



UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

ALISSON DE SOUZA DA SILVA

**MÉTODO PARA RECONHECIMENTO AUTOMATIZADO DE FALHAS
CONSTRUTIVAS NA EXECUÇÃO DE FACHADAS COM USO DE
DRONES E APRENDIZADO DE MÁQUINA**

Salvador
2023

ALISSON DE SOUZA DA SILVA

**MÉTODO PARA RECONHECIMENTO AUTOMATIZADO DE FALHAS
CONSTRUTIVAS NA EXECUÇÃO DE FACHADAS COM USO DE DRONES E
APRENDIZADO MÁQUINA**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Civil, Escola Politécnica, Universidade Federal da Bahia, como requisito para obtenção do título de Mestre em Engenharia Civil.

Orientadora: Prof.^a Dr.^aDayana Bastos Costa

Coorientador: Prof. Dr.Reymard Sávio Sampaio de Melo

Agência Financiadora: Fundação de Amparo à Pesquisa do Estado da Bahia-FAPESB

Salvador

2023

Ficha catalográfica elaborada pelo Sistema Universitário de Bibliotecas (SIBI/UFBA),
com os dados fornecidos pelo(a) autor(a).

Silva, Alisson de Souza da
MÉTODO PARA RECONHECIMENTO AUTOMATIZADO DE FALHAS
CONSTRUTIVAS NA EXECUÇÃO DE FACHADAS COM USO DE
DRONES E APRENDIZADO MÁQUINA / Alisson de Souza da
Silva. -- Salvador, 2023.
181 f.

Orientadora: Dayana Bastos Costa.
Coorientador: Reymard Sávio Sampaio de Melo.
Dissertação (Mestrado - Programa de Pós Graduação em
Engenharia Civil) -- Universidade Federal da Bahia,
Escola Politécnica, 2023.

1. Inspeções automatizadas de fachadas. 2. Fachadas
de paredes de concreto moldadas in loco. 3. Uso de
drones e aprendizado de máquina. 4. Suporte para o
sistema de gestão da qualidade durante a execução . 5.
Construção Civil. I. Costa, Dayana Bastos. II. Melo,
Reymard Sávio Sampaio de . III. Título.

MEMBROS DA BANCA EXAMINADORA DA DISSERTAÇÃO DE MESTRADO

Alisson de Souza da Silva

APRESENTADA AO MESTRADO EM ENGENHARIA CIVIL, DA UNIVERSIDADE FEDERAL DA BAHIA, EM 22 DE MARÇO DE 2023.

BANCA EXAMINADORA

Documento assinado digitalmente
gov.br DAYANA BASTOS COSTA
Data: 23/03/2023 06:58:09-0300
Verifique em <https://validar.itl.gov.br>

Prof.(a) Dr.(a) **Dayana Bastos Costa**

Orientadora

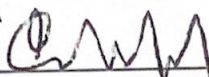
PPEC-UFBA

Documento assinado digitalmente
gov.br REYMARD SAVIO SAMPAIO DE MELO
Data: 23/03/2023 11:19:07-0300
Verifique em <https://validar.itl.gov.br>

Prof.(a) Dr.(a) **Reymard Sávio Sampaio de Melo**

Coorientador

PPEC- UFBA



Prof.(a) Dr.(a) **Francisco Gabriel da Silva**

PPEC-UFBA



Prof.(a) Dr.(a) **Fabiano Rogerio Correa**

PPG- PCC- USP

Documento assinado digitalmente
gov.br ROSENEIA RODRIGUES SANTOS DE MELO
Data: 23/03/2023 10:47:45-0300
Verifique em <https://validar.itl.gov.br>

Prof.(a) Dr.(a) **Roseneia Rodrigues Santos de Melo**

PPEC-UFBA

Dedico este trabalho à minha família, em especial a minha mãe Marleti e meu irmão Vitor, pelo apoio e amor incondicional durante toda minha vida, e ao meu amor Ismael, pela cumplicidade e paciência durante esta jornada.

AGRADECIMENTOS

Primeiramente a Deus, o Todo-Poderoso, quem, por seu amor, misericórdia e fidelidade, tornou possível essa conquista em minha vida.

À professora Dayana Bastos Costa, pela excelente orientação para conclusão desta dissertação, por me proporcionar grande crescimento profissional e pessoal e além disso, por ter aberto as portas para mim e acreditado no meu trabalho.

À FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) pelo auxílio financeiro concedido ao longo desta pesquisa.

À empresa participante do projeto e aos profissionais dessa empresa, pela atenção, interesse e colaboração, o que fizeram possível a execução deste projeto.

À Pós Doc. Roseneia Melo, pela excelente supervisão, apoio, dedicação e paciência ao longo dessa jornada. Apoio esse fundamental para a conclusão deste trabalho.

Ao professor Reymard Sávio, pela coorientação deste trabalho e por suas contribuições.

Aos alunos de Iniciação Científica, Leonardo Gonçalves, Luciano Staffa e João Nogueira pelo apoio durante todo o mestrado.

Aos colegas do GETEC, em especial à Caroline Araújo, Hugo Peinado, Luara Fernandes, Mahara Lima, Rafaela Rey e Vanessa Pacheco por todo apoio e conselhos prestado. E aos demais membros do GETEC pela honra de fazer parte deste grupo tão especial.

Aos colegas do PPEC (Programa de Pós Graduação em Engenharia Civil da UFBA), em especial à Gilberto Neto, Ingrid Santana, Henrique Almeida e Daniela Mota por todo carinho ao longo desta jornada.

À querida Erica Mitie Umakoshi Kuniochi, por sua amizade e apoio prestado desde a graduação, além de ser uma inspiração pessoal e profissional para mim.

Aos meus familiares, em especial ao meu pai Miguel, meu irmão Everson, meus sobrinhos Gustavo, Otávio e Enzo, meu padrasto Leandro e aos meus tios José, Luciano, Cida, Toninha, Bel e Fabiana, por todo apoio e amor incondicional.

Aos meus primos, em especial à Alam, Fabiane, Franciele, Fausto, Eduardo, Lais, Carielen e Ckatullyn, por todo amor e pela torcida durante toda minha vida.

Às minhas melhores amigas de Mato Grosso, Alice Costa, Bruna Ferreira, Bruna Pompilho, Caroline Ramalho, Carla Alessandra e Vanessa Bezerra, que sempre me deram apoio e cultivaram a nossa amizade, mesmo à distância.

À querida sogra D. Deijanira e seus familiares por terem me acolhido tão bem.

“Every great dream begins with a dreamer. Always remember, you have within you the strength, the patience, and the passion to reach for the stars to change the world.”

Harriet Tubman.

RESUMO

A fachada é um dos principais subsistemas de uma edificação e o surgimento de manifestações patológicas pode comprometer seu desempenho. Portanto, atividades de inspeções e manutenções periódicas são necessárias, principalmente durante a execução, onde surgem diversas anomalias. No entanto, muitas vezes, as inspeções manuais e visuais apresentam algumas limitações, sendo consideradas demoradas, caras e inseguras. Diante disso, o uso de tecnologias digitais pode minimizar tais limitações. Neste contexto, o objetivo principal deste trabalho é propor um método de reconhecimento automatizado para identificar manifestações patológicas em fachadas de parede de concreto durante a execução, com uso de drones e algoritmos de Aprendizado de Máquina (AM), visando a melhoria na qualidade da obra. Para tanto, foi adotado a estratégia de pesquisa da Design Science Research (DSR), envolvendo três estudos de caso ao longo das seguintes etapas: a) Conscientização através da investigação do problema teórico por meio de uma Revisão Sistemática da Literatura-RSL, identificando as lacunas de pesquisa e através da investigação do problema prático em campo; b) Sugestão do artefato através da realização de um estudo de caso exploratório, no qual foi utilizando drones para aquisição de imagens e algoritmos de AM para processamento digital de imagens; c) Desenvolvimento do artefato com a realização de dois estudos de caso implementando o método de reconhecimento automatizado de manifestações patológicas através de protocolos de aquisição e processamento de imagens, além da incorporação das informações oriundas dessas atividades no sistema de gestão da qualidade da obra; d) Avaliação do método proposto através dos constructos Transparência, Eficiência e Utilidade, por meio de variáveis e fontes de evidências; e por fim, e) Conclusão com a formalização do método proposto e considerações finais sobre o estudo. Foram propostos dois protocolos que permitiram maior celeridade e precisão nas etapas de aquisição e processamento de imagens. Nos estudos foram levantadas onze manifestações patológicas, das quais quatro foram visualizadas com drone e analisada por algoritmos de aprendizado de máquina. Dos nove modelos criados no software de AM chamado Custom Vision, o que apresentou melhor desempenho atingiu 58,99% de F1 Score e 65% de mAP. Além disso, durante os testes, algumas falhas construtivas foram reconhecidas corretamente com até 97,4% de probabilidade. Do ponto de vista gerencial, as informações adquiridas por meio das inspeções foram incorporadas no processo de execução da obra através de relatórios, imagens coletadas com drone e planos de ação baseados no ciclo PDCA. Após a avaliação do método, evidenciou que as informações através do método proposto deram suporte aos gestores na tomada de decisão em relação ao controle da qualidade durante o processo construtivo de fachadas de paredes de concreto moldadas in loco.

Palavras-chave: Inspeção automatizada. Fachada de parede de concreto. Drone. Inteligência Artificial. Controle da qualidade.

ABSTRACT

The facade is one of the central systems of a building, and the appearance of pathologies in this system can compromise its performance. Therefore, periodic inspections and maintenance activities are necessary, especially during execution, when several anomalies arise. However, manual and visual inspections often have some isolated ones, being considered time-consuming, expensive, and unsafe. Therefore, the use of digital technologies can minimize such limitations. In this context, the main objective of this work is to propose a controlled recognition method to identify pathological manifestations in concrete wall facades during execution, using drones and Machine Learning (ML) algorithms, aiming to improve the quality of the work. To this end, the research strategy of Design Science Research (DSR) was adopted, involving three case studies along the following steps: a) Awareness through the investigation of the theoretical problem through a Systematic Literature Review-RSL, identifying the research gaps and through investigation of the practical problem in the field; b) Suggestion of the process by carrying out an exploratory case study, in which drones were used for image acquisition and AM algorithms for digital image processing; c) Development of the experiment with the realization of two case studies implementing the method of recognition of pathological manifestations through image acquisition and processing protocols, in addition to the incorporation of information arising from these activities in the quality management system of the work; d) Evaluation of the proposed method through the constructs Transparency, Efficiency and Usefulness, through measurement and sources of evidence; and finally, e) Conclusion with the formalization of the proposed method and final considerations about the study. Two standardized protocols allowed incredible speed and precision in image acquisition and processing stages. In the studies, eleven pathological manifestations were raised, of which four were visualized with a drone and followed by machine learning algorithms of the new models created in the AM software called Custom Vision, the one that presented the best food performance at 58.99% of F1 Score and 65% of mAP. Furthermore, some constructive faults were recognized correctly, with up to 97.4% probability during testing. From a managerial point of view, the information acquired through the inspections was incorporated into the work execution process through a report, images collected with a drone, and action plans based on the PDCA cycle. After evaluating the method, it was found that the information through the standard method supported managers in decision-making about quality control during the construction process of cast-in-place concrete wall facades.

