



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**DISSERTAÇÃO DE MESTRADO**

**CAIO HENRIQUE ESQUINA LIMÃO**

**DM: 13/23**

**DETECÇÃO DE EROÇÃO EM TALUDES BASEADA EM DEEP  
LEARNING**

**UFPA/ITEC/PPGEE  
Campus Universitário do Guamá  
BELÉM-PA  
2023**



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**CAIO HENRIQUE ESQUINA LIMÃO**

**DM: 13/23**

**DETECÇÃO DE EROSÃO EM TALUDES BASEADA EM DEEP  
LEARNING**

Dissertação de Mestrado  
submetida à Banca Examinadora  
do Programa de Pós-Graduação  
em Engenharia Elétrica para o  
exame de qualificação de  
mestrado em Engenharia Elétrica,  
elaborada sob a orientação do  
Prof. Dr. Carlos Renato Lisboa  
Francês.

**UFPA/ITEC/PPGEE  
Campus Universitário do Guamá  
BELÉM-PA  
2023**



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**DETECÇÃO DE EROSÃO EM TALUDES BASEADA EM DEEP  
LEARNING**

Aprovada em: \_\_\_\_ / \_\_\_\_ / \_\_\_\_

DISSERTAÇÃO DE Mestrado submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Pará como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica com ênfase em Computação Aplicada.

---

Prof. Dr. Carlos Renato Lisboa Francês  
**Orientador – PPGEE/UFPA**

---

Prof. Dra. Evelin Helena Silva Cardoso  
**Avaliadora Externa ao Programa – UFPA**

---

Prof. Dr. Marcelino Silva da Silva  
**Avaliador Interno – PPGEE/UFPA**

## AGRADECIMENTOS

Mesmo sendo incapazes de atender todas as pessoas que me deram suporte, motivação e que possibilitaram o desenvolvimento deste trabalho, estes parágrafos serão responsáveis por expressar parte da gratidão que guardo por cada um que cruzou meu caminho. Portanto, desde já peço desculpas aos que não pude incluir aqui.

Agradeço primeiramente a Deus por sempre me apoiar, proteger e capacitar. Por cuidar de minha saúde mental e física afim de que eu atinja os objetivos dEle em minha vida.

Agradeço, em especial, a minha mãe, Ester Simone, pelos ensinamentos, exemplo, sacrifício, amor, incentivo, educação e por me proporcionar muito mais do que necessito. Muito obrigado mãe!

Agradeço a minha noiva, Malena Almeida, por despertar em mim a vontade de sempre melhorar em tudo o que eu faço, pelo companheirismo, amizade e pelo amor que construímos juntos.

Agradeço ao meu pai, Carlos Limão, pelas lições e ensinamentos, pelo suporte financeiro e disponibilidade quando precisei.

Agradeço ao meu irmão, Carlos Eduardo, pelo cuidado, exemplo e papel que têm desempenhado em minha vida todos esses anos.

Agradeço aos demais parentes, irmã, avó, tios e primos pelo ambiente familiar em que me encontro, pelo amor e suporte proporcionado por cada um de vocês.

Agradeço ao meu grande amigo, Sérgio Corrêa, pela amizade e companheirismo desenvolvido com o decorrer dos anos. Pela paciência e suporte durante grande parte de minha graduação e mestrado e pelos aconselhamentos trocados durante todo esse tempo.

Agradeço também aos meus demais amigos pelas experiências que me tornam hoje que eu sou, sem vocês eu não chegaria onde estou e nem onde desejo estar futuramente.

Agradeço pela orientação do Prof. Dr. Renato Frances e direcionamento da Prof<sup>ª</sup>. Thabatta Araújo por me introduzir ao tema tratado nesta dissertação e dar início ao que será tratado a seguir, me guiando durante todo este processo.

Agradeço também o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior-CAPEs, do Conselho Nacional de Desenvolvimento Científico e Tecnológico-CNPq, da Norte Energia S.A e do Programa de Apoio à Produção Qualificada-PROPESP/UFPA (PAPQ) (Edital 08 /2022) pelo suporte.

Enfim, a todos os que contribuíram de diversas maneiras para a realização deste trabalho.

*“O homem erudito é um descobridor de fatos que já existem - mas o homem sábio é um criador de valores que não existem e que ele faz existir.”*

Albert Einstein (1879 – 1955)

## RESUMO

As recentes catástrofes desencadeadas pelo rompimento das barragens de Fundão e Córrego do Feijão causaram cerca de 300 mortes e inúmeros danos socioambientais irreparáveis. Visto que a utilização de sistemas de monitoramento mais precisos e a realização adequada de manutenções preventivas e corretivas permitiriam identificar, e até amenizar, os danos causados à sociedade, pode-se constatar que há necessidade de maior investimento e incentivo à criação de soluções de Monitoramento da Integridade Estrutural (SHM) capazes de diagnosticar ocorrências que comprometem as principais estruturas civis, como pontes, barragens e taludes. As técnicas de Inteligência Artificial (IA) de alto desempenho têm sido capazes de resolver estes problemas de análise estrutural e apresentado resultados superiores às soluções anteriores, sua utilização têm aumentado drasticamente nos mais diversos cenários de SHM. Quando se trata de soluções de análise e classificação de imagens, a Rede Neural Convolutiva (CNN) é o tipo de rede neural que apresenta os melhores resultados. Logo, esta dissertação irá descrever o processo de desenvolvimento de uma CNN com três camadas de convolução que combina a utilização das tecnologias mais consolidadas no atual cenário de visão computacional, tais como o otimizador Adam e a normalização em lotes. A CNN proposta foi treinada com uma base de dados montada especificamente para esta dissertação, sendo composta por imagens de relatórios públicos de obras do governo brasileiro, portfólios de empresas que trabalham com construção e manutenção de taludes e reportagens sobre deslizamentos e/ou catástrofes. Estas imagens foram rotuladas, de acordo com o contexto de cada uma delas, como taludes estáveis ou não. Os resultados obtidos foram bastante satisfatórios, apresentando uma acurácia de 96,67% e provando que esta solução é capaz de identificar de maneira precisa e aprimorada os indicadores de instabilidade apresentados pelos taludes analisados, permitindo um planejamento mais adequado das manutenções para cada caso, na prevenção de possíveis desastres, gestão mais eficiente da mão de obra, redução de custos, maior segurança e saúde estrutural para garantir sua integridade a longo prazo.

**PALAVRAS-CHAVE:** CNN. CLASSIFICAÇÃO DE IMAGENS. SHM. INTELIGÊNCIA ARTIFICIAL. APRENDIZADO PROFUNDO. EROSÃO. TALUDE.

## ABSTRACT

The recent catastrophes triggered by the rupture of the *Fundão* and *Córrego do Feijão* dams caused around 300 deaths and countless irreparable socio-environmental damages. Since the use of more accurate monitoring systems and the proper execution of preventive and corrective maintenance would allow identifying, and even mitigating, the damage caused to society, it can be stated that there is a need for greater investment and incentive to create solutions of Structural Health Monitoring (SHM) capable of diagnosing occurrences that compromise the most crucial civil structures, such as bridges, buildings, dams and slopes. High-performance Artificial Intelligence (AI) techniques have been able to solve these structural analysis problems and presented superior results to previous solutions, their use has increased dramatically in the most diverse (SHM) scenarios. When it comes to image analysis and classification solutions, Convolutional Neural Network (CNN) is the type of neural network that delivers the best results. Therefore, this dissertation will describe the development process of a CNN with three convolutional layers that combines the use of the most consolidated technologies in the current scenario of computer vision, such as the Adam optimizer and batch normalization. The proposed CNN was trained with a database set up specifically for this dissertation, consisting of images of public work reports made by the Brazilian government, portfolios of companies that work with construction and maintenance of slopes and reports on landslides and/or catastrophes. These images were labeled, according to the context of each one of them, as stable or instable slopes. The results obtained were quite satisfactory, presenting an accuracy of 96.67% and proving that this solution is capable of identifying in a precise and improved way the instability indicators presented by the analyzed slopes, allowing a more adequate planning of the maintenance for each case, in the prevention of possible disasters, more efficient manpower management, cost reduction, greater safety and structural health to ensure its long-term integrity.

**KEYWORDS:** CNN. IMAGE CLASSIFICATION. SHM. ARTIFICIAL INTELLIGENCE. DEEP LEARNING. EROSION. SLOPE.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Composição da estrutura de um talude.....	20
Figura 2 - Estrutura genérica de uma MLP.....	23
Figura 3 - Estrutura de uma CNN com duas camadas convolucionais e de pooling e uma camada totalmente conectada.....	25
Figura 4 - Matriz tridimensional representativa de uma imagem.....	26
Figura 5 - Fluxograma da Camada Convolutiva.....	27
Figura 6 - Representação gráfica da função ReLU.....	29
Figura 7 - Exemplo de Max-pooling 2x2.....	31
Figura 8 - Fluxograma da metodologia adotada para desenvolvimento da CNN capaz de detectar erosão em taludes.....	33
Figura 9 - Gráfico da distribuição das imagens da base de dados.....	34
Figura 10 - Mosaico representando a variedade da base de dados utilizada.....	35
Figura 11 - Estrutura da CNN que obteve a melhor performance.....	36
Figura 12 - Imagem original e seu estado após análise da rede neural e reshade.....	39
Figura 13 - Figura 12 após aplicação dos filtros da primeira camada de convolução....	40
Figura 14 - Mapa de características da Figura 12 gerados pela primeira camada de convolução.....	41
Figura 15 - Figura 12 após aplicação dos filtros da última camada de convolução.....	42
Figura 16 - Mapa de características da Figura 12 gerados pela última camada de convolução.....	42
Figura 17 - Matriz de confusão da melhor performance obtida.....	43



## LISTA DE TABELAS

Tabela 1 – Trabalhos Relacionados.....	17
Tabela 2 - Comparação entre as diferentes arquiteturas testadas.....	38

## LISTA DE ABREVIATURAS E SIGLAS

<b>SHM</b>	Monitoramento de Integridade Estrutural
<b>CNN</b>	Redes Neurais Convolucionais
<b>ML</b>	Aprendizado de Máquina
<b>LR</b>	Regressão Logística
<b>DT</b>	Árvore de Decisão
<b>RF</b>	Floresta Aleatória
<b>GBM</b>	Aumento Gradual
<b>SVM</b>	Máquina de Vetores de Suporte
<b>MLP</b>	Perceptron Multicamadas
<b>GNSS</b>	Sistemas de Navegação por Satélite
<b>CV</b>	Visão Computacional
<b>DL</b>	Aprendizado Profundo
<b>RNA</b>	Redes Neurais Artificiais
<b>VANT</b>	Veículo Aéreo Não-Tripulado
<b>TLS</b>	Escaneamento Laser Terrestre
<b>FC</b>	Fully-Connected
<b>ReLU</b>	Unidade Linear Retificada
<b>ADAM</b>	Estimativa de Momento Adaptável
<b>BN</b>	Batch Normalization
<b>TP</b>	Verdadeiro Positivo
<b>TN</b>	Verdadeiro Negativo
<b>FN</b>	Falso Negativo
<b>FP</b>	Falso Positivo

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>13</b>
1.1 Motivações.....	14
1.2 Objetivos.....	15
1.3 Estrutura do Trabalho.....	16
<b>2. FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>17</b>
2.1 Considerações Iniciais.....	17
2.2 Trabalhos Correlatos.....	17
2.3 Estabilidade de Taludes.....	19
2.3.1.Cenário Atual para Monitoramento de Taludes.....	20
2.4 Redes Neurais Artificiais.....	21
2.4.1 Particularidades das RNAs.....	22
2.4.2 Redes Neurais Convolucionais.....	25
2.5 Demais Tecnologias Utilizadas.....	28
2.5.1 Camada de Ativação ReLU.....	29
2.5.2 Otimizador Adam.....	30
2.5.3 Normalização em Lotes.....	30
2.6 Considerações Finais.....	31
<b>3. METODOLOGIA.....</b>	<b>31</b>
3.1 Considerações Iniciais.....	31
3.2 Fluxograma do Desenvolvimento da CNN.....	32
3.3 Formulação da Base de Dados.....	33
3.4 Estrutura da CNN Desenvolvida.....	35
3.5 Análise de Performance.....	36
3.6 Considerações Finais.....	37
<b>4. RESULTADOS OBTIDOS.....</b>	<b>37</b>
4.1 Ambiente Operacional.....	37
4.2 Resultados da CNN Proposta.....	38

4.3 Considerações Finais.....	44
<b>5. CONCLUSÃO E TRABALHOS FUTUROS.....</b>	<b>44</b>
5.1 Principais Contribuições desta Dissertação.....	45
5.2 Trabalhos Futuros e Possíveis Desdobramentos.....	45
5.3 Dificuldades Encontradas.....	46
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>47</b>

# 1 INTRODUÇÃO

Englobando qualquer superfície inclinada de um maciço de solo ou rocha, o conceito de talude serve tanto para os de origem natural (também denominado de encosta) quanto os construídos pelo homem, como por exemplo, os aterros e cortes. Aqueles construídos pelo homem resultam de cortes em encostas, de escavações ou de lançamento de aterros, onde estes cortes devem ser executados com altura e inclinação adequadas para garantir a estabilidade da obra (GERSCOVICH, 2016).

