

Detecção Automática de Manifestações Patológicas em Obras Geotécnicas Utilizando Visão Computacional

Leandro Silva de Assis
Doutorando, EP USP, São Paulo, Brasil, leandroassis@usp.br

Ana Carolina Fernandes de Souza
Iniciação Científica, GeoinfraUSP / EP USP, São Paulo, Brasil, anafsouza@usp.br

Bernardo Lopes Poncetti
Doutorando, GeoinfraUSP / EP USP, São Paulo, Brasil, bernardoponcetti@usp.br

Marcos Massao Futai
Prof. Coordenador, GeoinfraUSP / EP USP, São Paulo, Brasil, futai@usp.br

RESUMO: Os túneis são elementos de estruturas geotécnicas com comportamento complexo que fazem parte da logística de transportes e requer elevada atenção na inspeção e monitoramento de sua performance, haja visto que, um possível colapso nesse tipo de ativo causa severos prejuízos. A literatura aponta como sendo uma necessidade a padronização na caracterização e classificação de manifestações patológicas em ativos de infraestrutura, bem como a indexação da espacialização com histórico do ativo. Este trabalho propõe uma metodologia inovadora para a detecção automática de manifestações patológicas em obras geotécnicas, como túneis, utilizando técnicas de visão computacional. A abordagem busca superar a subjetividade na caracterização e classificação das patologias nesses ativos e requer maior robustez na construção de data set.

PALAVRAS-CHAVE: Túneis, Inteligência Artificial, Inspeção, Patologia, Geotecnia.

ABSTRACT: Tunnels are elements of geotechnical structures with complex behavior that are part of transport logistics and require great attention in the inspection and monitoring of their performance, given that a possible collapse in this type of asset causes severe losses. The literature points out that standardization in the characterization and classification of pathological manifestations in infrastructure assets is a necessity, as well as the indexing of spatialization with the asset's history. This work proposes an innovative methodology for the automatic detection of pathological manifestations in geotechnical works, such as tunnels, using computer vision techniques. The approach seeks to overcome subjectivity in the characterization and classification of pathologies in these assets and requires greater robustness in data set construction.

KEYWORDS: Tunnels, Artificial Intelligence, Inspection, Pathology, Geotechnics

1 INTRODUÇÃO

Os túneis são elementos de estruturas geotécnicas com comportamento complexo que fazem parte da logística de transportes e requer elevada atenção na inspeção e monitoramento de sua performance, haja visto que, um colapso nesse tipo de ativo causa severos prejuízos.

Via de regra a inspeção de túneis sempre foi desenvolvida na subjetividade de profissionais responsáveis pelo ativo, de acordo com a percepção empírica das equipes, sem registros históricos ou uniformização das rotinas, repetindo práticas que não acompanham o desenvolvimento tecnológico. Como solução, recentemente alguns estudos avaliam a possibilidade de automação das inspeções de estruturas, por meio da aplicação de técnicas de inteligência artificial, por exemplo, por representarem uma das alternativas mais promissoras no ramo do monitoramento de estruturas (Belloni et al., 2020). Esses projetos já fazem parte de investimentos de grandes empresas do ramo da construção civil, como a Vale®, Petrobrás® e a Acciona®, e a tendência é que a busca por regulamentação e maiores investimentos nesse ramo cresçam.

Mesmo que seja um ramo relativamente novo de pesquisa, sabe-se que é possível desenvolver e aplicar monitoramento de túneis usando a detecção de danos por meios visuais ou fazendo uso de equipamentos e sensores[MF1]. Parte essencial desses estudos envolve o método de aprendizado de máquina que tem sido aplicado cada vez mais, desde as últimas décadas, no ramo da construção. É uma ferramenta poderosa, que funciona por automatizar e aprimorar funções humanas, diminuindo a demanda de mão de obra in loco e, conseqüentemente, aumentando a segurança (Yayin et al., 2021). Ele já foi aplicado no monitoramento de questões de ocupação e segurança em locais de construção (Zhang and Shi, 2020) e na análise e comparação dos custos do ciclo de vida de construções, considerando a manutenção das obras ao longo do tempo (Gao et al., 2019).

