

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

USO DE REDES NEURAIS CONVOLUCIONAIS COMO MÉTODO DE IDENTIFICAÇÃO DE ANOMALIAS EM BARRAGENS

Bruno Joakinson Böving¹; Daniel Detzel²

Abstract: This study investigates the feasibility of automating the identification of anomalies in earth dams using convolutional neural networks (CNNs). In light of the growing number of poorly documented dams under the National Dam Safety Policy in Brazil, the research aims to streamline safety inspections by reducing manual image analysis time through a CNN-based model. The methodology involves building a database with 400 images for each identified anomaly type and developing a customized CNN architecture, drawing on elements from LeNet-5, AlexNet, and VGG16. The results show that the proposed model can effectively identify most anomalies, although further adjustments are required to achieve full process automation. It is concluded that CNNs are a promising tool to support dam safety inspections, with significant potential to reduce the time required for assessing dam conditions.

Resumo: Este estudo investiga a viabilidade da automatização da identificação de anomalias em barragens de terra por meio do uso de redes neurais convolucionais (CNNs). Considerando o aumento expressivo do número de barragens com documentação incompleta no âmbito da Política Nacional de Segurança de Barragens (PNSB), a proposta visa otimizar o processo de inspeção, reduzindo o tempo necessário para a análise manual de registros fotográficos. A metodologia adotada contempla a construção de uma base de dados composta por 400 imagens para cada tipo de anomalia selecionada, bem como o desenvolvimento de uma arquitetura de CNN customizada, inspirada em elementos das redes LeNet-5, AlexNet e VGG16. Os resultados obtidos demonstram que o modelo é eficaz na identificação das principais manifestações patológicas, embora sejam recomendados ajustes adicionais para viabilizar a automatização integral do processo. Conclui-se que o uso de CNNs representa uma solução promissora para apoio às inspeções de segurança de barragens, com potencial significativo para a redução do tempo e do esforço técnico na triagem e caracterização de anomalias.

Palavras-Chave: Segurança de Barragens; Redes Neurais Convolucionais; Detecção de Anomalias

1) Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental, UFPR, brunoboving@gmail.com
2) Departamento de Hidráulica e Saneamento, UFPR, detzel@ufpr.br

INTRODUÇÃO

A segurança de barragens representa um componente essencial na gestão dos recursos hídricos e energéticos, afetando diretamente o abastecimento de água, a geração de energia elétrica e o controle de cheias. No Brasil, a Política Nacional de Segurança de Barragens (PNSB) estabelece diretrizes para o monitoramento, manutenção e documentação dessas estruturas, com o objetivo de preservar sua integridade e prevenir incidentes com potencial de grandes impactos sociais e ambientais.

Entre os instrumentos técnicos previstos pela PNSB, destacam-se os relatórios de inspeção de segurança, que devem incluir registros fotográficos sistemáticos de possíveis manifestações patológicas. No entanto, a triagem manual dessas imagens ainda é a prática predominante nos processos de elaboração dos relatórios técnicos. Essa abordagem demanda tempo considerável dos engenheiros responsáveis e está sujeita a falhas humanas.

Com o avanço das técnicas de inteligência artificial e visão computacional, torna-se possível explorar ferramentas que automatizem etapas desses processos. Neste contexto, o estudo avalia a viabilidade técnica e operacional da aplicação de redes neurais convolucionais no reconhecimento automático de anomalias visuais em barragens de terra, a partir de registros fotográficos coletados em campo. A proposta é que, por meio da aplicação dessas técnicas, seja possível acelerar o processo de triagem e classificação das imagens, com precisão controlada na identificação das patologias e contribuindo para um monitoramento mais eficiente das estruturas.

FUNDAMENTAÇÃO TEÓRICA

Barragens no Brasil

Segundo o texto da Lei 12.334 (2010), atualizada pela Lei 14.066 (2020), é denominada barragem “qualquer estrutura construída dentro ou fora de um curso permanente ou temporário de água, em talvegue ou em cava exaurida com dique, para fins de contenção ou acumulação de substâncias líquidas ou de misturas de líquidos e sólidos, compreendendo o barramento e as estruturas associadas;”.

