



Uso de Redes Convolucionais para Mapeamento de Deslizamentos de Terra

Karoline Guedes de Souza

Discente, Universidade Federal do Paraná, Curitiba, Brasil, karoline.guedes@ufpr.br

Adriana Talita de França Almeida

Discente, Universidade Federal do Paraná, Curitiba, Brasil, adriana.franca@ufpr.br

Liamara Paglia Sestrem

Docente da Universidade Federal do Paraná, Curitiba, Brasil, liamara@ufpr.br

RESUMO: O presente estudo teve como objetivo o desenvolvimento e a aplicação de um sistema baseado em redes neurais convolucionais (CNN) voltado para a identificação de superfícies de terra por meio da análise de imagens de satélite. A metodologia proposta foi aplicada na região litorânea do Paraná, integrando imagens satélites de múltiplas fontes com modelos de aprendizagem profunda para monitoramento e análise preditiva. Dois modelos foram treinados: um classificador binário (deslizamento/não deslizamento) e outro segmentador, capaz de delimitar espacialmente as áreas afetadas. A base de dados incluiu imagens satélites de múltiplas fontes e registros georreferenciados de eventos anteriores. O sistema foi desenvolvido em Python, com suporte de bibliotecas especializadas, e integrado ao Google Earth Engine para aquisição e processamento automatizado de imagens. Os modelos apresentaram acurácia satisfatória no treinamento e validação, e a aplicação do sistema na área de estudo revelou seu potencial como ferramenta eficaz para o monitoramento contínuo e predição de deslizamentos.

PALAVRAS-CHAVE: Deslizamentos de terra, Redes Neurais Convolucionais, Sensoriamento remoto, Monitoramento.

ABSTRACT: This study aimed to develop and apply a system based on convolutional neural networks (CNN) for the identification of landslides through satellite image analysis. The proposed methodology was applied in the coastal region of Paraná, integrating satellite images from multiple sources with deep learning models for monitoring and predictive analysis. Two models were trained: a binary classifier (landslide/non-landslide) and a segmenter, capable of spatially delimiting affected areas. The database included satellite images from multiple sources and georeferenced records of previous events. The system was developed in Python, supported by specialized libraries, and integrated with Google Earth Engine for automated image acquisition and processing. The models showed satisfactory accuracy in training and validation, and the system's application in the study area revealed its potential as an effective tool for continuous landslide monitoring and prediction.

KEYWORDS: Landslides, Convolutional Neural Networks, Remote sensing, Monitoring.

1 INTRODUÇÃO

A intensificação dos eventos climáticos extremos, associada às mudanças globais no clima, tem contribuído para o aumento da frequência e magnitude de processos geodinâmicos naturais, tais como movimentos de massa. Esses fenômenos, ao incidirem sobre áreas ocupadas e resultarem em perdas materiais, sociais ou ambientais, são classificados como desastres naturais. No Brasil, os escorregamentos de solos e/ou rochas ocorrem, normalmente, associados a eventos pluviométricos intensos e prolongados e podem ser intensificados por ações antrópicas.

Em paralelo, o avanço do conhecimento no período de Evolução Tecnológica (ou Era Digital) impulsionado pelo aparecimento e desenvolvimento das inteligências artificiais (IA) tem permitido o desenvolvimento de soluções aplicadas em diversas áreas. As IAs representam ferramentas onde estruturas são programadas com o objetivo da realização de tarefas complexas com capacidade cognitiva, em certo



nível, similar à humana. Tais ferramentas podem ser ramificadas em diversas categorias, destacando-se a Machine Learning (ML), técnica caracterizada pelo aprendizado de máquina que envolve procedimentos de avaliação de dados, voltados à automatização de padrões analíticos. Parte-se do princípio de que sistemas tecnológicos têm a capacidade de aprender com o uso de dados a partir de padrões e são capazes de tomar decisões, aperfeiçoando-se sem interferência humana no processo, conforme descrito por Morais & Branco (2023).

Para o presente trabalho, buscou-se fundamentar o desenvolvimento e a aplicação de um sistema – mais especificamente aqueles do tipo Machine Learning (ML) e suas subdivisões, com destaque para o aprendizado profundo (Deep Learning – DL) – para a identificação automática das ocorrências de deslizamentos dentro da área de estudo. Por fim, os resultados foram organizados em representações georreferenciadas que possibilitam a visualização dos pontos deslizados, oferecendo uma ferramenta de apoio à análise técnica e à tomada de decisão — dando agilidade às ações necessárias para que um fenômeno natural não se torne um desastre, reduzindo assim eventuais consequências e danos à sociedade.

