



**UNIVERSIDADE FEDERAL DA FRONTEIRA SUL
CAMPUS ERECHIM
BACHARELADO EM ENGENHARIA SANITÁRIA E AMBIENTAL**

MATEUS BRUSCHI

***DEEP LEARNING* APLICADA A SEGMENTAÇÃO SEMÂNTICA
SEMIAUTOMÁTICA DE CICATRIZES DE DESLIZAMENTOS DE TERRA**

**ERECHIM
2022**

MATEUS BRUSCHI

***DEEP LEARNING* APLICADA A SEGMENTAÇÃO SEMÂNTICA
SEMIAUTOMÁTICA DE CICATRIZES DE DESLIZAMENTOS DE TERRA**

Trabalho de Conclusão de Curso de graduação apresentado ao Curso de Bacharelado em Engenharia Sanitária e Ambiental da Universidade Federal da Fronteira Sul como requisito para obtenção do grau de Engenheiro Ambiental da Universidade Federal da Fronteira Sul.

Orientador: Prof. Dr. José Mario Grzybowski.

ERECHIM

2022

Esse trabalho é dedicado a todos que fizeram parte dessa jornada, principalmente aos professores, familiares e amigos.

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Neuri Carlos Bruschi e Ivone Salette Bartnicki Bruschi, por todo o apoio incondicional e incentivo nesse caminho traçado.

A minha vó Ida Bruschi, que sempre serviu como um exemplo de dedicação e empenho para toda a família.

Ao meu irmão Renan Carlos, que é um grande exemplo de excelência profissional e trabalho duro.

Ao meu professor orientador José Mario Vicensi Grzybowski e ao meu professor coorientador Pedro Eugênio Gomes Boehl pelos conhecimentos, tempo dedicado e assistência em todas as etapas da produção desse trabalho e da graduação.

Ao pessoal da Marcos, que além de amigos, sempre foram também uma segunda família.

A todos os amigos feitos na graduação, que também traçaram esse longo caminho.

E também a todos os professores que fazem parte do corpo docente da Universidade Federal da Fronteira Sul, do curso de Engenharia Sanitária e Ambiental, e de outros também, que contribuíram para a minha formação profissional, sempre com muita excelência.

Bibliotecas da Universidade Federal da Fronteira Sul - UFFS

Bruschi, Mateus

DEEP LEARNING APLICADA A SEGMENTAÇÃO SEMANTICA
SEMIAUTOMÁTICA DE CICATRIZES DE DESLIZAMENTOS DE TERRA /
Mateus Bruschi. -- 2022.

37 f.:il.

Orientador: Doutor José Mario Grzybowski

Trabalho de Conclusão de Curso (Graduação) -
Universidade Federal da Fronteira Sul, Curso de
Bacharelado em Engenharia Ambiental e Sanitária,
Erechim,RS, 2022.

1. Deslizamentos de terras. 2. Inventário de
Deslizamentos. 3. U-Net. 4. Redes Neurais. 5. Movimento
de massas. I. Grzybowski, José Mario, orient. II.
Universidade Federal da Fronteira Sul. III. Título.

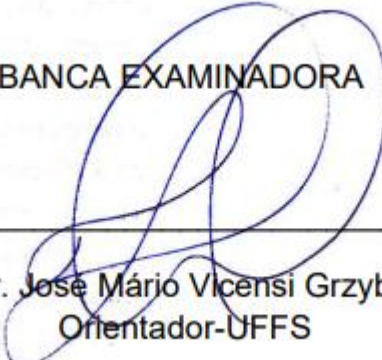
MATEUS BRUSCHI

***DEEP LEARNING* APLICADA A SEGMENTAÇÃO SEMÂNTICA
SEMIAUTOMÁTICA DE CICATRIZES DE DESLIZAMENTOS DE TERRA**

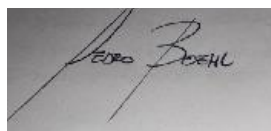
Trabalho de Conclusão de Curso de graduação apresentado ao Curso de Bacharelado em Engenharia Sanitária e Ambiental da Universidade Federal da Fronteira Sul como requisito para obtenção do grau de Engenheiro Ambiental da Universidade Federal da Fronteira Sul.

Este trabalho foi avaliado e aprovado pela banca em 25/08/2022.

BANCA EXAMINADORA



Prof. Dr. José Mário Vicensi Grzybowski
Orientador-UFFS



Prof. Mestre Pedro Eugênio Gomes Boehl
Avaliador-UFFS



Prof. Drª. Helen Treichel
Avaliador-UFFS

RESUMO

Cada ano, desastres naturais são responsáveis por inúmeras perdas para a sociedade, tanto econômicas quanto sociais. Deslizamentos de terra são desastres que podem ser causados por fatores naturais, como chuvas fortes, terremotos e características do solo e do relevo do local, e também por ações humanas, como o desmatamento, construções, exploração de minérios, queimadas entre outros. Este trabalho tem como objetivo realizar a aplicação de uma metodologia de mapeamento de cicatrizes de deslizamentos, através da aplicação de redes neurais totalmente convolucionais, para a detecção e aprendizado de reconhecimento dessas cicatrizes, e com isso produzir e disponibilizar publicamente um banco de dados de deslizamento de alta confiabilidade para os estados do Rio Grande do Sul, Santa Catarina e Paraná. Para isso, foi realizada a triagem manual dos pontos de deslizamento obtidos da etapa anterior, e os melhores pontos foram submetidos a análise de um especialista, para a confirmação definitiva desses pontos como cicatrizes de deslizamento. Esse inventário de deslizamentos pode possibilitar o desenvolvimento de mapas de suscetibilidade de deslizamentos, e pode servir como primeiro passo para o desenvolvimento de sistemas de alertas de risco e prevenção, reduzindo assim as consequências negativas desse tipo de desastre na sociedade. O F1-Score é utilizado para avaliar o desempenho geral das redes neurais. Para a arquitetura U-Net utilizada nesse trabalho, os valores de F1-Score foram de 0.7433, 0.7141 e 0.6825, respectivamente.

Palavras-Chave: Deslizamentos de terras. Inventário de Deslizamentos. Movimentos de Massa. U-Net. Redes Neurais.

RESUMO

Each year, natural disasters are responsible for countless losses to society, both economically and socially. Landslides are disasters that can be caused by natural factors like heavy rains, earthquakes, characteristics of the soil and the topography of the region, as well as human actions like deforestation, constructions, ore mining and forest fires, and among others. The purpose of this work is to apply a methodology of landslide scars mapping, based on the application of fully convolutional neural networks, to detect and learn how to map landslide scars, and from that, to produce and make a publicly available and highly reliable landslide database for the states of Rio Grande do Sul, Santa Catarina and Paraná. In order to do so, the landslide points obtained from the previous step were manually sorted, and the best ones were submitted for expert analysis, to confirm those as definitive landslide scars. This database can make possible the development of landslide susceptibility maps, and be the first step of the development of alert and prevention system. This way, the negative consequences of this kind of disaster on society can be reduced. The F1-Score is used to measure overall performance in neural networks. For the U-Net architecture used in this work, the F1-Score was 0.7433, 0.7141 e 0.6825 for training, validation and test, respectively.

Palavras-Chave: Landslides. Landslides Databases. Mass Movements. U-Net. Neural Networks.

LISTA DE ABREVIATURAS E SIGLAS

CEMADEN - Centro Nacional de Monitoramento e Alertas de Desastres Naturais

ANNs – Artificial Neural Networks

SIG - Sistema de Informação Geográfica

AM – Aprendizagem de máquina

CPRM - Companhia de Pesquisa de Recursos Minerais

SAP – Sistema de alerta precoce

USGS - United States Geological Survey

IBGE - Instituto Brasileiro de Geografia e Estatística

RNC – Rede Neural Convolucional

DEM- Digital Elevation Model

TM – Thematic Mapper

SUMÁRIO

1 INTRODUÇÃO	7
1.1 OBJETIVOS	9
1.1.1 OBJETIVO GERAL.....	9
1.1.2 OBJETIVOS ESPECÍFICOS	9
2 MATERIAIS E MÉTODOS	9
2.1 CARACTERIZAÇÃO DO LOCAL DE ESTUDO	10
2.2 DESLOCAMENTOS DE MASSAS	12
2.3 U-NETS	14
2.4 TRIAGEM DOS PONTOS	20
3 RESULTADOS	23
3.1 DESEMPENHO DA REDE	23
3.2 PONTOS GERADOS	24
3.3 ANÁLISE DOS PONTOS	25
3.4 BANCO DE DADOS	25
4 DISCUSSÃO	29
5 CONSIDERAÇÕES FINAIS	30
5 REFERÊNCIAS	31

1 INTRODUÇÃO

Deslizamentos de terra são desastres que ocorrem devido a diversos fatores, alguns naturais, como a declividade, elevação e a geologia do local, e outros antropológicos, como o desflorestamento, o uso incorreto do solo, entre outros. No Brasil, os desastres que acontecem com mais frequência, e atingem o maior número de pessoas, são as inundações e os deslizamentos. Os danos sofridos em virtude destes acontecimentos causam grandes impactos econômicos, e também, nos piores casos, podem resultar em fatalidades. A parcela mais afetada da população, é a menos privilegiada economicamente, que com a expansão urbana desenfreada, muitas vezes acaba se marginalizando em zonas impróprias para a ocupação (Tavares, 2010).

Em 2008, 78.000 pessoas ficaram desabrigadas e 135 morreram, em decorrência de inundações e deslizamentos, na região do Vale do Itajaí, em Santa Catarina. No ano de 2011, os deslizamentos e as enxurradas na Região Serrana, no Rio de Janeiro, resultaram em 900 mortes e mais de 350 desaparecidos (Bertone, 2013). Os deslizamentos e as inundações relacionadas ao Ciclone Subtropical Kurumi, em 2020, nos estados de Minas Gerais, Rio de Janeiro e Espírito Santo, causaram a morte de pelo menos 70 pessoas, e deixaram mais de 30.000 pessoas desabrigadas.

