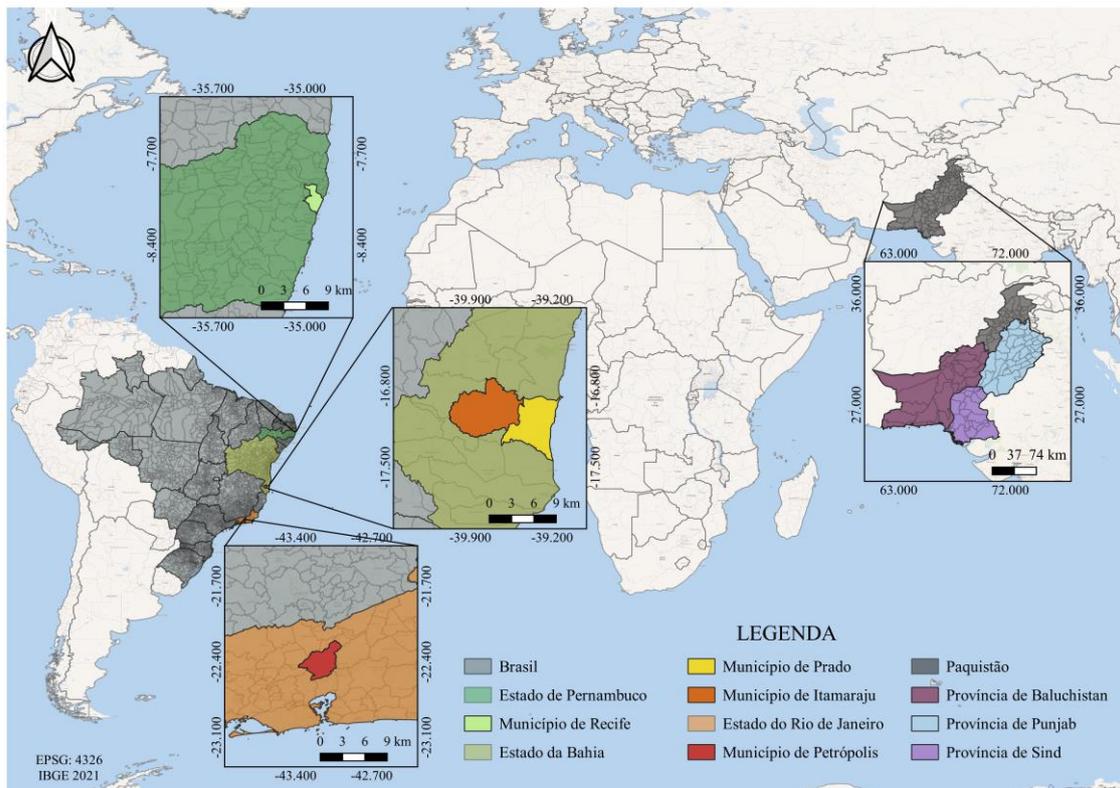
Características (AMAZONIA-1)	WFI
Bandas Espectrais	0,45-0,52 μ m (B) 0,52-0,59 μ m (G) 0,63-0,69 μ m (R) 0,77-0,89 μ m (NIR)
Resolução	65 m
Largura da Faixa Imageada	850 km
Revisita	5 dias
Quantização	10 bits

Fonte: INPE (2022).

3 ESTUDOS DE CASO

Neste capítulo, serão apresentadas as quatro áreas de estudo escolhidas para a aplicação da metodologia (Figura 3.1). Para a escolha das áreas foram considerados os eventos mais recentes, a dimensão das ocorrências e a participação do Brasil em parceria com a Carta.

Figura 3.1 - Localização dos 4 casos de estudo.



3.1 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 et al., 2007). Com o intenso desmatamento da região, juntamente com o desenvolvimento urbano vinculado às ocupações irregulares, segundo Torres et al. (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 (Figura 3.2), onde um total de 232 óbitos foram registrados, além de cerca de 1.117 pessoas desabrigadas (FOLHA DE SÃO PAULO, 2022).

Figura 3.2 – Uma das cicatrizes de deslizamentos desencadeadas na cidade de Petrópolis-RJ.



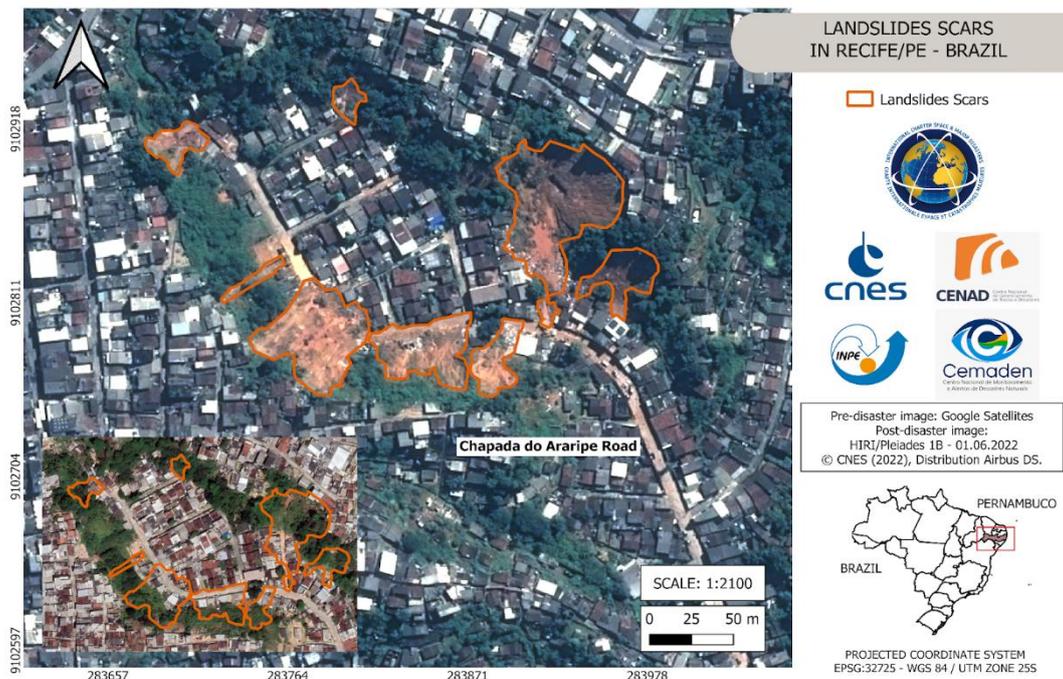
Fonte: Folha de São Paulo (2022).

3.2 Município de Recife (PE)

A cidade de Recife (PE) possui cerca de 65% do seu território caracterizado como áreas de morros. Esse aspecto geomorfológico, vinculado à Formação Barreiras e às condicionantes climáticas, favorecem naturalmente o desencadeamento de deslizamentos, que são ainda mais intensificados pelo processo de ocupação urbana irregular no município (ALHEIROS, 1998).

Em maio de 2022, uma série de deslizamentos e inundações atingiram o Estado de Pernambuco, após episódios de chuvas intensas, onde foram contabilizadas 122 mortes e cerca de 10 mil pessoas desabrigadas (BARROS, 2022). Dentre os 36 municípios afetados, o *International Charter Space and Major Disasters* (ICSMD, 2022) identificou 136 cicatrizes de deslizamentos apenas na cidade de Recife, a partir de imagens do HIRI/Pleiades-1B. O bairro Barro (Figura 3.3) foi uma das localidades mais afetadas, onde o maior deslizamento mapeado foi de 4145,910 m².

Figura 3.3 – Cicatrizes de deslizamentos no bairro Barro (Recife-PE), mapeadas pela Carta a partir de imagens de altíssima resolução do HIRI/Pleiades-1B.



Fonte: ICSMD (2022).

3.3 Províncias de Sind, Balochistan e Punjab (Paquistão)

Segundo Ahmed (2013) e Shah et al. (2020), 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., 2018; DEEN, 2015). Rehman (2016) afirma que mais da metade da população vive em planícies aluviais e o país é constantemente exposto às atividades sísmicas, fatos que potencializam o aumento das fatalidades anuais.

Entre os meses de agosto e setembro de 2022, três províncias do Paquistão (Sind, Balochistan e Punjab) foram severamente atingidas por inundações (Figura 3.4), com mais de mil óbitos contabilizados desde o início das monções, além de milhares de pessoas desabrigadas em cerca de um terço do país (UM SÓ PLANETA, 2022).

Figura 3.4 – Uma das áreas alagadas da província de Sindh, Paquistão.



Fonte: UNICEF (2022).

3.4 Municípios de Itamaraju e Prado (BA)

O clima do estado da Bahia, assim como na maior parte do Nordeste do Brasil, é caracterizado como tropical semiárido em cerca de 68% de seu território. Atualmente, as secas se prolongam de forma eminente e os eventos de inundação são cada vez mais frequentes. Estes prejuízos estão diretamente relacionados tanto à impermeabilização do solo, que está agregada à intervenção inadequada nas bacias hidrográficas urbanas, quanto às consequências das mudanças climáticas que afetam o globo como um todo (LIMA et al., 2011; CASTRO et al., 2015; DOS SANTOS et al., 2021).

Entre dezembro de 2021 e janeiro de 2022, cerca de 165 municípios foram afetados por inundações no estado, em destaque para os municípios de Prado, e Itamaraju (Figura 3.5), com um total de 6 óbitos dentre os 27 registrados. No geral, todos os municípios afetados ficaram em situação de emergência, onde o aumento dos níveis dos principais rios e a probabilidade de rompimento de barragens desabrigaram cerca de 30.000 pessoas (OLIVEIRA; CANDAL, 2021). Os aspectos hidrológicos e meteorológicos do desastre foram aprofundados em Marengo et. al (2023).

Figura 3.5 – Uma das áreas inundadas do município de Itamaraju (BA).

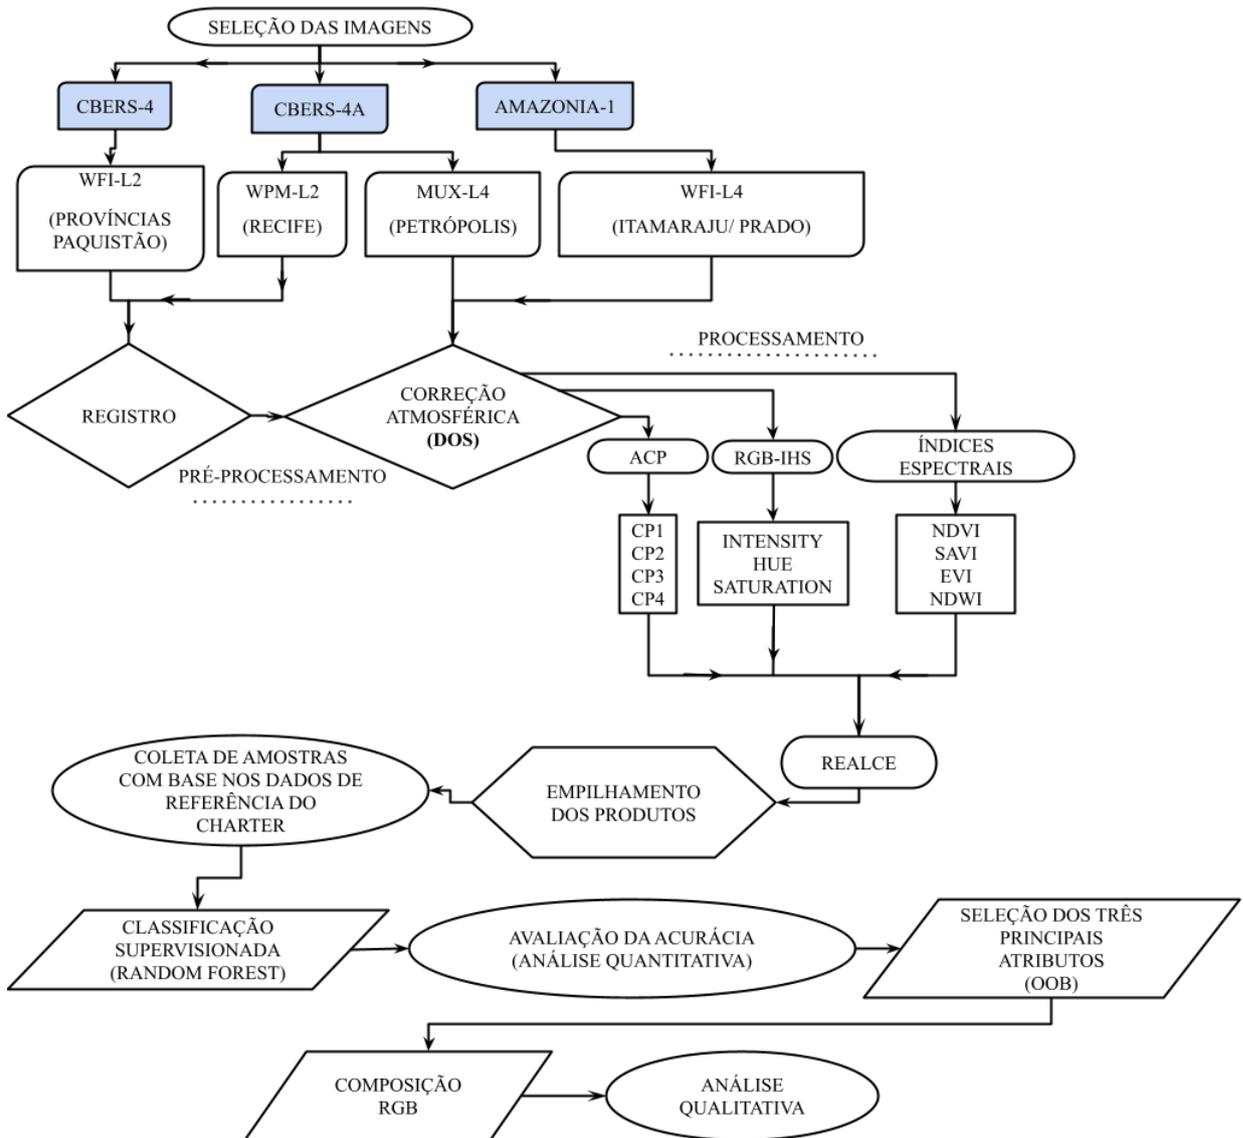


Fonte: Nunes (2021).

4 METODOLOGIA

As etapas metodológicas da presente pesquisa estão representadas na Figura 4.1. Neste capítulo todos os processos realizados serão detalhados.

Figura 4.1 – Fluxograma da metodologia.



4.1 Seleção das Imagens

Sumarizadas na Tabela 4.1, as imagens disponíveis nas datas mais próximas às ativações da Carta e com baixa porcentagem de nuvens foram adquiridas no catálogo de imagens do INPE. Para a avaliação dos deslizamentos, imagens dos sensores MUX e WPM do satélite CBERS-4A foram utilizadas, sendo o primeiro aplicado ao caso de Petrópolis, e o segundo ao caso de Recife. Os níveis das imagens foram L4 e L2, obtidas 15 e 36 dias após a ativação da Carta, respectivamente. Em relação à análise das inundações regionais, imagens do WFI/CBERS-4 foram aplicadas ao caso das províncias do Paquistão, obtidas em nível L4, após 9 dias de ativação. Já para os eventos nos municípios do sul da Bahia, imagens do WFI/AMAZONIA-1 foram avaliadas, estas em nível L2, adquiridas após 13 dias de ativação.

Tabela 4.1 – Datas referentes às ativações emergenciais da Carta após o início dos desastres avaliados, e as datas de aquisição das imagens utilizadas.

ESTUDO DE CASO	SENSOR /SATÉLITE	NÍVEL *	RESOLUÇÃO ESPACIAL	DATA DE ATIVAÇÃO DA CARTA	DATA DE AQUISIÇÃO DE IMAGENS
Petrópolis	MUX/ CBERS-4A	L4	16,5 m	16.02.2022	04.03.2022
Recife	WPM/ CBERS-4A	L2	8 m	30.05.2022	05.07.2022
Províncias do Paquistão	WFI/ CBERS-4	L4	64 m	30.08.2022	08.09.2022
Itamaraju/ Prado	WFI/ AMAZONIA-1	L2	55 m	30.12.2021	12.01.2022

*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 (CASTEJON et al, 2015).

*Nível L4: as imagens são ortoretificadas, onde a correção aplicada considera também as distorções atribuídas à geometria de imageamento do relevo (CASTEJON et al, 2015).

A linguagem de programação *Python* foi utilizada para a correção atmosférica, devido à indisponibilidade de algoritmos voltados para os sensores do CBERS-4, CBERS-4A e AMAZONIA-1 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. Também contou-se com uma rotina de classificação de uso e ocupação do solo¹, desenvolvida pelo cientista de dados geoespaciais Chris Holden (HOLDEN, 2017). Com a utilização da biblioteca *Scikit-Learn*, deu-se ênfase no algoritmo RF e nas métricas estatísticas discutidas na Seção 2.2.7.2.

Os demais procedimentos (registro, ACP, transformação RGB-IHS, cálculo dos índices espectrais, realce automático e combinação dos atributos mais relevantes no espaço de cores RGB) foram realizados no QGIS 3.22.6 e no TerraView 5.6.3. Pelo uso gratuito das plataformas, juntamente com as suas características intuitivas, o fluxo de processamento pode ser aplicado com mais agilidade pelos analistas, considerando a necessidade de fornecimento urgente das informações espaciais adquiridas.

4.2 RF e a seleção de atributos

O RF também é uma técnica de mineração de dados que proporciona selecionar e classificar os atributos de maior relevância na discriminação dos alvos, baseando-se na decisão majoritária entre as árvores (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; LUCIAN, 2016).

¹ Rotina de classificação de uso e ocupação do solo disponível em:
https://ceholden.github.io/open-geo-tutorial/python/chapter_5_classification.html.

A característica quantitativa supracitada foi explorada para a seleção dos três atributos mais importantes para a classificação de áreas de deslizamentos e de inundações, que posteriormente foram combinados no espaço RGB de cores. Esta última etapa (discutida no próximo tópico) foi avaliada de forma qualitativa pelo produto visual gerado e as referências mapeadas pela Carta. No total, 11 produtos foram extraídos das bandas dos sensores e, juntamente com as suas quatro bandas originais, formaram o arquivo contendo os 15 produtos empilhados (Tabela 4.2), para a posterior seleção de atributos.

Tabela 4.2 – Atributos de entrada para a classificação supervisionada RF.

BANDAS ORIGINAIS	COMPONENTES PRINCIPAIS*	ÍNDICES ESPECTRAIS	TRANSFORMAÇÃO RGB-IHS*
RED GREEN BLUE NIR	CP1 CP2 CP3 CP4	NDVI SAVI EVI NDWI	INTENSITY HUE SATURATION
<p>* Componentes principais extraídas a partir das quatro bandas originais de cada sensor utilizado.</p> <p>* Transformação RGB realizada a partir das bandas RED, GREEN e BLUE de cada sensor utilizado.</p>			

Para a análise dos deslizamentos, o estudo de caso de Petrópolis (descrito na Seção 3.1) foi utilizado como referência principal para a seleção de atributos, em decorrência ao tamanho e quantidade de cicatrizes. Ainda, estas propriedades puderam ser bem visualizadas nas imagens do MUX/CBERS-4A, que não possuem uma alta resolução espacial e, conseqüentemente, de processamento digital mais rápido. Para a avaliação metodológica em dados de resolução mais refinada, a classificação também foi aplicada às imagens do WPM/CBERS-4A para a análise dos deslizamentos em Recife (descrito na Seção 3.2). Estes foram mais numerosos porém de dimensões inferiores quando comparados ao caso de Petrópolis.

Para a análise das inundações regionais, o estudo de caso do Paquistão (descrito na Seção 3.3) foi a principal referência devido à possibilidade posterior de análise comparativa com o mapeamento realizado pela Carta (UNOSAT, 2022). Em relação às cidades da Bahia, a Carta não avaliou regionalmente as áreas inundadas neste caso, porém a análise exploratória da região foi praticada de forma independente no período. Com isso, foi observado um padrão semelhante ao caso que ocorreu posteriormente nas províncias do Paquistão sendo, portanto, mais uma possibilidade de teste metodológico.

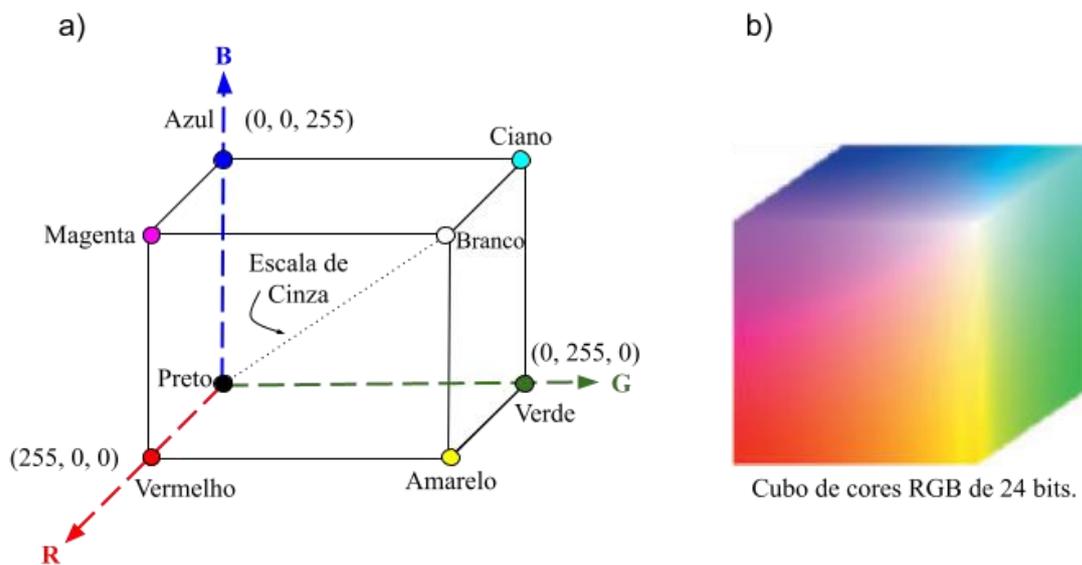
Para as classificações supervisionadas, foram utilizados o arquivo contendo o empilhamento dos 15 atributos relativo a cada caso de estudo juntamente com o arquivo ROI (*Region Of Interest*-“Região de Interesse”) contendo as amostras coletadas aleatoriamente. Estas foram identificadas como “0” (referente 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. Em relação ao caso das cidades da Bahia, os polígonos das áreas inundadas foram mapeados visualmente a partir das próprias imagens do WFI/AMAZONIA-1 e as amostras foram igualmente coletadas aleatoriamente. 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 Lucian (2016), e 200 árvores para o caso das inundações. A quantidade de amostras variou em cada estudo de caso em decorrência ao número diferente de polígonos de referência mapeados pela Carta.

4.3 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 (Figura 4.2a), 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). Considerando que o número de bits é representado pelo expoente na base 2 (2^8), quando realizada a combinação de três imagens (R, G, B) de 8 bits cada, temos: $(2^8)^3$. Como resultado, uma imagem de 24 bits é gerada contendo 16.777.216 cores possíveis (Figura 4.3b).

Figura 4.2 – Representação do sistema de coordenadas cartesianas dos componentes espectrais primários (a) e cubo de cores para uma composição de 24 bits (b).