Keywords: Automated inspection. Concrete wall façade. Drone. Artificial intelligence. Quality control.

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplo de Ficha de Verificação de Serviços (FVS).....	16
Figura 2 - Ciclo PDCA.....	16
Figura 3 - Acessórios de forma metálica com detalhamento.....	18
Figura 4 - Tratamento de Fachada.....	20
Figura 5 - Faquetas de travamento.....	23
Figura 6 - Fissuras em fachadas de concreto.....	24
Figura 7 - Ninhos de concretagem em paredes de concreto.....	25
Figura 8 - Armadura exposta em paredes de concreto.....	25
Figura 9 - Processamento de imagem.....	31
Figura 10 - Processamento de imagem.....	31
Figura 11 - Detecção de elementos.....	31
Figura 12 - Reconhecimento de padrões.....	32
Figura 13 - Inteligência Artificial e seus subconjuntos.....	33
Figura 14 - Categorização do Aprendizado de Máquina.....	34
Figura 15 - Matriz de Confusão.....	36
Figura 16 - Fórmula da intersecção sobre a união.....	38
Figura 17 - Exemplo de uma Rede Neural Convolutiva e suas camadas.....	40
Figura 18 - Exemplo do processo de convolução.....	41
Figura 19 - Publicações: (a) por periódicos; e (b) por ano e tipo de construção.....	42
Figura 20 - Exemplos dos drones utilizados.....	44
Figura 21 - Delineamento geral da pesquisa.....	52
Figura 22 - Ilustração do empreendimento da Obra A.....	54
Figura 23 - Ilustração do empreendimento da Obra B.....	54
Figura 24 - Ilustração do empreendimento da Obra C.....	55
Figura 25 - Fluxograma do Custom Vision.....	56
Figura 26 - Delineamento da RSL.....	60
Figura 27 - Manifestações patológicas identificadas com drone.....	63
Figura 28 - Etapas de utilização do Custom Vision.....	64
Figura 29 - Exemplo de imagens com manifestações patológicas compartilhadas.....	65
Figura 30 - Exemplo de variações de imagens utilizando o <i>Data Augmentation</i>	68
Figura 31 - Esquema do 1º Ciclo de Implementação.....	70
Figura 32 - Esquema do 2º ciclo de Implementação.....	70

Figura 33 - a) Cobertura do voo; b) Foto tirada de outro ângulo	72
Figura 34 - Mosaico das imagens coletadas	72
Figura 35 - Esquema de implementação das informações	75
Figura 36 - Estrutura analítica simplificada da pesquisa	76
Figura 37 - Resultado o levantamento	82
Figura 38- Imagens de alguns problemas recebidas no levantamento	82
Figura 39 - Marcação das linhas auxiliares para montagem das formas de paredes	83
Figura 40 - Armação entre paredes e lajes	84
Figura 41 - Montagem das Formas	84
Figura 42 - Concretagem das paredes.....	86
Figura 43 - Desforma após a concretagem	86
Figura 44 - Tratamento de fachada	87
Figura 45 - FVS utilizada na Empresa X	88
Figura 46 - Desempenho geral dos Modelos 1 e 2 criados no Custom Vision	91
Figura 47 - Protocolo de aquisição de imagens com drone	92
Figura 48 - Posição dos operadores de drone durante o voo.....	93
Figura 49 - Trajetória de voo nas fachadas	94
Figura 50 - Protocolo de Processamento de imagens.....	94
Figura 51 - Desempenho geral do M3 a) Precisão e Recall; b) F1 Score e mAP....	100
Figura 52 - Ciclo PDCA utilizado nos estudos de caso	101
Figura 53 - Fachada Posterior com as manifestações patológicas identificadas	102
Figura 54 - Plano de ação enviado.....	102
Figura 55 - Posição das fachadas	103
Figura 56 - Manifestações patológicas identificadas nas fachadas da Obra B	104
Figura 57 - Desempenho geral dos modelos criados no Estudo de Caso C	107
Figura 58 - Valores dos indicadores F1 Score e mAP.....	108
Figura 59 - Acompanhamento da execução da fachada da torre 1	112
Figura 60 - Estrutura do relatório entregue a Empresa X.....	113
Figura 61 - Plano de ação preenchido por colaboradores da Empresa X	114
Figura 62 - Manifestações patológicas identificadas nas fachadas da Obra C	114
Figura 64 - Avaliação dos indicadores de desempenho do Custom Vision	119
Figura 65 - Workshop realizado no Estudo de Caso C	123
Figura 66 - Estrutura Final do Método Proposto.....	124

LISTA DE QUADROS

Quadro 1 - Tecnologias utilizadas para aquisição de dados	42
Quadro 2 - Aplicação de visão computacional e subconjuntos de IA	45
Quadro 3 - Drones utilizados no estudo	55
Quadro 4 - Perfil dos entrevistados	60
Quadro 5 - Visitas à obra	61
Quadro 6 - Características de voos da Obra A.....	63
Quadro 7 - Treinamento no Custom Vision	65
Quadro 8 - Visitas à obra B	66
Quadro 9 - Características de voos da Obra B.....	67
Quadro 10 - Treinamento no Custom Vision	69
Quadro 11 - Visitas à obra C.....	71
Quadro 12 - Características de voos da Obra C	73
Quadro 13 - Treinamento no Custom Vision	74
Quadro 14 - Constructos, variáveis e fontes de evidência para avaliação	78
Quadro 15 - Entrevistas.	79
Quadro 16 - Caracterização dos participantes do workshop.....	79
Quadro 17 - Desempenho do Modelo 1 gerado no Custom Vision	90
Quadro 18 - Desempenho do Modelo 2 gerado no Custom Vision	90
Quadro 19 - Manifestações patológicas levantadas no Estudo de Caso B	97
Quadro 20 - Algoritmo da técnica <i>Data Augmentation</i>	97
Quadro 21 - Terceiro modelo criado no Custom Vision.....	99
Quadro 22 - Manifestações patológicas levantadas no Estudo de Caso C.....	104
Quadro 23 - Relação dos modelos criados de acordo com as obras estudadas ...	105
Quadro 24 - Modelo 4 criado no Custom Vision.....	106
Quadro 25 - Modelo 5 e submodelos criados no Custom Vision.....	106
Quadro 26 - Modelo 6 criado no Custom Vision.....	107
Quadro 27 - Resumo de todos os modelos	110
Quadro 28 - Avaliação dos entrevistados - Constructo Transparência	115
Quadro 29 - Desempenho médio da aquisição de imagens com drone	117
Quadro 30 - Tempo para inspeção de fachada e fornecimento das informações ...	118
Quadro 31 - Avaliação dos entrevistados - Constructo Utilidade	120

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ANAC	Agência Nacional de Aviação Civil
AEC	Auxiliar de Engenharia Civil
AECO	Arquitetura, Engenharia, Construção e Operações
CNN	<i>Convolutional Neural Network</i>
CV	<i>Computer Vision</i>
DL	<i>Deep Learning</i>
DSR	<i>Design Science Research</i>
ECA	Engenheiro Civil Analista
EEC	Estagiário de Engenharia Civil
ECP	Engenheiro Civil de Produção
EST	Engenheiro de Segurança do Trabalho
FVS	Ficha de Verificação de Serviço
GD	Gêmeo Digital
GP	Gestor de Produção
GETEC	Grupo de Pesquisa e Extensão em Gestão e Tecnologia das construções
IA	Inteligência Artificial
IoT	Internet das Coisas
ISO	<i>International Standards Organization</i>
LED	<i>Light Emitting Diode</i>
ML	<i>Machine Learning</i>
M1	Modelo 1
M2	Modelo 2
M3	Modelo 3

M4	Modelo 4
M5	Modelo 5
M6	Modelo 6
NBR	Norma Brasileira Regulamentadora
PES	Procedimento de Execução de Serviço
RA	Realidade Aumentada
RV	Realidade Virtual
RM	Realidade Mista
RPA	<i>Remotely-Piloted Aircraft</i>
RPAS	<i>Remotely-Piloted Aircraft Station</i>
TST	Técnico em Segurança do Trabalho
UFBA	Universidade Federal da Bahia
USP	Universidade de São Paulo

SUMÁRIO

1. INTRODUÇÃO	1
1.1 PROBLEMA DE PESQUISA.....	3
1.2 QUESTÕES DE PESQUISA.....	7
1.2.1 Questão Principal	7
1.2.2 Questões Secundárias.....	7
1.3 OBJETIVOS DA PESQUISA	8
1.3.1 Objetivo Principal.....	8
1.3.2 Objetivos Secundários.....	8
1.4 DELIMITAÇÃO DA PESQUISA	8
1.5 ESTRUTURA DO TRABALHO	9
2. CONTROLE DA QUALIDADE NA EXECUÇÃO DE FACHADAS DE PAREDE DE CONCRETO MOLDADAS <i>IN LOCO</i>	10
2.1 CONCEITOS DE QUALIDADE	10
2.2 CONCEITOS DE QUALIDADE NA CONSTRUÇÃO CIVIL.....	12
2.3 GESTÃO E CONTROLE DA QUALIDADE	13
2.3.1 Procedimento de Execução e Ficha de Verificação de Serviços.....	15
2.3.2 Ciclo PDCA	16
2.4 CONTROLE DA QUALIDADE NA EXECUÇÃO DE PAREDES DE CONCRETO MOLDADAS <i>IN LOCO</i>	17
2.4.1 Execução.....	18
2.4.2 Tratamento pós execução	20
2.5 MANIFESTAÇÕES PATOLÓGICAS EM FACHADAS DE CONCRETO MOLDADAS <i>IN LOCO</i>	21
2.5.1 Fissuras.....	22
2.5.2 Ninhos ou vazios de concretagem	24
2.5.3 Armadura exposta	25
2.6 CONSIDERAÇÕES ACERCA DO CAPÍTULO 2	26
3. TECNOLOGIAS DIGITAIS UTILIZADAS PARA IDENTIFICAÇÃO AUTOMATIZADA DE MANIFESTAÇÕES PATOLÓGICAS NA CONSTRUÇÃO ...	28
3.1 DRONES PARA AQUISIÇÃO DE DADOS	28
3.2 VISÃO COMPUTACIONAL.....	30
3.3 INTELIGÊNCIA ARTIFICIAL E SUBCONJUNTOS.....	32