Por definição, a erosão do solo é um processo geomórfico e, ao mesmo tempo, de degradação do solo que separa partículas de solo, fragmentos de rocha, agregados de solo e matéria orgânica de seu local primário e os transporta para outro local (POESEN, 2018). Sendo afetados, e muitas vezes intensificados pela intervenção humana, os processos naturais de erosão têm apresentado aumento significativo em sua ocorrência em todos os tipos de paisagens (BORRELI et al., 2021). Este tipo de degradação do solo é a principal causa de instabilidade em taludes e ocorre quando a resistência do solo diminui. Essa diminuição se dá principalmente por: redução da tensão de sucção da matriz, descontinuidades (falhas e fraturas), modificação da estrutura de solos sensíveis, liquefação de areia fina saturada e perda de coesão (CALLE, 2000).

Com o crescimento populacional ao redor do mundo, a construção de estradas, pontes e barragens, assim como a manutenção de seu funcionamento ideal têm sido de extrema importância para suprir e conectar os grandes polos rurais e urbanos. Visto que os taludes possuem impacto direto na barragem de rios, na sustentação, estabilidade do solo e no impedimento da queda de blocos e desmoronamentos, eles são amplamente utilizados como estruturas auxiliares às mencionadas anteriormente para aumentar sua segurança e preservá-las.

Devido ao impacto direto que os taludes possuem nas principais construções civis, como pontes e barragens, necessita-se do mais intenso monitoramento e da realização urgente de manutenções corretivas, e preventivas, para este tipo de estrutura. Tal investimento torna-se necessário afim de prevenir novas catástrofes, como as de Fundão e Córrego do Feijão, que recentemente causaram cerca de 300 mortes. Além das fatalidades, este tipo de catástrofe reflete em danos socioambientais

irreparáveis, como: isolamento de áreas habitadas, desalojamento de comunidades pela destruição de moradias e estruturas urbanas, destruição de áreas de preservação permanente e vegetação nativa, restrições à pesca, dificuldade de geração de energia elétrica pelas usinas atingidas e alteração na qualidade e quantidade de água (IBAMA, 2020).

O Monitoramento da Integridade Estrutural (SHM) consiste na detecção, identificação e avaliação em tempo real da evolução da segurança e do desempenho de estruturas. É uma área que têm crescido e atraído grande interesse por parte das grandes empresas de tecnologia, engenharia civil e da academia. Isto se dá devido à necessidade de soluções novas e inovadoras para solucionar problemas como o descrito no parágrafo anterior, que afetam diretamente a economia de um país e o funcionamento ideal da sociedade (BAO; CHEN; WEI, 2019).

Aliado ao crescimento do SHM, os sistemas de visão de baixo custo apresentam crescimento significativo, e com o auxílio da análise de imagens e vídeos, permitem avaliar, em alta qualidade, as condições estruturais de prédios, pontes, barragens e taludes. Este crescimento de ambas propostas possibilitou a utilização de SHM baseado em visão, que consiste principalmente em quatro etapas: calibração da câmera, aquisição e retificação da imagem, determinação do campo de deslocamento, medição e detecção dos danos (SONY; LAVENTURE; SADHU, 2019).

Sabe-se que os aplicativos de engenharia geralmente são “testbeds” eficazes para novas tecnologias, e a crescente utilização de Redes Neurais Convolucionais para solucionar problemas de SHM utilizando visão computacional reafirma que este tipo de tecnologia já está consolidado como uma solução eficiente e precisa. A última etapa do SHM baseado em imagem, medição e detecção dos danos, é o objeto de estudo desta dissertação, que busca atingir alto desempenho de detecção de danos por meio da utilização de CNNs, da Visão Computacional (CV) e do Aprendizado Profundo (DL) que têm apresentado grande sucesso devido ao rápido crescimento da Inteligência Artificial. (GAO; MOSALAM, 2022).

Contextualizando para cenários semelhantes ao desta proposta, a inteligência artificial entraria como aliada aos sistemas de monitoramento, onde as imagens obtidas por VANTs, ou até mesmo pela equipe de campo, seriam interpretadas e o diagnóstico referente a presença ou não de instabilidades e erosões aparentes capazes de comprometer a estrutura estudada fosse gerado.

## **1.1 Motivações**

Falhas em taludes podem causar danos ambientais, econômicos, psicológicos, patrimoniais e até mesmo resultar na perda de vidas humanas. É por isso que na maioria dos projetos de engenharia civil, a estabilidade do local tem sido considerada um grande problema. Infelizmente, mesmo a erosão do solo sendo uma das principais causas deste tipo de instabilidade, muitas vezes é negligenciada, apresentando suas consequências em longo prazo (MOAYEDI et al., 2021).

Atualmente, a abordagem predominante para detectar danos aparentes em estruturas têm sido a análise de imagens digitais. Com o aumento da utilização de veículos aéreos não tripulados (VANTs) e desenvolvimento deste tipo de meio de locomoção, a obtenção imagens/dados atingiu patamares revolucionários. Este cenário incentiva o desenvolvimento e utilização de softwares em conjunto aos VANTs, que possibilita a avaliação de terrenos de difícil acesso e/ou comprometidos, melhor precisão e velocidade na etapa de tomada de decisões e menor dependência da disponibilidade da mão de obra qualificada (AKBAR; QIDWAI; JAHANSHAH, 2018).

Propostas como a desta dissertação buscam explorar a oportunidade criada pelo ecossistema descrito anteriormente e oferecer soluções completas capazes de obter, analisar, interpretar e tomar decisões previamente programadas para melhorar a segurança e os serviços prestados à sociedade. Deste modo, a Rede Neural Convolutiva desenvolvida possibilita a detecção precoce de ocorrências de deslizamento e erosão por meio dos indicadores de instabilidade aparentes, prevenindo acidentes, mantendo e aprimorando a integridade do talude e do ambiente em que se encontra (WANG et al., 2020).

Um software de análise e classificação de imagens baseado em CNN foi preferível devido à facilidade de fusão com sistemas de monitoramento existentes, como drones, satélites e qualquer outro tipo de sistema capaz de capturar imagens com o objetivo de interpretá-las para obter informação relevante, aumentando a precisão, objetividade e velocidade de processamento dos sistemas de monitoramentos utilizados atualmente para casos de extrema relevância, como a integridade estrutural de taludes.

## **1.2 Objetivos**

Este trabalho tem como objetivo geral desenvolver uma rede neural convolucional de 3 camadas capaz de detectar danos estruturais aparentes em taludes e classificá-los como estruturas estáveis ou não. O diagnóstico é obtido através da análise de imagens coletadas, e visa aprimorar a tomada de decisão por parte dos sistemas de monitoramento.

A definição do objetivo geral resultou em uma melhor compreensão acerca da problemática retratada e da delimitação do escopo desta proposta, gerando os seguintes objetivos específicos:

- Realizar o levantamento da literatura atual sobre erosão em taludes;
- Definir o tipo de imagens a serem utilizados no banco de dados da aplicação e rotulá-las de cada uma delas como estável ou instável de acordo com o seu contexto;
- Padronizar, caso seja necessário, o formato e resolução das imagens;
- Utilizar diferentes estruturas de CNN no banco de dados desenvolvido para utilizar a que apresentar os melhores resultados;
- Testar combinações de hiperparâmetros e algoritmos distintas para definir a mais apropriada para esta proposta;
- Coletar as métricas necessárias para avaliar a performance da rede neural e validá-las utilizando o método de validação cruzada;
- Comparar os resultados obtidos com os da literatura;
- Publicar os resultados.

### **1.3 Estrutura do Trabalho**

Este trabalho está organizado em seis seções distintas, sendo uma delas de referências.

No capítulo 2, é apresentada a fundamentação teórica, algumas publicações semelhantes ao proposto neste trabalho, e as tecnologias necessárias para o funcionamento ideal desta abordagem. Dentre tais tecnologias, destacam-se: Estabilidade de Taludes, Aprendizado Profundo para Classificação de Imagens e Particularidades de CNNs.

O capítulo 3 apresenta a base de dados utilizada, a divisão dos dados, a estrutura da rede neural proposta e o seu funcionamento.

O capítulo 4 traz a análise de desempenho da CNN desenvolvida, detalhando as etapas de treinamento e teste, assim como apresentando o melhor resultado obtido para a detecção de instabilidade de talude.



Por fim, o capítulo 5 conclui o trabalho apresentando a análise dos resultados obtidos, possíveis melhorias que tal proposta pode ter para atingir uma melhor performance e as dificuldades encontradas durante o desenvolvimento desta dissertação.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Considerações Iniciais

Este capítulo irá apresentar os trabalhos correlatos, apresentar e contextualizar os conceitos necessários para a compreensão do cenário descrito posteriormente neste trabalho, apresentando o conceito de estabilidade de taludes e como se apresentam as instabilidades neste tipo de estrutura. A seguir, tem-se os conceitos básicos de Redes Neurais Artificiais e as principais diferenças que justificam a escolha das CNNs como estrutura base para o desenvolvimento da solução proposta, finalizando o capítulo com a apresentação e motivo da escolha das principais “tecnologias auxiliares” que aprimoraram o desempenho da rede neural.

### 2.2 Trabalhos Correlatos

A seguir, será apresentada uma breve revisão da literatura, incluindo várias pesquisas e propostas de Redes Neurais Artificiais (RNAs) para detecção de imagem, bem como métodos de previsão de estabilidade de taludes, conforme descrito na Tabela 1. Para o desenvolvimento deste artigo, a pesquisa bibliográfica girou em torno de artigos bem fundamentados que servem como base para novas implementações de RNAs. Obviamente, este trabalho busca mesclar os principais temas e tecnologias de cada artigo lido para propor a arquitetura mais adequada, visando que a rede neural proposta alcance o melhor desempenho possível.

Tabela 1 – Trabalhos Relacionados.

Pesquisa estudada	Tecnologias abordadas					Resumo da proposta
	Estabilidade de Taludes	Aprendizado Profundo	CNN	ReLU	Normalização em Lotes	
(YANG et al, 2022)	X	√	√	X	√	Proposta inovadora utilizando YOLO v3 para obter uma rede neural rápida e precisa capaz de detectar a soldura de parafusos em torres de turbinas eólicas.

(LIU et al, 2020)	√	X	X	X	X	Diagnóstico de estabilidade de taludes 2D e 3D utilizando métodos de elementos finitos foi proposta.
(QI; TANG, 2018)	√	√	X	X	√	Propôs uma excelente comparação entre seis algoritmos de Aprendizado de Máquina distintos.
(LU; TAN; JIANG, 2021)	X	√	√	√	X	Testou diferentes tipos de arquiteturas e conjuntos de dados CNN para encontrar o método ideal de classificação de doenças em plantas através da análise de suas folhas.
(KATTENBORN et al., 2021)	X	√	√	√	√	Apresentou um modelo de rede neural bem desenvolvido, e bem explicado, utilizado na classificação de vegetação.
(YADAV; JADHAV, 2019)	X	√	√	X	√	Possibilitou o diagnóstico de doenças por meio de CNN, combinando diferentes parâmetros e técnicas para atingir o melhor desempenho.

Fonte: Elaboração Própria.