Estas estruturas podem ser organizadas em diferentes grupos em função do seu material de construção. A Tabela 1 apresenta os valores percentuais e absolutos de barragens e seus materiais construtivos no Brasil. Cabe salientar que os valores absolutos são restritos às barragens que possuem informações sobre materiais construtivos, o que representa apenas 34,5% do total (ANA, 2022).

Tabela 1: Resumo das informações disponibilizadas pelo Sistema Nacional de Informações sobre Segurança de Barragens (SNISB), quanto ao material construtivo

Tipo de material	Quantidade absoluta	Quantidade relativa
Terra	6437	77,79%
Concreto	938	11,34%
Enrocamento	517	6,25%
Materiais menos convencionais	383	4,63%

Adaptado de: ANA (2022).

Gameleira e Amaral (2018), afirmam que as barragens de terra são as mais numerosas devido não apenas à disponibilidade da matéria prima, mas também devido à permissividade de uma fundação menos robusta, o que viabiliza a implementação destas obras.

Entre as principais estruturas que compõe uma barragem independente do material de construção entre eles estão: reservatório, ombreiras, barramento, fundação, sistema de drenagem, instrumentação, órgãos extravasores e tomada d'água.

Manifestações patológicas em barragens

Semelhante ao uso empregado na área da saúde, o termo patologia descreve o tipo de manifestação que afeta negativamente, tanto o desempenho esperado das estruturas civis, quanto a sua vida útil. Pode ser definida também como a ciência que busca compreender os malefícios provenientes do material empregado, método construtivo ou fatores externos, visando identificar suas origens, métodos de degradação e possíveis evoluções (Gonçalves, 2015).

O Volume II do Manual do Empreendedor, elaborado pela ANA (2016), apresenta entre suas considerações uma série de manifestações patológicas definidas como as mais frequentes observadas em barragens e suas estruturas associadas, considerando o seu tipo de material construtivo.

Aprendizado de máquina

O aprendizado de máquina (machine learning) é um subcampo da inteligência artificial (IA) que desenvolve algoritmos capazes de aprender padrões e tomar decisões com base em dados. Esses modelos tornam-se progressivamente mais precisos à medida que expostos a novos dados.

Entre os métodos mais comuns estão o aprendizado não supervisionado, envolvendo a análise de dados sem rótulos, onde o objetivo é descobrir padrões ocultos ou agrupamentos nos dados, e o aprendizado supervisionado, onde os algoritmos são treinados com dados rotulados, sendo fornecidas tanto a entrada quanto a saída desejada (Cerqueira, 2010).

A avaliação dos modelos de aprendizado de máquina é crucial para garantir que eles funcionem da maneira esperada e forneçam resultados precisos. Métodos comuns de avaliação incluem a divisão dos dados em conjuntos de treinamento e teste, validação cruzada e o uso de métricas de desempenho, como precisão, recall, F1-score (James et al., 2013).

O aprendizado profundo é uma subcategoria do aprendizado de máquina que utiliza redes neurais artificiais profundas para modelar padrões complexos em grandes conjuntos de dados. Essa abordagem foi responsável por revolucionar alguns campos, como visão computacional, descrita no item a seguir.

Visão computacional

Para dos Santos (2017), a visão computacional compreende a obtenção de dados a partir de um método de emulação da visão humana. Dentro da visão computacional o reconhecimento de imagem é apenas uma das áreas responsáveis pela análise dos pixels e padrões que são utilizados na identificação de objetos, expressões faciais, caracteres, entre outros.

As redes neurais convolucionais (CNNs) são um tipo de método de aprendizado de máquina, inspirado no funcionamento do cérebro humano para realizar tarefas complexas. Esse algoritmo tem demonstrado alto desempenho em tarefas de visão computacional, como detecção de objetos, segmentação e reconhecimento de imagens, como demonstrado por Pereira (2023).

O funcionamento dessas redes neurais baseia-se em um sistema de camadas que aplicam convoluções aos dados de entrada, utilizando uma série de filtros aprendidos, o que aumenta a robustez do algoritmo.

METODOLOGIA

O desenvolvimento da pesquisa estruturou-se em dois eixos complementares: a concepção de um modelo computacional baseado em redes neurais convolucionais para detecção de anomalias em imagens de barragens, e a construção de um banco de dados especializado para seu treinamento e validação. O modelo computacional foi desenvolvido em linguagem Python.

