

Geoinformação e Sensoriamento Remoto em Geografia

Detecção automatizada de cicatrizes de deslizamentos de terra associado ao evento pluviométrico extremo em 2024 com uso de Inteligência Artificial: estudo de caso em um trecho da Bacia Hidrográfica Taquari Antas/RS

Automated detection of landslide scars associated with the extreme rainfall event in 2024 using Artificial Intelligence: a case study in a section of the Taquari-Antas River Basin, RS

Detección automatizada de cicatrices de deslizamientos de tierra asociadas al evento pluviométrico extremo de 2024 mediante Inteligencia Artificial: estudio de caso en un tramo de la Cuenca Taquari-Antas, RS

**Camila Reigota Ferreira^I , Waterloo Pereira Filho^I ,
Igor da Silva Narvaes^{II} , Andressa Kossmann Ferla^{II} **

^I Universidade Federal de Santa Maria , Santa Maria, RS, Brasil

^{II} Instituto Nacional de Pesquisas Espaciais , Santa Maria, RS, Brasil

RESUMO

Em 2024, o Rio Grande do Sul (RS) enfrentou desastres geo-hidrológicos severos, como inundações históricas e Deslizamentos de Terra (DT), causados por elevados índices de Precipitação Pluviométrica (PP). Neste contexto, o Sensoriamento Remoto (SR) tem se mostrado essencial no monitoramento destes eventos extremos. Este estudo avaliou a acurácia dos classificadores supervisionados Random Forest (RF) e *TempCNN* na detecção de cicatrizes de DT em um trecho da Bacia Hidrográfica Taquari-Antas/RS (BHTA). Para isto, integrou-se o cubo de dados Sentinel-2 e o Modelo Digital de Elevação (MDE) por meio do *software* de código aberto *Satellite Image Time Series Analysis* (SITS) no R Studio. As bandas R, G, B, NIR e *ELEVATION* foram aplicadas como variáveis explicativas no RF, e apenas as bandas ópticas no *TempCNN*, devido às limitações do SITS. Os valores de PP foram obtidos no *Google Earth Engine* (GEE) com dados do *Climate Hazards Center InfraRed Precipitation with Station* (CHIRPS), para comparar o comportamento da magnitude do evento de PP (2023–2024). Os resultados indicaram acurácia global de 0,98% para RF e 0,97% para *TempCNN*. Embora ambas as técnicas apresentem alta acurácia global, mostraram baixas acurácias de usuário e produtor para a classe “Deslizamento”.

Ajustes são necessários na intensificação amostral e na incorporação de variáveis ópticas adicionais, variáveis de sensores SAR e derivadas do MDE.

Palavras-chave: Algoritmos de classificação de imagem; Movimentos de massa; Evento climático extremo

ABSTRACT

During 2024, Rio Grande do Sul (RS) faced severe geo-hydrological disasters, such as historic floods and landslides (DT), caused by high rainfall indices (PP). In this context, remote sensing (RS) has proven essential for monitoring these extreme events. This study evaluated the accuracy of the supervised classifiers Random Forest (RF) and TempCNN in detecting landslide scars in a section of the Taquari-Antas River Basin (BHTA). For this purpose, Sentinel-2 and Digital Elevation Model (DEM) data cubes were integrated using the open-source software Satellite Image Time Series Analysis (SITS) in R Studio. The R, G, B, NIR, and ELEVATION bands were used as explanatory variables for RF, and only the optical bands for TempCNN, due to SITS limitations. Rainfall values were obtained from Google Earth Engine (GEE) using data from the Climate Hazards Center InfraRed Precipitation with Station (CHIRPS) to compare the magnitude behavior of the rainfall event (2023–2024). Results indicated an overall accuracy of 0.98% for RF and 0.97% for TempCNN. Although both techniques showed high overall accuracy, they presented low user and producer accuracies for the “Landslide” class. Adjustments are needed in sample intensification and the incorporation of additional optical variables, SAR sensors, and DEM-derived variables.

Keywords: Algorithm image classification; Mass movements; Extreme climate event

RESUMEN

En 2024, Rio Grande do Sul (RS) enfrentó desastres geo-hidrológicos severos, como inundaciones históricas y deslizamientos de tierra (DT), causados por altos índices de precipitación pluvial (PP). En este contexto, el teledetección (SR) ha demostrado ser esencial para el monitoreo de estos eventos extremos. Este estudio evaluó la precisión de los clasificadores supervisados Random Forest (RF) y TempCNN en la detección de cicatrizes de deslizamientos en un tramo de la Cuenca Hidrográfica Taquari-Antas/RS (BHTA). Para ello, se integraron los cubos de datos Sentinel-2 y el Modelo Digital de Elevación (MDE) mediante el software de código abierto Satellite Image Time Series Analysis (SITS) en R Studio. Las bandas R, G, B, NIR y ELEVATION se aplicaron como variables explicativas en RF, y solo las bandas ópticas en TempCNN, debido a las limitaciones del SITS. Los valores de PP se obtuvieron en Google Earth Engine (GEE) con datos del Climate Hazards Center InfraRed Precipitation with Station (CHIRPS), para comparar el comportamiento de la magnitud del evento PP (2023–2024). Los resultados indicaron una precisión global de 0,98% para RF y 0,97% para TempCNN. Aunque ambas técnicas mostraron alta precisión global, presentaron bajas precisiones de usuario y productor para la clase “Deslizamiento”. Se requieren ajustes en la intensificación del muestreo y la incorporación de variables ópticas adicionales, sensores SAR y variables derivadas del MDE.