2 REVISÃO BIBLIOGRÁFICA

A compreensão e análise dos eventos requer uma abordagem multidisciplinar que integre aspectos geológicos, hidrológicos e técnicas contemporâneas de análise de dados. Porém, o foco deste artigo é na utilização das tecnologias disponíveis atualmente, uma vez que as tecnologias de aprendizagem de máquina e inteligência artificial (IA) avançaram significativamente, tornando-se ferramentas essenciais na análise de dados, conforme abordado por Forsyth & Ponce (2011).

Os termos IA, aprendizado de máquina (*Machine Learnig* - ML) e aprendizado profundo (*Deep Learnig* - DL) são frequentemente confundidos, apesar de suas interconexões. A IA refere-se a sistemas que simulam ações humanas e é o nível macro, enquanto o ML é um subcampo da IA que se concentra em aprender a partir de dados. O crescimento do ML, especialmente em visão computacional, foi impulsionado pela disponibilidade de bases de dados rotuladas, que permitiu o surgimento dos DLs, o qual utiliza múltiplas camadas para processar informações, permitindo a resolução de problemas complexos a partir de conjuntos de menores dados, segundo Goodfellow, Bengio, & Courville (2016) com essas divisões é possível resolver problemas complexos a partir de pequenos conjuntos com várias informações.

2.1 Redes Neurais Convolucionais (CNN)

A motivação para concepção de redes neurais artificiais surgiu com o reconhecimento da capacidade do cérebro humano em resolver problemas altamente complexos, não-lineares e de rápido processamento, segundo Haykin (2004). As redes neurais podem ser definidas como um processador maciçamente paralelo e distribuído, composto por unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.

Segundo Karpathy (2016), as redes neurais convolucionais (CNN) são semelhantes às regulares, sendo formadas por blocos de neurônios os quais recebem uma informação de entrada, aplica-se um produto escalar entre os pesos do neurônio e os valores de entrada e, posteriormente uma função de ativação no resultado do produto. O diferencial está na suposição inicial onde, para esse tipo de arquitetura, todas as entradas são imagens. Por isso, a CNN trabalha com neurônios dispostos em 3 dimensões: largura, altura, profundidade, onde profundidade está referida a uma terceira dimensão de um volume de ativação. Um exemplo desse modelo pode ser visto na Figura 1.

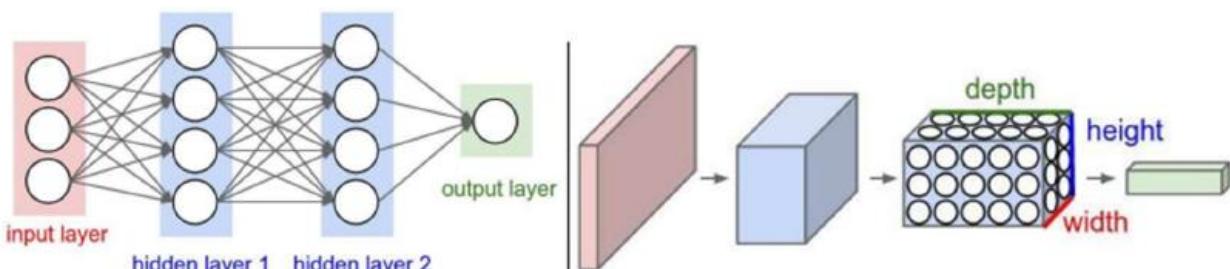


Figura 1. Tratamento de imagens com CNN (Karpathy, 2016).

2.1.1 Definição e Estrutura de CNN

Uma CNN é um tipo de arquitetura de DL caracterizado por possuir camadas. Sendo assim, uma CNN pode também ser definida pelo empilhamento de três tipos principais de camadas: Camada de Convolução, Camada de Pooling e Camada Totalmente Conectada.

