





INSPEÇÃO DE ESTRUTURAS DE BETÃO ARMADO COM BASE EM VEÍCULOS AÉREOS NÃO TRIPULADOS E PROCESSAMENTO SUPERVISIONADO DE IMAGEM

PAULO ALEXANDRE COELHO LOPES

novembro de 2020



INSPEÇÃO DE ESTRUTURAS DE BETÃO ARMADO COM BASE EM VEÍCULOS AÉREOS NÃO TRIPULADOS E PROCESSAMENTO SUPERVISIONADO DE IMAGEM

PAULO ALEXANDRE COELHO LOPES
Outubro de 2020



**INSPEÇÃO DE ESTRUTURAS DE BETÃO ARMADO COM BASE EM VEÍCULOS
AÉREOS NÃO TRIPULADOS E PROCESSAMENTO SUPERVISIONADO DE
IMAGEM**

PAULO ALEXANDRE COELHO LOPES

Dissertação submetida para satisfação parcial dos requisitos do grau de

MESTRE EM ENGENHARIA CIVIL – RAMO DE ESTRUTURAS

Orientador: Prof. Diogo Rodrigo Ferreira Ribeiro (ISEP-IPP)

Co-Orientador: Prof. Ricardo Manuel Pereira Santos (ISEP-IPP)

OUTUBRO DE 2020

ÍNDICE GERAL

Índice Geral	iii
Resumo.....	v
Abstract	vii
Agradecimentos	ix
Índice de Texto	xi
Índice de Figuras.....	xiii
Índice de Tabelas.....	xvii
Abreviaturas	xix
CAPÍTULO 1 Introdução.....	1
CAPÍTULO 2 Anomalias e patologias nas construções em betão armado	3
CAPÍTULO 3 Técnicas automatizadas de inspeção visual de estruturas	17
CAPÍTULO 4 Técnicas de processamento de imagem	23
CAPÍTULO 5 Ferramentas de deteção de fissuras e armaduras expostas.	37
CAPÍTULO 6 Casos de Estudo	49
CAPÍTULO 7 Considerações Finais.....	77
Referências Bibliográficas	79
Anexo I – Opções de treino da rnc – 2 categorias.....	85
Anexo II – Opções de treino da rnc – 3 categorias.....	86
Anexo III – <i>Sliding window</i>	87
Anexo IV – Pré-processamento de imagens – abordagem 1	89
Anexo V – Pré-processamento de imagens – abordagem 2	90

RESUMO

A presente dissertação tem como objetivos o desenvolvimento de ferramentas e procedimentos para a detecção de anomalias em estruturas de betão armado de forma semi automatizada recorrendo a técnicas de *Deep Learning*. Das várias anomalias que podem ser encontradas em estruturas de betão armado, destacam-se neste documento as fissuras e as armaduras expostas, para as quais foi desenvolvido um método alternativo de inspeção, baseado no processamento avançado de imagens, de modo a determinar se seria viável e vantajosa a substituição deste método pelo método de inspeção visual tradicional. As ferramentas desenvolvidas assentam em técnicas de Inteligência Artificial, em particular as redes neuronais convolucionais (RNC), mais concretamente na utilização do *transfer learning* recorrendo à RNC Alexnet. Foram conduzidas experiências em diversas construções de modo a aferir a eficiência do método, recorrendo a veículos aéreos não tripulados (VANT), e em condições de acesso condicionado. Os resultados obtidos mostram ser bastante promissores, sendo previsível que do aprimoramento do método, possa resultar na adoção desta tecnologia como auxiliar nas inspeções visuais num futuro próximo.

Palavras-chave: Inspeção, Anomalias, Betão armado, *Deep-Learning*, Processamento de imagem, Redes Neuronais Convolucionais (RNC), Veículos aéreos não tripulados.

ABSTRACT

This dissertation aim is to develop tools and procedures for the detection of anomalies in reinforced concrete structures in a semi-automated way using Deep-Learning techniques. Of the various anomalies that can be found in reinforced concrete structures, this document highlights the exposed rebars and cracks, for which an alternative inspection method was developed, based in advanced image processing, in order to determine whether it would be feasible and advantageous to replace this method with the traditional visual inspection method. The tools developed are based on artificial intelligence techniques, in particular, convolutional neural networks (CNN), more specifically in the use of transfer-learning using the CNN Alexnet. Experiments were conducted in several constructions in order to assess the efficiency of the method, using unmanned aerial vehicles (UAV), under conditions of conditioned access. The results show to be quite promising, and it is foreseeable that its improvement may result in the adoption of this technology for aid in visual inspections in the near future.

Keywords: Inspection, Anomalies, Reinforced concrete, Deep-Learning, Image processing, Convolutional Neural Networks (CNN), Unmaned Aerial Vehicles

AGRADECIMENTOS

Aos Engenheiros Diogo Ribeiro e Ricardo Santos pela orientação e apoio facultados no desenvolvimento desta dissertação.

Aos meus colegas, Gustavo Nina, Anderson Shibasaki e Hélio Teixeira pela ajuda prestada no desenvolvimento dos algoritmos necessários á concretização do trabalho, e pelo fornecimento de imagens para os casos de estudo.

Ao Sr. Manuel Moreira da Imotâmega por ter facilitado o acesso ao edifício localizado em Marco de Canaveses

À Sr.ª Manuela Faria do Grupo Prime, por interceder junto dos proprietários do complexo industrial de Vila do Conde para que a captação de imagens fosse possível, e também aos proprietários por deferirem o pedido.

À minha família por todo o apoio e sacrifícios que permitiram realizar o meu percurso académico.

À minha noiva Sónia Carvalho pelo incentivo, e pelas palavras de motivação que me ajudaram a levar avante o meu percurso para obtenção do grau de Mestre.

ÍNDICE DE TEXTO

CAPÍTULO 1	Introdução.....	1
1.1	Considerações Iniciais.....	1
1.2	Objetivos.....	2
1.3	Organização do trabalho.....	2
CAPÍTULO 2	Anomalias e patologias nas construções em betão armado	3
2.1	Nota histórica da construção em betão armado	3
2.2	Anomalias e patologias.....	4
CAPÍTULO 3	Técnicas automatizadas de inspeção visual de estruturas	17
3.1	Técnicas tradicionais de inspeção visual.....	17
3.2	Técnicas automatizadas com recurso a VANTs.....	19
CAPÍTULO 4	Técnicas de processamento de imagem	23
4.1	Processamento heurístico de imagem	23
4.2	Processamento de imagem baseado em machine Learning	25
4.3	Aplicação na Engenharia Civil	31
CAPÍTULO 5	Ferramentas de deteção de fissuras e armaduras expostas.	37
5.1	Pesquisa de imagens.....	38
5.2	Técnica de aumento de dados.....	42
5.3	Treino da Rede Neuronal Convolucional	43
CAPÍTULO 6	Casos de Estudo	49
6.1	Deteção de armaduras expostas	59
6.2	Deteção de Fissuras	49

ÍNDICE DE TEXTO

CAPÍTULO 7	Considerações Finais	77
7.1	Conclusões	77
7.2	Desenvolvimentos Futuros	78

ÍNDICE DE FIGURAS

Figura 2-1 - Viaduto Duarte Pacheco em Lisboa (Restos-de-coleção, 2013)	4
Figura 2-2- Grupos de Anomalias	5
Figura 2-3- Causas de deterioração no betão armado.....	6
Figura 2-4 - Fissuras por assentamento plástico (civilblog, 2020)	7
Figura 2-5- Fissuras por retração plástica (Constrofacilator, 2020).....	7
Figura 2-6 - Fissuras por retração (Rodrigues, 2019)	8
Figura 2-7 - Fissuras por variação de temperatura (Theconstructor,2019)	9
Figura 2-8 – Erros de projeto ou construção (adaptado de E-Civil, 2020)	10
Figura 2-9 - Fissuração por assentamentos diferenciais (Inspectapedia,2017)	11
Figura 2-10 - Fissuração por cargas excessivas (Souza,1998)	11
Figura 2-11 – Ciclo gelo-degelo (adaptado de RainGuard, 2017)	12
Figura 2-12 – Fissuração devido a reação alcalis-sílica (BlogLPE, 2020)	13
Figura 2-13 – Fissuras devido a cristalização de sais (Dreamstime, 2020).....	13
Figura 2-14 - Processo de corrosão (Costa, 1999).....	14
Figura 2-15 – Armadura exposta por destacamento do betão de recobrimento.....	15
Figura 3-1 – Exemplo de ficha de inspeção	18
Figura 3-2 – Métodos de inspeção visual de estruturas	19
Figura 3-3 – Utilização de VANTs na inspeção de pontes (Lovelace, 2015).....	21
Figura 3-4 - Software para deteção de anomalias <i>Leica Albot</i> (LeicaGeosystems, 2020).....	22
Figura 4-1 – Exemplo de algoritmo para deteção de fissuras. (Teixeira, 2019)	24
Figura 4-2 – Aplicação de técnicas heurísticas	25

Figura 4-3 – Diferenças entre Inteligência artificial, <i>Machine Learning</i> e <i>Deep Learning</i> (Lavagnoli, 2020)	26
Figura 4-4 - Rede <i>Feed-Forward</i> na estrutura de uma rede neuronal (Medium, 2020)	27
Figura 4-5 - Exemplo de arquitetura de uma RNC (Mathworks, 2020)	28
Figura 4-6 – Exemplo de obtenção da matriz de uma imagem RGB (Stanford, 2020)	29
Figura 4-7 - Aplicação da convolução a uma imagem (Medium, 2020)	29
Figura 4-8 - Função Relu (Medium, 2020)	30
Figura 4-9 – Exemplo de aplicação da função <i>Pooling</i> (cs231n, 2020)	30
Figura 4-10 - Exemplo de aplicação da ferramenta de deteção de fissuras desenvolvida por <i>Cha et al...</i>	32
Figura 4-11 - Transformação de imagem através de técnicas de aumento de dados (Kim, 2018)	33
Figura 4-12 - Aplicação de uma janela deslizante através do método simplificado e probabilístico (Kim, 2018)	34
Figura 4-13 - Exemplo de aplicação da ferramenta de deteção de fissuras desenvolvida por <i>Kim e Cho</i> (2018)	35
Figura 5-1 – Processo de treino de uma RNC	37
Figura 5-2 – Interface do programa Photoscape (Photoscape, 2020)	39
Figura 5-3 - Recolha de imagens de armaduras expostas, Vila do Conde	40
Figura 5-4 - Recolha de imagens de armaduras expostas, Penafiel	40
Figura 5-5 - Recolha de imagens de fissuras, Marco de Canaveses	41
Figura 5-6 - Recolha de imagens de fissuras, Penafiel	41
Figura 5-7 – Transformação de imagens para aumento de dados	43
Figura 5-8 - Etapas de treino da rede Alexnet (Mathworks, 2020)	44
Figura 5-9 – Etapas de pré-processamento	46
Figura 5-10 - Imagens descartadas	46
Figura 5-11 – Esquematização do funcionamento da janela deslizante	47
Figura 5-12 – Imagem original e imagem processada	47
Figura 6-1 - Edifício F do ISEP (Flickr, 2020)	50
Figura 6-2 – Imagem 1 (Original, Fissuras, Edifício F)	51

Figura 6-3 – Imagem 1 (Abordagem 1 (RNC), Fissuras, Edifício F)	51
Figura 6-4 – Imagem 2 (Original, Fissuras, Edifício F).....	52
Figura 6-5 – Imagem 2 (Abordagem 1 (RNC), Fissuras, Edifício F)	52
Figura 6-6 - Edifício em estudo.....	53
Figura 6-7 – Imagem 1 (Original, Fissuras, Unidade Hoteleira).....	54
Figura 6-8 - Imagem 1 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)	54
Figura 6-9 - Imagem 2 (Original, Fissuras, Unidade Hoteleira)	55
Figura 6-10 - Imagem 2 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)	55
Figura 6-11 - Imagem 3 (Original, Fissuras, Unidade Hoteleira)	56
Figura 6-12 - Imagem 3 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)	56
Figura 6-13 - Imagem 4 (Original, Fissuras, Unidade Hoteleira)	57
Figura 6-14 - Imagem 4 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)	57
Figura 6-15 - Imagem 5 (Original, Fissuras, Unidade Hoteleira)	58
Figura 6-16 - Imagem 5 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)	58
Figura 6-17 - Edifício em estudo (visto da ponte de Formariz)	60
Figura 6-18 - Edifício em estudo (visto do Bairro do Rio Ave).....	60
Figura 6-19 – Estação de trabalho e zona de captação de imagens	61
Figura 6-20 - Grupo de trabalho.....	62
Figura 6-21 – Imagem 1 (Original, Armaduras expostas, Edifício industrial)	64
Figura 6-22 - Imagem 1 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)	64
Figura 6-23 - Imagem 1 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)	64
Figura 6-24 – Imagem 2 (Original, Armaduras expostas, Edifício industrial)	65
Figura 6-25 – Imagem 2 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	65
Figura 6-26 - Imagem 2 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)	65
Figura 6-27 – Imagem 3 (Original, Armaduras expostas, Edifício industrial)	66
Figura 6-28 – Imagem 3 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	66
Figura 6-29 – Imagem 3 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial).....	66

ÍNDICE DE FIGURAS

Figura 6-30 – Imagem 4 (Original, Armaduras expostas, Edifício industrial)	67
Figura 6-31 -Imagem 4 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	67
Figura 6-32 – Imagem 4 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial).....	67
Figura 6-33 – Imagem 5 (Original, Armaduras expostas, Edifício industrial)	68
Figura 6-34 – Imagem 5 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	68
Figura 6-35 – Imagem 5 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial).....	68
Figura 6-36 – Imagem 6 (Original, Armaduras expostas, Edifício industrial)	69
Figura 6-37 – Imagem 6 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	69
Figura 6-38 – Imagem 6 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial).....	69
Figura 6-39 – Imagem 7 (Original, Armaduras expostas, Edifício industrial)	70
Figura 6-40 - Imagem 7 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	70
Figura 6-41 - Imagem 7 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial).....	70
Figura 6-42 - Torre Altice (Martins, 2018)	72
Figura 6-43 – Imagem 1 (Original, Armaduras expostas, Torre Altice)	73
Figura 6-44 – Imagem 1 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	73
Figura 6-45 – Imagem 1 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Torre Altice).....	73
Figura 6-46 – Imagem 2 (Original, Armaduras expostas, Torre Altice)	74
Figura 6-47- Imagem 2 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial).....	74
Figura 6-48 – Imagem 2 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Torre Altice).....	74

ÍNDICE DE TABELAS

Tabela 4-1 – Soluções sugeridas por Kim e Cho (2018) para melhoria da RNC desenvolvida	35
Tabela 5-1 - Pesquisas efetuadas em motores de busca	38
Tabela 5-2 - Número de imagens válidas após seleção.....	38
Tabela 5-3 - Número de imagens válidas após processo de divisão	39
Tabela 5-4 - Número de imagens válidas após adição de imagens capturadas.....	42
Tabela 5-5 - Número de imagens válidas após aumento de dados	43
Tabela 5-6 – Limites da escala RGB para extração de armaduras expostas	45
Tabela 6-1 – Precisão das abordagens em estudo	71
Tabela 6-2 - Precisão das abordagens em estudo.....	75

ABREVIATURAS

EUA – Estados Unidos da América

GPS – Global Positioning System

ISEP – Instituto Superior de Engenharia do Porto

RGB – Red, Green and Blue

RNC – Rede Neuronal Convolucional

VANT – Veículo aéreo não tripulado

CAPÍTULO 1

INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

O betão armado é a nível mundial, um dos materiais mais utilizados na construção de infraestruturas, como pontes, viadutos, canais, barragens, centrais nucleares ou edifícios. Isto deve-se á sua capacidade em ser facilmente moldado á forma pretendida além da relação custo-benefício. No entanto inevitavelmente, as construções começam a sofrer de anomalias que comprometem a sua durabilidade e funcionalidade. O betão, ao contrário do que se possa pensar é um material sensível que sofre de degradação ao longo do tempo. Essa degradação advém de causas naturais, ou seja, um “envelhecimento” causado pelo meio ambiente no qual a estrutura se insere, e artificiais, causadas maioritariamente por erro humano ou negligência quer na fase de projeto, construção ou exploração da infraestruturas, gerando um “envelhecimento” precoce da estrutura. Atualmente, decorridos cerca de cem anos após a grande expansão da utilização do betão na construção, observa-se uma crescente degradação destas estruturas com o conseqüente aparecimento de anomalias.

Torna-se cada vez mais urgente o desenvolvimento de técnicas e de materiais que visem não só dotar as construções em betão armado das características mecânicas, funcionais e estéticas originais, como também prolongar o seu ciclo de vida útil. É crucial assim implementar medidas de monitorização do estado de conservação dos elementos estruturais de modo a analisar e prescrever eventuais intervenções que sejam necessárias efetuar de modo a incrementar a sua durabilidade, segurança e conforto. A realização de inspeções periódicas é imprescindível em todas as obras de Engenharia, independentemente do seu tipo de construção e deverão ser efetuadas ao longo da sua vida.

A grande maioria das Infraestruturas existentes hoje, já foram construídas no século passado, sendo que, por exemplo, nos Estados Unidos da América muitas pontes construídas entre os anos 1950 e 1960 foram concebidas para um tempo de vida útil de 50 anos e, portanto, já foram utilizadas para além da perspetiva original. Assim por estes e outros motivos observa-se um crescente número de campanhas de inspeção e manutenção em diversas obras de Engenharia Civil a nível mundial.

O acesso visual dos técnicos às estruturas é um fator determinante para a sua avaliação. Assim em estruturas de grande dimensão é necessário o uso de equipamentos adicionais para facultar esse acesso. Para além do incremento da insegurança para as equipas, isto também acarreta um acréscimo de custos. Na Europa estima-se que anualmente sejam gastos entre 4 a 6 mil milhões de euros para a manutenção de infraestruturas de betão (Silva, 2018).