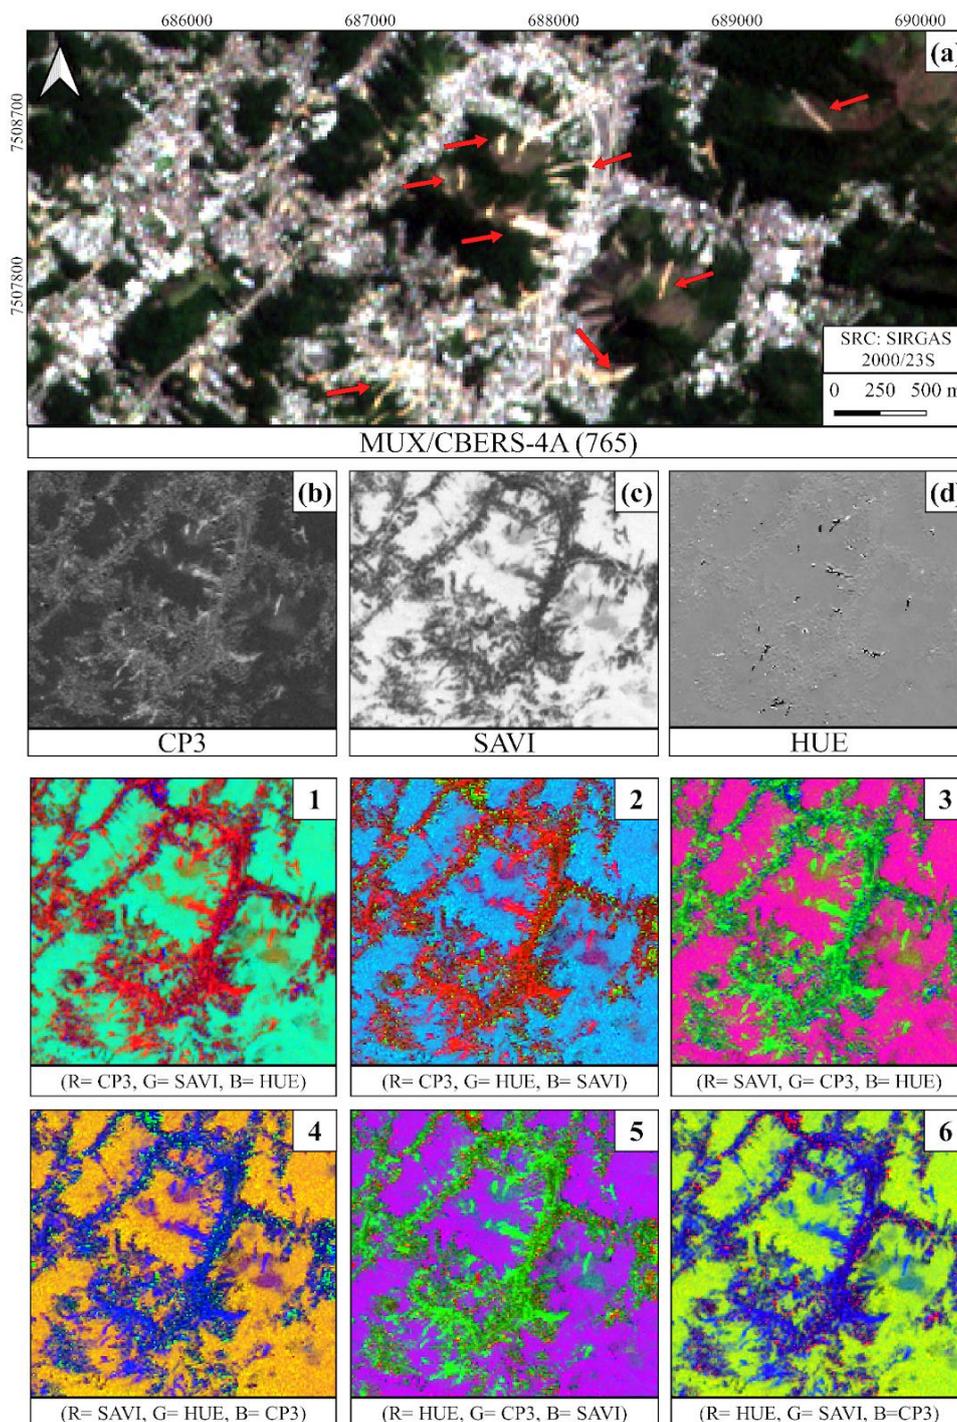


Fonte: Adaptado de Gonzalez e Woods (2009).

Para uma composição RGB apropriada na 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, de modo a facilitar a visualização e integração de informações diferentes, a depender do entendimento do analista.

Tal abordagem foi aplicada em cada estudo de caso da presente pesquisa para análises qualitativas, onde os três principais atributos selecionados pelo RF foram combinados no espaço RGB de cores (exemplificado na Figura 4.3), sendo selecionada a composição de melhor correspondência visual dos alvos de interesse. No trabalho de Ban et al. (2017), áreas inundadas foram estimadas a partir da seleção de 3 das 36 bandas espectrais que compõem o MODIS/TERRA que melhor distinguiram água, solo e vegetação. As bandas foram combinadas na composição RGB 652, onde a banda 6 (1,64 μm) e a banda 5 (1,24 μm) são sensíveis à umidade, e a banda 2 (0,86 μm) é útil para diferenciar a água de solo e vegetação. Outras aplicações são aprofundadas em Mondini et al. (2011) e Vecchiotti et al. (2021).

Figura 4.3 – Exemplo de combinações possíveis entre os três atributos mais relevantes na classificação do RF, para o estudo de caso do município de Petrópolis. Em (a): composição em cor verdadeira (765) do sensor MUX/CBERS-4A e algumas cicatrizes de deslizamento indicadas pelas setas vermelhas; em (b): CP3 extraída do empilhamento das quatro bandas do mesmo sensor avaliado; em (c): componente *Hue* extraída da transformação RGB-IHS das bandas (765). Todas as combinações possíveis entre os produtos CP3, SAVI e HUE estão destacadas nas imagens numeradas de 1 a 6.



5 RESULTADOS E DISCUSSÕES

Para cada caso de estudo, os resultados obtidos serão apresentados e discutidos separadamente. De forma inicial, a quantidade de amostras aleatórias coletadas com base nos dados de referência da Carta será apresentada. Posteriormente, 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 supervisionada RF. Para análise qualitativa, a composição RGB de melhor correspondência visual dos alvos (gerada com base nos três principais atributos ranqueados pela classificação) será avaliada, e as vantagens e desvantagens em cada caso serão discutidas.

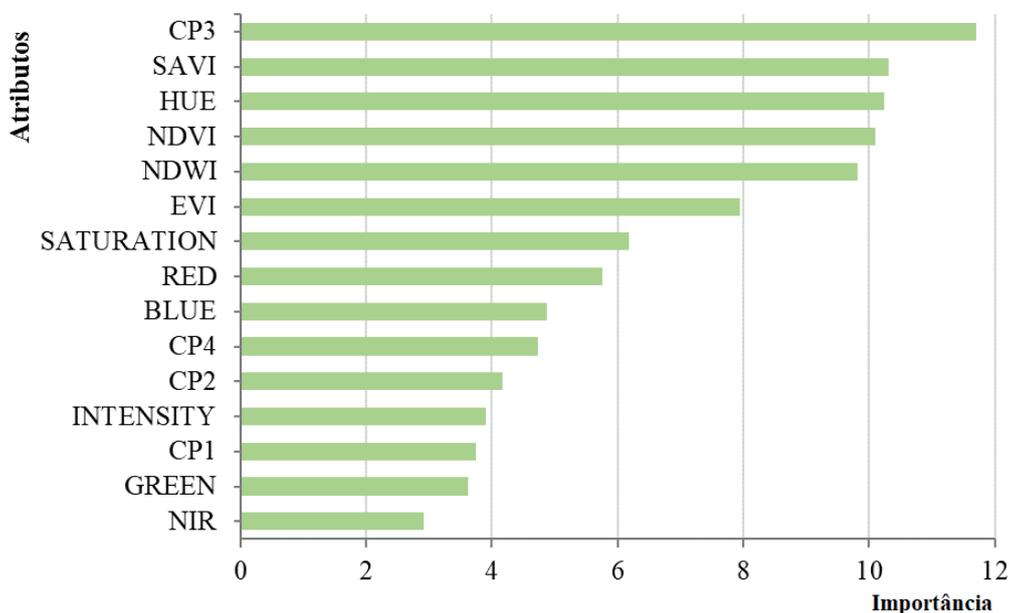
5.1 Amostragem para o caso dos deslizamentos em Petrópolis (RJ)

Foram coletadas aleatoriamente 165 amostras dentro dos 55 polígonos caracterizados como deslizamentos pela Carta (3 amostras por polígono), e 165 amostras aleatórias localizadas fora dos polígonos de deslizamento. Ressalta-se que a vetorização realizada pela Carta no período do evento foi baseada em imagens de altíssima resolução espacial do HIRI/Pleiades-1B, de 50 centímetros.

5.1.1 Ranqueamento dos atributos a partir da classificação RF

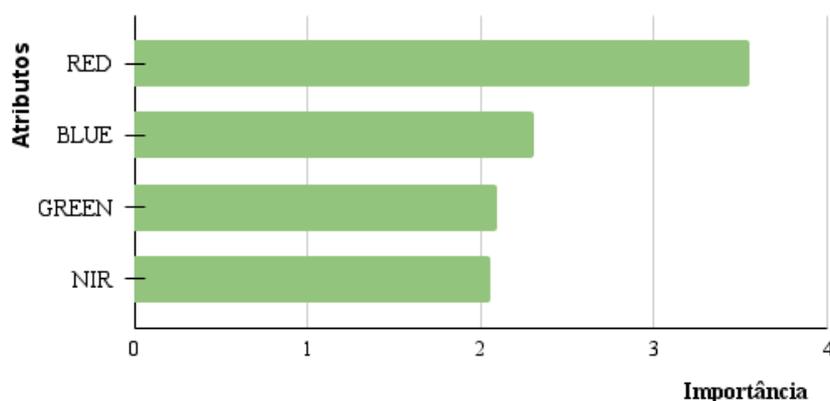
Com uma exatidão de 83,11% calculada usando-se as amostras OOB, o ranqueamento dos 15 atributos (Figura 5.1) foi obtido. Para a cena avaliada, a CP3, o SAVI e o HUE foram os atributos de maior relevância na classificação binária.

Figura 5.1 – Ranqueamento de importância/relevância do empilhamento dos quinze atributos extraídos para o estudo de caso dos deslizamentos em Petrópolis (RJ), a partir da análise das amostras OOB.



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, identificados pelos números 7, 6, 5 e 8, respectivamente). Como indicado na Figura 5.2, com uma exatidão de 80,95% calculada usando-se as amostras OOB, a banda do RED foi o atributo de maior contribuição, seguido pelo BLUE, GREEN e NIR.

Figura 5.2 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor MUX/CBERS-4A para o estudo de caso dos deslizamentos em Petrópolis (RJ), a partir da análise das amostras OOB.



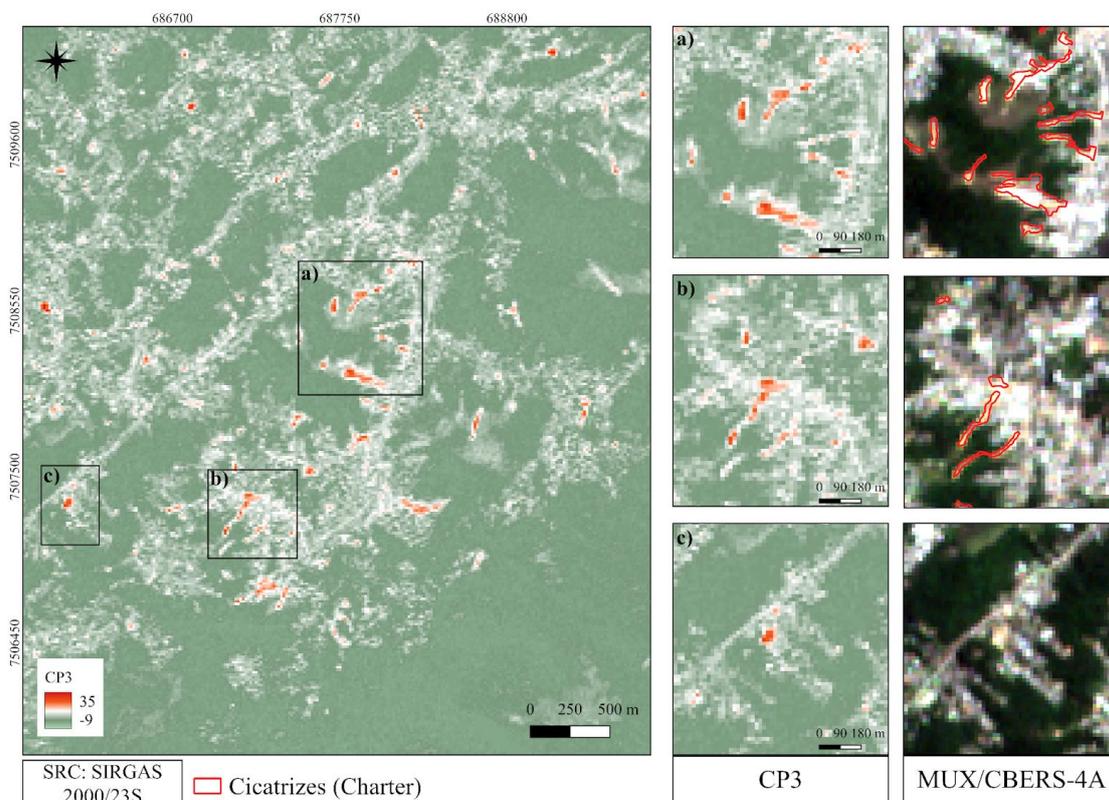
No ranqueamento com base nos quinze atributos (Figura 5.1), a banda RED ocupou o sétimo lugar em relação aos demais atributos, demonstrando a relevância da exploração e integração mais específica das técnicas de PDI ao algoritmo. Isso se comprova com os valores de acurácia obtidos nos dois casos (Tabela 5.1). 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.

Tabela 5.1 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do sensor MUX/CBERS-4A para o caso dos deslizamentos em Petrópolis (RJ).

MUX/CBERS-4A (PETRÓPOLIS)	EXATIDÃO OOB	MÉTRICAS EXTRAÍDAS A PARTIR DA 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

O elemento de maior relevância na classificação RF do empilhamento de quinze atributos (Figura 5.1) foi a CP3 (Figura 5.3). 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 vão sendo reduzidas a cada CP sucessiva, restando no terceiro conjunto de saída (CP3) características espectrais mais específicas e descorrelacionadas (CROSTA, 1992; ESTORNELL et al., 2013; LOUGHLIN, 1991).

Figura 5.3 – CP3 extraída das bandas (5678) do MUX/CBERS-4A, para o caso do município de Petrópolis. Em (a) e (b) cicatrizes de deslizamentos; em (c) área de solo exposto com mesma tonalidade dos deslizamentos.



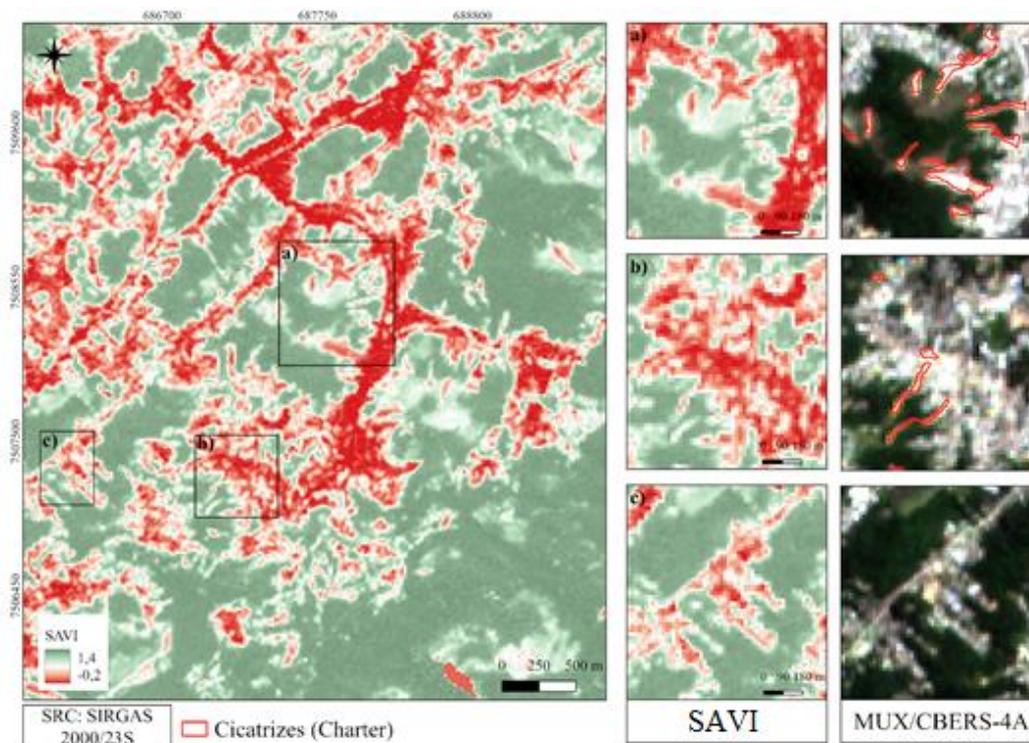
Com isso, como retratado na Tabela 5.2, a terceira componente explica 0,3395% da variância total dos dados. Em termos quantitativos, o conteúdo de informação decresce para as últimas componentes mas, em termos qualitativos, contém informações relevantes na ênfase de alvos particulares.

Tabela 5.2 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes extraídas das bandas do sensor MUX/CBERS-4A.

COMPONENTES PRINCIPAIS (MUX/CBERS-4A)	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

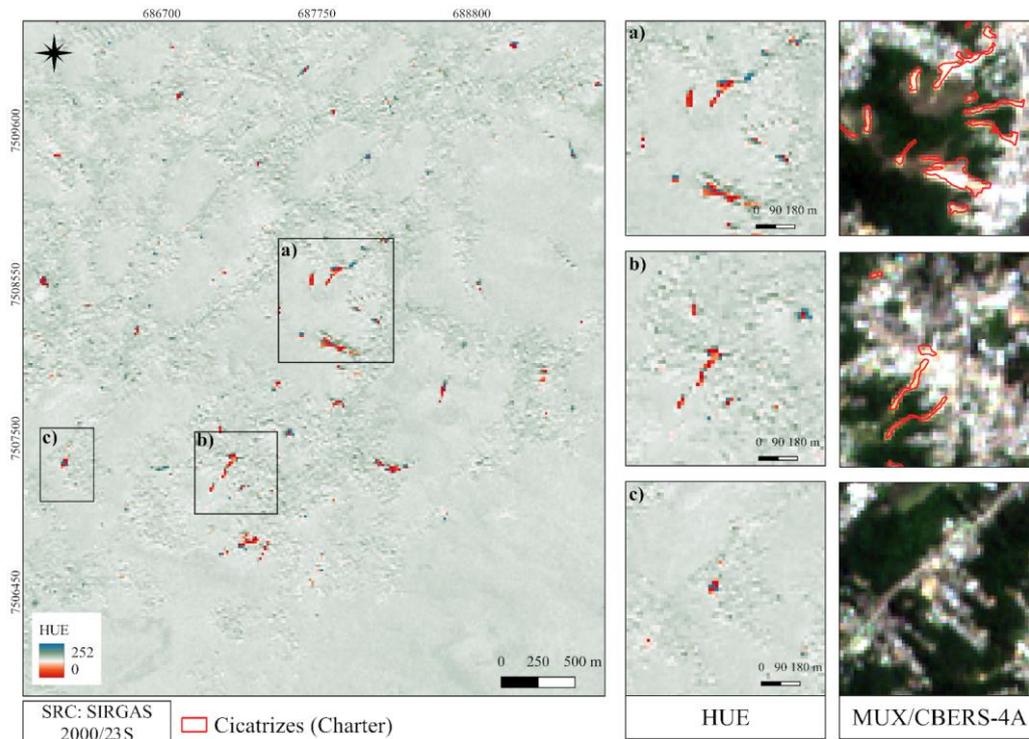
Em sequência no ranqueamento, o SAVI apresentou o segundo melhor desempenho na distinção das áreas identificadas como deslizamentos e não-deslizamentos (Figura 5.4). Na composição RGB posteriormente proposta (Seção 5.1.2), seu posicionamento no canal verde de visualização também facilitou a obtenção do contraste entre as áreas vegetadas e os demais alvos relevantes.

Figura 5.4 – Atributo SAVI extraído a partir das bandas do MUX/CBERS-4A, para o caso de Petrópolis (RJ). Em (a) e (b) áreas de deslizamentos; em (c) área de solo.



A componente *Hue* da transformação RGB-IHS (Figura 5.5), em terceiro lugar dentre os demais atributos do ranqueamento (Figura 5.1), 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 a Matiz não é influenciada pelos distintos níveis de reflectância causados por diferenças de iluminação e sombra (LIU; MOORE, 1990).

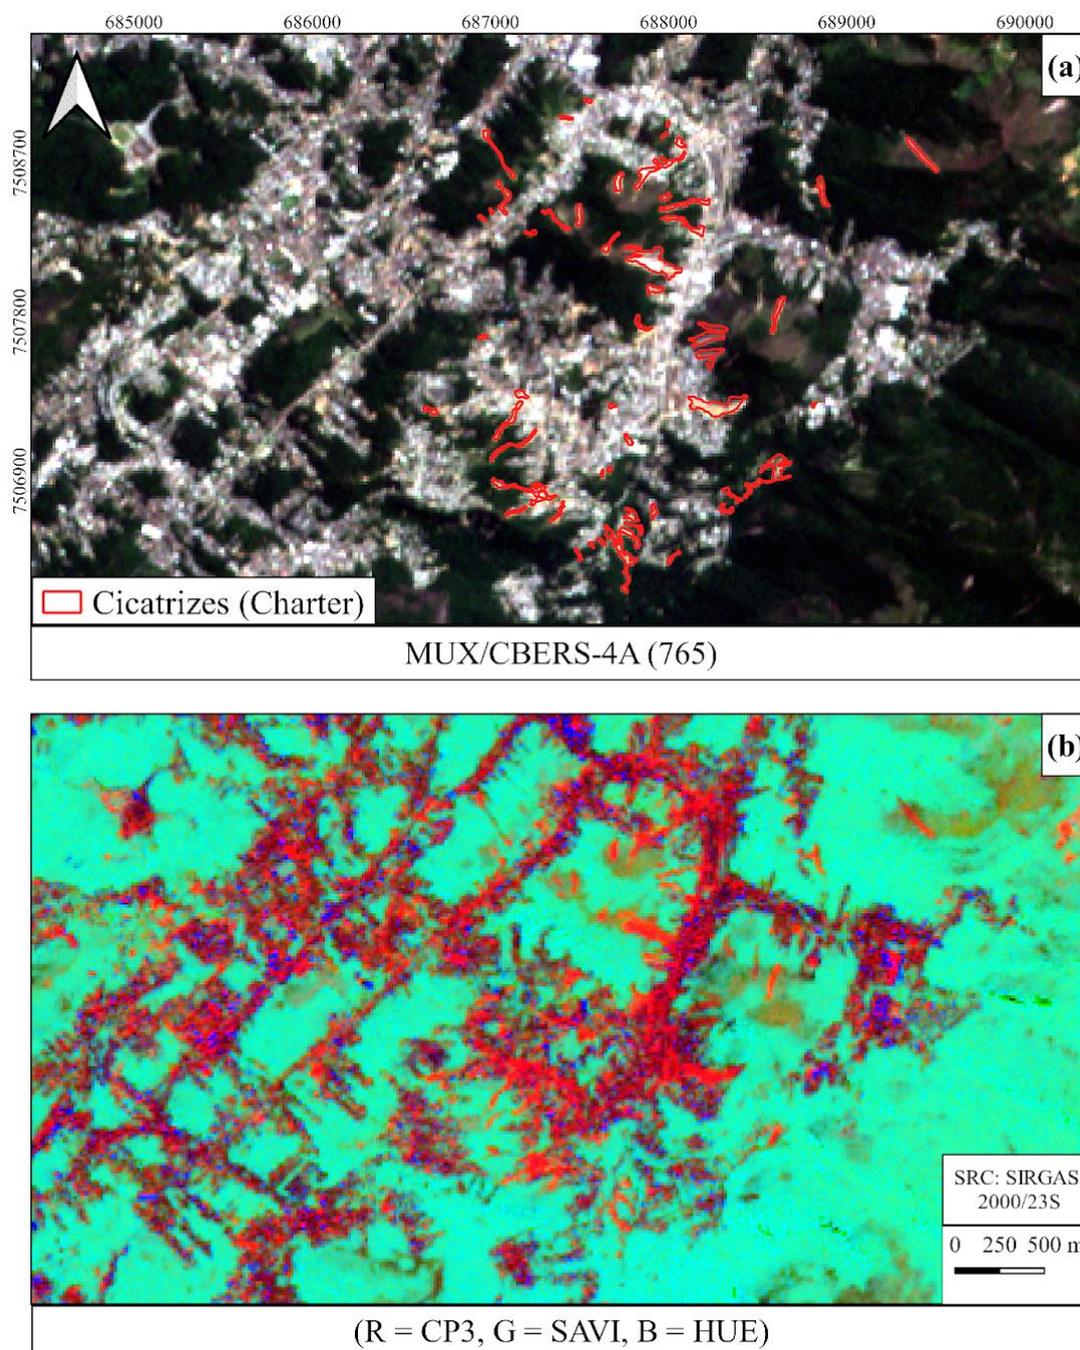
Figura 5.5 – Componente *Hue* resultante da transformação RGB-IHS a partir das bandas do MUX/CBERS-4A, para o caso do município de Petrópolis. Em (a) e (b) cicatrizes de deslizamentos; em (c) área de solo exposto com mesma tonalidade dos deslizamentos.



