

Digitalização de informação na inspeção remota de estruturas de betão armado com recurso a inteligência artificial

<https://doi.org/10.21814/uminho.ed.32.39>

**Eurico Carola¹, Ricardo Santos², Diogo Ribeiro^{2,1},
Gustavo Nina³, Rafael Cabral⁴, Nuno Pinto⁴**

¹ *Conduril – Engenharia SA, Ermesinde*

² *CONSTRUCT-LESE, ISEP/ISEPBIM, Porto*

³ *ISEP, Porto*

⁴ *CONSTRUCT-LESE, FEUP, Porto*

Resumo

O presente artigo descreve o desenvolvimento de uma metodologia eficiente de identificação de fissuras em estruturas de betão armado com recurso a UASs e a técnicas de inteligência artificial de processamento de imagem. A metodologia possibilita a deteção e caracterização dimensional das fissuras, nomeadamente do seu desenvolvimento e abertura, com recurso a redes neuronais convolucionais por regiões (R-CNN) e algoritmos dedicados, desenvolvidos em Matlab[®]. A rede neuronal foi baseada numa extensa base de dados, com cerca de 86000 imagens, e apresentou um índice de fiabilidade próximo dos 99%. A metodologia foi aplicada à inspeção remota da fachada exterior do edifício F do campus do ISEP onde foi possível identificar diversas fissuras com dimensões que atingiram 0,3 mm. A informação digital recolhida servirá de base para o planeamento mais eficiente das operações de manutenção da infraestrutura incluindo eventuais trabalhos de reparação ou reforço.

1. Introdução

A digitalização da informação proveniente de inspeções de estruturas de betão armado, é ainda, em muitas situações, um desafio para os inspetores. Atualmente novos meios tecnológicos de inspeção remota estão disponíveis particularmente o recurso a veículos aéreos não tripulados (UAS) e sistemas avançados de vídeo. Além disso, novas técnicas baseadas em inteligência artificial têm possibilitado a identificação automática e eficiente de anomalias estruturais.

No que diz respeito as técnicas baseadas em Inteligência Artificial (IA) [1], algoritmos de aprendizagem profunda (*deep learning*) são amplamente utilizados em visão computacional e mais especificamente na classificação de imagens. Neste domínio os algoritmos mais utilizados são as Redes Neurais Convolucionais (CNNs) [2], nomeadamente as baseadas em Regiões (R-CNN), que têm demonstrado resultados promissores na deteção e caracterização de anomalias sobretudo de fissuras.

Cha et al. [3] propuseram uma metodologia baseada em R-CNN para a deteção automática de fissuras. Para isso utilizaram uma base de dados de 40,000 imagens de betão intacto e fissurado, e registaram uma taxa de sucesso de classificação de 97,95%. Li e Zhao [4] analisaram o desempenho de cinco modelos de *deep learning* na deteção e localização de fissuras em estruturas de betão tendo concluído que existe uma relação direta entre a precisão do modelo e a qualidade e dimensão da base de dados. No entanto, o aumento da dimensão da base de dados sem a necessária variabilidade das características das imagens degradou o desempenho dos modelos. Também a criteriosa definição dos hiperparâmetros dos modelos demonstrou ser decisiva para alcançar maiores taxas de sucesso.

Além da deteção de fissuras, também é possível realizar a sua caracterização, nomeadamente em termos da aferição do seu desenvolvimento e abertura, recorrendo a técnicas de processamento heurístico de imagens [5]. Geralmente, estas características são diretamente medidas na unidade do píxel e facilmente convertidas para o sistema métrico conhecida a resolução da imagem [6].

Mais recentemente, novos meios tecnológicos foram introduzidos nas inspeções remotas, nomeadamente os sistemas UAS com sistemas de visão computacional [7, 8]. Estes sistemas acoplados demonstraram ser competitivos em estruturas localizadas em áreas extensas e/ou de difícil acesso, permitindo uma redução considerável dos custos e tempos de execução, uma vez que requerem menos pessoal técnico. No entanto, o desempenho das ferramentas de processamento de imagens digitais depende muito das condições de aquisição das imagens, tais como [9]: o ângulo de captura, distorção, as condições meteorológicas e a eventual presença de poeiras nas superfícies.

