



Indústria 5.0: Oportunidades e Desafios
para Arquitetura e Construção

13º Simpósio Brasileiro de Gestão e
Economia da Construção e 4º Simpósio
Brasileiro de Tecnologia da Informação
e Comunicação na Construção

ARACAJU-SE | 08 a 10 de Novembro

1 ANÁLISE DE TÉCNICAS DE *DATA AUGMENTATION* PARA APERFEIÇOAMENTO DA DETECÇÃO DE SISTEMAS DE GUARDA-CORPO E RODAPÉS EM CANTEIROS DE OBRAS COM INTELIGÊNCIA ARTIFICIAL

Analysis of data augmentation techniques to improve the detection of guardrail systems in construction sites with artificial intelligence

Hugo Sefrian Peinado

Universidade Federal da Bahia | Salvador, BA | hugospeinado@gmail.com

Carolina Andrade de Oliveira

Universidade Federal da Bahia | Salvador, BA | carolina.bam27@gmail.com

André Luiz Carvalho Ottoni

Universidade Federal do Recôncavo da Bahia | Cruz das Almas, BA | andre.ottoni@ufrb.edu.br

Roseneia Rodrigues Santos de Melo

Universidade Federal da Bahia | Salvador, BA | roseneia.engcivil@gmail.com

Dayana Bastos Costa

Universidade Federal da Bahia | Salvador, BA | dayanabcosta@ufba.br

Marcela Silva Novo

Universidade Federal da Bahia | Salvador, BA | marcela.novo@ufba.br

RESUMO

Apesar do avanço do uso de técnicas de aprendizado profundo (AP) (área da inteligência artificial) para inspeções de segurança em canteiro de obras, o desenvolvimento dessas tecnologias é muitas vezes limitado pela pequena quantidade disponível de imagens para treinamento dos algoritmos. A partir disso, tem-se observado o uso de técnicas de *data augmentation* (DA) que visam criar dados artificiais para treinamento, a partir dos dados de treinamento existentes. Nesse sentido, esse trabalho tem como objetivo avaliar o desempenho de algoritmo de AP na detecção de sistemas de guarda-corpo e rodapés (GcR) com uso de bancos de imagens de treinamento originais e artificiais (criadas a partir de diferentes técnicas de DA). As etapas da pesquisa envolveram coleta de imagens com uso de aeronaves remotamente pilotadas (RPA) em dois canteiros de obras, estruturação de banco de imagens originais e artificiais geradas por transformações geométricas do tipo zoom, rotação e cisalhamento, criação de quatro modelos no Custom Vision®, treinamento, teste e análise dos resultados dos modelos. O desempenho do algoritmo treinado com imagens artificiais foi superior àquele treinado com imagens originais, indicando que as imagens geradas por DA contribuíram substancialmente para o aperfeiçoamento do desempenho do sistema de detecção de GcR.

Palavras-chave: Visão computacional; Aprendizado profundo; Aprendizado de máquina; drone; Construção 4.0.

ABSTRACT

Despite the advances in using deep learning (DL) techniques for safety inspections at construction sites, the development of these technologies is often limited by the small number of images available for algorithm training. It has been observed the use of data augmentation (DA) techniques that aim to create artificial data for training from existing training data. Thus, this paper aims to evaluate the performance of a DL algorithm in detecting guardrail systems using original and artificial training image banks (created using different DA techniques). The research steps involved images collected using remotely piloted aircraft (RPA) at two construction sites, structuring of a bank of original and artificial images generated by geometric transformations such as zoom, rotation, and shear, creation of four models in the Custom Vision®, training, testing, and analysis of model results. The performance of the algorithm trained with artificial images was superior to that trained with original images, indicating that the images generated by DA contributed substantially to improving the performance of the guardrail detection system.

Keywords: Computer vision; Deep learning; Machine learning; drone; Construction 4.0.