5.1.2 Detecção de áreas de deslizamentos em Petrópolis (RJ)

As três primeiras bandas mais relevantes do empilhamento de melhor desempenho qualitativo (empilhamento de 15 atributos) foram combinadas no espaço de cores RGB (CP3, SAVI, HUE), de acordo com a melhor correspondência visual dos alvos. Como retratado na Figura 5.6, foram gerados alertas visuais de possíveis cicatrizes de deslizamentos.

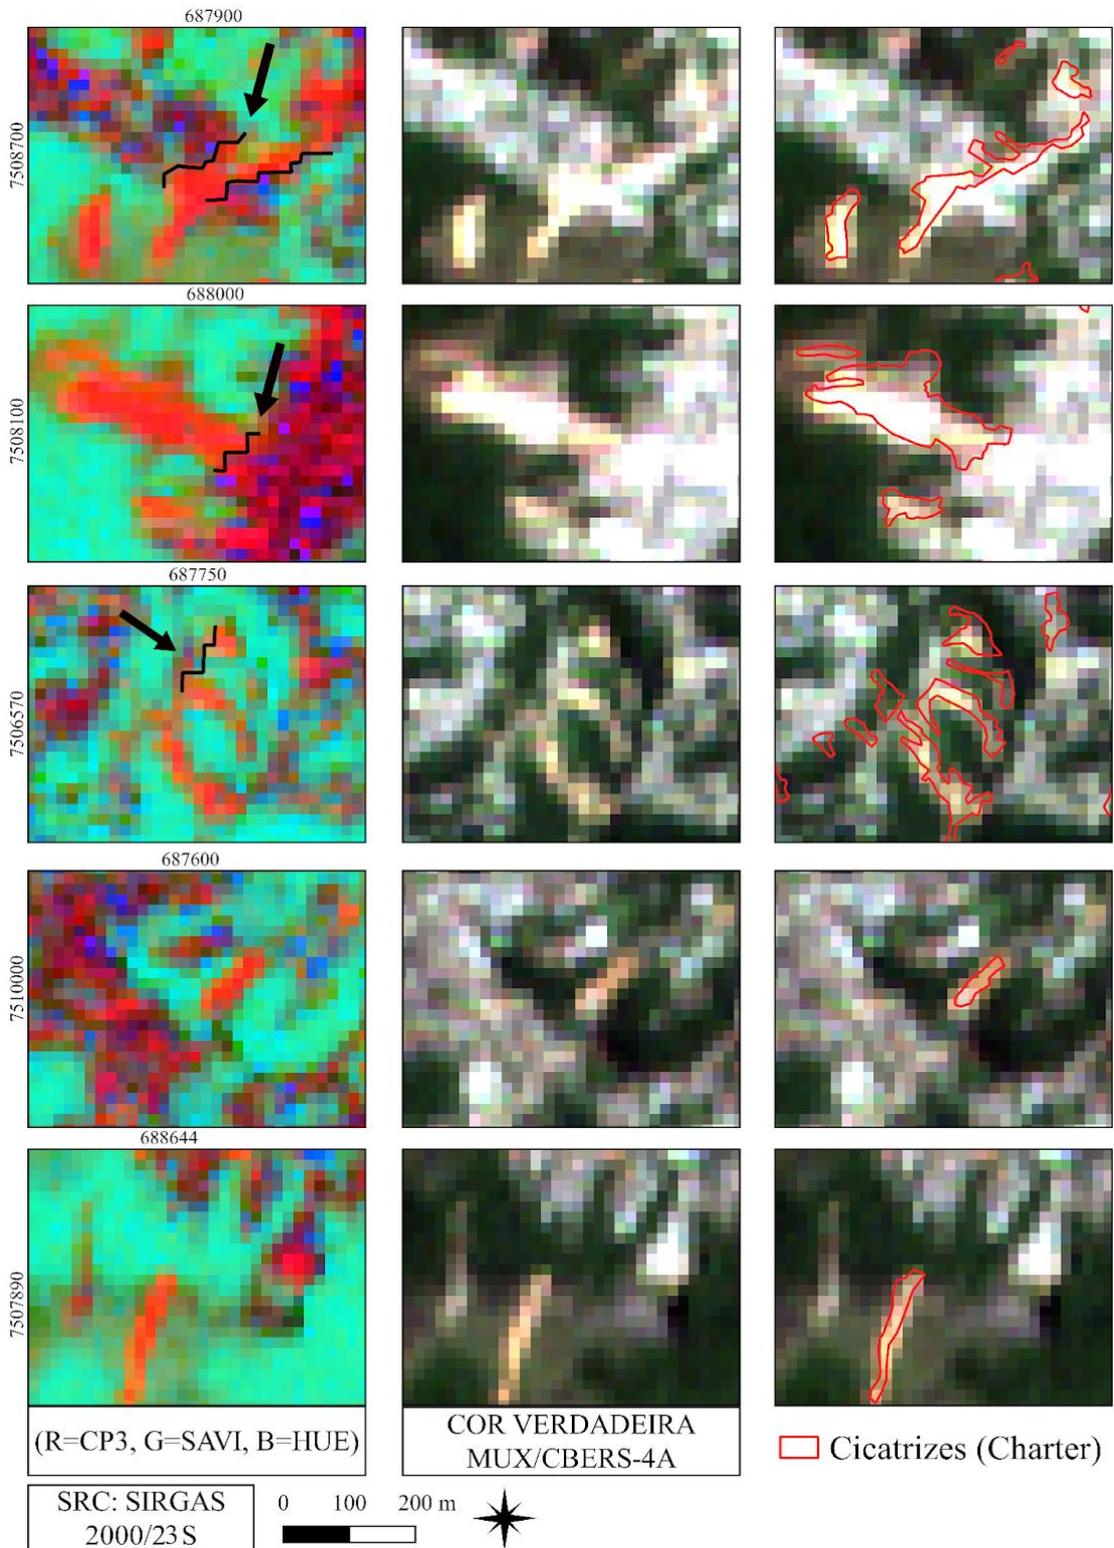
Figura 5.6 – Áreas de deslizamentos destacadas em tons de laranja na composição RGB (CP3, SAVI, HUE) sugerida a partir do ranqueamento OOB dos quinze atributos em comparação à composição em cor verdadeira (765) do sensor MUX/CBERS-4A.



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 (765) 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, tornando-se evidentes quando a escala é diminuída. Já na composição sugerida (R=CP3, G=SAVI, B=HUE), esse efeito é minimizado pelo melhor contraste estabelecido entre as cores. Como mostra a Figura 5.7, 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 delimitados pela Carta.

Figura 5.7 – Áreas de deslizamentos destacadas em tons de laranja na composição RGB sugerida (R= CP3, G= SAVI, B= HUE), em comparação com a composição RGB (765) do MUX/CBERS-4A. As setas pretas indicam o limite entre as classes.

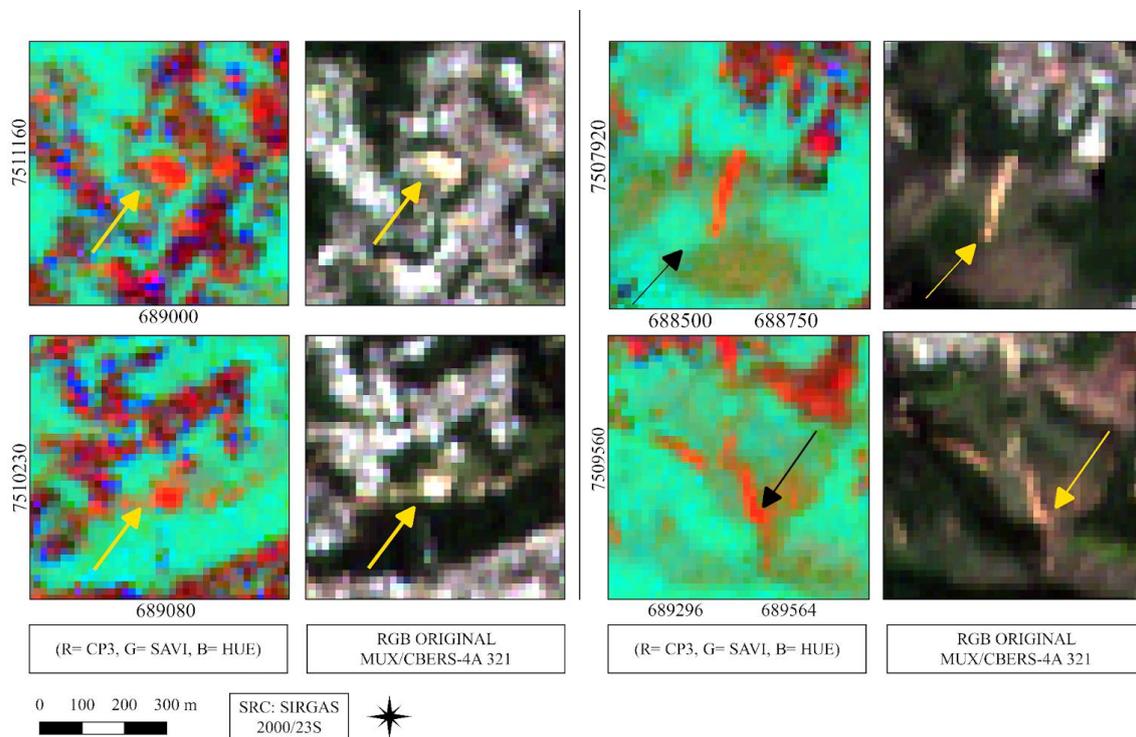


Algumas áreas mais antigas de solo exposto também foram diferenciadas, havendo a identificação da assinatura espectral individualizada de um solo mais úmido e exposto recentemente, de áreas já evidenciadas ou desmatadas em um momento passado (PIKE, 1988). Com a diferença de 15 dias entre a data de aquisição da imagem e a data de ativação da Carta, o contraste entre estas duas classes pôde ser evidenciado (exemplo no Apêndice A.1).

As demais áreas destacadas em tons de laranja que não foram caracterizadas como deslizamentos pela Carta (Apêndice A.2), foram identificadas principalmente como áreas de desmatamento recente, baseando-se em imagens do *Google Satellites* de antes do evento. Tais alvos apresentam um comportamento espectral semelhante, sendo comumente confundidos em trabalhos equivalentes. Nestas situações, os alertas gerados “erroneamente” podem ser rapidamente descartados se a composição sugerida for sobreposta a um *basemap* disponibilizado gratuitamente em ambiente SIG². Ainda, percebe-se um formato distinto entre o conjunto de pixels que delimitam o solo exposto e o conjunto de pixels que delimitam os deslizamentos. Ao serem comparados (Figura 5.8), as áreas de solo exposto em laranja possuem formatos mais circulares, e os deslizamentos formatos mais retilíneos.

² No QGIS 3.22, por exemplo, o complemento *Quick Map Services* possibilita a integração dos serviços do *Google* ao projeto em análise.

Figura 5.8 – Formatos distintos entre o conjunto de pixels que delimitam o solo exposto e o conjunto de pixels que delimitam as cicatrizes de deslizamentos no caso de Petrópolis (RJ), indicados pelas setas amarelas.

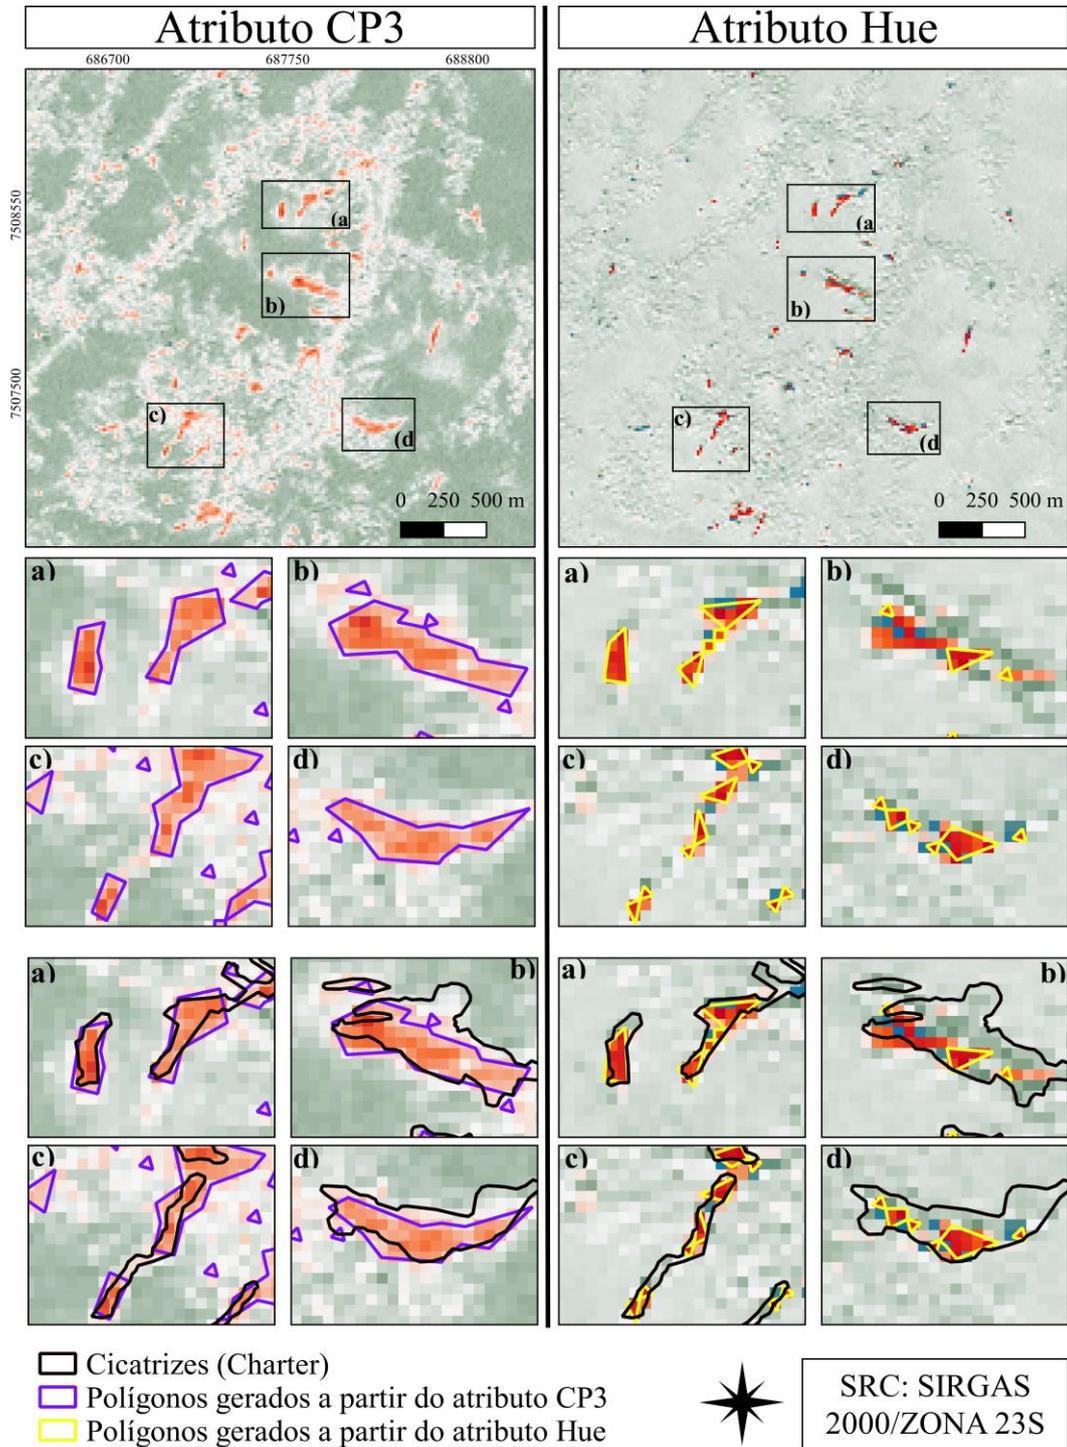


5.1.3 Avaliação dos resultados com base nos dados de referência

Sob a mesma perspectiva de fornecimento de respostas rápidas, os atributos CP3 e Hue foram avaliados individualmente como análise complementar, ambos com resultado visual semelhante na ênfase das cicatrizes. Os polígonos gerados³ foram comparados com a delimitação manual realizada pela Carta (Figura 5.9).

³ A vetorização se deu através da reclassificação do *raster* de cada produto, a partir da ferramenta “Reclassify” do QGIS 3.22, posterior isolamento e vetorização da classe onde as cicatrizes puderam ser melhor evidenciadas.

Figura 5.9 – Reclassificação dos produtos CP3 e *Hue*, posterior isolamento e vetorização das classes em que as cicatrizes foram melhor evidenciadas. Os polígonos roxos foram extraídos a partir da reclassificação da CP3; os polígonos amarelos foram extraídos a partir da reclassificação da componente *Hue*; os polígonos pretos são as cicatrizes de referência da Carta.



Das 55 cicatrizes delimitadas pela Carta na principal área de interesse (polígonos pretos), 73 polígonos gerados pelo produto CP3 (polígonos roxos) foram assertivamente localizados nas áreas de referência mapeadas, caracterizando, portanto, mais de um polígono dentro de algumas cicatrizes de referência (Tabela 5.3). Outros 121 polígonos isolados também foram gerados, de tamanhos de aproximadamente 1 pixel, que podem ser explicados pela resposta espectral semelhante de alguns alvos urbanos ou ainda de solo exposto recentemente dentro da área de interesse.

Tabela 5.3 – Comparação entre os polígonos gerados pelos produtos CP3 e *Hue*, em relação às 55 cicatrizes mapeadas manualmente pela Carta.

	CP3	HUE
Polígonos gerados	194	61
Polígonos inseridos dentro das referências	73	48
Cicatrizes de referência sem nenhum polígono associado	19	38
Área de interseção entre os polígonos e as cicatrizes de referência	68227,6 / 201896 m ²	17068,0 / 201896 m ²

Quanto ao produto *Hue*, dos 61 polígonos gerados (polígonos amarelos), 48 se localizaram dentro das áreas de referência. Assim como no atributo CP3, algumas cicatrizes mapeadas não foram contempladas pelos polígonos gerados, além de outros 13 situados fora das extensões delimitadas pela Carta. Sobre este último resultado, diferentemente da CP3, poucos polígonos isolados foram gerados, porém apresentaram tamanhos bem menores e descontínuos, não caracterizando o formato das cicatrizes como a CP3. Mesmo considerando tais questões, os dois atributos podem ser úteis quando avaliados individualmente.

Diante de todos os produtos gerados, apesar de possuírem uma resolução espacial média (16,5 metros), as imagens do MUX/CBERS-4A puderam ser processadas para a identificação da geometria (tamanho e forma) das cicatrizes

de deslizamento nas encostas do município de Petrópolis (RJ). Essas características são essenciais para o desenvolvimento de mapas emergenciais de cicatrizes de deslizamentos, sendo vantajosa a exploração da imagem caso esteja disponível e com baixa porcentagem de nuvens. Apesar da literatura apontar para a utilização de imagens de alta resolução espacial para o mapeamento desse tipo de desastre, observou-se que é possível explorar as imagens do MUX quando a extensão das cicatrizes é significativa.

5.2 Amostragem para o caso dos deslizamentos em Recife (PE)

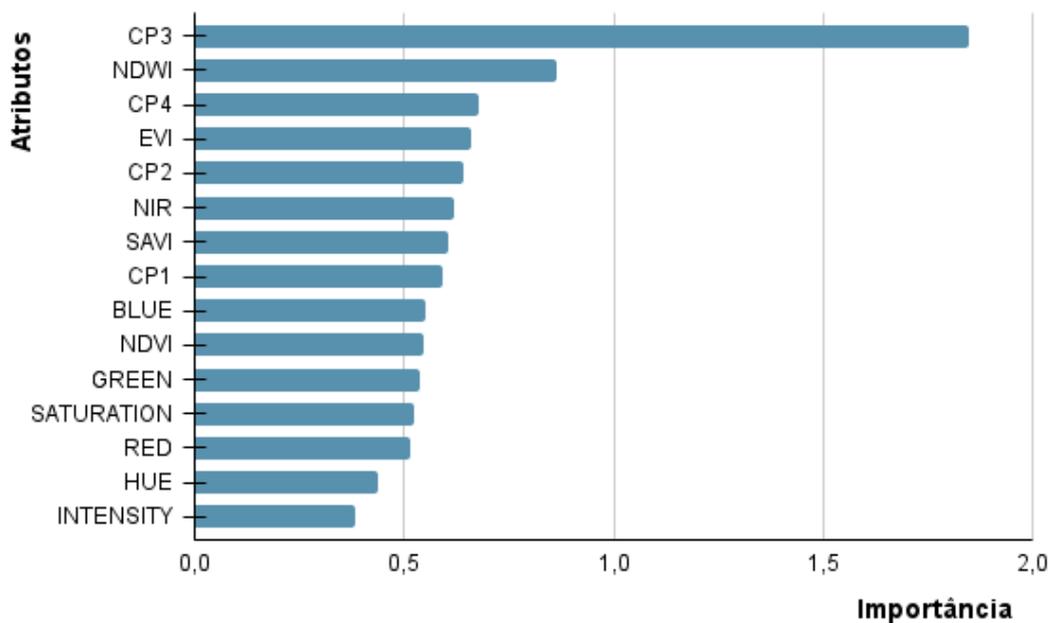
A metodologia proposta na Seção 5.1 foi igualmente aplicada ao caso de Recife, porém baseada nos produtos extraídos das quatro bandas do WPM/CBERS-4A, de 8 metros de resolução espacial. Propositamente, as imagens não foram fusionadas devido ao tempo de processamento dos dados. Como uma imagem fusionada do WPM requer um espaço computacional considerável e o objetivo da pesquisa é fornecer respostas rápidas, foram utilizadas as bandas originais de 8 metros para a otimização do processo.

Na cena avaliada, 180 amostras aleatórias foram coletadas no interior dos 60 polígonos caracterizados como cicatrizes de deslizamento pela Carta. Esta vetorização também foi baseada em imagens do HIRI/Pléiades-1B de 50 cm de resolução espacial. A mesma quantidade de amostras foi coletada nas demais áreas de não-deslizamento, para a posterior aplicação do RF sobre os atributos derivados do sensor WPM/CBERS-4A.