O mapeamento de suscetibilidade é um passo importante para mitigar os riscos desse tipo de desastres e minimizar as consequências, tanto econômicas quanto sociais que eles podem causar (Vanâcor, 2012). Entretanto, muitos modelos utilizados para realizar esse mapeamento dependem da existência de um inventário de cicatrizes para a sua validação. Os mapas devem contêr localização, forma, datas de ocorrência, limites e devem estar registrados e disponíveis para serem acessados em plataformas SIG. (Hervás, 2009). Esses mapas são muitas vezes escassos, uma vez que o processo para a sua elaboração depende de profissionais qualificados, é lento, custoso e a sua metodologia de elaboração não é muito bem definida, e até mesmo subjetiva (Soares, 2022).

Esses mapas podem ser elaborados de três formas; manual, semiautomática e automática. Os métodos manuais dependem da obtenção de dados de campo e da interpretação desses dados por especialistas qualificados. Os outros dois métodos

utilizam classificação através de algoritmos baseados em pixel e objetos. (Soares, 2022).

Os métodos de classificação supervisionada e não-supervisionada, detecção de mudanças e segmentação baseada em um *threshold* se destacam na abordagem baseada em pixel. Esses métodos desconsideram fatores importantes, como informações geométricas e contextuais das imagens, o que explica o porque deles muitas vezes não obterem uma boa precisão, apesar de serem os mais utilizados. (Stumpf e Kerle, 2011; Blaschke et al., 2014; Zhong et al., 2019; Prakash et al., 2020). Uma maneira de obter resultados com uma precisão maior é através de métodos baseados em objetos. Esses métodos consideram diversas informações, como as especiais, espectrais e morfológicas que são analisadas por um especialista, reduzindo assim o ruído na classificação. (Soares, 2022).

Com o avanço da tecnologia, os métodos quantitativos, ou objetivos, vem se mostrando como uma alternativa viável aos métodos qualitativos, ou subjetivos. Com a capacidade de processamento dos computadores modernos, é possível realizar o mapeamento de suscetibilidades a deslizamentos com rapidez e eficiência. Nos métodos de aprendizagem de máquina (AM), alguns trabalhos de destaque conseguem atingir mais de 85% de precisão para detectar áreas suscetíveis a deslizamentos (Gameiro, 2020). Um estudo comparativo entre os modelos de AM, realizado por Pourghasemi e Rahmati (2018), demonstrou que as técnicas com a maior precisão são as de Florestas Aleatórias, Máquina de Vetores de Suporte e as ANNE, apesar disso, a escolha da técnica mais apropriada deve ser realizada com base nas características do local de estudo.

A aplicação da ferramenta r.landslide para o mapeamento de suscetibilidade a deslizamentos, em um estudo de caso na cidade de Porto Alegre, apresentou resultados satisfatórios, quando em comparação com o mapa elaborado pela Companhia de Pesquisa de Recursos Minerais (CPRM). A área abaixo da curva característica de operação do receptor (Curva COR) apresentou valores de 0,96, o que indica uma ótima precisão (Bragagnolo et al., 2019).

Técnicas capazes de elaborar mapas de suscetibilidade a deslizamentos podem servir como importantes ferramentas para o estabelecimento de sistemas de alerta precoce (SAP). O sistema norueguês de previsão e alerta de deslizamentos de terra induzidos pela chuva e derretimento de gelo, utiliza o mapeamento de suscetibilidade a deslizamentos, com base em modelos aditivos generalizados, em

conjunto com sistemas de monitoramento em tempo real de dados hidrometeorológicos e modelos hidrológicos, para identificar situações de risco até 66 horas antes delas ocorrerem. Com essa informação, as autoridades conseguem tomar ações preventivas para diminuir os impactos destes desastres (Krøgli et al, 2018). Grego e Pagano (2017), analisam as principais características de alguns modelos comuns utilizados em SAPs, como os modelos estocásticos, modelos físicos e modelos determinados por métodos empíricos baseados no histórico de chuvas, e orientam como desenvolver e aplicar um SAP efetivo.

1.1 OBJETIVOS

1. 1.1 OBJETIVO GERAL

Gerar e disponibilizar uma base de dados de deslizamentos de terra confiável para a região do Paraná, Santa Catarina e Rio Grande do Sul utilizando a arquitetura U-Net, e um processo de triagem manual.

1. 1.2 OBJETIVOS ESPECÍFICOS

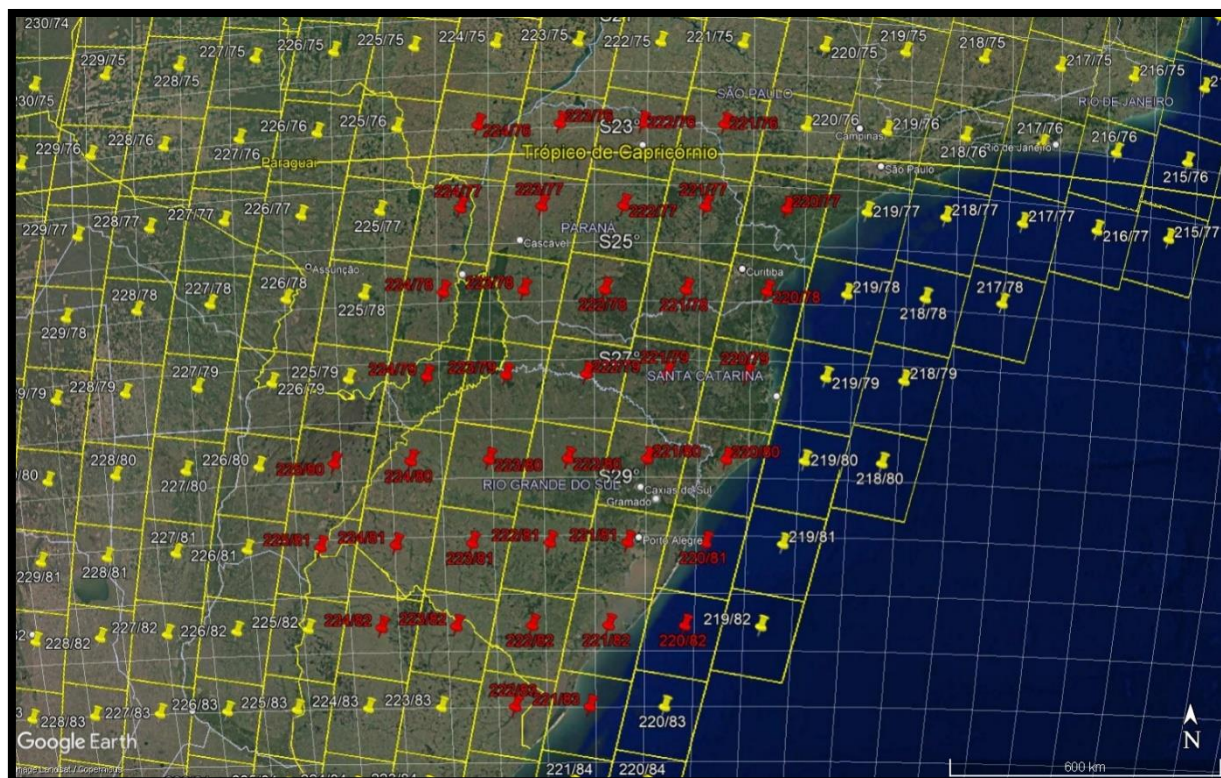
- Aplicar uma metodologia baseada em redes neurais convolucionais para mapear cicatrizes de deslizamentos de terra na região sul;
- Triar os pontos obtidos e realizar a verificação manual, a fim de remover os falsos-positivos.
- Produzir uma base de dados de cicatrizes de deslizamento de alta confiabilidade
- Realizar a análise histórica da região classificada para entender a causa do deslizamento.

2 MATERIAIS E MÉTODOS

Além das imagens obtidas pela composição de banda, para esse trabalho também foram usadas as imagens de *digital elevation model* (DEM). O DEM fornece informações geomorfológicas referentes a elevação e a declividade. Essas informações são importantes para a eliminação de falsos-positivos ocorrentes em áreas planas. Os dados são obtidos através da SRTM (Shuttle Radar Topography Mission) com uma resolução espacial de 30 metros, pelo portal OpenTopography (<https://portal.opentopography.org/raster?opentopoID=OTSRTM.082015.4326.1>) ou

pele portal do Earth Explorer (<https://earthexplorer.usgs.gov/>). Esses rasters de elevação foram baixados para cada grade TM da América do Sul do Landsat, conforme pode ser visualizado na figura 1.

Figura 1 - Grades TM da América do Sul



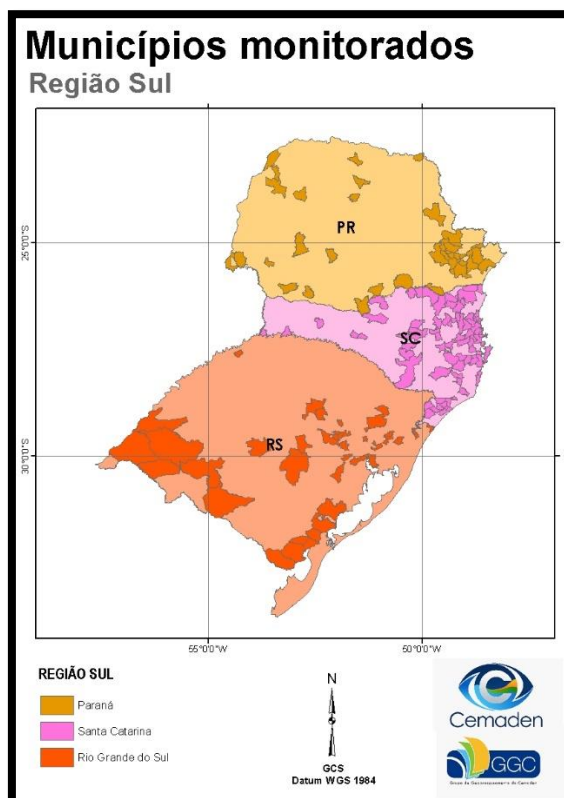
Fonte: <http://www.dgi.inpe.br/documentacao/grades>

2.1 CARACTERIZAÇÃO DO LOCAL DE ESTUDO

Fazem parte da Região Sul três estados: Rio Grande do Sul; Santa Catarina e Paraná. A sua área é de 576.409,6. É a menor das 5 regiões brasileiras. Segundo o Instituto Brasileiro de Geografia e Estatística, a região sul possui 3.042 áreas de risco a deslizamentos, sendo a maioria dessas áreas localizadas no estado de Santa Catarina. A maioria dos municípios monitorados pelo CEMADEN, por possuir histórico de desastres naturais decorrentes de movimento de massa ou de processos hidrológicos, também estão localizadas em Santa Catarina. É uma região muito afetada pelo desmatamento, com pouca vegetação nativa restante. O clima da região é subtropical ou temperado, com chuvas bem distribuídas durante o ano.