Este artigo apresenta desenvolvimentos recentes sobre a digitalização da informação de inspeções remotas baseadas em técnicas de visão computacional e UAS. É da

especial atenção ao desenvolvimento e aplicação de uma metodologia robusta capaz de detetar e caracterizar fissuras em estruturas de betão armado.

2. Metodologia de inspeção remota com recurso a drones e IA

A metodologia proposta para a inspeção remota baseada em UAS compreende quatro fases distintas, conforme indicado na Figura 1, nomeadamente: 1) reconhecimento da estrutura e preparação do voo; 2) recolha de imagens utilizando UAS, 3) processamento das imagens com recurso a CNNs e/ou técnicas heurísticas, e 4) a digitalização da informação com integração BIM.

A fase 1 de reconhecimento e preparação envolve: *i)* a recolha de elementos do projeto e a investigação do histórico de inspeção da estrutura-alvo *ii)* visita ao local para avaliar as condições e possíveis fatores de risco (obstáculos ao voo, exposição ao vento, interferências eletromagnéticas, etc.), *iii)* obtenção de licenças de voo das autoridades nacionais competentes *iv)* seleção do pessoal técnico e equipamento de voo (UAS, câmara, etc.), *v)* elaboração de um plano de voo, incluindo a definição de zonas de aterragem/descolagem, o tempo de voo, a estratégia de recolha de imagens e a proximidade do UAS ao alvo.

A fase 2, de recolha de imagens com UAS, envolve, numa primeira etapa, um levantamento topográfico de precisão de alguns pontos de controlo da estrutura, i.e, alvos auxiliares e/ou pontos notáveis da estrutura. Esta etapa é essencial para a georreferenciação e calibração das imagens recolhidas. Numa segunda etapa, as imagens são captadas com um UAS equipado com uma câmara vídeo. A recolha de imagens deve ser feita com segurança, o mais próximo possível da estrutura, uma vez que distâncias mais curtas melhoram a resolução da imagem.



Figura 1
Metodologia para inspeção remota.

A fase 3 envolve a deteção e identificação automática de fissuras na superfície do betão, com base em CNNs ou técnicas heurísticas. As imagens georreferenciadas podem ainda ser usadas para realizar uma reconstituição geométrica 3D da estrutura por aplicação de técnicas de fotogrametria disponíveis no Pix4Dmapper®, ou para a realização de ortofotos por aplicação do Microsoft Image Composite Editor®.

Por último, a fase 4 consiste na integração da imagem com as patologias identificadas no modelo BIM, e envolve duas fases: i) a incorporação da máscara associada a uma determinada patologia no modelo BIM desenvolvido na plataforma Autodesk Revit, e ii) a quantificação de indicadores de dano com base nas medições efetuadas diretamente a partir das imagens. A imagem com as patologias marcadas é incluída no modelo BIM através do software Autodesk Navisworks.

3. Identificação automática de fissuras com recurso a CNNs

3.1. Aspectos gerais

No processo de criação de uma CNN estável e eficiente, dois passos essenciais devem ser realizados: i) a constituição de um *dataset* de imagens, ii) o treino e validação do modelo.

A qualidade do *dataset* é crucial no desenvolvimento de uma CNN e deve cobrir o maior número de cenários reais possíveis. Por sua vez, o modelo de *deep learning* utilizado baseou-se no conceito de *transfer-learning*, i.e., na adaptação de um modelo pré-treinado ao problema da identificação de fissuras, neste caso o modelo *AlexNet*. Os parâmetros de treino têm muita influência na eficiência do modelo, sobretudo a definição da percentagem do *dataset* reservada para validação, da taxa de aprendizagem, do número máximo de *epochs* e do tamanho do *batch* [3]. No processo de validação são calculadas métricas que permitem avaliar a qualidade do modelo treinado, nomeadamente a *accuracy*, *precision*, *recall* e *F1 score* [3]. Caso os valores das métricas descrevam um modelo deficiente será necessário retrainar o modelo após melhorar o *dataset* e/ou alterar os parâmetros de treino.

Na Figura 2 ilustra-se a metodologia de deteção e caracterização de fissuras em estruturas de betão. Nas secções seguintes serão detalhados os algoritmos inerentes à metodologia.

