

# UTILIZAÇÃO DE REDES ADVERSÁRIAS GENERATIVAS (GANS) PARA MELHORAR A VISUALIZAÇÃO DE MOVIMENTOS DE MASSA EM IMAGENS DE SATÉLITE

Marco Antônio da Rosa Soares<sup>1</sup>  
Franqueline Monback Noschang<sup>2</sup>  
Romario Trentin<sup>3</sup>

## INTRODUÇÃO

Os eventos de precipitação extrema no estado do Rio Grande do Sul causaram movimentos de massa e inundações, resultando em perda de vidas, pessoas desabrigadas, danos a estruturas urbanas e prejuízos a áreas de cultivo. De acordo com o INMET (2024), os acumulados de chuva durante o mês de maio de 2024 ultrapassaram a média histórica do estado, com a capital Porto Alegre registrando o mês mais chuvoso desde o ano de 1910.

Os movimentos de massa, segundo Maciel Filho e Nummer (2011), são um deslocamento conjunto de uma porção de solo e/ou rocha, envolvendo tanto volume quanto massa. Esses movimentos podem ser classificados em corridas, rastejos, quedas e escorregamentos, podendo apresentar mais de um tipo em um evento, sendo a velocidade e o material transportado a principal diferença entre os diferentes processos (Guidicini e Nieble, 1983).

A elaboração de um inventário é uma das técnicas para o mapeamento e maior conhecimento dos movimentos de massa, essa prática permite uma melhor estratégia na ocupação e planejamento da área em escala regional (WIECZOREK, 1984). Os inventários geológicos podem ser diferenciados conforme a abrangência temporal que é feita do evento, se é inventariado os fenômenos em um evento, em um período histórico, em uma estação ou se são feitos múltiplos inventários ao longo do tempo (GUZZETTI et al., 2012).

A evolução tecnológica permitiu novas maneiras para a organização de inventários, algumas ferramentas utilizadas ao longo do tempo foram: interpretação de fotos aéreas (WIECZOREK, 1984), GIS (CHAU et al., 2004), aprendizado de máquina

---

<sup>1</sup>Mestrando do Programa de Pós Graduação em Geografia da Universidade Federal de Santa Maria – UFSM, ma-arco@hotmail.com;

<sup>2</sup>Graduanda pelo curso de Geografia – Bacharelado da Universidade Federal de Santa Maria – UFSM, [franqueline.noschang@gmail.com](mailto:franqueline.noschang@gmail.com);

<sup>3</sup>Professor associado do departamento de geociências da Universidade Federal de Santa Maria – UFSM, [romario.trentin@gmail.com](mailto:romario.trentin@gmail.com);

(WANG et al., 2021) e se observa uma crescente nas aplicações utilizando algoritmos da visão computacional (CHENG et al., 2021). O mapeamento dos fenômenos em diferentes momentos permite um maior entendimento acerca dos mesmos, o que pode possibilitar no conhecimento da frequência e impacto dos desastres em questão (MESSERI et al., 2015).

Nesse contexto, o uso de algoritmos da visão computacional que permitem a identificação automática de movimentos de massa em imagens de satélite se apresenta como uma solução viável para diminuir o tempo necessário para a elaboração de múltiplos inventários. As metodologias na literatura para essa tarefa se dividem entre as baseadas em estatística e as com base no aprendizado de máquina (CHENG et al., 2021), as do primeiro grupo se encontram principalmente apoiadas em quantificações computacionais na área de *clustering*, alguns exemplos de algoritmos são k-Nearest Neighbor (knn) (MARJANOVIC, BAJAT E KOVACEVIC, 2024) e K-means (HACIEFENDIOĞLU, SÜLEYMAN E GÖKHAN, 2023).

As técnicas baseadas em aprendizado de máquina utilizam ferramentas para treinar algoritmos a reconhecer padrões em conjuntos de dados (MONARD e BARANAUSKAS, 2003). Uma série de trabalhos nessa área com o objetivo de detecção de movimentos de massa utilizam Redes Neurais Convolucionais (CNN) (ULLO et al., 2021; DING et al., 2016), uma das arquiteturas mais conhecidas na atualidade. O uso de redes neurais permite ao algoritmo aprender e adaptar-se ao problema específico, como a detecção de movimentos de massa.