Palabras-clave: Algoritmos de clasificación de imágenes; Movimientos de masa; Evento climático extremo

1 INTRODUÇÃO

No Brasil, os Deslizamentos de Terra (DT), inundações e enxurradas estão entre os principais desastres naturais, de modo a afetar diretamente o ambiente, a economia e a sociedade (EM-DAT, 2018). A remoção da cobertura vegetal em áreas de floresta torna o solo mais suscetível à erosão, e a intensidade dos eventos pode superar a proteção oferecida pela vegetação, ao resultar em cicatrizes visíveis por longos períodos (de Lima *et al.*, 2021).

Os DT são movimentos de massa caracterizados pelo deslocamento de solo, rocha e vegetação sob ação da gravidade. Podem ser desencadeados por fatores naturais, como Precipitação Pluviométrica (PP), ou agravados por ações humanas, como a sobrecarga das encostas (Farah, 2003; Tominaga *et al.*, 2015; Fagundes *et al.*, 2023), especialmente com a supressão da vegetação nativa. Neste contexto, as técnicas de Sensoriamento Remoto (SR) são amplamente aplicadas na análise de desastres, ao permitir avaliar a extensão dos danos e monitorar o uso e a cobertura da terra por meio de séries temporais (Sausen e Lacruz, 2015; Attri *et al.*, 2015).

As iniciativas de monitoramento da ocorrência de DT em condições de eventos pluviométricos extremos auxilia na compreensão dos fatores desencadeadores, como geologia, morfologia e ações antrópicas (Toan *et al.*, 2025). Assim, a classificação digital de imagens de SR permite uma identificação mais rápida e sem a realização de uma avaliação inicial à campo, por meio de algoritmos de Aprendizado de Máquina (*Machine Learning* - ML) e Aprendizado Profundo (*Deep Learning* - DL), ao possibilitar a detecção automatizada das áreas afetadas.

Entre os métodos de ML, o *Random Forest* (RF) destaca-se por lidar com dados de alta dimensionalidade e alcançar alta precisão, além de exigir menor capacidade computacional que modelos de DL (Belgiu e Drăguț, 2016; Sheykhoumoussa *et al.*, 2020). Ademais, se mostra eficiente na identificação de cicatrizes de DT, de modo a auxiliar na distinção de áreas afetadas com uso de variáveis como índices de vegetação, declividade

e orientação do terreno (Zêzere *et al.*, 2017; Chen *et al.*, 2018). Já os algoritmos de DL, como o *TempCNN*, utilizam Redes Neurais Artificiais (RNA) profundas e são adequados para séries temporais de SR, ao capturar padrões sazonais e variações abruptas associadas a DT (Le Cun *et al.*, 2015; Pelletier *et al.*, 2019; Perbet *et al.*, 2024), contudo, demandam maior capacidade computacional e tempo de processamento.

Apesar dos avanços da Inteligência Artificial (IA) na detecção automatizada de cicatrizes de DT, persistem desafios relacionados à qualidade dos inventários e à generalização dos modelos (Xavier, 2025). Ainda, há uma lacuna na integração de dados pluviométricos extremos com algoritmos de detecção, sobretudo em áreas com grande variabilidade geomorfológica e cobertura vegetal dinâmica.

Assim, torna-se essencial o desenvolvimento de abordagens mais robustas e adaptativas, capazes de integrar séries temporais de PP, variáveis ambientais locais e imagens de satélite de sensores ópticos e *Synthetic Aperture Radar* (SAR), a fim de aprimorar a prevenção e a gestão de riscos em regiões vulneráveis. Neste sentido, o trabalho tem como objetivo comparar o desempenho de classificadores supervisionados de RF e *TempCNN* para a classificação de cicatrizes de DT associados ao evento extremo de PP no ano de 2024 em um trecho da Bacia Hidrográfica do Taquari-Antas (BHTA).


2 MATERIAL E MÉTODOS

2.1 Área de estudo

A área de estudo se encontra nas coordenadas centrais: Latitude: 29° 0'31.54"S; Longitude: 51°49'57.93"O, e possui área total de 88 km², correspondendo a um trecho localizado na BHTA, nordeste do RS, e abrange o Rio Guaporé e o Rio Taquari (Figura 1). A região compreende as cidades de Dois Lajeados, Vespasiano Corrêa, São Valentim do Sul e Cotiporã. A ocorrência de processos geo-hidrológicos extremos distintos na BHTA, como inundações, no Rio Taquari, e os movimentos de massa e enxurradas,

no Rio Guaporé (Ferri e Togni, 2012), motivou, o desenvolvimento da pesquisa, como também a definição da área de estudo.

Figura 1 – Localização da área de estudo – Imagem Sentinel 2, composição colorida RGB (4, 3, 2), de 06/05/2024



Fonte: Autores (2025)

Referente a geologia e geomorfologia, o evento de deslizamento concentrou-se predominantemente na Borda Sul da Bacia Intracratônica do Paraná. Esta representa, em seu limite sul, relevo caracterizado por morfologia íngreme (Egas *et al.*, 2025). A *área de interesse está situada no* Rebordo do Planalto Meridional e é compreendida, quase totalmente, por litologias da Bacia do Paraná (FEPAM, 2001). A Escarpa da Serra Geral, uma feição erosiva de desgaste, compreende esta região que cruza múltiplos vales fluviais. Além disto, esta unidade geomorfológica é altamente suscetível a deslizamentos (IBGE 2006, CPRM, 2010).