Várias técnicas de processamento de imagens têm vindo a ser desenvolvidas nos últimos anos de modo a serem implementadas em infraestruturas, com o objetivo de detetar anomalias, e assim substituindo parcialmente a presença humana no local de inspeção. Com estas técnicas é possível reduzir os custos de inspeção bem como o risco de acidentes. No entanto estas técnicas são fortemente afetadas pela luminosidade e incidência solar, levando muitas vezes a resultados insatisfatórios, impedindo assim a sua adoção em larga escala (Cha et al., 2017).

1.2 OBJETIVOS

De modo a ultrapassar os problemas anteriormente referidos propõe-se o desenvolvimento de um sistema semi automático focado na deteção de fissuras e armaduras expostas em estruturas de betão armado utilizando um modelo baseado em aprendizagem automática ou *Machine Learning*. O recurso a VANTs permite capturar imagens remotamente, sendo elas posteriormente processadas pelas ferramentas criadas. O desenvolvimento deste sistema tem como objetivo aumentar a fiabilidade e o nível de automatização na inspeção de estruturas de betão armado.

1.3 ORGANIZAÇÃO DO TRABALHO

O trabalho encontra-se organizado da seguinte forma:

- No capítulo 2 são abordadas as anomalias e patologias mais comuns na construção em betão armado.
- Técnicas automatizadas de inspeção de estruturas são abordadas no capítulo 3.
- O capítulo 4 aborda as técnicas de Processamento de imagem e as suas possíveis aplicações.
- O desenvolvimento das ferramentas para deteção de fissuras e armaduras expostas encontram-se no capítulo 5.
- No capítulo 6 apresentam-se casos de estudos de forma a validar a eficiência das ferramentas desenvolvidas.
- Finalmente no capítulo 7 tecem-se as considerações finais.

CAPÍTULO 2

ANOMALIAS E PATOLOGIAS NAS CONSTRUÇÕES EM BETÃO ARMADO

2.1 NOTA HISTÓRICA DA CONSTRUÇÃO EM BETÃO ARMADO

Há milhares de anos que as argamassas e o betão são utilizados como materiais de construção, sendo à época produzidos por uma mistura de argila, areia, cascalho e água, sendo os romanos dos poucos povos que utilizavam um betão com ligantes não hidráulicos. Até ao século XVIII o betão teve uma utilização reduzida sendo maioritariamente utilizado em fundações e no interior de paredes de alvenaria. (Appleton, 2013).

O cimento como o conhecemos hoje, deve-se a Joseph Aspdin que em 1824 patenteou o cimento *Portland*, em analogia à pedra *Portland*, um calcário oolítico que é extraído, na Ilha de *Portland* em Inglaterra. O conceito de betão armado surgiu em 1849 em França quando Lambot construiu um pequeno barco com argamassa e fios de aço de pequeno diâmetro.

Em 1850 tiveram início uma série de ensaios realizados pelo norte-americano Thaddeus Hyatt, que em 1877 obteve a patente para um sistema de execução de vigas de betão armado no qual as barras metálicas previam os efeitos de tração e corte, sugerindo uso de estribos e barras dobradas. Anos depois em 1880, Hennebique construiu a primeira laje armada. Frederick Ransome concebeu em 1885 os Fornos Rotativos, o que permitiu baixar substancialmente o preço do cimento. (Appleton, 2013)

A utilização do betão armado ganhou então uma nova dinâmica, tornando-se cada vez mais popular na construção civil, potenciando o estudo das suas propriedades e criação de novas patentes.

No final do século XIX já com vários estudos publicados sobre o comportamento do betão armado, foi criada a primeira disciplina sobre o tema na *École National de Ponts et Chaussées* (ENPC) em Paris.

Em 1906 foram publicadas as primeiras instruções francesas no domínio do betão armado, que serviriam de base para o primeiro regulamento português “Instruções regulamentares para o emprego do betón armado” publicado em 1918. (Costa, 1999)

Durante a primeira metade do século XX houve um desenvolvimento notório na compreensão do funcionamento do betão armado. A sua versatilidade e vasta gama de aplicação caracterizou esta época

por uma extraordinária utilização deste material. Em Portugal são imensas as obras deste período da qual se salienta o Viaduto Duarte Pacheco em Lisboa, que conta com um arco central com um vão de cerca de 92m e um desenvolvimento total de 505m, concluído em 1944, sendo na época um dos maiores viadutos da Europa.



Figura 2-1 - Viaduto Duarte Pacheco em Lisboa (Restos-de-coleção, 2013)

Atualmente a construção em betão armado conta com mais de um século de estudo e desenvolvimento, e são vários os regulamentos já publicados em Portugal, vigorando atualmente o Eurocódigo 2 (Norma NP EN 1992-1-1 de 2010).

2.2 ANOMALIAS E PATOLOGIAS

Com o envelhecimento, as estruturas de betão armado começam a apresentar anomalias que comprometem a sua durabilidade e funcionalidade. Uma anomalia é, por definição, algo que se desvia da norma, do expectável, da média geral ou do propósito com que foi criado, podendo também ser caracterizado como uma irregularidade. Já o termo patologia designa o conjunto de fenómenos que afetam o comportamento e desempenho de uma construção, com implicações estruturais ou não estruturais (Brito, 2001).

O diagnóstico destas anomalias é muitas vezes complexo devido à variedade de fenómenos que as podem causar. Podendo estas ser de origem natural, provocadas pelo meio ambiente em que se inserem, tendo como fatores a variação de temperatura, humidade, vento, poluição, proximidade à costa, sismos entre outras, ou, devido a outros fatores artificiais e que causam um envelhecimento precoce do material, entre estes fatores podem-se identificar causas como a falta de manutenção, erros de projeto e construção, excesso de carga e reações químicas indesejadas. As anomalias podem ser divididas em 3 grupos principais: anomalias decorrentes do processo de construção, anomalias estruturais e anomalias de durabilidade. (Figura 2-2)



Figura 2-2- Grupos de Anomalias

As causas para a deterioração podem ter origens variadas. Na figura 2-3 são listadas as mais comuns para o betão e para a armadura.

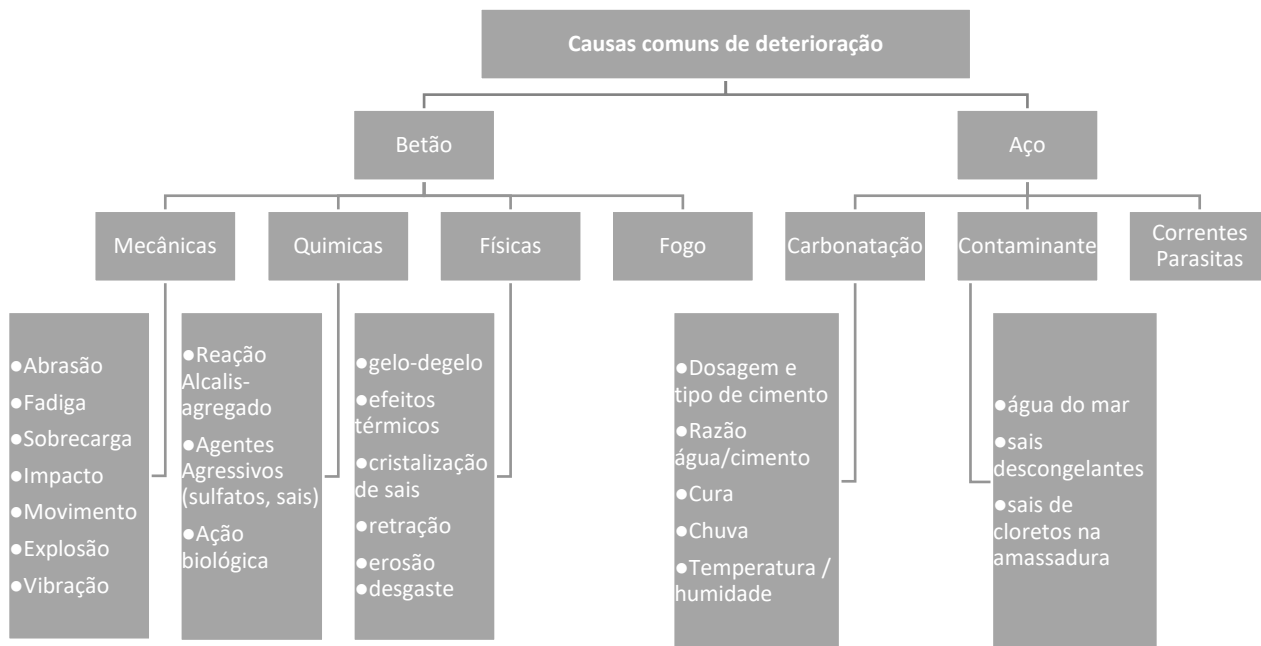


Figura 2-3- Causas de deterioração no betão armado

Nesta dissertação serão abordadas mais em detalhe as anomalias e respetivas causas relacionadas com fissuras e exposição de armaduras pois são estas as anomalias alvo do desenvolvimento das ferramentas de deteção utilizadas nos casos de estudo.

2.2.1 Fissuras

Uma fissura é por definição uma abertura estreita, alongada e pouco profunda. Ocorrem sempre que a tensão de tração do betão ultrapassa a sua resistência. Movimentos gerados no interior do betão, expansão de um material embebido no betão e condições externamente impostas são os três principais mecanismos causadores de fissuração.

2.2.1.1 Assentamentos plásticos

O assentamento plástico do betão (Figura 2-4) ocorre devido à migração da água do betão para a superfície antes de ser atingida a presa. Este processo conduz à diminuição do volume do betão, levando a que ocorra fissuração sempre que o assentamento não seja uniforme devido a obstáculos como armaduras e cofragens. (Coutinho, 1998).

As principais causas para a ocorrência do assentamento plástico podem ser:

- Teor elevado de finos
- Teor elevado de água

- Movimentos da cofragem
- Má vibração do betão




Figura 2-4 - Fissuras por assentamento plástico (civilblog, 2020)

2.2.1.2 Retração plástica

A retração plástica do betão ocorre quando na cura há uma elevada perda de água num curto espaço de tempo. A elevada temperatura do ar, baixa humidade, insolação e velocidade do vento elevada são fatores que contribuem para a ocorrência deste fenómeno. Nas primeiras horas de cura o betão ainda não adquiriu muita resistência, a rápida perda de água na superfície do betão leva à diminuição do seu volume, sendo geradas tensões que originam fissuração superficial irregular. (Figura 2-5)



Figura 2-5- Fissuras por retração plástica (Constrofacilator, 2020)

2.2.1.3 Retração

Ocorre devido à diminuição do volume do betão pela evaporação da água ao longo do tempo. Trata-se de um processo que se prolonga durante anos. (Sampaio, 2010). Com a diminuição do volume do betão e as restrições impostas pela estrutura, são geradas tensões que levam à fissuração do betão. Quanto mais rígida for uma estrutura maior será a probabilidade de ocorrerem fissuras por retração. Em fase de projeto deverão ser projetadas juntas de dilatação para ter em conta o efeito de retração do betão.

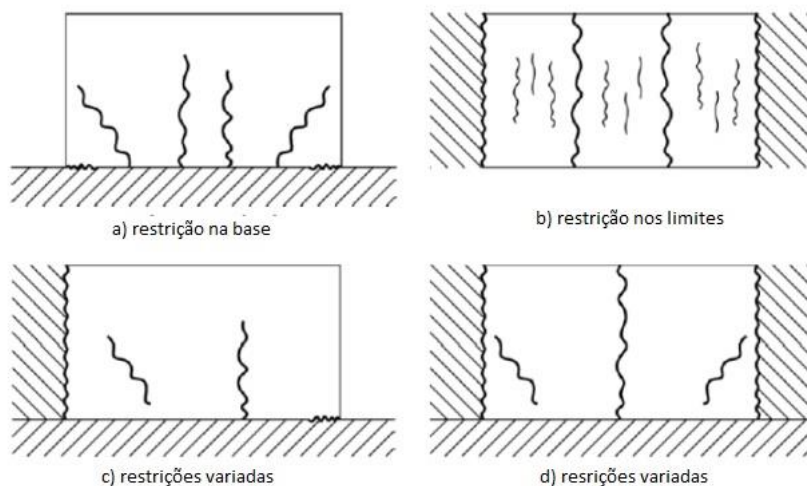


Figura 2-6 - Fissuras por retração (Rodrigues, 2019)

2.2.1.4 Efeitos da temperatura

A variação da temperatura tem efeitos no betão armado, o qual contrai quando há uma diminuição de temperatura e dilata quando esta aumenta (Silva, 1998). A variação de comprimento numa peça de betão armado pode ser obtida pela expressão 2-1:

$$\Delta L = \alpha \cdot \Delta T \cdot L \tag{2-1}$$

Em que:

ΔL representa a variação de comprimento

α representa o coeficiente de dilatação térmica que no betão é de cerca de $10 \times 10^{-6} / ^\circ\text{C}$

L representa o comprimento inicial

As estruturas hiperestáticas estão vulneráveis ao aparecimento de fissuras uma vez que são estruturas que estão impedidas de se deformarem, como tal com a variação da temperatura geram-se tensões nas peças que levam á sua fissuração. Em projeto este efeito deverá ser contabilizado sempre que uma estrutura tenha mais de 30 metros de comprimento (EN1992-1, 2010; REBAP, 1983).




Figura 2-7 - Fissuras por variação de temperatura (Theconstructor,2019)

2.2.1.5 Erros de construção

O deslocamento das armaduras durante a betonagem, ou mesmo a sua incorreta colocação pode levar a um recobrimento insuficiente levando à formação de fissuras no betão no alinhamento dos varões. (Figura 2-8)

A incorreta colocação de cofragens ou a sua remoção prematura pode provocar fissuras no betão pois este entra em carga antes de atingir a resistência necessária para as ações aplicadas. Em casos mais graves pode mesmo levar ao colapso parcial ou total da estrutura.

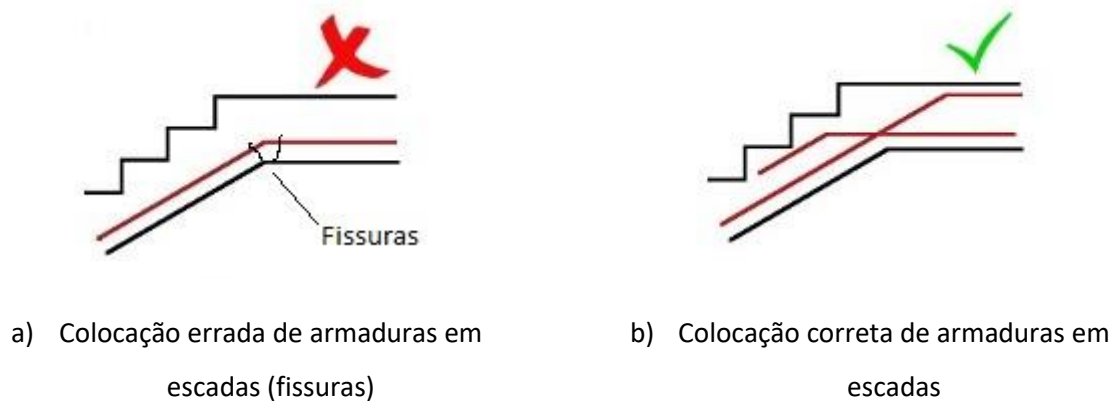


Figura 2-8 – Erros de projeto ou construção (adaptado de E-Civil, 2020)

2.2.1.6 Fluência do betão

Cargas constantes a atuar na estrutura, a longo prazo podem levar à deformação dos elementos estruturais. Devido às restrições impostas por apoios pode ocorrer fissuração. (Gromicko et al, 2014)

2.2.1.7 Assentamentos diferenciais

Os solos são suscetíveis de sofrer deformações sempre que são sujeitos a cargas externas. Com a utilização da estrutura, estas deformações poderão não ser uniformes ao longo de toda a área em que a estrutura se encontra assente (Jacome et al., 2005). O deslocamento dos apoios gera tensões excessivas em alguns elementos estruturais levando ao aparecimento de fissuras (Figura 2-9). As principais causas para a ocorrência de assentamentos diferenciais são:

- vibrações
- rotura de condutas
- escavações
- heterogeneidade do solo de fundação
- fundações sobre aterros
- dimensionamento incorreto das fundações
- deficiente consolidação do terreno

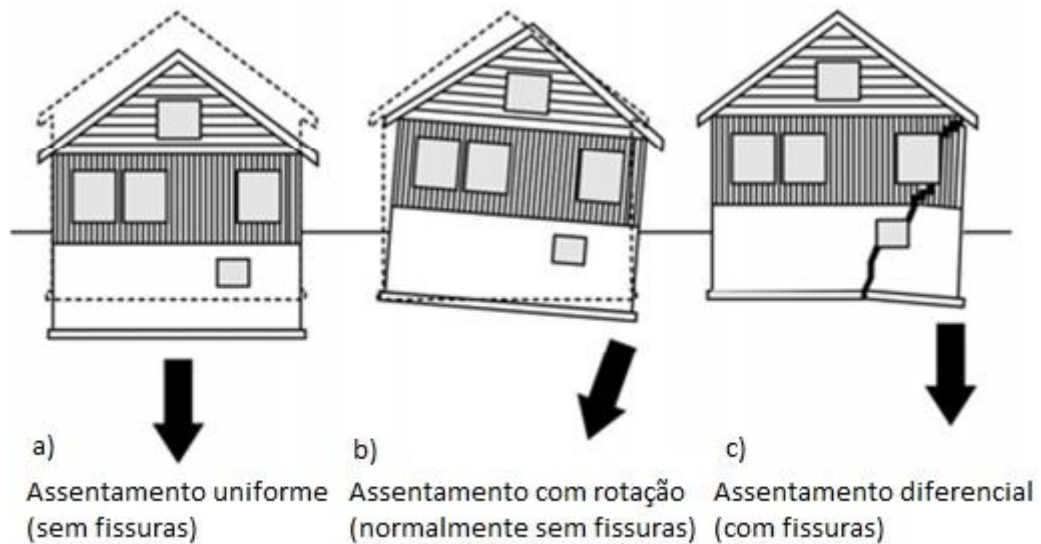


Figura 2-9 - Fissuração por assentamentos diferenciais (Inspectapedia,2017)

2.2.1.8 Cargas excessivas

Quando uma estrutura é utilizada para fins para os quais não foi projetada, ou devido a um erro de projeto as ações foram subestimadas, ocorre uma fendilhação excessiva na estrutura, o que poderá levar a uma corrosão de armaduras e conseqüentemente o agravamento dos problemas. Em projeto a abertura de fissuras deve ser controlada tendo em conta parâmetros como a função, durabilidade, deformação e estética da estrutura. Na figura 2-10, apresentam-se alguns modos de fissuração por carga excessiva.