Dentro das CNNs se destaca a arquitetura “You Only Look Once” (YOLO), criada por REDMON et al. (2016), uma eficiente ferramenta que por meio da divisão da imagem em grades realiza a previsão de objetos dentro de cada retângulo definido pela grade. Uma das problemáticas dos algoritmos de *deep learning* é a necessidade de um *dataset* robusto, com um grande número de imagens em boa qualidade (MILZ et al., 2018). Em vista disso, o uso de imagens de satélite com YOLO encontra o obstáculo da resolução do produto de sensoriamento remoto, especificamente, o zoom necessário para a visualização do movimento de massa gera a pixelização da imagem, impedindo a identificação da feição pelo algoritmo.

Uma das soluções vistas na literatura é o uso de Redes Adversárias Generativas (GANs) para melhorar a qualidade da imagem, sua arquitetura consiste em um gerador, que possui o objetivo de gerar informações novas, e o discriminador, que busca distinguir as informações reais das falsas (WANG et al., 2020). Algumas aplicações desse método são vistas em Singh e Komodakis, 2018, que utiliza GANs para retirar

nuvens de imagens do Sentinel-2, e em Beaulieu et al, 2018, que, por meio de *image-to-image translations*, ampliou imagens utilizando as arquiteturas Cycle-GAN e Bicycle-GAN.

Em vista disso, o presente trabalho objetiva utilizar GANS, em específico a REAL-ESRGAN (WANG et al, 2021), para melhorar as imagens de satélites com movimentos de massa ocorridos no evento climático extremo no Rio Grande do Sul no final de abril e aumentar o zoom sem danificar a forma das feições, por fim, procura-se analisar os resultados obtidos.

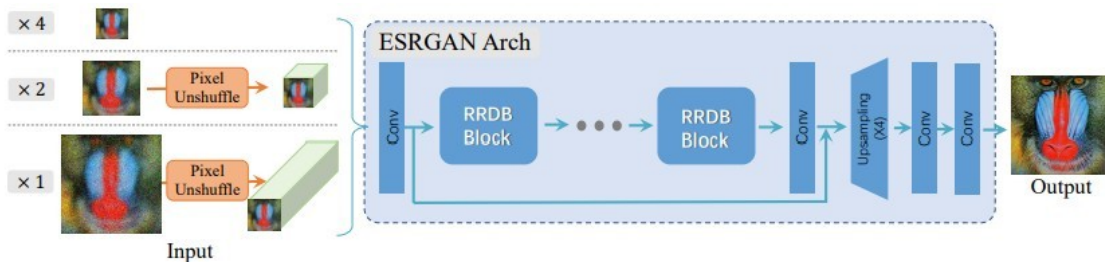
## MATERIAL E MÉTODO

A coleta das imagens foi realizada utilizando o *software* de captura de tela Lightshot, com a criação de um retângulo que cobria todo o movimento de massa na imagem em questão, posteriormente, a imagem foi salva no formato de arquivo .png a fim de garantir a melhor qualidade possível nessa etapa. Os movimentos de massa foram identificados manualmente pelo autor com uma imagem adquirida da empresa Planet Labs PBC, utilizou-se uma licença estudantil disponibilizada pela mesma, no software ArcGis Pro, com licença disponibilizada para o grupo de pesquisa pela universidade.

A imagem original foi melhorada e ampliada em 4 vezes utilizando a Real-ESRGAN (Enhanced Super Resolution Generative Adversarial Networks) de Wang et al., 2021, a mesma foi copiada do GitHub do criador do algoritmo para ambiente local. O método é uma adaptação para imagens reais do ESRGAN, proposto por Wang et al., 2018. Os pesos utilizados foram os pré-treinados fornecidos pelos autores no GitHub, uma vez que o número de imagens disponíveis não seria suficiente para um treinamento específico voltado a imagens de satélite.

O gerador do Real-ESRGAN é composto por um componente central denominado Residual-in-Residual-Block (RRDB), uma arquitetura (Figura 1) que engloba blocos densos (RRDB), os quais possuem camadas convolucionais e função de ativação Leaky Rectified Linear Unit (Leaky ReLU). O discriminador é composto por uma arquitetura U-Net com conexões de salto e *spectral normalization*, proposto por Miyato et al., 2018, que possui o objetivo de estabilizar o treinamento do discriminador.