A aprendizagem profunda tem ganhado espaço no ramo das técnicas de aprendizado de máquina devido à sua alta performance[MF2] em termos de rapidez e acurácia, quando comparada a subjetividade e imperícia humana. A aplicação da visão computacional, com o uso de drones e fotogrametria abrem espaço para uma nova era na inspeção de estruturas (Savino & Tondolo, 2020). Nesse ramo do aprendizado de máquina, são utilizadas redes neurais artificiais com múltiplas camadas, de maneira que diversas informações possam ser extraídas, a partir de diferentes níveis de estudo e detalhe. Assim, essas redes neurais são altamente qualificadas para tarefas de classificação de objetos e imagens por meio da compreensão e adaptação de características (Simonyan et al., 2014), (Redmon et al., 2016).

É escassa a disponibilidade de *dataset* com manifestações patológicas em concreto projetado, sendo necessária a construção desse repositório de dados para possibilitar a aplicação da Inteligência Artificial, muitas vezes sendo necessária a aplicação de técnicas de ampliação sintética de dados – *data augmentation*.

A técnica de *data augmentation* consiste na manipulação da imagem real, alterando sua rotação, brilho, suavidade, espelhamento entre outros, para multiplicar o número de imagens disponível, até que alcance um quantitativo de imagem viável para garantir o aprendizado da máquina.

De acordo com o atual cenário esse trabalho visa a aplicação de inteligência artificial, através do YOLO V5® para detecção de manifestações patológicas em túneis e avaliar a influência do banco de dados de imagem com aplicação de técnicas de *data augmentation*.

2 METODOLOGIA

2.1 Fluxo da metodologia

Com o intuito de aprimorar a detecção de patologias no concreto, o primeiro passo do estudo envolveu a construção de uma base de dados, capaz de prover imagens suficientes para um estudo. A partir disso, a base de dados foi aplicada em um programa de implementação do algoritmo de visão computacional YOLO V5®, e os resultados preliminares obtidos foram analisados. A Figura 1, ilustra o fluxograma da metodologia.

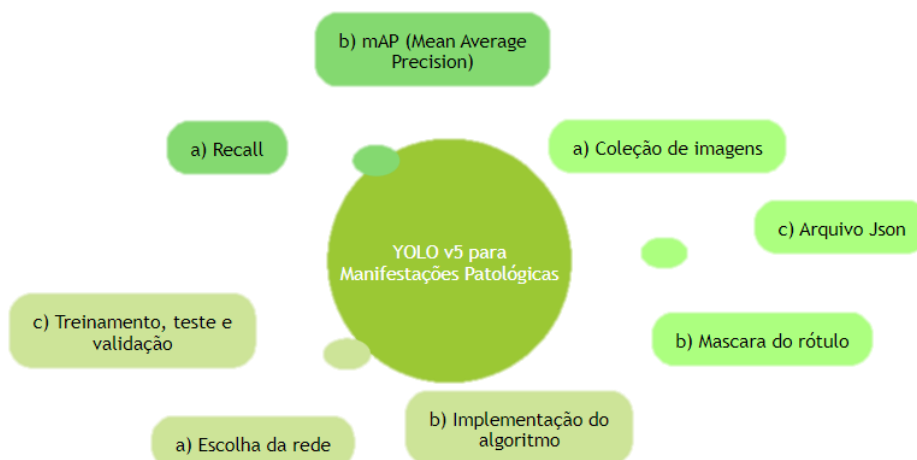


Figura 1. Fluxograma da metodologia.

A Figura 1 [MF3] ilustra as etapas desenvolvidas neste trabalho para implementação dos algoritmos de detecção de manifestações patológicas em concreto projetado.

2.1.1 Construção do Data set

Foram reunidas 53 imagens [MF4] que apresentassem manifestações patológicas de infiltração no revestimento de túneis em concreto projetado, porque além de se tratar de um tipo de manifestação comumente encontrada, é a responsável pelo desencadeamento de outras ainda mais graves. As imagens colecionadas foram rotuladas utilizando o software Vott®, *open source* desenvolvido pela Microsoft®, que auxilia na criação da máscara sobre a região onde aparece a manifestação patológica, e os parâmetros dessas máscara, indicando o rótulo da patologia, foram exportados em arquivo formato *.json, que por sua vez servirá como referência para a rede neural a decodificar os parâmetros de saída da última camada e imprimir a caixa delimitadora, conforma esquema da Figura 2.




Figura 2. Construção do *data set*.