¹ PEINADO, H. S.; OLIVEIRA, C. A.; OTTONI, A. L. C.; MELO, R. R. S.; COSTA, D. B.; NOVO, M. S. A. Análise de técnicas de *data augmentation* para aperfeiçoamento da detecção de sistemas de guarda-corpo e rodapés em canteiros de obras com inteligência artificial. In: SIMPÓSIO BRASILEIRO DE GESTÃO E ECONOMIA DA CONSTRUÇÃO, 13., 2023, Aracaju. **Anais [...]**. Porto Alegre: ANTAC, 2023.

1 INTRODUÇÃO

A queda de altura está entre as principais causas de acidentes nas atividades que integram a construção de edificações verticais (PEINADO, 2019; ZERMANE *et al.*, 2023). No planejamento das atividades da construção, não sendo possível evitar o trabalho em altura, a Norma Regulamentadora n° 35 (NR-35) (BRASIL, 2022) estabelece a necessidade de adotar medidas que eliminem o risco de queda dos trabalhadores. Nesse sentido, deve-se implementar prioritariamente sistemas de proteção coletiva contra quedas (SPCQ). Alguns SPCQ usualmente utilizados na construção são sistemas de guarda-corpo e rodapés (GcR), redes de segurança e fechamento de aberturas em pavimentos (BORGES; PEINADO, 2019), todos regulamentados pela NR-18 (BRASIL, 2020). Apesar da ampla utilização de sistemas de GcR nos contextos brasileiro e internacional (PEINADO, 2019; BARUFFI; COSTELLA; PRAVIA, 2021), a inexistência ou inadequação desses sistemas estão entre os principais fatores que resultam em acidentes por queda de altura na construção (NADHIM *et al.*, 2016; ZLATAR *et al.*, 2019).

Segundo Kolar, Chen e Luo (2018), para o aperfeiçoamento da segurança em canteiros de obras, são necessárias abordagens mais eficientes que complementem as práticas de inspeções manuais na identificação das condições inseguras. Os autores destacam a necessidade de processos automatizados envolvendo outras tecnologias digitais, principalmente a visão computacional. Observa-se na literatura o aumento das aplicações de visão computacional em inspeções de segurança em canteiro de obras nos últimos anos (AKINOSHO *et al.*, 2020; PHAM *et al.*, 2021; OTTONI; NOVO; COSTA, 2022). São identificadas implementações principalmente de técnicas de aprendizado de máquina (AM) e, mais especificamente, de aprendizado profundo (AP) (campos da inteligência artificial) na detecção de equipamentos de proteção individual e de SPCQ, entre outras aplicações (AKINOSHO *et al.*, 2020; PHAM *et al.*, 2021; OTTONI; NOVO; COSTA, 2022).


Otoni *et al.* (2023) pontuam que um desafio para a aplicação de técnicas de AP no setor da construção consiste, muitas vezes, na disponibilidade de pequenos bancos de dados para treinamento desses algoritmos de detecção. Dada a dificuldade de aquisição de imagens, diversos trabalhos relacionados a temáticas da construção têm empregado técnicas de *data augmentation* (DA) para aumento desses bancos de imagens e posterior treinamento de algoritmos de AP (FANG *et al.*, 2020; OTTONI; NOVO; COSTA, 2022). *Data augmentation* é uma técnica para criação de dados artificiais para treinamento de algoritmos a partir dos dados de treinamento existentes (originais) aplicando, por exemplo, transformações geométricas (BROWNLEE, 2019; SHORTEN; KHOSHGOFTAAR, 2019). O uso de técnicas de DA parte do pressuposto de que mais informações poderão ser extraídas do banco de dados original por meio de aumento da quantidade desses dados com a implementação de transformações (SHORTEN; KHOSHGOFTAAR, 2019).

Apesar da existência de trabalhos direcionados à inspeção de segurança na construção com a integração de visão computacional que utilizam técnicas de DA (KOLAR; CHEN; LUO, 2018; FANG *et al.*, 2020; OTTONI; NOVO; COSTA, 2022), há duas lacunas a serem exploradas neste artigo: há poucos trabalhos que empregam técnicas de DA para geração de imagens artificiais e, posterior, treinamento de algoritmos de AP para detecção de sistemas de GcR; não há trabalhos que comparem o desempenho de algoritmos de AP treinados com bases de imagens artificiais geradas a partir de diferentes técnicas de DA com foco na detecção de sistemas de GcR.