3.3.1	Aprendizado de Máquina.....	33
3.3.2	Aprendizado Profundo.....	38
3.3.3	Redes Neurais Convolucionais e demais subconjuntos.....	39
3.4.1	Tecnologias digitais utilizadas para aquisição de dados	42
3.4.2	Tecnologias digitais usadas para processamento de dados	44
3.4.2.1	Técnicas de Classificação	45
3.4.2.2	Técnicas de Detecção	46
3.4.2.3	Técnicas de Segmentação	48
3.5	CONSIDERAÇÕES ACERCA DO CAPÍTULO 3	48
4.	MÉTODO DE PESQUISA.....	50
4.1	ESTRATÉGIA DE PESQUISA.....	50
4.2	DELINEAMENTO DA PESQUISA	51
4.2.1	Caracterização geral da Empresa participante.....	53
4.2.2	Caracterização das Obras estudadas	53
4.2.3	Caracterização das tecnologias digitais utilizadas para aquisição de dados..	55
4.2.4	Caracterização da tecnologia utilizada para processamento de dados.....	56
4.3	ETAPA DE CONSCIENTIZAÇÃO.....	58
4.3.1	Revisão da literatura	58
4.3.2	Revisão Sistemática da Literatura (RSL).....	58
4.3.3	Investigação do Problema Prático.....	60
4.4	ETAPA DE SUGESTÃO	61
4.1	Mapeamento do sistema construtivo de parede de concreto, com foco na fachada e em seu controle de qualidade	62
4.2	Aquisição de imagens com drone	62
4.3	Testes utilizando as imagens coletadas para treinamento do algoritmo	64
4.5	ETAPA DE DESENVOLVIMENTO DO ARTEFATO.....	66
4.5.1	Estudo de Caso B	66
4.5.2	Estudo de Caso C	71
4.6	ETAPA DE AVALIAÇÃO DO ARTEFATO	75
4.7	ETAPA DE CONCLUSÃO DO ARTEFATO.....	80
5.	APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS	81
5.1	RESULTADOS DAS FASES DE CONSCIENTIZAÇÃO E SUGESTÃO	81
5.1.1	Levantamento inicial de dados realizado com membros da Empresa X.....	81

5.1.2	Mapeamento do sistema construtivo de Paredes de Concreto moldadas in loco, com foco na fachada e no controle da qualidade	83
5.1.3	Estudo de Caso na Obra A	89
5.2	RESULTADOS DA ETAPA DE DESENVOLVIMENTO	96
5.2.1	Estudo de Caso B	96
5.2.2	Estudo de Caso C	104
5.3	AVALIAÇÃO DAS IMPLEMENTAÇÕES DO MÉTODO PROPOSTO COM BASE NOS CONSTRUCTOS DE PESQUISA	114
5.3.1	Transparência	115
5.3.2	Eficiência	117
5.3.3	Utilidade	120
5.4	ESTRUTURA FINAL DO MÉTODO	123
5.4.1	Apresentação da Estrutura Final do Método Proposto	123
5.5	DISCUSSÃO DOS RESULTADOS	127
6.	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	131
6.1	CONCLUSÕES DO TRABALHO	131
6.2	SUGESTÕES PARA TRABALHOS FUTUROS	134
	REFERÊNCIAS	135
	APÊNDICE A - LISTA DE ARTIGOS DA RSL	154
	APÊNDICE B - LEVANTAMENTO DE DADOS (GOOGLE FORMS)	155
	APÊNDICE C - CHECKLIST PARA MISSÃO DE VOO COM DRONE	161
	APÊNDICE D – PROTOCOLO DE ENTREVISTA 1	162
	APÊNDICE E – PROTOCOLO DE ENTREVISTA 2	164

1. INTRODUÇÃO

Na construção civil, a durabilidade das edificações pode ser comprometida pelo aumento da degradação de seus componentes. Isso ocorre devido ao processo natural de envelhecimento dos materiais de sua composição, dos agentes externos os quais essas edificações estão localizadas, além do tempo e uso ocasionando a redução de seu desempenho (SILVA; BRITO; GASPAR, 2016; LIU; YEOH; CHUA, 2020). Devido a esse processo de degradação, os sistemas e elementos das edificações tornam-se obsoletos e incapazes de atender às demandas de desempenho estabelecidas durante a concepção do projeto (CHAI et al., 2013; POSSAN; ALBERTO DEMOLINER, 2013).

Entre os subsistemas de um edifício, a fachada é considerada a “pele” da edificação, atuando como uma camada protetora contra os agentes de degradação ambiental (SILVA; BRITO; GASPAR, 2016). A fachada é considerada o sistema mais exposto às condições ambientais externas devido sua inércia desfavorável, sua espessura fina e por ser constituída de várias camadas de acabamento. Além disso, a fachada recebe todo o ciclo higrotérmico diretamente, ou seja, sofre o impacto da chuva, dos ventos e ruídos, causando sua deterioração e levando desde o deslocamento de seus elementos até o comprometimento da vida útil do edifício (SOUZA et al., 2020; LIU; YEOH; CHUA, 2020; BAUER et al., 2020).

Devido à importância da fachada para a edificação, a inspeção periódica e a manutenção preventiva desse sistema são atividades essenciais para garantir a integridade física do edifício (MEDEIROS JUNIOR; LIMA; BALESTRA, 2013). A manutenção preventiva evita que manifestações patológicas, como fissuras, em estágio inicial se expandam, ocasionando defeitos na estrutura da edificação. As fissuras presentes na superfície da fachada são indicadores de potenciais danos às instalações externas anexadas ao edifício, sendo assim, a detecção imediata destas pode evitar o possível colapso das fachadas, que afetará diretamente a estrutura e o interior do edifício (LIU; YEOH; CHUA, 2020).

Segundo Souza e Ripper (2009), as manifestações patológicas surgem durante a etapa de execução e são causadas, principalmente, devido à falta de controle da qualidade. Além disso, de acordo com Helene (1992) e Mészárosóvá et al. (2015), as manifestações patológicas estão relacionadas a falhas ou falta de interpretação de projeto, ocasionando erros durante a execução das atividades. Diante disso, as

inspeções e o acompanhamento dessas atividades podem ser promovidos por meio de um controle de qualidade ativo e eficiente.

No entanto, as inspeções, principalmente as manuais e visuais, apresentam alguns desafios para sua realização. Tais desafios estão relacionados à extensão da fachada, altura dos edifícios e condições de segurança suficientes para que o profissional responsável pela coleta de dados seja capaz de identificar os danos existentes (JUCÁ; OLIVEIRA; ZANONI, 2022). Alguns pesquisadores apontam que esse tipo de inspeção é considerado uma atividade lenta, trabalhosa e cara, quando contabilizado as horas-homem necessárias para coletar as informações em campo e o seu processamento (HOANG, 2018; DAIS et al., 2021; GUO; WANG; LI, 2021), além de limitações no contexto de objetividade e confiabilidade (ORING, 2022).

Para superar essas limitações, Kumarapu, Shashi, Keesara (2021) apontam que o uso de tecnologias avançadas como drones e visão computacional podem auxiliar os profissionais na tomada de decisão, automatizando essa atividade, tornando-a ágil, segura, confiável e eficaz. Além disso, as imagens digitais associadas às técnicas de processamento de dados têm melhorado as estratégias de inspeção, fornecendo avaliações automatizadas das condições dos elementos construtivos (STOCHINO et al., 2018).

Nesse contexto, os drones têm se tornado ferramentas populares, cada vez mais implementados em diversos fins, como monitoramento do progresso de obras (ÁLVARES; COSTA, 2019; PURI; TURKAN, 2020; ZHANG; ARDITI 2020), inspeção da integridade de estradas e pavimentos (SOILÁN et al., 2019; ATENCIO et al., 2020; HAN et al., 2021), inspeção de pontes (LIU et al., 2020; JALINOOS et al., 2020; HUBBARD; HUBBARD, 2020), inspeções de monumentos históricos (YUSOF; AHMAD; ABDULLAH, 2020), inspeções de telhados (BOWN; MILLER, 2018; GAJJAR; BURGETT, 2020; SILVEIRA et al., 2021), inspeção de fachadas (LIU; YEOH; CHUA, 2020; RUIZ et al., 2021; CHEN et al., 2021) e inspeção de segurança (MELO et al., 2017; MARTINEZ et al., 2020, REY et al., 2021).

Além dos drones, os subconjuntos de Inteligência Artificial-IA como os algoritmos de Aprendizado de Máquina (*Machine Learning*-ML) e Aprendizado Profundo (*Deep Learning*-DL) vêm sendo utilizados para resolver problemas durante o gerenciamento de construções (RAFIEI et al., 2017; RAFIEI; ADELI, 2018a), e monitoramento da saúde estrutural (RAFIEI; ADELI, 2018b). Alguns exemplos de aplicações de ML para avaliação de danos incluem a detecção de rachaduras em estradas (ZHANG et al.,

2017; ZHANG; CHENG; ZHANG, 2018), identificação do nível de ferrugem em estruturas de aço (XU; GUI; HAN, 2020) e inspeção de ponte de concreto armado (LIANG, 2019).

Diante disso, a integração dessas tecnologias permite o aprimoramento no processo de avaliação e manutenção periódica, automatizando as atividades de coleta e processamento de dados. A utilização dessa integração durante a fase de uso e ocupação já é uma realidade. No entanto, sua aplicação em obras durante a execução pode auxiliar os gestores no controle da qualidade, gerando informações em tempo hábil, dando suporte para a tomada de decisão.

1.1 PROBLEMA DE PESQUISA

As paredes de concreto moldadas in loco fazem parte de um sistema construtivo utilizado principalmente em obras de edificações em que a produção é realizada em larga escala e alta repetitividade (DALDAT, 2020; SILVA; JUNIOR; FLORIAN, 2022). Empreendimentos com essa característica adaptam-se muito bem a este sistema, que busca padronização e agilidade na execução, bem como um retorno significativo na velocidade de entrega das unidades habitacionais (MESOMO, 2018). Esse método construtivo envolve várias etapas e a execução incorreta de alguma delas pode prejudicar o desempenho desse subsistema. Dessa forma, para execução desse elemento, devem-se seguir os requisitos das Normas NBR 15575¹ (ABNT 2021) e NBR 16055² (ABNT 2022), evitando a propagação de manifestações patológicas.