Os estados do Rio Grande do Sul, de Santa Catarina e do Paraná, são compostos por 1.190 municípios, dos quais 154 são monitorados pelo Centro Nacional de Monitoramento e Alertas de Desastres Naturais, por apresentarem riscos decorrentes de movimento de massa ou de processos hidrológicos.

Figura 2 - Municípios monitorados da Região Sul.



Fonte: www.cemaden.com.br, 2022.

O estado do Rio Grande do Sul é dividido em 497 municípios, e sua área total é de aproximadamente 281.000 km². Sua capital é a cidade de Porto Alegre. Ele faz divisa com o Oceano Atlântico ao leste, a Argentina ao oeste e Uruguai ao sul, e com Santa Catarina ao norte. A sua população é estimada em 11.466.000 de pessoas. Da região sul, é o maior em área e o segundo mais populoso. Dos 154 municípios monitorados pelo CEMADEN, 39 fazem parte do Rio Grande do Sul. As grades TM da América do Sul que englobam o estado são: 222/83, 221/83, 223/82, 222/82, 221/82, 220/82, 225/81, 224/81, 223/81, 222/81, 221/81, 220/81, 225/80, 224/80, 223/80, 222/80, 221/80, 220/80, 224/79, 223/79, 222/79 e 221/79.

O estado de Santa Catarina é dividido em 295 municípios, e sua área total é de aproximadamente 95.700 km². Sua capital é a cidade de Florianópolis. Faz fronteira com o Oceano Atlântico ao leste, com o estado do Paraná ao norte e o estado do Rio Grande do Sul ao sul, e a oeste com a Argentina. A sua população pode ser estimada em 7.300.000 de pessoas. Dos 154 municípios monitorados pelo CEMADEN, 79 deles fazem parte de Santa Catarina. Santa Catarina é o estado com mais municípios monitorados pelo CEMADEN, apesar de ser também o menor em área e população. As grades TM da América do Sul em que o estado está presente são: 223/79, 223/78, 222/79, 222/78, 221/80, 221/79, 221/78, 220/78, 220/79, 220/80 e 219/79.

O estado do Paraná é dividido em 399 municípios, e sua área total pode ser estimada em 199.300 km². Sua capital é a cidade de Curitiba, e faz fronteira com o Mato Grosso do Sul a noroeste, São Paulo ao norte e Santa Catarina ao sul. Também faz fronteira com a Argentina a sudoeste e ao Paraguai a oeste. Sua população é de aproximadamente 11.500.000 habitantes. É o quinto estado mais rico do Brasil, e o maior em população da região sul, apesar de ser apenas o segundo em extensão territorial. Dos 154 municípios monitorados pelo CEMADEN, 36 fazem parte do Paraná. É o estado com menos municípios monitorados da região sul. As grades TM da América do Sul as quais contém o estado do Paraná são: 220/77, 220/78, 221/78, 221/77, 221/76, 222/78, 222/77, 222/76, 223/76, 223/77, 223/78, 224/78, 224/77 e 224/76.

2.2 DESLOCAMENTOS DE MASSAS

Deslocamentos de massas podem ser definidos como qualquer deslocamento de terra ou rochas pela influência da gravidade ou por sobrecargas. Eles são classificados por diversos autores, mas para a região de estudo, a classificação utilizada por Filho (1992) é mais apropriada para esse trabalho, pois ela foi elaborada especificamente para a classificação de deslizamentos que ocorrem em regiões de clima tropical e subtropical. Eles são classificados com base no movimento das massas, no seu comportamento com o tempo, geometria e a origem. Para ele, os deslizamentos são divididos em quatro tipos; rastejos, escorregamentos, quedas e corridas.

Os rastejos são movimentos mais lentos e contínuos da massa de solo de uma região, que não tem geometria e superfície de ruptura bem definidas, apesar de ainda causarem uma deformação plástica. São mais ocorrentes em regiões de transição entre solos e rochas.

Escorregamentos são movimentos de massas de alta velocidade, com grande volume, com o material se deslocando para baixo e para fora do talude. Esse processo ocorre devido a ruptura ao cisalhamento, causada pelos aumentos das forças de tensões atuantes ou queda da resistência no solo. Os escorregamentos são movimentos de massas que ocorrem em curtos períodos de tempo, e são classificados de acordo com a sua geometria e tipo de material. Os escorregamentos planares ocorrem em maciços rochosos e acontecem em estruturas geológicas planares. Os escorregamentos circulares, ou rotacionais, apresentam uma superfície de ruptura encurvada, formando um movimento rotacional com um eixo definido. Sua ocorrência é mais comum em aterros, rochas sedimentares fraturadas, pacotes de solo ou depósitos de maior espessura. Escorregamentos em cunha são movimentos em um eixo formado pela intersecção de estruturas planares em grandes rochas, que desloca um material de forma prismática.

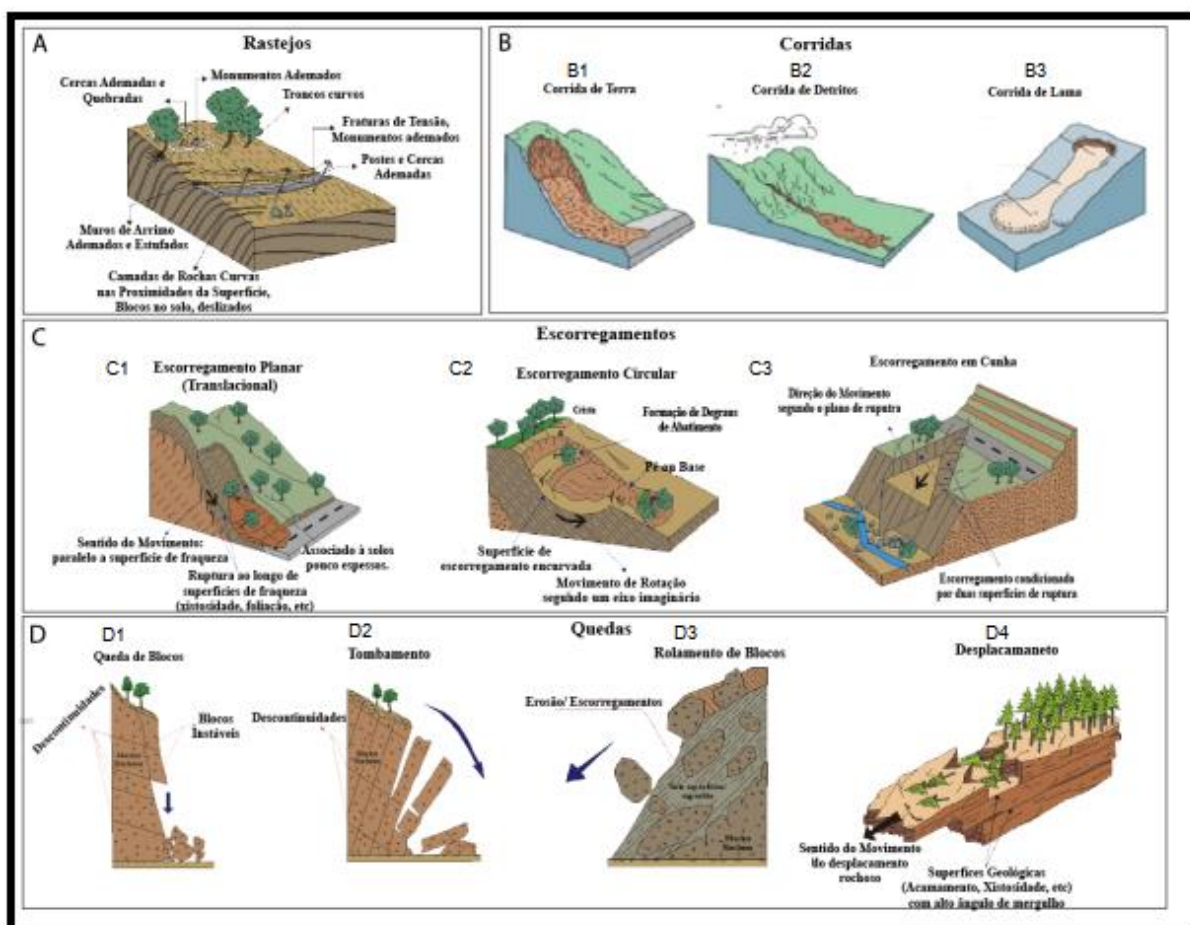
As quedas são deslocamentos por gravidade de blocos de rochas. Quedas de blocos são massas de rocha maciça que se deslocam em queda livre, e podem ocorrer em diversos tipos de solo e em volumes variados. Tombamento de blocos são blocos rochosos que se deslocam em um movimento rotacional, e acontecem em estruturas geológicas em maciços rochosos sub-verticais. Rolamentos de blocos ocorrem ao longo de encostas e são causados geralmente por descalçamento. Desplacamentos de blocos são blocos rochosos em queda livre ou deslizando, que ocorrem em superfícies estruturais e ocorrem devido a variações de temperatura ou por conta do aumento de pressão.