Nesse contexto, o presente artigo tem como objetivo avaliar o desempenho de algoritmo de AP na detecção de sistemas de GcR com uso de bancos de imagens de treinamento originais e artificiais (criadas a partir de diferentes técnicas de DA). Os resultados obtidos poderão auxiliar na determinação de técnicas de DA mais adequadas para a ampliação de bancos de imagens de treinamento e aperfeiçoamento do desempenho do algoritmo de AP para detecção de GcR. Esse artigo integra uma pesquisa mais ampla em andamento que tem a finalidade de desenvolver um sistema de detecção automatizada que identifique as falhas de segurança nesse SPCQ, como a ausência de GcR, espaçamento entre as grades de proteção, entre outras apontadas por Peinado *et al.* (2023). Desse modo, a etapa inicial do desenvolvimento desse sistema (expressa nesse artigo) consiste no treinamento e teste de modo a determinar se o algoritmo é capaz de detectar os GcR nas imagens dos canteiros de obras, para posterior avanço na detecção das falhas desses SPCQ. Esses resultados darão suporte para o avanço da integração da visão computacional em inspeções automatizadas da segurança em sistemas de GcR em canteiros de obras.

2 MÉTODO DE PESQUISA

A estratégia adotada para a condução da pesquisa foi o estudo de caso exploratório. Essa abordagem tem como finalidade identificar questões de pesquisa ou procedimentos a serem utilizados em pesquisas futuras (YIN, 2018). As etapas de condução da pesquisa são apresentadas na Figura 1.



Fonte: os autores.

A coleta de imagens para construção de um banco de dados ocorreu em duas visitas a canteiros de obras distintos (CO1 e CO2) na região metropolitana de Salvador (BA). O sistema construtivo dos empreendimentos é paredes de concreto moldada *in loco* e, portanto, os sistemas de GcR utilizados são industrializados, como indicado na Figura 2.

Figura 2: Sistemas de GcR



Fonte: adaptado de Peinado *et al.* (2023).

Foram utilizadas aeronaves remotamente pilotadas (RPA) para ambas as coletas de imagens. Para a coleta no CO1, utilizou-se o DJI Phantom 4, com inclinação da câmera igual a 0° com a horizontal. Para a coleta no CO2, foi utilizado o DJI Air 2S, com inclinação da câmera a 20° com a horizontal. Peinado *et al.* (2023) sugere essas inclinações como potencialmente mais adequadas para visualização dos sistemas de GcR e, por conseguinte, para identificação mais eficiente de problemas que podem comprometer o desempenho desses sistemas.


A coleta resultou em um total de 150 imagens, sendo 90% delas usada para a etapa de treinamento do algoritmo de detecção de GcR e 10% para a etapa de teste desse algoritmo. Os bancos de imagens para treinamento foram estruturados conforme segue:

- B1 - Banco original: 135 imagens (71 imagens do CO1 e 64 do CO2);
- B2 - Banco com DA de zoom: 405 imagens, com *zoom in* e *zoom out* de até 15% atribuídos de forma aleatória;
- B3 - Banco com DA de rotação: 405 imagens, com pequena rotação atribuída de forma aleatória nas imagens (chegando a 15°);

- B4 - Banco com DA de cisalhamento: 405 imagens, com distorção da imagem ao longo de um eixo com o uso de cisalhamento π radianos.

Para aplicação das técnicas de transformação geométrica nas imagens, foi utilizada a biblioteca Keras no Software R (CHOLLET.; ALLAIRE, 2018) e o algoritmo apresentado em Staffa *et al.* (2022). A Figura 3 (a) a (d) mostra exemplo de imagem original e de imagens com as transformações geométricas aplicadas no presente estudo.

Figura 3: (a) Imagem original; (b) Imagem com Zoom; (c) Imagem com Rotação; (d) Imagem com Cisalhamento



Fonte: os autores.