As manifestações patológicas em fachadas de concreto originam-se nas paredes ou estruturas desse sistema e são causadas por diversos fatores que, de acordo com Silva (2018), estão relacionadas a falhas dos profissionais envolvidos durante as etapas de construção. Falhas que vão desde a troca das especificações de materiais utilizados durante o período de execução, como falhas na concretagem, até erros de cálculo e dimensionamento (GALLETTO; ANDRELLO, 2013; BRITO, 2017). Tais fatores podem causar manifestações patológicas como fissuras (SILVA, 2011; OLIVEIRA, 2012), desagregação (SOUZA; RIPPER, 1998) e segregação do concreto (ANDRADE; SILVA, 2005), corrosão das armaduras (LOTTERMANN, 2013) e junta fria (MEDEIROS, 2010).

¹ **NBR 15575** - Edificações habitacionais — Desempenho - Parte 1: Requisitos gerais.

² **NBR 16055** - Parede de concreto moldada no local para a construção de edificações - Requisitos e procedimentos.

Segundo Montoya (2017), boa parte dessas manifestações patológicas surgem durante a fase de execução e podem ser evitadas através de um controle de qualidade mais eficiente. Diante disso, a localização dessas anomalias através de inspeções visuais para mapeamento e avaliação do nível de gravidade dessas manifestações patológicas, para então, priorizar os processos de qualidade e manutenção, são de grande importância para conter sua propagação (LIN et al., 2021).

A inspeção visual busca avaliar a condição do limite vertical e seus diversos componentes, fornecendo diretrizes para uma manutenção eficiente e econômica. Em relação às fachadas, essa atividade garante o bom funcionamento desse subsistema, permitindo que ela cumpra as funções para as quais foi construída e tenha sua vida útil prolongada (RUIZ et al., 2021). No entanto, as inspeções visuais, baseadas em métodos tradicionais, requerem muito trabalho quando referente à digitalização dos documentos, caracterizando essa atividade em uma tarefa tediosa e sujeita a erros, o que pode interferir na análise de seus resultados (DING; ZHOU, 2013; LIN et al., 2014; ZHANG et al., 2016).

Para automatizar esse processo de inspeção é recomendado o uso de tecnologias avançadas como drones, subconjuntos de inteligência artificial e visão computacional (KUMARAPU, SHASHI, KEESARA, 2021). Para agilizar a aquisição de imagens, o uso de drones tem apresentado diversas vantagens, devido à capacidade de coletar grande número de imagens, com alta resolução em curto tempo, permitindo o aumento da periodicidade de inspeções de fachadas (EMELIANOV; BULGAKOW; SAYFEDDINE, 2014; JORDAN et al., 2015; DAIS et al., 2021). Nesse sentido, diversos estudos vêm sendo desenvolvidos nessa área buscando aprimorar cada vez mais a automatização dessa atividade.

Silva e Lucena (2018) buscaram aumentar o nível de automação na inspeção de infraestrutura de concreto utilizando drones e redes de *Deep Learning* (DL). Os autores desenvolveram um modelo de detecção de fissuras baseado em algoritmos de classificação de imagens da *Convolutional Neural Network* (CNN). Para este trabalho, foi utilizado um conjunto de dados com 3500 imagens de superfícies de concreto, divididas em dados de treinamento e teste em uma proporção de 80/20. O melhor modelo desse experimento atingiu 92,27% de precisão. Entretanto, esse projeto tratou apenas da classificação de imagens, informando se existia ou não fissuras em estruturas de concreto. Além disso, não deixa claro onde está localizada a fissura, o que é essencial para uma inspeção automatizada.

Kim e Cho (2018) criaram um método automático de detecção de fissuras usando redes AlexNet da CNN. Utilizando aproximadamente 42.000 imagens da literatura, foi desenvolvido um modelo para classificação de fissuras e outros objetos como superfícies intactas sem fissuras, toda a superfície, plantas, linhas únicas e juntas e bordas de várias linhas. O modelo foi treinado para classificar imagens de forma binária, indicando se existe fissura ou não. O método proposto obteve 92,35% de precisão média e 89,28% de *recall*.³ No entanto, por mais que as fissuras sejam prejudiciais a estrutura das construções, existem outras manifestações patológicas em estruturas de concreto que possuem o mesmo potencial prejudicial e também requerem a identificação através de inspeções.

No estudo de Staffa et al. (2020) foi criado um modelo para identificação automática de não conformidades em telhados inclinados com telhas de fibrocimento com o objetivo de avaliar a potencialidade das técnicas de processamento de imagem. Para isso, foram inspecionados 61 telhados, utilizando drones, coletando 1661 imagens. A base de dados coletada foi analisada manualmente e identificadas 525 imagens com não conformidades. A partir dessa seleção, criaram um modelo de aprendizado de máquina utilizando 473 imagens para treinamento e 52 para testes. O modelo avaliou dez classes de problemas em telhados e, desse total, os que apresentaram melhor desempenho em relação a precisão e recall, respectivamente, foram “Alçapão aberto ou fechado” (100% e 57,10%), “Presença de resíduos no telhado” (82,10% e 51,10%) e “Integridade da calha” (77,80% e 43,80%). Os autores consideraram os resultados deste estudo satisfatório, no entanto, observando a base de dados utilizada, considera-se relativamente baixa em relação a outros estudos como o de Cha, Choi e Büyüköztürk (2017) e Kim e Cho (2018). Além disso, observa-se a oportunidade de utilizar esse método para identificação de defeitos em fachadas.

Bouzan et al. (2021) propuseram um sistema de baixo custo para identificação e classificação de manifestações patológicas de fachadas a partir de imagens de alta resolução coletadas por drone. As manifestações patológicas ou anomalias utilizadas nesse modelo foram: fissuras profundas, eflorescência, armadura exposta e mancha de ferrugem. Foi realizado uma análise comparativa da eficácia nos algoritmos baseados em *Decision Trees* (DT), *Random Forests* (RF) e CNN na classificação dessas anomalias. Em relação à precisão do modelo treinado, os algoritmos de CNN

³ Recall é um indicador de desempenho dos modelos que utilizam inteligência artificial indicando a frequência em que o classificador encontra os exemplos de uma classe em uma imagem.

apresentaram o melhor desempenho, com valores variando entre 65 e 90% para cada anomalia. O algoritmo RF apresentou valores variando entre 50 e 80% para cada manifestação patológica e, em seguida, o modelo DT com uma variação entre 50 e 70% para cada anomalia. O modelo de identificação e classificação foi avaliado como satisfatório, no entanto, o método utilizado nesse trabalho contempla apenas a fase de uso e ocupação, não explorando fachadas de edifícios durante a execução. Diante disso, tendo em vista que grande parte dessas anomalias surge durante essa etapa construtiva, destaca-se a importância de utilizar as informações dessas inspeções para apoiar os gestores na tomada de decisão em relação ao processo de controle da qualidade.

Ali et al. (2022) apresentaram uma extensa revisão da literatura sobre o potencial uso de redes de DL e CNN em aplicações de detecção de fissuras. Foi apresentado vários estudos sobre identificação automatizada de fissuras em diversas estruturas civis, como túneis (PANELLA et al., 2018; PROTOPAPADAKIS et al., 2019; REN et al., 2020), estradas (OLIVEIRA; CORREIA, 2012; CUBERO-FERNANDEZ, 2017; MANDAL; MUSHROOM; ADU-GYAMFI, 2018), pontes (XU et al., 2019; LI et al., 2020; JANG et al., 2020), estruturas de concreto (DUNG; ANH, 2019; LIU et al., 2019) e estruturas metálicas (CHEN; JAHANSHAH, 2018). No entanto, não houve nenhum estudo aplicando métodos de DL para identificação de fissuras em fachadas, nem mesmo trabalhos que contemplem outra fase do ciclo de vida, além de uso e ocupação.

Foram identificados na presente pesquisa trabalhos sobre inspeções automatizadas de fachada, utilizando tecnologias digitais como drones e redes de aprendizado de máquina para inspeções em fachadas de vidro (BOWMAN et al., 2021), fachadas de revestimentos cerâmicos (SILVESTRE; BRITO, 2010; EDIS; FLORES-COLEN; DE BRITO, 2014; BAUER et al., 2016), revestimento com pedras naturais (NETO; BRITO, 2011) e inspeção de deslocamento de objetos das fachadas (CHEW, 2021). No entanto, em nenhum dos trabalhos encontrados na literatura apresentou uma investigação de manifestações patológicas em paredes de concreto, tendo em vista a crescente utilização desse sistema construtivo em Habitações de Interesse Social (HIS) no Brasil.

Além disso, no estudo exploratório realizado nesta pesquisa, com foco no controle da qualidade na execução de fachadas de concreto, observou-se que essa atividade recebia maior atenção na parte interna dos edifícios. Os profissionais

utilizam as Fichas de Verificação de Serviço-FVS e sistemas internos da empresa para mapear as manifestações patológicas dentro da edificação. No entanto, é necessário que essa atividade seja realizada na parte externa da edificação. Diante disso, observou-se a oportunidade da utilização de tecnologias digitais para realização deste tipo de inspeção dando suporte na tomada de decisão.

Um estudo realizado por Benachio, Duarte e Scheer (2019) aponta a necessidade de novos estudos utilizando tecnologias digitais para o controle de qualidade na execução de obras. Nesse estudo, foram identificados que o uso de algumas tecnologias estava concentrado apenas em tarefas já executadas (SIU; LU, 2011; CHI et al, 2015; TEZEL; AZIZ, 2017; ZHOU; LUO; YANG, 2017), ou para controle dos materiais em canteiro (CHO et al., 2014; FANG et al., 2018). No entanto, diversas atividades podem ser auxiliadas com o uso de tais tecnologias, como o uso de drone para controle da qualidade na parte externa da edificação.

Diante disso, apesar de terem sido analisados diversos estudos sobre inspeções de fachadas, os mesmos estão focados apenas na classificação dos tipos de manifestações patológicas, buscando classificar uma imagem em uma categoria de defeitos (GUO et. al., 2020; GUO; LIU; YEOH; CHUA, 2020; WANG; LI, 2021). No entanto, a simples classificação de imagens com defeitos não fornece informações suficientes para os profissionais realizarem trabalhos de reparo e manutenção. Portanto, para permitir que os gestores entendam melhor os defeitos e desenvolvam um plano de reparo, é desejável indicar as localizações dos problemas encontrados, bem como a sua adequada categorização.

1.2 QUESTÕES DE PESQUISA

1.2.1 Questão Principal

Como reconhecer automaticamente falhas construtivas em fachadas de concreto durante a fase de execução com uso de drones e Aprendizado de Máquina visando melhoria da qualidade da obra?

1.2.2 Questões Específicas

O presente trabalho possui as seguintes questões secundárias:

- a) Quais falhas construtivas ou manifestações patológicas em fachadas de concreto durante a execução da obra podem ser identificadas em plano

vertical com imagens adquiridas com drone e analisadas por algoritmos de Aprendizado de Máquina?