Corridas são movimentos de massas classificados como escoamentos rápidos, que envolvem grandes volumes de materiais, e são classificadas pelo volume de material envolvido, pela extensão do deslizamento e pelas dinâmicas físicas envolvidas. Geralmente, esse tipo de movimento de massas tem alto poder destrutivo. As corridas de terra são movimentos de solo com baixa quantidade de água e baixa velocidade. As corridas de lama são movimentos de solo com a presença de muita água, de alta velocidade e potencialmente muito destrutivas. As corridas de detritos são constituídas majoritariamente por materiais mais grossos e sólidos, como blocos

de rochas de diversos tamanhos. Tem velocidade elevada e são consideradas os deslizamentos com o maior poder destrutivo.

Esses 4 tipos de deslizamentos e suas subclassificações podem ser visualizados na figura 3.

Figura 3 - Tipos de deslizamento




Fonte: Soares, 2022.

2.3 U-NETS

A estrutura da arquitetura U-Net funciona através de um lado de contração, onde as principais características e classes da imagem são identificadas, e pelo lado direito, onde as informações espaciais das classes identificadas são recuperadas.

Figura 4 - Arquitetura U-Net com 3 canais de 256x256 pixels de entrada e 16x16 na resolução mais baixa. Toda caixa azul representa um mapa de recurso de multicanais, com o número de canais indicado na parte superior da caixa e o tamanho xy no canto

esquerdo inferior. As flechas representam os diferentes processos de filtragem convolucionais.



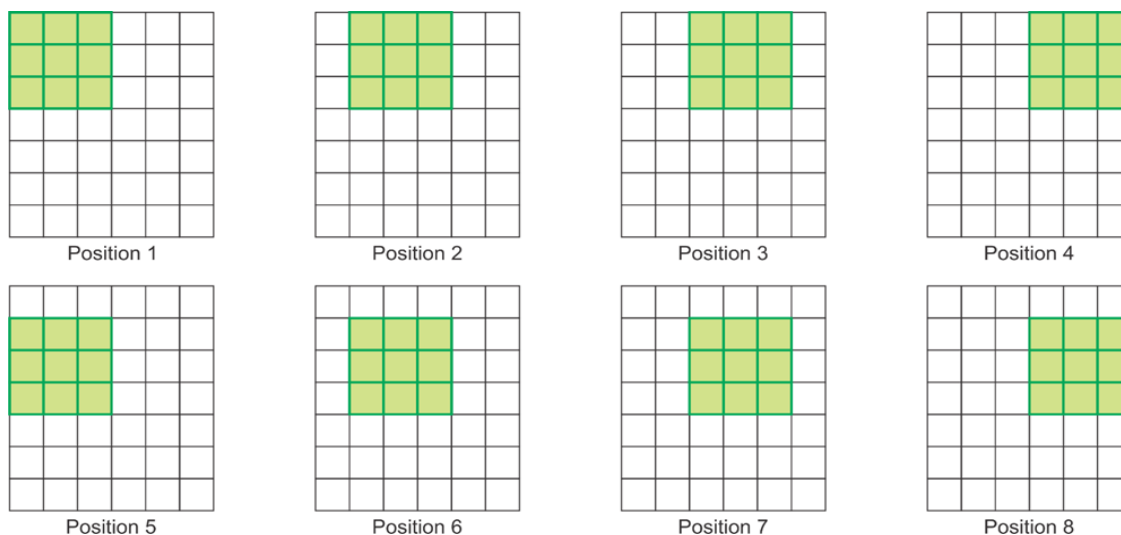
Fonte: Modificado de Ronneberger et al. (2015).

O caminho de contração é característico de uma Rede Neural Convolucional, com duas etapas principais: (a) o processo de convolução e (b) de sub-amostragem. A camada de convolução é composta por um filtro de tamanho menor do que a imagem original, que é completamente escaneada. Esses múltiplos núcleos de convolução conseguem extrair as informações características das imagens, aprendendo não apenas as informações espectrais, mas também da textura de dimensão espacial. Dessa forma, a arquitetura de uma Rede Neural Convolucional, e o processo de convolução, é dado através da aplicação de filtros (Bragagnolo et al., 2021).

O filtro kernel é formado por valores aleatórios de inicialização, que são ajustados de forma interativa durante o processo de treinamento. Para cada parte da estrutura de uma RNC, uma quantidade n de kernels de tamanho $m \times m$ podem ser aplicados, resultando em uma quantidade n de matrizes. Posteriormente, em uma camada de *pooling*, os resultados da camada de convolução são sub-amostrados em blocos menores, através da aplicação de filtros com dimensões menores do que as imagens resultantes do processo anterior. Esse processo consiste em calcular uma média, ou o valor máximo dos pixels contidos no filtro. Quanto mais profunda as camadas vão ficando, a importância relativa dos filtros diminui, e a dos conjuntos de

filtros aumentam, o que torna possível a identificação das características a nível de objeto (Bragagnolo et al., 2021). O filtro pode ser visualizado na figura 8.


Figura 5 – Filtro da camada de convolução de dimensão de 3x3 em uma imagem de dimensão de 7x6.



Fonte: Dados da Pesquisa.

O caminho de contração de uma arquitetura U-Net consiste então na aplicação repetida de duas camadas de convolução, seguidas da aplicação da função de ativação ReLu (Unidade Linear Retificada) e uma operação de *maximum pool* (figura 9). Para cada etapa de amostragem, o número de mapas de recursos é dobrado. No caminho de expansão, o método de convolução transposta é aplicado, onde cada blocos de imagem são submetidos a duas camadas de convolução, seguido por uma camada de amostragem. O número de blocos de expansão é igual ao número de blocos de contração. Na camada final é aplicada uma camada de convolução 1x1 para gerar o resultado de saída final. Toda a rede contém 23 camadas convolucionais. (Ronneberger et al., 2015).

Figura 6 – Operação da camada de *pooling* com a utilização de um filtro de 2x2 com passo de 2 pixels.



Fonte: Dados da pesquisa.

Para esse estudo, foi utilizada a API (Application Programming Interface) de alto nível Keras, que permite a aplicação de arquiteturas de redes neurais na linguagem de programação Python. Essa biblioteca foi aplicada em conjunto com o *back-end TensorFlow*, que é uma biblioteca de aprendizado de máquina *open source*, seguindo o método apresentado por Bragagnolo et al. (2020). Esse processo foi realizado em um processador Intel Xeon de 3,6 GHz de 32 GB de memória RAM, com uma placa de vídeo NVIDIA GeForce GTX 1060 Ti de 6 GB de ram, com o NVIDIA CUDA Toolkit 10.0.

A U-Net também precisa passar por um processo de treinamento, onde seus parâmetros são ajustados através de imagens de satélite amostradas, que contêm as máscaras associadas as cicatrizes de deslizamento. Essas máscaras são representativas da classe de interesse, as quais a rede neural deve utilizar para aprender a diferenciar os objetos tidos como de interesse dos demais. As camadas das máscaras são compostas por uma matriz de 1 e 0 indicando as regiões com deslizamentos e sem deslizamentos, respectivamente (Bragagnolo et al., 2021). Para as etapas subsequentes de treinamento e validação, foram utilizadas cenas do satélite Landsat-8, contendo imagens do Japão, por ser uma região onde são registradas frequentes ocorrências de deslizamentos (Kirschbaum et al., 2015).

A localização e as coordenadas para esses deslizamentos passados foram retiradas do banco de dados de deslizamentos registrados por Kirschbaum et al. (2015). Esses dados são colocados como parâmetros de entrada no algoritmo de download de imagens do Landsat-8, construído com base na API landsatxplore (Forget, 2018). Para a identificação das cicatrizes, as imagens mais próximas da data catalogada foram utilizadas, com um critério de uma presença máxima de 30% de nuvens. Após o download das imagens, as cicatrizes são identificadas através de uma análise visual das coordenadas registradas no banco de dados (Kirschbaum et al., 2015) utilizando-se o programa Google Earth Pro, e com o auxílio do programa

GRASS GIS 7.6.0 (GRASS Development Team, 2019), onde sub-imagens do Landsat-8 e suas respectivas máscaras são geradas.

Para melhorar a qualidade das imagens, foi utilizado o método de *pan-sharpening*, onde uma banda de melhor resolução é utilizada para melhorar a resolução de uma banda base. Nesse caso, as imagens tem resolução espacial de 30 m, então foi utilizada a banda pancromática de resolução espacial de 15 m para compor uma imagem com resolução espacial de 15 m. O processo exige no seu total 4 bandas, a banda 6 (1.57 μm a 1.65 μm), a banda 5 (0.85 μm a 0.88 μm) e a banda 2 (0.45 μm a 0.51 μm), além da pancromática.

As cicatrizes de deslizamento são geradas a partir dos pixels de contorno que estão delimitando o solo exposto visível decorrente de cada deslizamento. Essas delimitações geram a camada de máscara de cada imagem, que são representadas por cores falsas compostas pela combinação das bandas espectrais 8, 6, 5 e 2, que favorecem a visualização do solo exposto.

Foram aplicadas um conjunto de 200 imagens para o treinamento, 17 para a validação e 5 para o teste da U-Net. Em cada uma das etapas, as imagens foram selecionadas de forma aleatória entre as imagens que fazem parte do inventário, para tornar os conjuntos representativos das diversas características presentes em um deslizamento. Para aumentar a quantidade de dados disponíveis, foi também utilizado o método de *data augmentation*, onde as imagens originais são modificadas em relação as suas características. Sendo assim, elas foram giradas, deslocadas em relação as dimensões de altura, largura e ângulo de cisalhamento, ampliadas e invertidas, e então são submetidas ao processo de normalização, onde seus valores foram ajustados para estar dentro do intervalo de 0 a 1, antes de serem utilizadas como entrada para o algoritmo de treinamento.