Desenvolvimento do Modelo

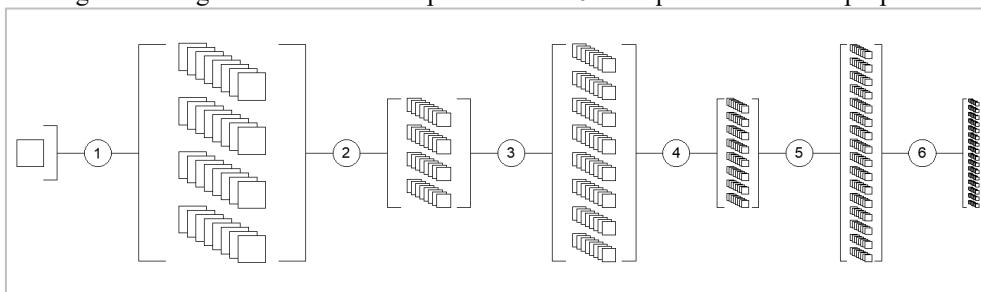
A etapa inicial do script é composta pela importação de bibliotecas, selecionadas de modo a suprir as necessidades da construção do modelo, entre elas: *PyTorch*; *torchvision*; *Matplotlib*; *NumPy*; e *Scikit-learn*.

A arquitetura da CNN desenvolvida neste estudo foi concebida para equilibrar a eficiência computacional com alta acurácia diagnóstica na identificação de anomalias visuais em estruturas de barragens. O modelo adotado é fruto da combinação de elementos estruturais consagrados em três arquiteturas clássicas: *LeNet-5*, que serviu como inspiração principal na definição da estrutura sequencial de camadas convolucionais seguidas por camadas de *pooling*; *AlexNet*, que influenciou a ampliação da profundidade da rede, a inserção de múltiplas camadas convolucionais e a adoção de técnicas de regularização como o *dropout*; e *VGG16*, cuja contribuição se refletiu no uso de filtros convolucionais com pequenas dimensões (3×3), favorecendo a extração detalhada de padrões locais.

A Figura 1 e a Figura 2 apresentam o diagrama esquemático da arquitetura da CNN, estruturada em dez etapas. O processamento tem início com a entrada de uma imagem RGB, que passa sucessivamente por três camadas convolucionais (etapas 1, 3 e 5), com 32, 64 e 128 filtros respectivamente. Essas camadas são responsáveis pela extração de mapas de características, correspondentes a padrões relevantes na imagem, como texturas, bordas e contornos de trincas ou infiltrações. Em conjunto, são aplicadas camadas de normalização do *batch* (*batch normalization*), que estabilizam a distribuição das ativações ao longo do treinamento, acelerando o processo de convergência e conferindo maior robustez à rede.

Entre cada camada convolucional, nas etapas 2, 4 e 6, inserem-se camadas de *max pooling*, cuja função é reduzir pela metade a dimensionalidade espacial dos dados em cada eixo (altura e largura), ao selecionar o valor máximo de regiões específicas do mapa de características. Esse procedimento contribui para tornar a rede menos sensível a pequenas variações espaciais ou distorções nas imagens de entrada, além de reduzir a carga computacional.

Figura 1: Diagrama ilustrativo dos processos 1 a 6 da arquitetura de CNN proposta.

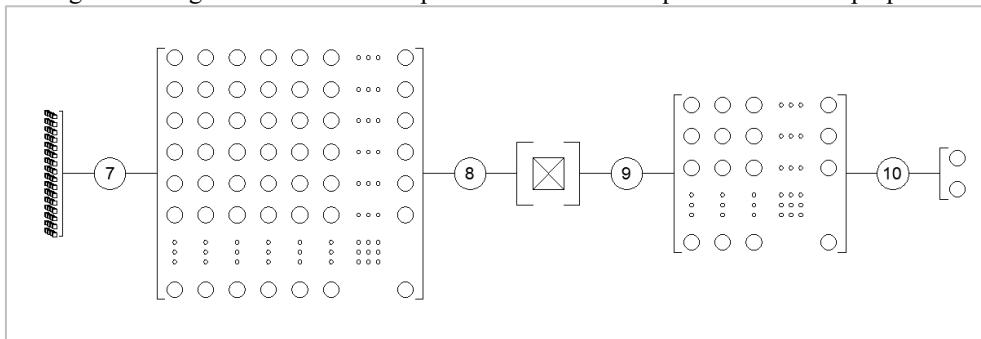


A fase de classificação é composta por três camadas totalmente conectadas (etapas 7, 9 e 10), também conhecidas como *fully connected layers*. Nessas camadas, cada neurônio é conectado a todas as ativações da camada anterior, permitindo a combinação de características extraídas anteriormente