Na camada de convolução é aplicado um filtro ou kernel nas imagens de entrada, de forma a extrair determinadas características delas, para que seja encontrado um padrão e posteriormente auxilie na identificação de novas imagens. O kernel funciona como uma janela deslizante que irá percorrer a imagem de entrada da esquerda para a direita e de cima para baixo por todo seu volume, realizando a multiplicação entre a sua matriz e o contexto atual em que a janela se encontra e, somando os valores da multiplicação resultante, conforme mostra a Figura 2.

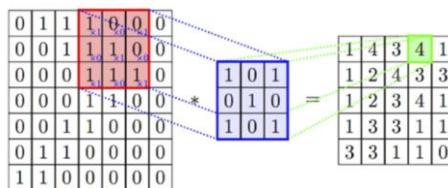


Figura 2. Exemplo de uma operação de convolução com kernel 3x3 (Gilleman, D., 2020)

Entre duas camadas de convolução pode ser inserida uma camada de pooling (tradução livre, agrupamento), que serve para simplificar as camadas. É realizado por meio de um stride não unitário, sendo 2 o tamanho mais comum, de forma que as dimensões espaciais são reduzidas pela metade. Basicamente, assim como na convolução, é escolhida uma unidade de área para transitar por toda a saída da camada anterior, a qual irá resumir a informação daquela área em um único valor. No modelo apresentado na Figura 3 é possível verificar o “índice de Max Pooling” que irá definir qual será esse valor reduzido.

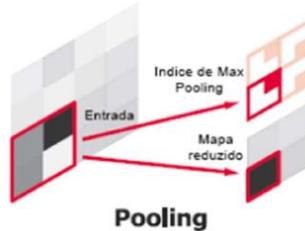


Figura 3. Camada de Pooling. (Noh, Hong, & Han, 2015).

Já a camada totalmente conectada, deve conectar todos os neurônios da camada anterior a cada um dos neurônios da camada atual. Quanto mais profunda a rede, mais características específicas podem ser mapeadas, devendo-se, contudo, evitar o overfitting, ou seja, um aprendizado tão profundo que a rede não consegue generalizar e consegue apenas reconhecer as entradas de treinamento.

3 METODOLOGIA

Dada a necessidade de dados de deslizamentos registrados com localização temporal e espacial, foi utilizado o banco de dados desenvolvido por Ribeiro (2021) em seu Trabalho de Conclusão de Curso. O autor catalogou eventos na região Leste do Paraná, que com o auxílio do software QGIS (ferramenta de Geoprocessamento) foi possível georreferenciar cada um dos eventos de deslizamento e visualizá-los de forma mais objetiva para a delimitação da área de estudo.

A área abordada neste estudo foi delimitada a partir do interesse pela região litorânea do Paraná, combinado à maior concentração de eventos de deslizamentos disponibilizados pelo banco de dados, totalizando 2.026 ocorrências distribuídas entre 9 anos, estes sendo entre os anos de 1995 e 2018. Porém, retirando os deslizamentos ocasionados por chuvas extraordinárias em 2011, o banco de dados ficou com 24 deslizamentos. Tal região está localizada entre as coordenadas 25,41°S a 25,64°S de latitude Sul e 48,96°W a 48,56°W de longitude Oeste, e compreende uma área total de 1040 km², abrangendo partes dos municípios de Antonina, Guaratuba, Morretes e Paranaguá, em uma região de transição entre o litoral paranaense e o primeiro planalto. Essa delimitação pode ser vista na Figura 4.



2025

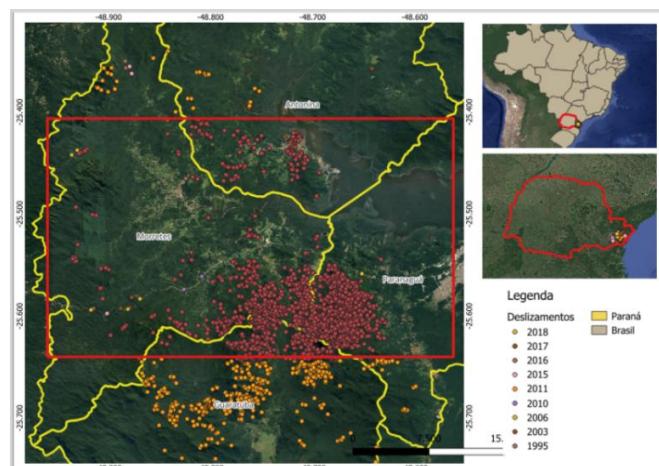


Figura 4. Área de estudo

Para automatizar a identificação dos deslizamentos, foram utilizadas imagens de satélite que alimentaram dois modelos de Redes Neurais Convolucionais (CNN): o primeiro para classificação binária (deslizamento/não deslizamento) e o segundo para delimitação espacial das áreas afetadas. Com essas informações, foi possível extrair dados como coordenadas dos eventos, índice de confiança da previsão e origem satelital da imagem.