Na etapa de treinamento e teste, os valores dos filtros de convolução, que são responsáveis por identificar características específicas das imagens, são ajustados através de um algoritmo de *backpropagation*. Na primeira etapa, a de propagação, a imagem se propaga por todas as camadas da rede neural gerando uma resposta em relação a presença ou não de uma cicatriz. Na segunda etapa, a de retropropagação, uma função de perda analisa o resultado em comparação com a imagem máscara real. Esse resultado é utilizado para ajustar os filtros de convolução através do método do gradiente descendente. Esse processo se repete até que desempenho desejado seja alcançado.

O algoritmo Gradiente Descendente Estocástico (SGD) com momento de Nesterov foi utilizado para otimizar o processo. A taxa de aprendizagem escolhida foi de 0,0001 e o momento em 0,9. Para avaliar a capacidade de generalização da rede neural, foram utilizadas 35 imagens, diferentes das imagens utilizadas no processo de treinamento, no processo de validação. Foi aplicado também o método de *early stop*, no qual os parâmetros de rede de interesse são coletados no ponto do mínimo absoluto da curva de erro de validação. Foram utilizadas um máximo de 200 *epochs*, com 200 etapas por *epoch*, no treinamento.

Para otimizar o desempenho no treinamento, foram utilizadas as funções de perdas combinadas. A combinação das funções de perdas foi aplicada pois ela resultou em resultados melhores em relação a qualquer função isolada durante o período de treino. As funções utilizadas foram a *Binary Crossentropy function* associada com a função *dice loss* (Bragagnolo et al, 2021).

Para avaliar a performance da rede durante as etapas de treino, validação e teste, foram aplicadas as métricas de *recall*, *F1-score* e precisão. O valor de precisão é referente a proporção de cicatrizes de deslizamento que foram corretamente identificadas, independentemente dos falsos negativos. A função de *recall* representa a proporção de cicatrizes de deslizamento que foram identificadas em relação ao total existente, independentemente dos falsos-positivos. A função *F1* é a media harmônica entre ambas, que serve para dar um desempenho geral.

$$\text{Precisão} = \frac{Tp}{(Tp + Fp)} \quad (1)$$

$$\text{Recall} = \frac{Tp}{(Tp + F_n)} \quad (2)$$

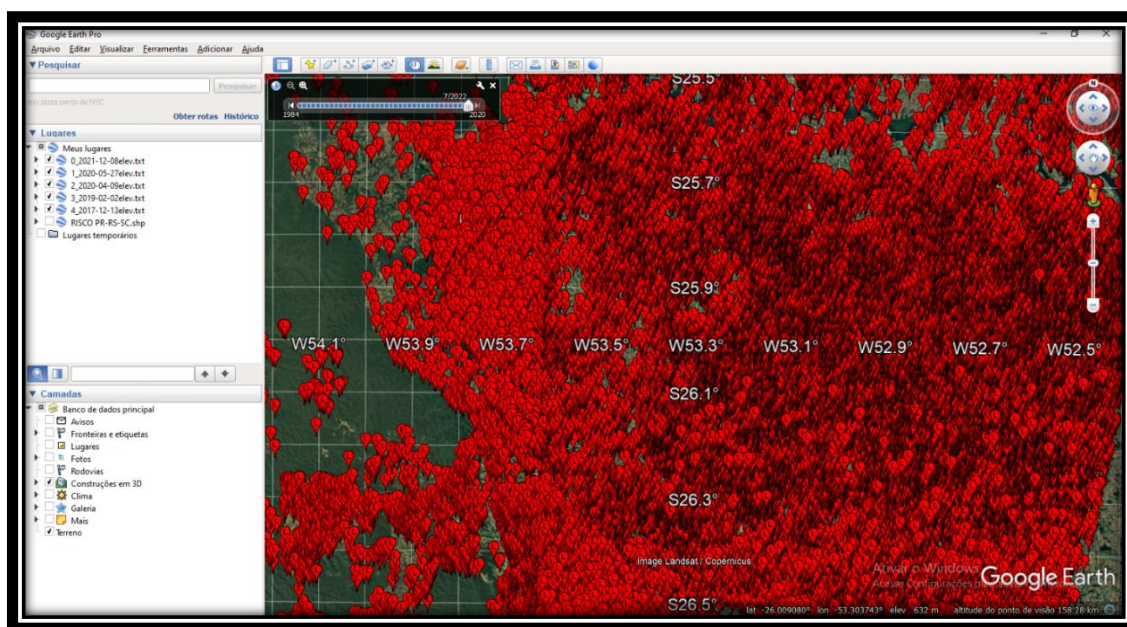
$$F1 = 2 * \frac{(\text{Precisão} * \text{recall})}{(\text{Precisão} + \text{recall})} \quad (3)$$

Os bancos de dados referentes ao treinamento foram disponibilizados por Bragagnolo et al (2020), e seu acesso está disponível em: <https://zenodo.org/record/3775870#.YupfUnbMKUm>(DOI 10.5281/zenodo.3775.870). Para esse procedimento, foram utilizados um conjunto de 200 imagens para o treinamento, 17 para a validação e 5 para teste.

2.4 TRIAGEM DOS PONTOS

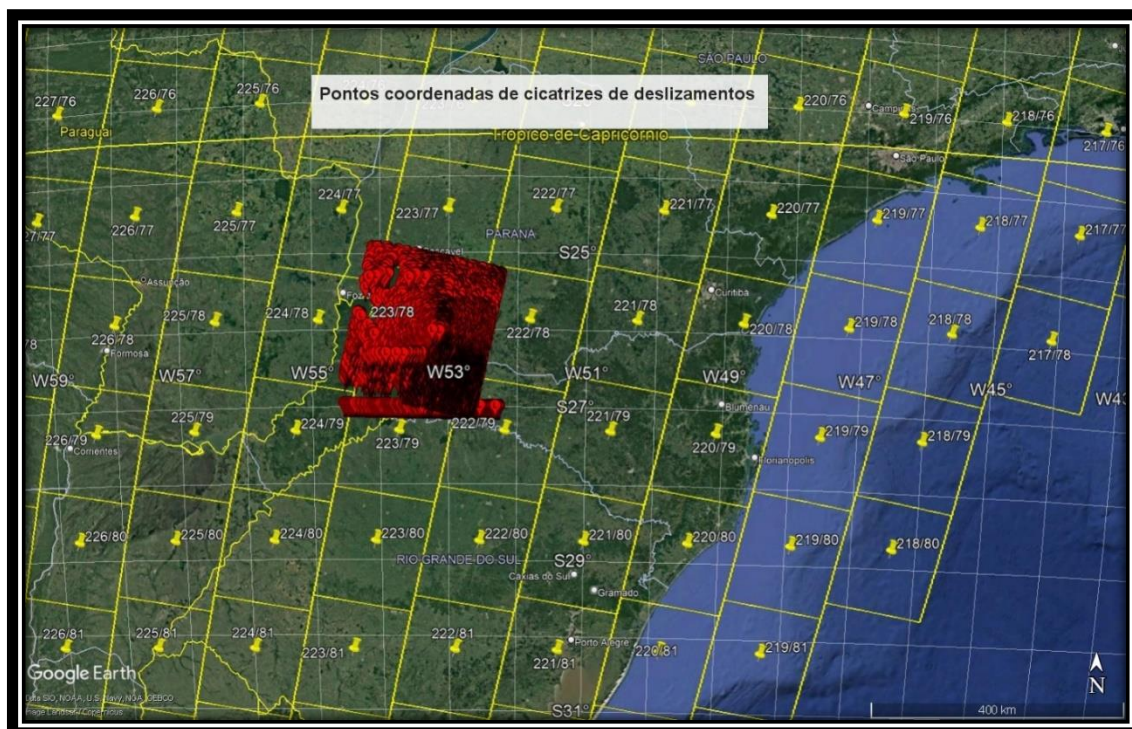
A confirmação manual das cicatrizes, por meio da análise de um profissional capaz, mostra-se uma etapa essencial para garantir a confiabilidade do banco de dados, uma vez que a metodologia aplicada para a obtenção dos pontos de deslizamento utilizados neste trabalho, através da aplicação de uma rede convolucional neural U-Net, apesar de eficiente, ainda apresenta um grande número de falsos-positivos. Os arquivos com os pontos obtidos são carregados no programa Google Earth Pro, como representado na figura 10 e na figura 11.

Figura 7 - Pontos para a triagem no Google Earth Pro.



Fonte: Dados da pesquisa.


Figura 8 – Pontos localizados nas grades 224/78, 224/79, 223/79, 222/79, 222/78, 223/77 e 222/77.



Fonte: Dados da pesquisa.

Esses pontos passam por um processo de triagem visual, para realizar separação dos pontos mais prováveis de corresponder a uma cicatriz. Para esses pontos selecionados, é realizada uma análise histórica das imagens dessas cicatrizes, como na figura 12, com a intenção de encontrar o ponto temporal onde ocorreu a ruptura. Para algumas cicatrizes de deslizamento, não é possível identificar o período temporal onde o movimento de massa aconteceu, então eles são classificados apenas como positivos ou não para deslizamento. Por fim, esses pontos são então submetidos a análise do Prof. Mestre Pedro Eugênio Gomes Boehl, para a confirmação final.