Para cada banco de imagens (B1 a B4), foi criado modelo específico no Custom Vision® (modelos M1 a M4). O Custom Vision® é um serviço de inteligência artificial da Microsoft Azure® que permite a criação de modelos customizados com a finalidade de classificação ou detecção de objetos em imagens empregando Redes Neurais Convolucionais (RNCs) (ResNet e AlexNet - redes de AP) (PEJČINOVIĆ, 2019; STAFFA *et al.*, 2022). Essa interface de programação de aplicação (API) tem sido utilizada por diversos segmentos na literatura científica com desempenho satisfatório, incluindo a construção civil (STAFFA *et al.*, 2022).

Criados os modelos, procedeu-se à marcação das imagens. Essa etapa teve como objetivo indicar à API todos os GcR de todas as imagens, para que posteriormente fosse realizado o treinamento do respectivo modelo. A marcação das imagens em todos os modelos foi realizada por apenas uma pesquisadora (segunda autora deste artigo), de modo a assegurar a padronização. Em seguida, foram realizados os treinamentos dos modelos M1 a M4 no Custom Vision®. Ao término de cada treinamento, a API retornava os valores dos parâmetros de desempenho Precisão e *Recall* de cada modelo. Com base nesses dois parâmetros, foi também calculado o parâmetro F1. O parâmetro Precisão indica a probabilidade de um resultado positivo ser de fato positivo (BROWNLEE, 2019). O *Recall* descreve quão bom o modelo é em prever uma classe positiva quando a saída é positiva (BROWNLEE, 2019). O F1 (ou F-Score) representa a média harmônica entre Precisão e *Recall* (BROWNLEE, 2019). As equações 1 a 3 expressam a forma de cálculo dessas métricas.

$$\text{Precisão} = \text{VP} / (\text{VP} + \text{FP}) \quad (1)$$


$$\text{Recall} = \text{VP} / (\text{VP} + \text{FN}) \quad (2)$$

$$\text{F1} = (2 \cdot \text{Precisão} \cdot \text{Recall}) / (\text{Precisão} + \text{Recall}) \quad (3)$$

Em que: VP = verdadeiro positivo – quando o algoritmo detecta uma face do GcR e de fato aquilo é um GcR; FP = falso positivo – quando o algoritmo detectou um GcR em um determinado local, mas não havia GcR ali; FN = falso negativo – quando o algoritmo não detectou um GcR, mas havia um GcR ali.

Na sequência, foram realizados os testes em 15 imagens (10% das imagens coletadas nas obras) individualmente para cada modelo (M1 a M4). As imagens de teste não foram submetidas a transformações por DA. Cada imagem possui um valor possível de VP. Assim, um dos pesquisadores do estudo (primeiro autor deste trabalho) delimitou manualmente nas imagens de teste quais seriam as faces do GcR a serem detectadas (gabarito), que resultou no valor de verdadeiros positivos máximos possíveis ($VP_{m\acute{a}x}$) em uma imagem (Figura 4). Foram adotados retângulos vermelhos para a marcação manual das faces dos GcR nas imagens, já que esse é o recurso visual utilizado pelo Custom Vision® para apresentar os elementos detectados.

Figura 4: Exemplos das imagens de teste com marcação manual das faces dos GcR (gabarito)



Fonte: os autores.

Com as marcações feitas pelo Custom Vision® nas imagens de teste para cada modelo e com o gabarito em mãos, foram identificados os parâmetros VP, FP e FN. A identificação desses parâmetros foi feita por dois pesquisadores de forma individual, para posterior comparação e discussão dos resultados. Em seguida, foram calculados os parâmetros de Precisão, *Recall* e F1 para identificar o desempenho dos modelos na etapa de teste. Por fim, procedeu-se à análise dos resultados de desempenho obtidos nas etapas de treinamento e teste.

3 RESULTADOS E ANÁLISES

Os dados referentes ao treinamento são indicados na Tabela 1.