O aprendizado de máquina é um processo estatístico, requerendo redundância de dados para aumentar a confiança dos resultados inferidos. Neste trabalho foi necessário utilizar a plataforma Robflow® para ampliar o número de 53 imagens disponíveis, aplicando as seguintes técnicas de *data augmentation*: segmentação com variação do zoom até 23%, rotação horizontal, brilho e exposição $\pm 25\%$, borrar acima de 2,5 px. Essa técnica sintética de ampliação de dados ajuda a garantir o mínimo de redundância, ampliando o *data set* para 177 imagens.

Para mensurar os efeitos da aplicação da técnica de *data augmentation*, foram comparadas as métricas obtidas antes e depois da ampliação da *data set*.

2.1.2 Implementação do algoritmo

O YOLO v5 foi o algoritmo escolhido, que é organizado a partir de redes neurais convolucionais, que conta com diversas camadas responsáveis por trazer maior eficiência e um menor custo computacional para o sistema. Ele retorna três produtos: as classes dos objetos detectados, com base em características pré-definidas como formatos, cores e texturas, “caixas de seleção”, traçadas ao redor dos objetos e as confianças de objeto (objectness scores), que uma probabilidade de 0 a 1 de que a caixa prevista realmente esteja sobre um objeto analisado.

O YOLO v5 foi definido por conta de sua entrega em agilidade comparada à acurácia, que supera por exemplo a *Faster RCNN*, outra forma de reconhecimento de imagem muito utilizada, e bastante precisa, mas que funciona quase 10 vezes mais devagar e com maior custo computacional. Além disso, percebeu-se um melhor desempenho do YOLO v5 quando em cenários de baixa iluminação, como é o caso da base de dados

aplicada nesta pesquisa. Ainda que existam filtros para a solução disso quando trabalhando com *data augmentation*, optou-se por seguir com um modelo que tivesse melhor ajuste com as características em estudo

A linguagem de implementação dos códigos foi realizada em Python® no ambiente do Google Colab®, que auxilia de forma prática a implementação de diversas linguagens via navegador web, sem necessidade de configurações prévias.

O *data set* foi dividido em porções obedecendo a fração 80/10/10, onde foram utilizadas 80% das imagens para treinamento da rede neural e 10% para teste e 10% para validação, conforme recomendado por Kapadia, 2022. Foram treinadas 200 épocas cada rótulo conforme indicado nas instruções de uso, analisando ao final suas convergências.

2.1.3 Avaliação das métricas dos resultados

mAP (Mean Average Precision): Foi a métrica utilizada para medir a média da precisão dos algoritmos em diferentes classes de objetos em uma detecção de objetos. Fornece uma visão geral da capacidade do modelo em detectar objetos de diferentes tipos.

IoU (Intersection over Union): Foi utilizada para avaliar a sobreposição entre a caixa delimitadora prevista pelo modelo e a caixa delimitadora verdadeira do objeto. Ajudando a determinar o quão bem o modelo localiza os objetos em uma imagem.

Precisão: Representa a proporção de verdadeiros positivos em relação ao total de itens positivos previstos pelo algoritmo. Indica a precisão das predições positivas feitas pelo modelo.

Recall: Indica a proporção de verdadeiros positivos em relação ao total de itens positivos presentes nos dados. Mostra a capacidade do modelo em recuperar corretamente os exemplos positivos.

F1: É a média harmônica entre precisão e recall, fornecendo uma única medida que equilibra ambos os aspectos. É útil quando há um desequilíbrio entre as classes de dados.

AP (Average Precision): É a média da precisão calculada em vários níveis de recall. Útil para avaliar a precisão das classificações em um conjunto de dados, especialmente em problemas de detecção de objetos.

3 RESULTADOS E DISCUSSÃO

O *data set* foi composto por 53 imagens de infiltração devidamente rotuladas, em diferentes condições de ângulo, iluminação e escala, afim de simular as condições de visualização encontrada no interior de um túnel.

As imagens após serem treinadas, testadas e validadas apresentaram as seguintes métricas indicadas nas Figuras 3 e 4, que mostram a performance do algoritmo com e sem aplicação de *data augmentation*. [MF5]