Figura 2-10 - Fissuração por cargas excessivas (Souza,1998)

2.2.1.9 Ações sísmicas

Em estruturas projetadas anteriormente à existência de regulamentação sísmica, ou sempre que seja desrespeitada esta regulamentação, a ocorrência de sismos pode provocar danos graves numa estrutura, podendo os elementos estruturais serem completamente atravessados por fissuras, e em casos mais graves levar a um colapso parcial ou total da estrutura. (Silva, 1998).

2.2.1.10 Ação do fogo

As temperaturas elevadas, levam a que o aço sofra uma maior dilatação que o betão, surgindo tensões na estrutura. As variações de volume que se verificam levam à fissuração da estrutura.

2.2.1.11 Ciclo gelo-degelo

Este fenómeno ocorre quando existem superfícies expostas à água com carácter permanente ou quase-permanente. Poros e fissuras já existentes no betão ficam saturados pelo contacto com a água, quando se atingem temperaturas negativas. Essa água congela e expande, gerando tensões no interior do betão e consequentemente fissuras e destacamento do betão superficial (Figura 2-11).



Figura 2-11 – Ciclo gelo-degelo (adaptado de RainGuard, 2017)

2.2.1.12 Reação alcalis-sílica

Esta anomalia tem origem na amassadura. Alguns agregados contêm sílica reativa que reage com os alcalis presentes no cimento, formando um gel que envolve os agregados. Teores elevados de humidade levam a que o gel expanda, criando trações no betão, o que leva à sua fissuração, diminuição de resistência e perda de integridade (Figura 2-12). A presença de eflorescências, juntamente com fissuração irregular é uma evidência de que podemos estar perante uma reação alcalis-sílica. (Gromicko, et al, 2014)



Figura 2-12 – Fissuração devido a reação alcalis-sílica (BlogLPE, 2020)

2.2.1.13 Cristalização de sais

Ocorre quando há elementos em contacto com soluções salinas. Com a evaporação a solução salina cristaliza, aumentando o seu volume. A fissuração ocorre por tensões resultantes da cristalização dos sais nos poros do betão (Lapa, 2008).



Figura 2-13 – Fissuras devido a cristalização de sais (Dreamstime, 2020)

2.2.1.14 Corrosão de armaduras

Quando o aço no interior do betão oxida dá-se uma expansão do material que gera tensões no interior do betão e conseqüente fissuração. Este fenómeno e as suas causas será abordado no próximo subcapítulo.

2.2.2 Corrosão de armaduras

A observação do comportamento das obras tem mostrado que o mecanismo de corrosão das armaduras é a principal fonte de deterioração das estruturas de betão armado. (Costa, 1999).

O próprio betão tem função protetora das armaduras atuando de duas formas. Por um lado, a camada de betão de recobrimento impede que agentes agressivos ataquem as armaduras, pois esta constitui uma

barreira á sua penetração, por outro gera no seu interior um ambiente alcalino que impede a corrosão do aço.

O betão possui uma elevada alcalinidade devido à presença de hidróxidos de cálcio, sódio e potássio. Estes hidróxidos dissolvem-se na água dos poros originando uma solução alcalina de PH normalmente entre 12.5 e 13.5, envolvendo os inertes e armaduras. Nestas condições o aço apresenta uma velocidade de corrosão insignificante devido á formação de uma película protetora de óxido de ferro, tendo assim um comportamento passivo.

A destruição desta película passivante ocorre por ação de sais quando o seu teor ultrapassa um valor crítico ou pela diminuição do PH da solução dos poros ao nível da armadura para valores inferiores a 11, iniciando-se assim o processo de corrosão. O princípio fundamental da corrosão do aço consiste num processo eletroquímico onde existe um ânodo e um cátodo, em que, qualquer diferença de potencial entre pontos, gera uma corrente. No caso do betão armado, a de corrosão (Figura 2-14).




Figura 2-14 - Processo de corrosão (Costa, 1999)

O ânodo consiste na zona de armadura despassivada e o cátodo na zona de armadura com acesso a oxigénio.

No ânodo processa-se a dissolução do ferro em que iões Fe^{++} passam para a solução libertando dois eletrões. A armadura que funciona como condutor elétrico permite que os eletrões passem para o cátodo, aqui dá-se uma reação química com o oxigénio e a água, originando iões de hidróxido, que fluem na direção do ânodo através do betão de forma a completar o circuito elétrico.

As reações anódicas referidas por si só não revelariam anomalias visíveis nas estruturas pois os iões de ferro se dissolveriam na solução dos poros, no entanto ocorrem reações anódicas secundárias (2-2 a 2-5) originando produtos de corrosão aos quais está associado um aumento de volume. Este aumento de

volume gera tensões elevadas no interior do betão que provoca a fendilhação, delaminação e destacamento do betão de recobrimento (Figura 2-15).



A fendilhação pode ocorrer de várias formas dependendo da localização, espessura e espaçamento dos varões. Pode distinguir-se de outras causas pelo aparecimento de manchas de ferrugem na superfície do betão na zona das fendas.



Figura 2-15 – Armadura exposta por destacamento do betão de recobrimento

2.2.2.1 Ação da carbonatação

O dióxido de carbono presente na atmosfera penetra na estrutura porosa do betão de recobrimento combinando-se com a pasta de cimento (2-5).



Esta reação provoca a diminuição do PH do betão de recobrimento e conseqüentemente a perda da película passivante. Da mesma forma que o dióxido de carbono penetra no betão também o oxigénio o faz, pelo que o único parâmetro limitador da velocidade de corrosão é a resistividade do betão, que é influenciada por fatores como a porosidade e o teor de humidade.

O tipo de corrosão originado pela carbonatação é a corrosão geral das armaduras, uma vez que ânodos e cátodos são nesta situação muito pequenos e muito próximos, formando microcélulas de corrosão.

2.2.2.2 Ação dos cloretos

Os cloretos podem ter origem nos agregados, na água de amassadura, no ar ou em sais-anti-gelo.

A corrosão por cloretos é muitas vezes localizada ou por picadas, no entanto quando há uma elevada contaminação pode ocorrer a destruição total da película passivante e conseqüentemente uma corrosão generalizada das armaduras.

A corrosão por ação dos cloretos é bastante gravosa uma vez que ocorre a uma velocidade elevada de cerca de 50 a 500 micrómetros por ano, podendo causar perdas de secção de armadura significativas num curto espaço de tempo. O teor de cloretos necessário para destruir a película passiva e ativar o mecanismo de corrosão, designado teor crítico de cloretos, tem sido alvo de investigação, no entanto, ainda não há consenso sobre a matéria. Na norma portuguesa, considera-se o valor de 0.4% em relação à massa de cimento utilizado para o betão fresco como sendo o valor de referência.

CAPÍTULO 3

TÉCNICAS AUTOMATIZADAS DE INSPEÇÃO VISUAL DE ESTRUTURAS

Com a preocupação do aparecimento de anomalias surge a necessidade de efetuar inspeções periódicas de modo a avaliar o estado de conservação de determinada estrutura, intervindo se assim for necessário.

A regularidade das inspeções é relacionada com a importância da estrutura e do meio ambiente em que se insere. A título de exemplo uma inspeção de rotina em obras de arte, deve ocorrer a cada dois anos (I.P., 2018). Outras inspeções não programadas podem ocorrer devido á ocorrência de acidentes, intenção de alterar a geometria ou o uso da estrutura e avaliações imobiliárias.

As inspeções regulares são de grande importância, uma vez que detetar as anomalias numa fase inicial permite muitas vezes que estas sejam reparadas ou corrigidas, contendo os custos de intervenção.

3.1 TÉCNICAS TRADICIONAIS DE INSPEÇÃO VISUAL

A inspeção visual é o primeiro passo para o diagnóstico de uma estrutura. Esta fornece ao técnico cerca de 80% da informação relevante acerca do estado de conservação da mesma. (Rodrigues, 2019)

Antes de se iniciar uma inspeção visual é necessário recolher o máximo de informação possível acerca da estrutura a ser inspecionada. Projetos de arquitetura e especialidades, registos de manutenção e intervenções e especificações dos materiais devem ser obtidos junto do dono de obra e entidades licenciadoras.

Uma visita preliminar deve ser efetuada de modo a aferir os principais problemas da estrutura à vista desarmada, compreender a estrutura e as suas condições de exposição e acesso. Após definir os objetivos da inspeção com o dono de obra poderá ser dado o início do planeamento da inspeção.



O planeamento tem por base a visita preliminar e deve conter:

- Definição do âmbito e da extensão da inspeção
- Escolha dos testes e ensaios a efetuar

- Preparação de meios de segurança e de acesso
- Preparação de fichas de inspeção
- A organização da equipa de inspeção
- Primeira avaliação das causas das anomalias
- Programação dos trabalhos
- Estimativa orçamental

Durante a inspeção visual deverão ser preenchidas fichas de inspeção que determinarão o estado de conservação de cada elemento estrutural (Figura 3-1)

OBRA		Edifício inacabado	DONO	Privado	GRUPO:	NÚMERO
LOCALIZAÇÃO	Rua Rio Este, Touguinhó - Vila do Conde - Portugal		Diana Duarte			1180392
DATA	19/10/2019	HORA	11:57	Diogo Maia		1111086
Condições ambientais	19.00	14.00	17.00	19.00	21.00	1090431

VISTA GERAL		Pilar A5 RC
		
		




ELEMENTO ESTRUTURAL		Pilar A5 RC					
Foto da anomalia	Descrição						
	Observa-se a existência de segregação do betão (A2) e bolhas de ar (A14). A segregação do betão localiza-se generalizadamente em todo o pilar, assim como as bolhas de ar. As possíveis causas para a existência de betão segregado são a má vibração do betão (C2), lançamento incorreto do betão (C27) ou composição do próprio betão (C12). A possível causa para a existência de bolhas de ar é a má execução das cofragens (C1) e/ou má vibração do betão (C3).						
	Regista-se a presença de diferentes juntas de betonagem (A5). Estas localizam-se generalizadas em todo o pilar. As prováveis causas para a existência de diferentes juntas de betonagem é a falta de ligação entre betões de distintas idades (fases de betonagem) (C11), mau tratamento da superfície endurecida (C11), ou ainda, betonagens muito espaçadas no tempo (C11).						
	Regista-se a proliferação de líquens (A15). Os líquens possuem uma coloração esverdeada e manifestam-se na parte inferior do pilar. A causa da anomalia é a humidade (C7) constante contribuindo a formação de fungos.						
RESUMO DE ANOMALIAS: A2; A5; A14; A15							
ESTADO DE CONSERVAÇÃO							
Elemento Estrutural	N	D	E	F	C	EC	ALERTA
Pilar A5 RC	0	1	1	0	0	2	-


Figura 3-1 – Exemplo de ficha de inspeção

Em obras de arte, a inspeção visual é normalmente um processo moroso e caro, uma vez que exige que o técnico tenha condições de acesso visual aos elementos estruturais, para que possa fazer uma inspeção cuidada da estrutura. Muitas vezes o técnico tem que recorrer a andaimes, plataformas elevatórias, cordas e outros equipamentos para que conseguir analisar os elementos estruturais. Estes meios acarretam custos elevados, sendo que por vezes podem por em risco segurança dos técnicos.

Na Figura 4-2, demonstram-se dois equipamentos utilizados na inspeção de estruturas.

O sistema *by-bridge* é muito utilizado na inspeção de pontes e viadutos. Este sistema consiste numa plataforma móvel acoplada a um veículo pesado que possibilita o acesso à parte inferior de um tabuleiro.

Em estruturas de grande dimensão em que não é possível ou viável a utilização de plataformas, recorre-se geralmente ao alpinismo industrial. O alpinismo industrial permite aos inspetores alcançar locais de difícil acesso recorrendo a um sistema de cordas que lhes fornece liberdade de movimento. A inspeção terá de ser feita por técnicos habilitados para o uso de cordas, o que faz acrescer os custos da inspeção. Apesar desta técnica possuir equipamentos para fixação de cordas onde não existem ancoragens, arnês para segurança e conforto e um sistema anti queda, apresenta um risco acrescido e desnecessário para as equipas.



a) sistema bybridge (bridgebybridge ,2020)



b) alpinismo industrial (shutterstock, 2020)

Figura 3-2 – Métodos de inspeção visual de estruturas

3.2 TÉCNICAS AUTOMATIZADAS COM RECURSO A VANTS

Com os últimos avanços tecnológicos, o uso de VANTS tem sido estudado como uma alternativa para ultrapassar as limitações das técnicas de inspeção tradicionais. A captação remota de imagens torna este método interessante uma vez que permite reduzir ou eliminar equipamento adicionais nas campanhas de inspeção, consequentemente reduzindo os custos.

Em 2015 o departamento de transportes do Minnesota, nos EUA conduziu uma série de experiências para avaliar esta tecnologia em termos de segurança e eficiência como um método para a inspeção de pontes (Figura 3-3).

Foram estudadas quatro pontes de diferentes dimensões e sistemas construtivos, após um planeamento de voo detalhado para cada ponte. Vários tipos de imagem foram testados, incluindo fotografia, vídeo e câmaras térmicas. Baseando-se nas observações em campo e em literatura da especialidade as seguintes conclusões foram tomadas:

- Os VANTs podem ser utilizados em segurança durante campanhas de inspeção em pontes. O risco para a equipa de inspeção e para o público em geral é baixo.
- Os VANTs são mais adequados para inspeções em pontes de grande dimensão.
- A tecnologia atual ainda não permite que os VANT consigam inspecionar autonomamente.
- As anomalias podem ser visualizadas com um elevado nível de detalhe.
- Medições podem ser estimadas, mas funções tácteis como limpar superfícies e efetuar testes não podem ser replicadas usando VANTs.
- VANTs com possibilidade de voar sem GPS e de direcionar as câmaras para cima são uma mais valia quando se usa esta tecnologia para inspeção de pontes.
- Os VANTs permitem obter informação detalhada a baixo custo.
- Riscos associados com o controlo de tráfego e trabalhos em altura podem ser minimizados.
- A utilização de veículos pesados e plataformas elevatórias podem ser reduzidos com a utilização de VANTs.
- Os VANTs podem fornecer informação importante em pré-inspeção que poderá ser utilizada para planear uma inspeção de larga escala.



Figura 3-3 – Utilização de VANTs na inspeção de pontes (Lovelace, 2015)

Com mais de 3400 km de autostradas, a concessionária *Autostrade per l'Itália* tem de inspecionar cerca de 4200 pontes, viadutos e túneis. (Leica-geosystems, 2020)

Pela lei italiana, todas as pontes devem ser inspecionadas duas vezes por ano. Devido ao elevado número de inspeções a realizar, a concessionária iniciou uma parceria com a empresa *Air View Group*, numa tentativa de tornar as inspeções mais eficientes.

Assim em 2012, a concessionária começou a utilizar VANTs na inspeção de pontes. Os VANTs foram modificados com tecnologia da *Leica Geosystems*, e contêm software para deteção de anomalias (Figura 3-4), bem como uma câmara de alta resolução, montada no topo do drone de modo a inspecionar a face inferior de tabuleiros. O controlo dos drones por pilotos profissionais garante a segurança da equipa de inspeção.

Todas as inspeções realizadas pela parceria seguem o mesmo padrão, sendo que cerca de 30% do tempo é despendido a planear o voo, 10% no voo, e os restantes 60% são utilizados no pós-processamento, análise e apresentação dos dados adquiridos.

A parceria entre a *Air View Group* e a *Autostrade per l'Itália* permitiu á concessionária reduzir os custos com inspeções. Tradicionalmente, nas inspeções recorria-se a veículos pesados adaptados para a inspeção de pontes, com uma equipa de 3 pessoas, mais cerca de 6 pessoas para controlo rodoviário. A utilização de VANTs permitiu cortar 6 postos de trabalho, pois não é necessário interromper o tráfego. Permitiu ainda poupar no custo de mobilização de veículos especiais e no tempo necessário para realizar uma inspeção.

Segundo o Grupo *Leica*, a possibilidade de adaptar grande parte dos sensores existentes no mercado num VANT, torna esta tecnologia uma mais valia, pois fornece a capacidade de capturar aquilo que o ser humano não pode ver a olho nu.