Figura 1: Arquitetura do Real-ESRGAN



Fonte: Wang et al. (2021).

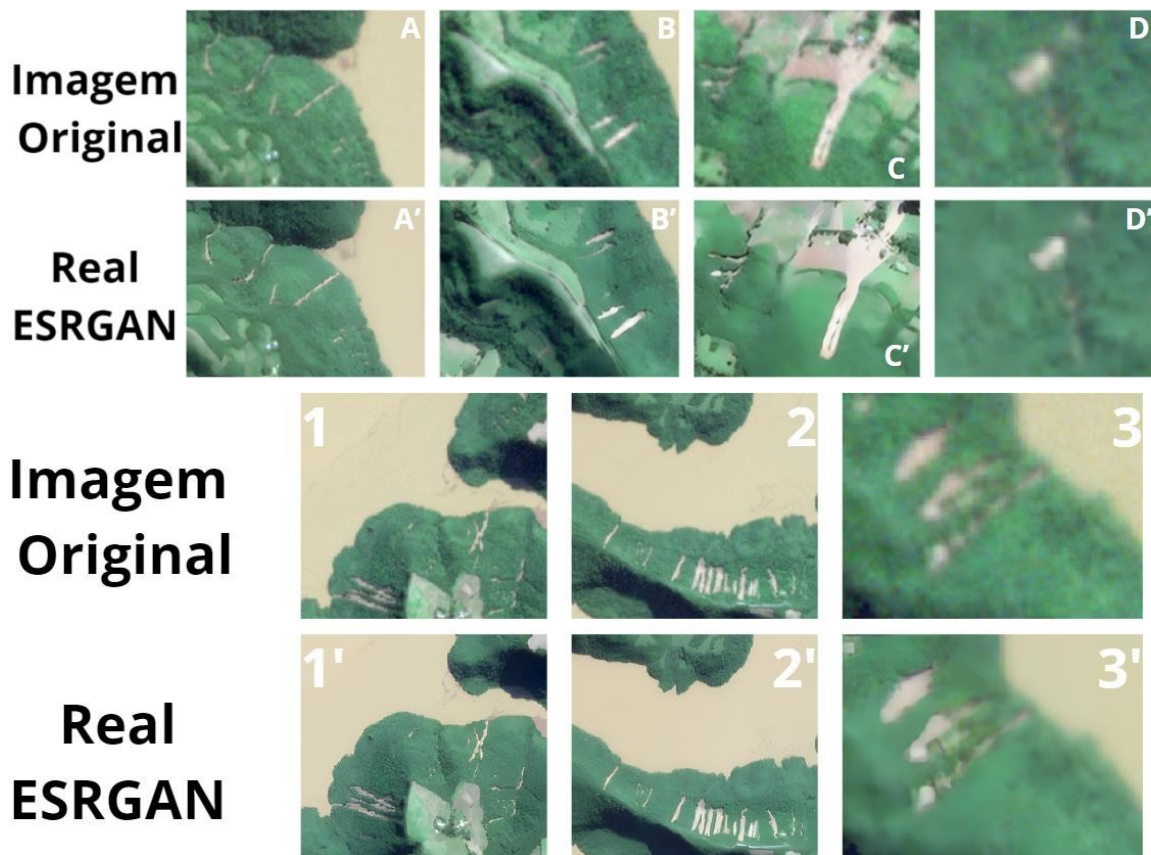
Um processo extra, denominado *Pixel Unshuffle*, é realizado quando a ampliação da imagem é 1x ou 2x, diminuindo a resolução espacial e consequentemente o custo computacional para a execução do algoritmo, posteriormente é realizado o *Pixel Shuffle* para restaurar a resolução. As configurações da máquina utilizada para o processamento das imagens foi:

- CPU: AMD Ryzen 7 5700X
- Memória: 2x Kingston Fury Beast 16GB 3200MHz, CL16
- GPU: Nvidia RTX 3060 TI 12GB

## RESULTADOS E DISCUSSÃO

A discussão dos resultados foi feita utilizando análise visual, entretanto, verifica-se em trabalhos similares uma junção desse tipo de análise com métodos quantitativos (NOGUEIRA et al., 2023; EDULA et al., 2023). O algoritmo melhorou a qualidade da imagem e ampliou-a em quatro vezes. Os resultados apresentados (Figura 2) são satisfatórios para o objetivo proposto, apesar dos pesos utilizados no treinamento não serem específicos. Esses pesos podem ser refinados por meio de um treinamento direcionado, utilizando imagens relacionados ao objeto de estudo, conforme visto em Nogueira et al., 2023.