Em (QI; TANG, 2018) uma comparação incrível entre seis algoritmos de Aprendizado de Máquina (ML) foi proposta, incluindo regressão logística (LR), árvore de decisão (DT), floresta aleatória (RF), aumento gradual (GBM), máquina de vetores de suporte (SVM) e rede neural perceptron multicamadas (MLP). O trabalho realizado por (LU; TAN; JIANG, 2021) destaca os melhores cenários para que uma CNN consiga realizar, de forma satisfatória, a classificação de imagens. E trabalhos como (KATTENBORN et al., 2021) apresentam como se têm utilizado as redes neurais convolucionais para realizar o sensoriamento remoto de vegetação, apresentando o estado da arte e diferentes propostas de sensoriamento remoto. Propostas como as apresentadas na Tabela 1 possibilitam e incentivam que surjam ideias como a desta dissertação, assim como novas aplicações que utilizam sistemas de visão aliados à CNNs.

As propostas mais atuais se diferem deste trabalho pois a arquitetura desenvolvida, combinada com as tecnologias apresentadas no próximo capítulo, obteve melhores resultados e desempenho superior, se comparada com a literatura atual. Isso se dá devido a necessidade de se utilizar múltiplas camadas convolucionais

para que a rede processe adequadamente a base de dados desenvolvida e possa trabalhar em conjunto com sistemas de monitoramento já existentes, utilizando as imagens por eles obtidas (via VANTs e/ou satélites) para extrair informações e diagnosticar sua integridade estrutural.

Este trabalho busca explorar o uso da visão computacional em conjunto com técnicas de processamento de alto desempenho, como as CNNs, para detectar danos em estruturas geotécnicas, uma vez que é essencial para a confiabilidade desses tipos de estruturas e para das demais que dela dependem.


### **2.3 Estabilidade de Taludes**

Segundo Marinho (2018), o nome genérico “*talude*” compreende quaisquer superfícies inclinadas que limitam um maciço de terra, rocha ou terra-rocha. A avaliação da estabilidade de taludes é crucial para geotecnia e engenharia civil, pois taludes artificiais, projetos de barragens, aterros e estruturas similares impactam diretamente o ecossistema, podendo acarretar desastrosas consequências (MARINHO, 2018), (MISHRA; GUNTURI; MIRANDA, 2019).

Tais consequências tendem a ser mais frequentes devido a urbanização e desenvolvimento de áreas sujeitas a escorregamentos, desflorestamento contínuo e aumento da taxa de precipitação causadas pelas mudanças climáticas. Dentre os principais movimentos de taludes, tem-se: Desprendimento de terra ou rocha, escorregamento e rastejo (MARINHO, 2018).

Como ilustrado na Figura 1, os taludes são terrenos que servem de base de sustentação para o solo, podendo ser de origem natural ou artificial (feitos pelo homem). A geometria ideal, dependendo das condições do solo, é no máximo de  $i=45$  (ou seja, de  $45^\circ$ ), pois variações maiores comprometem a sua estabilidade. Os de origem não natural, chamados de taludes artificiais, são, em sua maioria, estruturas construídas para evitar deslizamentos de terra em locais onde esta ocorrência afetaria diretamente o homem (PIRAMIDE, 2018).

Figura 1 – Composição da estrutura de um talude.



Fonte: (MARINHO, 2018)

A utilização de taludes, aliada a utilização de tirantes, âncoras, concreto projetado e drenagem, proporciona grande estabilidade ao solo e é ideal para casos em que a pressão gerada pela terra excede à suportada. Porém, se submetidos a grande pressão, recomenda-se a utilização de técnicas de proteção, e a escolha de qual utilizar depende do tipo de projeto em que ela se encontra inserida. Geralmente, tal proteção é feita utilizando revestimento de pedra, solo grampeado, concreto, muro de arrimo, bermas ou ancoragem. Dependendo do comprimento da encosta, também é aconselhável construir curvas de nível para evitar a erosão causada pela chuva. Outro método de preservação é o uso de vegetação para cobrir as encostas, proporcionando maior estabilidade (PIRAMIDE, 2018) e (LIEß; GLASER; HUWE, 2011).

### 2.3.1 Cenário Atual para Monitoramento de Taludes

O monitoramento de taludes e barragens é um componente essencial dos programas de prevenção de riscos aplicados no mundo moderno. Dado que pequenas falhas estruturais são capazes de levar grandes estruturas civis ao colapso, e refletem em perdas materiais e econômicas significativas e grande número de fatalidades, faz-se necessário o investimento pesado em prevenção e monitoramento. Tais ocorrências refletiram na mudança e melhoria dos programas de inspeção, compondo e fundamentando o SHM como identificação experimental de propriedades dinâmicas relevantes de grandes estruturas (RUIZ-ARMENTEROS et al., 2021).

Quando se trata de talude e similares, costumava-se realizar suas medições, de maneira frequente, utilizando sensores sem fio, fibra óptica, sistemas de radar interferométrico, sistemas de navegação por satélite (GNSS) e/ou escaneamento via laser terrestre (TLS). Porém, o desenvolvimento dos sistemas de visão de baixo custo têm revolucionado a maneira como se analisa as estruturas civis, proporcionando um diagnóstico da integridade real da estrutura de maneira mais objetiva e rápida por meio de imagens e vídeos capturados em diferentes ângulos da estrutura em questão (FLAH et al., 2020) e (RUIZ-ARMENTEROS et al., 2021).

Porém, o avanço da tecnologia de veículos aéreos não tripulados e o desenvolvimento de diversas ferramentas de pilotagem e programação de voos automáticos permite a aquisição de dados relevantes à análise de taludes e encostas de forma ágil, e sem expor a equipe técnica aos riscos de instabilidade destas estruturas. Logo, a utilização de drones para realizar o monitoramento de áreas de difícil acesso e mapeamento de estruturas por meio de fotogrametria e/ou filmagem, têm aumentado em quantidade e qualidade. As soluções de inteligência artificial, cada vez mais utilizadas em conjunto aos VANTs, têm sido aprimoradas para aquisição, segmentação e diagnóstico de dados provenientes de imagens. Esta combinação tem apresentado resultados semelhantes e até superiores quando comparada com as técnicas de monitoramento já citadas, agregando redução de custo e tempo (RIBAS et al., 2022) e (ZUCATELLI; PHILIPS; WATASHI, 2018).

Vale destacar que neste trabalho a instabilidade de talude é considerada como a remoção da cobertura vegetal, rupturas de caráter superficial ou profundo e presença constante de lama ou detritos, sendo classificada em duas categorias: deslizamentos e erosão. O primeiro representa os movimentos gravitacionais de massa que ocorrem quando a tensão excede a resistência mecânica de um talude, e o segundo conceito engloba a remoção da vegetação e/ou solo superficial causados por diferentes tipos de erosão (LÖBMAN et al., 2020).

### **2.3 Redes Neurais Artificiais**

A seguir, será apresentado e explicado o funcionamento das Redes Neurais Artificiais de maneira geral, o cenário em que elas estão imersas, os conceitos necessários para compreender o seu funcionamento e como se dá o processo de aprendizado, treino e teste deste tipo de tecnologia.

Após o cenário geral das RNAs ser apresentado, o tipo de rede neural proposto

nesta dissertação é descrito juntamente das inovações e particularidades que ele tem em relação as demais opções de estrutura de RNA. Explica-se o porquê de sua excelência em problemas que envolvem análise e classificação de imagens e como esta rede as interpreta, como funcionam as camadas de convolução e *pooling* e como os mapas de características são gerados.

### 2.3.1 Particularidades das RNAs

Nos últimos tempos, as Redes Neurais Artificiais têm se tornado muito populares e úteis nas mais diversas aplicações industriais e comerciais. As RNAs são um tipo de modelo de Aprendizado de Máquina (ML) e vêm competindo cada vez mais com os modelos convencionais de regressão e estatística pelo melhor desempenho. O grande potencial desse tipo de solução é o processamento de alta velocidade, o que justifica a crescente necessidade de pesquisa nesse domínio (ABIODUN et al., 2018).

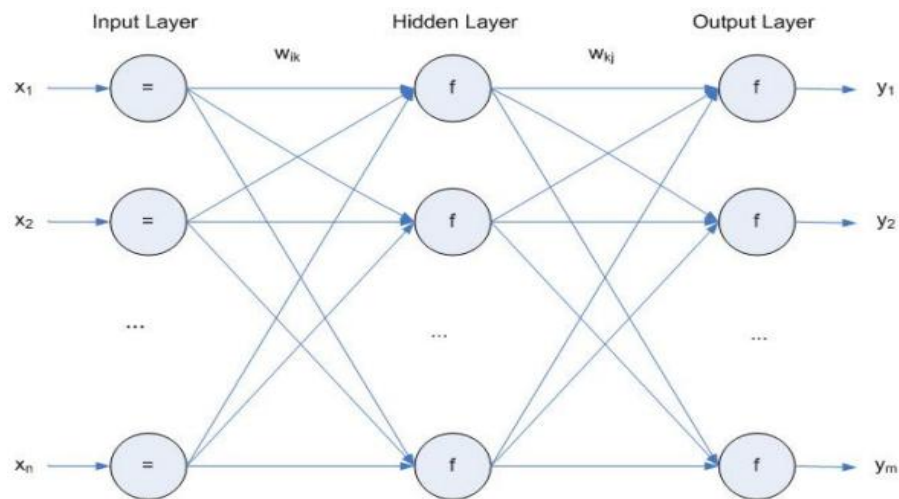
As Redes Neurais Artificiais são modelos computacionais inspirados no funcionamento de sistemas nervosos biológicos, como o cérebro humano. São capazes de realizar o aprendizado de máquina através do processamento de informações, sendo comumente utilizadas para solucionar problemas de reconhecimento de padrões. Elas são projetadas para aprender com dados experimentais ou analíticos/teóricos, permitindo que elas classifiquem dados, prevejam valores e auxiliem nas tomadas de decisão nos mais diversos tipos de processo (ASTERIS; MOKOS, 2019).

O modelo introduzido em 1958 por Rosenblatt, denominado de rede *feedforward* de camada única, tem o seu aprendizado limitado a padrões linearmente separáveis. Logo, para que as redes neurais fossem capazes de trabalhar com valores não-lineares, são introduzidas camadas escondidas (*Hidden Layers*) entre a camada de entrada (*Input Layer*) e de saída (*Output Layer*) com o objetivo de transformar as entradas da rede por meio de funções de ativação não-lineares para representar a resposta da rede de maneira probabilística, geralmente entre 0 e 1 (ROSENBLATT, 1958).

A Figura 2 mostra a estrutura base do tipo de rede neural mais utilizado, denominada Perceptron multicamadas (MLP), onde os nós com o símbolo “=” em seu interior possuem a saída igual a entrada, já o “*f*” representa que a sua saída é uma função da soma ponderada das entradas do neurônio. Em sua maioria, este tipo de

rede é treinado utilizando o algoritmo Backpropagation. Tal algoritmo é uma técnica de aprendizado supervisionado que otimiza os pesos dos nós da rede para que ela possa mapear corretamente cada entrada apresentada a ela. Com o objetivo de obter melhores resultados, a rede compara a sua resposta com a resposta esperada pelo problema, obtendo o valor de erro. Este valor é propagado do último nó em direção ao primeiro, ajustando o peso de cada nó pelo caminho (HUANG, 2009).

Figura 2 – Estrutura genérica de uma MLP.



Fonte: (HUANG, 2009)

Um algoritmo de aprendizado de máquina é um processo computacional que utiliza os dados de entrada para realizar tarefas sem ser programado para produzir determinado resultado. Esses algoritmos alteram e adaptam automaticamente sua arquitetura para se tornarem cada vez melhores na realização da tarefa desejada. Este processo de adaptação chama-se treinamento, onde são fornecidas amostras de dados de entrada juntamente dos resultados esperados para cada uma delas (EL NAQA, 2015).

De maneira otimizada, o algoritmo se configura para ser capaz de generalizar e produzir resultados satisfatórios para as mesmas entradas apresentadas durante o treinamento e novas entradas de dados, não apresentadas para ele anteriormente. Esta seria a parte de aprendizado, onde os pesos são ajustados para os valores considerados satisfatórios. Dentre os principais tipos de aprendizado, destacam-se três categorias: aprendizado supervisionado, não supervisionado e por reforço (EL NAQA, 2015).

No Aprendizado Supervisionado, os exemplos de entrada e as suas respectivas respostas são fornecidas para a rede, e conforme os dados são analisados

pelo algoritmo, seus pesos são ajustados de maneira que o erro entre a saída da rede e a resposta esperada diminua. É importante considerar, quando confeccionando a base de dados utilizada para o treinamento, que ela deve representar fielmente o objeto de desenvolvimento da rede neural, visto que um conjunto de treinamento não representativo não pode produzir um modelo confiável e geral. Por fim, após a rede ser treinada e apresentar performance satisfatória, seus pesos são fixados para que ela possa entrar em operação (ZOU; HAN; SO, 2008).