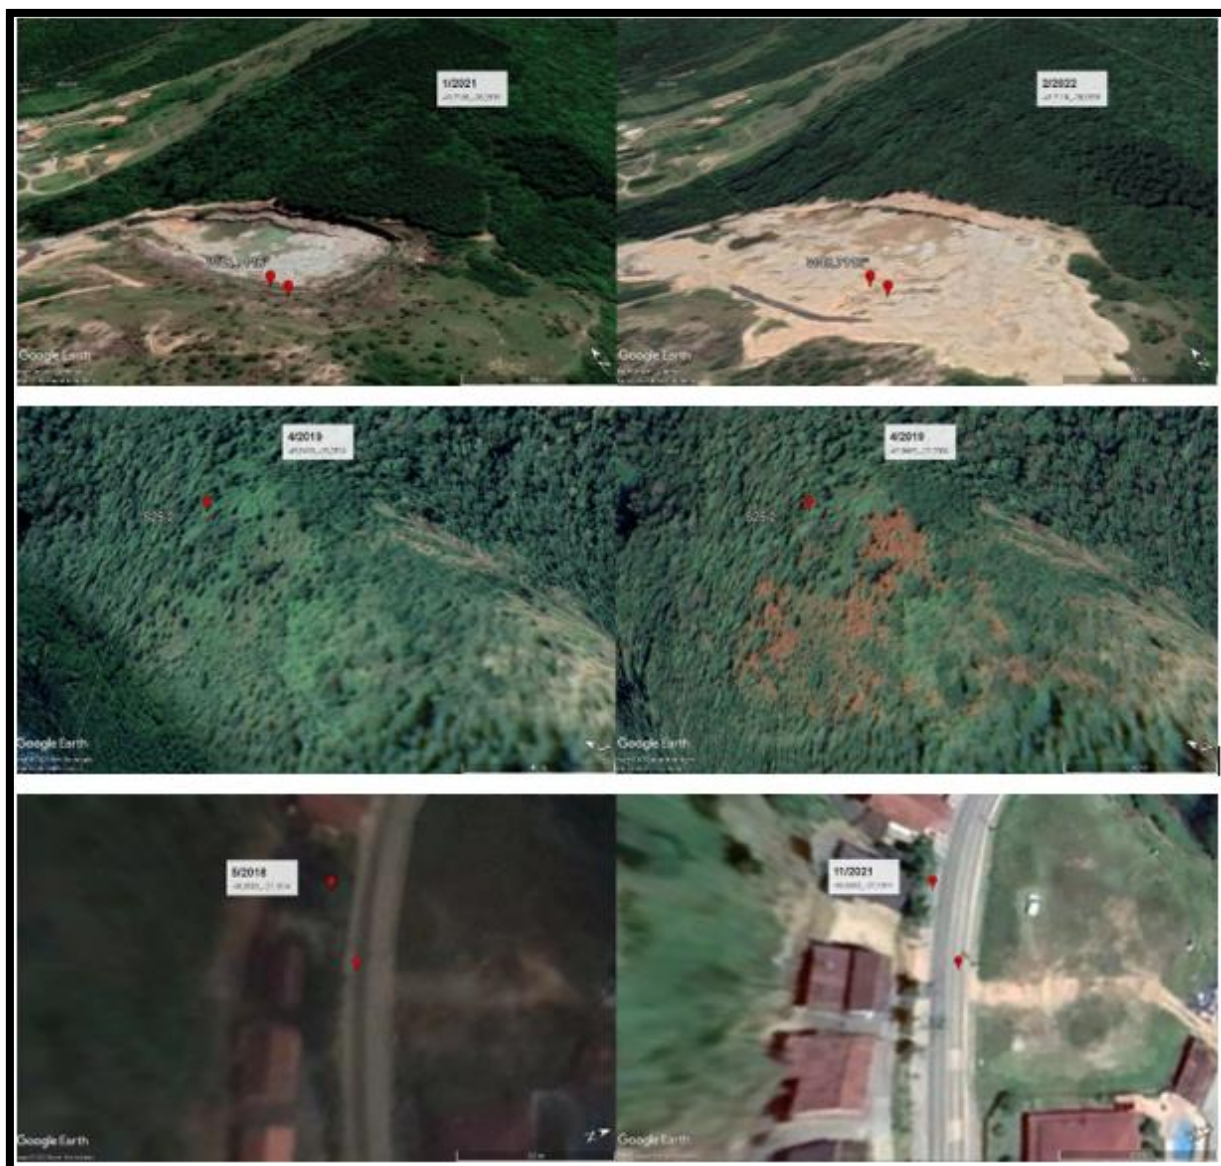
Figura 9 - Antes e depois de movimentos de massa.



Fonte: Dados da pesquisa.

Queimadas, desmatamentos, erosão, construções humanas, solo cultivado ou sendo preparado para o cultivo, são também interpretados como cicatrizes de deslizamento, dando origem a esses falsos-positivos, que podem ser observados na figura 13.

Figura 10 - Exemplos de falsos-positivos.



Fonte: Dados da pesquisa.

3 RESULTADOS

3.1 DESEMPENHO DA REDE

Os parâmetros de otimização foram obtidos para uma época de 180, no ponto de *early stopping*. Para os valores de precisão e de recall, quantos mais próximos de 1, melhor. A função F-1 é uma média harmônica entre os valores de *recall* e precisão. A média harmônica descreve melhor o desempenho geral da rede, e é mais indicada

que a média aritmética para medidas que expressão proporções, pois ela é mais sensível a um dos valores serem muito baixos. Os valores de desempenho da rede estão expressos na tabela 1.

Tabela 1 – Valores de desempenho da rede.

	Precisão	Recall	F-1
Treinamento	0.8560	0.6568	0.7433
Validação	0.7738	0.6630	0.7141
Teste	0.8252	0.5919	0.6825

Fonte: Dados da pesquisa.

3.2 PONTOS GERADOS

A aplicação dessa metodologia proposta por Bragagnolo et al (2020) é um esforço inicial para que a detecção totalmente automática de cicatrizes de deslizamento seja um dia possível. Apesar de ainda não ser possível a detecção totalmente automática, o trabalho necessário para procurar visualmente por cicatrizes aleatoriamente em uma área muito grande é muito maior do que realizar a análise dos pontos identificados. Também é importante mencionar que a rede neural foi capaz de identificar cicatrizes de deslizamento que não haviam sido identificadas anteriormente no processo de criação das máscaras, ou que não estavam registradas em inventários de deslizamentos conhecidos, o que solidifica a importância da aplicação de aprendizado de máquina para a identificação de áreas que passaram previamente despercebidas.

Os pontos foram gerados para as 38 grades TM da América do Sul. Para cada grade analisada, são gerados em média cerca de 50.000 pontos de coordenadas. Esses pontos representam em sua maioria falsos-positivos, e a sua correta identificação muitas vezes depende da qualidade das imagens de satélite disponíveis para o local.

A grande quantidade de falsos-positivos obtida não é algo desanimador. É considerado menos problemático a identificação de uma cicatriz não existente do que a não identificação de uma cicatriz existente, uma vez que apesar de exigir esforço humano, os falsos-positivos podem ser removidos sem grandes dificuldades, mas as

cicatrices não identificadas oferecem um risco maior. Esses falsos-positivos também não são difíceis de serem entendidos. Todo fenômeno ou evento que causa com que as massas de solos e rochas tomem características semelhantes à de um deslizamento, pode causar um falso-positivo. Áreas de floresta queimada, terra plantada ou sendo preparada para o plantio, atividades de mineração, estradas, novas construções, telhados, florestas desmatadas, solos que sofreram erosão são falsos-positivos comuns de serem encontrados nos resultados de saída deste procedimento.

3.3 ANÁLISE DOS PONTOS

A primeira etapa de separação dos falsos-positivos dos verdadeiros-positivos, feita manualmente, serve para separar os falsos-positivos mais grosseiros e que são mais fáceis de serem identificados, como as construções, atividades de mineração e zonas de plantio. A segunda etapa da separação, que é a mais desafiadora, é a validação das cicatrizes já separadas na primeira etapa. Esses falsos-positivos analisados na segunda etapa são bem mais difíceis de serem diferenciados de uma cicatriz de deslizamento, por muitas vezes possuir forma, cor e aparência muito semelhantes à de um deslizamento real. Além disso, as imagens fornecidas pelo Google Earth Pro nem sempre são completamente claras e frequentemente acabam ficando distorcidas na visualização 3D, o que dificulta ainda mais o processo. Por isso, para garantir a confiabilidade do banco de dados, na segunda etapa, os pontos também foram submetidos a análise de um especialista em solos. É importante mencionar que mesmo com a análise de um especialista, é possível que alguns deslizamentos tenham sido incorretamente identificados. Apesar disso, conforme o trabalho foi sendo desenvolvido, maior é a confiança na identificação correta dos pontos, uma vez que essa também é uma função que exige conhecimento e prática. Para essa segunda etapa, foram analisados cerca de 800 pontos com potencial de serem algum tipo de movimento de massa.

3.4 BANCO DE DADOS

Além do banco de dados ser composto pelos pontos com as coordenadas das cicatrizes de deslizamento de alta confiabilidade, ele também contém informações referentes a data de ocorrência dos movimentos de massa, o que permite também