- b) Como automatizar a identificação das falhas construtivas e manifestações patológicas em fachadas utilizando Aprendizado de Máquina?
- c) Quais as dificuldades e oportunidades de melhoria para integrar os dados de inspeções de fachada na fase de execução da obra utilizando drones e Aprendizado de Máquina ao controle de qualidade da obra?

1.3 OBJETIVOS DA PESQUISA

1.3.1 Objetivo Principal

Propor um método de reconhecimento automatizado para identificar falhas construtivas e manifestações patológicas em fachadas durante a execução com uso de drones e Aprendizado de Máquina visando melhoria na qualidade da obra.

1.3.2 Objetivos Específicos

- a) Identificar as possíveis manifestações patológicas em fachadas de concreto em plano vertical com imagens adquiridas com drone e analisadas por inteligência artificial durante a fase de execução de obras;
- b) Utilizar algoritmos de Aprendizado de Máquina para reconhecimento automatizado de manifestações patológicas em fachadas de concreto;
- c) Identificar as dificuldades e oportunidades de melhoria para incorporar os dados de inspeções de fachada na fase de execução utilizando drone e Aprendizado de Máquina no processo de controle qualidade da obra.

1.4 DELIMITAÇÃO DA PESQUISA

Os requisitos considerados como delimitadores do escopo da pesquisa são:

- a) O estudo se restringe à análise de obras durante a fase de execução, por isso não serão incluídas edificações pertencentes à fase de uso e ocupação;
- b) Serão investigadas falhas construtivas e manifestações patológicas apenas em fachadas de paredes de concreto moldadas in loco;
- c) O estudo se restringe à ação corretiva para controle de qualidade durante o processo de construção;

- d) Serão utilizadas redes de algoritmos pré treinados do Microsoft Custom Vision para treinamento e testes de reconhecimento das manifestações patológicas nas imagens.

1.5 ESTRUTURA DO TRABALHO

Esta pesquisa está dividida em seis capítulos. O **Capítulo 1** consiste na Introdução, em que foram apresentados a justificativa e problema de pesquisa, além das questões, objetivos, delimitações e estrutura da pesquisa.

O **Capítulo 2** apresenta a revisão da literatura fundamentando a pesquisa, abordando conceitos e definições sobre a gestão da qualidade durante a execução de fachadas de concreto moldadas *in loco* e as manifestações patológicas que podem surgir nesses elementos.

O **Capítulo 3** apresenta os aspectos das tecnologias digitais e sua utilização na construção civil para o reconhecimento automatizado. Apresentam-se ainda os conceitos e aplicações de drones, subconjuntos de Inteligência Artificial e técnicas de Visão Computacional.

O **Capítulo 4** apresenta o método de pesquisa, contemplando a estratégia de pesquisa utilizada, as etapas da pesquisa e as ferramentas utilizadas.

O **Capítulo 5** apresenta as análises e discussão dos resultados da pesquisa. Inicialmente são apresentados os resultados do estudo exploratório e proposta inicial do método. Em seguida são apresentados os resultados da implementação nos estudos de caso, bem como a avaliação do método proposto através de constructos e variáveis. Por fim, ainda é apresentada a estrutura detalhada e versão final do método proposto.

O **Capítulo 6** apresenta as conclusões do trabalho, incluindo suas contribuições e impactos avaliados a partir dos resultados, além de apresentar possíveis desdobramentos e sugestões para trabalhos futuros.

2. CONTROLE DA QUALIDADE NA EXECUÇÃO DE FACHADAS DE PAREDE DE CONCRETO MOLDADAS *IN LOCO*

Este capítulo apresenta uma revisão bibliográfica sobre o controle da qualidade em obras da construção civil, abordando os conceitos e as normativas para o controle da qualidade na execução de fachadas de concreto, bem como as ferramentas utilizadas para garantir a qualidade do produto final.

2.1 CONCEITOS DE QUALIDADE

Em um contexto geral, os conceitos de qualidade têm sido discutidos durante muitos anos e diversas definições já foram propostas. Para Garvin (1987), a qualidade é uma oportunidade competitiva e com este intuito propôs oito dimensões críticas da qualidade buscando facilitar a visualização das necessidades e preferências dos clientes, além de servir como base para os gestores fazerem análises estratégicas. Diante disso, essas dimensões se referem:

- **Desempenho:** se refere às características operacionais básicas;
- **Características:** se refere aos adereços ou características secundárias;
- **Confiabilidade:** se refere à probabilidade do mau funcionamento ou falha;
- **Conformidade:** se refere ao grau de atendimento as especificações;
- **Durabilidade:** se refere à vida útil;
- **Atendimento:** se refere à rapidez e facilidade de reparo;
- **Estética e Qualidade percebida:** se refere às percepções individuais de cada consumidor.

Em relação à conformidade, Garvin (1987) se refere ao grau de adesão do produto aos padrões previamente estabelecidos relacionando com os custos associados à má qualidade, que podem ser associadas às funções de perda. Essas perdas incluem custos de garantia, clientes não recorrentes e outros problemas resultantes de falhas de desempenho.

Além disso, embora a abordagem baseada na produção reconheça o interesse do consumidor pela qualidade, em que um produto ou serviço que se desvie das especificações provavelmente será mal feito ou não confiável, proporcionando menos satisfação que outro adequadamente feito ou prestado, seu enfoque básico é interno. Sendo assim, para Garvin (1992) esta é uma fraqueza grave, pois se destina pouca

atenção ao elo que os consumidores reconhecem entre qualidade e características do produto além da conformidade.

De acordo com Deming (1990), a qualidade pode ser definida através de quem a aplica, ou seja, através do operário ou gestor. Para o operário, esse conceito se dá quando ele está satisfeito com o trabalho, de forma que a ausência da qualidade determina menor lucro para empresa, acarretando a perda de seu emprego. Para o gestor, a qualidade é determinada quando se atinge as metas definidas para produção, atendendo a satisfação dos consumidores a um preço específico.

Juran e Gryna (1991) conceituaram a qualidade como a adequação ao uso, envolvendo dois aspectos: o primeiro diz que um produto de qualidade é aquele que satisfaz o cliente, ou seja, que possui características que atenda às necessidades e expectativas dele. O segundo complementa o primeiro aspecto ao considerar que a qualidade se refere à maior aproximação possível da ausência de defeitos.

Ishikawa (1993) define a qualidade como a visão e satisfação das necessidades do mercado, adequação ao uso e igualdade dos resultados do processo, sendo capaz de aumentar, idealizar, elaborar e vender um produto mais proveitoso e econômico para o cliente. Além disso, Picchi (1993) define a qualidade como um conceito dinâmico que varia com o tempo, possuindo interpretações de acordo com o interesse das pessoas ou instituições que as empregam.

Atualmente, com a chegada da indústria 4.0 (I4.0) alguns autores afirmam que o conceito de qualidade evoluiu em seis estágios, que são qualidade do produto, qualidade do processo, qualidade do serviço, qualidade da gestão, qualidade do design e qualidade da informação. As empresas estão mudando sua atenção do produto para os dados e a qualidade combinada com I4.0 pode agora ser considerada uma disciplina orientada por dados, recebendo o termo de Qualidade 4.0 (ZONNENSHAIN; KENETT et al., 2020).

O termo Qualidade 4.0 refere-se à digitalização da Gestão da Qualidade Total e seu impacto na tecnologia, processos e pessoas de qualidade. Ele se baseia em ferramentas tradicionais de qualidade e considera também conectividade, inteligência e automação para melhorar o desempenho e tomar decisões oportunas baseadas em dados em um cenário de ponta a ponta, envolvendo todas as partes interessadas e proporcionando visibilidade e transparência (CHIARINI, 2020).

Diante disso, no contexto geral, o conceito de qualidade deve estar associado ao seguimento das especificações, seja em relação aos materiais utilizados ou as

etapas de produção, além de seguir o planejamento estabelecido para evitar desvios, o que conseqüentemente evitarão defeitos no produto final, reduzindo a insatisfação do cliente. Além disso, a implementação de tecnologias emergentes da Indústria 4.0 pode auxiliar nesse processo. Essa percepção deve se estender a todos os setores produtivos, inclusive a construção civil.

2.2 CONCEITOS DE QUALIDADE NA CONSTRUÇÃO CIVIL

A busca pela qualidade está presente em todos os setores produtivos. Segundo Souza (1995), na indústria da construção, a qualidade pode ser conceituada como o resultado eficiente do planejamento e gerenciamento, da organização do canteiro de obra, das condições de higiene e segurança do trabalho, da adequada operacionalização dos processos administrativos, do controle de recebimento e armazenamento dos materiais e equipamentos e da correta execução de cada serviço específico do processo de produção.

Além disso, para Souza (1997), a qualidade de toda obra depende do empenho da equipe durante a execução dos serviços e do controle e supervisão de tais serviços para a prevenção de erros, garantindo que o fluxo seja conforme planejado, sem interrupções ou que haja problemas que impactem as etapas subsequentes. Nesse sentido, segundo Moreira (2016), a qualidade pode ser definida como adequação ao uso e ausência de falhas. Assim, a ausência de defeitos em produtos gera impactos positivos em relação à redução de custo, reclamações e, conseqüentemente, a satisfação do cliente (BERR, 2010).

Mesmo considerando que as definições e metodologias de qualidade surgiram no âmbito da indústria, é necessário fazer algumas adaptações para contemplar a heterogeneidade do setor da construção que, apesar de vir acompanhando a evolução desse conceito, ainda apresenta falhas consideráveis quando comparada a evolução entre os demais setores industriais (SOUZA, 2004). Essas dificuldades podem estar relacionadas, principalmente, com a diferença na maneira de produção e colocação dos produtos no mercado, ou seja, devido às especificidades desta área em relação a outros setores (CUNHA, 2011).

Somado a isso, de acordo com Souza (2004), o setor da construção apresenta características próprias que aumentam a dificuldade em implementar um sistema de gestão da qualidade eficiente, ou garantir a qualidade dessa área. Segundo este autor, tais especificidades são:

- a) a indústria da construção é considerada de caráter nômade;
- b) seus produtos são feitos de forma única e não em série;
- c) utiliza mão de obra com pouca qualificação;
- d) aplica a produção centralizada e não em cadeia;
- e) as responsabilidades são dispersas e pouco definidas.

Além dessas variáveis, o processo de produção na construção civil pode ser dividido em cinco etapas: planejamento, projeto, fabricação de materiais e componentes, execução da obra e uso, operação e manutenção (SOUZA, 1995; BERR 2010). Diante disso, o controle da qualidade deve ser realizado durante todas essas etapas, podendo ser realizado por meio do controle de produção, quando o foco é no controle de processos, que, por sua vez afetam a qualidade final do produto, ou pelo controle de recebimento, propondo a garantia e conformidade do produto entregue (SOUZA, 1995).