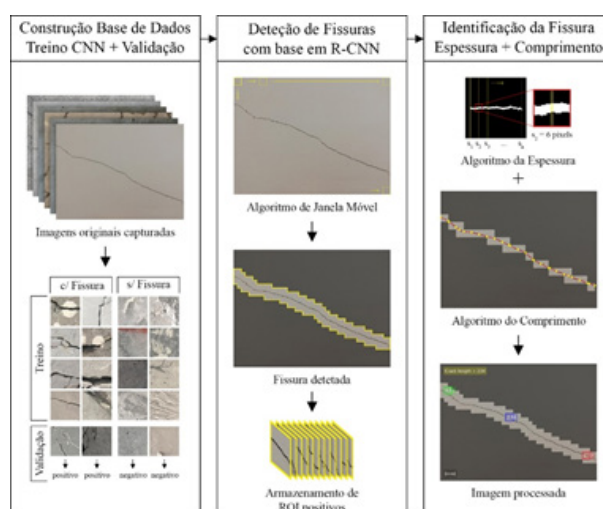


Figura 2
Metodologia de deteção e caracterização de fissuras.

3.2. Base de dados de imagens

Na Figura 3 ilustra-se esquematicamente o processo de desenvolvimento do *dataset* de imagens que pode ser dividido em três etapas.

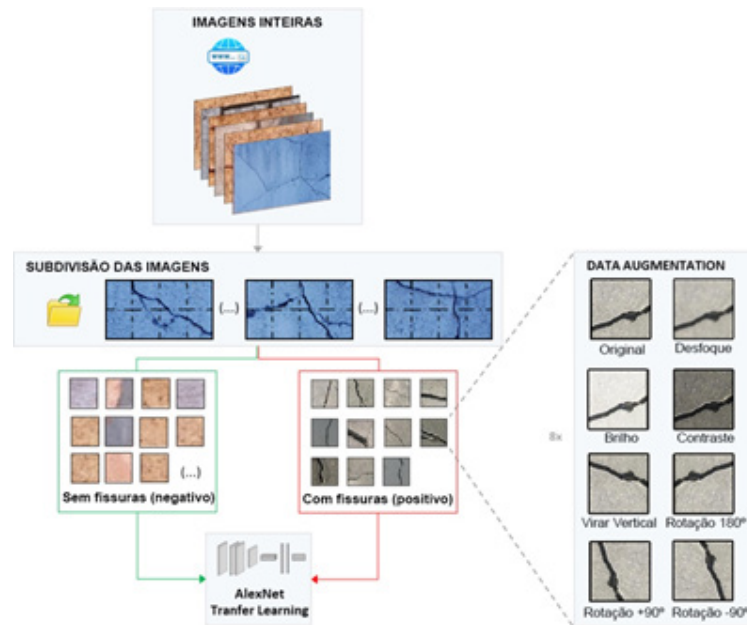


Figura 3
Fluxograma de desenvolvimento do *dataset* de imagens.

Inicialmente, foi realizada uma pesquisa Web extensiva com o objetivo de recolher o maior número de imagens de superfícies de betão fissuradas e não fissuradas. Seguidamente, foi aplicado um *script* desenvolvido em ambiente MATLAB® para subdividir as imagens obtidas em 227×227 píxel considerando uma sobreposição de 50% de modo a conseguir-se o melhor aproveitamento das imagens. Finalmente, é aplicada uma técnica de *data augmentation* que consiste no aumento da base de dados recorrendo a transformações geométricas das imagens, nomeadamente, filtros de *blur*/desfoque, alterações no brilho e contraste, rotação e espelho, etc.

3.3. Treino e validação

O treino da CNN foi executado em ambiente MATLAB®, mais especificamente através da *Deep Learning Toolbox*. Dos diversos modelos pré-treinados disponíveis nesta *Toolbox* foi escolhido o *AlexNet* devido à sua flexibilidade e velocidade de treino. O *AlexNet* está configurado para classificar 1000 categorias, por isso foi necessário alterar os últimos *layers* da arquitetura do modelo de forma a torná-lo um classificador binário: superfície com fissura (positivo) e superfície sem fissura (negativo). O *dataset* de imagens foi dividido de modo a que 80% das imagens foram usadas no treino, enquanto os restantes 20% foram reservados para a validação. O treino durou cerca de 8 h num computador com processador Intel I7-10510U @ 1,80GHz, placa gráfica Nvidia GeForce MX250, *motherboard* Asus H110M-K, RAM HyperX Fury DDR4 8GB (2400MHz) e sistema operativo Windows 10 64-bit. Após o treino, foi efetuada

uma avaliação do modelo com recurso ao cálculo das métricas de validação, sendo que os valores da *accuracy*, *precision*, *recall* e *F1-score* foram iguais a 97.7%, 98.3%, 97.5% e 98.1%, respetivamente. A Figura 4 ilustra esquematicamente o processo de treino e validação.