A escolha da linguagem de programação Python se deu por sua sintaxe limpa e intuitiva, facilitando a interpretação e o desenvolvimento. O ambiente Google Colaboratory (Google Colab) foi selecionado para a execução dos códigos, devido à sua integração com recursos em nuvem.

No desenvolvimento das CNNs, durante o pré-processamento foram definidos hiperparâmetros essenciais que influenciaram o treinamento, como o número de épocas (10) a qual refere-se a uma passagem completa pelo conjunto de treinamento, conforme descrito por Goodfellow, Bengio e Courville (2016) e as taxas de aprendizagem (0,0001), que controla o tamanho do passo na atualização dos pesos durante a descida do gradiente, definido com base em Bishop (2006). Ambos parâmetros foram adotados a fim de evitar overfitting.

Para a implementação, foram utilizadas bibliotecas especializadas em redes neurais, como TensorFlow e Keras. Os modelos foram treinados com dois bancos de imagens públicos do Kaggle, mesclados para aumentar a eficiência do treinamento. O primeiro dataset, "bijie-landslide-dataset", contém imagens da cidade de Bijie, na China, com e sem deslizamentos, enquanto o segundo, "Landslide Segmentation", possui imagens com deslizamentos e máscaras de segmentação. O conjunto de dados final foi dividido em três partes: 1.400 imagens para treinamento, 403 para validação e 200 para teste. Essa divisão foi essencial para evitar Data leakage, - utilização de informações futuras para realizar a previsão. Exemplo das imagens contidas nos conjuntos podem ser vistos abaixo na Figura 5.



Figura 5. Exemplos de imagens dos datasets utilizados. (Kaggle, 2024)

O primeiro modelo desenvolvido baseou-se em uma classificação binária onde 0 = Não deslizamento e 1 = Deslizamento. Já o segundo modelo teve como objetivo principal segmentar a área deslizada para que, entre dias consecutivos, houvesse um comparativo identificando se o deslizamento já foi mapeado ou representa um novo evento.

De forma geral, os modelos seguiram os seguintes passos: (i) Configuração do ambiente e hiperparâmetros, (ii) Carregamento e pré-processamento das imagens, (iii) Definição de uma CNN, (iv) Treinamento do modelo, (v) Validação do modelo, (vi) Teste do modelo. A etapa de definição do modelo é

onde são definidas as camadas da rede convolucional. A camada construída para ambos modelos segue o apresentado na Figura 6.

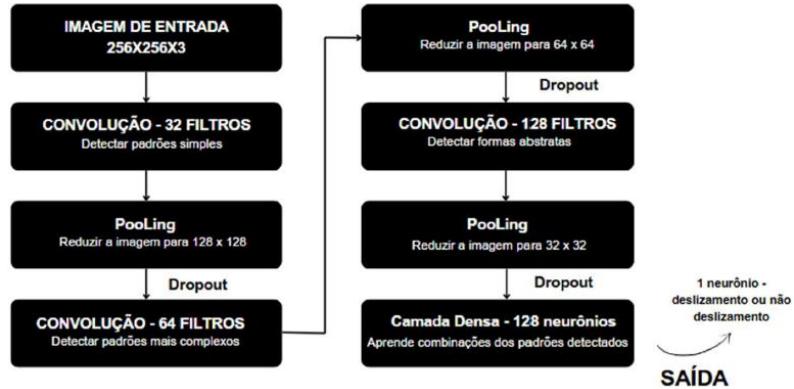


Figura 6. Camada da rede neural desenvolvida.

Após a definição das camadas de Pooling acrescentou-se uma etapa adicional de Dropout com a finalidade de desligar aleatoriamente 25% dos neurônios, a fim de evitar o overfitting em cada época.