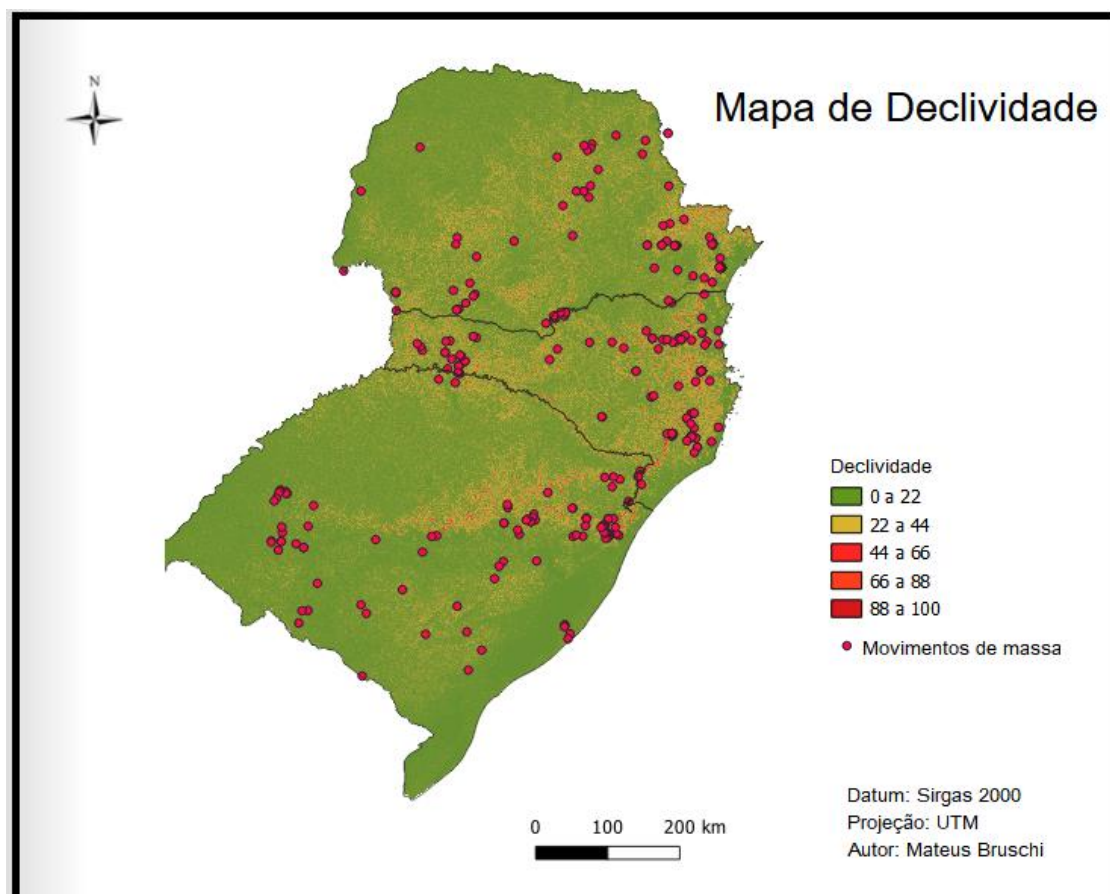
investigar as possíveis causas dos mesmos. Entretanto, isso não é regra para todos os pontos presentes no banco de dados, pois muitas destas cicatrizes são muito antigas e não foi possível realizar a identificação da sua data de origem. É também algo comum certas regiões não possuírem imagens de satélite que permitam a verificação do período de ocorrência dos deslizamentos.

Essa metodologia também foi capaz de identificar diversas cicatrizes de deslizamento localizadas fora das áreas dos municípios monitorados pelo CEMADEN. Isso reforça a importância da realização de trabalhos como esse para a complementação dos bancos de dados existentes, principalmente em países em desenvolvimento, onde a falta de infraestrutura técnica faz com que nem a população, nem as entidades governamentais, tenham conhecimento suficiente a respeito da localização e da ocorrência de deslizamentos, dificultando assim a identificação e classificação de zonas de risco (Petschko et al., 2014).

A grande maioria dos pontos confirmados nessa etapa não fazem parte de zonas urbanas. Um possível motivo para isso é que os deslizamentos de terra em cidades ou locais com população ativa acabam sendo limpos de forma mais rápida, diferente dos que acontecem no meio de florestas ou longe da presença humana. Outra ocorrência comum identificada nos pontos, são locais onde ocorreram algum tipo de movimento de massa e foram trabalhados em cima pelo homem, o que também pode dificultar a sua detecção.

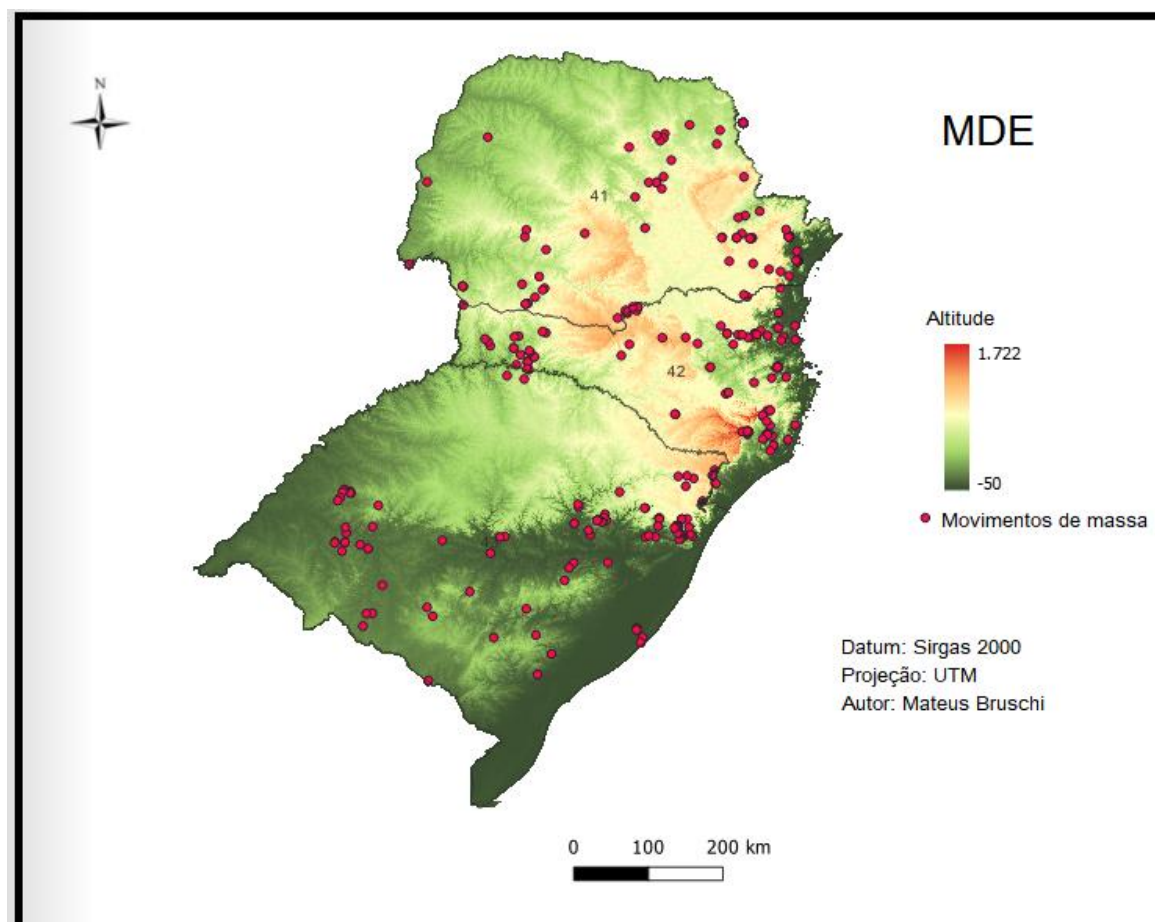
Alguns dos pontos de coordenadas, apesar de identificarem corretamente uma cena com movimentos de massa, não coincidem exatamente com o local do movimento de massa. Por causa disso, e para facilitar a utilização futura desse banco de dados, foi realizado a correção manual desses pontos. Esses pontos também foram destacados no banco de dados. O produto final desse trabalho é um banco de dados com 307 pontos de deslizamentos de terra de alta confiabilidade verificados por um especialista. Nas figuras 11 e 12 estão representados os pontos de deslizamento coletados nesse trabalho, em mapas de declividade e elevação, respectivamente, para toda a região sul. Na figura 13 é possível ver os pontos em relação aos municípios da região sul, estando os municípios monitorados pelo CEMADEN destacados em rosa.

Figura 11 – Mapa de declividade da Região Sul com os pontos produzidos.



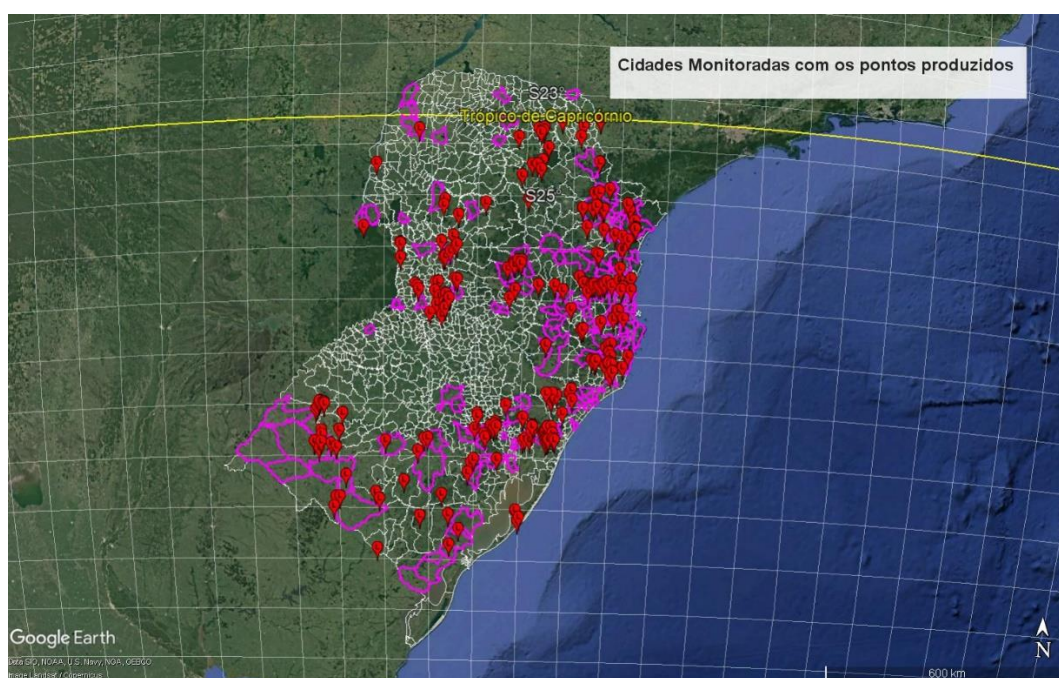
Fonte: Dados da pesquisa.

Figura 12 – Mapa de elevação da Região Sul com os pontos produzidos.