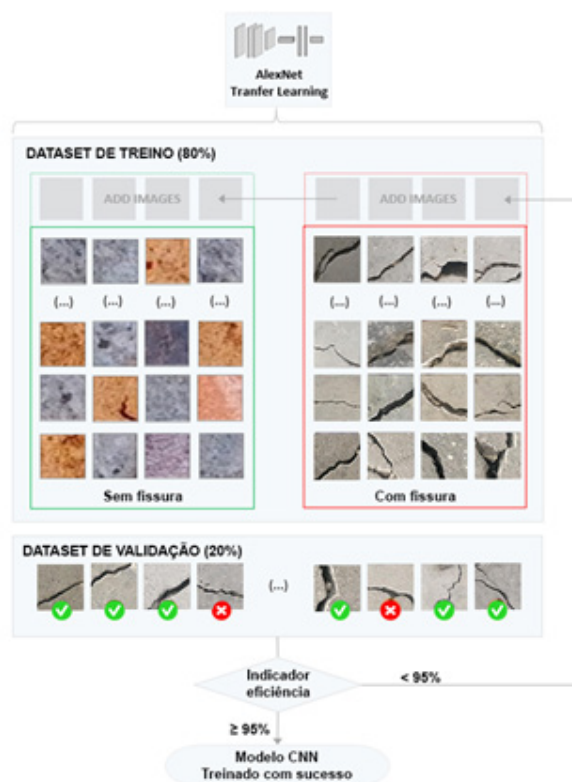


Figura 4
Fluxograma de treino e validação.

3.4. Algoritmos de caracterização da espessura e desenvolvimento

A caracterização da fissura consiste em analisar dois fatores: as espessuras em diversos pontos e o desenvolvimento da fissura ao longo da superfície. Para tal, foram desenvolvidos dois algoritmos com base em métodos heurísticos de processamento de imagem. Na base da caracterização está a deteção da fissura realizada pelo modelo CNN, e a sua robustez é fulcral na credibilidade dos resultados. Ao longo da deteção são guardados todos os ROIs (*Regions Of Interest*) classificados como positivos. Esses mesmos ROIs positivos são depois processados e caracterizados um a um tal e qual está detalhado na Figura 5. No final, é exportada a imagem com os valores calculados pelos algoritmos.