Considerou-se a variação dos índices pluviométricos conforme as características geográficas específicas de cada microrregião. Esta variação foi verificada no estado, e conforme a classificação de Köopen, corresponde ao tipo Cfa (subtropical úmido)

que se caracteriza por temperaturas médias compreendidas entre -3°C e 18°C para o mês mais frio e superiores a 22°C para o mês mais quente, com PP bem distribuída durante o ano e total anual em torno de 1400 mm (FEPAM, 2001).

2.2 Métodos

Para atingir o objetivo proposto, a pesquisa foi dividida em três etapas: I) Pré-processamento dos dados; II) Processamento dos dados; III) Análises estatísticas dos resultados (Figura 2). A primeira consiste na coleta de amostras e a obtenção dos dados. A segunda etapa corresponde ao processamento dos dados obtidos, com a extração das séries temporais de cada classe e a realização do treinamento dos modelos composto pelas variáveis explicativas eleitas para a classificação em ambiente R (Posit, 2024). Por fim, a terceira etapa compreende a análise visual, a validação dos resultados obtidos a partir da acurácia de cada classificador e análises estatísticas do comportamento da magnitude da média mensal da PP ao longo de cada ano.

Figura 2 – Processo metodológico para a determinação de áreas de DT



Fonte: Autores (2025)

2.2.1 Base e processamento dos dados

Para a classificação supervisionada com uso dos algoritmos RF e *TempCNN*, *necessitou-se coletar e inserir amostras ao algoritmo de classificação*. Para isto, utilizou-

se imagens Sentinel-2, sensor MSI (*Multispectral Imager*), *composição colorida RGB* (B4, B3, B2), para a coleta pré evento (30/08/2023) e pós evento (06/05/2024), com resolução espacial de 10 metros e resolução radiométrica de 12 bits, sem a presença de nuvens.

O processo de coleta das amostras nas imagens foi realizado de forma visual, conforme classes de uso e cobertura da terra definidas para a área de interesse, no QGIS (versão 3.34.5). Foram geradas 420 amostras pós evento, divididas em 5 classes: 74 de água (classe 1); 73 de área construída (classe 2); 124 de deslizamentos (classe 3); 73 de florestas (classe 4) e 76 de agricultura (classe 5). Enquanto que os pontos coletados anteriores ao evento totalizaram 296 amostras, sendo 4 classes: 74 de água (classe 1); 73 de área construída (classe 2); 73 de florestas (classe 3) e 76 de agricultura (classe 4).

No *software* de código aberto SITS, disponível na plataforma R Studio (versão 4.5.0) gerou-se um cubo de dados irregular da coleção Sentinel-2-L2A, do banco de dados *Microsoft's Planetary Computer* (MPC), para o período de 01/12/2023 à 01/12/2024. O cubo de dados possui resolução espacial de 10 metros, onde as bandas utilizadas foram B2 (azul), B3 (verde), B4 (vermelho) e B8 (*Near-InfraRed* - NIR) para o *tile* 22JDN. Desta maneira, realizou-se a regularização destes dados mediante a função *sits_regularize()*, já que os mesmos não são regulares em espaço e tempo, de modo que as bandas podem apresentar resoluções diferentes e as imagens podem não cobrir todo o bloco (*tiles*) (Simões *et al.*, 2021).

Em seguida criou-se um cubo de dados irregular MDE da coleção TanDEM-X, disponível no banco de dados MPC, com resolução espacial de 30 m (COP-DEM-GLO-30). Realizou-se a reprojeção do cubo para a resolução espacial de 10 m e após extraiu-se a banda "*ELEVATION*". O período não foi estipulado, pois os dados de MDE não são temporais, já que eles representam a topografia da superfície terrestre em um determinado espaço no tempo. Por fim, realizou-se a regularização deste cubo por meio da função *sits_regularize()*.

Na intenção de incorporar dados topográficos às imagens de satélite, para a análise e a interpretação destes, mesclou-se o cubo de dados Sentinel-2 com o cubo de dados MDE, com uso da função *sits_merge()*, com o intuito de organizar os dados, de forma que os dados do MDE obtenham paridade com as outras bandas espectrais. Assim, realizou-se a extração da série temporal de cada amostra com a função *sits_get_data()* para todo pixel de mesma coordenada de cada imagem com relação à cada variável: R, G, B, NIR e *ELEVATION*.

Foi executado o treinamento do algoritmo RF com a função *sits_train* e o pacote *sits_rfor()* em modo *default* em que *ntree* = 100, e *mtry* foi calculado a partir da raiz quadrada do número de variáveis (Simões *et al.*, 2021), em seguida gerado o mapa classificado e rotulado, com uso das funções *sits_classify()* e *sits_label_classification()*, respectivamente.

Para a classificação *TempCNN* não foi possível a utilização do cubo MDE no processamento, pois o SITS não está configurado para tal, de modo que foi realizada a classificação apenas com o cubo de dados Sentinel-2. Desta forma, realizou-se o ajuste do modelo ao aplicar a função *sits_tuning()*, a fim de obter os melhores parâmetros do modelo, que foram: número de camadas (64, 64, 64), kernels de convolução (3; 3; 3), taxas de abandono (0,3; 0,3; 0,3), taxa de aprendizado 0,000803 e decaimento de peso 0,0000550. Ademais, foi implementada a função *sits_train()* para o treinamento do modelo, com uso do pacote *sits_tempcnn()*, enquanto que para a classificação da imagem e a geração do mapa utilizou-se a função *sits_classify()* e *sits_label_classification()*, respectivamente.

O mesmo processo foi executado para a classificação pré evento, em que criou-se um cubo de dados para o período de 06/05/2023 à 20/04/2024, apenas para o modelo RF, visto que apresentou melhor acurácia entre os classificadores quando realizada a classificação pós evento.