Fonte: Dados da pesquisa.

Figura 13 – Estados Monitorados pelo CEMADEN com os pontos produzidos.



Fonte: Dados da pesquisa.

Espera-se que o banco de dados produzido nesse trabalho seja utilizado para o desenvolvimento e a aprimoração de metodologias cada vez mais eficientes e eficazes na detecção de cicatrizes de deslizamento, além de poder ser utilizado como base para a produção de mapas de susceptibilidade de risco de deslizamentos e sistemas de alertas e prevenção.

4 DISCUSSÃO

Os resultados produzidos e as análises presentes nesse trabalho deixam evidente que a aplicação de métodos baseados em *deep learning*, para a segmentação de locais onde ocorreram deslizamentos de massas de solos e rochas, tem grande potencial. Apesar disso, ainda fica evidente que o caminho para um método de segmentação totalmente automático ainda é longo, e a verificação dos pontos por um profissional é necessária para o método aplicado nesse trabalho.

Os resultados de desempenho da U-Net para esse tipo de trabalho vêm evoluindo e apresentaram resultados satisfatórios. Os valores para a função F-1 obtidos nesse trabalho foram superiores aos obtidos por alguns outros trabalhos anteriores similares, como o de Bragagnolo (2021) e Soares (2020), que obtiveram valores de 0.67 e 0.55, respectivamente.

A utilização de imagens de melhor resolução para aplicação dessa metodologia seria capaz de melhorar o desempenho e os resultados, e diminuir o esforço manual necessário para a produção de bancos de dados de deslizamentos. Apesar disso, imagens com uma resolução melhor muitas vezes não são disponíveis para todas as regiões, especialmente as menos desenvolvidas e mais pobres. Portanto é considerado como necessário o desenvolvimento e o aprimoramento de metodologias que sejam aplicáveis para esse tipo região, que muitas vezes são as que mais sofrem em decorrência de desastres naturais.

Também é possível um refinamento ainda maior do banco de dados produzidos nesse trabalho, sendo que os pontos podem ser classificados de diversas formas e inclusive formarem novos bancos de dados. Algumas das possibilidades de classificação desses pontos são a classificação por tipo de movimento de massa, por tipo de solo na região de acontecimento do deslizamento e pelo tamanho ou magnitude do acontecimento.

5 CONSIDERAÇÕES FINAIS

A aplicação de metodologias de aprendizado de máquina vem demonstrando muito promessa no combate aos riscos e impactos dos desastres ambientais. Este estudo produziu, através de uma abordagem semiautomática, um banco de dados de alta confiabilidade de cicatrizes de deslizamentos. Esse inventário de deslizamentos além de conter as coordenadas geográficas, o inventário também contém informações relacionadas a data de ocorrência dos movimentos de massa. Essas informações podem ser valiosas para o desenvolvimento de novos sistemas de mapeamento de susceptibilidade e risco de deslizamentos de terra.

Outra possibilidade é a aprimoração da metodologia, para que além de identificar a existência ou não de uma cicatriz de deslizamento, seja possível também classificar automaticamente, através da forma da cicatriz, o tipo de movimento de massa ocorrido. Além disso, com os intervalos de tempo onde os deslizamentos foram formados, é possível obter os dados hidrológicos do local, para possivelmente estimar com boa precisão a data de ocorrência dos movimentos de massas, e a geração de mapas de layers.

A criação de novos mapas com os pontos pertencentes ao banco de dados produzido nesse trabalho transpostos em cima dos mapas geológicos e de riscos do Serviço Geológico do Brasil é um próximo passo a ser feito, para analisar e estudar esses acontecimentos. A presença dos dados de cotas nas imagens também seria de grande importância para facilitar a validação das cicatrizes de deslizamentos.

Os falsos-positivos são um problema existente, porém essa metodologia ainda assim requer menos recursos e esforços humanos que a grande maioria das alternativas conhecidas. A validação deste inventário de deslizamentos de terra, por um especialista em estabilidade de massas de solos e rochas, garante a esse inventário um alto grau de confiabilidade. Uma outra análise, realizada por outro profissional, seria um esforço interessante para melhorar ainda mais o banco de dados produzido nesse trabalho.

Essa pesquisa nada mais é do que um esforço para o desenvolvimento de sistemas capazes de minimizar os riscos e as consequências de desastres naturais, como os deslizamentos de terra, para a sociedade. Especialmente para as regiões mais carentes em infraestrutura e recursos, que são necessários para lidar adequadamente com esses desastres.

5 REFERÊNCIAS

AUGUSTO FILHO, O. **Caracterização geológico-geotécnica voltada a estabilização de encostas: uma proposta metodológica.** Conferência Brasileira sobre Estabilidade de encostas – COBRAE, 1992.

BERTONE, P.; MARINHO, C. **Gestão de Riscos e Respostas a Desastres Naturais: A Visão Do Planejamento.** VI Congresso CONSAD de Gestão Pública, Brasília, 2013. Disponível em: < <http://www.sgc.goias.gov.br/upload/arquivos/2013-12/gestao-de-riscos-e-resposta-a-desastres-naturais.pdf>>.

BLASCHKE, T. et al. **Geographic object-based image analysis-towards a new paradigm.** ISPR journal of photogrammetry and remote sensing, Elsevier, V87, p. 180-191, 2014.

BRAGAGNOLO, L.; DA SILVA, R.V; GRZYBOWSKI, J.M.V. **Landslide susceptibility mapping with r.landslide: A free open-source Gis-integrated tool based on Artificial Networks.** 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364815219300647?via%3Dihub>.

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, SciELO Brasil v.51, 2021.

FRANÇOIS, Chollet et al. **Keras.** Disponível em: <https://github.com/fchollet/keras>, 2015. Acesso em: 07 jun 2022.

GAMEIRO, S. **Capacidade de generalização e extrapolação espacial de redes neurais artificiais no mapeamento a suscetibilidade de deslizamentos.** 100 f. Dissertação de mestrado – Universidade Federal do Rio Grande do Sul, curso de pós-graduação em Sensoriamento Remoto, Porto Alegre, 2020.

HERVÁS, J.; Bobrowsky, P..**Mapping: inventories, susceptibility, hazard and risk.** Landslides-Disaster Risk Reduction. Springer, p.321-349, 2009.

HIGHLAND, L.M; Bobrowsky, P. **O Manual de Deslizamento–Um Guia para a Compreensão de Deslizamentos.** Reston. US Geological Survey Circular, Virginia, 2008.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTÁTISTICA. **Censo demográfico.** Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9662-censo-demografico-2010, 2010>.

KIRSCHBAUM, D. et al. **A global landslide catalog for hazard applications: method, results, and limitations.** Natural Hazards, v. 52, n. 3, p. 561-575, 2010. Disponível em:doi:10.1007/s11069-009-9401-4. Acesso em:10 jul 2022.

KIRSCHBAUM, D. et al. **Spatial and temporal analysis of a global landslide catalog**. *Geomorphology*, v. 249, p. 4-15, 2015. Disponível em: <http://dx.doi.org/10.1016/j.geomorph.2015.03.016>, doi:10.1016/j.geomorph.2015.03.016. Acesso em 10 jul 2022.

KRØGLI, I.K et al. **The Norwegian forecasting and warning service for rainfall- and snowmelt-induced landslides**. *Natural hazards and earth system sciences*, 2018.

PETSCHKO, H. et al. **Assessing the quality of landslide susceptibility maps - Case study lower Austria**. *Nat. Hazards Earth Syst. Sci*, 2014.

POURGHASEMI, H.R; Rahmati, O.. **Prediction of the landslide susceptibility: Which algorithm, which precision?** *Catena*. Disponível em: 10.1016/j.catena.2017.11.022, 2018.

PRAKASH, N., et al. **Mapping landslides on EO data: Performance of deep learning models vs. traditional machine learning models**. *Remote Sensing*, v. 12, n. 3, p. 346, 2020. Disponível em: 10.3390/rs12030346. Acesso em: 06 jul 2022.

RONNEBERGER, Olaf et al.. **U-net: Convolutional networks for biomedical image segmentation**. In: *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015. p. 234-241. Disponível em: arXiv:arXiv:1505.04597v1.

SOARES, L. P.. **Segmentação automática de cicatrizes de deslizamento de terra em imagens de sensores remotos utilizando aprendizagem profunda de máquina (Deep Learning)**. 2022. Dissertação (Mestrado em Recursos Minerais e Meio Ambiente) - Instituto de Geociências, Universidade de São Paulo, São Paulo, 2022. doi:10.11606/D.44.2022.tde-08072022-080909. Acesso em: 2022-07-02.

STUMPF, A.; Kerle, N.. **Object-oriented mapping of landslides using Random Forests**. *Remote sensing of environment*, Elsevier, V. 115, n. 10, p. 2564-2577, 2011.

TAVARES, R. (2010). **Imbricações entre os ritmos do clima e os ritmos da urbanização na formação de risco e vulnerabilidade socioambientais a deslizamentos de terra na Serra do Mar-Ubatuba/SP**. 263 f. Dissertação (doutorado em Geografia) – Universidade Federal do Paraná, Curitiba, 2010.

UNESP. **Movimentos de Massa**. *Geodinâmica Externa: Processos de dinâmica superficial*, 2022. Disponível em: <http://www1.rc.unesp.br/igce/aplicada/ead/interacao/inter09.html>.

VANACÔR, R. N.; Rolim, S. B. A. **Mapeamento da suscetibilidade a deslizamentos usando técnicas de estatística bivariada e sistema de informações geográficas na região nordeste do rio grande do sul**. *Revista Brasileira De Geomorfologia*, 13, 2012.

WANG, W.D et al. **A subjective and objective integrated weighting method for landslides susceptibility mapping based on GIS.** Environmental Earth Sciences, 2012.

ZHONG, C. et al. **Landslide mapping with remote sensing: challenges and opportunities.** International Journal of Remote Sensing, Taylor & Francis p. 1-27, 2019.