Por sua vez, no Aprendizado não Supervisionado não há categorização e rotulação dos dados. O algoritmo é deixado por conta própria para que ele possa analisar os dados de entrada e agrupá-los de acordo com as suas semelhanças. Quando novos dados são apresentados para a rede, ela utiliza o que aprendeu durante o treinamento para reconhecer a classe de cada entrada. Dentre os tipos de aprendizado não supervisionado, os mais utilizados são: Clustering, Agrupamento Hierárquico e K-means (MAHESH, 2019).

O Aprendizado por Reforço ocorre quando o agente depende do ambiente para enviar a ele um número escalar em resposta a cada nova ação, não é apresentado para o algoritmo quais ações ele deve tomar, por outro lado, ele deve descobrir quais decisões oferecem a melhor recompensa ou a menor punição. Em aplicações mais desafiadoras, as decisões da rede neural podem afetar não apenas a recompensa imediata, mas também todas as subsequentes. Essas duas características: busca por tentativa e erro e recompensa atrasada são duas das características distintivas mais importantes do aprendizado por reforço (DATA SCIENCE ACADEMY, 2022) e (SUTTON; BARTO, 2018).

As pesquisas e aplicações de aprendizado de máquina têm avançado cada vez mais sob a liderança do aprendizado profundo (*deep learning*). Este é um conceito que deriva da rede neural convencional, mas apresenta melhores resultados ao empregar transformações e múltiplas camadas para representar as abstrações dos dados e construir modelos computacionais que mudaram completamente a percepção que se tinha sobre processamento de informações. Os algoritmos de aprendizado profundo mais utilizados são: redes generativas adversárias, redes neurais convolucionais, de memória de curto e longo prazo e redes neurais recorrentes (POUYANFAR et al., 2019) e (ALZUBAIDI, 2021).

Dentre os diferenciais dos modelos de aprendizado profundo, destaca-se a sua capacidade de trabalhar com grandes conjuntos de dados e continuar se aprimorando




conforme novas entradas são apresentadas a eles. Tal característica, aliada ao fato deste tipo de aplicação ser capaz de trabalhar com dados de entrada de diferentes tipos (áudio, imagens, linguagem natural, entre outros), supera os resultados atingidos pelas abordagens clássicas do aprendizado de máquina (ESTEVA et al., 2019).

### **2.3.2 Redes Neurais Convolucionais**

A estrutura deste tipo de rede neural foi inspirada no funcionamento da visão humana, tornando-a uma ferramenta bem-sucedida em soluções de visão computacional e estado da arte para os modelos de atividade neural e resolução de problemas visuais. Seguindo o exemplo da primeira aplicação bem-sucedida de uma CNN, desenvolvida por Yann LeCun em 1998, este tipo de rede neural possui um histórico de alta acurácia para problemas de reconhecimento de imagem, detecção e reconhecimento de objetos. Por ser um tipo de rede *feed forward*, o princípio básico por trás do seu funcionamento gira em torno da utilização da convolução para produzir diversos mapas de características por meio da aplicação de filtros (LINDSAY, 2020); (TIAN et al., 2020) e (METHA; PAUNWALA; VAIDYA, 2019).

A crescente utilização deste tipo de rede neural se deu pela sua diferente proposta, que consiste em analisar regiões da imagem, e não cada um de seus pixels, refletindo na diminuição da quantidade de conexões necessárias entre os nós da rede e na otimização das etapas de treinamento e teste. Assim, apenas os dados que correspondem a cada região da imagem são apresentados para os neurônios das camadas ocultas. A Figura 3 apresenta a estrutura de uma Rede Neural Convolucional com duas camadas de convolução e de pooling intercaladas e uma camada totalmente conectada (ALBAWI; MOHAMMED; AL-ZAWI, 2017) e (GIRSHICK, 2015).

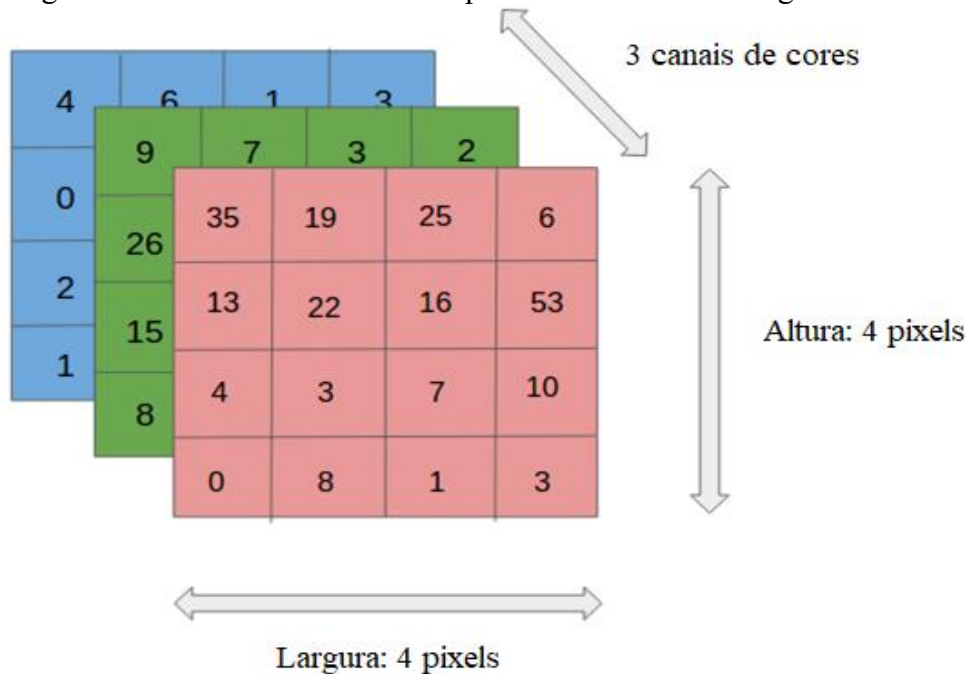
Figura 3 – Estrutura de uma CNN com duas camadas convolucionais e de pooling e uma camada totalmente conectada.



Fonte: Elaboração Própria.

Se tratando de problemas de classificação e reconhecimento de imagens, as entradas da rede são apresentadas como matrizes tridimensionais, como ilustrado na Figura 4. A largura e altura da matriz varia de acordo com as dimensões da imagem (no exemplo se utiliza 4 pixels), e sua profundidade de acordo com a quantidade de canais de cores e seus respectivos valores para cada pixel da entrada. A maior parte das aplicações deste tipo utiliza 3 canais de cores, seguindo o padrão RGB, que representa as cores em escalas de vermelho, verde e azul (ALVES, 2018).

Figura 4 – Matriz tridimensional representativa de uma imagem.



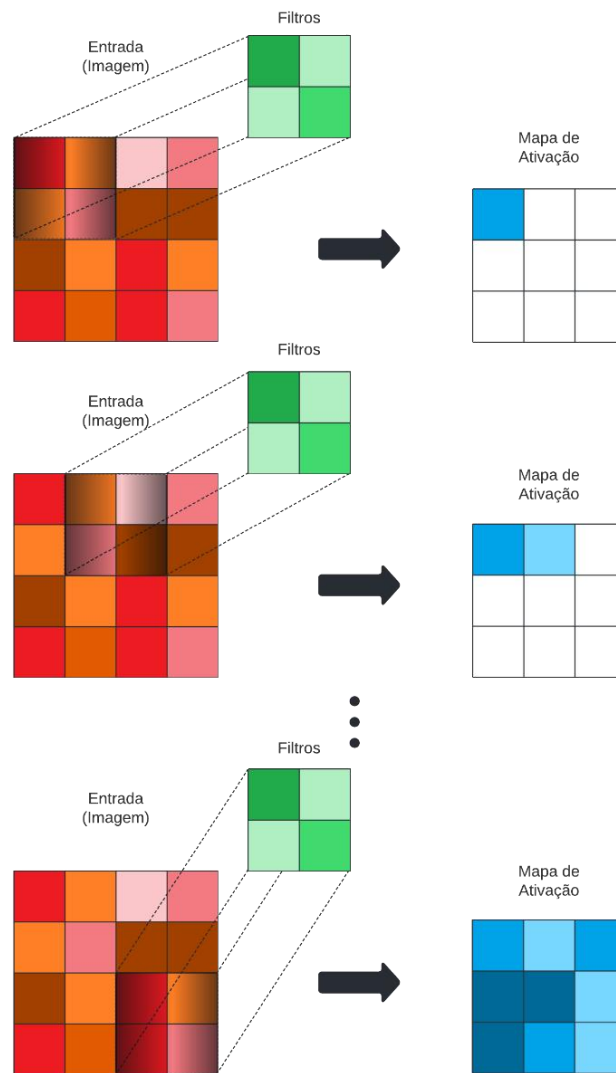
Fonte: (ALVES, 2018)

Após processar a respectiva matriz dimensional de cada entrada submetida à CNN, a rede dá início ao processo de convolução. Nesta camada, como representado na Figura 5, são aplicados filtros que executam operações convolucionais em toda a

imagem, escaneando e encontrando o produto escalar entre o filtro aplicado e cada região desta imagem. O resultado destas operações é denominado de mapa de características, que fornece informações sobre os cantos e arestas da imagem para as demais camadas, possibilitando que elas aprendam as demais características da imagem (SZEGEDY et al., 2015).

Vale destacar que a profundidade da saída de uma operação de convolução é igual a quantidade de filtros aplicados, estes pesos são gerados aleatoriamente e se atualizam a cada nova entrada durante o processo de *backpropagation*. Logo, quanto maior a quantidade de filtros aplicados aos dados de entrada mais detalhados serão os mapas de características gerados pela rede neural e a divisão entre as diferentes seções de cada imagem (ALVES, 2018).

Figura 5 – Fluxograma da Camada Convolutiva.



Fonte: Elaboração Própria.

Na maioria dos casos, as imagens possuem uma série de informações redundantes para a rede, por isso há a necessidade de utilizar camadas de *pooling* após as operações de convolução, para evitar que o desempenho da rede seja afetado de maneira negativa. Atualmente, a técnica de *pooling* que têm apresentado os melhores resultados para representações que dependem de estatística de contagem é o *Max-pooling*, visto que esta técnica otimiza o mapa de características, selecionando o elemento máximo de cada região da imagem (geralmente se utiliza em regiões 2x2), e melhorando o desempenho em aplicações que processam muitas imagens (AKHTAR; RAGAYENDRAN, 2020), (MURRAY; PERRONNIN, 2014), (GRAHAM, 2015) e (HE et al., 2019).

Por fim, a última característica que podemos notar na Figura 3 quanto a estrutura das redes neurais convolucionais é a camada totalmente conectada (FC).

Nesta camada inicia-se o processo de classificação das informações extraídas pelas camadas anteriores, visto que ela recebe os mapas de características e aplica pesos para prever o rótulo correto. Quando se utiliza múltiplas camadas totalmente conectadas, a primeira tem a função de aproximação dos dados, aprimorando a performance de classificação, e a última camada FC geralmente tem a função de aplicar a função de ativação escolhida para fornecer as probabilidades finais para cada classe (LIU et al., 2018).

Sabe-se que as características analisadas pela última camada convolucional das CNNs correspondem apenas a uma parte da entrada, logo, a visão da rede não engloba toda a visão espacial da imagem, tornando obrigatória a utilização da camada totalmente conectada. Quanto aos parâmetros desta camada, como o número de camadas FC e a quantidade de neurônios necessários nelas varia de acordo com o cenário (BASHA et al., 2020).

## **2.4 Demais Tecnologias Utilizadas**

Entende-se como “demais tecnologias” as principais tecnologias auxiliares à estrutura de CNN desenvolvida, sendo elas: Função de Ativação ReLU, Otimizador Adam, Normalização de lotes, Maxpooling e Função Softmax. A escolha destas soluções em lugar de qualquer outra concorrente se deu tanto por elas já estarem consolidadas no cenário de Inteligência Computacional, quanto pelos resultados obtidos após os testes realizados durante o desenvolvimento desta CNN (Tabela 1).