2.2.1.1 Dados de precipitação pluviométrica

Com o intuito de representar a variação do acumulado pluviométrico, realizou-se a análise da PP mensal para cada ano (2023 e 2024). No entanto, destaca-se que para determinar a frequência de ocorrência de movimentos de massa é necessário analisar a peculiaridade da região de estudo a fim de definir um limiar pluviométrico (Santos, Fragoso e Souza, 2019), já que a maior influência na ocorrência de deslizamentos está relacionada às altas intensidades pluviométricas (Huang *et al.*, 2021).

Para isso, obteve-se os dados a partir do catálogo *Climate Hazards Center InfraRed Precipitation with Station (CHIRPS)* disponível em: *Earth Engine Data Catalog*. Este incorpora imagens de satélite com resolução de 0,05° e dados de estações *in situ* para criar séries temporais (Funk *et al.*, 2015). Os dados foram processados no GEE ao utilizar a banda "PRECIPITATION" e extraído a média dos valores.

2.2.2 Análise estatística

Com o *plugin AcATaMa (Accuracy Assessment of Thematic Maps)* no *software QGIS 3.34.5*, analisou-se a precisão do mapeamento de DT, com uso do método de amostragem aleatória estratificada, a fim de reduzir os erros-padrão das estimativas de precisão específica de cada classe (Olofsson, 2014). Desta maneira, para a classificação do RF foram gerados 445 pontos aleatórios, com erro padrão de 0,02 e precisão do usuário de 0,8. Estes pontos foram classificados em duas classes, sendo elas: Deslizamento e Não Deslizamento, enquanto que para a classificação com *TempCNN*, foram gerados 357 pontos. Neste sentido, gerou-se a matriz de confusão na qual foram calculadas a acurácia geral, do usuário e a do produtor.

Para a análise da PP foi aplicada a estatística descritiva, com a finalidade de verificar as distribuições e a variabilidade dos dados, a qual engloba os valores da média, mediana, desvio padrão, intervalo (amplitude), máximo, mínimo e soma. Para a verificação da normalidade dos eventos de PP em 2023 e 2024, utilizou-se o teste

de Shapiro-Wilk (S-W) com valor $p < 0,05$ (normal) e o teste não paramétrico de Mann-Whitney para comparar a diferença de médias dos dois grupos independentes sob a condição de não normalidade dos dados.


Para a verificação da tendência do comportamento da precipitação entre os anos de 2023 e 2024 também foi utilizado o coeficiente de determinação (R^2) que permite quantificar a direção e a magnitude da variação de uma variável dependente em função do tempo, indicando também o grau de ajuste do modelo, muito utilizado em estudos climáticos e mudanças no uso e cobertura da terra (Kaiser *et al.*, 2022; Mehmood *et al.* 2024).

3 RESULTADOS E DISCUSSÃO

3.1. Análise mensal e anual da PP (2023-2024)

A avaliação da PP mensal nos anos 2023 e 2024 evidenciou acumulados em dois períodos distintos (Figura 3). Em 2023, o máximo pluviométrico foi de 435 mm em setembro. Já em 2024, o valor máximo mensal foi de 661 mm em maio, contudo, os maiores acumulados se estenderam de abril a maio, com total de 1048 mm com uma diferença pluviométrica destes dois anos de 420 mm.

Embora 2024 aponte para um comportamento linear decrescente da PP ao longo do período ($R^2 = 0,092$), este baixo valor reflete a influência de eventos atípicos, concentrados especialmente em maio, de modo que a concentração em poucos dias é um fator determinante para a saturação do solo, conforme discutido por Tucci (1997) comprovando a concentração de ocorrência de DT neste período em nossa análise. No entanto, em 2023 a regressão linear de ocorrência de PP foi crescente ($R^2 = 0,416$), devido, principalmente ao fato de as maiores PP terem ocorrido de setembro a novembro (segundo semestre), apesar das maiores PP nestes meses, o ano de 2023 apresentou valores mais bem distribuídos.

Figura 3 – PP média dos anos de 2023 e 2024 (em mm) e seus respectivos R²


Fonte: Autores (2025)

Assim, o teste de S-W comprovou a anomalia da PP ao longo dos anos analisados com p (normal) de 0,02207 e 0,006108 em 2023 e 2024, respectivamente. Ambos não seguem distribuição normal, embora a dinâmica pluviométrica de cada ano ao longo dos dois períodos seja semelhante e significativa a 0,05 (Mann-Whitney Test = 0,70745), mesmo com a presença de um valor discrepante para o mês de maio de 2024, correspondente ao mês de ocorrência dos deslizamentos de terra em nossa análise (Tabela 1).

De acordo com Notas Técnicas do INMET, os eventos ocorridos em 2023 e 2024, que ocasionaram os extremos pluviométricos, estiveram relacionados a combinação de sistemas meteorológicos, como frentes frias, baixas pressões e ciclones extratropicais, juntamente com os efeitos do *El Niño*, em 2023 (INMET, 2023; INMET, 2024), que associados as condições de solo, ocupação e relevo do trecho da bacia hidrográfica analisada foram responsáveis pelos deslizamentos ocorridos.