e promovendo a tomada de decisão. A última camada *fully connected* possui o número de neurônios igual ao número de classes predefinidas no problema de classificação (por exemplo, “normal” e “anomalia”).

Para mitigar o risco de *overfitting* — fenômeno em que o modelo se ajusta excessivamente aos dados de treinamento e perde capacidade de generalização para novos dados — foi incluída a camada de *dropout* (etapa 8), que atua desativando aleatoriamente uma fração dos neurônios durante o treinamento, forçando a rede a desenvolver representações mais robustas e menos dependentes de caminhos específicos.

Figura 2: Diagrama ilustrativo dos processos 7 a 10 da arquitetura de CNN proposta.



Previamente à entrada dos dados na arquitetura da CNN apresentada, são aplicados alguns métodos de pré-processamento dos dados, que visam a melhoria do desempenho, generalização e robustez do modelo a partir da padronização das entradas e da utilização de ferramentas de *data augmentation*, tais como as funções: *resize*, responsável por padronizar a entrada de dados; *randomhorizontalflip*, randomizar o espelhamento da imagem; *randomrotation*, randomizar o ângulo da entrada dos dados; *totensor*, transformar o valor padrão dos pixels; e *normalize*, que normaliza o valor transformado dos pixels.

O fluxo de gerenciamento de dados foi estruturado utilizando o *pipeline* do *PyTorch*, com início no carregamento automatizado por meio da função *ImageFolder*, que atribui rótulos binários (*true/false*) com base na estrutura hierárquica dos diretórios. A seguir, realizou-se uma partição estratificada aleatória dos dados em 80% para treinamento e 20% para teste, assegurando representatividade proporcional de ambas as classes.

Para a otimização, adotou-se o algoritmo *Adam* (com *learning rate* = 0.001, β_1 = 0.9 e β_2 = 0.999), amplamente reconhecido por sua eficiência em espaços de parâmetros não convexos. A função de perda utilizada foi a *CrossEntropyLoss*, ajustada com pesos inversamente proporcionais à frequência das classes no conjunto de dados, estratégia fundamental para mitigar o viés causado pelo desbalanceamento entre classes.

Complementando o regime de treinamento, implementou-se decaimento dinâmico da taxa de aprendizado (*StepLR*), com redução de 90% a cada 10 épocas, além da técnica de *early stopping* com paciência de 10 épocas — medidas que visaram tanto a economia de recursos computacionais quanto a prevenção de *overfitting*.

A avaliação do desempenho do modelo foi conduzida a partir de um conjunto de métricas multidimensionais, entre elas: as curvas de perda de treinamento e validação; a matriz de confusão; métricas variadas de classificação (precisão, *recall* e *F1-score*); e a acurácia global como medida sintética de desempenho.

Construção do Banco de Dados

Considerando o formato de entrada e o método de carregamento previamente definidos no desenvolvimento do modelo, iniciou-se a construção do banco de dados de imagens, etapa essencial para a robustez e fidedignidade dos experimentos subsequentes. Foram utilizadas 1.600 imagens coletadas durante inspeções mensais de segurança realizadas ao longo de 2023 em cinco diferentes barragens de terra, contemplando distintos elementos estruturais

A definição das categorias de anomalias foi orientada tanto por sua recorrência nos registros técnicos quanto pelo impacto potencial sobre a estabilidade das estruturas (Figura 3). Entre as classes selecionadas estão: (A) formigueiros, cupinzeiros e tocas de animais, que compartilham características morfológicas semelhantes e podem comprometer a integridade geotécnica da barragem; (B) canaletas obstruídas ou danificadas, cuja falha de funcionamento pode comprometer o escoamento superficial e provocar erosões; (C) vegetação excessiva, fator que dificulta o monitoramento visual e pode indicar ausência de manutenção; e (D) falhas no revestimento superficial, geralmente associadas à exposição direta do maciço ao intemperismo.