Tabela 1: Dados de desempenho na etapa de treinamento

Modelo do Custom Vision®	Quantidade de Imagens	Indicadores de desempenho			Ranking
		Precisão	Recall	F1	
M1 - Original	135	63,50%	96,10%	76,47%	3°
M2 - Com Zoom	405	75,10%	98,20%	85,11%	1°
M3 - Com Rotação	405	56,70%	97,10%	71,59%	4°
M4 - Com Cisalhamento	405	74,80%	94,90%	83,66%	2°

Fonte: os autores.

Com base na Tabela 1, observa-se que o modelo que apresentou melhores métricas foi o M2 (com imagens artificiais geradas com o uso de zoom), seguido dos modelos M4 (com cisalhamento), M1 (imagens originais) e M3 (com rotação), respectivamente. Assim, tem-se que houve melhora no desempenho no treinamento dos modelos com banco de imagens artificiais com Zoom (M2) e Cisalhamento (M3) em relação ao modelo treinado com banco de imagens original (M1). Apenas o modelo que fez uso de imagens com rotação apresentou precisão inferior ao modelo M1.

Os dados referentes ao teste são apresentados na Tabela 2.

Tabela 2: Dados de desempenho na etapa de teste

Modelo do Custom Vision®	Quantidade de imagens	Métricas			Indicadores de desempenho			Ranking
		VP	FP	FN	Precisão	Recall	F1	
M1 - Original	15	60	17	2	77,92%	96,77%	86,33%	4°
M2 - Com Zoom	15	61	10	1	85,92%	98,39%	91,73%	3°
M3 - Com Rotação	15	61	3	1	95,31%	98,39%	96,83%	2°
M4 - Com Cisalhamento	15	61	2	1	96,83%	98,39%	97,60%	1°

Nota: VP – Verdadeiro Positivo; FP – Falso Positivo; FN – Falso Negativo; Valor limiar adotado de de 50% (nível de confiança que o modelo deve ter de uma detecção para considera-la válida).

Fonte: os autores.

A partir dos dados apresentados na Tabela 2, observa-se que do total de 62 VP possíveis no conjunto das 15 imagens de teste, todos os modelos apresentaram elevado desempenho da detecção desses VP, além de terem detectado poucos FN. Esses resultados satisfatórios são também evidenciados no *Recall*, que depende objetivamente dos parâmetros de VP e FN. A detecção das faces de GcR na 'imagem 4' em cada modelo gerados na etapa de teste a partir do Custom Vision® são apresentados na Figura 5. A Figura 4 apresentou previamente o gabarito referente à 'imagem 4'.

Figura 5: Detecções de GcR na imagem a partir do modelo (a) M1; (b) M2; (c) M3; (d) M4



Fonte: os autores.

Além disso, os modelos M3 e M4 detectaram poucos FP. O modelo M2 apresentou número elevado de FP em comparação aos demais modelos treinados com bancos de imagens artificiais. Destaca-se principalmente a 'Imagem 7' do teste, em que o modelo M2 detectou cinco FP, indicando a tela de armação das paredes de concreto como se fossem GcR nesses cinco pontos. Ainda assim, o modelo que apresentou maior número de FP e, portanto, menor precisão, foi o M1. Nas imagens do teste de M1 houve 17 FP, no qual o modelo confundiu o GcR com telas de proteção em aberturas das paredes de pavimentos já concretados, janelas, motor do elevador cremalheira, carros, trabalhadores, entre outros elementos. Exemplifica-se com a 'imagem 15' do modelo M1, que apresentou 6 FP (Figura 6).

Figura 6: FP identificados na 'imagem 15' (M1)



Fonte: os autores.

Por fim, é apresentado na Tabela 3 o aperfeiçoamento observado considerando os valores de Precisão, Recall e F1 entre as etapas de treinamento e teste.