Tabela 1 – Estatística descritiva da PP em milímetros, no ano de 2023 e 2024 e a dinâmica pluviométrica mensal, desvios padrão a 95% e valores de *outliers*

Estatística	PP (mm) – ano 2023	PP (mm) – ano 2024
Média	174,92 (S-W test - p normal = 0,02207)	209,99 (S-W test - p normal = 0,006108) **Mann-Whitney test = 0,70745)
Mediana	126,61	147,02
Desvio Padrão	127,68	175,70
Amplitude	380,74	600,86
Mínimo	55,18	60,84
Máximo	435,93	661,70
Soma	2099,14	2519,96



* Valor p (normal = <0,05) = Distribuição de dados não é normal; **Mann-Whitney test (>0,05).
Fonte: Autores (2025)

3.2. Desempenho dos classificadores supervisionados RF e TempCNN

A partir da análise gerada pelo método de amostragem aleatória estratificada, o classificador RF apresentou a melhor acurácia geral, com 98% (Tabela 2), à medida que o classificador *TempCNN* obteve uma precisão de 97% (Tabela 3). Embora estes valores representem bom desempenho geral, a análise da acurácia do usuário, em que mede a confiabilidade da classe mapeada, mostrou valores médios para o RF (0,6) e baixo para o *TempCNN* (0,42), referente a classe de deslizamento. Em decorrência de uma baixa acurácia de usuário, o mapeamento superestimou as classes, o que resultou em falsas informações e comprometeu a confiança do produto final. Tendência similar também foi encontrada na análise de Ferla *et al.* (2025), os quais mapearam áreas de desmatamento com uso dos classificadores RF e *TempCNN*.

Tabela 2 – Matriz de Confusão do algoritmo de classificação RF

		Validação		
		(1) Não DT	(2) DT	Acurácia do Usuário
Mapa Temático	1	393	2	0,99
	2	20	30	0,60
Acurácia do Produtor		0,99	0,62	Acurácia Geral 0,98

Fonte: Autores (2025)

A maior acurácia para o algoritmo de classificação do RF para a identificação de cicatrizes de DT também foi encontrada na análise de Dias *et al.* (2021), com melhores resultados (90,2%), comparado às aplicações do *Support Vector Machine* (SVM), no município de Itaóca, São Paulo. Neste sentido, o RF em nossa análise obteve melhor precisão em relação ao TempCNN. Deste modo, ao classificar o DT, o RF mostrou maior probabilidade de classificá-lo corretamente (menos falsos positivos), devido a sua acurácia de usuário ser mais alta, uma vez que foi utilizado, além das bandas RGB e NIR, o MDE como uma variável explicativa fortemente associada à ocorrência de deslizamentos (Saleem *et al.*, 2019). Assim, o RF foi capaz de separar áreas de deslizamento, ao aumentar a precisão (0,60) sem comprometer a sensibilidade (0,62).

O *TempCNN* apresentou alta acurácia de produtor (84%), o que indica que conseguiu identificar a maior parte dos DT reais, com apenas 16% de erros de omissão. Entretanto, a acurácia do usuário foi baixa (42%), de modo a revelar que mais da metade dos pixels classificados como DT correspondiam a áreas sem ocorrência, o que resultou em um alto valor de erros de comissão. Esta limitação ocorre porque o *TempCNN* não incorpora o MDE e, portanto, perde informações espaciais cruciais diretamente relacionadas com a configuração do terreno, que ajudam a diferenciar deslizamentos de áreas com comportamento espectral semelhante. Por outro lado, sua arquitetura baseada em séries temporais (Ló *et al.*, 2023) favoreceu a detecção dos casos verdadeiros e reduziu o nível de omissão.

Tabela 3 – Matriz de Confusão do modelo *TempCNN*

		Validação		
		(1) Não DT	(2) DT	Acurácia do Usuário
Mapa Temático	1	386	1	0,99
	2	29	21	0,42
Acurácia do Produtor		0,98	0,84	Acurácia Geral 0,97


Fonte: Autores (2025)

3.3. Classificação final dos algoritmos RF e *TempCNN*

As classificações finais dos algoritmos para os períodos de pré e pós evento mostraram uma discrepância considerável na área atribuída à classe água no cenário pré-evento (Figura 4). Esta diferença está associada ao cubo de dados utilizado para a construção da série temporal, que incluiu principalmente os episódios de PP extrema ocorrido nos meses de setembro, outubro e novembro de 2023, de modo que o classificador gerado pelo cubo de dados deste ano detectou a presença de umidade no solo e, portanto, a divergência da classe água no resultado da classificação.

Conclusões semelhantes foram obtidos por Quevedo *et al.* (2024), em que houve uma superestimativa das áreas referentes a classe de água ao utilizar RF, como também, confusões entre a classe água e área de solo úmidos ainda descobertos próxima ao rio, o que confirma o padrão encontrado em nossa análise, onde houve sobreposição espacial entre as classes água e as classes agricultura em algumas regiões, principalmente em grandes áreas alagadas em planícies de inundação, próximas à margem dos rios.

Figura 4 – Classificação final dos algoritmos RF e *TempCNN* em período pré e pós evento



Fonte: Autores (2025)

Ainda, na classificação do *TempCNN* fica evidente os falsos positivos (classificações equivocadas), com manchas dispersas e fragmentadas de agricultura e deslizamentos que não seguem a lógica da paisagem. Isso sugere que o modelo confundiu *pixels* de áreas de deslizamento com áreas de agricultura em estágio inicial ou áreas com solo exposto ainda em preparação para o plantio. Desta maneira, este classificador é mais sensível ao ruído e casos de sobreposição espectral entre estas classes, o que resultou a superestimação das áreas de deslizamento.

Do mesmo modo, na análise de Oliveira *et al.* (2019), em que compararam o desempenho do RF e de RNA na modelagem de suscetibilidade a deslizamentos na Bacia do Rio Fão, Sul do Brasil, concluíram que o modelo RF se destacou nesse aspecto, ao registrar o maior índice de precisão entre todas as configurações testadas (0,949).