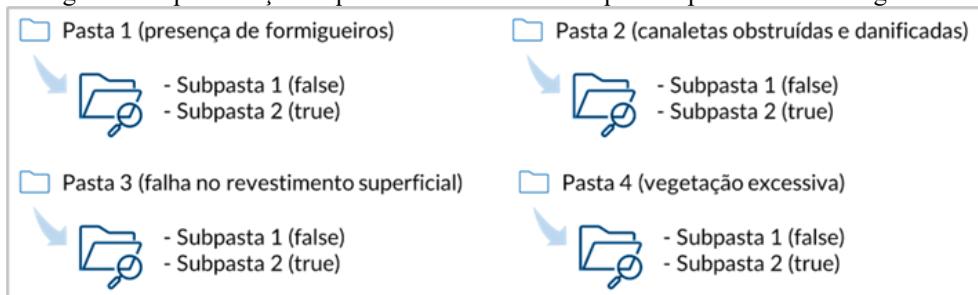
Figura 3: Exemplo de anomalias rotuladas como positivas em cada classe.



Para cada uma das quatro categorias, foram reunidas 400 imagens rotuladas, sendo 20% positivas, ou seja, com a anomalia em questão visível e claramente identificável, e 80% negativas, consistindo em registros diversos das estruturas onde a ocorrência não está presente. Essa distribuição, juntamente com técnicas de rebalanceamento no modelo, garantiram um conjunto balanceado para fins de treinamento e validação do modelo de classificação binária.

As imagens foram organizadas em diretórios estruturados hierarquicamente por classe e por rótulo, conforme ilustrado na Figura 4. Tal organização serve não apenas para o carregamento automatizado via módulo *ImageFolder* do *PyTorch*, como também para assegurar a escalabilidade do banco de dados, permitindo a futura incorporação de novas categorias de anomalias por simples replicação da lógica de armazenamento.

Figura 4: Representação esquemática dos diretórios que compõe o acervo fotográfico.



A curadoria técnica desempenhou papel central na qualidade do banco de dados. Foram removidas imagens que apresentavam iluminação visivelmente inadequada, desfocagem acentuada, ruído digital elevado ou resolução inferior a 1280×960 pixels. Também foram descartadas aquelas em que as anomalias estavam parcialmente ocluídas ou ocupavam uma fração muito reduzida do campo visual, comprometendo sua identificação.

Por outro lado, registros que, embora não ideais em termos de ângulo, luminosidade ou resolução, ainda se mostravam coerentes com situações operacionais reais foram intencionalmente mantidos. Tal escolha visou expor o modelo a condições próximas da realidade de campo, contribuindo para sua capacidade de generalização e robustez frente a variações de captura.

RESULTADOS E DISCUSSÕES

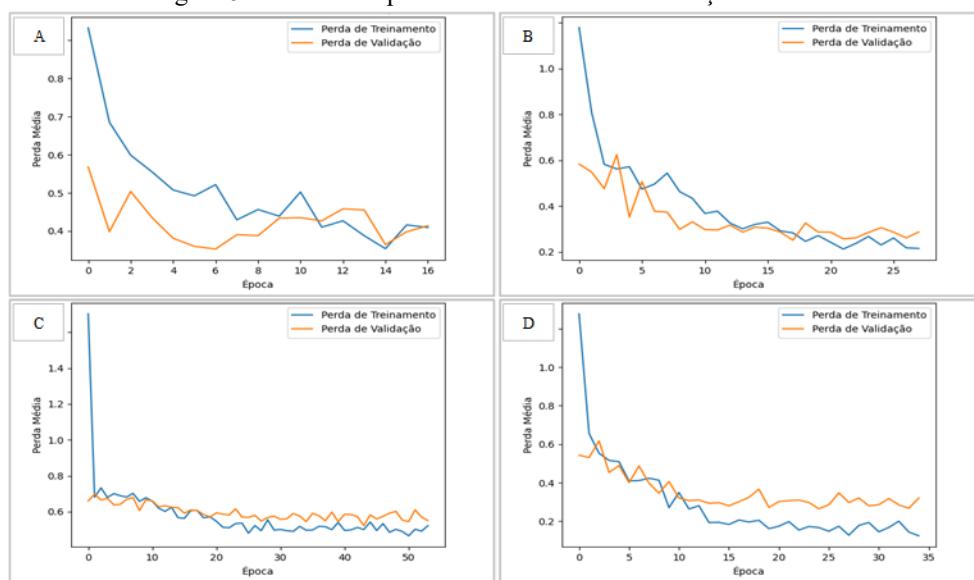
A análise comparativa dos quatro modelos de redes neurais convolucionais treinados para detecção de anomalias em barragens revelou padrões significativos quanto ao desempenho, estabilidade e aplicabilidade prática. A avaliação integrou múltiplas métricas, entre estas: curvas de perda; acurácia global; matrizes de confusão; e indicadores estatísticos (precisão, *recall*, *F1-score*).