Os modelos desenvolvidos apresentaram alta acurácia no treinamento e validação, conforme visto na Figura 7. Importante ressaltar que pelo fato de ser um Machine Learning, ou seja, aprender por repetições, o modelo de segmentação precisou ser retreinado e por isso o gráfico já inicia com acurácia alta, diferente do apresentado pelo modelo de classificação.

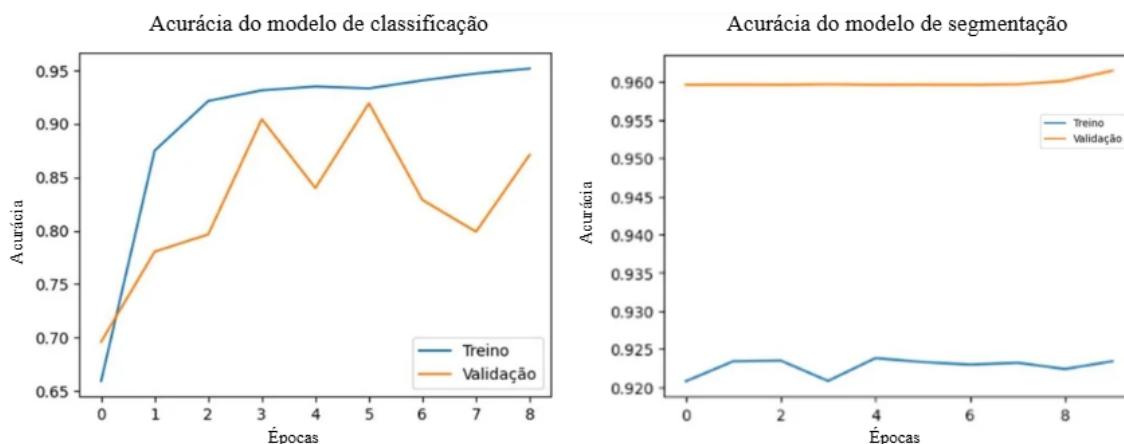


Figura 7. Acurácia dos modelos desenvolvidos.

Optou-se por utilizar o Google Earth Engine (GEE), uma plataforma de análise geoespacial baseada em nuvem que oferece um timelapse com mais de 40 anos de imagens de satélite. O GEE integra dados de diversos satélites, todos acessíveis por meio de uma API (Application Programming Interface) disponível em Python, o que facilitou a comunicação com o Google Colab.

No que diz respeito aos parâmetros analisados, foram estudadas as órbitas e a resolução espacial dos satélites. A resolução temporal também foi avaliada, sendo definida como a frequência com que o sensor passa sobre o mesmo local em um determinado intervalo de tempo. A seleção dos satélites foi realizada com base nas informações disponíveis no site da National Aeronautics and Space Administration (NASA), conforme a Tabela 1.

Tabela 1. Satélites utilizados

| Satélite | Resolução (m) | Revisita (dias) | Órbita | Período ativo |
|------------|---------------|-----------------|--------------------------------------------------|---------------|
| LandSat 5 | 30 | 16 | | 1984 – 2013 |
| LandSat 7 | 30 | 16 | Polar heliosíncrona (Vertical, 0º de inclinação) | 1999 – 2025 |
| LandSat 8 | 30 | 8 | | 2013 – 2025 |
| Sentinel-2 | 10 | 5 | | 2015 – 2025 |

2025

Os satélites selecionados utilizam sensores ópticos, que captam a luz visível e outras partes do espectro eletromagnético refletidas pela superfície da Terra, por esse motivo estão sujeitos a interferências causadas pelas nuvens. Para mitigar esse problema, foram filtradas somente as imagens que possuíam menos de 25% do conteúdo coberto por nuvens, o que impactou diretamente na quantidade de imagens disponíveis.

As imagens foram inicialmente extraídas do Google Earth Engine (GEE) com uma resolução de 1024x1024 pixels, resultando em imagens grandes e distantes. Para aprimorar a análise, essas imagens foram divididas em uma malha de tiles, com dimensões de 1 km x 1 km para o satélite Sentinel e 3 km x 3 km para os satélites Landsat. Essas dimensões foram testadas durante o mapeamento e mostraram-se adequadas para preservação das características importantes das imagens sem distorções. Para cada imagem coletada, foram gerados 1.215 tiles para o Sentinel e 135 tiles para o Landsat.