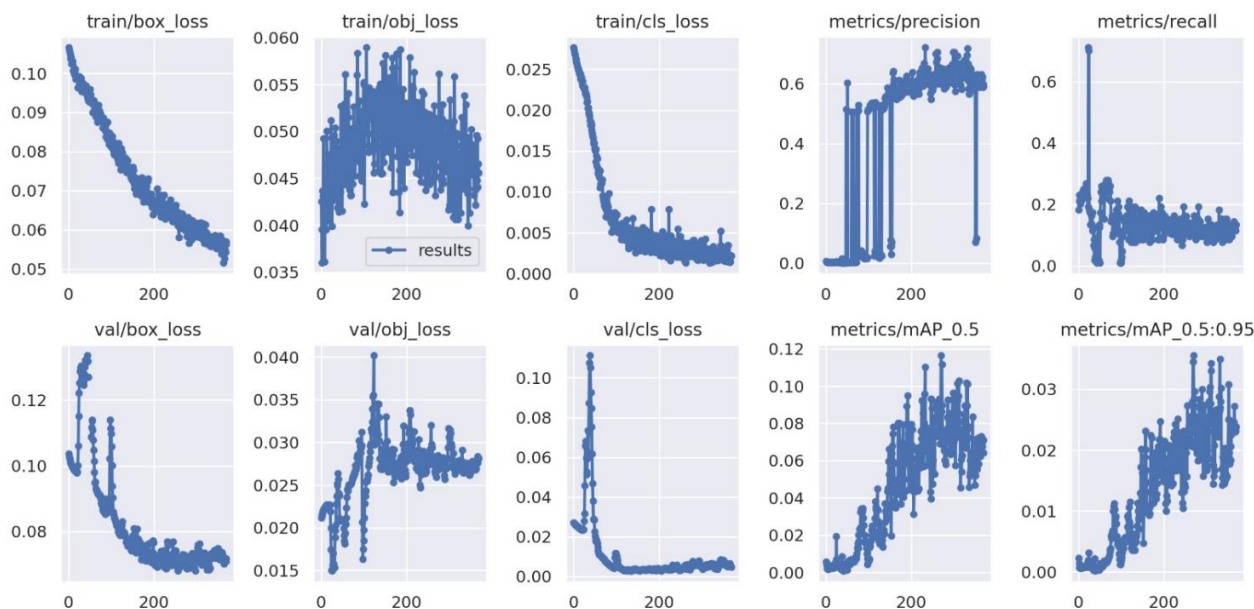


Figura 3 – métrica de avaliação do algoritmo de detecção de manifestações patológicas sem aplicação de *data augmentation*.

Analisando o “*box loss*”, consegue-se uma visão a respeito dos acertos do modelo quanto às previsões das caixas de seleção, considerando o posicionamento da caixa em relação ao centro do objeto e o tamanho da caixa em relação ao tamanho do objeto. Menores valores são mais satisfatórios e o esperado seria um gráfico próximo a uma “*elbow curve*”. Com base em uma análise de “*Intersect over Union*”, basicamente comparando as regiões de sobreposição do local previsto para ter um objeto a ser detectado e os locais que realmente tinham objetos, percebe-se que ao longo do tempo o erro aumentou, o que indica certa deficiência ou desfalque no experimento. Isso é atribuído à pequena quantidade de imagens fornecida, que representa cerca de 10% da quantidade ideal para o treinamento de uma rede dessa categoria.

Analisando o “*object loss*”, pretende-se obter valores pequenos, indicando que o algoritmo é bem certo quanto à presença de objetos nas caixas de seleção. Para os gráficos obtidos, atribui-se baixa perda na seção de validação, com um pico, e uma perda que aumenta gradativamente na parte selecionada para treinar o algoritmo. Esse comportamento tende a ser revertido com uma melhor distribuição de imagens entre as subseções dos *data sets*, claro, quando a quantidade de imagens é satisfatória para teste. Idealmente, um modelo teria um baixo “*object loss*”, indicando maior confiança de objeto, o que significa que há uma boa distinção entre os objetos buscados e ruídos de fundo.

Analisando o “*class loss*”, foi obtido um resultado mais satisfatório. Isso porque esse parâmetro considera os acertos do modelo em atribuir as categorias corretas aos objetos identificados. Foi possível garantir tanta precisão neste modelo por conta das poucas classes definidas.

Em seguida, são apresentados gráficos mais claros de se interpretar, que consideram a precisão do modelo. No quarto gráfico da primeira linha, observa-se a precisão geral do modelo, considerando quantas das detecções positivas estavam de fato corretas, enquanto nos gráficos de mAP (*Mean Average Precision*), explicita-se uma relação que considera a precisão classe por classe. Uma precisão aceitável para o YOLO v5 seria acima de 70% inicialmente, aproximando de 80% quando o *data set* e o treinamento do modelo fossem ideais, conforme observado pela bibliografia. Ainda que em certos momentos as seções tenham se aproximado dessa métrica, em sua maioria percebe-se que ainda há um extenso caminho trabalhando na expansão dessa base de dados.