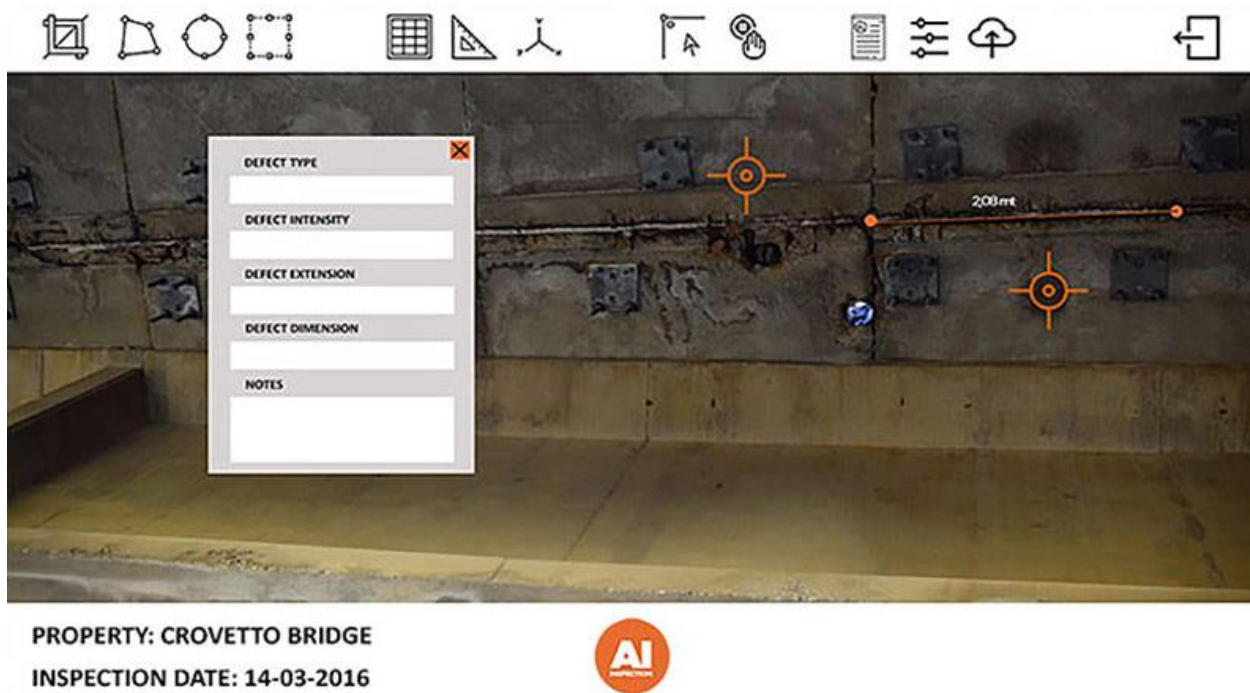


Figura 3-4 - Software para deteção de anomalias *Leica Albot* (LeicaGeosystems, 2020)

Os estudos e experiências anteriores validam a utilização de VANTs na inspeção de estruturas, no entanto há que ter em conta alguns aspetos para a sua utilização em segurança. Os VANTs devem ser manobrados por técnicos especializados, que conheçam as limitações do veículo e saibam responder a problemas inesperados. A realização de um plano de voo é de extrema importância, pois permite antecipar problemas, tornando o tempo de voo o mais eficiente possível. A capacidade de voar sem GPS, resistência á chuva, bateria de grande longevidade, iluminação e possibilidade de instalação de uma câmara com rotação de 360º, são uma mais valia quando se utiliza este equipamento em inspeção de estruturas.

CAPÍTULO 4

TÉCNICAS DE PROCESSAMENTO DE IMAGEM

Técnicas de processamento de imagens foram desenvolvidas e testadas nos últimos anos de modo a serem implementadas em infraestruturas, com o objetivo de detectar anomalias. A técnica consiste na captação de imagens de uma estrutura que posteriormente são processadas por um algoritmo específico para determinada anomalia.

4.1 PROCESSAMENTO HEURÍSTICO DE IMAGEM

Os algoritmos heurísticos têm por base a aplicação de filtros na imagem, como detecção de contornos, detecção de gradiente ou aumento de contraste, ou em buscas, pixel a pixel numa escala RGB especificada. Na figura 4-1 encontra-se esquematizado um algoritmo para detecção de fissuras recorrendo a técnicas heurísticas.

O propósito destas técnicas consiste na substituição parcial da presença humana no local bem como a redução dos custos de inspeção e risco de acidentes. As anomalias podem ser detetadas automaticamente por aplicação destes métodos, minimizando o erro humano. No entanto estas técnicas são fortemente afetadas por fatores externos, tais como as condições climatéricas, a luminosidade, a presença de riscos e manchas nas superfícies, impedindo assim a sua adoção em larga escala (Ellenberg et al., 2016).

A luminosidade externa do ambiente afeta a escala de cores, o que atinge de forma sensível os resultados dos filtros criados para detecção de anomalias (Shibasaki, 2019).

Em algumas situações, as diferenças de incidência solar durante a captação de imagens de uma estrutura, implicam a necessidade de rever os parâmetros RGB para detecção de anomalias (Teixeira, 2019).

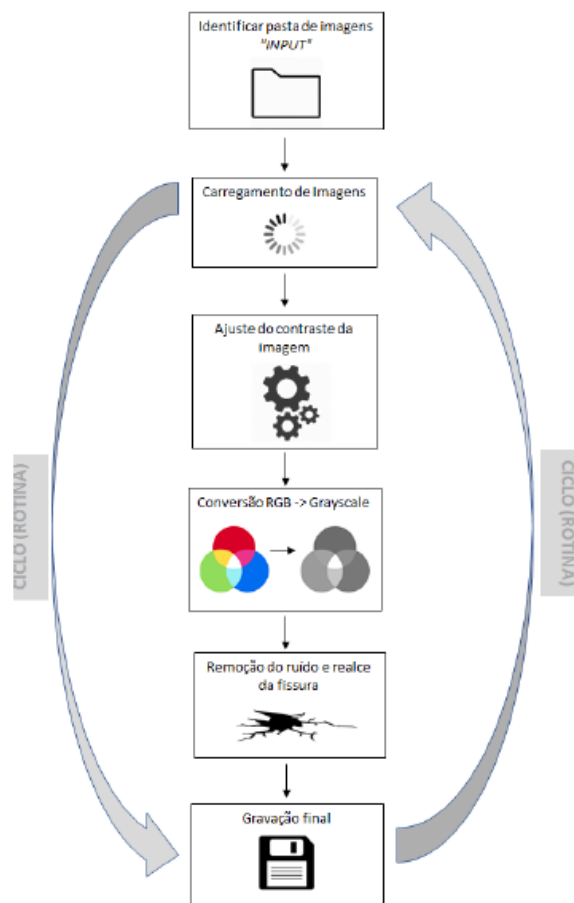



Figura 4-1 – Exemplo de algoritmo para detecção de fissuras. (Teixeira, 2019)

Na figura 4-2, mostra-se a aplicação de um filtro para detecção de armaduras em que se demonstra a sensibilidade deste à luminosidade. O filtro consiste na seleção dos píxeis num intervalo de parâmetros RGB, que depois são modificados para uma cor falsa, neste caso, o vermelho. As imagens são da mesma estrutura, captadas em locais diferentes. Na imagem à esquerda, com mais luminosidade, o filtro funcionou como o previsto selecionando os píxeis correspondentes à armadura exposta. No entanto na imagem da direita, com menor luminosidade, são selecionados vários píxeis não correspondentes a armaduras expostas, obrigando assim o utilizador a rever os parâmetros RGB.

A sensibilidade destas técnicas a fatores externos, conduz muitas vezes, a resultados insatisfatórios, não sendo assim plausível a sua utilização em contexto real. Assim, surge a necessidade de desenvolver novos métodos que se possam adaptar ao ambiente em que as imagens são capturadas, aumentando o nível de fiabilidade.



a) Aplicação bem-sucedida



b) Aplicação malsucedida

Figura 4-2 – Aplicação de técnicas heurísticas

4.2 PROCESSAMENTO DE IMAGEM BASEADO EM MACHINE LEARNING

4.2.1 Conceitos base

O *Machine Learning* é um ramo da inteligência artificial baseado na ideia que sistemas podem aprender com dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. Simplificando, é a prática de usar algoritmos para adquirir dados, aprender com eles e efetuar previsões de qualidade em situações futuras relacionadas com os dados previamente adquiridos. Assim ao invés da tradicional implementação de comandos de software com instruções específicas para completar uma tarefa em particular, o *Machine Learning* permite que um computador seja treinado apenas com um conjunto de dados e algoritmos, o que lhe dá a habilidade de aprender como executar a tarefa. Como o *Machine Learning* geralmente usa uma abordagem iterativa para aprender com os dados, a aprendizagem pode ser facilmente automatizada. As etapas são executadas através dos dados até que um padrão robusto seja encontrado. O aspecto iterativo do *Machine Learning* é importante porque, quando os modelos são expostos a novos dados, são capazes de se adaptar autonomamente.

O *Machine Learning* está instituído no dia-a-dia do cidadão comum, que praticamente não se apercebe da sua utilização. Filtragem de *spam* no correio eletrónico, reconhecimento de voz, reconhecimento de fraudes e invasões e anúncios com recomendações de produtos em *websites* são alguns exemplos de aplicações do *Machine Learning* na vida quotidiana (Alpaydin, 2010).

O *Deep Learning* é um ramo do *Machine Learning* inspirado pela estrutura biológica do cérebro humano, combina avanços no poder computacional e tipos especiais de redes neuronais artificiais para aprender padrões complexos em enormes quantidades de dados. As técnicas de *Deep Learning* são a última

inovação tecnológica no que respeita à identificação de objetos em imagens e palavras em sons (Deng, 2014).

O *Deep Learning* difere do *Machine Learning*, pois o *Machine Learning* está dependente da intervenção humana para fazer a sua aprendizagem, ou seja, nesta técnica os dados devem ser categorizados pelo utilizador, isto é conhecido como *supervised learning* (Figura 4-3). Já o *Deep Learning* não requer a intervenção humana, este é capaz de categorizar dados autonomamente, neste caso estamos perante *unsupervised learning* (Bansal, 2020).

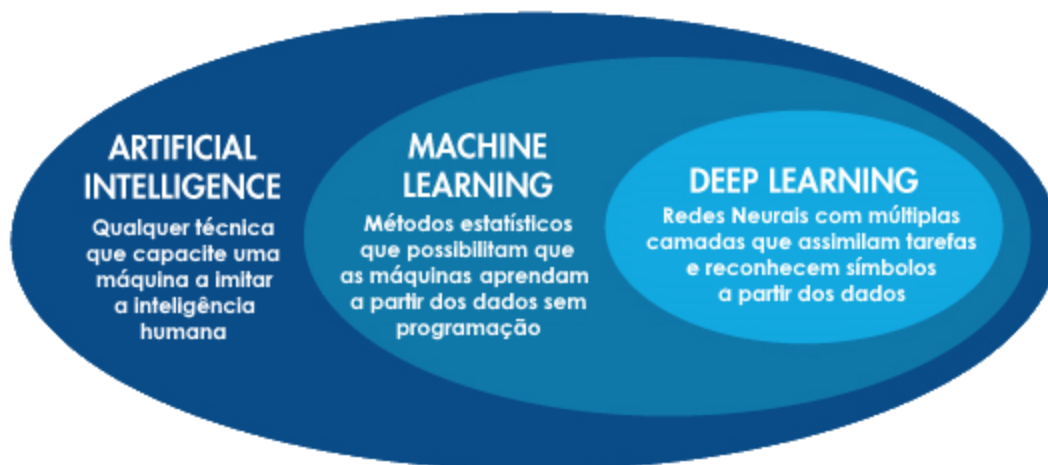


Figura 4-3 – Diferenças entre Inteligência artificial, *Machine Learning* e *Deep Learning* (Lavagnoli, 2020)

4.2.2 Redes Neurais

Uma rede neuronal consiste numa estrutura conectada, na qual o processamento se encontra distribuído por um grande número de pequenas unidades densamente interligadas.

Uma rede neuronal artificial é similar ao cérebro humano em dois aspetos:

- O conhecimento é adquirido pela rede através do ambiente por um processo de aprendizagem
- Conexões inter-neuronais são utilizadas para guardar o conhecimento adquirido

Um neurónio artificial recebe um ou mais sinais de entrada, *inputs*, processa essa informação e produz uma resposta, *output*. Geralmente aos *inputs* é aplicada uma ponderação ou peso, os sinais resultantes são posteriormente somados e à soma resultante é aplicada uma função não linear, chamada de função transferência, sendo assim gerado o *output*. Normalmente, as ponderações de uma rede neuronal são ajustadas inicialmente para pequenos valores aleatórios. Como o processo de treino, os pesos de conexão são gradualmente modificados de acordo com regras computacionais específicas para o algoritmo de aprendizagem que está a ser utilizado. Assim, os pesos irão eventualmente convergir para valores que

Ihes permitam executar um processamento útil. Pode-se dizer que a rede neuronal começa com total desconhecimento e move-se adquirindo algum conhecimento real.

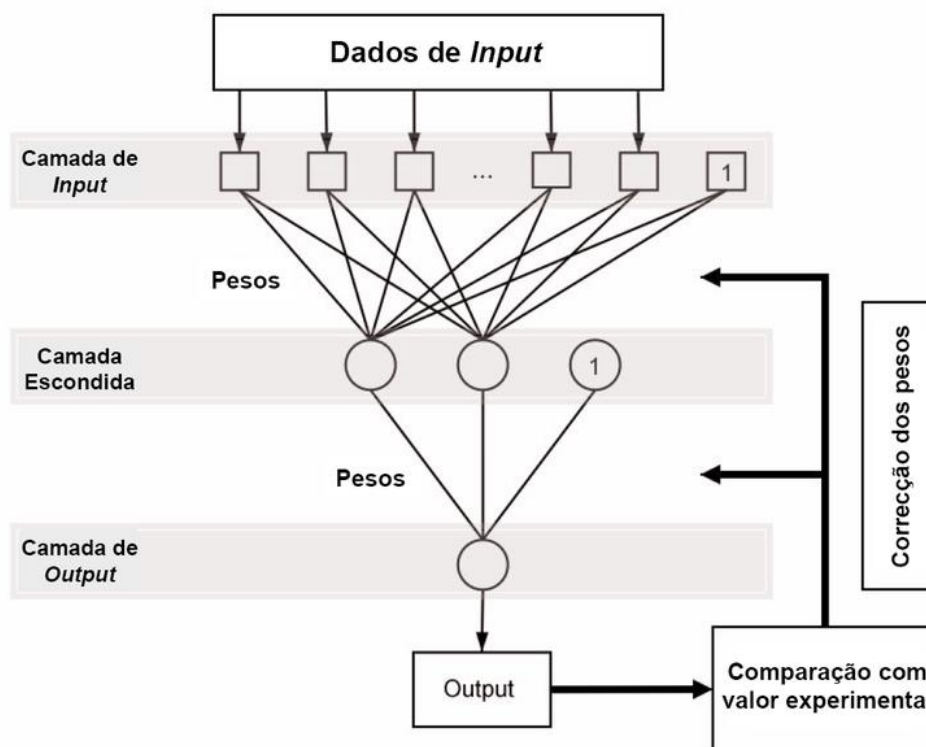


Figura 4-4 - Rede *Feed-Forward* na estrutura de uma rede neuronal (Medium, 2020)

Uma rede neuronal artificial tem a capacidade de aprender com a informação que lhe é fornecida e de melhorar a sua performance durante o processo de aprendizagem - aprende por um processo iterativo de ajuste das forças sinápticas (pesos). É capaz, a cada iteração do processo de aprendizagem, de aperfeiçoar a sua representação e compreensão do problema em questão, ou seja, aprende por treino e experiência segundo certas regras pré-definidas. Ao conjunto de regras pré-definidas pelo qual se faz a alteração dos pesos dá-se o nome de algoritmo de aprendizagem. Existem diversos algoritmos de aprendizagem que diferem entre si na forma como os pesos são corrigidos e da estrutura da rede. A Figura anterior mostra de uma forma geral a arquitetura de uma rede neuronal artificial e ilustra o processo de aprendizagem (correção dos pesos) numa rede de *feed-forward*. Uma rede Neuronal que consista em mais de três camadas (*layers*), é considerada um algoritmo de *Deep Learning* (Kavlakoglu, 2020).

Existem vários tipos de redes neuronais, cada qual com diferentes propósitos. Exemplificando, “Redes neuronais recorrentes” podem ser utilizadas para prever o estado do tempo baseando-se num histórico do clima. A rede de Hopfield é capaz de reconstruir informação a partir de informação incompleta ou corrompida. Já as Redes Neuronais Convolucionais, que são aplicadas nesta dissertação, são normalmente utilizadas para resolver problemas relacionados com imagem e vídeo. (Ciresan, 2011)

4.2.3 Redes neurais Convolucionais (RNC)

Um dos tipos mais populares de redes neurais artificiais são as redes neurais convolucionais (RNC) ou *Convolutional Neural Networks (CNN)* na terminologia inglesa. Matematicamente, uma convolução é uma operação linear que a partir de duas funções, gera uma terceira (normalmente chamada de *feature map*). Uma RNC usa *layers* convolucionais a duas dimensões o que torna a sua arquitetura ideal para processar dados a 2 dimensões como imagens.

As RNCs eliminam a necessidade de efetuar uma extração manual de características, fazendo-o automaticamente através das imagens fornecidas. Esta extração automática faz com que este modelo de Deep Learning seja altamente fidedigno para classificação de objetos, e quando comparadas com outros algoritmos de classificação de imagem exigem um menor tempo de pré-processamento. (Alves, 2018)

Na figura 4-5 encontra-se esquematizado o exemplo de arquitetura de uma RNC e das camadas que a compõem.




Figura 4-5 - Exemplo de arquitetura de uma RNC (Mathworks, 2020)

A arquitetura de uma RNC aplicada ao reconhecimento de características em imagens consiste nos *layers*, ou camadas seguintes:

Input: No início do processo a imagem de entrada é dividida em píxeis. Para uma imagem a preto e branco a cada pixel é atribuído um valor entre 0 e 255, correspondendo às cores preto e branco respetivamente, em que entre esses valores existe a escala de cinza. Uma imagem a cores é representada por uma matriz tridimensional, de forma a ser possível armazenar a combinação das três cores da escala RGB.