5.2.1 Ranqueamento dos atributos a partir da classificação RF

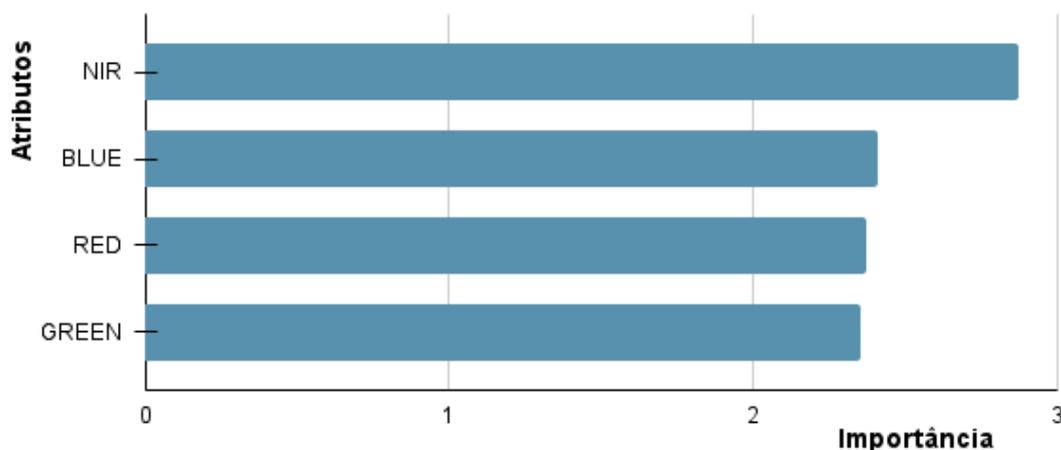
Com uma exatidão de 77,82% obtida usando-se as amostras OOB, o ranqueamento das quinze bandas foi obtido (Figura 5.10). Para a cena avaliada, a CP3, o NDWI e a CP4 ocuparam os três primeiros lugares em ordem de relevância na classificação.

Figura 5.10 – Ranqueamento de importância/relevância do empilhamento dos quinze atributos extraídos para o estudo de caso dos deslizamentos em Recife (PE), a partir da análise das amostras OOB.



A classificação RF também foi aplicada considerando somente as quatro bandas originais do WPM/CBERS-4A (RED, GREEN, BLUE e NIR, identificados pelos números 3, 2, 1 e 4, respectivamente). Como retratado na Figura 5.11, o NIR foi o atributo de maior influência na classificação.

Figura 5.11 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor WPM/CBERS-4A para o estudo de caso de deslizamentos em Recife (PE), a partir da análise das amostras OOB.



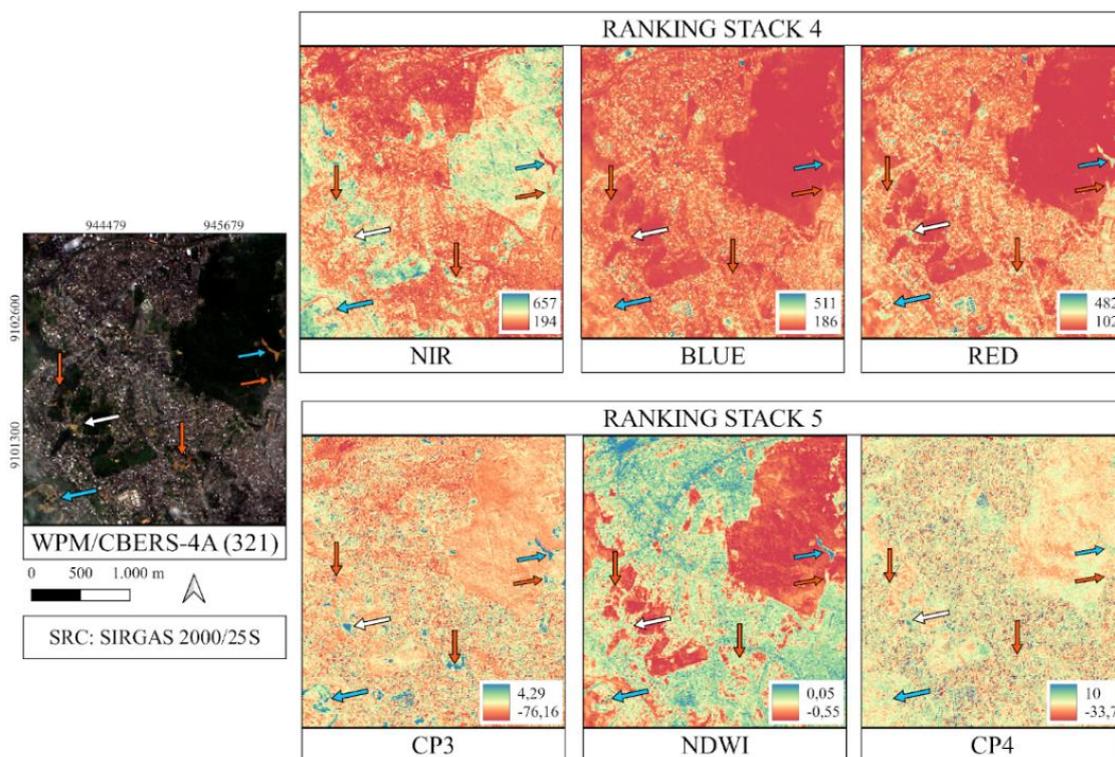
Comparando os resultados das métricas estatísticas obtidas com base nos quinze atributos e os resultados obtidos a partir dos quatro atributos apenas, em exceção ao OOB, os demais valores de acurácia foram relativamente maiores no segundo caso (Tabela 5.4). Como análise quantitativa, a classificação aponta para uma melhor performance de mapeamento a partir das bandas originais do sensor WPM/CBERS-4A.

Tabela 5.4 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do sensor WPM/CBERS-4A para o caso dos deslizamentos em Recife (PE).

WPM/CBERS-4A (RECIFE)	EXATIDÃO OOB	MÉTRICAS EXTRAÍDAS A PARTIR DA MATRIZ DE CONFUSÃO			
		AG	P	R	F1 - score
Empilhamento de quatro atributos	73,22%	78,64%	0,786	0,786	0,786
Empilhamento de quinze atributos	77,82%	76,69%	0,766	0,766	0,766

A Figura 5.12 retrata as bandas mais relevantes na classificação RF utilizando os quatro e os quinze atributos. Apesar da classificação de quatro atributos ter apresentado valores quantitativos maiores, os três principais atributos ranqueados do empilhamento de quinze também foram explorados para a análise qualitativa.

Figura 5.12 – Atributos mais importantes/relevantes na classificação RF utilizando os quatro e os quinze atributos, para o caso dos deslizamentos em Recife (PE). As setas laranjas indicam áreas de deslizamentos; as setas azuis indicam áreas de corpos hídricos; as setas brancas indicam áreas de solo exposto.



Especificamente sobre o empilhamento dos quinze atributos, a CP3 se apresentou novamente em primeiro lugar no ranqueamento de importância a partir da análise das amostras OOB, explicando 0,97% da variância total dos dados (Tabela 5.5). O NDWI foi o índice espectral que apresentou o segundo melhor desempenho na separabilidade entre as áreas de deslizamento e não-deslizamento, seguido pela última componente principal (CP4). Quando posicionada no canal azul de visualização da composição RGB (aprofundado na Seção 5.2.2), a CP4 proporcionou um contraste visual entre as áreas urbanas e regiões vegetadas. Muitas referências apontam que a última componente principal extraída de um conjunto de bandas espectrais apresenta uma quantidade significativa de ruído. Porém, neste caso observou-se que na classificação RF dos atributos do WPM, a última componente ainda revela informações relevantes na separabilidade entre os alvos.

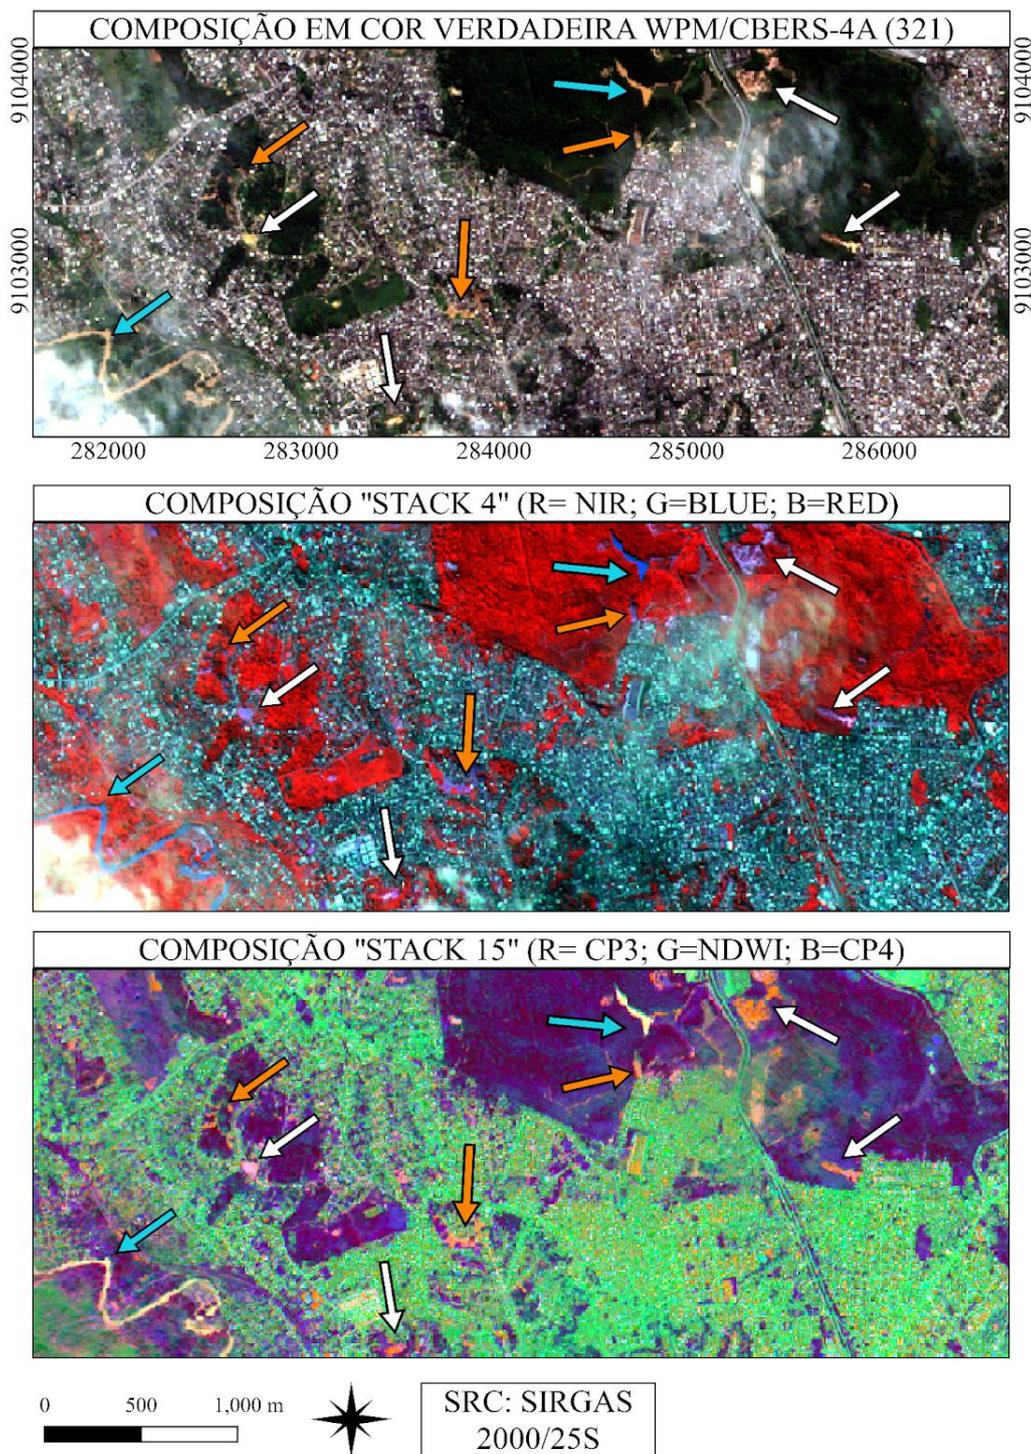
Tabela 5.5 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes extraídas das bandas do sensor WPM/CBERS-4A.

COMPONENTES PRINCIPAIS (WPM/CBERS-4A)	AUTOVALORES (%)	AUTOVETORES			
		BLUE	GREEN	RED	NIR
CP1	70,23	0,501	0,476	0,568	0,444
CP2	28,51	-0,229	-0,181	-0,343	0,892
CP3	0,97	0,694	0,157	-0,699	-0,058
CP4	0,27	0,460	-0,846	0,263	0,048

5.2.2 Detecção das áreas de deslizamentos em Recife (PE)

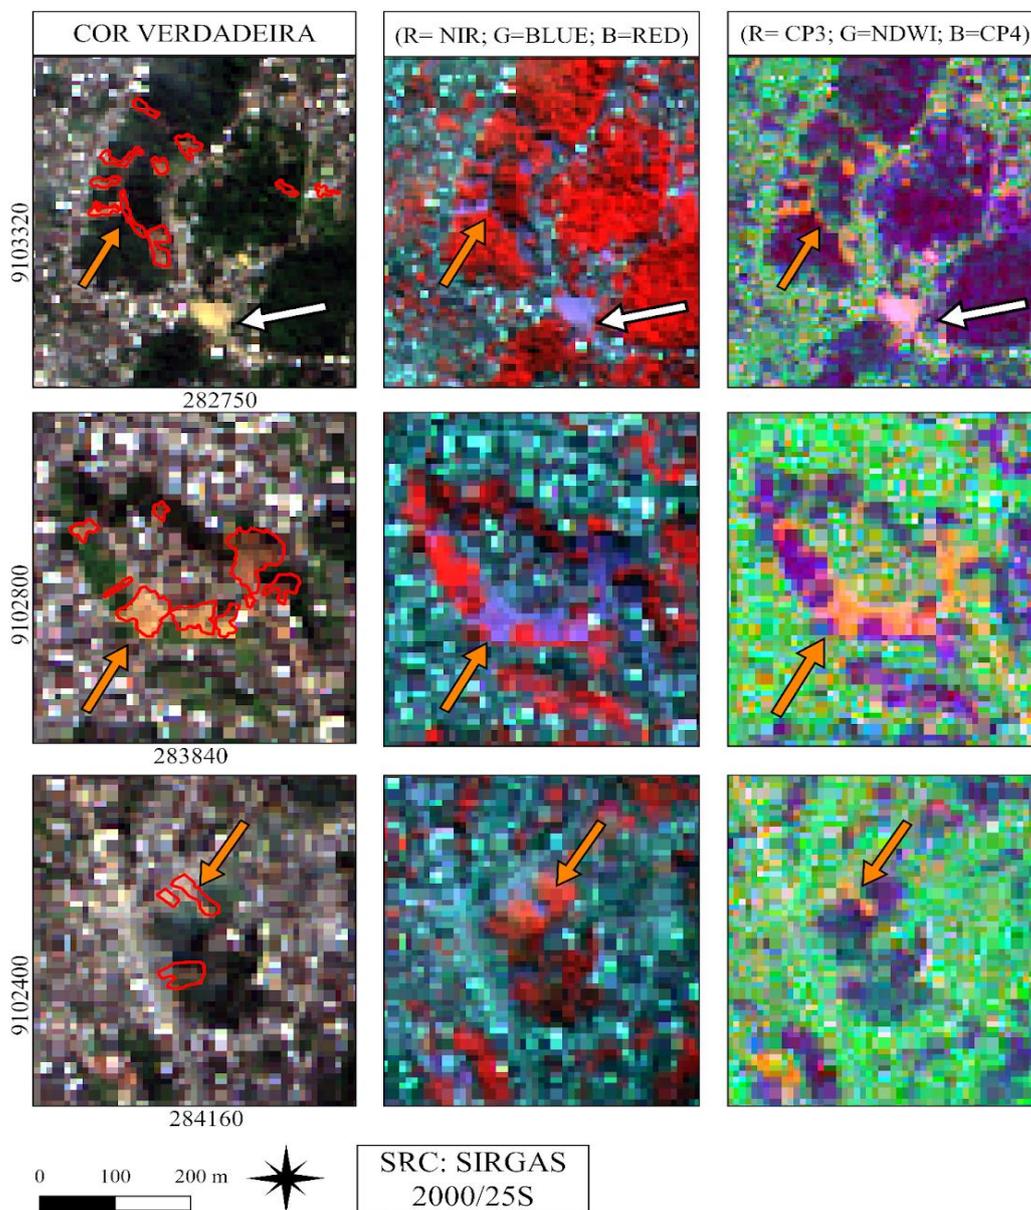
De forma qualitativa, as três possíveis composições (composição em cor verdadeira (321), composição sugerida pelo ranqueamento de quinze atributos (R=CP3, G=NDWI, B=CP4) e composição sugerida pelo ranqueamento de quatro atributos (413) foram comparadas (Figura 5.13). Mesmo com maiores valores de acurácia, os principais alvos de análise da composição falsa cor sugerida pelo empilhamento de quatro atributos (413) não foram visualmente diferenciados, de forma contrária à composição sugerida pelo ranqueamento do empilhamento de quinze.

Figura 5.13 – Composição cor verdadeira (321) e a falsa cor (413) do sensor WPM/CBERS-4A em comparação à composição RGB (CP3, NDWI, CP4) sugerida a partir do ranqueamento OOB dos quinze atributos. Setas laranjas: áreas de deslizamentos mapeadas pela Carta; setas azuis: corpos hídricos; setas brancas: áreas de solo exposto.



Na composição sugerida pelo ranqueamento de quatro atributos (Figura 5.14b), tanto os deslizamentos (setas laranjas) quanto às áreas de solo exposto (setas brancas) apresentaram os mesmos tons de magenta, não sendo portanto visualmente diferenciados. Na composição sugerida pelo ranqueamento de quinze atributos (Figura 5.14c), os deslizamentos passaram a adquirir a coloração laranja e áreas antigas de solo exposto a coloração magenta.

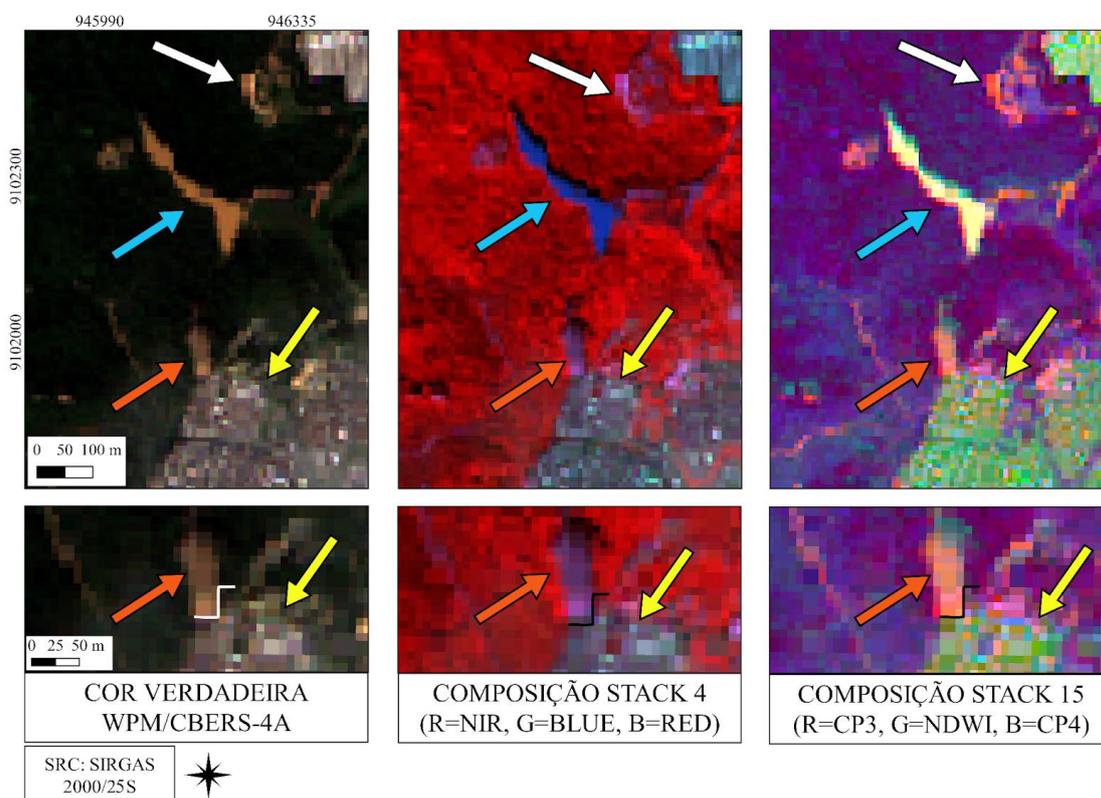
Figura 5.14 – Áreas de deslizamentos e de solo exposto nas três composições avaliadas para o caso dos deslizamentos em Recife (PE). Setas laranjas: áreas de deslizamentos; setas brancas: áreas de solo exposto.



Algumas áreas de solo exposto não foram destacadas em magenta pela composição sugerida pelo ranqueamento de quinze atributos e apresentaram a mesma tonalidade adquirida pelos deslizamentos. Nas áreas onde o solo se apresenta exposto há mais tempo (como o campo de futebol indicado pelas setas brancas da Figura 5.14), a composição foi sensível à variação das propriedades pedológicas. Onde provavelmente o solo foi mobilizado recentemente, a composição não foi capaz de diferenciá-los devido às características muito semelhantes entre os dois alvos. Já na composição sugerida pelo ranqueamento de quatro atributos (de melhor desempenho quantitativo), as variações de solo exposto não apresentaram tons diferentes. Esse resultado pode indicar a sensibilidade maior dos atributos presentes na composição derivada do ranqueamento de quinze às mudanças nas propriedades do solo. Exemplos das áreas correspondentes são apresentados no Apêndice A.3.

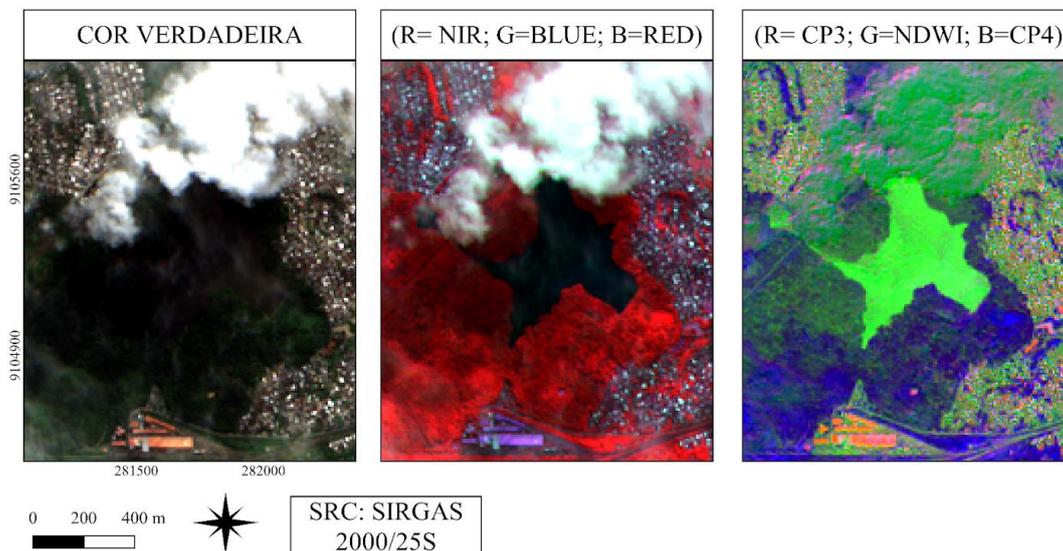
Similarmente, devido à elevada turbidez dos corpos hídricos em períodos chuvosos, o comportamento espectral da concentração de matéria orgânica na água pode ser confundido com a assinatura dos deslizamentos de terra. Esse tipo de caso foi retratado na Figura 5.15, onde tanto na composição em cores verdadeiras do WPM quanto na composição sugerida pelo empilhamento de quatro atributos, um corpo hídrico (indicado pelas setas azuis) foi destacado em tons semelhantes a de um deslizamento (indicado pelas setas laranjas) desencadeado nas proximidades. Já na composição sugerida pelo empilhamento de quinze, de performance quantitativa inferior, tais alvos apresentaram tonalidades diferentes, sendo possível melhor visualizar o limite existente entre as classes. Ainda, o meio urbano (indicado pelas setas amarelas) foi melhor retratado no último caso, pelo contraste obtido pelo posicionamento do NDWI no canal verde de visualização. De acordo com Ho et al. (2010), o padrão de reflectância das áreas urbanas é similar ao da água na faixa do verde. Logo, especificamente nesse caso, o posicionamento do NDWI foi favorável à diferenciação visual entre os deslizamentos e os demais alvos.