Figura 2: Comparação entre a imagem original e a ampliada com Real-ESRGAN



Fonte: Elaborado pelos autores (2024).

A Figura 2 demonstra que as imagens coletadas com baixa ampliação foram significativamente aprimoradas pelo algoritmo, permitindo uma demarcação mais clara das bordas dos movimentos de massa. Nas imagens de número 1 e 2, é possível observar que a marcação da cicatriz e do ponto de ruptura são facilitadas com o uso do algoritmo, especialmente quando há uma série de movimentos próximos.

A demarcação precisa da cicatriz é crucial quando o objetivo do usuário é realizar uma segmentação de instância em vez de uma detecção de objetos por caixas delimitadoras (*bounding boxes*). A segmentação de instância é mais adequada para este caso, pois permite uma análise mais detalhada, encontrando os eventos com maior proporção, uma vez que é possível ter uma ideia geral da área afetada pelo movimento de massa.

Um ponto negativo do uso do algoritmo é que a imagem melhorada pelo algoritmo pode ser apenas utilizada para análises visuais, o que se apresenta como um grande limitante para a sua aplicação em grande parte dos cenários na área da Geografia Física. Nesse contexto, afirma-se possível a criação de um *script* adicional para a utilização do



formato .tiff com o Real-ESRGAN, entretanto, a tarefa exige um elevado conhecimento computacional e testes para verificar os resultados.

Em contraste, as imagens D e 3, obtidas com alta ampliação, resultaram em pixelização e sofreram degradação adicional após o processamento pelo algoritmo, exibindo borrões e perdas de detalhe. Um efeito similar ocorreu em áreas com extensa porção sem vegetação, como mostrado em C. Nota-se uma perda de textura e um processo de "aplainamento" da superfície, fenômeno também relatado por Panagiotopoulou, 2023, que aplicou GANs para ampliar as imagens de uma igreja.

Uma das problemáticas encontradas com a utilização dessa GAN é a perda dos dados radiométricos e espectrais no produto do sensoriamento remoto, já que a imagem é obtida com formato .png, devido à falta de suporte do algoritmo para a extensão .tiff. Esse é um fator importante, pois impossibilita operações de geoprocessamento que dependem dessas informações.

## **CONSIDERAÇÕES FINAIS**

O uso de Redes Adversárias Generativas, nesse caso a Real-ESRGAN, mostrou-se eficaz para melhorar a visualização de movimentos de massa em imagens de satélite da empresa *PlanetLabs*, permitindo uma ampliação significativa sem perda de detalhes cruciais. Ainda, destaca-se que a marcação acentuada das bordas da cicatriz nas imagens permite maior probabilidade de sucesso quando o produto for utilizado no contexto de detecção de objetos.

No entanto, a aplicação da técnica na Geografia Física é limitada pela perda de dados radiométricos e espectrais, o que impede operações mais avançadas de geoprocessamento. Além disso, observa-se uma perda da textura original, o que pode ser um problema dependendo do foco do estudo em questão.

Apesar dessas limitações, as GANs se apresentam como uma ferramenta promissora, especialmente em análises visuais, podendo ser potencializada com a execução de treinamentos específicos para definir parâmetros que melhor se adequam a imagens de satélite. No futuro, pretende-se efetuar a implementação de scripts adicionais para compatibilizar o formato .tiff com o algoritmo, dessa forma, tornar-se-ia possível expandir as aplicações da técnica, tornando-a mais viável para estudos geoespaciais e ambientais de alta precisão.