Figura 4-6 – Exemplo de obtenção da matriz de uma imagem RGB (Stanford, 2020)

Convolution: O propósito da *convolution* ou convolução é extrair características da imagem de entrada. Trata-se de uma operação matemática que tem como dados de entrada a matriz da imagem e uma matriz filtro, em que a matriz filtro percorre toda a matriz imagem, resultando numa matriz de menor dimensão cujo processamento será mais fácil. A convolução de uma imagem com diferentes filtros pode identificar características como cores, gradiente, orientação e bordas.




Figura 4-7 - Aplicação da convolução a uma imagem (Medium, 2020)

Relu: Relu significa “unidade linear retificada para operações não lineares”. Neste *layer* é aplicada a função: $f(x)=\max(0,x)$. O propósito deste layer é introduzir não linearidade à nossa rede. Uma vez que a maioria dos problemas complexos não são lineares é importante o uso desta função de ativação.




Figura 4-8 - Função Relu (Medium, 2020)

Pooling: Após a extração de características através do *layer* “convolução”, o mapa de características resultante é passado para o *layer* “*Pooling*” logo após a aplicação da função de não linearidade.

Este *layer* reduz a dimensão do input, extraíndo a informação mais dominante, assim é possível reduzir a carga computacional necessária, mantendo a eficácia do processo de treino do modelo.




Figura 4-9 – Exemplo de aplicação da função *Pooling* (cs231n, 2020)

Fully conected layer: Este *layer* é usado para a classificação das características extraídas nos *layers* anteriores. Os mapas de resultantes são convertidos em vetores e as suas características são combinadas para criar um modelo.

4.3 APLICAÇÃO NA ENGENHARIA CIVIL

Vários autores já testaram as redes neurais convolucionais como método para identificação semiautomática de patologias em estruturas de betão-armado. Neste capítulo serão apresentados e discutidos alguns estudos recentes sobre o tema.

Cha et al. (2017) conduziram um estudo para determinar a fiabilidade de um método de deteção automática de fissuras recorrendo ao *Deep Learning*. Os autores recolheram 332 imagens de betão fissurado, que das quais 227 de resolução 4928x3264 píxeis foram cortadas em pequenas imagens de 256x256 píxeis e utilizadas para construir uma base de dados, selecionando manualmente imagens com betão intacto e imagens com betão fissurado. As restantes 55 imagens foram usadas para testes. Para assegurar uma vasta gama de adaptabilidade as imagens foram obtidas num ambiente não controlado, garantindo variadas condições de luminosidade e distâncias ao objeto entre 0.1 m e 1.5 m. Das 227 imagens cortadas obtiveram-se 40 mil imagens, das quais 32 mil foram usadas para treino e 8 mil para validação.

Após o treino e validação da RNC foi obtida uma precisão de 97,95%, isto é, das 8 mil imagens, utilizadas para validação, apenas 164 foram mal classificadas. Um estudo paramétrico utilizando bases de dados com diferentes dimensões revelou que seriam necessárias pelo menos 10 mil imagens para obter um classificador razoável.

De modo a testar a ferramenta desenvolvida, 55 imagens que não foram usadas no treino ou validação, foram submetidas ao classificador através de uma *sliding window*.

Uma *sliding window* ou janela deslizante, consiste numa janela de pequena dimensão, em relação ao tamanho da imagem a ser processada, que percorre essa imagem com intervalos iguais, até esta ser processada na sua totalidade. Este conceito tornar-se-á mais claro com o desenvolver desta dissertação.

Os resultados revelaram uma precisão média de 97%, o que é praticamente idêntico ao resultado obtido durante o processo de validação. Apesar das imagens terem sido obtidas em diferentes condições, incluindo forte exposição solar, sombra, desfocagem da imagem e diferentes distâncias, os resultados obtidos foram consistentes, variando a sua precisão entre 87% e 100%. Na figura 4-10, apresenta-se uma imagem que a equipa usou para testar o modelo de classificação, onde é possível visualizar onde o classificador falhou, mostrando os falsos-positivos nos retângulos magenta e os falsos-negativos nos retângulos azuis.

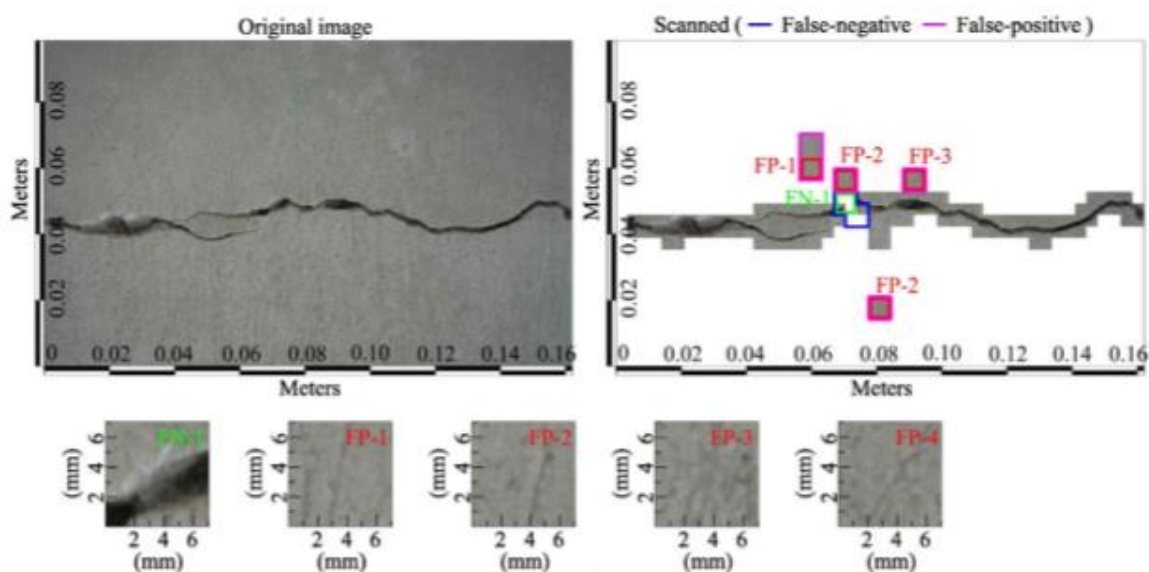


Figura 4-10 - Exemplo de aplicação da ferramenta de detecção de fissuras desenvolvida por *Cha et al*

Os autores concluem que a habilidade que a RNC tem em aprender características é certamente uma mais valia em relação aos métodos tradicionais de processamento de imagens, no entanto necessita de uma grande quantidade de dados para treinar um classificador robusto.

Kim e Cho (2018) conduziram um estudo semelhante, no entanto com algumas diferenças na sua metodologia.

Ao invés da obtenção das imagens em ambiente real os autores utilizaram imagens obtidas através de motores de busca na Internet. De modo a aumentar a fiabilidade na detecção de fissuras foram criadas novas categorias. Além de imagens de betão com fissuras e com betão intacto, os autores acrescentaram três novas categorias. Foram acrescentadas duas categorias contendo imagens de juntas de dilatação, bordas e cantos em elementos estruturais, e outra com vegetação indesejada no betão. A adição destes elementos surgiu após a análise de casos semelhantes em que apenas era considerado um binário (betão fissurado e não fissurado). Os autores de alguns desses estudos revelam que foram detetados falsos positivos exatamente em zonas com vegetação, juntas, bordas e cantos e por isso *Kim e Cho* decidiram criar estas novas categorias para tentar eliminar esses falsos positivos e assim aumentar a precisão do seu modelo.

Para o desenvolvimento do classificador os autores decidiram não desenvolver um modelo de raiz, pois tal requer uma base de dados muito extensa, além do tempo de treino, que pode levar vários dias mesmo num computador de elevado desempenho. De modo a contornar este problema os autores decidiram usar uma técnica de *Transfer Learning*. O *Transfer Learning* reduz significativamente o tempo de treino, pois utiliza uma base de dados pré-treinada com um propósito semelhante, o qual é ajustado para um novo problema. Neste estudo os autores decidiram utilizar a RNC classificadora de objetos *AlexNet*.

Apesar de a utilização de uma base de dados mais reduzida ser uma das vantagens do *Transfer Learning* o número de imagens recolhidas ainda era insuficiente para treinar um classificador robusto, uma vez que não cobriam totalmente as variações de padrões e condições de iluminação ou restantes variações na qualidade dos fotografamas obtidos.

Para ultrapassar esta limitação os autores utilizaram técnicas de *Data Augmentation* ou “aumento de dados”. As imagens de treino podem ser aumentadas em número por transformações geométricas, desfocagem e mudanças na escala de cores. Nas transformações geométricas pode-se aplicar rotação, translação e reflexão á imagem original, com isto pretende-se ter em conta a variação da direção e do ângulo em que uma imagem possa ser obtida. Com a desfocagem pretende-se simular a imagem em condições de luminosidade insuficiente ou desfocagem da câmara utilizada. Com as mudanças na escala de cores pretende-se considerar a variação da luminosidade e das características de cor da câmara utilizada.

O uso de técnicas de *Data Augmentation*, pode aumentar a base de dados inicial até 10 vezes. Na Figura 4-11, mostra-se um exemplo de aplicação de técnicas de aumento de dados a uma imagem contendo uma fissura.




Figura 4-11 - Transformação de imagem através de técnicas de aumento de dados (Kim, 2018)

Através das técnicas de aumento de dados, *Kim e Cho (2018)*, conseguiram obter 10 mil imagens para cada classe, o que corresponde a um total de 50 mil imagens. 40 mil imagens foram usadas para treino e 10 mil imagens para validação. O processo de treino decorreu durante 316 minutos e no final do treino foi obtida uma precisão de 99,39%. Apesar de utilizarem uma base de dados menor que a de *Cha et al (2017)*, e do curto tempo de treino num computador pessoal que o autor revela ser de fraco poder computacional, a precisão foi superior, o que revela a eficácia do *Transfer Learning*.

Posteriormente foi criada uma ferramenta para a detecção de fissuras utilizando também uma janela deslizante que percorre a imagem e a classifica fração a fração. Para incrementar a sua eficiência os autores aplicaram a sobreposição de janelas em conjunto com um mapa probabilístico, isto é, a imagem de teste é verificada pelo classificador em várias posições, posteriormente é efetuada uma média nos locais onde as janelas se sobrepõem, e sempre que essa média seja superior a 50%, a imagem deverá ser classificada como Fissura. Para melhor compreensão a figura 4-12, apresenta a aplicação do anteriormente relatado, em que de a) a c) é representado o método simplificado e de d) a f) o método probabilístico.

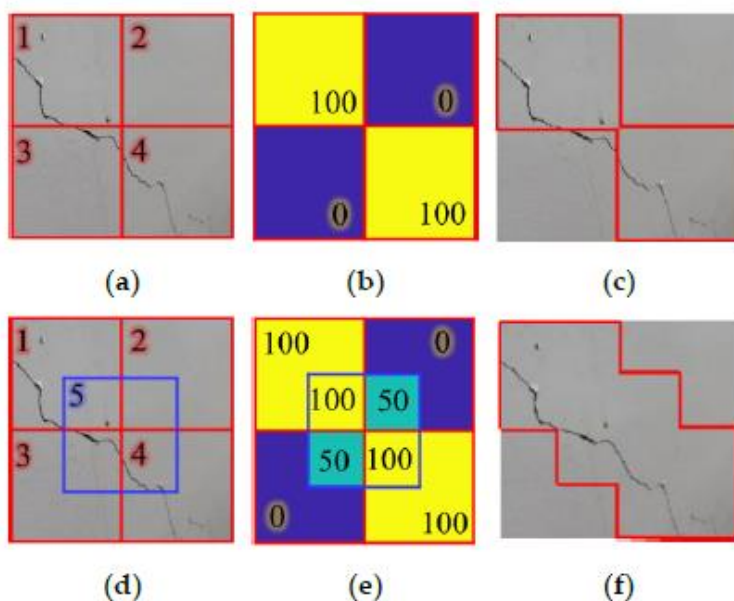


Figura 4-12 - Aplicação de uma janela deslizante através do método simplificado e probabilístico (Kim, 2018)

Através deste método foi possível minimizar erros na classificação das fissuras, pois os autores repararam que ao utilizar o método mais simples demonstrado na figura 4-12, nas alíneas de a) a c), o classificador descartava imagens com a fissura localizada num dos bordos da secção da imagem a testar.

Para validar o método de detecção automática de fissuras, 40 imagens obtidas com câmaras de *smartphones* bem como câmaras profissionais, foram utilizadas para teste. Após teste e análise das imagens foi obtida uma precisão de 97.02 % semelhante aos resultados obtidos por *Cha et al.* (2017).

A figura 4-13, representa um exemplo de uma imagem utilizada para teste, representando verdadeiros positivos (VP), falsos positivos (FP) e falsos negativos (FN), a verde, amarelo e vermelho respetivamente, enquanto os verdadeiros negativos são representados pelas áreas não demarcadas.

Os falsos positivos na imagem foram causados por pasta de cimento sobreposta no betão, causando o classificador a classificar incorretamente a secção com base no formato irregular.




Figura 4-13 - Exemplo de aplicação da ferramenta de detecção de fissuras desenvolvida por *Kim e Cho* (2018)

Kim e Cho (2018) testaram ainda a sua RNC utilizando um drone, fazendo a detecção de fissuras em tempo real. Como o drone está em constante movimento, as imagens resultantes podem por vezes ficar desfocadas, no entanto a RNC conseguiu classificar corretamente 15 das 16 fissuras detetadas na inspeção visual, viabilizando assim o método para aplicação em VANTs.

Os autores concluem que apesar do método apresentar uma boa performance, ainda apresenta algumas limitações e sugerem algumas soluções para minimizar os falsos positivos e falsos negativos, em estudos posteriores com base nos problemas por eles encontrados. Na Tabela 4-1, apresentam-se os problemas encontrados e soluções sugeridas pelos autores.

Tabela 4-1 – Soluções sugeridas por Kim e Cho (2018) para melhoria da RNC desenvolvida

Falsos Positivos	
Descrição	Soluções
Contaminantes com forma de fissura	Iluminação Suficiente; Adição de infravermelhos
Pasta de cimento sobreposta	Adição de infravermelhos
Poros distribuídos de forma linear	Adição destes elementos à base de dados
Bordos	Adição destes elementos à base de dados
Falsos Negativos	
Descrição	Soluções
Fissuras atrás de objetos	Imagens Dinâmicas (Vídeo)
Fissuras retilíneas	Adição destes elementos à base de dados
Fissuras em superfícies escuras	Adição de infravermelhos
Fissuras no canto da janela de classificação	Imagens Dinâmicas (Vídeo)

Apesar dos problemas encontrados, os autores pensam que métodos baseados em RNC, irão substituir as inspeções visuais num futuro próximo, uma vez que todos os problemas são facilmente ultrapassáveis. Referem ainda a utilização de veículos não tripulados como o meio mais provável para a realização de inspeções devido ao seu custo-eficácia.

CAPÍTULO 5

FERRAMENTAS DE DETEÇÃO DE FISSURAS E ARMADURAS EXPOSTAS.

Neste capítulo é descrito com detalhe como foram construídas as bases de dados utilizadas para treino, as opções tomadas para treino e as abordagens consideradas. O processo de construção da base de dados envolveu captação de imagens em contexto real, obtenção de imagens *online* e métodos para aumento de dados. A escolha do software e da arquitetura da RNC, bem como as abordagens sugeridas são fatores que condicionaram o desempenho das ferramentas desenvolvidas. Na Figura 5-1 encontra-se esquematizado o processo.



Figura 5-1 – Processo de treino de uma RNC

5.1 PESQUISA DE IMAGENS

O desenvolvimento das ferramentas de deteção iniciou-se com a aquisição de imagens das anomalias, bem como de betão intacto. Foram efetuadas várias pesquisas no motor de busca Google em diversos idiomas de modo a maximizar o número de resultados. Na tabela 5-1 encontram-se alguns dos termos pesquisados no motor de busca.

Tabela 5-1 - Pesquisas efetuadas em motores de busca

Fendilhação do betão	Armaduras expostas	Betão sem defeitos
Fendilhação do betão	Corrosão das armaduras	Betão
Fendas no betão	Armadura à vista	Cimento
Fissuras no cimento	Delaminação do betão	Textura de betão
Concrete Crack	Rebar Corrosion	Concrete texture
Grietas en estructuras de hormigón	Corrosión del acero en el hormigón armado	Cement texture
Fisuras en obras de hormigón	Corrosion des armatures	Hormigón
Fissuration du béton	Concrete corrosion	Béton

Após um processo de seleção das imagens, o número de imagens considerado válido foi o constante na tabela 5-2:

Tabela 5-2 - Número de imagens válidas após seleção

Fendilhação do betão	264
Armadura exposta	113
Betão sem defeitos	924

De seguida foi utilizado o programa PhotoScape de modo a dividir as imagens na resolução 227x227 píxeis.

A resolução anteriormente indicada foi selecionada pois é a mais convencional para “dados de entrada” nas RNC pré-treinadas. A Figura 5-2 representa um exemplo de uma imagem válida de armadura à vista, a qual foi submetida ao processo de divisão no Photoscape. A imagem originalmente tem uma resolução de 710x500 píxeis, sendo que após o processo de divisão foram obtidas 12 imagens, das quais apenas 6

ficaram com a resolução pretendida, assim as restantes foram descartadas. Também foram descartadas todas as imagens que após divisão não foram consideradas válidas para classificação.