Figura 5.15 – Composição em cor verdadeira (321) e em falsa-cor (413) do sensor WPM/CBERS-4A em comparação à composição RGB (CP3, NDWI, CP4), onde o contraste existente entre um corpo hídrico de elevada turbidez e um deslizamento de terra foi melhor evidenciado. Setas laranjas: cicatriz de deslizamento; setas azuis: corpo hídrico; setas brancas: solo exposto; setas amarelas: meio urbano.



Feições sombreadas também foram evidenciadas a partir das duas composições RGB propostas pelo ranqueamento de quatro e quinze atributos. Como mostra a Figura 5.16, um corpo hídrico pôde ser destacado e bem delimitado, considerando a sua visualização comprometida em cor verdadeira (321). Tal resultado pode ser associado ao espalhamento atmosférico, que é significativo na faixa do azul e tende a diminuir à medida que o comprimento de onda aumenta. Logo, com a manipulação do infravermelho nas duas composições sugeridas, o efeito do espalhamento é minimizado e a feição sombreada delimitada. Essa informação pode ser útil para a possível visualização de cicatrizes de deslizamentos em áreas sombreadas, diminuindo as desvantagens de uma imagem com uma elevada cobertura de nuvens.

Figura 5.16 – Visualização de área sombreada a partir das composições em cor verdadeira (321), em falsa-cor (413) e a sugerida pelo ranqueamento OOB de quinze atributos (R=CP3, G=NDWI, B=CP4), obtidas a partir de dados do sensor WPM/CBERS-4A.



Diante dos produtos extraídos dos dados do WPM, pela menor resolução espacial (8 m), a identificação dos deslizamentos é facilitada já na interpretação das possíveis composições RGB geradas a partir bandas originais. Já no caso dos dados do MUX, que apresentam uma menor resolução espacial (16,5 m), o mapeamento de alvos pontuais e de pequenas extensões é dificultado. Porém, considerando as vantagens observadas com a utilização dos atributos extraídos do empilhamento de quinze atributos em Recife, uma perspectiva mais aprofundada da área pode ser estabelecida tal como a avaliação de áreas sombreadas, de corpos hídricos de elevada turbidez e ainda da separabilidade entre solo exposto e deslizamentos em áreas complexas e de difícil interpretação.

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

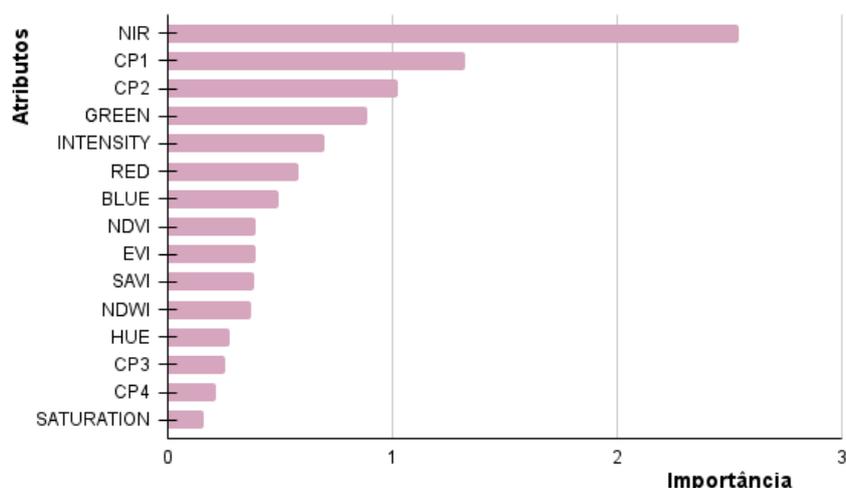
Assim como no caso dos deslizamentos, após os procedimentos metodológicos de pré-processamento e extração de atributos, o cubo de dados contendo os 15 produtos derivados do sensor WFI/CBERS-4 foi classificado pelo RF. Um total de 300 amostras foram coletadas aleatoriamente dentro do polígono caracterizado como regiões inundadas (808.882 km²) pela Carta, e 300 amostras aleatórias coletadas fora desta grande área.

Neste caso, três vetorizações foram realizadas pela Carta no período do evento a partir de imagens de diferentes satélites, sendo eles: o NOAA-20/VIIRS, com resolução espacial de 375 metros; o MSI/Sentinel-2, com resolução espacial de 10 metros; e o *Planet* de 3 metros de resolução. Na presente pesquisa, o polígono de inundação utilizado como referência principal foi o extraído pelo NOAA-20/VIIRS, devido à capacidade de processamento de dados de uma área tão extensa.

5.3.1 Ranqueamento dos atributos a partir da classificação RF

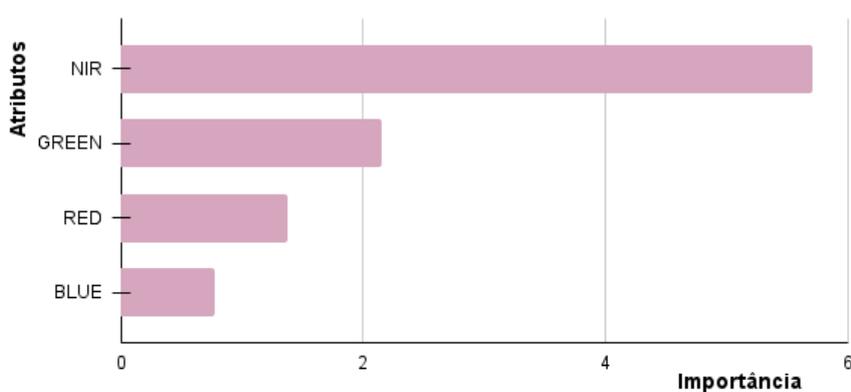
O ranqueamento dos quinze atributos para o caso da Bahia foi obtido com uma exatidão OOB de 87,76% (Figura 5.17). Na cena avaliada, a banda do NIR, a CP1 e a CP2 foram os atributos de maior relevância na classificação.

Figura 5.17 – Ranqueamento de importância/relevância dos quinze atributos extraídos para o estudo de caso da inundação regional no Paquistão, a partir da análise das amostras OOB.



A classificação supervisionada também foi aplicada às quatro bandas originais do sensor WFI/CBERS-4 (RED, GREEN, BLUE e NIR, identificados pelos números 15, 14, 13 e 16, respectivamente). De acordo com o ranqueamento OOB (Figura 5.18), a banda NIR apresentou um desempenho significativo para a identificação de áreas inundadas, assim como no ranqueamento de quinze atributos (Figura 5.17).

Figura 5.18 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor WFI/CBERS-4 para o estudo de caso da inundação regional em Sind, Balochistan e Punjab (Paquistão), a partir da análise das amostras OOB.



A relevância do atributo 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 estatísticas calculadas, o empilhamento de quatro atributos apresentou valores de acurácia menores do que os obtidos a partir da classificação do empilhamento de quinze (Tabela 5.6).

Tabela 5.6 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do WFI/CBERS-4 para o caso da inundação regional em Sind, Balochistan e Punjab (Paquistão).

WFI/CBERS-4 (PAQUISTÃO)	EXATIDÃO OOB	MÉTRICAS EXTRAÍDAS A PARTIR DA MATRIZ DE CONFUSÃO			
		AG	P	R	F1 - score
Empilhamento de quatro atributos	87,52%	87,77%	0,875	0,877	0,876
Empilhamento de quinze atributos	87,76%	88,33%	0,883	0,880	0,881

Sobre a ordem de importância dos demais atributos do empilhamento de quinze (Figura 5.17), a CP1 e a CP2 ocuparam o segundo e terceiro lugar na mineração de dados, 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 diretamente dependentes das características espectrais da cena avaliada, as informações de interesse da classificação nesse caso se concentraram já nas primeiras componentes pela grande predominância de pixels de água no recorte analisado. Como indicado na Tabela 5.7, a CP1 e a CP2 explicam 82,93% e 15,19% da variância total dos dados.

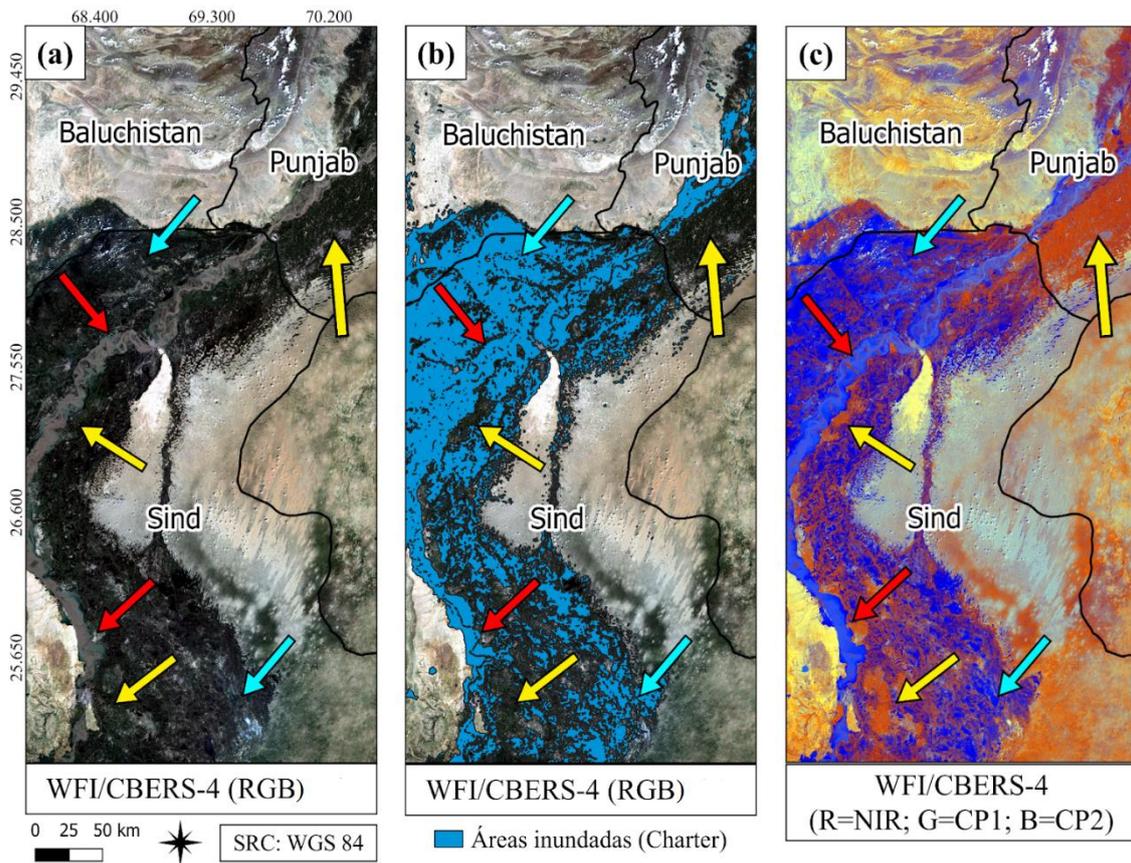
Tabela 5.7 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes extraídas das bandas do sensor WFI/CBERS-4.

COMPONENTES PRINCIPAIS (WFI/CBERS-4)	AUTOVALORES (%)	AUTOVETORES			
		BLUE	GREEN	RED	NIR
CP1	82,93	0,439	0,438	0,635	0,460
CP2	15,19	-0,262	-0,198	-0,323	0,886
CP3	1,77	-0,767	-0,119	0,629	-0,023
CP4	0,08	-0,386	0,868	-0,308	-0,032

5.3.2 Detecção da inundação regional

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 (NIR, CP1, CP2) de melhor correspondência visual dos alvos de interesse. A vetorização realizada a partir de imagens do sensor NOAA-20/VIIRS (375 m) foi sobreposta à composição em cor verdadeira (15,14,13) do sensor WFI/CBERS-4 (Figura 5.19).

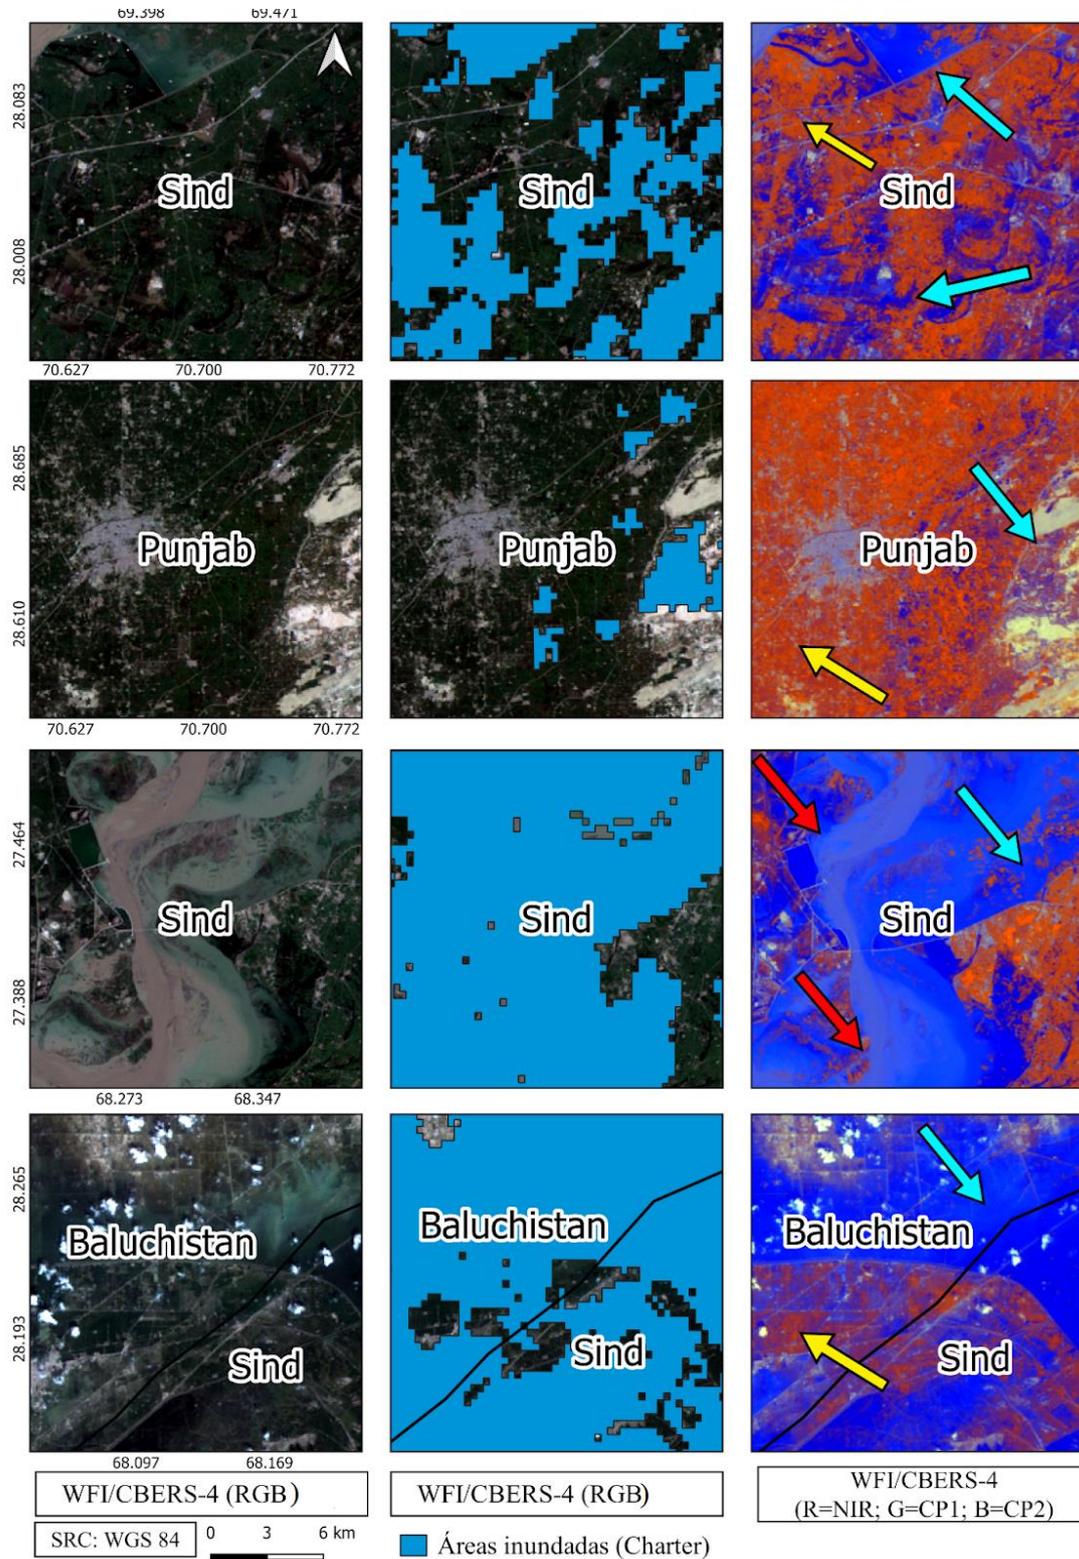
Figura 5.19 – Composição RGB (NIR, CP1, CP2) sugerida a partir do ranqueamento OOB dos quinze atributos para o caso da inundação regional no Paquistão. Setas azuis: áreas inundadas; setas amarelas: áreas não-inundadas; setas vermelhas: rio principal.



Na composição em cor verdadeira (Figura 5.19a), comparando com a vetorização das áreas inundadas mapeadas pela Carta (Figura 5.19b), nota-se que as regiões indicadas pelas setas amarelas não apresentaram 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 áreas inundadas (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.

Diminuindo a escala de visualização (Figura 5.20), as áreas de referência inundadas coincidiram com as áreas em azul destacadas predominantemente pela CP2. Em decorrência da diferença de resolução espacial entre o NOAA-20/VIIIRS (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 do sensor brasileiro. Destaca-se ainda que, após a avaliação qualitativa das combinações entre os três principais atributos selecionados, a banda do NIR foi estrategicamente posicionada no canal vermelho de visualização para que as áreas inundadas adquirissem a tonalidade azul (coloração comumente utilizada para a identificação de áreas inundadas nos mapas geográficos).

Figura 5.20 – Áreas inundadas destacadas em tons de azul na composição RGB (NIR, CP1, CP2) sugerida, em comparação com a composição RGB (15,14,13) do WFI/CBERS-4 sobreposta à vetorização realizada pela Carta. Setas azuis: áreas inundadas; setas amarelas: áreas não-inundadas.



Diante dos produtos gerados a partir das imagens do WFI/CBERS-4, comprova-se que para esse tipo de desastre da ordem de milhares de quilômetros quadrados, a utilização de uma imagem de resolução espacial maior pode ser muito vantajosa. O tamanho do pixel não é útil para a visualização de detalhes, porém possibilita uma rápida visão geral da área inundada, a identificação das cidades em estado de risco, além de um monitoramento urgente do direcionamento e do progresso da inundação regional. Uma avaliação complementar do desempenho do WFI para a identificação de áreas inundadas está apresentada no Apêndice A.4.

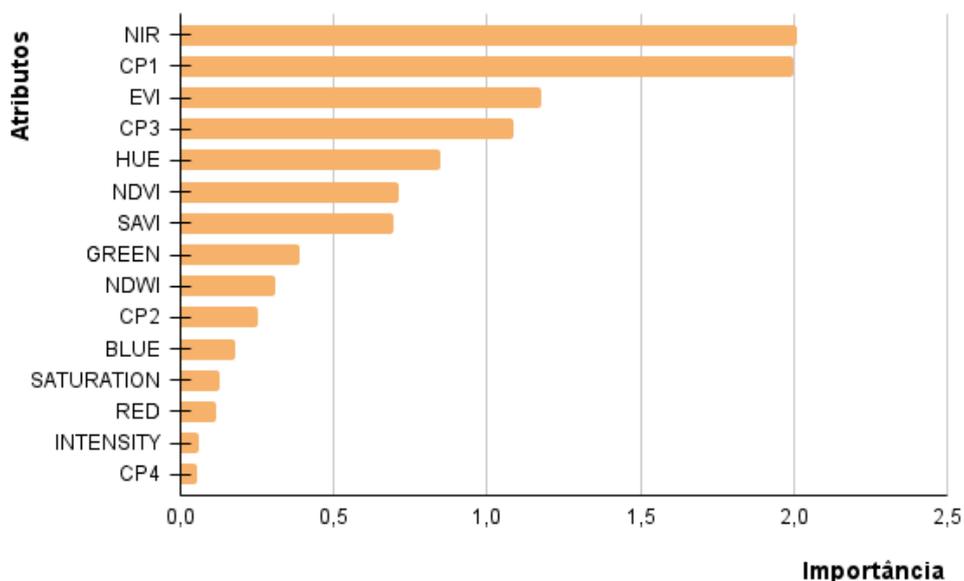
5.4 Inundação regional em Itamaraju e Prado (Rio Jucuruçu-BA)

Como último caso de estudo, os produtos extraídos das quatro bandas do sensor WFI/AMAZONIA-1 foram utilizados para a avaliação da inundação regional no sul da Bahia. No total, 174 amostras aleatórias foram coletadas na cena avaliada, sendo 87 no interior dos 29 polígonos de áreas inundadas e 87 nas áreas não-inundadas. Tal amostragem se deu a partir da comparação visual de imagens do WFI/CBERS-4A e do WFI/AMAZONIA-1 pré e pós-evento. Como não há vetorização de referência da Carta neste caso de estudo, a análise foi realizada baseando-se em imagens pré-evento e fotografias aéreas disponibilizadas pelo Portal Oficial do Estado da Bahia (GOVBA).

5.4.1 Ranqueamento dos atributos a partir da classificação RF

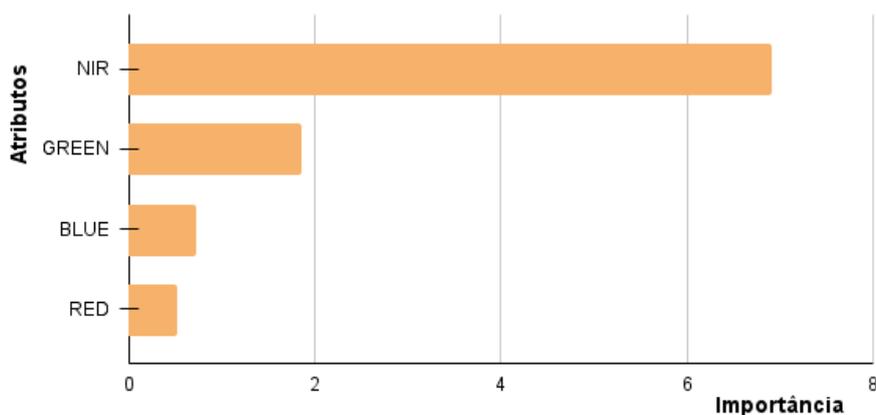
Para a detecção das áreas inundadas, o ranqueamento dos quinze atributos foi obtido (Figura 5.21), com uma exatidão de 97,5% calculada a partir das amostras OOB. Os três atributos mais relevantes da cena avaliada foram: o NIR, a CP1 e o índice EVI.

Figura 5.21 – Ranqueamento de importância/relevância do empilhamento dos quinze atributos extraídos para o estudo de caso da inundação regional em Itamaraju e Prado (BA), a partir da análise das amostras OOB.



A classificação supervisionada também foi aplicada no empilhamento de quatro atributos, considerando apenas a análise das bandas originais do sensor WFI/AMAZONIA-1 (RED, GREEN, BLUE e NIR, identificadas como 7, 6, 5 e 8, respectivamente). Como retratado na Figura 5.22, o NIR foi o atributo de maior influência na classificação, seguido pelo GREEN, BLUE e RED em sequência.

Figura 5.22 – Ranqueamento de importância/relevância do empilhamento das quatro bandas originais do sensor WFI/AMAZONIA-1 para o estudo de caso da inundação regional em Itamaraju e Prado (BA), a partir da análise das amostras OOB.