### **2.4.1 Camada de Ativação ReLU**

As funções de ativação são comumente utilizadas após cada camada de convolução com o objetivo de proporcionar uma certa linearidade na saída do neurônio, uma vez que os dados de uma imagem não são linearmente separáveis. A Unidade Linear Retificada (ReLU) é a função de ativação mais utilizada no mundo, se mostrando a mais eficiente tanto em aplicações que utilizam redes neurais convolucionais quanto as demais de aprendizado profundo. Por mais que a ReLU pareça ser uma função linear, ela não é, pois possui uma função derivada que permite retropropagação. No entanto, quando a entrada se aproxima de zero ou menos, o gradiente desta função torna-se zero, impedindo que a rede realize retropropagação (BANDEMIAN; FRANCA, 2021) e (RIZZO; CANATO, 2021).

Na prática, as saídas dos filtros são submetidas à função de ativação ao final

de cada camada convolucional, e após passar por este processo, utilizadas para atualizar os pesos da rede neural (VERNE et al., 2022).

Figura 6 – Representação gráfica da função ReLU.



Fonte: (NOMIDL, 2022)

Observando a Figura 6, nota-se que a função ReLU é representada por  $f(x) = \max(0, x)$ , logo, os neurônios só serão ativados se a entrada for maior que zero, e os neurônios que receberem valores negativos serão “apagados”. Essa particularidade aumenta a velocidade de treinamento, previne a dissipação de gradientes e reduz o custo computacional, por outro lado, se um neurônio recebe apenas valores negativos, ele não proporcionará ganho para o aprendizado para a rede.

#### 2.4.2 Otimizador Adam

Um algoritmo de otimização adaptativo existe com o intuito de encontrar os melhores pesos para uma rede neural, visando a minimização da função de erro (quanto mais próximo de zero, melhor), refletindo na redução do erro da rede como um todo. A estimativa de momento adaptável (ADAM) combina as melhores propriedades dos algoritmos AdaGrad e RMSProp para fornecer um algoritmo de otimização que trata ruídos (ZHANG, 2018).

Inventado por Kingma e Ba, este é um dos algoritmos de otimização para descida de gradiente mais populares na área de redes neurais. É um método realmente eficiente ao trabalhar com grande quantidade de dados ou parâmetros, requer menos memória e apresenta grande eficiência, visto que converge muito mais rápido do que qualquer outro otimizador tanto para redes neurais multicamadas quanto para redes neurais convolucionais, mas não apresenta resultados tão bons em casos de

generalização (KINGMA; BA, 2015) e (BOCK; GOPPOLD; WEIß, 2018).

### **2.4.3 Normalização em Lotes**


Comumente chamada de Batch Normalization (BN), a normalização de lotes permite que os hiperparâmetros sejam definidos de forma mais livre, pois reduz significativamente o tempo de treinamento ao normalizar a entrada de cada camada da rede, e não apenas da camada de entrada. Essa abordagem permite o uso de taxas de aprendizado mais altas, reduzindo o número de etapas de treinamento (GARBIN; ZU; MARQUES, 2020).

Essas vantagens tornam a normalização em lote um candidato natural para acelerar o treinamento de diferentes combinações de hiperparâmetros necessários para otimizar o uso de camadas de dropout, fazendo a rede convergir de maneira mais rápida. Durante o treinamento, o BN estima a média e a variância de todas as ativações dentro de um mini-lote por meio da média móvel exponencial e do fator de atualização, utilizando esses valores para as ativações de entrada durante a fase de teste (GARBIN; ZU; MARQUES, 2020) e (CHANG et al., 2019).

### **2.4.4 Max-pooling**

Tradicionalmente, as operações de pooling são utilizadas para simplificar a informação resultante da camada na qual elas forem aplicadas (normalmente são aplicados após cada camada de convolução). Por exemplo, se for definido que a unidade de área de pooling será  $2 \times 2$  e a camada anterior às operações de pooling apresentar uma resposta  $24 \times 24$ , o pooling reduzirá esta resposta para  $12 \times 12$ . Observando a Figura 7, nota-se que o max-pooling, por sua vez, obtém apenas o valor máximo de cada unidade de área das janelas de agrupamento, resultando em um *downsampling* do mapa de recursos convolucionais que retém a resposta máxima (recursos de pooling) (ZHENG; IWANA; UCHIDA, 2019).

Figura 7 – Exemplo de Max-pooling 2x2.



Fonte: (WALTERS, 2019)

#### 2.4.5 Softmax

A função de ativação Softmax é normalmente utilizada para problemas de classificação múltipla e aplicada na última camada da rede neural. Esta função visa converter a saída desta última camada, e conseqüentemente a resposta da rede, no que é essencialmente uma distribuição probabilística. Visto que os componentes do vetor de resposta da rede podem ser negativos, maiores que um, ou a sua soma pode não ser igual a um, a camada softmax gera uma distribuição de probabilidade para que a soma de saída seja 1. Sua implementação ajuda o treinamento a convergir mais rapidamente, fazendo com que esta função seja recomendada para tarefas de classificação múltipla (ASADI; JIANG, 2020).

#### 2.5 Considerações Finais

Neste capítulo, todas as tecnologias utilizadas durante o desenvolvimento deste trabalho foram apresentadas, explicadas e tiveram o motivo de sua escolha justificado pelo papel que possuem na estrutura de rede neural desenvolvida. Também foram apresentados os conceitos necessários para o entendimento completo dos seguintes capítulos. O próximo capítulo detalha a metodologia adotada nesta dissertação.

### 3 METODOLOGIA



### **3.1 Considerações Iniciais**

Este capítulo apresenta a ideia por trás da solução proposta, definindo o seu escopo, o fluxograma que foi seguido para que o seu desenvolvimento fosse completo e atingisse os objetivos destacados na introdução desta dissertação, como se originou a base de dados utilizada e as fontes das quais as imagens utilizadas nas etapas de treinamento e teste foram obtidas.

Após esta apresentação, a estrutura da CNN customizada para esta aplicação é apresentada e seu funcionamento explicado juntamente da análise de performance, feita para determinar se a performance obtida supre a necessidade que parte dos atuais sistemas de monitoramento de taludes possuem por uma solução de visão computacional eficiente.

Esta proposta visa agregar redundância ao processo de fiscalização e monitoramento, muitas vezes prevenindo o deslocamento desnecessário de profissionais, e aumentar a segurança por meio da identificação precisa dos indicadores de instabilidade, o que reflete em um planejamento de manutenção mais adequado, reduzindo gastos e prevenindo possíveis desastres ambientais.

Esta redundância torna-se necessária para minimizar ao máximo os erros humanos inevitavelmente cometidos durante a análise do talude e da região em que ele se encontra por equipe de campo e possibilitar que esta mesma equipe trabalhe em conjunto com a rede neural, rotulando as imagens obtidas para que a rede seja capaz de extrair novos conceitos, refletindo na identificação dos mais diversos tipos de instabilidade de maneira mais precisa.

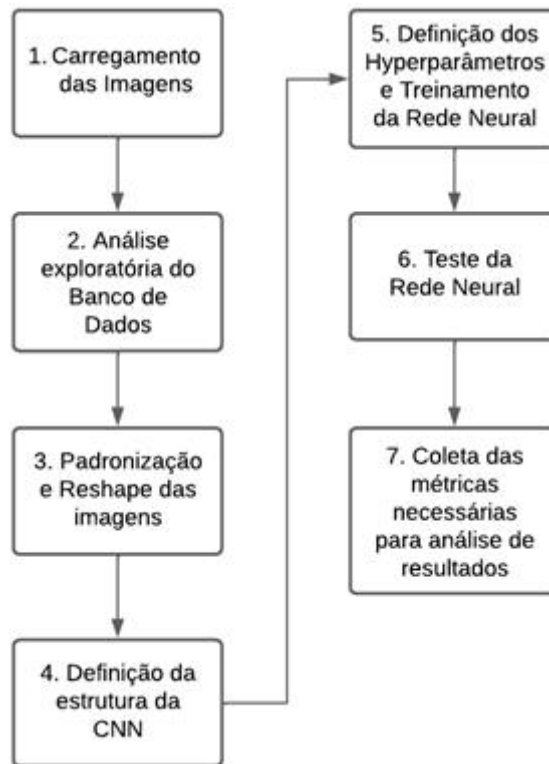
Nota-se que tal aplicação não efetua o cálculo do fator de segurança, dada a indisponibilidade de uma base de dados robusta e composta por diversos exemplos de taludes rotulados em todos os cenários necessários para que tal cálculo fosse possível. Logo, a avaliação de estabilidade de taludes se dá sem a utilização de tal fator, sendo feita por meio da detecção de instabilidades aparentes.

### **3.2 Fluxograma do Desenvolvimento da CNN**

Neste trabalho, desenvolveu-se uma Rede Neural Convolutiva de três camadas capaz de identificar, por meio da análise visual, diferentes tipos de erosão e deslizamentos de terra, utilizada para diagnosticar a estabilidade de estruturas de talude. No entanto, visto que este trabalho utiliza imagens como entrada da rede

neural, os casos de deslizamento também acabam sendo rotulados como erosões, por estar em seu estado final. A Figura 8 apresenta um fluxograma da metodologia utilizada para o desenvolvimento desta rede neural.

Figura 8 - Fluxograma da metodologia adotada para desenvolvimento da CNN capaz de detectar erosão em taludes.



Fonte: Elaboração Própria.

Os subtópicos a seguir irão tratar das principais etapas de desenvolvimento desta CNN, estes são: Formação da Base de Dados, Estrutura da CNN, Etapas de Treino e Teste.

### 3.3 Formulação da Base de Dados

A base de dados utilizada foi formada por imagens obtidas da internet, a maioria delas de relatórios públicos de obras do governo brasileiro, de reportagens sobre deslizamentos, catástrofes ou acidentes e o restante das imagens foram retiradas de sites de empresas privadas que as postaram para demonstrar seus trabalhos de manutenção de taludes. Este conjunto de imagens possui dimensões diferentes e suas extensões variam entre PNG, JPG e JPEG. Para que a rede neural pudesse analisá-las igualmente, elas tiveram a sua totalidade de pixels dividida em seções de  $128 \times 128 \times 3$ , onde o último número refere-se aos canais de cores, onde 3 representa o grau de vermelho, verde e azul presente em cada pixel.

O conjunto de dados analisado neste trabalho consiste em 300 imagens. Onde 200 destas representam estruturas com erosão e o restante corresponde a estruturas de talude sem danos visíveis e consideradas estáveis, ou seja, sem erosão ou deslizamento de terra aparente. A distribuição destas imagens, demonstrada na Figura 9, segue a seguinte proporção: 73% para treinamento (219 imagens), 17% para validação (51 imagens) e 10% para teste (30 imagens).

Figura 9 – Gráfico da distribuição das imagens da base de dados.



Fonte: Elaboração Própria.

A Figura 10 representa a variedade de imagens da base de dados utilizada pela rede para que ela possa aprender a identificar uma erosão e um talude estável. Nota-se que as imagens da base de dados possuem diferentes ângulos de fotografia e graus de instabilidade. As ilustrações apresentadas pela Figura 10 buscam esclarecer o que se entende por "Erosão" e "Talude estável" mencionados neste trabalho. O primeiro termo generaliza danos aparentes que comprometem ou podem vir a comprometer a estrutura do talude, enquanto o segundo engloba todo tipo de ocorrências menores consideradas irrelevantes (como os buracos cavados para plantio).

A rotulação das imagens encontradas no mosaico da Figura 10 foram feitas de acordo com o contexto em que elas se encontravam. Seguindo a sequência da esquerda para a direita, as três primeiras imagens foram rotuladas como taludes estáveis e as três restantes como taludes instáveis. Isto foi feito para que a rede fosse capaz de identificar diferentes tipos de instabilidade, sendo estas superficiais ou não.

Figura 10 – Mosaico representando a variedade da base de dados utilizada.



Fonte: Elaboração própria


Vale destacar que as imagens utilizadas nesta base de dados, antes de serem selecionadas, tiveram os seus contextos analisados de maneira individual para que elas pudessem ser rotuladas como estáveis, ou não, antes de serem submetidas ao processamento e análise da rede neural desenvolvida. Em caso de não tratamento das imagens apresentadas a esta CNN, imagens com presença de grande quantidade de sombras podem induzir a rede ao erro, visto que em alguns casos estas sombras se assemelham bastante com buracos e/ou erosões superficiais.