Figura 5-2 – Interface do programa Photoscape (Photoscape, 2020)

Finalizado o processo de divisão e seleção de imagens, o número de imagens considerado válido foi o constante na Tabela 5-3

Tabela 5-3 - Número de imagens válidas após processo de divisão

Fendilhação do betão	2129
Armaduras expostas	921
Betão sem defeitos	9536

Segundo Cha et al (2018), o número mínimo de imagens para obter um classificador razoável é de 10 mil imagens, assim os números obtidos ficam aquém do expectável para um bom desempenho do classificador. O baixo número de imagens obtido deve-se sobretudo à baixa resolução das imagens encontradas *online*, o que não permite aumentar significativamente o número de imagens utilizadas para treino.

Deste modo decidiu-se capturar imagens em contexto real. Para tal foi utilizada uma câmara de *smartphone* com resolução de 4000x3000 píxeis, bem como uma câmara de drone da marca *DJI*, modelo *Mavic Mini* com uma resolução de 4000x2250 píxeis e também uma câmara profissional *Canon EOS 250d* com resolução 4000x3000 píxeis. Foram fotografados vários edifícios e infraestruturas que apresentavam

anomalias nos concelhos de Penafiel, Vila do Conde e Marco de Canaveses. As fotografias foram capturadas de várias distâncias, ângulos e em diferentes períodos do dia de modo a cobrir os mais variados cenários. Nas figuras 5-3 a 5-6 encontram-se alguns exemplos de locais onde as imagens foram obtidas.

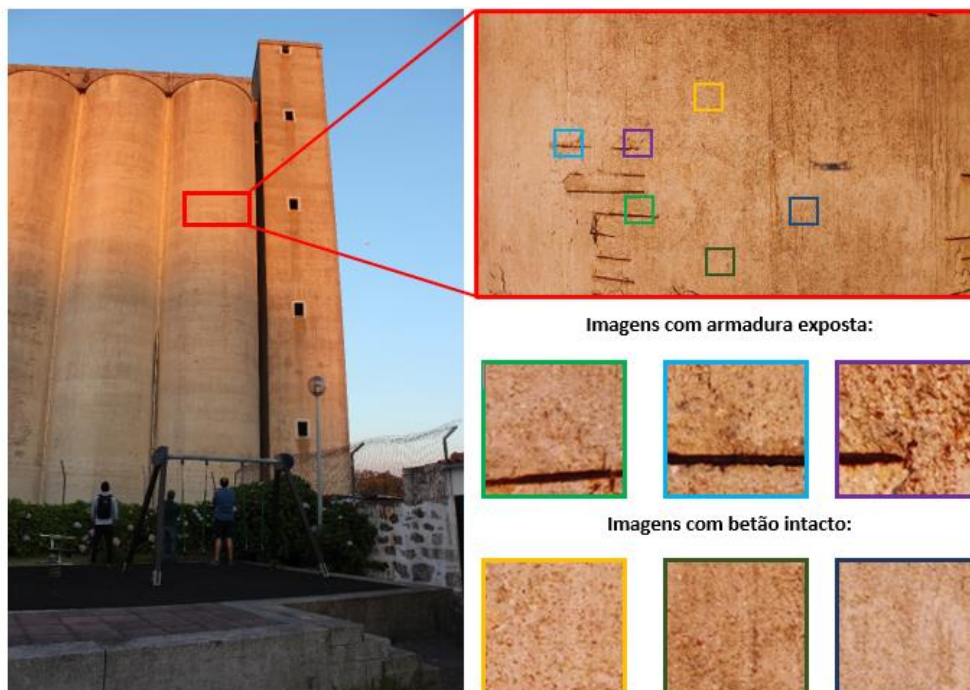


Figura 5-3 - Recolha de imagens de armaduras expostas, Vila do Conde




Figura 5-4 - Recolha de imagens de armaduras expostas, Penafiel




Figura 5-5 - Recolha de imagens de fissuras, Marco de Canaveses




Figura 5-6 - Recolha de imagens de fissuras, Penafiel

As imagens capturadas em contexto real passaram pelos mesmos processos de divisão e seleção, anteriormente referidos. A adição destas novas imagens provocou um aumento significativo a base de dados. Incluindo já os resultados anteriores, obteve-se o número de imagens constantes na Tabela 5-4.

Tabela 5-4 - Número de imagens válidas após adição de imagens capturadas

Fendilhação do betão	5129
Armaduras expostas	2264
Betão sem defeitos	15356

5.2 TÉCNICA DE AUMENTO DE DADOS

Os resultados obtidos ficam ainda aquém do pretendido, tornando-se assim necessária a utilização de técnicas de *Data Augmentation*. As imagens foram submetidas às seguintes transformações:

- Escurecimento da imagem em 70%
- Clareamento da imagem em 70 %
- Rotação de 90º à esquerda
- Rotação de 90º à direita
- Rotação de 180º
- Espelhamento na vertical
- Desfocagem da imagem

Na Figura 5-7 é possível visualizar o resultado da aplicação de diferentes transformações.

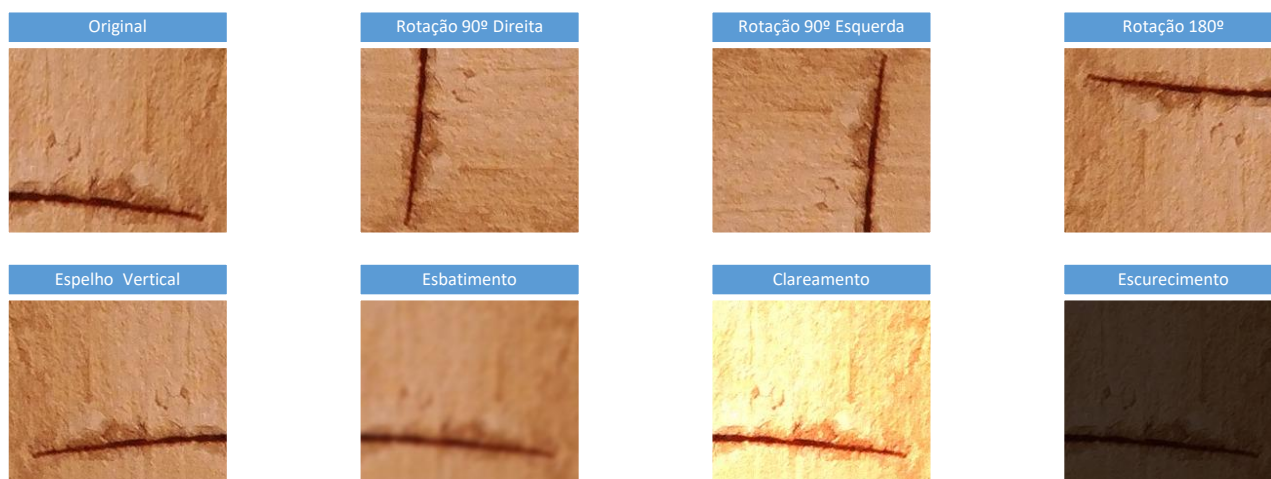


Figura 5-7 – Transformação de imagens para aumento de dados

Estas transformações permitiram que a base de dados aumentasse em 7 vezes o seu tamanho original, obtendo-se um número de imagens válidas suficiente para treino da RNC, conforme consta na Tabela 5-5.

Tabela 5-5 - Número de imagens válidas após aumento de dados

Fendilhação do betão	35903
Armaduras expostas	15848
Betão sem defeitos	107492

5.3 TREINO DA REDE NEURONAL CONVOLUCIONAL

Para realizar o treino da RNC utilizou-se o programa MatLab, com a *Deep Learning Toolbox*, na qual estão implementados alguns dos mais populares algoritmos de redes neuronais convolucionais.

Existem 20 algoritmos de redes neuronais convolucionais implementados no Matlab, entre as mais populares podem-se encontrar as redes *Alexnet*, *Googlenet*, *Resnet* e *VGG-19*. Estas redes diferem entre si na conceção das suas arquiteturas, variando o número de *layers*, parâmetros, dimensão dos dados de entrada e ocupação em disco. Isto leva a que as redes tenham comportamentos diferentes e consequentemente apresentem resultados diferentes, variando o tempo de treino e a precisão, na resolução do mesmo problema.

Optou-se por utilizar a rede pré-treinada *Alexnet* para o treino da RNC, não só por esta obtido um bom desempenho em experiências semelhantes, como a de Kim e Cho (2018), mas também devido ao tempo de treino bastante abaixo da média. *Alexnet* é uma rede neuronal convolucional com 8 camadas de profundidade que está treinada com mais de um milhão de imagens e pode classificar imagens em mil categorias. Como resultado esta RNC aprendeu de forma eficaz a extrair características de uma vasta gama de imagens. Isto como referido anteriormente, reduz significativamente o tempo de treino e o número de dados necessários, em relação a uma RNC treinada de raiz (Mathworks, 2020).

A Figura 5-8 ilustra o processo de treino da rede *Alexnet*, com a adição de novos dados.

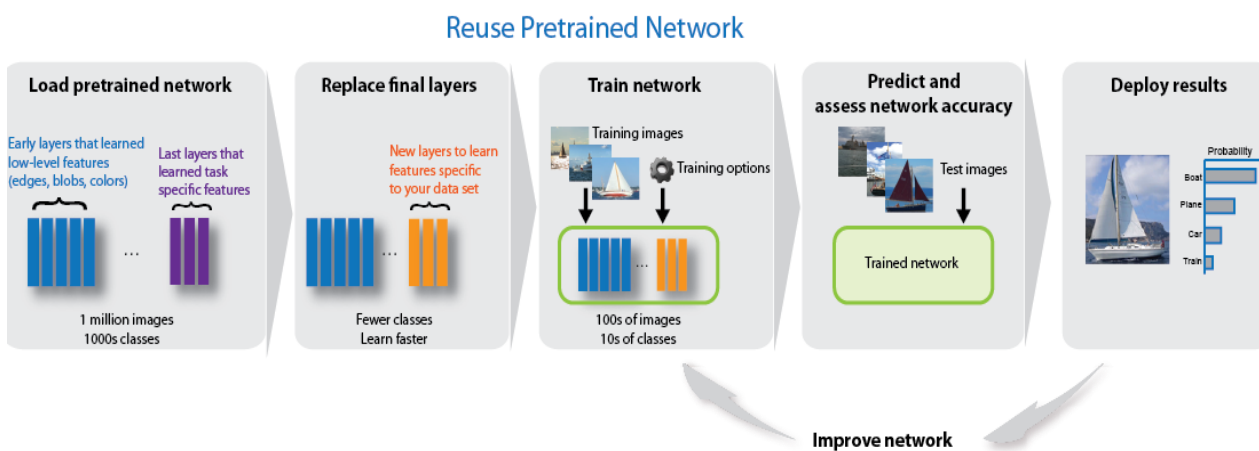


Figura 5-8 - Etapas de treino da rede Alexnet (Mathworks, 2020)

Para o treino adotaram-se três abordagens, com o propósito de testar a eficiência de cada uma delas e compará-las entre si.

- Abordagem 1: treino utilizando apenas duas categorias
- Abordagem 2: treino utilizando três categorias
- Abordagem 3: treino utilizando duas categorias com imagens pré-processadas (técnica mista)

Na primeira abordagem, para o treino da rede em deteção de fissuras foram criadas duas categorias, uma contendo imagens com fissuras e outra contendo betão intacto, ambas as categorias contendo 35 mil imagens cada.

Como a RNC *Alexnet* está configurada para mil categorias foi necessário fazer pequenas alterações nas suas camadas de modo a classificar apenas duas categorias. Para cada categoria subdividiram-se as imagens, 80% foram utilizadas para o treino da RNC e 20% para validação.

O treino foi efetuado num computador de média gama com as seguintes características:

- Processador: i5-7500
- Placa Gráfica: GTX 1050 2GB
- Motherboard: ASUS H110M-K
- RAM: HyperX Fury DDR4 8GB DDR4 (2400MHz)
- Disco Rígido: Kingston Disco SSD 120GB SATA 3 UV400 / TOSHIBA DISCO 3.5P 1TB
- SO: Windows 10 64bits

O treino demorou aproximadamente 12 horas, e a validação resultou numa eficiência de 98,3%.

Para o treino da rede em armadura exposta também foram criadas duas categorias, uma contendo imagens de betão com armadura exposta, e a outra imagem com betão intacto, ambas as categorias contendo 15 mil imagens cada. O restante processo foi similar ao processo descrito para o treino da rede em deteção de fissuras.

O treino teve uma duração aproximada de 8 horas, e a validação resultou numa eficiência de 96,6%.

Na segunda abordagem a rede neuronal foi treinada contendo as 3 categorias (betão intacto, fissuração e armadura exposta), contendo cada categoria 15 mil imagens. O treino demorou cerca de 10 horas e a validação resultou numa eficiência de 93%. Devido ao mau desempenho desta abordagem em resultados preliminares, decidiu-se não avançar com ela para a fase de testes.

Finalmente, na terceira abordagem, adotou-se uma técnica mista, a qual foi aplicada apenas para deteção de armadura exposta. Esta abordagem consistiu no pré-processamento das imagens de treino as quais posteriormente foram utilizadas para treino da RNC. Numa primeira abordagem ao pré-processamento optou-se por uma técnica de extração de cor das imagens de treino. Foram analisados vários píxeis de diferentes imagens e verificou-se que a coloração da armadura exposta com corrosão se situava no sistema de cores RGB dentro dos valores indicados na Tabela 5-6.

Tabela 5-6 – Limites da escala RGB para extração de armaduras expostas

Cor	Mínimo	Máximo
Vermelho (R)	32	158
Verde (G)	11	70
Azul (B)	5	70

Utilizando o Matlab foi criado um ciclo em que para cada imagem de treino se extraíam os píxeis que respeitavam as condicionantes da tabela anterior, excluindo os que não respeitavam. Estes píxeis foram depois convertidos na cor vermelha e sobrepostos na imagem original. A Figura 5-9 demonstra o processo.



Figura 5-9 – Etapas de pré-processamento

As imagens foram analisadas e foram descartadas as imagens que não correspondiam aos parâmetros como as da figura 5-10, em que manchas de ferrugem são detetadas por estarem dentro dos parâmetros de coloração.



Figura 5-10 - Imagens descartadas

A seleção resultou no descarte de 2500 imagens, sendo utilizadas 12500 imagens para treino.

O treino teve uma duração aproximada de 8 horas, e a validação resultou numa eficiência de 95,1%.

Na segunda abordagem ao pré-processamento, adotou-se uma técnica de extração de contornos, conforme descrito por Anderson Shibasaki na sua tese de mestrado, no entanto em testes preliminares esta técnica mostrou-se demasiado sensível ao ambiente em que se inseria e foi por isso descartada.

Cumprido o objetivo principal com resultados satisfatórios, tornou-se necessário desenvolver um sistema para avaliar imagens de teste de modo a comprovar a eficiência real da RNC.

Foi desenvolvido um código no Matlab que processa uma imagem introduzida por frações, à semelhança do que foi descrito por Kim e Cho (2018). A janela deslizante percorre a imagem com intervalos (*strides*) de 113 píxeis no caso das fissuras e 227 píxeis no caso de armaduras expostas, tanto na direção horizontal como na vertical, sendo que sempre que a média nas zonas de sobreposição seja superior a 50%, o

classificador remete um resultado positivo. A Figura 5-11 esquematiza o funcionamento de uma janela deslizante.



Figura 5-11 – Esquemática do funcionamento da janela deslizante

A razão da utilização de um intervalo menor para a detecção de fissuras prende-se com a incapacidade da RNC em detetar fissuras em bordos de uma imagem, conforme descrito por Kim e Cho (2018). Já na detecção de armaduras esse problema não foi encontrado nos testes preliminares, pelo que se optou pelo método simplificado, reduzindo assim o tempo de processamento em cerca de 75%.

O princípio básico de funcionamento consiste no escurecimento da imagem nas frações onde o classificador não encontrou anomalias, destacando assim as zonas com anomalias na imagem processada. Conforme mostra o exemplo da Figura 5-12.



a) Imagem original

b) Imagem processada

Figura 5-12 – Imagem original e imagem processada

CAPÍTULO 6

CASOS DE ESTUDO

Neste capítulo serão retratados alguns exemplos da aplicação das ferramentas desenvolvidas.

Pretende-se comparar a eficiência entre as 2 ferramentas validadas desenvolvidas.

Foram selecionados quatro casos de estudo, dois para detecção de fissuras e dois para detecção de armaduras expostas.

6.1 DETECÇÃO DE FISSURAS

O primeiro caso de estudo para a detecção de fissuras foi o edifício F, do campus do Instituto Superior de Engenharia do Porto (Figura 6-1).

O edifício F do ISEP é um projeto da autoria do arquiteto português Filipe Oliveira Dias, ocupando uma área de 13 200 m², que representou, à data da sua edificação, uma aposta de crescimento do ISEP.

O edifício é composto por 5 pisos acima da cota de soleira e um piso enterrado destinado ao estacionamento de veículos. No rés-do-chão possui oficinas e laboratórios e nos restantes pisos, encontram-se salas de aula, gabinetes de professores, anfiteatros, laboratórios e um restaurante. Atualmente este edifício está afeto aos cursos de mecânica, mecânica automóvel, gestão industrial e eletrotecnia, tendo ainda laboratórios dedicados a outros cursos lecionados no ISEP.



Figura 6-1 - Edifício F do ISEP (Flickr, 2020)

Nas Figuras 6-2 a 6-5 encontram-se os resultados da aplicação da ferramenta de deteção de fissuras. Sublinhados a cor vermelha, visualizam-se falsos positivos e a cor verde falsos negativos.