Após essas definições, foi desenvolvido um terceiro programa com o objetivo de aplicar os modelos na área de interesse. O fluxo de trabalho seguiu a seguinte ordem: (i) preparação do ambiente de execução (ii) definição da área de interesse e satélite a ser utilizado, (iii) geração de tiles, (iv) definição do período e filtro das nuvens, (v) importação dos modelos treinados, (vi) Loop principal: processamento de cada tiles, (vii) construção das informações na tabela resumo.

A validação do método automatizado foi realizada comparando os deslizamentos mapeados com os registrados no banco de dados de referência. Nesta etapa fez-se uma análise manual devido à interferência de nuvens, que gerou falsos positivos. Após uma análise cuidadosa, cada ocorrência recebeu um ID para ser plotado no mapa, e cada ponto do banco de dados foi avaliado individualmente para verificar se o modelo foi capaz de identificá-lo.

Os pontos foram classificados em quatro categorias: (I) Ponto validado, (II) Ponto validado com ajuste, (III) Ponto não validado com justificativa e (IV) Ponto não validado.

4 ANÁLISE DE RESULTADOS

Os resultados demonstraram que todos os pontos inicialmente não validados foram justificados, classificando-se na terceira categoria, conforme apresentado anteriormente. Com isso, conclui-se que, se o banco de dados de imagens de satélite fosse de maior qualidade, sem áreas sem informação ou utilizando satélites de radar para evitar nuvens, o modelo teria capacidade para mapear todos os pontos de referência.

Além dos pontos validados pelo banco de dados, foi possível mapear novos deslizamentos durante os 9 anos estudados, sendo 41 deslizamentos no total. Para utilizar o satélite Sentinel 2, que possui melhores condições e não havia sido utilizado até o momento por questões de disponibilidade de imagens optou-se por aplicar a metodologia para o primeiro mês de 2019, onde foi possível mapear mais 22 deslizamentos. Os deslizamentos mapeados estão ilustrados abaixo, na Figura 8.

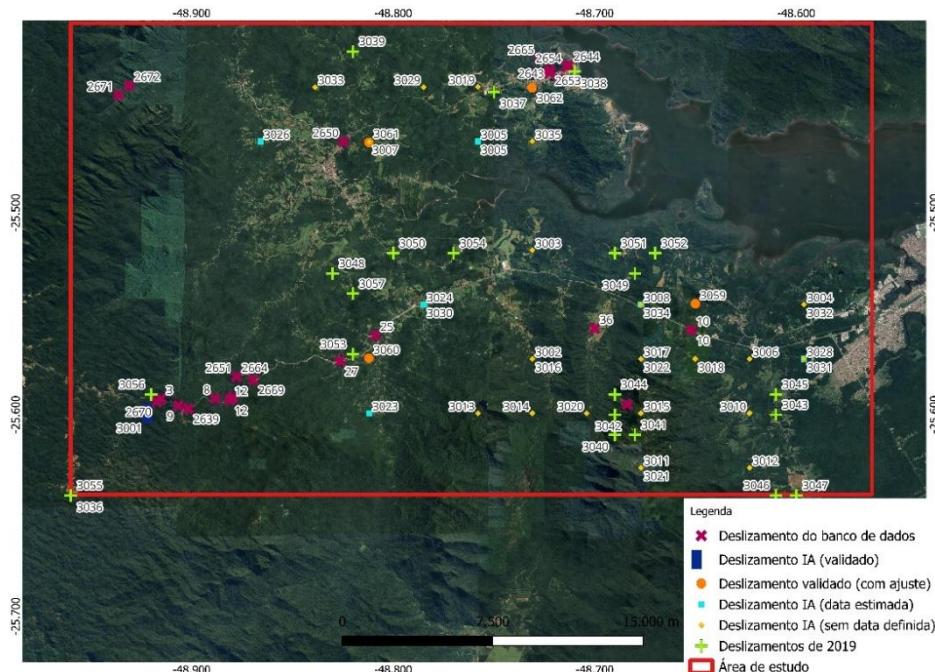


Figura 8. Deslizamentos mapeados.