Igualmente ao caso do Paquistão, nas duas classificações a banda do NIR e a CP1 (Tabela 5.8) apresentaram uma maior relevância na identificação de áreas inundadas devido ao melhor desempenho na separabilidade das duas classes avaliadas (áreas inundadas e áreas não-inundadas). Sobre as métricas estatísticas calculadas em ambos os casos, o uso de quatro atributos apresentou valores de acurácia relativamente menores do que os obtidos a partir dos quinze (Tabela 5.9).

Tabela 5.8 – Autovalores e autovetores da matriz de variância-covariância das 4 componentes principais extraídas das bandas do sensor WFI/AMAZONIA-1.

COMPONENTES PRINCIPAIS (WFI/AMAZONIA-1)	AUTOVALORES (%)	AUTOVETORES			
		BLUE	GREEN	RED	NIR
CP1	74,44	0,511	0,507	0,613	0,322
CP2	24,40	-0,178	-0,120	-0,248	0,944
CP3	0,97	-0,745	-0,065	0,663	0,025
CP4	0,17	0,388	-0,850	0,349	0,057

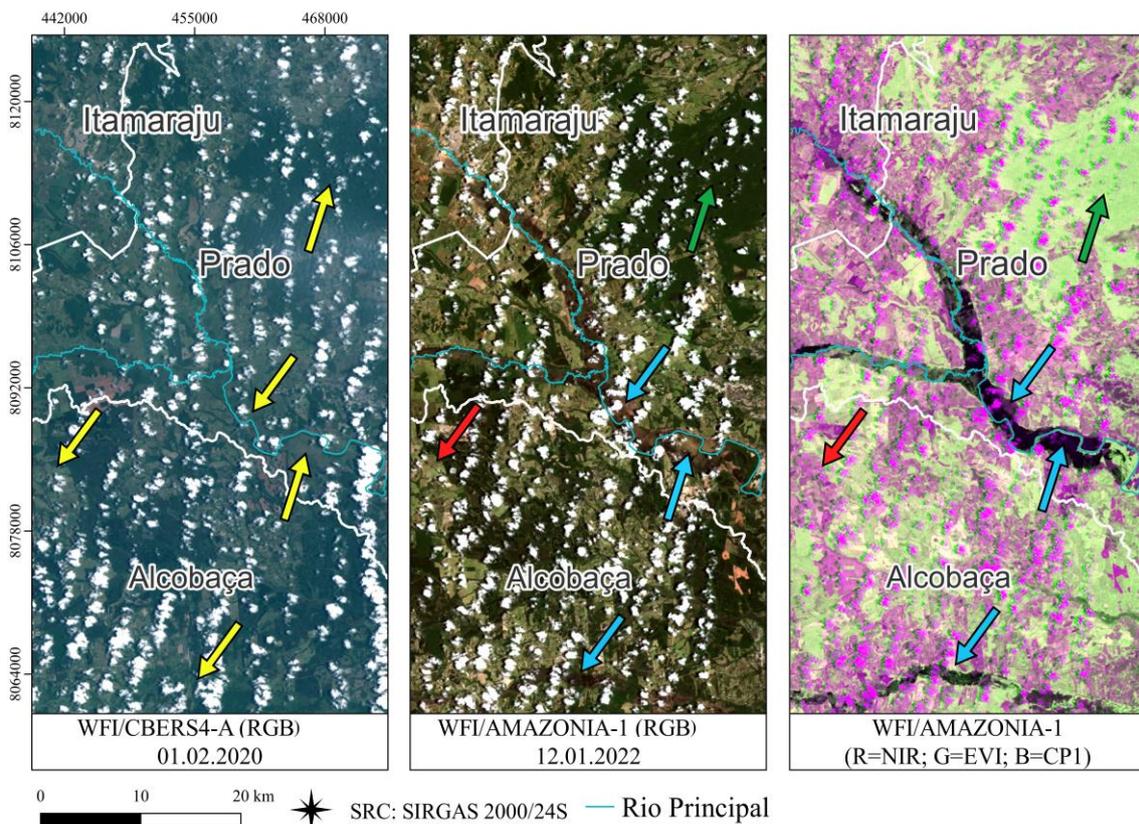
Tabela 5.9 – Valores de acurácia da classificação RF utilizando quatro e quinze atributos derivados do sensor WFI/AMAZONIA-1 para o caso da inundação regional em Itamaraju e Prado (BA).

WFI/AMAZONIA-1 (ITAMARAJU E PRADO)	EXATIDÃO OOB	MÉTRICAS EXTRAÍDAS A PARTIR DA MATRIZ DE CONFUSÃO			
		AG	P	R	F1 - score
Empilhamento de quatro atributos	95,83%	96,15%	0,960	0,965	0,961
Empilhamento de quinze atributos	97,5%	98,08%	0,979	0,982	0,980

5.4.2 Detecção da inundação regional

As três principais bandas ranqueadas pela análise das amostras OOB do empilhamento de quinze atributos, pelo melhor desempenho quantitativo, foram combinadas no espaço RGB de cores (R=NIR, G=EVI, B=CP1), retratado na Figura 5.23. A dimensão do grande transbordamento do Rio Jucuruçu foi identificada em tons escuros (pela participação da CP1), as áreas densamente vegetadas em tons de verde (devido à influência do EVI posicionado na faixa verde de visualização) e as áreas com pouca ou nenhuma vegetação em tons de magenta (indicando a representação do NIR e da CP1 posicionados nas faixas do vermelho e azul, respectivamente).

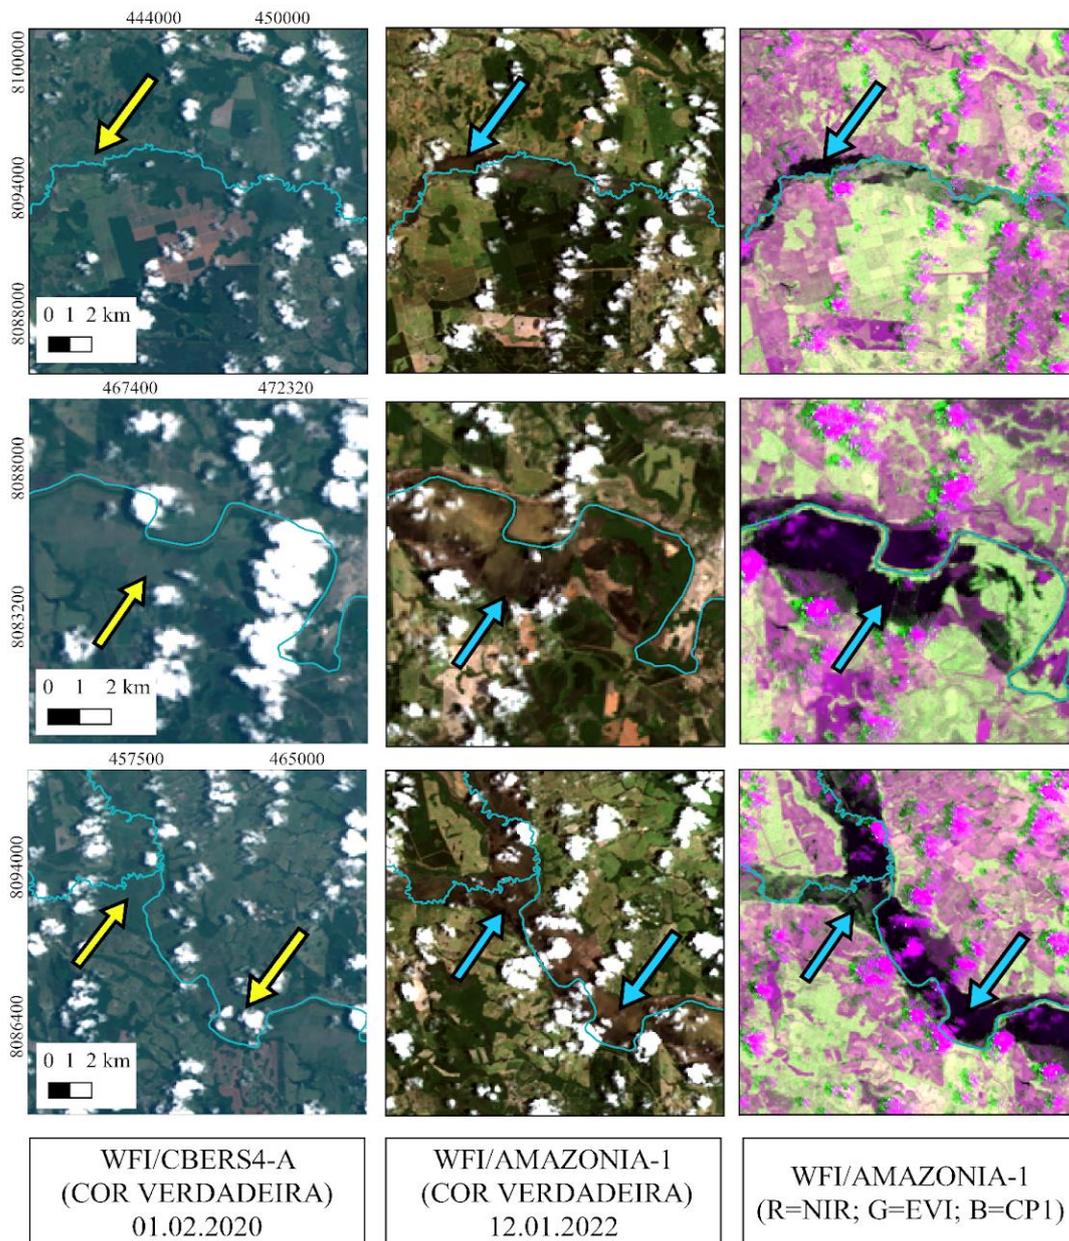
Figura 5.23 – Áreas inundadas destacadas em tons escuros na composição RGB (R=NIR, G=EVI, B=CP1) sugerida a partir do ranqueamento de 15 atributos, em comparação com as composições em cor verdadeira de pré e pós-evento do WFI/CBERS4-A e do WFI/AMAZONIA-1. Setas azuis: áreas inundadas pós-evento; setas amarelas: localização das mesmas áreas na imagem pré-evento. Setas verdes: áreas densamente vegetadas; setas vermelhas: áreas com pouca ou nenhuma vegetação.



Destaca-se que a obtenção de informações extraídas de dados ópticos para a avaliação de grandes inundações normalmente é afetada pela cobertura de nuvens devido ao cenário chuvoso característico. Neste caso de Itamaraju e Prado, a densidade de nuvens na cena não limitou a visualização do delineamento da inundação, tanto devido ao contraste estabelecido entre os alvos na composição sugerida, quanto pela proporção significativa do evento. Logo, reduzindo a escala de visualização (Figura 5.24), na composição RGB (R=NIR, G=EVI, B=CP1), as nuvens passaram a adquirir os mesmos tons em magenta das demais áreas com pouca ou nenhuma vegetação e as suas sombras destacadas em tons de verde, contribuindo para a separabilidade dos alvos e direcionamento visual rápido das áreas potencialmente atingidas.

Devido à pequena largura entre as margens do rio Jucuruçu (em torno de 40 metros, medida e vetorizada a partir de imagens do *Google Earth*), a visualização da extensão do leito do rio principal foi dificultada em vista à resolução espacial do WFI, diferentemente do caso de estudo anterior (largura em torno de 2160 metros entre as margens do rio Indus - Paquistão). Tal resultado implica na importância da disponibilização de arquivos vetoriais pré-estabelecidos dos corpos hídricos para análises emergenciais.

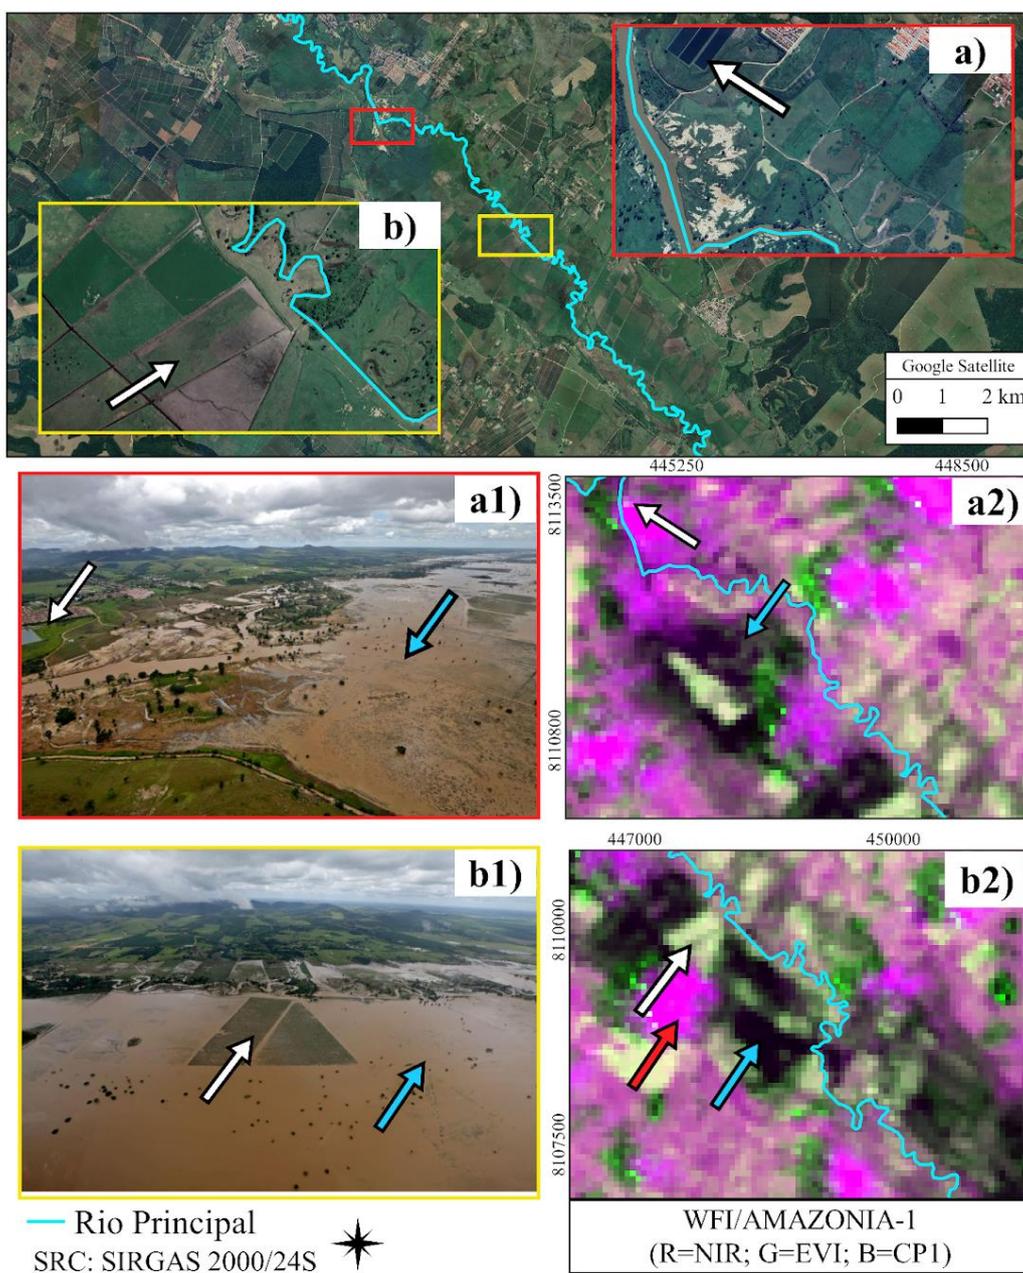
Figura 5.24 – Áreas inundadas destacadas em tons escuros na composição RGB (R=NIR, G=EVI, B=CP1) sugerida a partir do ranqueamento de 15 atributos. As nuvens passaram a adquirir os mesmos tons de magenta das áreas com pouca ou nenhuma vegetação. Setas azuis: áreas inundadas pós-evento; setas amarelas: localização das mesmas áreas na imagem pré-evento.



SRC: SIRGAS 2000/24S — Rio Principal

Como no caso da Bahia não há referência da Carta para a identificação regional das áreas inundadas, algumas fotografias aéreas foram associadas às áreas identificadas como potencialmente inundadas pela composição de melhor performance quantitativa (R=NIR, G=EVI, B=CP1). Como indicado na Figura 5.25, as áreas inundadas foram diferenciadas das áreas vegetadas, não vegetadas e do meio urbano ao adquirirem tons escuros na imagem. Complementarmente, sabendo-se que as águas das inundações se elevam e recuam de forma gradual, com a resolução temporal de cinco dias do WFI/AMAZONIA-1, o acompanhamento da dinâmica da inundação pode ser realizado em um menor intervalo de tempo, considerando o início do evento até o escoamento total da água. Dados hidrometeorológicos das bacias hidrográficas associadas também podem ser integrados e, de forma conjunta, um banco de séries históricas da área pode ser desenvolvido (SAUSEN et al., 2015).

Figura 5.25 – Comparação entre a composição RGB sugerida (R=NIR, G=EVI, B=CP1); e as fotografias aéreas (MANU DIAS/GOVBA). Em a1 e b1: exemplos de áreas inundadas registradas por fotografias aéreas. Em a2 e b2: localização das mesmas áreas das fotografias, com base na composição sugerida pelo empilhamento de quinze atributos. Setas brancas: áreas de referência, setas azuis: áreas inundadas; seta vermelha: presença de nuvens.



6 CONCLUSÃO

Os resultados apresentados confirmam a utilidade dos sensores brasileiros para análises emergenciais de deslizamentos de terra e de inundações regionais, considerando o conhecimento adequado das suas propriedades temporais, espectrais e espaciais. Se o período de ocorrência do desastre avaliado coincidir com a disponibilidade das imagens, a exploração dos dados com a aplicação das técnicas de PDI pode contribuir para a geração de respostas rápidas, tanto para os chamados da Carta quanto para outras eventuais solicitações de emergência. Assim, conclui-se que:

- a) Para a análise de deslizamentos de terra em Petrópolis (RJ), a classificação supervisionada utilizando o algoritmo RF apresentou um desempenho 4% superior quando aplicada ao empilhamento dos quinze atributos extraídos do sensor MUX/CBERS-4A (AG=81,82%; OOB=83,11%; F1-score=0,81801), em comparação ao empilhamento das quatro bandas originais apenas (AG=77,78%; OOB=80,95%; F1-score=0,77666). A terceira componente principal (CP3), o índice SAVI e a componente *Hue* da transformação RGB-IHS, foram os três principais atributos estabelecidos pelo RF, de melhor desempenho na separabilidade das áreas de deslizamento e não-deslizamento. Mesmo confundindo algumas áreas recentes de solo exposto, a CP3 revelou a maioria das cicatrizes de referência mapeadas pela Carta, sendo estas destacadas em tons de laranja com o posicionamento da CP3 na faixa vermelha de visualização da composição RGB proposta (R=CP3, G=SAVI, B=HUE). Também com a contribuição da componente *Hue*, os “clarões” presentes na composição em cor verdadeira passaram a adquirir tons diferentes das áreas de deslizamento. Logo, o contraste estabelecido entre os atributos destacou os principais alvos de interesse, sem a necessidade da aplicação de limiares.
- b) Para a análise dos deslizamentos em Recife (PE), o RF apresentou resultados quantitativos superiores (cerca de 2%) na classificação do empilhamento das quatro bandas originais do sensor WPM/CBERS-4A (AG=78,64%; OOB=73,22%; F1-score=0,78623), em comparação à

classificação do empilhamento de quinze (AG=76,69%; OOB=77,82%; F1-score=0,76644). A composição em cor verdadeira, a composição sugerida pelo *ranqueamento* estabelecido a partir do empilhamento de quatro atributos (R=NIR, G=BLUE, B=RED) e pelo *ranqueamento* resultante do empilhamento de quinze atributos (R=CP3, G=NDWI, B=CP4) foram comparadas, sendo a composição derivada dos quinze atributos a de melhor desempenho qualitativo em relação à separabilidade de áreas de solo exposto e de corpos hídricos de elevada turbidez. As duas composições falsas-cor sugeridas foram capazes de revelar áreas sombreadas, de pouca ou nenhuma visualização na composição em cor verdadeira. Devido à maior resolução espacial, as áreas de deslizamentos puderam ser melhor identificadas pelo sensor WPM quando comparado ao sensor MUX.

- c) A classificação RF apresentou métricas estatísticas muito semelhantes tanto para o empilhamento de quinze (AG=88,33%; OOB=87,76%; F1-score=0,88140) quanto para o de quatro atributos (AG=87,77%; OOB=87,52%; F1-score=0,87654), extraídos do sensor WFI/CBERS-4, no caso da inundação regional que atingiu as três províncias do Paquistão. Tal resultado se deu provavelmente pelo desempenho predominante da banda do NIR no *ranqueamento* OOB obtido em ambos os casos. Na composição sugerida avaliada (R=NIR, G=CP1, B=CP2), as áreas inundadas foram reveladas, sendo então diferenciadas dos demais alvos presentes na cena.
- d) Devido à ausência de vetorização de referência, com base na comparação de imagens pré e pós-evento, o RF selecionou igualmente a banda do NIR como atributo de melhor desempenho na identificação da inundação regional em Itamaraju e Prado (BA). Este resultado foi obtido tanto a partir do empilhamento de quinze (AG=98,08%; OOB=97,5%; F1-score=0,9805) quanto do empilhamento das quatro bandas originais do WFI/AMAZONIA-1 (AG=96,15%; OOB=95,83%; F1-score=0,96131).

- e) As componentes principais apresentaram significativa relevância na avaliação dos casos, estando presentes em todos os resultados obtidos pela classificação.
- f) Uma maior exploração da transformação RGB-IHS, incluindo a banda do NIR no processo, é uma alternativa para o aprimoramento da metodologia, assim como a aplicação da segmentação a partir da contribuição dos atributos mais relevantes para a identificação de deslizamentos e inundações regionais.

Portanto, tendo-se um conhecimento prévio do tipo de desastre avaliado e das técnicas de PDI aplicáveis às propriedades específicas dos sensores brasileiros, a aplicação direta das composições propostas podem facilitar o mapeamento de áreas complexas e potencialmente atingidas por eventos extremos, propiciando a exploração de dados adicionais às quatro bandas originais dos sensores disponíveis. O fornecimento rápido de produtos especializados pode contribuir para a avaliação da magnitude do impacto do desastre, além de conduzir as atividades de campo de forma mais otimizada e servir como ferramenta para a obtenção rápida de recursos governamentais.

REFERÊNCIAS BIBLIOGRÁFICAS

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.

AHMED, Z. Disaster risks and disaster management policies and practices in Pakistan: a critical analysis of Disaster Management Act 2010 of Pakistan. **International Journal of Disaster Risk Reduction**, v. 4, p. 15-20, 2013. Disponível em: <https://doi.org/10.1016/j.ijdrr.2013.03.003>.

ALHEIROS, M.M. **Risco de escorregamentos na Região Metropolitana do Recife**. 1998. 129p. Tese (Doutorado em Geologia) - Universidade Federal da Bahia, Salvador, 1998.

AMARNATH, G. An algorithm for rapid flood inundation mapping from optical data using a reflectance differencing technique. **Journal of Flood Risk Management**, v. 7, n. 3, p. 239-250, 2014. Disponível em: <https://doi.org/10.1111/jfr3.12045>.

AZADLI, H.; BARTALI, A. A.; NOOGHABI, S.; SCHEFFRAN, J. Climate-related disasters and agricultural land conversion: towards prevention policies. **Climate and Development**, 2022. Disponível em: <https://doi.org/10.1080/17565529.2021.2008291>.

BAN, H. J.; KWON, Y. J.; SHIN, H.; RYU, H. S.; HONG, S. Flood monitoring using satellite-based RGB composite imagery and refractive index retrieval in visible and near-infrared bands. **Remote Sensing**, v.9, n.4, e 313, 2017. Disponível em: <https://doi.org/10.3390/rs9040313>.