Dentro deste contexto, inúmeras pesquisas sobre o tema buscam estabelecer uma metodologia apropriada para a classificação de áreas afetadas por DT ocasionadas por PP extremas (Tabela 4).

Tabela 4 – Pesquisas realizadas para o monitoramento de DT a partir de técnicas de SR

Autor	Contribuição	Significado	Metodologia Utilizada	Acurácia Reportada	Variáveis Explicativas
Sausen e Lacruz (2015)	Sistematização do uso do SR para monitoramento de desastres.	Fundamenta o papel das imagens de satélite na gestão de riscos e resposta a eventos extremos.	Revisão técnica e conceitual sobre aplicações práticas de SR em desastres.	—	—
Xavier (2025)	Automatização de inventários com ML.	Integra SR a modelos preditivos para mapear suscetibilidade a deslizamentos.	Utilização de ANN e RF treinados com inventários georreferenciados e dados de sensores ópticos.	89%	Altitude, declividade, orientação de encosta, uso do solo e PP.
Dias <i>et al.</i> (2021)	Comparação de SVM, RF e Máxima Verossimilhança em imagens de alta resolução.	Avalia classificadores aplicados ao SR em áreas de risco geológico.	Classificação supervisionada com imagens de alta resolução e análise estatística de desempenho.	91% (RF), 88% (SVM), 84% (MV)	NDVI, textura, elevação, declividade, uso e cobertura do solo.
Ferla <i>et al.</i> (2025)	ML e DL para mapeamento de supressão vegetal.	Detecta alterações ambientais associadas a desastres com imagens de satélite.	Aplicação de algoritmos de ML e DL em séries temporais de imagens para detectar supressão de vegetação.	87%	R, G, B, NIR, NDVI EVI, variação temporal de cobertura vegetal.
Quevedo <i>et al.</i> (2024)	Mudanças de uso e cobertura da terra em áreas afetadas por deslizamentos.	Evita transições inválidas e melhora a acurácia dos mapas de áreas impactadas.	Modelagem de transições de uso da terra com validação cruzada e imagens multitemporais.	86%	Classes de uso da terra, histórico de cobertura e padrões de transição.

Fonte: Autores (2025)

No cenário de mudanças climáticas enfrentadas no Rio Grande do Sul, Sausen e Lacruz (2015) já o contextualizaram ao mostrar os principais desafios para o seu monitoramento com técnicas de SR e os principais produtos já utilizados ao longo deste tempo, além de se servir como uma das principais bibliografias norteadoras nas análises realizadas atualmente.

Atualmente, as abordagens metodológicas para a classificação de áreas de DT têm se pautado no uso de algoritmos de ML e DL ao utilizar como variáveis preditoras bandas e índices de vegetação de sensores ópticos, MDE e derivados deste, uso e cobertura da terra e dados de PP. Todavia, em algumas abordagens mais avançadas a utilização de um grande volume de informação via cubo de dados (Ferreira *et al.*, 2020; Ferreira e Queiroz, 2021) e com variáveis derivadas de imagens SAR (*Synthetic Aperture Radar* – Radar de Abertura Sintética) demonstram resultados promissores ao serem adicionados a modelos de classificação com os mais diversos tipos de variáveis (Chen *et al.*, 2024), embora ainda demande de um grande esforço computacional, o que pode inviabilizar análises em larga escala.

4 CONSIDERAÇÕES FINAIS

A partir desta análise conclui-se que: a abordagem automatizada com o RF foi a que demonstrou melhor desempenho, com nível aceitável de concordância e menor tendência à superestimação. Enquanto o *TempCNN* apresenta erros ao confundir e superestimar algumas áreas, embora demonstre melhor sensibilidade devido à sua acurácia de produtor alta.

Com o estabelecimento do fluxo de análise se demonstrou a viabilidade do uso de classificadores de ML e DL para o estabelecimento de metodologias robustas para apoiar e complementar trabalhos de campo na identificação de DT, ao fornecer respostas mais ágeis do mapeamento de um desastre aos tomadores de decisão.

A utilização de classificadores automáticos mostrou-se promissora e com potencial de aprimoramento, de modo que demanda do refinamento de modelos, como o modelo linear misto, que incorporem às variáveis extraídas de sensores ópticos, as variáveis hidrológicas (como taxa de infiltração e umidade antecedente do solo), variáveis climáticas, variáveis extraídas de imagens de radar e variáveis derivadas do MDE, tais como ângulo de inclinação e aspecto, para uma melhor predição.