Curvas de perda

Os gráficos de perda, representados na Figura 5, evidenciaram comportamentos distintos durante o treinamento e validação para cada uma das classes. Para a classe A, o modelo convergiu com o melhor resultado na 7^a época, iterações posteriores diminuíram a assertividade da validação em detrimento da melhora no treinamento. Já para a classe B, o modelo convergiu com o melhor resultado na 18^a época, iterações posteriores obtiveram resultados bastante próximos, mas ainda assim com eficiência inferior.

Quanto à classe C, o modelo convergiu com o melhor resultado na 44^a época, são observáveis indícios de *overfitting* a partir da 20^a época, onde o gráfico começa a apresentar fenômenos de espelhamento entre as curvas. Por fim, para a classe D, o modelo convergiu com o melhor resultado na 25^a época, iterações posteriores obtiveram resultados relativamente próximos, mas assim como a classe anterior observasse o fenômeno de *overfitting*.

Figura 5: Gráficos de perda no treinamento e validação da CNN.



Acurácia global

A acurácia agregada as classes foi relativamente alta, variando entre 78%, para vegetação excessiva, e 90%, para canaletas obstruídas. Entretanto, a métrica mostrou-se enganosa para avaliação contextual. Como um exemplo, o modelo para formigueiros alcançou 85% de acurácia global, mas revelou certas fragilidades quando analisado sob perspectivas complementares, apresentando taxas relativamente altas de falsos positivos em função da melhoria da acurácia. Essa limitação da acurácia como indicador único reforça a necessidade de métricas estratificadas para problemas com desbalanceamento amostral.

Matriz de confusão

Na Tabela 2 estão representados os resultados das matrizes de confusão para as quatro classes de anomalias treinadas, com a quantificação de verdadeiros positivos (VP), falsos positivos (FP), verdadeiros negativos (VN) e falsos negativos (FN). Não são realizadas análises diretamente sobre os valores de cada uma das validações dos modelos treinados, uma vez que esses dados são utilizados para gerar as métricas de análise do próximo subitem.

Tabela 2: Resumo dos resultados das matrizes de confusão para todas as classes estabelecidas

Modelo	VP	FP	VN	FN
Formigueiros	12	11	56	1
Canaletas quebradas e obstruídas	11	4	61	4
Vegetação excessiva	5	8	57	10
Falha no revestimento	10	7	61	2

Métricas complementares

A Tabela 3 apresenta os resultados das métricas de desempenho obtidas na etapa de validação do modelo, conforme os critérios definidos anteriormente. Observa-se que, em termos de precisão, métrica que quantifica a proporção de verdadeiros positivos entre todas as previsões positivas realizadas pelo modelo, a classe "canaletas quebradas ou obstruídas" obteve o melhor desempenho, indicando baixa taxa de falsos positivos.

Por outro lado, a métrica de *recall*, que avalia a capacidade do modelo em identificar corretamente os exemplos positivos presentes no conjunto de validação, ou seja, sensível à ocorrência de falsos negativos, apresentou sua melhor performance na classe "formigueiros", o que demonstra a maior abrangência do modelo na detecção dessa anomalia específica.

Por fim, o *F1-score*, que representa a média harmônica entre precisão e *recall*, fornecendo uma medida equilibrada entre esses dois aspectos, indicou desempenho superior para a classe "canaletas quebradas ou obstruídas", que demonstrou, portanto, maior consistência global ao longo do treinamento.