BARROS M. L. **Chuva atinge 36 cidades de Pernambuco e enchentes deixam quase 10 mil pessoas fora de casa**. BF. Jul/ 2022. Disponível em: <https://www.brasildefato.com.br/2022/07/05/chuva-atinge-36-cidades-de-pernambuco-e-enchentes-deixam-quase-10-mil-pessoas-fora-de-casa#:~:text=Desde%20a%20%C3%BAltima%20quinta%2Dfeira,moradores%20fora%20de%20suas%20casas>.

BERNARDO, N.; WATANABE, F.; RODRIGUES, T.; ALCÂNTARA, E. Atmospheric correction issues for retrieving total suspended matter concentrations in inland waters using OLI/Landsat-8 image. **Advances in Space Research**, v.59, p.2335-2348, 2017. Disponível em: <https://doi.org/10.1016/j.asr.2017.02.017>.

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.

BHANDARI, A.; KUMAR, A.; SINGH, G. Feature extraction using normalized difference vegetation index (ndvi): a case study of jabalpur city. **Procedia Technology**, v. 6, p. 612–621, 2012. Disponível em: <https://doi.org/10.1016/j.protcy.2012.10.074>.

BEHLING, R.; ROESSNER, S.; KAUFMANN, H.; KLEINSCHMIT, B. Automated spatiotemporal landslide mapping over large areas using rapideye time series data. **Remote Sensing**, v. 6, n.9, p.8026-8055, 2014. Disponível em: <https://doi.org/10.3390/rs6098026>.

BIGARELLA, J. J.; BECKER, R. D.; PASSOS, E. **Estrutura e origem das paisagens tropicais e subtropicais**. Florianópolis: UFSC, 2003. p. 1026-1098.

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. Disponível em: [10.1007/978-3-319-09048-1_3](https://doi.org/10.1007/978-3-319-09048-1_3).

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5-32, 2001.

BRUBACHER, J. P. **Inundações e enxurradas, município de Esteio-RS**. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

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. Disponível em: <http://dx.doi.org/10.1590/S1982-21702015000400038>.

CASTRO, L.A. **Manual de planejamento em defesa civil**. Brasília: Imprensa Nacional, 1999. Disponível em: <http://cidbimena.desastres.hn/docum/crid/Marzo2004/pdf/por/doc10498/doc10498-1a.pdf>. Acesso em: 05 fev. 2022.

CASTRO, T. O.; NASCIMENTO, B. F. O.; TORRES, F. S. Inundações urbanas na cidade de vitória da conquista, estado da Bahia. In: CONGRESSO BRASILEIRO DE GESTÃO AMBIENTAL, 2015. **Anais...** 2015. Disponível em: <https://www.ibeas.org.br/congresso/Trabalhos2015/IX-003.pdf>.

CATANI, F.; LAGOMARSINO, D.; SEGONI, S.; TOFANI, V. Landslide susceptibility estimation by random forests technique: sensitivity and scaling issues. **Natural Hazards and Earth System Sciences**, v. 13, n. 11, p. 2815–2831, 2013.

CELIK, S.; CORBACIOGLU, S. Role of information in collective action in dynamic disaster environments. **Disasters**, v. 34, p.137-154, 2010. Disponível em: <https://doi.org/10.1111/j.1467-7717.2009.01118.x>.

CELIK, T. Unsupervised change detection in satellite images using principal component analysis and k-means clustering. **IEEE Geoscience and RemoteSensing Letters**, 2009. Disponível em: 10.1109/LGRS.2009.2025059.

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>.

CENTRE FOR RESEARCH ON THE EPIDEMIOLOGY OF DISASTERS, UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION (UNDRR). **The human cost of disasters**. An overview of the last 20 years (2000–2019). [S. I.]: UNDRR, 2020.

CENTRO NACIONAL DE MONITORAMENTO E ALERTA DE DESASTRES NATURAIS (CEMADEN). **Anuário da sala de situação do CEMADEN 2017**. Disponível em: http://www2.cemaden.gov.br/wp-content/uploads/2020/06/Anuario_Sala_Situa%C3%A7%C3%A3o_2017.pdf.

CHANG, S. E.; STONE, J.; DEMES, K.; PISCITELLI, M. Consequences of oil spills: a review and framework for informing planning. **Ecology and Society**, v. 19, e 26, 2014. Disponível em: <http://dx.doi.org/10.5751/ES-06406-190226>.

CHATFIELD, C.; COLLINS, A. J. **Introduction to multivariate analysis**. [S.I.]: Chapman and Hall, 1986.

CHAVEZ JR., P. S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, n. 3, p. 459-479, 1988. Disponível em: [https://doi.org/10.1016/0034-4257\(88\)90019-3](https://doi.org/10.1016/0034-4257(88)90019-3).

CHEN, Y. E. et al. Identifying the influence of natural disasters on technological innovation. **Economic Analysis and Policy**, v. 70, p. 22-36, 2021. Disponível em: <https://doi.org/10.1016/j.eap.2021.01.016>.

CHENG, Y. S.; YU, T. T.; SON, N. T. Random forests for landslide prediction in Tsengwen River Watershed, Central Taiwan. **Remote Sensing**, v. 13, n. 2, p. 199, 2021. Disponível em: <https://doi.org/10.3390/rs13020199>.

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. Disponível em: <https://doi.org/10.1007/s13753-019-00232-2>.

CHUVIECO E.; HUETE A. **Fundamentals of satellite remote sensing**. Boca Raton (FL): Taylor & Francis, 2002.

COLTIN, B.; MCMICHAEL, S.; SMITH, T.; FONG, T. Automatic boosted flood mapping from satellite data. **International Journal of Remote Sensing**, v. 37, n. 5, p. 993-1015, 2016. Disponível em: <https://doi.org/10.1080/01431161.2016.1145366>.

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**. Campinas: Unicamp, 1999.

CUTLER, D. R.; EDWARDS JUNIOR, T. C.; BEARD, K. H.; CUTLER, A.; HESS, K. T.; GIBSON, J.; LAWLER, J. J. Random forests for classification in ecology. **Ecology**, v. 88, n.11, p.2783-2792, 2007. Disponível em: <https://doi.org/10.1890/07-0539.1>.

DAVIES, R. South Africa; evacuations after more flooding in KwaZulu-Natal. **Floodlist**. Disponível em: <https://floodlist.com/africa/south-africa-floodi-kwazulu-natal-may-2022>. Acesso em: 8 ago. 2022.

DEEN, S. Pakistan 2010 floods: policy gaps in disaster preparedness and response. **International journal of disaster risk reduction**, v. 12, p. 341-349, 2015. Disponível em: <https://doi.org/10.1016/j.ijdr.2015.03.007>.

DENIS, G. 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. Disponível em: <https://doi.org/10.1016/j.actaastro.2016.06.012>.

DENG, J. S. et al. PCA-based land-use change detection and analysis using multitemporal and multisensor satellite data. **International Journal of Remote Sensing**, v. 29, n. 16, p. 4823-4838, 2008. Disponível em: <https://doi.org/10.1080/01431160801950162>.

DIMITRIADIS, P.; TEGOS, A.; OIKONOMOU, A.; PAGANA, V.; KOUKOUVINOS, A., MAMASSIS, N.; EFSTRATIADIS, A. Comparative evaluation of 1D and quasi-2D hydraulic models based on benchmark and real-world applications for uncertainty assessment in flood mapping. **Journal of Hydrology**, v. 534, p. 478-492, 2016. Disponível em: <https://doi.org/10.1016/j.jhydrol.2016.01.020>.

DOMENEGHETTI, A.; SCHUMANN, G. J.-P.; TARPANELLI, A. Preface: remote sensing for flood mapping and monitoring of flood dynamics. **Remote Sensing**, v. 11, n. 8, p. 943, 2019. Disponível em: <https://doi.org/10.3390/rs11080943>.

DOS SANTOS OLIVEIRA, L.; FERREIRA, B. C; ESTEVAM, A. L. D. Enchentes na cidade de Salvador, Bahia (Brasil): estudos geográficos nos rios urbanos Luísa e Camarajipe. **Brazilian Journal of Development**, v. 7, n. 1, p. 10551-10571, 2021. Disponível em: <https://doi.org/10.34117/bjdv7n1-721>.

ECO.A. **Inundações urbanas são agravadas por danos à infraestrutura natural**. Ecologia e Ação. 2022. Disponível em: <https://ecoa.org.br/inundacoes-urbanas-sao-agravadas-por-danos-a-infraestrutura-natural/>.

EPIPHANIO, J. C. N. CBERS-3/4: características e potencialidades. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/07.14.19.08/doc/p1222.pdf>.

ESTORNELL, J. et al. Principal component analysis applied to remote sensing. **Modelling in Science Education and Learning**, v. 6, p. 83-89, 2013.

EUROPEAN COMMISSION JOINT RESEARCH CENTRE (ECJRC). **Copernicus emergency management service**. 2022. Disponível em: <https://emergency.copernicus.eu/>.

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.

FONSECA, L. M. G. et al. Earth observation applications in Brazil with focus on the CBERS program. **IEEE Geoscience and Remote Sensing Magazine**, v. 2, n. 2, p. 53-55, 2014. Disponível em: <https://doi.org/10.1109/MGRS.2014.2320924>.

FONSECA, L. M. G.; NAMIKAWA, L. M.; CASTEJON, E. F. Digital image processing in remote sensing. In: BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING, 22, 2009. **Proceedings...** IEEE, 2009. p.59-71. Disponível em: <https://doi.org/10.1109/SIBGRAPI-Tutorials.2009.13>.

GÄHLER, M.; MARGHANY, M. Remote sensing for natural or man-made disasters and environmental changes. In: MARGHANY, M. (Ed.). **Environmental applications of remote sensing**. InTech, 2016. p. 309-338.

GAIDA, W.; BREUNING, F. M.; GALVÃO, L. S.; PONZONI, F. J. Correção atmosférica em sensoriamento remoto: uma revisão. **Revista Brasileira de Geografia Física**, v. 13, n.1, p.229-248, 2020. Disponível em: http://mtcm21c.sid.inpe.br/col/sid.inpe.br/mtcm21c/2020/05.08.12.48/doc/gaida_correcao.pdf.

GERENTE, J.; PLETSCHE, M. A. J. S.; SOTHE, C.; FRANCISCO, C. N. Classificação semiautomática de cicatrizes de movimentos de massa por meio de técnicas de detecção de mudanças. **Revista Brasileira de Geomorfologia**, v. 18, n.4, 2017. Disponível em: <https://doi.org/10.20502/rbg.v18i4.1249>.

GHAFFARIAN, S.; KERLE, N.; FILATOVA, T. Remote sensing-based proxies for urban disaster risk management and resilience: a review. **Remote Sensing**, v. 10, n. 11, p. 1760, 2018. Disponível em: <https://doi.org/10.3390/rs10111760>.

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>.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R.; Random forest for land cover classification. **Pattern Recognition Letters**, v. 27, p. 294-300. 2006.

GÓMEZ-PALACIOS, D.; TORRES, M. A.; REINOSO, E. Flood mapping through principal component analysis of multitemporal satellite imagery considering the alteration of water spectral properties due to turbidity conditions. **Geomatics, Natural Hazards and Risk**, v. 8, n. 2, p. 607-623, 2017. Disponível em: <https://doi.org/10.1080/19475705.2016.1250115>.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. [S.l.]: Pearson Educação, 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. Disponível em: <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.

GUZZETTI, F. et al. Landslide inventory maps: new tools for an old problem. **Earth-Science Reviews**, v. 112, n. 1-2, p. 42-66, 2012. Disponível em: <https://doi.org/10.1016/j.earscirev.2012.02.001>.

G1. Mais de 822 mil pessoas são afetadas pela chuva na Bahia e estado tem quase 70 mil desalojados. **Grupo Globo**. 8 jan. 2022. Disponível em: <https://g1.globo.com/ba/bahia/noticia/2022/01/06/mais-de-822-mil-pessoas-sao-afetadas-pela-chuva-na-bahia-e-estado-tem-quase-70-mil-desalojados.ghtml>.

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. Disponível em: <https://doi.org/10.1016/j.landusepol.2018.12.026>.

HO, L. T. K.; UMITSU, M.; YAMAGUCHI, Y. Flood hazard mapping by satellite images and SRTM DEM in the Vu Gia–Thu Bon alluvial plain, Central Vietnam. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science**, v. 38, pt. 8, p. 275-280, 2010.

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.

HOTELLING, H. Analysis of a complex of statistical variables into principal components. **Journal of Educational Psychology**, v. 24, n. 6, p. 417, 1933. Disponível em: <https://psycnet.apa.org/doi/10.1037/h0071325>.

HU, C.; LU, Y.; SUN, S.; LIU, Y. Optical remote sensing of oil spills in the ocean: what is really possible? **Journal of Remote Sensing**, 2021. Disponível em: <https://doi.org/10.34133/2021/9141902>.

HUANG, S. Q.; YOU, H.; WANG, Y. T. Environmental monitoring of natural disasters using synthetic aperture radar image multi-directional characteristics. **International Journal of Remote Sensing**, v. 36, n. 12, p. 3160-3183, 2015. Disponível em: <https://doi.org/10.1080/01431161.2015.1041171>.

HUANG, Q. et al. Landslide monitoring using change detection in multitemporal optical imagery. **IEEE Geoscience and Remote Sensing Letters**, v. 17, n. 2, p. 312-316, 2019. Disponível em: 10.1109/LGRS.2019.2918254.

HUANG, X.; WANG, C.; LI, Z. A near real-time flood-mapping approach by integrating social media and post-event satellite imagery. **Annals of GIS**, v. 24, n. 2, p. 113-123, 2018. Disponível em: <https://doi.org/10.1080/19475683.2018.1450787>.

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. Disponível em: [https://doi.org/10.1016/0034-4257\(88\)90043-0](https://doi.org/10.1016/0034-4257(88)90043-0).

INTERNATIONAL CHARTER ON SPACE AND MAJOR DISASTERS (ICSMD) **History**. 2022. Disponível em: <https://disastersCarta.org/web/guest/history>.

INSTITUTO DE PESQUISAS TECNOLÓGICAS (IPT). **Banco de acidentes com vítimas fatais associados a escorregamentos**. São Paulo: IPT, 2017. Disponível em: https://www.ipt.br/noticias_interna.php?id_noticia=1190.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **CBERS program**. 2022. Disponível em: <http://www.cbears.inpe.br/sobre/historia.php>. Acesso em: 08 fev. 2022.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Missão Amazônia**. 2022. Disponível em: <http://www.inpe.br/amazonia1/galeria.php>. Acesso em: 08 fev. 2022.

JENSEN, J.R. **Introductory digital image processing: a remote sensing perspective**. Englewood Cliffs: Prentice Hall, 1986. 379p.

JI, L.; ZHANG, L.; WYLIE, B. Analysis of dynamic thresholds for the normalized difference water index. **Photogrammetric Engineering & Remote Sensing**, v. 75, n. 11, p. 1307-1317, 2009. Disponível em: <https://doi.org/10.14358/PERS.75.11.1307>.

JONES, B. K.; STRYKER, T. S.; MAHMOOD, A.; PLATZECK, G. R. The International charter 'space and major disasters'. In: LIPPITT, C. D.; STOW, D. A.; COULTER, L. L. (Ed.). **Time-sensitive remote sensing**. New York: Springer, 2015. p. 79-89. Disponível em: 10.1007/978-1-4939-2602-26.

JOYCE, K. E.; BELLISS, S. E.; SAMSONOV, S. V.; MCNEILL, S. J.; GLASSEY, P. J. A review of the status of satellite remote sensing and image processing techniques for mapping natural hazards and disasters. **Progress in Physical Geography**, v. 33, n. 2, p. 183-207, 2009. Disponível em: <https://doi.org/10.1177/0309133309339563>.

KHAN, A.; GOVIL, H.; KHAN, H. H.; THAKUR, P. K.; YUNUS, A. P.; PANI, P. Channel responses to flooding of Ganga River, Bihar India, 2019 using SAR and optical remote sensing. **Advances in Space Research**, v. 69, n. 4, p. 1930-1947, 2022. Disponível em: <https://doi.org/10.1016/j.asr.2021.08.039>.

KOTZ, S.; JOHNSON, N. L. **Encyclopedia of statistical sciences**. New York: John Wiley & Sons; 1983. v.4, p.352-4.

LATORRE, M. L.; CARVALHO JUNIOR, O. A. D.; CARVALHO, A. P. F.; SHIMABUKURO, Y. E. **Correção atmosférica: conceitos e fundamentos**, 2002. Disponível em: <https://repositorio.unb.br/handle/10482/10659>.

LEDLEY, R. S.; BUAS, M.; GOLAB, T. J. Fundamentals of true-color image processing. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 10., 1990. **Proceedings...** IEEE, 1990. p.791-795. Disponível em: <https://doi.org/10.1109/ICPR.1990.118218>.

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://mar.tecnico.unicamp.br/col/dpi.inpe.br/sbsr@80/2008/11.16.12.28/doc/6951-6958.pdf>.

LETRAS AMBIENTAIS. **Satélite brasileiro detecta mancha de óleo e amplia cena do vazamento no Litoral do RN**. ISSN 2674-760X. Disponível em: <https://www.letrasambientais.org.br/posts/satelite-brasileiro-detecta-mancha-de-oleo-e-amplia-cena-do-vazamento-no-litoral-do-rn>. Acesso em: 9 mar. 2022.

LI, Y. et al. Semiautomatic landslide detection using remote sensing and slope units. **Transportation Research Record**, v. 2604, n. 1, p. 104-110, 2017. Disponível em: <https://doi.org/10.3141/2604-13>.

LIMA, J. R. A.; NEVES, D. J. D.; DE ARAÚJO, L. E.; DE AZEVEDO, P. V. Identificação de tendências climáticas no Estado da Bahia. **Revista de Geografia (Recife)**, v. 28, n.3, p.172-187, 2011. Disponível em: <https://periodicos.ufpe.br/revistas/revistageografia/article/download/228962/23371>.

LISSAK, C.; BARTSCH, A.; DE MICHELE, M.; GOMEZ, C.; MAQUAIRE, O.; RAUCOULES, D.; ROULLAND, T. Remote sensing for assessing landslides and associated hazards. **Surveys in Geophysics**, v.41, n.6, p.1391-1435, 2020. Disponível em: <https://link.springer.com/article/10.1007/s10712-020-09609-1>.

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.

LODHI, M. A. Earthquake-induced landslide mapping in the western Himalayas using medium resolution ASTER imagery. **International Journal of Remote Sensing**, v. 32, n. 19, p. 5331-5346, 2011. Disponível em: <https://doi.org/10.1080/01431161.2010.502158>.

LOUGHLIN, W. P. Principal component analysis for alteration mapping. **Photogrammetric Engineering and Remote Sensing**, v. 57, n. 9, p. 1163-1169, 1991.

MA, Y.; CHEN, F.; LIU, J.; HE, Y.; DUAN, J.; LI, X. An automatic procedure for early disaster change mapping based on optical remote sensing. **Remote Sensing**, v. 8, n.4, e 272, 2016. Disponível em: <https://doi.org/10.3390/rs8040272>.

MA, Y. et al. Remote sensing big data computing: **Challenges and opportunities**. **Future Generation Computer Systems**, v. 51, p. 47-60, 2015. Disponível em: <https://doi.org/10.1016/j.future.2014.10.029>.

MAHMOOD, A. Monitoring disasters with a constellation of satellites—type examples from the International Charter ‘Space and Major Disasters’. **Geocarto International**, v. 27, n. 2, p. 91-101, 2012.

MANFRÉ, L. A. **Identificação e mapeamento de áreas de deslizamentos associadas a rodovias utilizando imagens de sensoriamento remoto**. 2015. Tese (Doutorado em Engenharia de Transportes) - Universidade de São Paulo, São Paulo, 2015. Disponível em: <https://www.teses.usp.br/teses/disponiveis/3/3138/tde-03032016-113209/pt-br.php>.

MARENGO, J. A.; SELUCHI, M. E.; CUNHA, A. P.; CUARTAS, L. A.; GOLÇALVES, D.; SPERLING, V. B.; MORAES, O. L. Heavy rainfall associated with floods in southeastern Brazil in November–December 2021. **Natural Hazards**, p.1-28, 2023. Disponível em: <https://doi.org/10.1007/s11069-023-05827-z>.

MARQUES FILHO, O.; NETO, H. V. **Processamento digital de imagens**. [S.l.]: Brasport, 1999.

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_HTdFOPwW8ZdEm6e5LulrO_oJTMZ3G_str2_0Zo3P7PwNgvpv5RYpFvRjN_SOdWss.

MASON, D. C.; DANCE, S. L.; CLOKE, H. L. Floodwater detection in urban areas using Sentinel-1 and WorldDEM data. **Journal of Applied Remote Sensing**, v. 15, n. 3, p. 032003, 2021. Disponível em: <https://doi.org/10.1117/1.JRS.15.032003>.

MATHER, P. M.; KOCH, M. **Computer processing of remotely-sensed images: an introduction**. [S.l.]: John Wiley & Sons, 2011.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n.7, p.1425-1432, 1996. Disponível em: <https://doi.org/10.1080/01431169608948714>.

MELACK, J. M.; HESS, L. L.; SIPPEL, S. Remote sensing of lakes and floodplains in the Amazon Basin. **Remote Sensing Reviews**, v. 10, n. 1-3, p. 127-142, 1994. Disponível em: <https://doi.org/10.1080/02757259409532240>.

MENESES, P.; ALMEIDA, T. D.; SANTA ROSA, A. C.; SANO, E.; SOUZA, E. D.; BAPTISTA, G., BRITES, R. **Processamento de imagens digitais de sensoriamento remoto**. Brasília: [s.n.], 2012.

MONDINI, A. C.; CHANG, K. T.; YIN, H. Y. Combining multiple change detection indices for mapping landslides triggered by typhoons. **Geomorphology**, v. 134, n. 3-4, p. 440-451, 2011. Disponível em: <https://doi.org/10.1016/j.geomorph.2011.07.021>.

MOUTINHO, S. First Brazilian-made satellite watches the Amazon. **Science**, p. 975, 2021. Disponível em: <https://doi.org/10.1126/science.371.6533.975>.

MUNASINGHE, D.; COHEN, S.; HUANG, Y. F.; TSANG, Y. P.; ZHANG, J.; FANG, Z. Intercomparison of satellite remote sensing-based flood inundation mapping techniques. **JAWRA Journal of the American Water Resources Association**, v. 54, n.4, p.834-846, 2018. Disponível em: <https://doi.org/10.1111/1752-1688.12626>.

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. Disponível em: <https://doi.org/10.3390/s22030960>.

NAMIKAWA, L. M.; KÖRTING, T. S.; CASTEJON, E. F. Water body extraction from Rapideye images: an automated methodology based on hue component of color transformation from RGB to HSV model. **Revista Brasileira de Cartografia**, v. 68, n. 6, p. 1097-1111, 2016. Disponível em: http://esensing.org/papers/paper_32.pdf.

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>.

NERY, T. D. **Avaliação da suscetibilidade a escorregamentos translacionais rasos na Bacia da Ultrafértil, Serra do Mar (SP)**. 2011. Tese de Doutorado. Tese (Doutorado em Geografia Física) - Universidade de São Paulo, São Paulo, 2011.

NEVES-SILVA, P.; HELLER, L. Rompimento da barragem em Brumadinho e o acesso à água das comunidades atingidas: um caso de direitos humanos. **Ciência e Cultura**, v. 72, n. 2, p. 47-50, 2020. Disponível em: <http://dx.doi.org/10.21800/2317-66602020000200013>.

NOTTI, D. et al. Potential and limitations of open satellite data for flood mapping. **Remote sensing**, v. 10, n. 11, p. 1673, 2018. Disponível em: <https://doi.org/10.3390/rs10111673>.

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. Disponível em: https://doi.org/10.1007/978-981-13-0992-2_3.

NOVO, E. M. L. **Sensoriamento remoto: princípios e aplicações**. 4.ed. São Paulo: Edgard Blucher, 2010. cap.7, p. 316-319.

NUNES, R. Enchentes: Bahia decreta situação de emergência para mais 47 cidades. **Correio Braziliense**. 26 dez. 2021. Disponível em: <https://www.correiobraziliense.com.br/brasil/2021/12/4973543-enchentes-bahia-decreta-situacao-de-emergencia-para-mais-47-cidades.html>.