REFERÊNCIAS

- ATTRI, P.; CHAUDHRY, S.; SHARMA, B. Remote Sensing & GIS based approaches for LULC change detection: a review. **International Journal of Current Engineering and Technology**, v. 5, n. 5, 2015.
- BELGIU, M.; DRĂGUT, 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.
- CHEN, H.; H. E., Y.; ZHANG, L.; *et al.* A multi-input channel U-Net landslide detection method fusing SAR multisource remote sensing data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 17, p. 1215-1232, 2024. Acesso em: 19 ago. 2025. DOI: <https://doi.org/10.1109/JSTARS.2023.3339294>.
- CHEN, W.; POURGHASEMI, H. R; NAGHIBI, S. A. A comparative study of landslide susceptibility maps produced using support vector machine with different kernel functions and entropy data mining models in China. **Bull Eng Geol Environ**, v. 77, p. 647-664, 2018. DOI: <https://doi.org/10.1007/s10064-017-1010-y>.
- CPRM. Serviço Geológico do Brasil. **Geodiversidade do Estado do Rio Grande do Sul**. P. 250, Porto Alegre, 2010. Disponível em: <https://rigeo.sgb.gov.br/handle/doc/16774>. Acesso em: 14 ago. 2025.
- DE LIMA, F. F.; SAITO, S. M.; MORELLI, S. Rainfall thresholds and forest regeneration in post-landslide areas of the Atlantic Forest. **Natural Hazards**, v. 109, p. 1399–1418, 2021.
- DIAS, H. C. *et al.* Landslide recognition using SVM, Random Forest, and Maximum Likelihood classifiers on high-resolution satellite images: a case study of Itaóca, southeastern Brazil. **Brazilian Journal of Geology**, v. 51, n. 4, 2021. DOI: 10.1590/2317-4889202120200105.
- EGAS, H. M.; STABILE, R. A.; ANDRADE, M. R. M. *et al.* Inventário abrangente e avaliação inicial de deslizamentos de terra desencadeados pelas chuvas do outono de 2024 no Rio Grande do Sul, Brasil. **Landslides**, v. 22, p. 579–589, 2025.
- EM-DAT – The International Disaster Database. Natural Disasters. Centre for Research on the Epidemiology of Disasters – CRED, **Université Catholique de Louvain**, Belgium, 2018.
- FAGUNDES, G. C. L; AQUINO, C. M. S; SOUSA, M. A. Movimentos gravitacionais de massa: estudo de caso em Teresina, Piauí. **Revista Espaço e Geografia**, v. 25, n. 1, p. 295–321, 2023. Disponível em: <https://periodicos.unb.br/index.php/espacoegeografia/article/view/44030>. Acesso em: 1 set. 2025. DOI: 10.26512/2236-56562022e44030.
- FARAH, F. Ocupação urbana e instabilidade de encostas. **Coleção Habitar**, São Paulo, v. 2, p. 312, 2003.
- FEPAM. Fundação Estadual de Proteção Ambiental. Secretaria Estadual do Meio Ambiente. **Diagnóstico ambiental da bacia do Taquari-Antas, RS**: diretrizes regionais para o licenciamento ambiental das hidrelétricas – trecho médio e superior. Porto Alegre, FEPAM, 2001.

FERLA, A. K.; NARVAES, I. S.; KUPLICH, T. M. Métodos de machine learning e deep learning para mapeamento de supressão da vegetação em área de campo no bioma Mata Atlântica. In: **Anais do XXI Simpósio Brasileiro de Sensoriamento Remoto**, 2025, Salvador. *Anais eletrônicos...*, Galoá, 2025. Disponível em: <https://proceedings.science/sbsr-2025/trabalhos/metodos-de-machine-learning-e-deep-learning-para-mapeamento-de-supressao-da-vege?lang=en>. Acesso em: 22 out. 2025.

FERREIRA, K. R.; QUEIROZ, G. R. Medindo o Brasil a partir do espaço: tecnologias de big data e inteligência artificial. **AtoZ**, v. 10, n. 3, 2021, DOI: <https://doi.org/10.5380/atoz.v10i3.81966>.

FERREIRA, K.R.; QUEIROZ, G.R.; VINHAS, L. *et al.* Earth Observation Data Cubes for Brazil: Requirements, Methodology and Products. **Remote Sensing**, v. 12, 2020, DOI: <https://doi.org/10.3390/rs12244033>.

FERRI, G. A.; TOGNI, A. C. **A história da bacia hidrográfica Taquari-Antas**. Editora Univates. Lajeado, 2012.

FUNK, C.; PETERSON, P.; LANDSFELD, M. *et al.* The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data** v.2, n. 150066, 2015. DOI: <https://doi.org/10.1038/sdata.2015.66>.

HUANG, J.; JU, N. P.; LIAO, Y. J. *et al.* Determination of rainfall thresholds for shallow landslides by a probabilistic and empirical method. **Natural Hazards and Earth System Sciences**, v. 15, 2021, DOI: <http://dx.doi.org/10.5194/nhess-15-2715-2015>.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Mapa de Unidades de Relevo do Brasil**. Rio de Janeiro, ed. 2, 2006.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Eventos extremos de abril de 2024 no Brasil. **Notas Técnicas**, 2024. Disponível em: <https://portal.inmet.gov.br/notasTecnicas>. Acesso em: 11 set. 2025.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). Eventos extremos de setembro de 2023 no Brasil. **Notas Técnicas**, 2023. Disponível em: <https://portal.inmet.gov.br/notasTecnicas>. Acesso em: 27 set. 2025.

KAISER, E. A.; ROLIM, S. B. A.; GRONDONA, A. E. B. *et al.* Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area by Using Landsat-TM and TIRS Images. **Atmosphere**, v. 13, n. 3, p. 460, 2022. DOI: <http://dx.doi.org/10.3390/atmos13030460>.

LE CUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521 p. 436–444, 2015, DOI: <https://doi.org/10.1038/nature14539>.

LÓ, T. B.; CORRÊA, U. B.; ARAÚJO, R. M. *et al.* Temporal convolutional neural network for land use and land cover classification using satellite images time series. **Arabian Journal of Geosciences**, v.16, n.10, p 1-18, 2023, DOI: <https://doi.org/10.1007/s12517-023-11688-4>.

MEHMOOD, K.; ANEES, S. A.; MUHAMMAD, S. *et al.* Analyzing vegetation health dynamics across seasons and regions through NDVI and climatic variables. **Scientific Reports**, v. 14, n. 1, p. 1-22, 2024. DOI: <http://dx.doi.org/10.1038/s41598-024-62464-7>.