Tabela 3: Resumo das metricas complementáres de precisão, *recall* e *F1-score*

Modelo	Precisão	Recall	<i>F1-score</i>
Formigueiros	0,52	0,92	0,67
Canaletas quebradas e obstruídas	0,73	0,73	0,73
Vegetação excessiva	0,38	0,33	0,36
Falha no revestimento	0,59	0,83	0,69

CONSIDERAÇÕES FINAIS

Levando em consideração o objetivo central deste estudo, verificar a viabilidade de automatizar a identificação de anomalias recorrentes em barragens de terra, os resultados obtidos demonstraram que a proposta é viável e efetiva, mesmo diante das limitações metodológicas e instrumentais apresentadas.

Os dados provenientes das etapas de treinamento e validação corroboram a hipótese de que redes neurais convolucionais (CNNs) são capazes de identificar anomalias visuais relevantes em registros fotográficos de inspeções, representando um avanço promissor na modernização dos métodos de monitoramento de segurança de barragens.

Entre as classes analisadas, a que apresentou maior sensibilidade às limitações do estudo foi a referente à “vegetação excessiva”. Essa fragilidade pode ser atribuída à alta variabilidade morfológica da anomalia, decorrente da diversidade de espécies vegetais, padrões de crescimento e localização sobre a estrutura inspecionada, o que dificulta a generalização da rede a partir de um conjunto limitado de exemplos.

As perspectivas de aprimoramento do modelo envolvem tanto a ampliação e qualificação do banco de dados quanto ajustes na própria arquitetura da rede. No que se refere ao acervo fotográfico, recomenda-se: a ampliação do número total de imagens; a experimentação de diferentes proporções entre amostras positivas e negativas; e a adoção de critérios de rotulagem mais específicos e homogêneos. Já no escopo do modelo de CNN, apontam-se como estratégias promissoras: o uso de esquemas alternativos de ponderação por classe; a introdução de camadas adicionais de processamento; a substituição por arquiteturas mais recentes e robustas; e o aumento da resolução das imagens de entrada.

Apesar das limitações identificadas, os resultados gerais foram satisfatórios e sugerem que há elevado potencial para o aprofundamento e a aplicação prática dessa abordagem. A maior parte dos modelos testados demonstrou desempenho consistente e capacidade de generalização na identificação automática das anomalias para as quais foram treinados, o que reforça a viabilidade técnica da proposta.

REFERÊNCIAS

- ANA (2016). “*Manuais do Empreendedor: Volume II - Guia de Orientação e Formulários para Inspeções de Segurança de Barragem*”. Brasília, DF: Agência Nacional de Águas e Saneamento Básico.
- ANA (2022). “*Relatório de Segurança de Barragens*”. Brasília, DF: Agência Nacional de Águas e Saneamento Básico.
- CERQUEIRA, F. R. (2010). “*As redes neurais artificiais e o ensino da medicina. Revista Brasileira de Educação Médica*”. Brasília, DF: Revista Brasileira de Educação Médica.
- DOS SANTOS, M. R. (2017). “*Desenvolvimento de um sistema de visão computacional para fenotipagem de alta precisão*”. Passo Fundo, RS: Universidade de Passo Fundo.
- GAMELEIRA, E. L.; AMARAL, F. N. da S. (2018) “*Análise do fluxo de água no maciço de uma barragem de terra com filtro*”. Maceió, AL: Centro Universitário Cesmac.
- GONÇALVES, E. A. B. (2015). “*Estudo de patologias e suas causas nas estruturas de concreto armado de obras de edificações*”. Rio de Janeiro, RS: Universidade Federal do Rio de Janeiro.
- JAMES, G. et al. (2013). “*An Introduction to Statistical Learning: with Applications in R*”. Springer Texts in Statistics.
- Lei Nº 12.334 (2010). “*Política Nacional de Segurança de Barragens*”. Brasília, DF: Diário Oficial da União.
- Lei Nº 14.066 (2020). “*Política Nacional de Segurança de Barragens*”. Brasília, DF: Diário Oficial da União.
- PEREIRA, W. F. (2023). “*Identificação automatizada de manifestações patológicas por meio de segmentação semântica: fissuras, rachaduras, trincas e fendas*”. Balsas, MA: Universidade Federal do Maranhão.