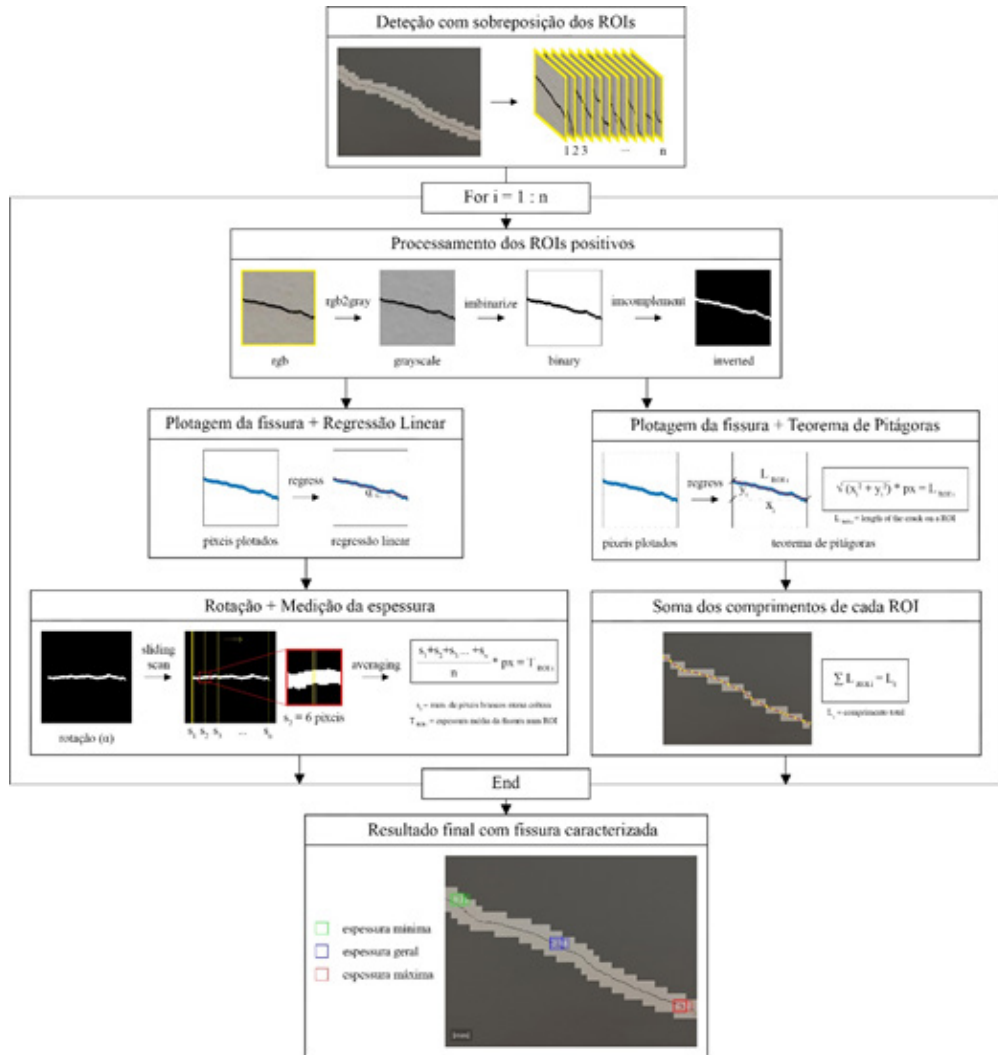


Figura 5
 Algoritmo heurístico de caracterização de fissuras.

4. Caso de estudo: edifício F do campus ISEP

4.1. Descrição do edifício

O edifício F do Campus do ISEP tem uma área de implantação de 2635 m² e uma área utilizável de 13432 m² distribuída por 5 pisos acima da cota soleira e um piso enterrado. A fachada leste do edifício (Figura 6) apresenta fendilhação evidente e distribuída em praticamente toda a sua extensão, desde o piso térreo até ao último piso, por razões possivelmente associadas a assentamentos das fundações. A parte da parede estudada corresponde à zona em alvenaria de tijolo com acabamento em reboco e pintura, por oposição a uma zona revestida com painéis de pedra natural, onde a fissuração não aparece tão evidente. Nestas circunstâncias a utilização de meios de inspeção remota é vantajosa uma vez que a fachada não facilita a utilização de meios mecânicos ou instalação de andaimes.



Figura 6
Vista da fachada leste do edifício F, objeto da inspeção remota.

4.2. Equipamento

A Figura 7 ilustra as especificações técnicas do drone Matrice 600 Pro do fabricante DJI, das câmaras fotográficas e do laser ótico que foram utilizados enquanto componentes do sistema de inspeção remota.



Figura 7
Descrição dos principais componentes do sistema.

O DJI Matrice 600 Pro é um hexacóptero com uma massa máxima recomendada de decolagem de 15,5 kg, uma velocidade horizontal máxima de 65 km/h, uma altura máxima de serviço de 2500m acima do nível do mar e uma autonomia estimada de voo de aproximadamente 32 min (por conjunto de baterias). A câmara instalada no drone é do modelo DJI Zenmuse X5 estabilizada por um *gimbal*, possui um sensor CMOS de 4/3" e uma resolução de 16 MPx. O *gimbal* garante a estabilização da imagem ao longo dos três eixos. A visualização das imagens e o controlo remoto do drone foram realizados através de um monitor táctil de alta resolução, o DJI Crystal Sky, com capacidade interna de armazenamento de imagens. Acoplado ao drone existe um laser ótico capaz de medir distâncias de 0.3m a 12m, com uma taxa de amostragem de 8 Hz, resolução de 0.01m e sincronizado com o relógio através de uma ligação Wifi ao telemóvel. A estimativa da distância entre o plano da câmara e o objeto é essencial para a avaliação precisa de distâncias em imagens e deste modo aferir o desenvolvimento e a abertura de eventuais fissuras.