NIU, X.; TANG, H.; WU, L. Satellite scheduling of large areal tasks for rapid response to natural disaster using a multi-objective genetic algorithm. **International Journal of Disaster Risk Reduction**, v. 28, p. 813-825, 2018. Disponível em: <https://doi.org/10.1016/j.ijdr.2018.02.013>.

OLIVEIRA, I.; CANDAL, L. “É o maior desastre natural da história da Bahia”, diz o governador Rui Costa. **CNN Brasil**. São Paulo, 27 dez. 2021. Disponível em: <https://www.cnnbrasil.com.br/nacional/e-o-maior-desastre-natural-da-historia-da-bahia-diz-o-governador-rui-costa/>. Acesso em: 20 jan. 2022.

OLIVEIRA, L. V.; NEGRI, R. G.; SANTOS, L. B. L. Análise de técnicas de detecção de mudança para mapeamento de desastres com uso de dados de sensoriamento remoto. **Revista Brasileira de Cartografia**, v. 72, n. 1, p. 177-189, 2020. Disponível em: <https://doi.org/10.14393/revbrascartogr>.

OLIVEIRA, T. R., de Oliveira, V. S., Pontes, M., Libório, M. P., Hadad, R. M., & Laudaes, S. (2019). Metodologia para análise de danos ambientais do rompimento da Barragem de Fundão em Bento Rodrigues (MG). **HOLOS**, 7, 1-17. Disponível em: <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. Disponível em: <https://doi.org/10.1080/14786440109462720>.
- PEKEL, J. F.; VANCUTSEM, C.; BASTIN, L., CLERICI, M.; VANBOGAERT, E.; BARTHOLOMÉ, E.; DEFOURNY, P. A near real-time water surface detection method based on HSV transformation of MODIS multi-spectral time series data. **Remote sensing of environment**, v. 140, p.704-716, 2014. Disponível em: <https://doi.org/10.1016/j.rse.2013.10.008>.
- PENA, P. G. L. et al. The crude oil spill on the Brazilian coast in 2019: the question of public health emergency. **Cadernos de Saúde Pública**, v. 36, p. e00231019, 2020. Disponível em: <https://doi.org/10.1590/0102-311X00231019>.
- PIKE, R. J. The geometric signature: quantifying landslide-terrain types from digital elevation models. **Mathematical Geology**, v. 20, p.491-511, 1988. Disponível em: <https://doi.org/10.1007/BF00890333>.
- POLIKAR, R. Ensemble learning. **Ensemble Machine Learning**, p. 1–34, 2012.
- PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Texto, 2012. 178p.
- POURSANIDIS, D.; CHRYSOULAKIS, N. Remote sensing, natural hazards and the contribution of ESA Sentinel missions. **Remote Sensing Applications: Society and Environment**, v. 6, p. 25-38, 2017. Disponível em: <https://doi.org/10.1016/j.rsase.2017.02.001>.
- RAHMAN, M. et al. The state of the art of spaceborne remote sensing in flood management. **Natural Hazards**, v. 85, n. 2, p. 1223-1248, 2017. 8 Disponível em: [10.1007/s11069-016-2601-9](https://doi.org/10.1007/s11069-016-2601-9).
- RAMOS-BERNA, R. N et al. Evaluation of unsupervised change detection methods applied to landslide inventory mapping using ASTER imagery. **Remote Sensing**, v. 10, n.12, 1987. Disponível em: [10.3390/rs10121987](https://doi.org/10.3390/rs10121987).
- RASHID, H; PRAMANIK, M. A. H. Areal extent of the 1988 flood in Bangladesh: how much did the satellite imagery show? **Natural Hazards**, v.8, p. 189-200, 1993.
- REHMAN, A.; JINGDONG, L.; DU, Y.; KHATOON, R.; WAGAN, S. A.; NISAR, S. K. Flood disaster in Pakistan and its impact on agriculture growth (a review). **Environment and Development Economics**, v. 6, n.23, p.39-42, 2016. Disponível em: <https://core.ac.uk/download/pdf/234647327.pdf>.

RICHARDS, J. A. **Remote sensing digital image analysis**. Berlin: Springer, 1999.

RIO DE JANEIRO. DEFESA CIVIL. **Classificação e Codificação Brasileira de Destatres (COBRADE)**. Disponível em: <http://www.defesacivil.rj.gov.br/images/formularios/COBRADE.pdf>. Acesso em: 12 jan. 2018.

ROBINSON, T. R.; ROSSER, N.; WALTERS, R. J. The spatial and temporal influence of cloud cover on satellite-based emergency mapping of earthquake disasters. **Scientific Reports**, v. 9, n. 1, p. 1-9, 2019. Disponível em: <https://doi.org/10.1038/s41598-019-49008-0>.

ROESSNER, S. et al. Automated remote sensing based landslide detection for dynamic landslide inventories. In: SASSA, K.; CANUTI, P.; YIN, Y. (Ed.). **Landslide science for a safer geoenvironment**. Cham: Springer, 2014. p. 345-350. Disponível em: 10.1007/978-3-319-05050-8_54.

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.

SALLEH, M. M.; ISMAIL, Z.; ARIFF, S. M.; RAHMAN, M. A.; KHANAN, M. A.; ASMADI, M. A.; RAZAK, K. A. Spatial prediction models for landslide activity mapping using vegetation anomalies. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, 2019.

SALLEH, M. R. M.; ISHAK, N. I.; RAZAK, K. A.; RAHMAN, M. Z. A.; ASMADI, M. A.; ISMAIL, Z.; KHANAN, M. F. A. Geospatial approach for landslide activity assessment and mapping based on vegetation anomalies. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 42, n. 4/W9, 2018.

SANTOS, A. C. Advances in network accessibility and reconstruction after major earthquakes. In: KOVACS, G.; SPENS, K.; MOSHTHARI (Ed.). **The palgrave handbook of humanitarian logistics and supply chain management**, [S.l.]: Palgrave, 2018. p.547-565. Disponível em: 10.1057/978-1-137-59099-2_18.

SAUSEN, T. M.; LACRUZ, M. S. P. **Sensoriamento remoto para desastres**. São Paulo: Oficina de Textos, 2015.

SCHETSELAAR, E. M. Fusion by the IHS transform: Should we use cylindrical or spherical coordinates. **International Journal of Remote Sensing**, v. 19, n. 4, p. 759-765, 1998.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. [S.l.]: Elsevier, 2006.

SENTINEL ASIA. **Sentinel**. Disponível em: <https://sentinel-asia.org/#>. Acesso em: 02 fev. 2022.

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. Disponível em: <https://doi.org/10.1016/j.ijdr.2020.101805>.

SHAH, A. A.; YE, J.; ABID, M.; KHAN, J.; AMIR, S. M. Flood hazards: household vulnerability and resilience in disaster-prone districts of Khyber Pakhtunkhwa province, Pakistan. **Natural Hazards**, v. 93, n.1, p. 147-165, 2018. Disponível em: <https://doi.org/10.1007/s11069-018-3293-0>.

SHADECK, R. (Org.). **Relatório de danos materiais e prejuízos decorrentes de desastres naturais no Brasil: 1995-2019/Banco Mundial**. 2. ed. Florianópolis: FAPEU, 2020. Disponível em: https://www.gov.br/mdr/pt-br/centrais-de-conteudo/publicacoes/protecao-e-defesa-civil-sedec/danos_e_prejuizos_versao_em_revisao.pdf. Acesso em: 01 ago. 2022.

SHAH-HOSSEINI, R.; SAFARI, A. R.; HOMAYOUNI, S. Monitoring and estimating flood damages by object-oriented change detection of optical and radar earth observations. **Journal of Geomatics Science and Technology**, v. 8, n. 1, p. 239-257, 2018.

SILVA, W. K. L. et al. Estudo do satélite brasileiro Amazonia-1 e de sua trajetória: mapeamento sistemático e análise documental dos artefatos históricos—oficiais. **Research, Society and Development**, v. 11, n. 2, p. e29011225894-e29011225894, 2022. Disponível em: <https://doi.org/10.33448/rsd-v11i2.25894>.

SOUZA MENDES, F.; BARON, D.; GEROLD, G.; LIESENBERG, V.; ERASMI, S. Optical and SAR remote sensing synergism for mapping vegetation types in the endangered Cerrado/Amazon types in the endangered Mutum – Mato Grosso. **Remote Sensing**, v. 11, n. 10, p. 1161, 2019. Disponível em: <https://doi.org/10.3390/rs11101161>.

STEFANOV, W. L.; EVANS, C. A. Data collection for disaster response from the international space station. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, 2015. Disponível em: [10.5194/isprsarchives-XL-7-W3-851-2015](https://doi.org/10.5194/isprsarchives-XL-7-W3-851-2015).

SWISS RE GROUP. **Extreme flood events once again drive high losses in 2021, yet 75% of flood risks remain uninsured**. Suíça. Mar/2022. Disponível em: <https://www.swissre.com/press-release/Extreme-flood-events-once-again-drive-high-losses-in-2021-yet-75-of-flood-risks-remain-uninsured-Swiss-Re-Institute-reveals/3269ad99-b743-4398-82e3-534a87783910>.

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. Disponível em: <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. Disponível em: <https://doi.org/10.20985/1980-5160.2020.v15n1.1611>.

UEHARA, T. D. T. et al. Landslide scars detection using remote sensing and pattern recognition techniques: comparison among artificial neural networks, gaussian maximum likelihood, random forest, and support vector machine classifiers. **Revista Brasileira de Cartografia**, v.72, n.4, p.665-680, 2020. Disponível em: <https://doi.org/10.14393/rbcv72n4-54037>.

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>.

UNITED NATIONS CHILDREN'S FUND (UNICEF). **Enchentes no Paquistão deixam 1,2 mil mortos e cenário pode piorar**. 06 set. 2022. Disponível em: <https://news.un.org/pt/story/2022/09/1800161>.

UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION. UNDRR 2019 Annual Report. Disponível em: <https://www.undrr.org/publication/undrr-annual-report-2019>.

VECCHIOTTI, F.; TILCH, N.; KOCIU, A. The use of TERRA-ASTER satellite for landslide detection. **Geosciences**, v. 11, n. 6, p. 258, 2021. Disponível em: <https://doi.org/10.3390/geosciences11060258>.

VOIGT, S. et al. Global trends in satellite-based emergency mapping. **Science**, v. 353, n. 6296, p. 247-252, 2016.

VRABEL, J. C. et al. System characterization report on the China-Brazil Earth Resources Satellite-4A (CBERS-4A). **US Geological Survey**, 2021. Disponível em: <https://doi.org/10.3133/ofr20211030J>.

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.

WENG, Q. Remote sensing of impervious surfaces in the urban areas: requirements, methods, and trends. **Remote Sensing of Environment**, v. 117, p. 34-49, 2012.

YAN, Y. E.; OUYANG, Z. T.; GUO, H. Q.; JIN, S. S.; & ZHAO, B. Detecting the spatiotemporal changes of tidal flood in the estuarine wetland by using MODIS time series data. **Journal of Hydrology**, v.384, n.1, p.156-163, 2010.
Disponível em: <https://doi.org/10.1016/j.jhydrol.2010.01.019>.

YANG, W.; WANG, M.; SHI, P. Using MODIS NDVI time series to identify geographic patterns of landslides in vegetated regions. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 4, p. 707-710, 2012.

YU, M.; YANG, C.; LI, Y. Big data in natural disaster management: a review. **Geosciences**, v. 8, n. 5, p. 165, 2018.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. Oficina de Textos, 2019.

ZHANG, Z.; HE, G.; WANG, X. A practical DOS model-based atmospheric correction algorithm. **International Journal of Remote Sensing**, v. 31, n. 11, p. 2837-2852, 2010.
Disponível em: <https://doi.org/10.1080/01431160903124682>.

ZHAO, C.; LU, Z. Remote sensing of landslides: a review. **Remote Sensing**, v. 10, n. 2, p. 279, 2018.

ZHOU, L. et al. Emergency decision making for natural disasters: An overview. **International Journal of Disaster Risk Reduction**, v. 27, p. 567-576, 2018.

APÊNDICE A - OUTROS EXEMPLOS DE FIGURAS E TABELAS

Figura A.1 – Áreas antigas de solo exposto em tons suaves em contraste às cicatrizes de deslizamentos na composição RGB (PC3, SAVI, HUE), em comparação à composição em cor verdadeira (765) do sensor MUX/CBERS-4A.

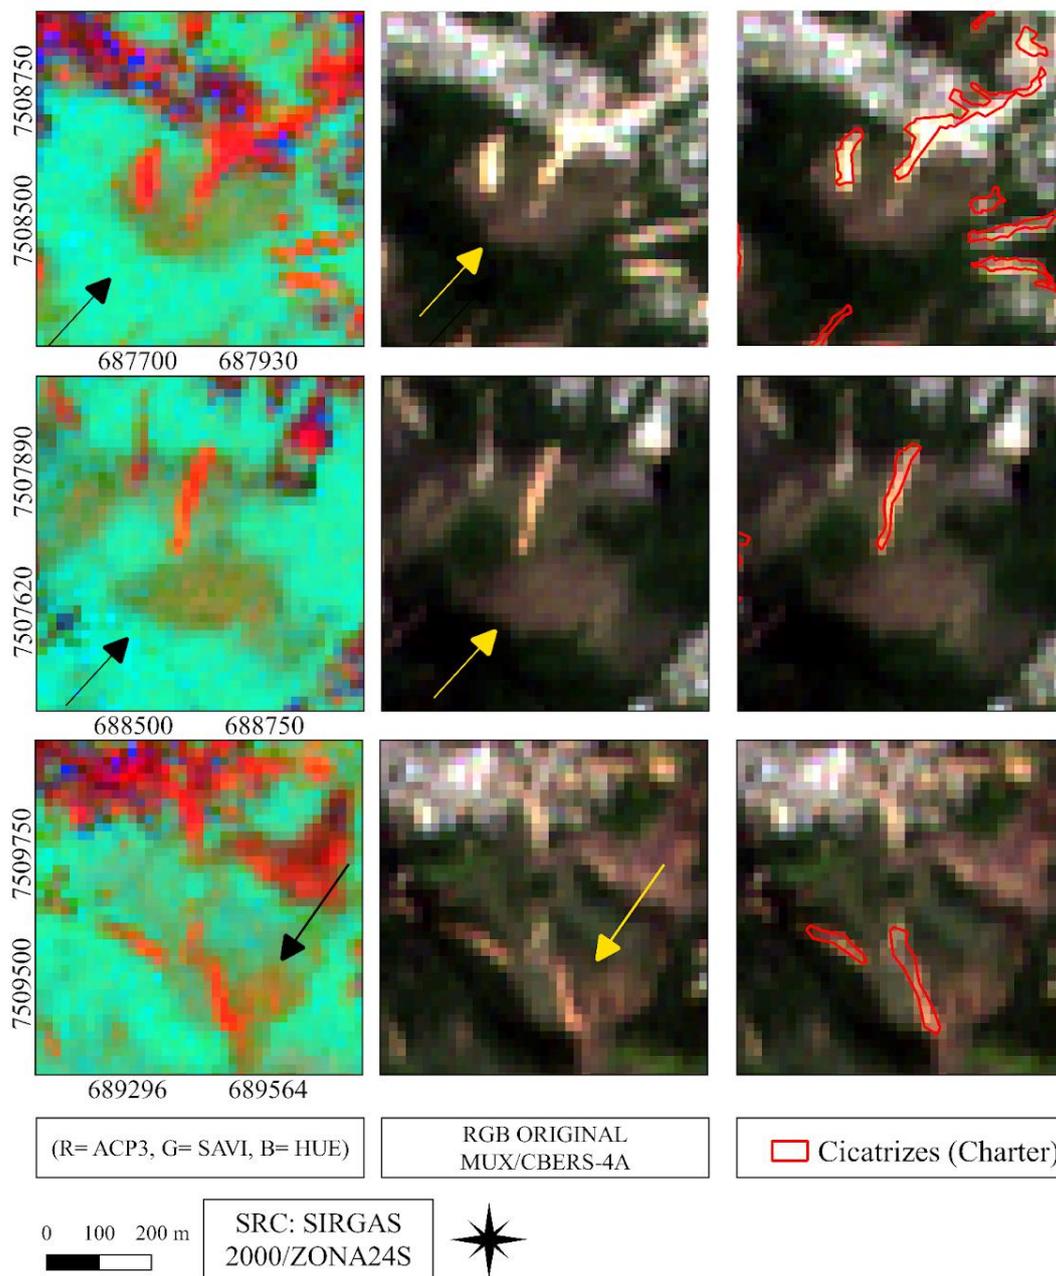


Figura A.2 – Áreas de desmatamento recente identificadas com a mesma tonalidade dos deslizamentos na composição RGB (CP3, SAVI, HUE), em comparação à composição em cor verdadeira (765) do sensor MUX/CBERS-4A.

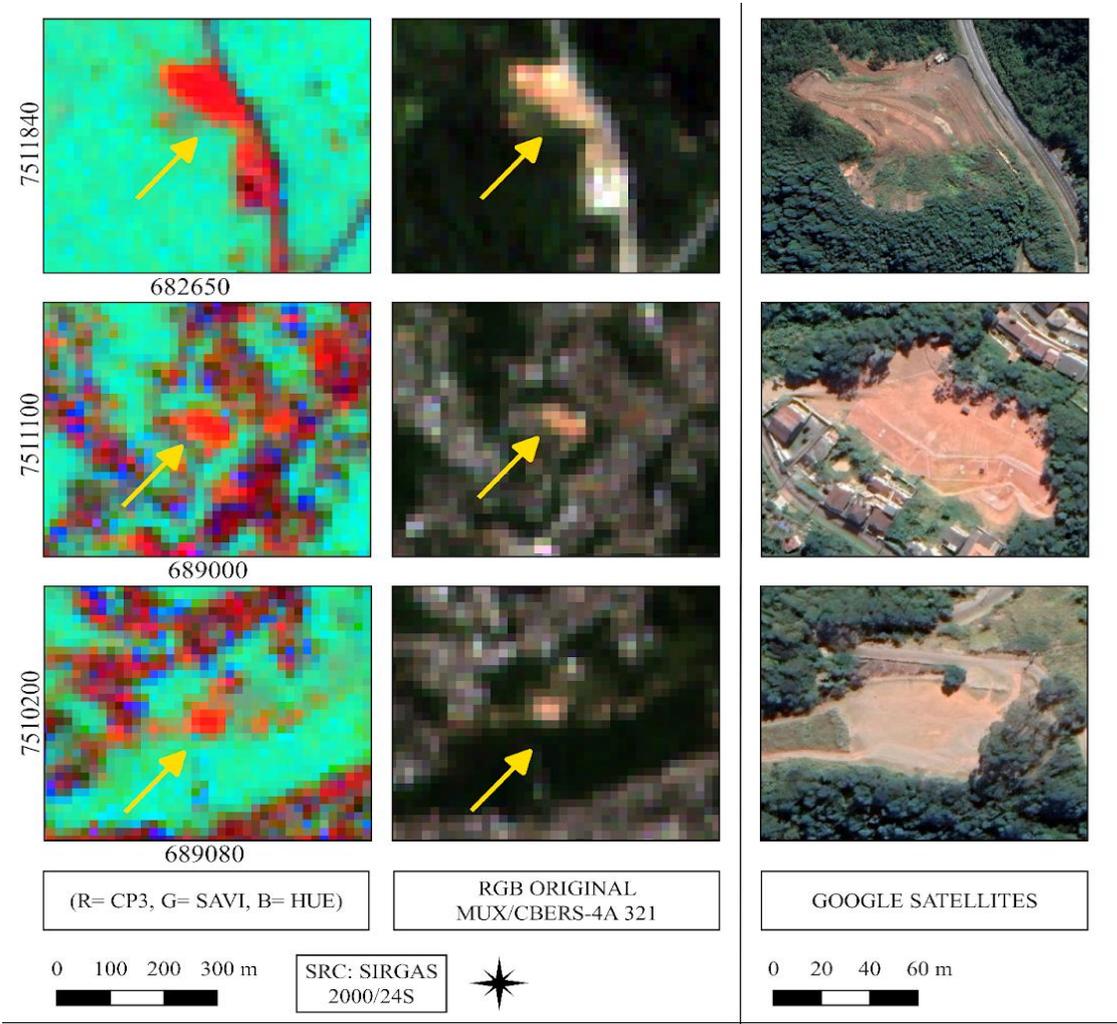
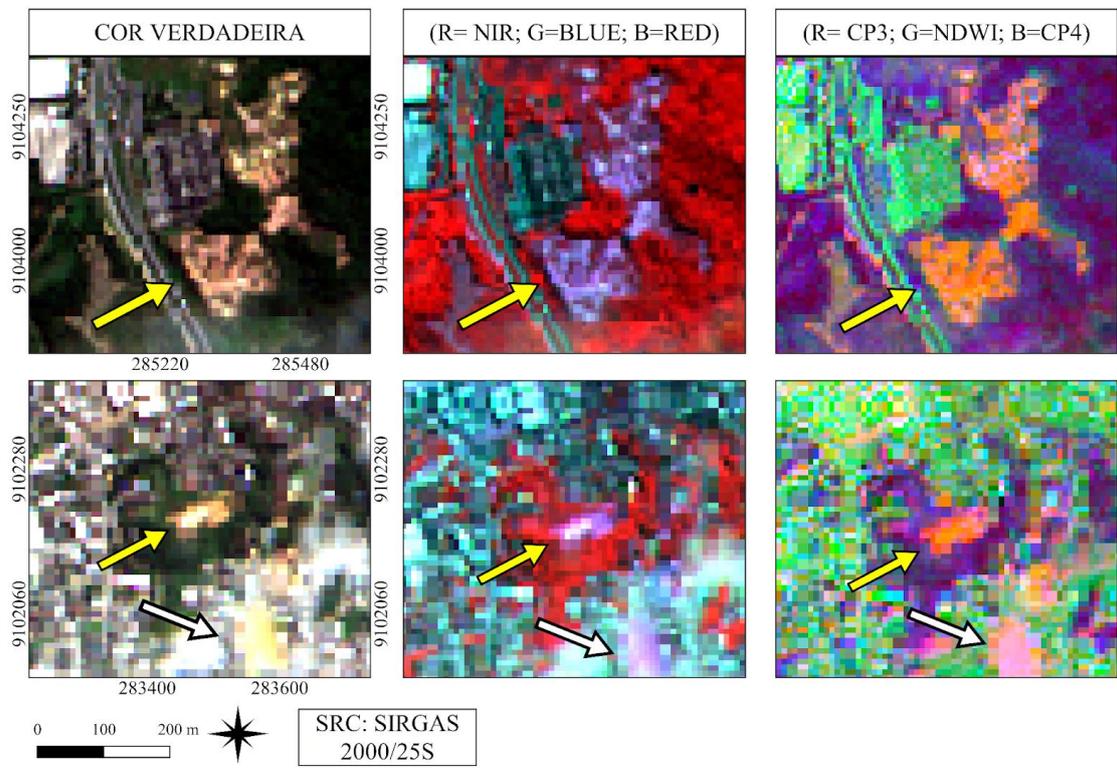


Figura A.3 – Áreas de solo exposto nas três composições avaliadas no caso dos deslizamentos em Recife (PE), a partir de imagens do sensor WPM/CBERS-4A.



Setas amarelas: áreas de solo exposto que não foram visualmente diferenciadas dos deslizamentos na composição falsa cor (423) e na composição RGB sugerida (CP3, NDWI, RED); setas brancas: áreas de solo exposto corretamente diferenciadas dos deslizamentos na composição RGB sugerida (CP3, NDWI, RED).

Figura A.4 – Avaliação das áreas inundadas destacadas a partir da composição sugerida (R=NIR, G=CP1, B=CP2), baseando-se na vetorização realizada pela Carta utilizando imagens do VIIRS/NOAA e do MSI/SENTINEL-2. Devido ao tamanho do arquivo, apenas uma cena da inundação regional pôde ser avaliada a partir da vetorização das imagens de 10 metros de resolução espacial do MSI/SENTINEL-2