Nesse sentido, aborda-se um tópico fundamental: a quantidade de patologias demarcadas na base de dados vigente, em comparação à real possibilidade de quantidades de patologias a serem consideradas. Esta base de dados em desenvolvimento preliminar conta apenas com imagens demarcadas de infiltração. Com a expansão da base de dados envolvendo todas as patologias idealizadas previamente, certamente será possível adquirir um melhor resultado.

Após as técnicas de *data augmentation*, o *data set* passou a ser constituído de 177 imagens e foi possível verificar o efeito sobre as respostas do algoritmo, conforme demonstrado na figura 4.

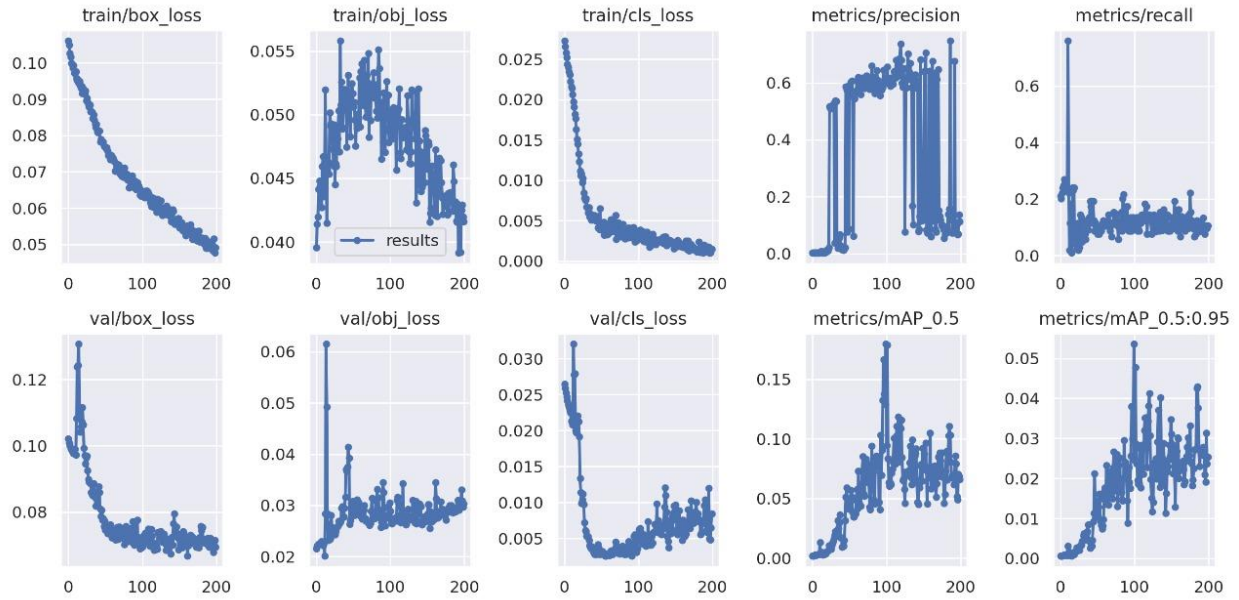


Figura 4 – métrica de avaliação do algoritmo de detecção de manifestações patológicas com aplicação de *data augmentation* com 200 épocas de treinamento.