Figura 6-2 – Imagem 1 (Original, Fissuras, Edifício F)




Figura 6-3 – Imagem 1 (Abordagem 1 (RNC), Fissuras, Edifício F)




Figura 6-4 – Imagem 2 (Original, Fissuras, Edifício F)

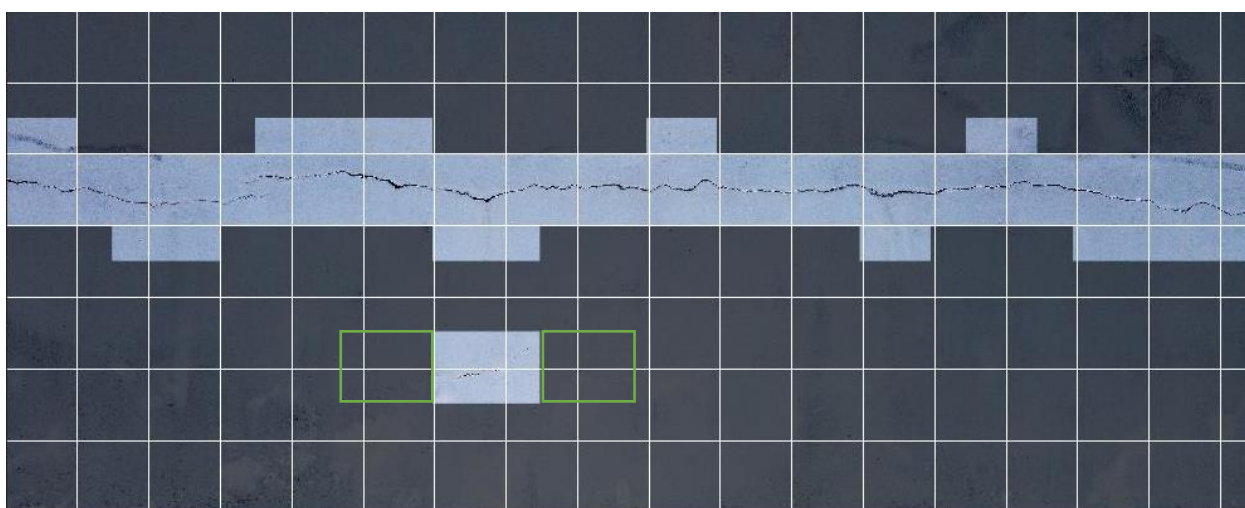


Figura 6-5 – Imagem 2 (Abordagem 1 (RNC), Fissuras, Edifício F)

O segundo caso de estudo trata-se de um edifício localizado na Rua de Santa Mafalda, freguesia de Alpendorada, Várzea e Torrão, concelho de Marco de Canaveses (Figura 6-6).

O edifício tem como dimensões aproximadas, 60 m de comprimento, 16m de largura e 15 m de altura. Possui 5 pisos acima da cota de soleira e um piso enterrado. O edifício que teria como destino uma unidade hoteleira, iniciou a sua construção no final dos anos 90, mas o projeto foi abandonado devido à falta de financiamento.



Figura 6-6 - Edifício em estudo

Os vinte anos de abandono e exposição aos elementos levaram a que o edifício desenvolvesse diversas anomalias. As imagens foram na sua maioria recolhidas na cave, com recurso ao *flash* da câmara fotográfica. Nas Figuras 6-7 a 6-16 encontram-se os resultados obtidos.



Figura 6-7 – Imagem 1 (Original, Fissuras, Unidade Hoteleira)




Figura 6-8 - Imagem 1 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)



Figura 6-9 - Imagem 2 (Original, Fissuras, Unidade Hoteleira)




Figura 6-10 - Imagem 2 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)



Figura 6-11 - Imagem 3 (Original, Fissuras, Unidade Hoteleira)




Figura 6-12 - Imagem 3 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)



Figura 6-13 - Imagem 4 (Original, Fissuras, Unidade Hoteleira)



Figura 6-14 - Imagem 4 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)




Figura 6-15 - Imagem 5 (Original, Fissuras, Unidade Hoteleira)




Figura 6-16 - Imagem 5 (Abordagem 1 (RNC), Fissuras, Unidade Hoteleira)

Outras imagens foram testadas de modo a ter dados suficientes para serem tiradas conclusões acerca da performance da ferramenta desenvolvida, apresentando-se anteriormente apenas uma pequena parte exemplificativa dos testes efetuados.

Pelas imagens observadas há pouco a apontar sobre a performance da ferramenta. Pode-se constatar que quando a fissura fica demasiado ténue a RNC não tem capacidade para a detetar como tal. Também se observou numa das imagens que um vazio foi erradamente detetado como fissura.

Como na deteção de fissuras foi utilizado um *stride* menor, torna-se mais complicado contabilizar a eficiência real da ferramenta por aplicação duma fórmula. No entanto por observação pode-se afirmar que esta é bastante elevada.

6.2 DETEÇÃO DE ARMADURAS EXPOSTAS

O primeiro caso de estudo para a deteção de armaduras expostas trata-se de um edifício industrial, localizado no lugar de Formariz, freguesia e concelho de Vila do Conde, junto á margem do Rio Ave e a cerca de dois quilómetros do Oceano Atlântico. É um edifício de grande dimensão com cerca de 20 metros de largura, 100 metros de comprimento e 35 metros de altura.

O edifício, agora abandonado, pertencente à empresa “Prazol”, outrora dedicava-se á moagem, tratamento e armazenamento de sementes e óleos alimentares. Fazia parte de um conglomerado de empresas fundado em 1920 por Agostinho Fernandes, o “Algarve Exportador”, que atuava especialmente na área da alimentação. A empresa entrou em declínio nos finais do século XX, e acabaria por encerrar na década de 80. O complexo industrial do qual o edifício em estudo faz parte, encontra-se agora em avançado estado de degradação (Ferro, 2002).



Figura 6-17 - Edifício em estudo (visto da ponte de Formariz)



Figura 6-18 - Edifício em estudo (visto do Bairro do Rio Ave)

No dia 17 de julho de 2020, entre as 19h30 e as 21h00, foi efetuada a primeira visita ao edifício com intuito de recolher imagens para alargar a base de dados utilizada para a aprendizagem da RNC. Foram capturadas imagens com recurso a drone e máquina fotográfica profissional, dos primeiros três silos, a partir do Bairro do Rio Ave no sentido Sudoeste-Nordeste. Foi concedida à equipe de trabalho a permissão de captação de imagens, no entanto as imagens teriam que ser captadas fora do complexo industrial por questões de segurança. Este fator aliado a restrições de ordem técnica do drone utilizado, limitou bastante as possíveis zonas de captação de imagens. Na Figura 6-19 pode visualizar-se a zona de captação de imagens, representada pelo retângulo ciano e a zona da estação de trabalho, onde era efetuado o controlo do drone, representada pelo círculo ciano. Na Figura 6-20 é possível visualizar o grupo de trabalho na estação de trabalho.

Conforme descrito no capítulo anterior a utilização das imagens captadas em contexto real, tornaram a RNC mais robusta e eficiente.



Figura 6-19 – Estação de trabalho e zona de captação de imagens



Figura 6-20 - Grupo de trabalho

A segunda visita ocorreu no dia 5 de setembro de 2020, entre as 10h30 e as 12h30, com o propósito de capturar imagens para efetuar o teste das ferramentas desenvolvidas. O local escolhido para a captura de imagens foi o quarto silo, no sentido Sudoeste-Nordeste, na estação de trabalho anterior. Foram selecionadas 10 imagens, para efetuar os testes com as ferramentas desenvolvidas, perfazendo um total de 20 testes. De seguida (Figuras 6-21 a 6-41) são apresentados os resultados dos testes, apresentado em primeiro lugar a imagem original, em segundo lugar a imagem processada pelo método da primeira abordagem e finalmente a imagem processada pelo método da terceira abordagem, referidas no final do capítulo anterior. Sublinhados a cor vermelha, visualizam-se falsos positivos e a cor verde falsos negativos. De modo a aferir a precisão da RNC utilizou-se a fórmula 6-1.

$$P = \frac{VN + VP}{VN + VP + FN + FP} \times 100 \quad (6-1)$$

em que:

P – representa a precisão da RNC em percentagem

VN – representa o número de verdadeiros negativos

VP – representa o número de verdadeiros positivos

FN – representa o número de falsos negativos

FP – representa o número de falsos positivos



Figura 6-21 – Imagem 1 (Original, Armaduras expostas, Edifício industrial)




Figura 6-22 - Imagem 1 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-23 - Imagem 1 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)



Figura 6-24 – Imagem 2 (Original, Armaduras expostas, Edifício industrial)




Figura 6-25 – Imagem 2 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-26 - Imagem 2 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)



Figura 6-27 – Imagem 3 (Original, Armaduras expostas, Edifício industrial)



Figura 6-28 – Imagem 3 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-29 – Imagem 3 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)



Figura 6-30 – Imagem 4 (Original, Armaduras expostas, Edifício industrial)




Figura 6-31 -Imagem 4 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-32 – Imagem 4 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)



Figura 6-33 – Imagem 5 (Original, Armaduras expostas, Edifício industrial)




Figura 6-34 – Imagem 5 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-35 – Imagem 5 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)




Figura 6-36 – Imagem 6 (Original, Armaduras expostas, Edifício industrial)




Figura 6-37 – Imagem 6 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-38 – Imagem 6 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)



Figura 6-39 – Imagem 7 (Original, Armaduras expostas, Edifício industrial)




Figura 6-40 - Imagem 7 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-41 - Imagem 7 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Edifício industrial)

A Tabela 6-1, apresenta uma comparação entre a precisão das duas abordagens.

Tabela 6-1 – Precisão das abordagens em estudo

Imagem	RNC (%)	Pré-processamento + RNC (%)
1	100,00	100,00
2	98,75	94,38
3	98,00	96,00
4	97,53	82,90
5	97,78	78,30
6	100,00	99,29
7	98,40	97,70
8	93,89	66,44
9	97,50	74,98
10	97,20	77,51

Obteve-se em média para este caso de estudo uma eficiência de 97,91% no caso da RNC pura e de 86,75% no caso da RNC com pré-processamento das imagens.

Como se pode observar, ao contrário do que seria expectável, as imagens com pré-processamento apresentam em geral piores resultados. Isto deve-se provavelmente numa fase inicial aos filtros aplicados no pré-processamento que são sensíveis às condições de captura da imagem, podendo a escala de cores variar conforme a luminosidade do local. Também durante o treino da RNC com estes filtros, é atribuído um maior peso à característica mais relevante, ou seja, como todas as imagens passam num filtro para tornar a gama de cores de metal corroído na cor vermelha, no treino a RNC reconhece a cor vermelha como a principal característica comum entre todas as imagens, atribuindo-lhe um maior peso. Isto faz com que manchas de ferrugem sejam detetadas erroneamente como armaduras expostas. No entanto, trata-se apenas de uma hipótese, podendo outros fatores terem contribuído para o desempenho abaixo do expectável nesta abordagem.

Na abordagem com RNC pura, obtiveram-se resultados dentro do esperado. Alguns dos falsos positivos estão associados a cenários avançados de delaminação e por isso de classificação difícil, mesmo em inspeção visual.

Para o segundo caso de estudo usaram-se imagens da Torre Altice em Vila Nova de Gaia, capturadas no âmbito de trabalhos anteriores. (Teixeira, 2019)

A Torre Altice, é uma torre de telecomunicações localizada no Monte da Virgem em Vila Nova de Gaia. Tem uma altura de 177 m, compostos por um fuste de betão armado com 126 m e uma torre metálica com 51 m, sendo assim a maior torre de telecomunicações em Portugal. O seu diâmetro é variável, apresentando na base 14,3 m e no topo do fuste de betão armado 7,7 m (Figura 6-42).

A obra da autoria do Ar. António da Silva Botelho e do Eng. João Pires da Fonseca, foi construída entre 1993 e 1995, tem 5 pisos, acessíveis via elevador ou escadas metálicas e tem como principal função assegurar a emissão do sinal de Televisão Digital Terrestre.



Figura 6-42 - Torre Altice (Martins, 2018)

Nas Figuras 6-43 a 6-48 apresentam-se as imagens processadas pelas ferramentas desenvolvidas, seguindo a mesma lógica do caso de estudo anterior.




Figura 6-43 – Imagem 1 (Original, Armaduras expostas, Torre Altice)




Figura 6-44 – Imagem 1 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-45 – Imagem 1 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Torre Altice)



Figura 6-46 – Imagem 2 (Original, Armaduras expostas, Torre Altice)




Figura 6-47- Imagem 2 (Abordagem 1 (RNC), Armaduras expostas, Edifício industrial)




Figura 6-48 – Imagem 2 (Abordagem 3 (Busca RGB+RNC), Armaduras expostas, Torre Altice)

A tabela 6-2 apresenta uma comparação entre a precisão das duas abordagens.

Tabela 6-2 - Precisão das abordagens em estudo

Imagem	RNC (%)	Pré-processamento + RNC (%)
1	100,00	83,57
2	100,00	94,00

Verifica-se que o mesmo problema sucede neste caso de estudo para a abordagem com pré-processamento, onde manchas dentro dos limites RGB programados são erroneamente detetadas como armaduras expostas, gerando vários falsos positivos. O pré-processamento interfere em todo o processo posterior, e como se pode comprovar, esta abordagem não se adequa para utilização em contexto real.

No caso da RNC pura, a eficiência foi bastante superior em ambos os casos de estudo, apresentando uma eficiência média de 98,25%. Os principais erros de deteção consistem em falsos positivos, onde manchas concentradas de ferrugem e fissuras de grande abertura são erroneamente confundidas com armaduras expostas, o que não é necessariamente mau, pois muitas dessas fissuras e manchas podem num futuro próximo tornar-se armaduras expostas, e assim a RNC tem também um caráter preventivo no que toca á deteção desta anomalia. Os falsos negativos detetados são pouco comuns e encontram-se principalmente em pequenos pontos de armadura exposta, que ocupavam uma parte mínima da região de interesse e por isso a RNC não os assumiu como sendo uma anomalia.

CAPÍTULO 7

CONSIDERAÇÕES FINAIS

7.1 CONCLUSÕES

A presente dissertação teve por objetivo desenvolver ferramentas semiautomáticas para a detecção de anomalias nas construções de betão armado. O desenvolvimento destas ferramentas surgiu com a necessidade de reduzir custos monetários e riscos associados à inspeção de estruturas de grande dimensão ou com difícil acesso para pessoas.

A aplicação das ferramentas na primeira abordagem decorreu com sucesso, encontrando-se taxas de eficiência dentro do expectável. Os principais desvios encontrados para a detecção de armadura exposta foram os falsos positivos em manchas concentradas de corrosão e fissuras associadas a delaminações, mas ainda sem armadura exposta. Já na detecção de fissuras, os falsos negativos com fissuras demasiado ténues foram o principal desvio encontrado.

As restantes abordagens não cumpriram com o expectável tendo sido abandonadas. A ferramenta treinada com três categorias acabou por se mostrar pouco eficiente pois acabava por confundir fissuras com armaduras expostas. Isto deveu-se provavelmente às fissuras associadas às delaminações na categoria de armadura exposta, que levou a RNC a entrar em conflito. A ferramenta com pré-processamento demonstrou ser demasiado sensível às condições de captura, demonstrando por isso piores resultados que a RNC pura.

O presente trabalho constitui um passo inicial nesta temática, inovadora e ainda pouco reportada na bibliografia da especialidade, mas os resultados obtidos demonstram que as RNC's poderão ser uma técnica promissora na inspeção de estruturas num futuro próximo.

7.2 DESENVOLVIMENTOS FUTUROS

Como desenvolvimentos futuros sugere-se o desenvolvimento de uma RNC, com múltiplas categorias contendo um maior número de anomalias. Para isto dever-se-á ultrapassar os problemas de conflitos entre categorias, o que poderá provavelmente ser conseguido aumentando significativamente a base de dados de imagens para cada categoria. Sugere-se também a introdução de categorias com elementos não estruturais que se podem encontrar nas construções, como tubos de queda, portas, janelas ou luminárias, isto poderá ajudar a rede a categorizar esses elementos, diminuindo a probabilidade de falsos positivos por falta de reconhecimento da RNC.

Pensa-se que imagens captadas com uma proximidade fixa à estrutura quer para treino, quer para teste poderá ser benéfico para eficiência da RNC uma vez que a qualidade da imagem é um fator importante no reconhecimento de uma anomalia, e permite ainda tirar partido da distância focal da lente, para por exemplo medir a espessura e extensão de uma fissura. Deverá assim ser pensada uma padronização da inspeção.

Sugere-se ainda a implementação em tempo real da deteção de anomalias, introduzindo num veículo aéreo não tripulado o “*software*” e “*hardware*” necessários para processar imagens em tempo real.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, Sara - Sistematização dos padrões de fissuração correntes em edifícios, Lisboa: IST, 2015.
Tese de Mestrado em Engenharia Civil

ALPAYDIM, Ethem - Introduction to Machine Learning, Nova Iorque: MIT Press, 2010.

ALVES, Gisely - Entendendo Redes Convolucionais [online]. [consultado em 1 de Agosto de 2020].
Disponível em - <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>

APPLETON, Júlio - Construções em betão - Nota histórica sobre a sua evolução. Lisboa: IST.

ARAÚJO, David - Reparação de Fendas em Elementos Construtivos de Betão Armado. Lisboa. IST, 2016.
Tese de Mestrado em Engenharia Civil.

BANSAL, Shubham - Supervised and Unsupervised learning [online]. [consultado em 8 de Agosto de 2020]. Disponível em <https://www.geeksforgeeks.org/supervised-unsupervised-learning/>

BlogLPE - Reação Álcali-Agregado (RAA) [online]. [consultado em 3 de Março de 2020]. Disponível em <http://lpe.tempsite.ws/blog/index.php/reacao-alkali-agregado-raa-ela-pode-afetar-o-pavimento-ou-piso-de-concreto/>

By-Bridge [online]. [consultado em 5 de março de 2020]. Disponível em <https://www.giffinoleggi.com/noleggio/prenota/step/1/mezzo/212/by-bridge-sottoponte/212>

BRITO, Jorge - Diagnóstico e patologia de construções em betão armado. Lisboa: IST.