2.3 GESTÃO E CONTROLE DA QUALIDADE

Segundo Flynn et al. (1994), a gestão e controle da qualidade pode ser definida como uma abordagem integrada para alcançar e manter a alta qualidade de saída dos produtos, focando sobre a manutenção e melhoria contínua dos processos e prevenção de defeitos em todos os níveis e funções da organização, com o objetivo de reunir e exceder as expectativas dos clientes.

De acordo com Paladini (2010), o planejamento é a função organizacional base da gestão da qualidade, considerando todos os setores da empresa, enquanto cabe ao controle da qualidade comparar os resultados obtidos nos processos produtivos com os padrões planejados. Entretanto, o conceito de controle de qualidade não se limita apenas à detecção dos problemas, mas também a solucioná-los (BERR, 2010; MATTOS, 2010). Para que esse controle aconteça de maneira correta, deve-se utilizar técnicas padronizadas, inovadoras e atualizadas, promovendo assim, flexibilidade e agilidade (SUKSTER, 2005).

De acordo com Cheng e Ko (2003), devido à incerteza, complexidade de gerenciamento e a variabilidade na construção civil, o controle da qualidade deve acontecer em todas as atividades. Além disso, segundo Sukster (2005) e Chen e Luo (2014), no setor da construção civil é comum que a inspeção seja realizada apenas no produto final e, apesar dessa prática evitar que o consumidor receba um produto inadequado, ela não contribui para o processo de produção.

Para minimizar tais problemas, muitas empresas têm implantado o Sistema de Gestão de Qualidade, como ferramenta de grande importância para a melhoria dos seus processos construtivos (KAYNAK; HARTLEY, 2005; JANUZZI; VERCESI, 2010). Para isso é necessário desenvolver estratégias analisando a melhor forma de aplicar o conceito de qualidade dentro de cada empresa, adaptando suas diretrizes a um melhor entendimento e prática do mesmo (LEAL; RIBEIRO, 2017).

Em 1987, a International Organization for Standardization- ISO, com base na norma britânica “BS5750”, lançou um conjunto de normas denominadas ISO 9000 estabelecendo uma família de normas, formando um modelo de gestão de qualidade elaborado para dar apoio às organizações na elaboração de seus processos para implantação do Sistema de Gestão da Qualidade. A NBR ISO 9000 é aplicável a qualquer produto, tipo de serviço e tamanho de organização, além de ser compatível com outros sistemas de gestão, focando na melhoria contínua (SUKSTER, 2005; ALMEIDA, 2015).

A produção de serviços objetiva o equilíbrio entre custo, prazo e qualidade. Dessa forma, as normas ISO 9000 procuram implantar o conceito de qualidade, abordando desde a concepção até a concretização do produto, considerando os fatores que nela interferem, sendo eles: fatores materiais (insumos e equipamentos), fatores humanos (mão de obra qualificada, treinamento e motivação) e fatores gerenciais (planejamento, custos, comunicação etc.) (THOMAZ, 2001). Dentro da família de normas ISO 9000 encontram-se a norma ISO 9001, que especificamente é utilizada pelas empresas que procuram reconhecimento de seu sistema de gestão da qualidade para obter certificação de qualidade de seus produtos ou serviços, atender contratos mais específicos ou a qualidade exigida pelo cliente (LEAL; RIBEIRO, 2017).

Para atingir a excelência de um processo consolidado é necessária a contratação de um organismo certificador para auditar a empresa e constatar o cumprimento da NBR ISO 9001. Buscando atender as diretrizes da ISO 9001 na rotina dos canteiros de obra, faz-se uso das “ferramentas de qualidade”, que, segundo Nese (2013), são técnicas utilizadas para definir, mensurar, analisar e propor soluções para as atividades que interferem no desempenho dos processos das empresas. São aplicadas para controlar, medir e monitorar o SGQ, as quais não são difíceis de serem entendidas e usadas.

As ferramentas para controle da qualidade operacionalizam e concretizam a teoria, permitindo definir, quantificar, analisar e propor soluções aos problemas

encontrados que interferem no desempenho dos processos organizacionais (OLIVEIRA, 2014; MOREIRA, 2016). Entre as diversas ferramentas disponíveis para auxiliar esse processo, existem os Procedimentos de Execução de Serviço- PES, as Fichas de Verificação de Serviços e o ciclo PDCA.

2.3.1 Procedimento de Execução e Ficha de Verificação de Serviços

A implantação de um sistema de qualidade começa, normalmente, pela definição de um conjunto de processos, ou seja, antes da inicialização da inspeção dos serviços executados no canteiro de obra, devem ser elaborados os Procedimentos de Execução de Serviços (PES) que darão respaldo ao processo de verificação e validação da atividade, conforme estabelecido por normas técnicas que visam à padronização destes processos construtivos. Além do necessário domínio do PES por parte da equipe que fará as inspeções, a equipe operacional também deve estar atenta ao que é exigido para que a execução do serviço seja conduzida de maneira correta seguindo as normas estabelecidas (LEAL; RIBEIRO, 2017).

A Ficha de Verificação de Serviço (FVS) é um parâmetro adotado por diversas construtoras que auxilia no controle de detalhes da produção, mantendo-se assim um registro que comprovem a conformidade dos serviços. A FVS, de modo geral, consiste em uma tabela de *checklist* com os principais indicadores que devem ser avaliados de acordo com os PES. Esta deve ser clara, de fácil preenchimento, com respostas objetivas, e itens suficientes para garantir o controle de execução (MIGUEL, 2001; LOBO, 2010).

De acordo com Thomaz (2001), além dos itens de controle previstos a serem observadas nas inspeções, as FVS contêm os métodos de inspeção e limites toleráveis dos serviços inspecionados (critério de aceitação e rejeição), data de início e término do serviço, local onde foi realizado (se necessário anexar a ficha um croqui referente ao ambiente inspecionado) e espaço para identificação do problema encontrado (Figura 1). Por meio destas fichas, ficam registrados os resultados das inspeções de forma a identificar a conformidade ou não do serviço e a liberação de prosseguimento para a etapa sucessora. O principal propósito da FVS é prevenir a repetição de situações não conformes, sejam elas reais ou potenciais, identificando e lidando como a causa raiz do problema, o que facilita a adoção de ações corretivas e preventivas (LEAL; RIBEIRO, 2017).

Figura 1 - Exemplo de Ficha de Verificação de Serviços (FVS)

ITEM		MÉTODO DE VERIFICAÇÃO	TOLERÂNCIA	KIT CONFERÊNCIA	APTO FINAL 1	APTO FINAL 2	APTO FINAL 3	APTO FINAL 4	APTO FINAL 5	APTO FINAL 6	APTO FINAL 7	APTO FINAL 8	APTO FINAL 9	APTO FINAL 10	APTO FINAL 11	APTO FINAL 12
VI	DESFORMA	Conferir se a desforma foi liberada apenas quando o resultado do concreto atingir 3MPa	Não há Tolerância	-												
VF	LIMPEZA DA FORMA	Verificar a limpeza com uso de desengrante, palha de aço e espátula sem resíduos de concreto das laterais e superfícies das placas	Não há Tolerância	-												
VF	INTEGRIDADE DA FORMA	Verificar visualmente a integridade dos painéis da forma, não deve estar abauladas e amassadas de modo a comprometer o acabamento final	Não há Tolerância	-												
VF	PRUMO	Na parte interna conferir com prumo de face ou régua de 5 bolhas todas as paredes dos cômodos. Externamente com prumo de face todas as quinas das formas e, com prumo calango, a parede concretada com o pavimento anterior. Em Torre checar o prumo com topógrafo a cada 3 pavimentos	±5mm	Prumo de Face Régua de 5 Bolhas Prumo Calango Estação Total												
VF	PLANICIDADE	Conferir parede e teto com uso de régua de 5 bolhas em ambas as direções (horizontal e vertical) e em pelo menos dois pontos em cada elemento avaliado	Conforme Revestimento	Régua de 5 Bolhas												
VF	NIVELAMENTO DO PISO	Realizar a verificação do nível em todos os ambientes, no centro e nas suas quatro extremidades	Conforme Revestimento	Nível a Laser												

Fonte: FVS da Empresa X.

2.3.2 Ciclo PDCA

A sigla PDCA vem do inglês e possui o significado de *Plan* de planejar, *Do* de executar, *Check* de verificar e *Action* de ação corretiva. O objetivo do ciclo é tornar os processos envolvidos na execução da gestão mais claros e ágeis (MOREIRA, 2016). O ciclo se inicia pelo planejamento, onde são determinados os objetivos, as metas e os métodos que serão utilizados para alcançar os resultados, isto é, os procedimentos e rotinas que serão adotados. A execução representa a realização das tarefas conforme o planejamento, e coleta de dados para análise. Essa análise consiste em comparar o desempenho real com o que foi planejado, e dessa maneira buscar ações corretivas, caso as metas planejadas não tenham sido alcançadas, ou adotar o procedimento como padrão, caso o plano tenha sido efetivo (SOUZA; ABIKO, 1997; NOCÊRA, 2010; CARRILHO, 2014). Portanto, a ferramenta PDCA permite a identificação dos problemas podendo ser utilizada como método para melhoria dos processos da organização (Figura 2).

Figura 2 - Ciclo PDCA



Fonte: O autor.

2.4 CONTROLE DA QUALIDADE NA EXECUÇÃO DE PAREDES DE CONCRETO MOLDADAS IN LOCO

Com o avanço tecnológico e a industrialização na construção, vários métodos construtivos foram aprimorados, sendo um deles o método construtivo de parede de concreto, que consiste na utilização de formas moduladas para executar as paredes moldadas in loco. Este método busca a otimizar a mão de obra, reduzindo de custos, aumentando a produtividade devido a praticidade de repetição das paredes de concreto, permitindo celeridade na montagem, execução e fechamento, gerando uma obra racionalizada (COSTA, 2013).

A ABNT NBR 16055 (2012) apresenta requisitos e procedimentos para a elaboração e construção de paredes de concreto moldada in loco, enfatizando a qualidade durante todo o processo construtivo. Segundo a NBR 16055 (2012), a parede de concreto moldada *in loco* é um “elemento estrutural autoportante, moldada no local, com comprimento maior que dez vezes sua espessura e capaz de suportar carga no mesmo plano da parede”. Esse método construtivo possui características de alta produtividade, principalmente para grandes empreendimentos com alta repetitividade das edificações construídas (BRAGUIM, 2013).

Mesomo (2018) destaca a importância da identificação e atuação direta nas falhas de execução dos sistemas construtivos deste tipo de empreendimento. A correção de problemas em nível de projeto e procedimento construtivo tem enorme repercussão nas unidades produzidas dali em diante. Um problema identificado e não corrigido se replica em todas as unidades produzidas. Por se tratar de produções em larga escala, o nível de incidência de prestação de serviço por parte da empresa no que diz respeito a reparos e assistência técnica ao consumidor pode se tornar altíssimo, acarretando o aumento de custos indesejáveis, bem como insatisfação do cliente/usuário.