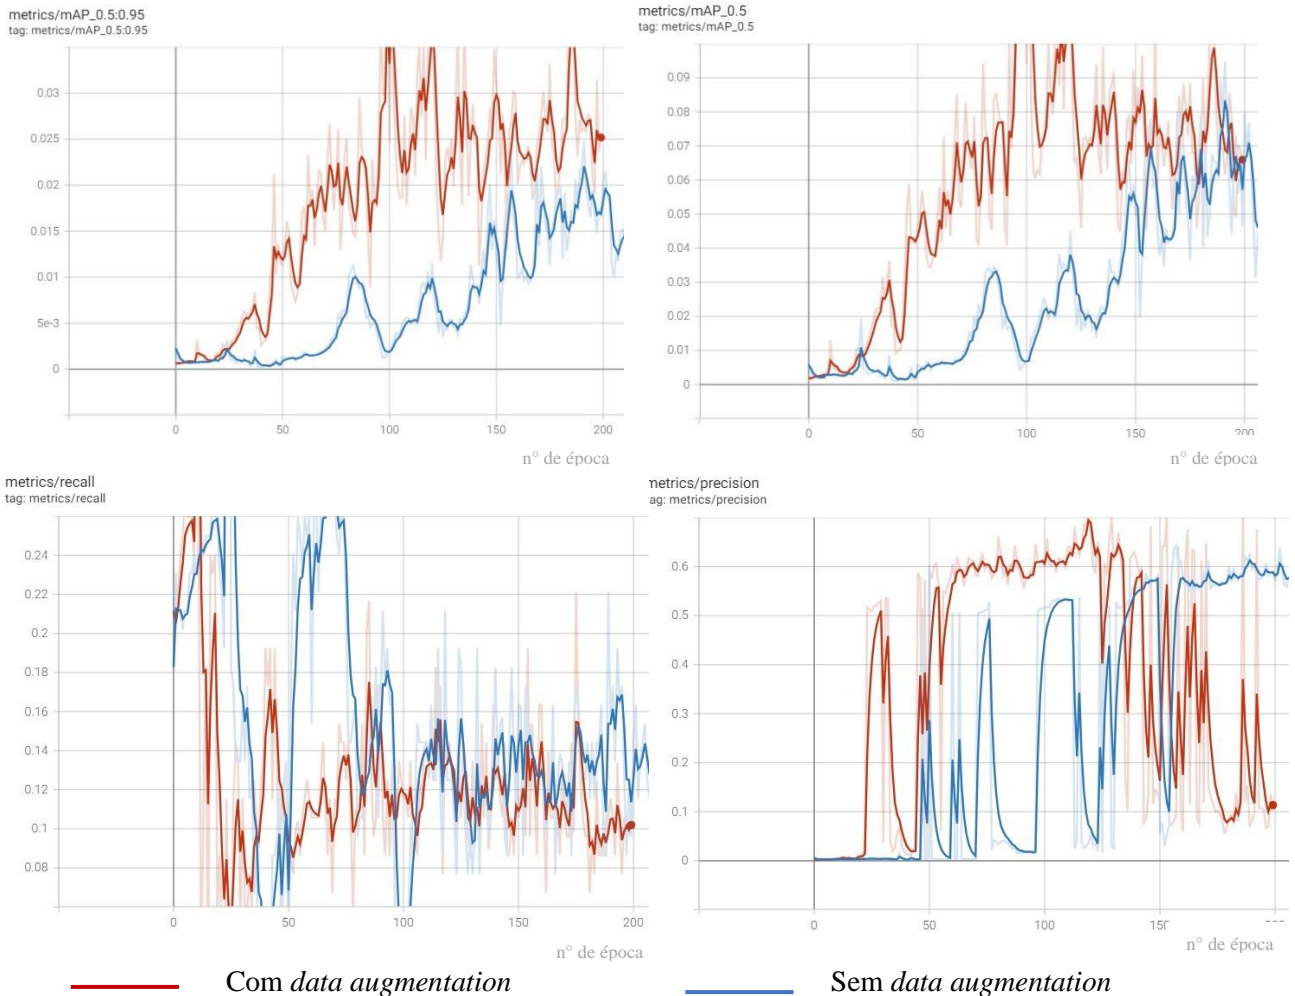


Figura 5 – efeito da *data augmentation* nas métricas de avaliação do algoritmo de detecção de manifestações patológicas.

Ao observar mostra mAP 50 e mAP 50:95, é notória a influência da aplicação da aplicação de *data augmentation* no set de imagens, permitindo a melhoria do algoritmo na sua capacidade de distinção entre objetos, conforme mostrado na Figura 5. Entretanto, para a capacidade de determinação de verdadeiros positivos, ou seja, a razão do número pelo número total de respostas, a técnica não mostrou interferência positiva, demonstrando uma redução na capacidade de recuperar os exemplos positivos dentro da população, conforme mostrado pela comparação dos gráficos de Recall.

Em termos de precisão a aplicação de *data augmentation* apresenta significativa melhoria, com uma forte tendência de queda a partir da janela de da época 150.

A Tabela 1, mostra a em números os melhores resultados alcançados pelos algoritmos com e sem a técnica de *data augmentation*.