Tabela 3: Aperfeiçoamento dos indicadores de desempenho entre treinamento e teste dos modelos

Modelo do Custom Vision®	Aperfeiçoamento dos Indicadores de desempenho		
	Precisão	Recall	F1
M1 - Original	22,71%	0,70%	12,89%
M2 - Com Zoom	14,40%	0,19%	7,78%
M3 - Com Rotação	68,10%	1,33%	35,24%
M4 - Com Cisalhamento	29,45%	3,67%	16,66%

Fonte: os autores.

Todos os modelos apresentaram desempenho superior na etapa de teste em comparação ao desempenho observado na etapa de treinamento, o que pode ser observado a partir dos percentuais de aumento dos parâmetros de Precisão, Recall e F1.

4 DISCUSSÕES

Os indicadores de desempenho das etapas de treinamento e teste mostram, em linhas gerais, que o uso de técnicas de DA em um pequeno banco de imagens e, por conseguinte, a criação de imagens artificiais contribuiu significativamente para o aperfeiçoamento do desempenho dos modelos na detecção de sistemas

de GcR. Apesar do desempenho de M3 (com imagens rotacionadas) ter sido inferior ao desempenho de M1 (imagens originais) na etapa de treinamento, todos os modelos treinados com imagens artificiais (com zoom, rotação e cisalhamento) apresentaram desempenho superior ao de M1 na etapa de teste. Resultados similares foram identificados por Staffa *et al.* (2022), que observou a melhoria do desempenho de algoritmo de AP utilizado na detecção de manifestações patológicas em coberturas de edificações a partir do treinamento dos modelos com imagens artificiais. Esses resultados convergem com a premissa apresentada por Fang *et al.* (2020) de que é fundamental a utilização de técnicas de DA para melhoria do desempenho da visão computacional utilizando pequenos bancos de imagens originais nos treinamentos.

Entre os modelos treinados com imagens artificiais, observou-se melhor desempenho na etapa de testes dos modelos M4 (imagens com cisalhamento) e M3 (imagens com rotação), com precisão de 96,83% e 95,31%, *recall* de 98,39% e 98,39% e F1 de 97,60% e 96,83%, respectivamente. No entanto, mesmo o modelo M2 (com zoom), apesar de ter apresentado menor precisão, ainda demonstrou resultados satisfatórios na detecção de GcR, com 85,92% de precisão, 98,39% de *recall* e 91,73% de F1. Os valores médios obtidos por Staffa *et al.* (2022) na etapa de teste dos modelos 1 e 2 treinados com imagens artificiais foram inferiores aos identificados no presente estudo. Os autores alcançaram precisão de 68,85% e 77,08%, *recall* de 80,77% e 71,15% e F1 de 74,34% e 74,0%, respectivamente.

Ainda, observa-se que o modelo M1 foi o que apresentou o maior número de detecções de falsos positivos na etapa de teste (17 no total), além desses FP terem sido de diversos itens que não compartilham características com os sistemas de GcR (carros, trabalhadores, entre outros). O mesmo não ocorreu com os demais modelos, que além de apresentarem menor número de FP, os itens identificados incorretamente tinham características em comum com as telas do sistema de GcR. Nesse sentido, tem-se que o aumento do banco de imagens com transformações geométricas resultou em mais informações sendo extraídas do banco de dados original, como apresentado por Shorten e Khoshgoftaar (2019) e, portanto, no melhor desempenho do algoritmo em conseguir diferenciar o que é um sistema de GcR de outros elementos.

Da forma como proposta, a detecção do sistema de GcR por meio de imagens coletadas por RPA e técnica de visão computacional tem o potencial de auxiliar gestores de segurança na inspeção visual desses sistemas, de modo a identificar se os GcR estão corretamente posicionados e se apresentam as condições de segurança requeridas pela NR-18 (BRASIL, 2020) e NR-35 (BRASIL, 2022). Considerando o objetivo mais amplo da pesquisa em andamento, os resultados satisfatórios na detecção automatizada de sistemas de GcR demonstrados no presente estudo dão respaldo para a continuidade da pesquisa, uma vez que o algoritmo treinado com os bancos de imagens artificiais teve grande êxito na detecção de sistemas de GcR em imagens coletadas em canteiros de obras.