Outro ponto importante para se considerar é o atendimento do método construtivo à Norma NBR 15575 que estabelece os parâmetros de desempenho em relação a diversos aspectos, tais como: desempenho térmico, desempenho acústico, resistência a impacto, permeabilidade da superfície, entre outros. Além disso, para garantir a qualidade na execução das paredes de concreto, a NBR 16055 (2012) enfatiza algumas medidas importantes a serem seguidas durante a execução das etapas ou materiais que formam o produto final, tais como:


2.4.1 Execução

Os componentes empregados na moldagem das paredes de concreto são, basicamente, as formas, armaduras de aço e o concreto, além dos acessórios necessários para a montagem dos elementos (CORSINI, 2011).

a) Formas: são estruturas provisórias utilizadas para moldar o concreto que será lançado fresco, apresentando a capacidade de resistir às solicitações, desde o lançamento do concreto até sua cura, mantendo a estanqueidade e a rigorosa manutenção da geometria da peça estrutural até o momento da desforma (MISURELLI; MASSUDA, 2009).

O sistema de formas é composto por painéis de parede e seus complementos pré-montados no local com parafusos para serem içados com um guindaste ou grua, permitindo a redução do tempo de montagem, transferência e desforma (NBR ABNT 16055:2012). Além dos painéis, são utilizados outros acessórios para montagem das formas, bem como desmoldante, aplicado antes de cada montagem. Os principais acessórios podem ser observados na Figura 3.

Figura 3 - Acessórios de forma metálica com detalhamento



Fonte: Adaptado de Pereira (2015).

b) Armadura: a armadura presente no sistema de parede de concreto tem como função impedir a fissuração dos elementos de concreto, de modo a garantir a integridade física e impedir que agentes agressivos penetrem no interior dos componentes, provocando deterioração e corrosão das armaduras. Além disso, ela

controla a retração do concreto para estruturar e fixar as tubulações das instalações presentes (BARTH; VEFAGO, 2007).

Para esse sistema, são utilizadas como armadura principal telas de aço soldadas posicionadas no eixo vertical das paredes. A utilização da armadura central deve-se, principalmente, para absorver as solicitações de flexo-compressão devidas as ações horizontais do vento e do desaprumo. Nos vãos de portas e janelas, ou em esperas para ar-condicionado, são utilizadas barras de aço como reforço ao redor de suas aberturas. Nos cantos, onde ocorrem encontros “parede x parede”, utilizam-se telas de aço dobradas em “L” (MISURELLI; MASUDA, 2009). Além disso, segundo Nemer (2016), armaduras em formatos treliçados também podem ser utilizadas na execução desse sistema, sendo estas também posicionadas centralmente ao eixo dos painéis e possuem mesma necessidade de reforços em vãos de portas e janelas.

c) Concreto: é uma mistura entre cimento, pedra, areia, água e muitas vezes aditivos. Seu endurecimento, entre outras situações, é designado através de reações exotérmicas encontradas no cimento (FOIATO; REGINATO; PIOVESAN, 2013). As principais características que o concreto deve possuir para ter bom desempenho são trabalhabilidade e resistência. A trabalhabilidade vai definir a empregabilidade do concreto para determinada situação e está diretamente relacionada com a consistência e a coesão do material. Se o concreto não tiver a trabalhabilidade adequada para o sistema que ele será submetido, toda a construção estará comprometida (HELENE, 1997).

De acordo com a NBR 16055 (2012), o concreto mais indicado e utilizado no sistema de paredes de concreto moldadas in loco é o Concreto Autoadensável, ou CAA. Esse concreto tem a capacidade de completar a superfície interna das formas sem que haja segregação e, com a característica de adensar somente através da gravidade, sem a necessidade de vibração. No CAA, a viscosidade e coesão agem em conjunto garantindo que não ocorra segregação na mistura (GIROTTO; BARBOSA; MACIEL (2014). Além disso, segundo Tutikian e Molin (2021), o CAA deve possuir três propriedades simultâneas: fluidez, coesão e resistência a segregação.


O concreto é um material suscetível a ocorrência de anomalias e manifestações patológicas, caso haja erros na dosagem, mistura, manuseio, transporte, adensamento, cura, estanqueidade das formas, eficiência dos escoramentos, qualidade dos materiais incorporadas. As manifestações patológicas geradas podem

ser exemplificadas como fissuras, rupturas, vazios de concretagem, manchas de superfícies, entre outras (BOLINA; TUTIKIAN; HELENE, 2019).

2.4.2 Tratamento pós execução

Geralmente, o tratamento da superfície é feito pela própria equipe de pintura (Figura 4). Para essa atividade, utiliza-se uma lixadeira elétrica com disco de desbaste para remoção das marcas de emendas de placas, emendas entre pavimentos, rebarbas, respingos e outras imperfeições do concreto. Na sequência, são iniciadas as correções de irregularidades e o preenchimento das frestas com argamassa (FARIAS, 2022).

Figura 4 - Tratamento de Fachada



Fonte: O autor.

No estudo de Farias (2022), observou-se que a regularização da superfície e preenchimento das frestas foi feito com argamassa colante AC III, de acordo com o procedimento da empresa. A AC III é uma argamassa colante flexível composta por cimento, agregados minerais e aditivos químicos, utilizada para assentamentos cerâmicos e de porcelanatos em áreas internas ou externas, podendo ser aplicada sobre diversos substratos entre eles paredes de concreto (VOTORANTIM, 2022).

Ainda em relação ao estudo de Farias (2022), após o tratamento da superfície, do preenchimento dos vazios, do assentamento das molduras de EPS e da vedação

e limpeza de esquadrias e peitoris, foi feita a aplicação do fundo preparador para pintura. Nas obras estudadas, foi usado um selador do tipo elastomérico com diluição de 10 % em água. Foram aplicadas duas demãos com um intervalo de 4 horas. Em relação ao produto utilizado, o selador elastomérico é um produto composto de resinas elastoméricas e acrílicas que é aplicado na forma de pintura e resulta numa membrana flexível com a função de proteger e impermeabilizar superfícies (HYDRONORTH, 2022). A aplicação da textura acrílica é realizada 3 dias depois da aplicação do selador elastomérico. É utilizada uma textura de base acrílica pigmentada. O acabamento utilizado é do tipo rolado, feito com o uso de um rolo de trama de vinil, no sentido de cima para baixo, evitando-se marcas de emenda (FARIAS, 2022).

Diante disso, para a execução de paredes de concreto, além dos procedimentos utilizados pelas empresas, a NBR 16055 (2012) apresenta requisitos que vão desde a elaboração do projeto até as características gerais de execução, que devem ser seguidas de forma a evitar problemas como retrabalho, perdas ou o surgimento de anomalias e manifestações patológicas.

2.5 FALHAS CONSTRUTIVAS E MANIFESTAÇÕES PATOLÓGICAS EM FACHADAS DE CONCRETO MOLDADAS IN LOCO

Após o século XIX, a produção de concreto foi sendo aprimorada, viabilizando altas resistências, trabalhabilidade, características relacionadas à durabilidade, entre outras (SCARI; SANTOS, 2021). Para o concreto ser considerado durável, é necessário que resista aos agentes de deterioração que atuam sobre ele. A durabilidade projetada pode não ser atingida por consequência de fatores externos e internos do concreto (NEVILLE, 2016).

As ações que podem prejudicar a durabilidade do concreto são divididas em: física, mecânica ou química. Sendo os danos mecânicos causados por impacto (capacidade de o elemento suportar golpes repetidos e absorver energia), abrasão (desgaste que ocorre devido ao atrito por arraste), erosão (ação de materiais abrasivos carregados pela água) e cavitação (danos ao concreto em água corrente). O ataque químico pode ser álcali-sílica, álcali-carbonato, cloretos, sulfatos, dióxido de carbono. Já as causas físicas têm-se os efeitos de altas temperaturas, diferença entre os coeficientes de dilatação térmica do agregado e da pasta de cimento endurecida (NEVILLE, 2016).

Esses problemas não ocorrem apenas em estruturas de concreto armado, mas sim em outros elementos construtivos, podendo ser chamados de manifestações patológicas (BOLINA; TUTIKIAN; HELENE, 2019). Entre as manifestações patológicas existentes, destacam-se as fissuras, que, segundo a ABNT NBR 15575-2:2013, é classificada como seccionamento (separação) na superfície da estrutura ou em toda a seção transversal, podendo ser isolada ou múltipla, ativa ou passiva. Como as fissuras podem aparecer nas primeiras idades do concreto, há uma necessidade de controle das estruturas, para que as deformações sejam impedidas, impossibilitando grandes variações, tanto de espessura, quanto de superfície livre (PEDROSO, 2019).

O surgimento de manifestações patológicas nas edificações pode ser causado por diversas maneiras, tais como, a utilização de materiais de má qualidade, o envelhecimento natural aliado a degradação de seus componentes, problemas de conservação dos componentes estruturais e construtivos, devido à manutenção deficiente nesses sistemas, além de erros durante a elaboração e execução do projeto (SOUZA; RIPPER, 1998; SILVA, 2007; MAZER, 2008; FERREIRA; LOBÃO, 2018).

De acordo com Corrêa (2012), as fachadas de paredes de concreto estão sujeitas ao aparecimento de manifestações patológicas como qualquer sistema construtivo que reduzem a resistência da estrutura e seu desempenho. Para Filho, Souza e Barreiros (2013), as não conformidades presentes nesses elementos são decorrentes, principalmente, da inadequação as propriedades do concreto fresco, ou do mau controle e da execução.


Diante das diversas maneiras de surgimento e desenvolvimento das manifestações patológicas, este trabalho apresenta o conceito de algumas das manifestações patológicas que podem surgir em paredes de concreto, tais como, as fissuras, ninhos ou vazios de concretagem e armadura exposta.

2.5.1 Falta de remoção das faquetas

Para a junção dos painéis que compõem as fôrmas são utilizados pinos e cunhas, e os espaçadores (faquetas) são utilizados para definir a espessura da parede, fazendo o travamento de uma fôrma na outra. As faquetas devem obrigatoriamente ser envolvidas por uma proteção plástica para facilitar sua desforma (ROCHA, 2022). As faquetas são hastes de metal que realizam o travamento entre paredes internas e externas, garantindo rigidez para a concretagem (Figura 5). Para

que possam ser reaproveitadas, foram utilizados os protetores de faquetas. Esses protetores são cilindros ocos de isopor embebidos em desmoldante (ASMUS, 2019).

Figura 5 - Faquetas de travamento



Fonte: O autor.