OLIVEIRA, G. G.; RUIZ, L. F. C.; GUASSELLI, L. A. *et al.* Random forest and artificial neural networks in landslide susceptibility modeling: a case study of the Fão River Basin, Southern Brazil. **Natural Hazards** v. 99, 1049–1073, 2019. DOI: [10.1007/s11069-019-03795-x](https://doi.org/10.1007/s11069-019-03795-x).

OLOFSSON, P. *et al.* Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, v. 148, p. 42–57, maio 2014.

PELLETIER, C.; WEBB, G. I.; PETITJEAN, F. Temporal convolutional neural network for the classification of satellite image time series. **Remote Sensing**, v. 11, n. 5, 2019.

PERBET, P.; GUINDON, L.; CÔTÉ, J. F. *et al.* Evaluating deep learning methods applied to Landsat time series subsequences to detect and classify boreal forest disturbances events: The challenge of partial and progressive disturbances. **Remote Sensing of Environment**, v. 306, 2024. DOI: <https://doi.org/10.1016/j.rse.2024.114107>.

POSIT. RStudio: Integrated Development for R. v. 2024.05.0, Boston, 2024. Disponível em: <https://posit.co/>. Acesso em: 9 set. 2025.

QUEVEDO, R. P.; MACIEL, D. A.; REIS, M. S. *et al.* Land use and land cover changes without invalid transitions: A case study in a landslide-affected area. **Remote Sensing Applications: Society and Environment**, v. 36, p. 101314, 2024. DOI: <https://doi.org/10.1016/j.rsase.2024.101314>.

SALEEM, N.; HUQ, M. E.; TWUMASI, N. Y. D. *et al.* Parameters derived from and/or used with digital elevation models (DEMs) for landslide susceptibility mapping and landslide risk assessment: a review. **ISPRS International Journal of Geo-Information**, v. 8, n. 12, 2019. DOI: <https://doi.org/10.3390/ijgi8120545>.

SANTOS, D. L.; FRAGOSO JR., C. R.; SOUZA, V. C. B. Limiar de precipitação com potencial de gerar deslizamentos nos complexos de risco em uma zona urbana. **Revista de Gestão de Água da América Latina**, v. 16, e12, 2019. DOI: <https://dx.doi.org/10.21168/reg.v16e12>.

SAUSEN, T. M.; LACRUZ, M. S. P. Sensoriamento remoto para desastres. **Oficina de Textos**, p. 285, São Paulo, 2015. P.

SHEYKHMUSA, M.; MAHDIANPARI, M.; GHANBARI, M. *et al.* Support vector machine versus random forest for remote sensing image classification: a meta-analysis and systematic review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 6308-6325, 2020.

SIMÕES, R. *et al.* Satellite image time series analysis for big earth observation data. **Remote Sensing**, v. 13, p. 2428, 2021.

TOAN, D. T.; DUC, D. M.; QUYNH, D. T. *et al.* Série de deslizamentos de terra induzidos por chuvas extremas e grandes deslizamentos de terra semelhantes a fluxos de água na comuna de Ho Bon, distrito de Mu Cang Chai, província de Yen Bai, Vietnã, em agosto de 2023. **Landslides**, v. 22, p. 2607–2622, 2025. DOI: <https://doi.org/10.1007/s10346-025-02544-5>.

TOMINAGA, L. K.; SANTORO, J.; AMARAL, R. **Desastres naturais: conhecer para prevenir**. São Paulo: Instituto Geológico, 2015.

TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 2. ed. Porto Alegre: Editora da Universidade, 1997.

XAVIER, M. O. **Automatização de inventários de deslizamentos aplicados à modelagem de suscetibilidade usando métodos de aprendizado de máquina**. 150 f. – Tese (Doutorado em Engenharia) – Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2025.

ZÊZERE, J. L.; PEREIRA, S.; MELO, R. *et al.* **Mapping landslide susceptibility using data-driven methods**. **Science of the Total Environment**, v. 589, p. 347-362, 2017.

Contribuições de autoria

1 – Camila Reigota Ferreira

Graduação em Geografia pela Universidade Federal de Santa Maria
<https://orcid.org/0009-0006-2453-720X> • camila.reigota@acad.ufsm.br
Contribuição: Escrita – Primeira redação, revisão e edição

2 – Waterloo Pereira Filho

Doutor em Geografia pela Universidade de São Paulo
<https://orcid.org/0000-0001-6449-6322> • waterloo@ufsm.br
Contribuição: Escrita – Revisão e edição.

3 – Igor da Silva Narvaes

Doutor em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais (INPE)
<https://orcid.org/0000-0002-9950-895X> • igor.narvaes@inpe.br
Contribuição: Escrita – Primeira Redação – Conceituação

4 – Andressa Kossmann Ferla

Mestre em Ciência e Tecnologia Ambiental pela Universidade Federal de Santa Maria
<https://orcid.org/0000-0003-1801-3355> • andressaferla94@gmail.com
Contribuição: conceituação, Metodologia, Administração do projeto, Supervisão, Escrita – revisão e edição

Como citar este artigo

FERREIRA, C. R.; PEREIRA FILHO, W.; NARVAES, I. S.; FERLA, A. K. Detecção automatizada de cicatrizes de deslizamentos de terra associado ao evento pluviométrico extremo em 2024 com uso de Inteligência Artificial: estudo de caso em um trecho da Bacia Hidrográfica Taquari Antas/RS. **Geografia Ensino & Pesquisa**, Santa Maria, v. 30, e94269, 2026. Disponível em: 10.5902/2236499494269 Acesso em: dia mês abreviado. ano.