4.1 Análise dos Satélites

Os satélites empregados neste estudo apresentam características orbitais semelhantes em termos de trajetória e orientação, diferenciando-se principalmente pelos parâmetros operacionais já abordados: resolução espacial e periodicidade. Os percentuais de participação de cada satélite no mapeamento podem ser vistos na Figura 9.

| Colaboração de cada satélite | | | | |
|------------------------------|-----------------------------|---------------------|------------------------|-----------------|
| Satélite | Quantidade de Deslizamentos | Quantidade de meses | Deslizamentos mapeados | Meses Presentes |
| Landsat 5 | 9 | 72 | 14.29% | 66.06% |
| Landsat 7 | 21 | 108 | 33.33% | 99.08% |
| Landsat 8 | 11 | 48 | 17.46% | 44.04% |
| Sentinel-2 | 22 | 1 | 34.92% | 0.92% |

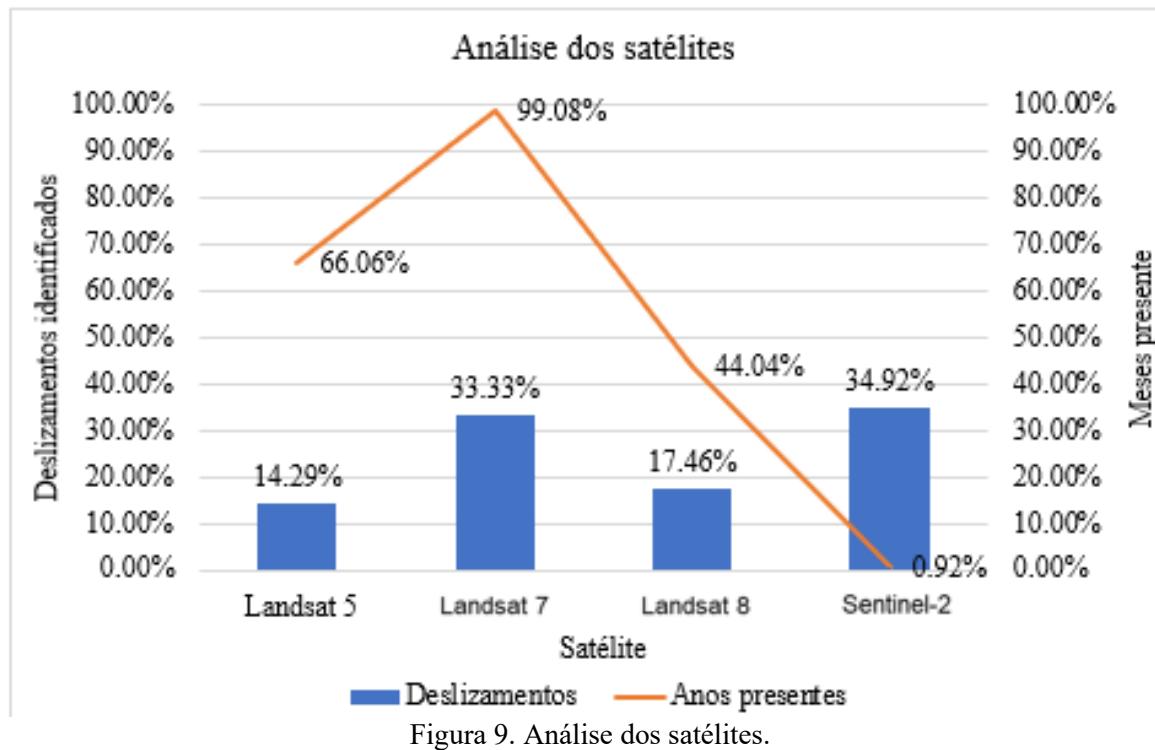


Figura 9. Análise dos satélites.

Os dados revelam que, embora o Landsat 7 e o Sentinel-2 apresentem percentuais semelhantes na quantidade absoluta de deslizamentos, a análise temporal demonstra uma diferença significativa em sua eficiência operacional. O Landsat 7 esteve disponível em 99% dos meses analisados, enquanto o Sentinel 2 em menos de 1% do período total.

Esta diferença torna evidente a superioridade do Sentinel-2 para o mapeamento de deslizamentos a partir de 2019. No entanto, os resultados também indicam que, na ausência deste sensor, a combinação de outros satélites disponíveis apresenta um desempenho satisfatório para o monitoramento contínuo desses eventos geológicos..