### 3.4 Estrutura da CNN Desenvolvida

A Figura 11 detalha a estrutura da rede neural utilizada neste trabalho, que foi escolhida após a realização de diversos testes dentre as arquiteturas propostas pelas soluções de CNN mais atuais (Tabela 1). A proposta é de uma CNN customizada com 3 camadas convolucionais, sendo que as duas primeiras possuem 32 filtros de tamanho 3 (altura e largura), cada uma delas tendo sua saída submetida a uma camada de max-pooling 2x2. Quanto à saída da terceira e última camada convolucional, nota-se a adição da camada *flatten* à de max-pooling (que esteve presente após as duas primeiras camadas convolucionais). Essa camada achatada é responsável por remodelar uma saída de 4 dimensões em 2D, para que as camadas totalmente conectadas possam utilizar seus neurônios juntamente da função ReLU

para extrair informações úteis para o aprendizado da rede.

Figura 11 – Estrutura da CNN que obteve a melhor performance.



Fonte: Elaboração Própria.

Para esta aplicação, não seria interessante que a classe vencedora fosse definida pelo maior valor numérico, então a saída da segunda camada totalmente conectada é submetida à função SoftMax para estimar a probabilidade que cada entrada (imagem analisada) tem de pertencer a uma das duas possíveis classes de saída: Estável e Instável no intervalo entre 0 e 1.

### 3.5 Análise de Performance

Para avaliar a performance da CNN proposta foram utilizados os valores de verdadeiro positivo (TP), verdadeiro negativo (TN), falso negativo (FN) e falso positivo (FP) para realizar o cálculo de sensibilidade, especificidade, precisão, acurácia e f1-score, de acordo com as Equações (1) a (5). Quanto as siglas presentes em cada equação têm-se que: TP é o número de casos positivos que foram classificados como positivos, TN é o número de casos negativos classificados como negativos, FP representa os casos negativos classificados como positivos e FN são os casos positivos classificados como negativos.

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{Especificidade} = \frac{TN}{TN + FP} \quad (2)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3)$$

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$\text{F1 - Score} = \frac{2 * \text{Precisão} * \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (5)$$

Utilizou-se o método de validação cruzada para confirmar os valores de precisão, sensibilidade, especificidade e acurácia, dado que este método fornece à cada amostra a oportunidade de ser uma amostra de teste. O conjunto de dados de validação difere do conjunto de teste porque é utilizado para fornecer uma estimativa imparcial da capacidade do modelo final enquanto ajusta os hiperparâmetros para uma melhor performance. A avaliação torna-se mais tendenciosa à medida que o modelo final é testado, logo, este conjunto de dados é incorporado ao modelo para que se “valide” que a rede neural não memorizou seus dados de treinamento e, portanto, aprendeu aspectos significativos dos dados analisados (BROWNLEE, 2017).

### **3.6 Considerações Finais**

Foi apresentada, neste capítulo, a metodologia utilizada neste trabalho para atingir os objetivos destacados na Introdução. A base de dados desenvolvida permitiu que se atingisse, utilizando o fluxograma apresentado na Figura 7, a melhor estrutura de CNN possível para o problema descrito. O capítulo seguinte utilizará os métodos de validação cruzada para analisar os resultados obtidos por esta proposta, assim como irá apresentar as respostas da rede para uma imagem em específico.

## **4 RESULTADOS OBTIDOS**

No capítulo anterior foi explicado o fluxograma da rede neural desenvolvida com a finalidade de detectar erosão em taludes, logo, este capítulo apresentará as características do ambiente de desenvolvimento, os principais hiperparâmetros utilizados e as suas variações testadas, os resultados obtidos para diferentes arquiteturas de CNN, os filtros e mapas de características gerados pela rede.

Após diversos testes contemplando diferentes estruturas de CNN (Tabela 1), foram coletadas as métricas de validação tidas como suficientes para comprovar a performance muito satisfatória do modelo proposto. A rede que obteve o melhor desempenho foi comparada com diversas arquiteturas e combinações de hiperparâmetros amplamente utilizados por outros autores para certificar-se de que se atingiu o melhor resultado possível para esta aplicação em específico. As vantagens de se utilizar esta CNN para detecção de danos e erosões em taludes e a matriz de confusão gerada encerram este capítulo.

## 4.1 Ambiente Operacional

O ambiente no qual esta aplicação foi desenvolvida é composto por:

- *Hardware*: Windows 10 Home x64, 8GB RAM and Intel i7-8750H (2.21GHz).
- Linguagem de programação: Python 3.4.12.
- Plataforma Web de computação interativa baseada: Project Jupyter.
- Principais bibliotecas utilizadas: TensorFlow 2.8.0, Pandas 1.4.1, NumPy 1.22.3, Matplotlib 3.5.1 e Scikit-learn 1.0.2.

## 4.2 Resultados da CNN Proposta

No ambiente descrito anteriormente foram testadas diversas combinações entre diferentes arquiteturas e hiperparâmetros. Observando a Tabela 1, pode-se notar que a arquitetura mais acima, proposta por este trabalho, apresentou a melhor performance. Vale destacar também que cada uma das combinações de arquiteturas e hiperparâmetros foi treinada pelo menos quatro vezes, optou-se por esta quantidade de treinos para cada arquitetura visando minimizar a influência do fator aleatório de geração dos pesos no resultado e não prolongar muito o tempo reservado para definição da arquitetura proposta.

Tabela 2 – Comparação entre as diferentes arquiteturas testadas.

<i>Arquitetura</i>	<i>Taxa de Aprendizado</i>	<i>Funções de Ativação e Otimizador</i>	<i>Neurônios em cada camada FC</i>	<i>Performance do conjunto de validação</i>	<i>Performance do conjunto de teste</i>
3 camadas convolucionais e uma camada de max-pooling após cada uma delas + 2 camadas totalmente conectadas	1e-4	ReLU, Adam, MaxPooling e Softmax	128	86,3%	29/30
4 camadas convolucionais e uma camada de max-pooling após cada uma delas + 1 camada totalmente conectada	1e-4	ReLU, Adam e MaxPooling, Softmax	128	84,31%	25/30
3 camadas convolucionais e uma camada de max-pooling após cada uma delas + 2 camadas totalmente conectadas	3e-4	ReLU, Adam, Pooling, Softmax	128	82,35%	25/30
3 camadas convolucionais e uma camada de average pooling após cada uma delas + 2 camadas totalmente conectadas	0,001	ReLU, Adam, Pooling, Softmax	128	80,39%	24/30
2 camadas convolucionais e uma camada de average pooling após cada uma delas + 1 camada totalmente conectadas	0,01	LeakReLU, Adam MaxPooling, Softmax	64	70,58%	18/30

2 camadas convolucionais e uma camada de max-pooling após cada uma delas + 1 camada totalmente conectadas	0,001	Tanh, Adam, Pooling, Softmax	64	66,66%	18/30
---	-------	------------------------------	----	--------	-------


Fonte: Elaboração Própria.

Optou-se por definir o *batch size* em 6 em todos os testes realizados para que as amostras da base de dados fossem divididas de maneira igualitária, e também com o objetivo de diminuir o custo computacional da fase de treino. A utilização de 128 neurônios durante o treinamento e teste da rede é preferível devido ao número de pixels das entradas após ela ser fragmentada em diferentes seções de 128x128 pixels, sendo essa escolha justificada pelo melhor desempenho da rede quando comparada à mesma arquitetura utilizando 64 neurônios.

Vale frisar que os testes que constam na Tabela 1 utilizaram 96 épocas/7000 iterações juntamente do otimizador Adam, dada a sua ótima performance em cenários semelhantes ao proposto neste trabalho. Como esperado, a performance da CNN para os conjuntos de teste e validação são semelhantes na maioria dos casos, embora ambos os conjuntos de dados tenham tido as suas entradas separadas aleatoriamente do total de 300 imagens da base de dados.

Figura 12 – Imagem original e seu estado após análise da rede neural e *reshade*.






Fonte: (AROH, 2020).

Para facilitar a compreensão dos pesos e das saídas das camadas de convolução, que serão ilustradas nas próximas imagens, necessita-se das entradas que foram apresentadas para a rede. Logo, a Figura 12, assim como as demais entradas da rede, é dividida em diferentes subseções 128x128 e tem cada seção analisada separadamente. Após a geração dos mapas de características respectivos a ela, sofre o processo de *reshade* para que as suas seções realmente relevantes para a tomada de decisão sejam representadas em escalas de cinza. Após a sua interpretação da Figura 12, a rede retornou as Figuras 13 e 14 como representação dos pesos e do mapa de características gerados após a primeira camada de convolução.

Ao examinar a Figura 13, encontrada a seguir, nota-se que a primeira camada convolucional traça as seções mais relevantes de acordo com o impacto de cada uma delas no processo de mapeamento de acordo com os 32 filtros utilizados. As áreas representadas por vermelho significam que as respectivas seções de cada mapa de características (gerados a partir da Figura 12) contribuem positivamente para a interpretação da imagem, já as áreas negativas, representadas pela cor azul, possuem

baixo nível de relevância para a resposta final da rede.

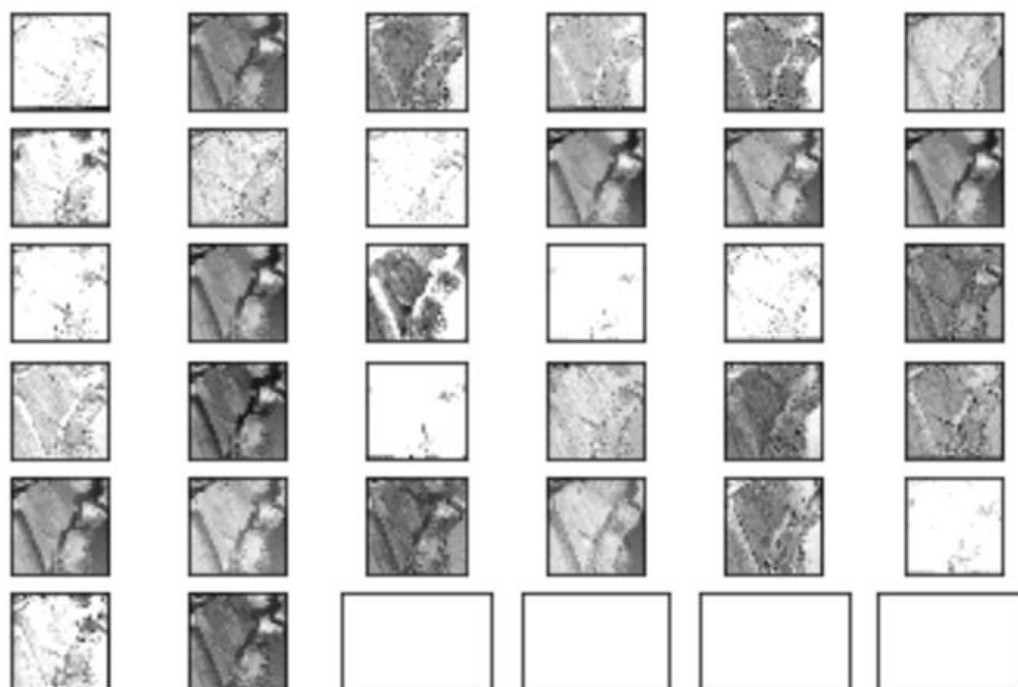
Figura 13 – Figura 12 após aplicação dos filtros da primeira camada de convolução.



Fonte: Elaboração Própria.

Como mencionado na Seção 3.4, a primeira camada de convolução conta com a aplicação de 32 filtros 3x3 para gerar 32 mapas de características, ou matrizes de neurônios, distintos. A análise dos mapas gerados após as operações de convolução permite compreender quais *features* da entrada a CNN dá mais importância, ou detecta melhor. Lembrando que as seções da imagem que possuem maior relevância destacam-se com o sombreamento (no caso da Figura 14, as discontinuidades no solo).


Figura 14 – Mapa de características da Figura 12 gerados pela primeira camada de convolução.



Fonte: Elaboração Própria.


Para a terceira e última camada convolucional da arquitetura de CNN proposta, a rede utiliza os 64 filtros 3x3 definidos para a terceira camada, objetivando o mapeamento mais abrangente da entrada analisada. Ao comparar os filtros e mapas de características gerados pela rede na terceira camada de convolução (Figuras 15 e 16), pode-se afirmar que a rede foi capaz de identificar de maneira precisa as discontinuidades presente na Figura 12. Este mapeamento mais preciso se dá pelo fato da entrada já ter sido submetida aos ajustes de todas as operações de convolução e *pooling* anteriores. Distinguindo melhor os limites da encosta e as instabilidades presentes através dos efeitos de sombreamento.