**Palavras-chave:** Redes Adversárias Generativas; GANs; Movimento de Massa; Real-ESRGAN; imagem de satélite.

## REFERÊNCIAS

- BEAULIEU, Mario et al. Deep image-to-image transfer applied to resolution enhancement of sentinel-2 images. In: **IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2018. p. 2611-2614.
- CHAU, Kam Tim et al. Landslide hazard analysis for Hong Kong using landslide inventory and GIS. **Computers & Geosciences**, v. 30, n. 4, p. 429-443, 2004.
- CHENG, Libo et al. A small attentional YOLO model for landslide detection from satellite remote sensing images. **Landslides**, v. 18, n. 8, p. 2751-2765, 2021.
- DING, Anzi et al. Automatic recognition of landslide based on CNN and texture change detection. In: **2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)**. IEEE, 2016. p. 444-448.
- FILHO, Carlos Leite Maciel; NUMMER, Andréa Valli. **Introdução à Geologia de Engenharia**. Editora UFSM, Santa Maria, 2011.
- GUIDICINI, Guido; NIEBLE, Carlos Manoel. **Estabilidade de taludes naturais e de escavação**. Editora da USP, São Paulo, 1984.
- GUZZETTI, Fausto et al. Landslide inventory maps: New tools for an old problem. **Earth-Science Reviews**, v. 112, n. 1-2, p. 42-66, 2012.
- HACIEFENDIOĞLU, Kemal; ADANUR, Süleyman; DEMIR, Gökhan. Automatic landslide segmentation using a combination of grad-CAM visualization and K-means clustering techniques. **Iranian Journal of Science and Technology, Transactions of Civil Engineering**, v. 48, n. 2, p. 943-959, 2024.
- INMET – Instituto Nacional de Meteorologia. Balanço: Porto Alegre (RS) teve temperaturas acima e chuva dentro da média em maio de 2023. Brasília – DF, 2024. Disponível em: <https://portal.inmet.gov.br/noticias/balanço-porto-alegre-rs-teve-temperaturas-acima-e-chuva-dentro-da-média-em-maio-de-2023>. Acesso em: 01 de agosto de 2024.
- MARJANOVIC, Miloš; BAJAT, Branislav; KOVACEVIC, Miloš. Landslide susceptibility assessment with machine learning algorithms. In: **2009 International Conference on Intelligent Networking and Collaborative Systems**. IEEE, 2009. p. 273-278.
- MILZ, Stefan; RUDIGER, Tobias; SUSS, Sebastian. Aerial ganeration: Towards realistic data augmentation using conditional gans. In: **Proceedings of the European Conference on Computer Vision (ECCV) Workshops**. 2018. p. 0-0.
- MIYATO, Takeru et al. Spectral normalization for generative adversarial networks. **arXiv preprint arXiv:1802.05957**, 2018.

NOGUEIRA, Emília A. et al. Upsampling of unmanned aerial vehicle images of sugarcane crop lines with a Real-ESRGAN. In: **2023 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)**. IEEE, 2023. p. 285-290.

PANAGIOTOPOULOU, Antigoni et al. Super-resolution techniques in photogrammetric 3D reconstruction from close-range UAV imagery. **Heritage**, v. 6, n. 3, p. 2701-2715, 2023.

REDMON, Joseph et al. You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 779-788.

SINGH, Praveer; KOMODAKIS, Nikos. Cloud-gan: Cloud removal for sentinel-2 imagery using a cyclic consistent generative adversarial networks. In: **IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2018. p. 1772-1775.

ULLO, Silvia Liberata et al. A new mask R-CNN-based method for improved landslide detection. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 3799-3810, 2021.

WANG, Haojie et al. Landslide identification using machine learning. **Geoscience Frontiers**, v. 12, n. 1, p. 351-364, 2021.

WANG, Xintao et al. Esrgan: Enhanced super-resolution generative adversarial networks. In: **Proceedings of the European conference on computer vision (ECCV) workshops**. 2018. p. 0-0.

WANG, Xintao et al. Real-esrgan: Training real-world blind super-resolution with pure synthetic data. In: **Proceedings of the IEEE/CVF international conference on computer vision**. 2021. p. 1905-1914.

WANG, Zhongyuan et al. Ultra-dense GAN for satellite imagery super-resolution. **Neurocomputing**, v. 398, p. 328-337, 2020.

WIECZOREK, Gerald. Preparing a detailed landslide-inventory map for hazard evaluation and reduction. **Bulletin of the Association of Engineering Geologists**, v. 21, n. 3, p. 337-342, 1984.