5 CONSIDERAÇÕES FINAIS

A presente pesquisa explorou o desempenho de algoritmo de AP na detecção de sistema de GcR a partir do treinamento com diferentes bancos de imagens. O banco de imagens originais foi coletado em canteiros de obras com uso de RPA. A partir dele, foram gerados três bancos de imagens artificiais com uso de técnicas de DA (zoom, rotação e cisalhamento). O desempenho do algoritmo treinado com diferentes bases de imagens artificiais foi superior àquele treinado com o banco de imagens originais, indicando que as imagens geradas por DA contribuíram substancialmente para o aperfeiçoamento do desempenho do sistema de detecção de GcR. Dá-se destaque às técnicas de cisalhamento e rotação, que apresentaram os melhores desempenhos em termos de precisão, *recall* e F1 na etapa de teste dos modelos. Além dos ganhos de aperfeiçoamento do sistema de detecção de GcR, o uso de técnicas de DA pode contribuir com a diminuição do número de visitas para coleta de imagens de treinamento em canteiros de obras, uma vez que parte dessas imagens podem ser geradas artificialmente.

Enquanto limitações do presente estudo, tem-se o tamanho dos bancos de imagens de treinamento, que foi restrito à coleta em dois canteiros de obras. Nesse sentido, sugere-se para trabalhos futuros a ampliação do banco de imagens, incorporando novos sistemas de GcR metálicos com diferentes cores/configurações. Por fim, os resultados promissores na detecção de sistemas de GcR em canteiro de obras observados neste estudo evidenciam a possibilidade de continuidade dessa pesquisa, aperfeiçoando o algoritmo de AP não apenas para a detecção do GcR, mas também de problemas em sistemas de GcR que comprometam a segurança do trabalhador, como a ausência de GcR e espaçamento entre as grades, entre outros elencados na literatura.

6 AGRADECIMENTOS

Ao Ministério da Educação por meio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa de doutorado ao primeiro autor e de pós-doutorado à quarta autora e à Fundação de Amparo à Pesquisa do Estado da Bahia (FABESB) pela concessão de bolsa de Iniciação Científica à segunda autora do trabalho. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de recursos financeiro (Projeto 402380/2021-5). À empresa MRV Engenharia pelo apoio financeiro.