Figura 15 – Figura 12 após aplicação dos filtros da última camada de convolução.



Fonte: Elaboração Própria.

Figura 16 – Mapa de características da Figura 12 gerados pela última camada de convolução.




Fonte: Elaboração Própria.

Mantendo os parâmetros apresentados no início desta seção, a Figura 17 representa, por meio da matriz de confusão, a capacidade da rede de identificar

corretamente 32 imagens de instabilidade (classe positiva) das 34 que foram apresentadas para ela, e 12 dos 17 exemplos de estruturas de talude estáveis (classe negativa). Quanto ao conjunto de dados de teste, 29 das 30 imagens foram classificadas com precisão, sendo um terço delas representações de taludes estáveis e o restante foram divididas aleatoriamente entre ocorrências de erosão e deslizamento de terra.

Figura 17 – Matriz de confusão da melhor performance obtida.



Fonte: Elaboração Própria.

Os resultados satisfatórios do modelo em questão também podem ser observados nas métricas de validação derivadas da matriz de confusão ilustrada na Figura 17, estas são: acurácia de 96,67% durante a etapa de teste e 86,27% para a base de dados de validação, uma precisão de 94,11%, f1-score de 90,13%, uma sensibilidade de 86,48% e 85,71% para a métrica de especificidade.

Para finalizar este capítulo, vale destacar que os impactos da utilização da rede neural proposta vão muito além da já chamativa diminuição considerável de possíveis acidentes e catástrofes ambientais e do aumento de segurança, também refletem em uma redução considerável de custos, maior saúde e integridade estrutural a médio e longo prazo e planejamento mais adequado das manutenções. Aprimorando os já existentes sistemas de monitoramento, se utilizados em conjunto, e muitas vezes descartando a necessidade de locomoção de mão de obra especializada para locais remotos. Nota-se que esta proposta pode ser utilizada em drones, satélites e qualquer outro tipo de sistema que trabalhe com imagens, aumentando sua precisão, objetividade e velocidade de processamento.

### **4.3 Considerações Finais**

Este capítulo justificou a preferência pela arquitetura escolhida nesta dissertação por meio da comparação com as demais opções. Também foram apresentados os filtros utilizados pela rede neural desenvolvida, os mapas de características gerados pelas diferentes camadas de convolução para o exemplo escolhido (Figura 12) e os valores de performance alcançados (utilizando medidores performance consolidados mundialmente). Nota-se que esta CNN apresentou resultado muito satisfatório, com elevada precisão e acurácia, o que prova que seu diagnóstico é suficiente e preciso para problemas de identificação de danos em taludes por meio de imagem.

## **5 CONCLUSÃO E TRABALHOS FUTUROS**

Este trabalho apresentou os resultados da aplicação de uma Rede Neural Convolutiva utilizada na análise e detecção de instabilidade em estruturas de talude, concluindo que múltiplas camadas convolucionais são recomendadas quando se trata de CNNs desenvolvidas para classificação de imagens. Quando mais de 3 camadas convolucionais foram utilizadas para este problema em específico, o desempenho da rede neural diminuiu ou não apresentou ganhos significativos. A combinação de uma taxa de aprendizado relativamente baixa com a técnica max pooling apresentou melhorias significativas, principalmente pelo fato de que as imagens apresentadas a rede neural são divididas em seções de 128x128 pixels.

Mesmo com certa carência de imagens que representem fielmente estruturas de taludes e possíveis instabilidades nelas, a CNN desenvolvida obteve resultados bastante satisfatórios, mostrando-se promissora para a análise de diferentes tipos de estruturas e aplicações da área de Monitoramento de Integridade Estrutural (SHM). Atingiu-se uma acurácia de 96,67% na etapa de teste e 86,27% para a base de dados de validação, com uma precisão de 94,11%, 86,48% de sensibilidade, uma especificidade de 85,71% e 90,13% de f1-score.

Para que este trabalho seja utilizado em conjunto com sistemas de monitoramento já existentes e em operação, necessita-se que se realize novos treinamentos e testes e que o sistema alimente esta rede neural com imagens já rotuladas. Assim ela poderá diagnosticá-las e destacar prováveis instabilidades presentes em sua estrutura de maneira rápida e eficiente.

## 5.1 Principais Contribuições desta Dissertação

No entendimento do autor, são consideradas como principais contribuições para deste trabalho as seguintes:

- Concepção e elaboração de uma metodologia para o desenvolvimento de uma CNN capaz de detectar danos aparentes em estruturas de taludes.
- Desenvolvimento de uma CNN de três camadas de convolução capaz de ser utilizada em diferentes problemas de classificação de imagens.
- Formulação de um banco de dados relativamente robusto, composto por imagens de estruturas de taludes obtidas após levantamento de relatórios públicos de obras do governo brasileiro, reportagens e trabalhos realizados por empresas privadas.
- Divulgação dos achados desta pesquisa por meio do artigo “Deep learning based slope erosion detection” publicado na revista *IAES International Journal of Artificial Intelligence (IJ-AI)*, volume 12, nº 3, de setembro de 2022.

## 5.2 Trabalhos Futuros e Possíveis Desdobramentos

Como trabalhos futuros, o objetivo principal é treinar esta mesma arquitetura de CNN com uma base de dados mais robusta e variada, ou seja, com mais de 2.000 imagens de taludes estáveis e instáveis, para verificar se seu desempenho continuaria satisfatório ou seriam necessárias alterações para que a rede pudesse se tornar mais precisa. Nota-se que este teste também necessitaria ser realizado para imagens obtidas em diferentes angulações (geradas por drones, celulares e demais dispositivos) assim como as imagens utilizadas nesta proposta.

Embora seja possível desenvolver uma aplicação CNN para analisar o processo de ruptura progressiva de taludes, seria necessário um extenso conjunto de dados com várias imagens de cada talude analisado em diferentes ângulos e instantes de tempo, para o cálculo correto do fator de segurança.

Outra sugestão de aprimoramento muito interessante seria a mescla desta CNN desenvolvida com uma Autoencoder, para que o software consiga prever e

simular os avanços de cada tipo de instabilidade em uma estrutura de talude ao longo do tempo, e não apenas detectar as já existentes.

### **5.3 Dificuldades Encontradas**

Dentre as principais dificuldades enfrentadas durante o desenvolvimento deste trabalho, destacam-se: Carência por maior variedade de imagens de taludes em perfeito estado ou com danos aparentes, obtenção de melhores resultados devido às limitações de hardware e dificuldade de locomoção para locais que possibilitassem a obtenção de maior quantidade de fotos de taludes para enriquecimento da base de dados.

As demais dificuldades se fizeram presentes durante o processo de teste e levantamento bibliográfico sobre o estado da arte das Redes Neurais Convolucionais e de propostas semelhantes, que utilizam a análise de imagens para detectar danos estruturais. Visto que, tratando-se de taludes, não foram encontradas similaridades entre este trabalho e as demais soluções disponíveis, o processo de teste para encontrar as tecnologias auxiliares mais adequadas foi mais árduo do que o esperado, dada a necessidade de teste entre diversas arquiteturas hiperparâmetros distintos.

Notou-se também grandes adversidades durante a escolha e formulação da base de dados utilizada, visto que necessita-se de diversos exemplos (distintos entre si) para que uma rede neural atinja precisão aceitável e suficiente afim ser capaz de analisar e interpretar diferentes estruturas de talude e diferenciá-las das paisagens em que se encontram. Tal contratempo se fez presente devido ao fato de as imagens de deslizamento/erosões ocorrerem com baixa frequência, visto que são consequências de catástrofes, ou provocadas por elas.

Por fim, não foi possível o teste e a integração desta Rede Neural com um VANT dada a limitação financeira durante a etapa de planejamento/desenvolvimento desta proposta. Esta interação seria de interesse extremo, pois possibilitaria a apresentação de uma solução de monitoramento completa e capaz de diagnosticar os danos aparentes em locais remotos e produzir imagens para alimentar as bases de dados de teste e treino e aprimorar seu desempenho de maneira constante.

A proposta de integração entre estes agentes, VANT e CNN, teria o veículo como coletor de dados e a rede como analista. Em um cenário ideal, as imagens seriam publicadas na nuvem utilizando protocolos de Internet das Coisas e a rede neural acessaria esses dados em tempo real, analisando e diagnosticando cada uma



das imagens em tempo hábil.

## REFERÊNCIAS BIBLIOGRÁFICAS

ABIODUN, O.; JANTAN, A.; OMOLARA, A.; DADA, K.; et al. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938. doi:10.1016/j.heliyon.2018.e00938.

AKBAR, M.; QIDWAI, A.; JAHANSHAH, M. (2018). An evaluation of image-based structural health monitoring using integrated unmanned aerial vehicle platform. *Structural Control and Health Monitoring*, e2276. doi:10.1002/stc.2276.

AKHTAR, N.; RAGAVENDRAN, U. (2020). Interpretation of intelligence in CNN-pooling processes: a methodological survey. *Neural Comput & Applic* 32, 879–898. <https://doi.org/10.1007/s00521-019-04296-5>.

ALBAWI, S.; MOHAMMED, T.; AL-ZAWI, S. Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET), 2017, pp. 1-6, doi: 10.1109/ICEngTechnol.2017.8308186.

ALVES, G. (2018). Entendendo Redes Convolucionais (CNNs). *Neuronio BR*. Disponível em: <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>. Acesso em 14 Ago 2022.

ALZUBAIDI, L.; ZHANG, J.; HUMAIDI, A. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 8, 53 (2021). <https://doi.org/10.1186/s40537-021-00444-8>.

AROH, C. Civil Defense, Community Struggle to Rescue Anambra Road from Erosion. *The Whistler*, Ogbaru, May 12, 2020. Disponível em: <https://thewhistler.ng/civil-defence-community-struggle-to-rescue-anambra-road-from-erosion/>. Acesso em 02 jun. 2022.

ASADI, B.; JIANG, H. On Approximation Capabilities of ReLU Activation and Softmax Output Layer in Neural Networks. *arXiv*, 2020. Disponível em: <https://arxiv.org/abs/2002.04060/>. Acesso em 04 abril 2023.

ASTERIS, P.; MOKOS, V. (2019). Concrete compressive strength using artificial neural networks. *Neural Computing and Applications*. doi:10.1007/s00521-019-04663-2.

BADEMIAN, G.; FRANÇA, C. (2021). Classification of traffic signs with neural networks (in portuguese: Classificação de placas de trânsito com redes neurais). Departamento de Engenharia Elétrica da Universidade

Federal de São Carlos, Pp. 1-7. Disponível em: [https://repositorio.ufscar.br/bitstream/handle/ufscar/15692/Monografia\\_Final\\_Gustavo\\_Bulka\\_B\\_Bademian\\_744593.pdf?sequence=1&isAllowed=y](https://repositorio.ufscar.br/bitstream/handle/ufscar/15692/Monografia_Final_Gustavo_Bulka_B_Bademian_744593.pdf?sequence=1&isAllowed=y). Acesso em 03 maio 2022.

BAO, Y.; CHEN, Z.; WEI, S.; XU, Y.; et al. The State of the Art of Data Science and Engineering in Structural Health Monitoring. *Engineering*, vol. 5, no 2, April 2019. doi:10.1016/j.eng.2018.11.027.

BASHA, S.; DUBEY, S.; PULABAIGARI, V.; et al. Impact of fully connected layers on performance of convolutional neural networks for image classification, *Neurocomputing*, Volume 378, 2020, Pages 112-119, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2019.10.008>.

BOCK, S.; GOPPOLD, J.; WEIß, M. (2018). An improvement of the convergence proof of the ADAM-Optimizer. *Oth Clusterkonferenz*, doi: <https://doi.org/10.48550/arXiv.1804.10587>.

BORRELLI, P.; ALEWELL, C.; ALVAREZ, P.; ANACHE, J.; et al (2021). Soil erosion modelling: A global review and statistical analysis. *Science of The Total Environment*, vol. 780, 2021,146494, ISSN 0048-9697, <https://doi.org/10.1016/j.scitotenv.2021.146494>.

BROWNLEE, J. (2017). What is the Difference Between Test and Validation Datasets?. Disponível em: <https://machinelearningmastery.com/difference-test-validation-datasets/>. Acesso em 11 maio 2022.