4.3. Resultados

A identificação automática das fissuras da fachada do edifício foi realizada com base em imagens captadas em zonas acessíveis e em zonas não-acessíveis da fachada.

A – Zonas acessíveis

As captações de imagens em zonas acessíveis da fachada, nomeadamente ao nível do piso térreo, tiveram como objetivo a validação da metodologia de identificação automática de fissuras. Em particular, foi realizada uma comparação dos resultados obtidos através das imagens recolhidas pelo UAS e os algoritmos dedicados de identificação de fissuras com os resultados de uma aferição manual das dimensões das fissuras. Na Figura 8 apresenta-se a comparação das dimensões de uma fissura aferida pelas abordagens manual (Figura 8a e 8b) e automática (Figura 8c). A abordagem manual envolveu o decalque das fissuras com recurso a papel vegetal e lápis (Figura 8a), a digitalização do decalque e a sua modelação precisa no programa AutoCAD (Figura 8b). Conforme se pode verificar as estimativas das dimensões obtidas através da abordagem manual (desenvolvimento e espessura média iguais a 379,6mm e 0,76mm respetivamente) e da abordagem automática (desenvolvimento e espessura média iguais a 376mm e 0,77mm respetivamente) são muito similares. A consistência dos resultados obtidos permitiu validar em ambiente operacional a metodologia de identificação automática de fissuras.

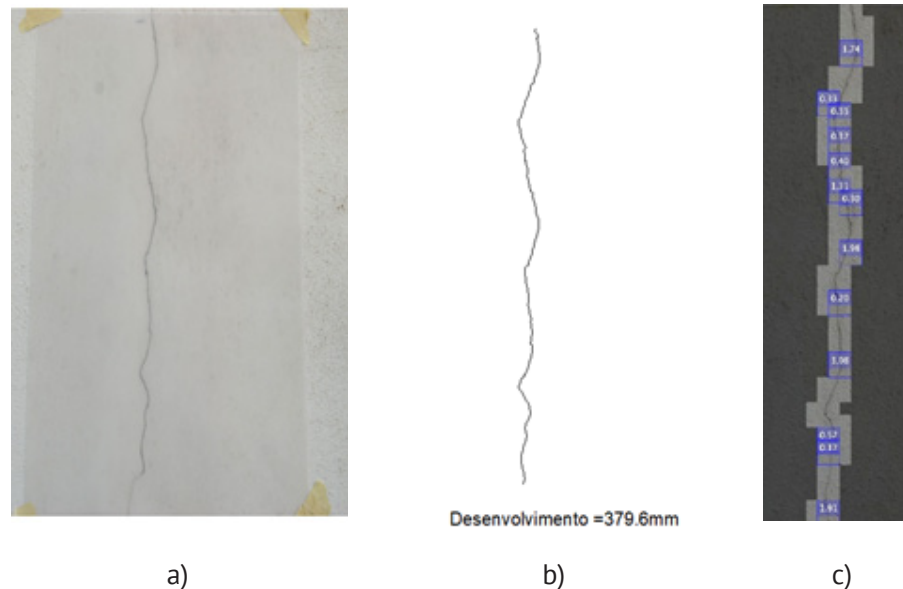


Figura 8
Identificação de fissura com base nas abordagens manual e automática: a) marcação da fissura; b) digitalização da fissura; c) algoritmo automático de identificação.

B – Zonas não-acessíveis

A obtenção das imagens nas zonas não-acessíveis foi direcionada para regiões específicas (ZF) onde se encontram as fissuras. Na Figura 9 encontram-se assinaladas duas regiões da fachada (ZF1 e ZF2) onde será aplicada a metodologia de identificação

automática de fissuras. Neste estudo o UAS voou a uma distância constante de 5 m da fachada e considerando o plano da câmara de vídeo paralelo ao plano da fachada de modo a serem obtidas ortofotos georreferenciadas [7].




Figura 9
Regiões alvo (ZF1 e ZF2) da identificação automática de fissuras.

Na Figura 10 ilustra-se a aplicação da metodologia de identificação automática das fissuras presentes nas regiões ZF1 (Figura 10a) e ZF2 (Figura 10b).