5 CONCLUSÃO

Este trabalho apresentou a aplicação de modelos de classificação e segmentação baseados em redes neurais convolucionais (CNN) para o mapeamento de deslizamentos de terra por meio da análise de imagens de satélite, alcançando uma precisão superior a 95% nas fases de treinamento e validação. A confiabilidade



foi maior nos modelos treinados com máscaras de segmentação, destacando a importância dos bancos de dados públicos utilizados.

A validação dos dados foi feita comparando os resultados de detecção com uma base de dados existente, mostrando eficácia do método na identificação tanto de eventos próximos a rodovias como também em regiões remotas, que muitas vezes não tem seus deslizamentos registrados pelos métodos convencionais. Embora imagens de satélites como Landsat 5 e 7, tenham sido utilizadas para eventos mais antigos, os satélites mais recentes apresentaram melhor qualidade de imagem e cobertura temporal, além disso, o Sentinel-2 superou a família Landsat em desempenho, devido à sua maior resolução espacial e frequência de revisita, permitindo uma análise detalhada com tiles de 1 km².

Um pré-processamento rigoroso das imagens de entrada foi identificado como essencial, pois a qualidade das imagens impacta diretamente o aprendizado da rede. Dessa forma, a eficácia da metodologia proposta depende de dois fatores primordiais: qualidade das imagens e da frequência de aquisição.

Apesar dos resultados promissores, o modelo apresenta algumas limitações, como já abordado relacionado as imagens de satélite, especialmente em áreas com cobertura frequente de nuvens. Além disso, embora a abordagem tenha sido eficaz na região litorânea do Paraná, sua generalização para outras áreas geográficas requer ajustes relacionados à topografia, uso e cobertura do solo e tipos de vegetação. Por fim, ainda que não tenha sido foco deste trabalho, é possível realizar uma comparação com métodos convencionais de mapeamento de deslizamentos, o que contribuiria para evidenciar com mais clareza as vantagens operacionais e preditivas da metodologia baseada em redes neurais convolucionais.

Em resumo, com o avanço no acesso a imagens de satélites de alta resolução, aliado à melhoria contínua das bases de treinamentos, a proposta se torna cada vez mais precisa e eficiente, representando uma solução promissora para a prevenção de desastres naturais e gestão de riscos geotécnicos.

REFERÊNCIAS BIBLIOGRÁFICAS

- Almeida, A. T. F.; Souza, K. G. *Uso de Redes Convolucionais para Mapeamento de Deslizamentos de Terra e a Correlação com seus Índices Pluviométricos*. 2025. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Setor de Tecnologia, Universidade Federal do Paraná, Curitiba, 2025.
- Bishop, C. M. *Pattern Recognition and Machine Learning*. Springer, 2006.
- Forsyth, D.; Ponce, J. *Computer Vision: A Modern Approach*. Nova: Prentice Hall, 2011.
- Gilleman, D. *Deep Learning Essentials. Convolutional Neural Networks Essentials*, 2020. Disponível em: <http://www.deeplearningessentials.science/convolutionalNetwork/>. Acesso em:
- Goodfellow, I.; Bengio, Y.; Courville, A. *Deep Learning*. MIT Press, 2016.
- Haykin, S. *Neural Networks: a comprehensive foundation*. Hamilton, Ontario, Canadá: Person Education, 2004.
- KAGGLE. Bijie Landslide Dataset, 2024. Disponível em: <https://www.kaggle.com/datasets/yolowsb/bijie-landslide-dataset>.
- Karpathy, A. Convolutional neural networks for visual recognition. *Neural networks*, 2016.
- Morais, F. D.; Branco, V. R. *A Inteligência Artificial: conceitos, aplicações e controvérsias*. XX SIMPÓSIO INTERNACIONAL DE CIÊNCIAS INTEGRADAS DA UNAERP, 2023.
- National Aeronautics And Space Administration (NASA). Landsat 5. Disponível em: <https://landsat.gsfc.nasa.gov/satellites/landsat-5/>.
- Noh, H.; Hong, S.; Han, B. *Learning Deconvolution Network for Semantic Segmentation*. Proceedings of the IEEE international conference on computer vision, 2015.
- Ribeiro, L. H. *Banco De Dados De Movimentos Gravacionais De Massa E Pluviosidade Do Litoral Do Estado Do Paraná*. 2021. Trabalho de Conclusão de Curso (Geologia) – Universidade Federal do Paraná, Curitiba, 2021.