REFERÊNCIAS

- AKINOSHIO, T. D.; OYEDELE, L. O.; BILAL, M.; AJAYI, A. O.; DELGADO, M. D.; AKINADE, O. O.; AHMED, A. A. Deep learning in the construction industry: A review of present status and future innovations. **Journal of Building Engineering**, vol. 32, 1 nov. 2020. <https://doi.org/10.1016/j.jobbe.2020.101827>.
- BARUFFI, D.; COSTELLA, M. F.; PRAVIA, Z. M. C. Experimental Analysis of Guardrail Structures for Occupational Safety in Construction. **The Open Construction and Building Technology Journal**, vol. 15, nº 1, p. 141–151, 25 nov. 2021. <https://doi.org/10.2174/1874836802115010141>.
- BORGES, C. M.; PEINADO, H.S. Equipamentos de Proteção Coletiva: especificações técnicas e diretrizes de projeto. In: Peinado, H.S. (Ed.), **Segurança e Saúde do Trabalho na Indústria da Construção Civil**. São Carlos: Ed. Scienza, 2019.
- BROWNLEE, J. **Deep Learning for Computer Vision: Image Classification, Object Detection and Face Recognition in Python**. Machine Learning Mastery, 2019.
- BRASIL. Ministério do Trabalho. **NR-18 – Segurança e saúde no trabalho na indústria da construção**. Brasília: MTb, 2020.
- BRASIL. Ministério do Trabalho. **NR-35 – Trabalho em altura**. Brasília: MTb, 2022.
- CHOLLET, F.; ALLAIRE, J.J. **Deep Learning with R**. Shelter Island: Manning, 2018.
- COSTA, D.B.; GHEISARI, M.; ALARCÓN, L.F. UAS applications to support Lean Construction implementation. In: GONZÁLEZ, V. A.; HAMZEH, F.; ALARCÓN, L.F. (Eds.) **Lean Construction 4.0: Driving a Digital Revolution of Production Management in the AEC Industry**. New York: Routledge, 2023. <https://doi.org/10.1201/9781003150930>
- FANG, W.; LOVE, P. E.D.; LUO, H.; DING, L. Computer vision for behaviour-based safety in construction: A review and future directions. **Advanced Engineering Informatics**, vol. 43, 1 jan. 2020. <https://doi.org/10.1016/j.aei.2019.100980>.
- KOLAR, Z.; CHEN, H.; LUO, X. Transfer learning and deep convolutional neural networks for safety guardrail detection in 2D images. **Automation in Construction**, vol. 89, p. 58–70, 1 maio 2018. <https://doi.org/10.1016/j.autcon.2018.01.003>.
- NADHIM, E. A.; HON, C.; XIA, B.; STEWART, I.; FANG, D. Falls from height in the construction industry: A critical review of the scientific literature. **International Journal of Environmental Research and Public Health**, vol. 13, nº 7, 1 jul. 2016. <https://doi.org/10.3390/ijerph13070638>.
- OTTONI, A. L. C.; NOVO, M. S.; COSTA, D. B. Deep Learning for Vision Systems in Construction 4.0: A Systematic Review. **Signal, image and video processing**, 2022.
- OTTONI, A. L. C.; AMORIM, R.M.; NOVO, M. S.; COSTA, D. B. Tuning of *data augmentation* hyperparameters in deep learning to building construction image classification with small datasets. **International Journal of Machine Learning and Cybernetics**, v. 14, n. 1, p. 171–186, 1 jan. 2023.
- PEINADO, H.S. Segurança e Saúde do Trabalho na Indústria da Construção Civil. In: Peinado, H.S. (Ed.), **Segurança e Saúde do Trabalho na Indústria da Construção Civil**. São Carlos: Ed. Scienza, 2019.
- PEINADO, H.S.; MELO, R.R.S.; SANTOS, M.C.F.; COSTA, D.B. Potential application of Deep Learning and UAS for guardrail safety inspections. Annual Conference of the International Group for Lean Construction, 31., 2023, Lille. **Anais [...] IGLC**, 2023.
- PEJČINOVIĆ, M. A Review of Custom Vision Service for Facilitating an Image Classification. In: Central European Conference on Information and Intelligent Systems, 30, 2019. **Anais [...]**, 2019.
- PHAM, H.T.T.L.; RAFIEZONOOZ, M.; HAN, S.; LEE, D. E. Current status and future directions of deep learning applications for safety management in construction. **Sustainability (Switzerland)**, vol. 13, nº 24, 1 dez. 2021. <https://doi.org/10.3390/su132413579>.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on Image Data Augmentation for Deep Learning. **Journal of Big Data**, vol. 6, nº 1, 1 dez. 2019. <https://doi.org/10.1186/s40537-019-0197-0>.
- STAFFA, L.; NOGUEIRA, J.; LIMA, M.; OTTONI, A.; COSTA, D. B.; NOVO, M. Data augmentation approach in detecting roof pathologies with UASs images. In: IOP Conference Series: Earth and Environmental Science, 1101, 2022 **Anais [...]** Institute of Physics, 2022. <https://doi.org/10.1088/1755-1315/1101/9/092002>.

ZERMANE, A.; MOHD TOHIR, M. Z.; ZERMANE, H.; BAHARUDIN, M. R.; MOHAMED YUSOFF, H. Predicting fatal fall from heights accidents using random forest classification machine learning model. **Safety Science**, vol. 159, 1 mar. 2023. <https://doi.org/10.1016/j.ssci.2022.106023>.

ZLATAR, T.; LAGO, E. M. G.; SOARES, W. A.; BAPTISTA, J. S.; BARKOKÉBAS JUNIOR, B. Falls from height: Analysis of 114 cases. **Production**, vol. 29, 2019. <https://doi.org/10.1590/0103-6513.20180091>.