Tabela 1 – Resumo de métricas do algoritmo de detecção de manifestações patológicas em túneis.

	mAP 50	F1 score	Recall	Precisão
Sem <i>data augmentation</i>	0,233	0,13 a 0,145	0,40	0,45
Com <i>data augmentation</i>	0,179	0,12 a 0,26	0,93	0,606

4 CONCLUSÕES

A partir dos resultados apresentados, entende-se que atravessando a limitação da quantidade de imagens e diversidade das imagens no *data set*, a capacidade de atuação do YOLO v5, se comprova de maneira efetiva para essa aplicação. Neste trabalho apresentou-se a metodologia para construção do *data set* voltado para inspeção de manifestações patológicas em túneis, um atual gargalo nessa área, afinal, busca-se a mitigação da subjetividade das atuais maneira de inspeção desses ativos. Assim, esse trabalho traz como principais contribuições o uso de visão computacional apoiado em uma plataforma aberta para preencher a lacuna de subjetividade na inspeção de túneis possibilitando a detecção em tempo real e ao vivo.

Ao comparar ambos os resultados das bases de dados, constata-se que ainda é necessário expandir a base de dados e isso seria possível a partir da inclusão de mais patologias. Além disso, confirmaram-se as hipóteses dos efeitos do *data augmentation*, que são benéficos até certo ponto, a partir do qual as interferências no modelo se demonstram por certo vício do algoritmo, conhecido como *overfitting*.

AGRADECIMENTOS

Universidade de São Paulo – USP, CAPES e Cátedra Under Rail - Vale.

REFERÊNCIAS BIBLIOGRÁFICAS

- Pires, P. J. M.; Meneguete, D. S.; Salgado, N. G. DE P (2016). Otimização dos processos de inspeção em monitoramento para túneis em rocha. *Revista Mosaicum*, n. 23, 20 maio 2016.
- Mirzazade, A. et al. (2021) Workflow for Off-Site Bridge Inspection Using Automatic Damage Detection-Case Study of the Pahtajokk Bridge. *Remote Sensing*, v. 13, n. 14, p. 2665, 7 jul. 2021.
- Savino, P.; Tondolo, F. (2021). Automated classification of civil structure defects based on convolutional neural network. *Frontiers of Structural and Civil Engineering*, v. 15, n. 2, p. 305–317, abr. 2021.
- Yayin Xu, Ying Zhou, Przemyslaw Sekula, Lieyun Ding, (2021). Machine learning in construction: From shallow to deep learning, *Developments in the Built Environment*, Volume 6, 2021.

- Gao, X. et al. (2019). Machine Learning Applications in Facility Life-Cycle Cost Analysis: A Review. *Computing in Civil Engineering* 2019, 13 jun. 2019.
- Lanning A, E. Zaghi A and Zhang T (2022). Applicability of Convolutional Neural Networks for Calibration of Nonlinear Dynamic Models of Structures. *Front. Built Environ.* 8:873546. doi: 10.3389/fbuil.2022.873546, abr. 2022
- Simonyan, K.; Zisserman, A. Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556, 2014. Disponível em: <<http://arxiv.org/abs/1409.1556>>.
- Anitescu, C. et al. Artificial neural network methods for the solution of second order boundary value problems. *Computers, Materials and Continua*, Tech Science Press, v. 59, n. 1, p. 345–359, 2019.
- Korfmann K, Sellinger T, Freund F, Fumagalli M, Tellier A. 2024. Simultaneous Inference of Past Demography and Selection from the Ancestral Recombination Graph under the Beta Coalescent. *bioRxiv*, 2022.09.28.508873. ver. 5
- Kaitian Wang, Panshan Li, Yang Liu, Hu Li, Yanqing Men and Yongliang Huang, 2021. Research on the Present Situation and Development Trend of Subway Tunnel Inspection Vehicle. *IOP Conf. Ser.: Mater. Sci. Eng.* 1203 022126. DOI 10.1088/1757-899X/1203/2/022126
- Jo Plested and Tom Gedeon 2022. Deep transfer learning for image classification: a survey. *Deep transfer learning for image classification: a survey*, <https://doi.org/10.48550/arXiv.2205.09904>
- Harsh K Kapadia, Paresh V Patel and Jignesh B Patel, Convolutional Neural Network Based Improved Crack Detection In Concrete Cubes - *International Journal of Computing and Digital Systems*, ISSN (2210-142X) *Int. J. Com. Dig. Sys.* 13, No.1 (Jan-2023), <http://dx.doi.org/10.12785/ijcds/130127>.