CHA, Young-Jin; Choi, Wooram ; Buyukozturk, Oral - Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. Winnipeg: Computer-Aided Civil and Infrastructure Engineering, 2017.
ISSN 1467-8667.

CIRESAN, Dan C., et al. - Flexible, High Performance Convolutional Neural Networks for Image Classification. Manno-Lugano: Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence, 2011

CivilBlog [online]. [consultado em 1 de Março de 2020]. Disponível em <https://civilblog.org/2017/07/22/10-factors-causing-fissuration-concrete/>

CNN Convolution On RGB Images [online]. [consultado em 8 de Março de 2020]. Disponível em <http://deeplearningbook.com.br/a-arquitetura-das-redes-neurais/>

Constrofacilitator [online]. [consultado em 12 de Abril de 2020]. Disponível em <https://www.constrofacilitator.com/alternative-materials-used-for-road-construction/>

Convolutional Neural Network [online]. [consultado em 12 de Maio de 2020]. Disponível em <https://towardsdatascience.com/covolutional-neural-network-cb0883dd6529>

Convolutional Neural Network, 3 things you need to know [online]. [consultado em 12 de Maio de 2020]. Disponível em <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>

CORREIA, Sérgio - Catálogo de técnicas de diagnóstico em elementos estruturais de edifícios correntes em betão armado, Lisboa. IST, 2014. Tese de Mestrado em Engenharia Civil

COSTA, António – Mecanismos de deterioração em estruturas de betão armado, Lisboa. IST, 1999.

COUTINHO, A. de Sousa – Fabrico e Propriedades do betão: Volume I. 5ª ed. Laboratório Nacional de Engenharia Civil, 2012. ISBN 978-972-49-0326-2.

COUTINHO, J.S. – Melhoria da durabilidade dos betões por tratamento da cofragem, Porto: FEUP, 1998. Tese de doutoramento em Engenharia Civil.

DENG, L.; Yu, D - Deep Learning: Methods and Applications, Redmond: Foundations and Trends in Signal Processing, 2014. ISBN 978-1-60198-814-0.

Dreamstime [online]. [consultado em 11 de Julho de 2020]. Disponível em <https://pt.dreamstime.com/image-free-94710282/>

E-civil [online]. [consultado em 1 de Setembro de 2020]. Disponível em <http://www.ecivilnet.com/artigos/23456.html>

ELLENBERG, A. et al. Bridge related damage quantification using unmanned aerial vehicle imagery. Structural Control And Health Monitoring. [S.l], p. 1168-1179. 20 jan. 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/epdf/10.1002/stc.1831>

FERRO, Silvestre Marchão - Vultos na Toponímia de Lagos, Lagos: Câmara Municipal de Lagos. 358 páginas. ISBN 972-8773-00-5

Flickr - Edifício F ISEP [online]. [consultado em 20 de Setembro de 2020]. Disponível em <https://www.flickr.com/photos/politecnicoporto/3248456192/>

Gromicko, N., Shepard, K. and Cyr, M. (2014) Visual Inspection of Concrete, [Online], Disponível em: <http://www.nachi.org/visual-inspection-concrete.htm>

Inspectapedia [online]. [consultado em 1 de Junho de 2020]. Disponível em https://inspectapedia.com/Building_Damage/Building-Damage-Assessment.php

JACOME, Carlos da Cruz; MARTINS, João Guerra. Identificação e tratamento de patologias em edifícios - Série REABILITAÇÃO, 2005.

KAVLAKOGLU, Eda - Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference? [online]. [consultado em 10 de Agosto de 2020]. Disponível em <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networksAI>

KIM, Byunghyun; Cho, Soojin - Automated Vision-Based Detection of Cracks on Concrete Surfaces Using a Deep Learning Technique. Seul: Sensors, 2018. ISSN 1424-8220.

KIM, Hyunjun, et al. - Crack and Noncrack Classification from Concrete Surface Images Using Machine Learning. Thousand Oaks: Structural Health Monitoring (SAGE). ISSN: 1475-9217.

LAPA, José Silva. - Patologia, recuperação e reparo das estruturas de concreto. Monografia para obtenção de título de especialização em Construção Civil : Universidade Federal de Minas Gerais, 2008.

LAVAGNOLI, Sílvia - Machine Learning ou Deep Learning? [online]. [consultado em 20 de Junho de 2020]. Disponível em <https://opencadd.com.br/machine-learning-ou-deep-learning/>

Leica Geosystems [online]. [consultado em 17 de Setembro de 2020]. Disponível em <https://leica-geosystems.com/case-studies/reality-capture/aiviewgroup-using-leica-geosystems-uav-solution-for-bridge-inspections>

LOVELACE, Barrit - Unmanned Aerial Vehicle Bridge Inspection Demonstration Project, Minnesota: Minnesota Department of transportation, 2015]. Disponível em <http://www.dot.state.mn.us/research/TS/2015/201540.pdf>

MARTINS, Carlos - Torre do Monte da Virgem abre ao público no Open House Porto [online]. [consultado em 15 de setembro de 2020]. Disponível em <https://abertoatedemadrugada.com/2018/06/torre-do-monte-da-irgem-abre-ao.html>

Machine Learning, o que é e qual sua importância? [online]. [consultado em 07 de Maio de 2020]. Disponível em https://www.sas.com/pt_br/insights/analytics/machine-learning.html

Mathworks - Deep Learning [online]. [consultado em 10 de Maio de 2020]. Disponível em <https://www.mathworks.com/discovery/deep-learning.html>

Mathworks - Alexnet [online]. [consultado em 15 de maio de 2020]. Disponível em <https://www.mathworks.com/help/deeplearning/ref/alexnet.html>

Medium - Understanding of Convolutional Neural Network (CNN) — Deep Learning [online].

[consultado em 13 de Maio de 2020]. Disponível em

<https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148>

NP EN 1992. 2010. Eurocódigo 2 – **Projeto de estruturas de betão**, Parte 1-1: Regras gerais e Regras para Edifícios. Monte da Caparica. Instituto Português da Qualidade.

PAI, Aravind - CNN vs. RNN vs. ANN – Analyzing 3 Types of Neural Networks in Deep Learning [online].

[consultado em 15 de agosto de 2020]. Disponível em

<https://abertoatedemadrugada.com/2018/06/torre-do-monte-da-virgem-abre-ao.html>

Rainguard [online]. [consultado em 18 de Maio de 2020]. Disponível em <https://rainguard.com/7892s/>

REBAP – Regulamento de estruturas de betão armado e pré-esforçado. **Decreto-Lei n.º 349-C/83.** D.R. I Série. 174 (83-07-30).

Rede Feed-Forward [online]. [consultado em 7 de Março de 2020]. Disponível em

<http://deeplearningbook.com.br/a-arquitetura-das-redes-neurais/>

Redes neurais roots #1 — introdução [online]. [consultado em 13 de Maio de 2020]. Disponível em

<https://medium.com/ensina-ai/redes-neurais-roots-1-introdução-ffdd6f8b9f01>

Restos de Coleção - Viaduto Duarte Pacheco [online]. [consultado em 1 de Março de 2020]. Disponível em <https://restosdecoleccion.blogspot.com/2013/07/viaduto-de-duarte-pacheco.html>

RODRIGUES, Carlos – **Inspeção e reforço de Estruturas:** Apontamentos da aula de INSRE: Porto, ISEP, 2019.

SHIBASAKI, Anderson - **Inspeção da torre do monte da virgem com auxílio de um veículo aéreo não tripulado.** Porto: ISEP, 2019. Tese de Mestrado em Engenharia Civil.

Shutterstock [online]. [consultado em 18 de Março de 2020]. Disponível em

<https://www.shutterstock.com/pt/featured-collections/233765765>

SILVA, Joana – **Métodos eletroquímicos para Prevenção da Deterioração e Reparação das Estruturas de betão armado: Proteção catódica, Dessalinização e Realcalinização,** Lisboa: Instituto Superior Técnico, 2007.

SILVA, José António Raimundo Mendes - **Fissuração das alvenarias - Estudo do comportamento das alvenarias sob acções térmicas:** Coimbra, 1998. Dissertação de Doutoramento em Engenharia Civil, especialidade de Construções.

SILVA, Wilson; Lucena, Diogo - Concrete Cracks Detection Based on Deep Learning Image Classification. Bruxelas: Sensors, 2018. ISSN 1424-8220.

TEIXEIRA, Hélio - Inspeção da torre de telecomunicações do monte da virgem com auxílio de um veículo aéreo não tripulado. Porto: ISEP, 2019. Tese de Mestrado em Engenharia Civil.

Theconstructor [online]. [consultado em 15 de Agosto de 2020]. Disponível em <https://theconstructor.org/construction/document-control-construction/224869/>

TONG, Zheng; Gao, Jie; Zhang Haitao - Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks. Xiao: Construction and Building Materials, volume 146, 2017. ISSN: 0950-0618

Torre Altice [online]. [consultado em 20 de Setembro de 2020]. Disponível em <https://abertoatedemadrugada.com/2018/06/torre-do-monte-da-virgem-abre-ao.html>

ANEXO I – OPÇÕES DE TREINO DA RNC – 2 CATEGORIAS

```
%% carregar a CNN pré-treinada
alex = alexnet;
layers = alex.Layers;

%% Modificar a CNN para 2 categorias
layers(23)=fullyConnectedLayer(2);
layers(25)=classificationLayer;

%% Dados para treino
allImages = imageDatastore('C:\Users\Paulo\Desktop\Matlab CNN\dbprefinal',
'IncludeSubfolders', true, 'LabelSource', 'foldernames');
[trainingImages, testImages] = splitEachLabel(allImages, 0.8, 'randomize');

%% Retreinar CNN
opts = trainingOptions('sgdm', 'InitialLearnRate', 0.001, 'MaxEpochs', 20,
'MiniBatchSize', 64);
CRS= trainNetwork(trainingImages, layers, opts);

%% Testar Fiabilidade
testImages.ReadFcn = @readFunctionTrain;
predictedLabels = classify(CRS, testImages);
accuracy = mean(predictedLabels == testImages.Labels)
```

ANEXO II – OPÇÕES DE TREINO DA RNC – 3 CATEGORIAS

```
%% carregar a CNN pré-treinada
alex = alexnet;
layers = alex.Layers;

%% Modificar a CNN para 2 categorias
layers(23)= fullyConnectedLayer(3);
layers(25)=classificationLayer;

%% Dados para treino
allImages = imageDatastore('C:\Users\Paulo\Desktop\Matlab CNN\treino 3
categorias', 'IncludeSubfolders', true, 'LabelSource', 'foldernames');
[trainingImages, testImages] = splitEachLabel(allImages, 0.8, 'randomize');

%% Retreinar CNN
opts = trainingOptions('sgdm', 'InitialLearnRate', 0.001, 'MaxEpochs', 20,
'MiniBatchSize', 64);
mcat= trainNetwork(trainingImages, layers, opts);

%% Testar Fiabilidade
predictedLabels = classify(mcat, testImages);
accuracy = mean(predictedLabels == testImages.Labels);
```

ANEXO III – SLIDING WINDOW

```

%% Carregar CNN

load CRS % introduzir a variavel conforme o que se pretende testar

%% Deteção de Positivos

sizeWindowROI = int16(227); % Tamanho predefinido da CNN
stride = int16(227); % numero de pixeis que a janela avança por classificação
(stride) (para fissuras = 113)
numPosROI = 0; % numero de positivos (ciclo começa em zero)
ROIstore = []; % Matriz que guarda todos os positivos
coordsROIstore = []; % Matriz que guarda as coordenadas dos positivos

    % cálculo do rácio entre a região de interesse e o stride
    ratioWindowStride = idivide(sizeWindowROI, stride, 'fix');
% Obter imagem
imgFile = uigetfile('*.jpg', 'Select source file');

    % Obter informação da imagem
imgInfo = imfinfo(imgFile);
imgWidth = int16(imgInfo.Width);
imgHeight = int16(imgInfo.Height);

    % array
imgOriginal = imread(imgFile);
imgDetected = imread(imgFile) / 2.5; % imagem 2.5 vezes mais escura que a
original

% criação de ciclo
    % numero de linhas e colunas da imagem
coll = idivide(imgWidth, sizeWindowROI, 'fix');
row = idivide(imgHeight, sizeWindowROI, 'fix');

    % Deteção de positivos
    % Deteção dos positivos eceto ultima linha e ultima coluna
    for i = 1:((row*ratioWindowStride)-(ratioWindowStride-1))
        for j = 1:((coll*ratioWindowStride)-(ratioWindowStride-1))
            ROI = imgOriginal((1+((i-1)*stride)):((i-
1)*stride+sizeWindowROI), (1+((j-1)*stride)):((j-1)*stride+sizeWindowROI),
:);

            classROI = classify(CRS, ROI);

            if classROI == 'Positivo'
                imgDetected((1+((i-1)*stride)):((i-
1)*stride+sizeWindowROI), (1+((j-1)*stride)):((j-1)*stride+sizeWindowROI), :)
= ROI;

                numPosROI = numPosROI + 1;
                ROIstore = cat(3, ROIstore, ROI);
                sizeROIstore = size(ROIstore, 3);

                coordsROI = [1+(j-1)*stride 1+(i-1)*stride];
                coordsROIstore = cat(3, coordsROIstore, coordsROI);
                sizeCoordsROIstore = size(coordsROIstore, 3);
            end
        end
    end
end

```

```

end

% 1.3.2.2 - Detecção dos positivos na ultima linha e coluna
for m = 1:((coll*ratioWindowStride)-(ratioWindowStride-1))
    ROI = imgOriginal((1+imgHeight-sizeWindowROI):imgHeight, (1+((m-1)*stride)):((m-1)*stride+sizeWindowROI), :);
    classROI = classify(CRS, ROI);

    if classROI == 'Positivo'
        imgDetected((1+imgHeight-sizeWindowROI):imgHeight, (1+((m-1)*stride)):((m-1)*stride+sizeWindowROI), :) = ROI;
        numPosROI = numPosROI + 1;
        ROIstore = cat(3, ROIstore, ROI);
        sizeROIstore = size(ROIstore, 3);

        coordsROI = [1+(m-1)*stride 1+imgHeight-sizeWindowROI];
        coordsROIstore = cat(3, coordsROIstore, coordsROI);
        sizeCoordsROIstore = size(coordsROIstore, 3);
    end
end

for n = 1:(((row-1)*ratioWindowStride)-(ratioWindowStride-1))
    ROI = imgOriginal((1+((n-1)*stride)):((n-1)*stride+sizeWindowROI), (1+imgWidth-sizeWindowROI):imgWidth, :);
    classROI = classify(CRS, ROI);

    if classROI == 'Positivo'
        imgDetected((1+((n-1)*stride)):((n-1)*stride+sizeWindowROI), (1+imgWidth-sizeWindowROI):imgWidth, :) = ROI;
        numPosROI = numPosROI + 1;
        ROIstore = cat(3, ROIstore, ROI);
        sizeROIstore = size(ROIstore, 3);

        coordsROI = [1+imgWidth-sizeWindowROI 1+(n-1)*stride];
        coordsROIstore = cat(3, coordsROIstore, coordsROI);
        sizeCoordsROIstore = size(coordsROIstore, 3);
    end
end

% 1.4 - Mostrar resultados
figure(1);
imshow(imgDetected);
axis on;
[rows, columns, numberOfColorChannels] = size(imgDetected);
hold on;
stepSize = 227; % conforme o tipo de stride.
for row = 1 : stepSize : rows
    line([1, columns], [row, row], 'Color', 'w', 'LineWidth', 0.5);
end
for col = 1 : stepSize : columns
    line([col, col], [1, rows], 'Color', 'w', 'LineWidth', 0.5);
end
imwrite(imgDetected, 'detection.jpg')

```

ANEXO IV – PRÉ-PROCESSAMENTO DE IMAGENS – ABORDAGEM 1

```
image_folder = 'C:\Users\Paulo\Desktop\Matlab CNN\tmv';
filenames = dir(fullfile(image_folder, '*.jpg'));
total_images = numel(filenames);
BaseName='Corrosao_'
for n = 1:total_images
FileName=[BaseName,num2str(n),'.jpg'];
f= fullfile(image_folder, filenames(n).name);
our_images = imread(f);
red = our_images(:,:,1); green = our_images(:,:,2); blue = our_images(:,:,3);
out = red>25 & red<158 & green>11 & green<70 & blue>5 & blue<70; %Define os
limites RGB
Kmedian = medfilt2(out,[15,15]) % elimina pontos dispersos
outo = imoverlay(our_images, Kmedian, 'red');
imwrite(outo,FileName,'jpg');
end
```

ANEXO V – PRÉ-PROCESSAMENTO DE IMAGENS – ABORDAGEM 2

```
image_folder = 'C:\Users\Paulo\Desktop\Matlab CNN\dbprefinal\Positivo';
filenames = dir(fullfile(image_folder, '*.jpg'));
total_images = numel(filenames);
BaseName='Corrosao_'
for n = 1:total_images
FileName=[BaseName,num2str(n),'.jpg'];
f= fullfile(image_folder, filenames(n).name);
our_images = imread(f);
img2 = our_images + 150;
[R,G,B] = imsplit(img2);
img3 = im2double(G);
[Gmag, Gdir] = imgradient(img3,'prewitt');
Limiar = graythresh(img2);
img5 = edge(Gmag, 'canny', Limiar);
SED = strel('square', 8);
img_dilat = imdilate(img5, SED);
img6 = imoverlay(our_images, img_dilat, 'red');
imwrite(img6,FileName,'jpg');
end
```