CALLE, J. Análise de ruptura de talude em solo não saturado. Dissertação (Mestrado). Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos. 2000.

CHANG, W.; YOU, T.; SEO, S; et al. Domain-Specific Batch Normalization for Unsupervised Domain Adaptation. *Computer Vision Lab, Seoul National University, Korea*, p. 1-9. 2019. Available at: <https://arxiv.org/pdf/1906.03950.pdf>.

DAS (DATA SCIENCE ACADEMY). Capítulo 65 - Distribuições de Probabilidade, Redes Neurais e Reinforcement Learning 2022. Disponível em: <https://www.deeplearningbook.com.br/distribuicoes-de-probabilidade-redes-neurais-e-reinforcement-learning>. Acesso em 10 jan. 2022.

EL NAGA, I.; MURPHY, M. (2015). What Is Machine Learning? *Machine Learning in Radiation Oncology*, 3–11. doi:10.1007/978-3-319-18305-3\_1.

ESTEVA, A.; ROBICQUET, A.; RAMSUNDAR, B.; KULESHOV, V.; et al. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24–29. doi:10.1038/s41591-018-0316-z.

FLAH, M.; NUNEZ, I.; CHAABENE, B.; NEHDI, M. (2020). Machine Learning Algorithms in Civil Structural Health Monitoring: A Systematic Review. *Archives of Computational Methods in Engineering*. doi:10.1007/s11831-020-09471-9.

GAO, Y.; MOSALAM, K. Deep learning visual interpretation of structural damage images. *Journal of Building Engineering*, vol. 60, 2022, 105144, ISSN 2352-7102, <https://doi.org/10.1016/j.job.2022.105144>.

GARBIN, C.; ZHU, X; MARQUES, O. (2020). Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimed Tools Appl* 79, 12777–12815. <https://doi.org/10.1007/s11042-019-08453-9>.

GERSCOVICH, D. (2016). *Estabilidade de Taludes*. São Paulo: Editora Oficina de Textos; 2ª edição. 2016.

GIRSHICK, R. Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2015, pp. 1440-1448. Disponível em: [https://www.cv-foundation.org/openaccess/content\\_iccv\\_2015/papers/Girshick\\_Fast\\_R-CNN\\_ICCV\\_2015\\_paper.pdf](https://www.cv-foundation.org/openaccess/content_iccv_2015/papers/Girshick_Fast_R-CNN_ICCV_2015_paper.pdf). Acesso em 05 maio 2022.

GRAHAM, B. Fractional Max-Pooling. Dept of Statistics, University of Warwick, p. 1 – 10, 2015. Available at: <https://arxiv.org/pdf/1412.6071.pdf>.

HE, T.; ZHANG, Z.; ZHANG H.; et al. “Bag of Tricks for Image Classification with Convolutional Neural Networks”. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 558-567.

HUANG, Y. (2009). *Advances in Artificial Neural Networks – Methodological Development and Application*. *Algorithms*, 2(3), 973–1007. doi:10.3390/alg02030973.

IBAMA. Rompimento da Barragem de Fundão: Documentos relacionados ao desastre da Samarco em Mariana/MG. 13 de agosto de 2020. Disponível em: <http://www.ibama.gov.br/informes/rompimento-da-barragem-de-fundao>. Acesso em 19 de fevereiro de 2023.

KATTENBORN, T. et al. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing Elsevier BV*, mar. 2021. Disponível em: <http://dx.doi.org/10.1016/j.isprsjprs.2020.12.010/>. Acesso em 20 abril 2022.

KINGMA, D.; BA, J. Adam: A Method for stochastic Optimization. San Diego: *The International Conference on Learning Representations (ICLR)*, 2015.

LIEß, M.; GLASER, B.; HUWE, B. “Functional soil-landscape modelling to estimate slope stability in a steep Andean Mountain Forest region”, *Geomorphology*, vol. 132, no. 3, pp. 287–299, 2011. doi:10.1016/j.geomorph.2011.05.015.

LINDSAY, G. (2020). Convolutional Neural Networks as a Model of the Visual System: Past, Present, and Future. *Journal of Cognitive Neuroscience*. 33. 1-15. [10.1162/jocn\\_a\\_01544](https://doi.org/10.1162/jocn_a_01544). [https://doi.org/10.1162/jocn\\_a\\_01544](https://doi.org/10.1162/jocn_a_01544).

LIU, K.; KANG, G.; ZHANG, N.; HOU, B. (2018). Breast Cancer

Classification Based on Fully-Connected Layer First Convolutional Neural Networks. *IEEE Access*, 6, 23722–23732. doi:10.1109/access.2018.2817593.

LIU, S.; et al. Slope stability analysis using elastic finite element stress fields. *Engineering Geology* Elsevier BV, ago. 2020. Disponível em: <http://dx.doi.org/10.1016/j.enggeo.2020.105673>. Acesso em 20 abril 2022.

LÖBMANN, M.; GEITNER, C.; WELLSTEIN, C.; et al. (2020). The influence of herbaceous vegetation on slope stability – A review. *Earth-Science Reviews*, vol. 209, 103328. <https://doi.org/10.1016/j.earscirev.2020.103328>.

LU, J.; TAN, L.; JIANG, H. Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification. *Agriculture* MDPI AG, 27 jul. 2021. Disponível em: <http://dx.doi.org/10.3390/agriculture11080707>. Acesso em 20 abril 2022.

MAHESH, B. (2019). Machine Learning Algorithms -A Review. 10.21275/ART20203995. Disponível em: [https://www.researchgate.net/publication/344717762\\_Machine\\_Learning\\_Algorithms\\_-\\_A\\_Review/citation/download](https://www.researchgate.net/publication/344717762_Machine_Learning_Algorithms_-_A_Review/citation/download). Acesso em 10 jan. 2022.

MARINHO, E. (2018). Estabilidade de Taludes. UNORP-Centro Universitário do Norte Paulista. Disponível em: <https://slideplayer.com.br/slide/13350148/>. Acesso em: 25, abril 2022.

MEHTA, S.; PAUNWALA, C.; VAIDYA, B. (2019). CNN based Traffic Sign Classification using Adam Optimizer. 2019 International Conference on Intelligent Computing and Control Systems (ICCS). doi:10.1109/iccs45141.2019.9065537.

MISHRA, M.; GUNTURI, V.; MIRANDA, T. (2019). Slope stability analysis using recent metaheuristic techniques: a comprehensive survey. *SN Appl. Sci.* 1, 1674. <https://doi.org/10.1007/s42452-019-1707-6>.

MOAYEDI, H.; OSOULI, A.; NGUYEN, H.; Nguyen H, et al. A novel Harris hawks' optimization and k-fold cross-validation predicting slope stability. *Engineering with Computers* 37, 369–379 (2021). <https://doi.org/10.1007/s00366-019-00828-8>.

MURRAY, N.; PERRONNIN, F. Generalized Max Pooling. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2014, pp. 2473-2480.

NAVEEN (2022). What is ReLU and Sigmoid activation function?. Disponível em: <https://www.nomidl.com/deep-learning/what-is-relu-and-sigmoid-activation-function/>. Acesso em 11 maio 2022.

PIRAMIDE (2018). O que é talude e qual sua importância em obras de construção civil?. Disponível em: <https://piramidesc.com.br/manutencao/o-que-e-talude-e-qual-sua-importancia-em-obras-de-construcao-civil/>. Acesso em 25 abril 2022.

POESEN, J. Soil erosion in the Anthropocene: research needs. *Earth Surf. Process.*

Landforms 84, 64–84 (2018). <https://doi.org/10.1002/esp.4250>.

POUYANFAR, S.; SAAD, S.; YILIN, Y.; HAIMAN, T.; et al. (2018). A Survey on Deep Learning: Algorithms, Techniques, and Applications. *ACM Computing Surveys*. Vol. 51, 5, Article 92 (September 2019), 36 pages. <https://doi.org/10.1145/3234150>.

QI, C.; TANG, X. Slope stability prediction using integrated metaheuristic and machine learning approaches: A comparative study. *Computers & Industrial Engineering* Elsevier BV, abr. 2018. Disponível em: <http://dx.doi.org/10.1016/j.cie.2018.02.028/>. Acesso em 20 abril 2022.

RIBAS, G.; SILVA, J.; FIGUEIREDO, L.; FILSEN, T.; et al. Técnicas e fluxo de trabalho para monitoramento de movimentação em taludes utilizando imagens de drone. 17º Congresso Brasileiro de Geologia de Engenharia e Ambiental. 2022. Belo Horizonte.

RIZZO, I.; CANATO, R. (2021). Artificial Intelligence: Activation Functions. *Colloquium Exactarum*. ISSN: 2674-8576, version 2, number 2, p. 51-65. Disponível em: <https://www.prospectus.fatecitapira.edu.br/index.php/pst/article/view/37/34>. Acesso em 03 maio 2022.

ROSENBLATT, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>.

RUIZ-ARMENTEROS, A.; MARCHAMALO-SACRSITÁN, M.; BAKOŇ, M.; LAMAS-FERNÁNDEZ, F.; et al. (2021). Monitoring of an embankment dam in southern Spain based on Sentinel-1 Time-series InSAR. *Procedia Computer Science*, 181, 353–359. doi:10.1016/j.procs.2021.01.178.

SONY, S.; LAVENTURE, S.; SADHU, A. A literature review of next-generation smart sensing technology in structural health monitoring. *Structural Control and Health Monitoring*, vol 26, no 3, 2019. doi:10.1002/stc.2321

SUTTON, R.; BARTO, A.; Introdução. In: SUTTON; BARTO. *Reinforcement Learning: An Introduction*. 2nd Edition. MIT Press, Cambridge, MA, 2018, 1–13.

SZEGEDY, C.; LIU, W.; JIA, Y.; et al. (2015). "Going deeper with convolutions," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1-9, doi: 10.1109/CVPR.2015.7298594.

TIAN, C.; FEI, L.; ZHENG, W.; XU, Y.; et al. (2020). Deep learning on image denoising: An overview. *Neural Networks*. doi:10.1016/j.neunet.2020.07.025.

VERNE, T.; SILVA, F.; ALMEIDA, L.; et al. (2022). Detecção e reconhecimento de plantas de pequeno porte utilizando aprendizagem de máquina. *Colloquium Exactarum*. ISSN: 2178-8332, 14(1), 36–45. Available at: <https://revistas.unoeste.br/index.php/ce/article/view/4099>.

WALTERS, A. (2019). Convolutional Neural Networks (CNN) to Classify Sentences. Disponível em: <https://austingwalters.com/convolutional-neural-networks-cnn-to-classify-sentences/>. Acesso em 04 abril 2023.

WANG, Y.; HUANG, J.; WANG, Y.; FENG, S.; et al. (2020). A CNN-Based Adaptive Surface Monitoring System for Fused Deposition Modeling. in IEEE/ASME Transactions on Mechatronics, vol. 25, no. 5, pp. 2287-2296, Oct. 2020, doi: 10.1109/TMECH.2020.2996223.

YADAV, S.; JADHAV, M. Deep convolutional neural network based medical image classification for disease diagnosis. Journal of Big DataSpringer Science and Business Media LLC, dez. 2019. Disponível em: <http://dx.doi.org/10.1186/s40537-019-0276-2/>. Acesso em 20 abril 2022.

YANG, X.; et al. Deep learning-based bolt loosening detection for wind turbine towers. Structural Control and Health MonitoringHindawi Limited, 18 fev. 2022. Disponível em: <http://dx.doi.org/10.1002/stc.2943/>. Acesso em 20 abril 2022.

ZHENG, Y.; IWANA, B.; UCHIDA, S. (2019). Mining the Displacement of Max-pooling for Text Recognition. Pattern Recognition. doi:10.1016/j.patcog.2019.05.014.

ZIJUN, Z. (2018). "Improved Adam Optimizer for Deep Neural Networks," 2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS), 2018, pp. 1-2, doi: 10.1109/IWQoS.2018.8624183.

ZOU, J.; HAN, Y.; SO, S.-S. (2008). Overview of Artificial Neural Networks. Artificial Neural Networks, 14–22. doi:10.1007/978-1-60327-101-1\_2.

ZUCATELLI, G.; PHILIPS, J. Fotogrametria aplicada ao monitoramento de loteamentos urbanos – estudo de caso. Revista Técnico-científica do CREA-PR, Paraná, edição especial, p. 1–14, junho, 2018.