Figura 10
Metodologia de identificação automática das fissuras (fotografia – à esquerda; algoritmo de detecção – ao centro; resultado da aplicação do algoritmo de identificação – à direita): a) ZF1; b) ZF2.

Na região ZF1 foi identificada uma fissura com um desenvolvimento igual a 1241mm e uma abertura variável entre os 1,83mm e 3,20mm. Por sua vez, na região ZF2 foi identificada uma fissura com um padrão aproximadamente circular com um desenvolvimento total igual a 8332mm e uma abertura variável entre os 2,01mm e 8,73mm. Os valores obtidos demonstram que as fissuras nestas regiões, sobretudo na região ZF2, já se encontram num grau de desenvolvimento muito considerável.

6. Conclusões

O presente artigo descreveu uma metodologia inteligente para a digitalização da informação de inspeções remotas com incidência na identificação de fissuras baseada em inteligência artificial. A metodologia proposta assenta numa rede neuronal convolucional por regiões (R-CNN), para a deteção das fissuras, complementada por técnicas heurísticas de processamento de imagens, para a caracterização do desenvolvimento e abertura das fissuras. A metodologia desenvolvida foi aplicada à identificação das fissuras da fachada de um edifício escolar. Os resultados demonstraram a sua eficiência e robustez na identificação de fissuras com distintos desenvolvimentos e aberturas de apenas 0,17mm. A validação da metodologia automática de identificação foi realizada com sucesso através da comparação do seu desempenho com uma abordagem manual baseada no decalque e medição de fissuras em zonas acessíveis da fachada.

Referências

- [1] Z. Liu, Y. Cao, Y. Wang, W. Wang “Computer vision-based concrete crack detection using U-net fully convolutional networks”, *Automation in Construction*, vol. 104, pp. 129-139, 2019. doi: 10.1016/j.autcon.2019.04.005.
- [2] S. Sony, K. Dunphy, A. Sadhu, M. Capretz “A systematic review of convolutional neural network-based structural condition assessment techniques”, *Engineering Structures*, vol. 226, pp. 111347, 2021. doi: 10.1016/j.engstruct.2020.111347.
- [3] Y. Cha, W. Choi, O. Büyüköztürk “Deep learning-based crack damage detection using convolutional neural networks”, *Computer-Aided Civil and Infrastructure Engineering*, vol. 32(5), pp. 361-378, 2017. doi: 10.1111/mice.12263.
- [4] S. Li, X. Zhao “Image-based concrete crack detection using convolutional neural network and exhaustive search technique”, *Advances in Civil Engineering*, vol. 2019, pp. 6520620, 2019. doi: 10.1155/2019/6520620
- [5] H. Qin, F. Huang, B. Cheng “Crack identification and measurement of bridges by using CNN models”, *In Bridge Maintenance, Safety, Management, Life-Cycle Sustainability and Innovations*, Ed. 1, pp. 123-128, 2021. doi: 10.1201/9780429279119-12
- [6] H. Kim, E. Ahn, S. Cho, M. Shin, S. Sim “Comparative analysis of image binarization methods for crack identification in concrete structures”, *Cement and Concrete Research*, vol. 99, pp. 53-61, 2017. doi: 10.1016/j.cemconres.2017.04.018
- [7] D. Ribeiro, R. Santos, A. Shibasaki, P. Montenegro, H. Carvalho, R. Calçada “Remote inspection of RC structures using unmanned aerial vehicles and heuristic image processing”, *Engineering Failure Analysis*, vol. 117, pp. 104813, 2020, doi: 10.1016/j.engfailanal.2020.104813.

- [8] D. Ribeiro, R. Santos, R. Cabral, A. Shibasaki “Remote Inspection and Monitoring of Civil Engineering Structures Based on Unmanned Aerial Vehicles”, *1st International Conference of the European Association on Quality Control of Bridges and Structures*, Springer, pp. 695-703, 2021, doi: 10.1007/978-3-030-91877-4_79.
- [9] Z. Ameli, Y. Aremanda, W. A. Friess, E. N. Landis “Impact of UAV Hardware Options on Bridge Inspection Mission Capabilities”, *Drones*, vol. 6(3), p. 64, 2022. doi: 10.3390/drones6030064.