Todos os vãos nas placas devem ter faquetas fixadas com pinos e cunhas, sendo considerado de extremamente importância. As faquetas, juntamente com o espaçador, limitam a espessura da parede. Embora o pino e a cunha possuam uma função semelhante, eles combatem a compressão que ocorre na peça durante a concretagem. É inadmissível a ausência desses componentes em qualquer parte da forma, especialmente na inferior, onde há pressão do concreto e no teto, onde há a carga do concreto e dos trabalhadores. (SAMPAIO, 2016).


Diante de sua importância durante as concretagens das paredes de concreto, é necessário que após esse serviço essas peças sejam removidas juntamente com a desmontagem das formas. A falta de remoção dessas peças pode causar problemas à estrutura, dando origem às manifestações patológicas como fissuras e corrosão das armaduras de aço, já que a peça exposta é de aço e pode transportar os agentes agressivos para as telas de aço, no interior das paredes de concreto. Dessa forma, a remoção dessas peças evita a redução de desempenho desse subsistema.

2.5.2 Fissuras

Segundo Azevedo (2011), as fissuras são manifestações patológicas que se apresentam nas estruturas de concreto sempre que ocorram tensões de tração que excedam a resistência do concreto, podendo ocorrer ainda no estado fresco ou no estado endurecido do material (Figura 6). Segundo Thomaz (2020), entre os mecanismos que possibilitam a formação de fissuras, vale destacar as variações de

temperaturas que os componentes de construção estão expostos, provocando tensões pelo movimento de dilatação e contração, causando o surgimento de fissuras. Essas movimentações térmicas estão também relacionadas à propriedade física do material, sendo levado em consideração a magnitude das tensões desenvolvidas e o grau de restrição imposto.

Figura 6 - Fissuras em fachadas de concreto



Fonte: O autor.

Além disso, as fissuras são consideradas manifestações patológicas características em estruturas de concreto, sendo o dano de ocorrência mais comum e o que mais chama a atenção de usuários (SOUZA; RIPPER, 2009). Segundo Silva (2011), tais aberturas afetam a superfície da estrutura de concreto armado tornando fácil o caminho para a entrada de agentes agressivos à estrutura.

2.5.2 Ninhos ou vazios de concretagem

Os ninhos ou vazios de concretagem, também conhecido popularmente por bicheiras (Figura 7), são espaços deixados na massa de concreto na realização do adensamento e lançamento dele. Essa segregação acontece quando não há o envolvimento dos agregados com a massa de concreto, fazendo com que não haja adesão entre os elementos da mistura (SANTOS, 2014). Estes defeitos podem afetar a durabilidade e resistência da estrutura (SILVA; FIGUEIREDO, 2018).

Figura 7 - Ninhos de concretagem em paredes de concreto



Fonte: O autor.

A separação entre agregado graúdo e argamassa pode acontecer por vários motivos, seja pela dosagem inadequada do concreto, espaçamento insuficiente de armaduras, formas não estanques, vibração inadequada e ainda lançamento do concreto a alturas elevadas (FIGUEROLA, 2006). Portanto, esses vazios devem ser completamente preenchidos, com graute ou concreto, dependendo do tamanho dele. Apenas o cobrimento com argamassa não garante a reparação do vazio e podem mascarar problemas futuros, como a corrosão da armadura (FIGUEROLA, 2006).

2.5.3 Armadura exposta

A armadura exposta pode ser causada devido ao mau posicionamento dos espaçadores ou o excesso de vibração do local, descolando a armadura (MESOMO, 2018), conforme mostra a Figura 8. Para evitar o surgimento dessa anomalia, a amarração das armaduras deve ser feita de maneira correta. Além disso, a identificação de pontos críticos e recorrência na movimentação das armaduras deve ser realizada, a fim de evitar a replicação dos erros em unidades futuras, levando em consideração a repetitividade do processo (MESOMO, 2018).

Figura 8 - Armadura exposta em paredes de concreto



Fonte: O autor.

A má interpretação do projeto, com o posicionamento incorreto da armadura, pode ocasionar zonas com insuficiência de armadura, que comprometem a capacidade de resistência da peça. As emendas entre as armaduras e o cobrimento de concreto são de extrema importância para a não aparição de manifestações patológicas relacionadas às armaduras, como as corrosões da estrutura de aço (TAKATA, 2009).

De acordo com Cândido (2005), a corrosão é o principal fenômeno patológico que afeta metais ferrosos e não ferrosos como zinco, manganês e alumínio, entre outros. Quando ocorre, esse fenômeno produz um elemento com propriedades diferentes daquele do material original, afetando características como resistência mecânica, elasticidade, ductilidade e estética. Isso acontece porque o material resultante da corrosão, seja óxido ou hidróxido, não apresenta as mesmas características do material original, comprometendo a durabilidade da construção.

Dessa forma, a corrosão é caracterizada pela deterioração de materiais, em geral metálicos, causada por ações químicas ou eletroquímicas do meio ambiente, podendo estar associada a esforços mecânicos. Essa deterioração pode apresentar alterações indesejáveis no material como desgaste, variações químicas e modificações estruturais, tornando-o inadequado para seu uso. A corrosão é um processo espontâneo e contínuo que transforma constantemente os materiais metálicos, afetando sua durabilidade e desempenho (GENTIL, 2007).

2.6 CONSIDERAÇÕES ACERCA DO CAPÍTULO 2

A partir dos conceitos apresentados neste capítulo é possível entender que um produto ou serviço de qualidade é aquele que atenda as expectativas e necessidades do cliente, de forma satisfatória, na qual deve receber o produto final com a maior aproximação possível da ausência de defeitos. Além disso, uma dimensão relacionada da qualidade é a conformidade, ou seja, o nível em que o modelo e as características operacionais de um produto estejam conformes aos padrões ou especificidades estabelecidas.

Na construção civil, a qualidade pode ser alcançada quando a equipe de produção segue todos os requisitos normativos, as diretrizes estabelecidas em projeto e desenvolve as atividades conforme o planejamento proposto. Caso esses pontos não sejam seguidos, o surgimento de defeitos ou manifestações patológicas é

eminente. Diante desses problemas, a necessidade de reparos ou retrabalhos é considerada como perdas, pois poderiam ser evitadas. Sendo assim, o conceito de qualidade percorre todos os setores da produção, envolvendo desde a utilização correta dos materiais até as técnicas e processos até a entrega do produto final.

Em relação à qualidade na execução de paredes de concreto moldadas in loco, o uso e seguimento de ferramentas como o PES e as FVS são necessários para produzir um produto livre de defeitos. A realização da FVS deve ser realizada durante todo o processo de construção, desde as atividades preparatórias para a execução, bem como nas atividades de pós execução, buscando identificar falhas no processo que possam ser corrigidas para que não ocorram mais. Além disso, a NBR 16055 (2012) apresenta requisitos e procedimentos para que esse elemento seja executado de maneira correta e atinja o desempenho esperado.

A interferência no desempenho de uma construção pode ser representada pela propagação de manifestações patológicas. Dessa forma, para garantir a qualidade durante o processo construtivo de fachadas de concreto é necessário inspecionar as atividades. Entretanto, a atividade de inspeção apresenta algumas limitações, principalmente quando é realizada de forma manual e visual. Portanto, o uso de ferramentas digitais para automatizar esse processo vem sendo investigada em diversos estudos e prometem melhorar essas atividades.

Nesse contexto, o capítulo seguinte abordará especificamente os conceitos relacionados às tecnologias digitais utilizadas para aquisição de dados e as técnicas de processamento digital a partir de subconjuntos de inteligência artificial.

3. TECNOLOGIAS DIGITAIS UTILIZADAS PARA IDENTIFICAÇÃO AUTOMATIZADA DE MANIFESTAÇÕES PATOLÓGICAS NA CONSTRUÇÃO

Este capítulo tem como objetivo apresentar as tecnologias digitais utilizadas para identificação automatizada de manifestações patológicas na construção civil. Inicialmente, são brevemente apresentados os conceitos de drones utilizado para aquisição de dados. Em seguida, são abordados os conceitos de Visão Computacional e suas subáreas e, posteriormente, são apresentados os princípios de processamento digital através de algoritmos de Inteligência Artificial (IA), bem como os conceitos de Aprendizado de Máquina, Aprendizado Profundo, Redes Neurais Convolucionais e outros subconjuntos.

Ainda neste capítulo, são apresentadas as tecnologias digitais utilizadas em pesquisas internacionais sobre reconhecimento automatizado de manifestações patológicas em construções, por meio dos resultados de uma Revisão Sistemática da Literatura- RSL.

3.1 DRONES PARA AQUISIÇÃO DE DADOS

A necessidade em utilizar as tecnologias digitais na indústria da construção civil vem crescendo gradualmente nas últimas décadas. Entre as diversas tecnologias utilizadas para aquisição de dados, os drones se destacam por contemplar diversos benefícios, conforme serão apresentados a seguir.

Os drones ou as Aeronaves Remotamente Pilotadas (RPA) são aeronaves não tripuladas, ou seja, pilotada a partir de uma estação de pilotagem remota com finalidade diversa de recreação (ANAC, 2021). As estações de pilotagem remota são chamadas RPS (*Remote Pilot Station*) e todo o sistema de aeronaves remotamente pilotadas é denominado de RPAS (*Remotely-Piloted Aircraft System*), o qual significa todo o conjunto de elementos abrangendo um drone, o RPS correspondente, os dispositivos de comando e controle e quaisquer outros elementos envolvidos na operação (KIM; IRIZARRY, 2015; ANAC, 2021).

Os drones surgiram durante as guerras militares que ocorreram no nordeste da Itália, em meados de 1849, e desde então, seu uso tem se tornando cada vez mais atraente para aplicações civis, federais e comerciais, com destaque para usos nas áreas da construção civil (PURI, 2005; KIM; IRIZARRY, 2015; MELO et al., 2017; RAKHA; GORODETSKY, 2018). Segundo Kim e Irizarry (2015), os drones funcionam por meio da combinação de hardwares e softwares, nos quais as plataformas não

tripuladas são equipadas para coleta e, em alguns casos, também processamento de dados sem intervenção humana direta (remotamente controlados).

A operação dos drones pode ser exercida de três maneiras: (1) operação autônoma, controlados apenas por computadores e sistemas de piloto automático; (2) remotamente controlados por um piloto humano, através de uma estação de controle portátil ou estacionária; ou (3) operação semiautônoma, também chamada de automatizada, que funciona como uma combinação das duas outras (COLOMINA; MOLINA, 2014; MORGENTHAL; HALLERMANN, 2014).

De acordo com Morgenthal e Hallermann (2014), os drones apresentam diversas vantagens comparadas as aeronaves tripuladas, tais como:

- maior velocidade, agilidade e leveza, possibilitando mobilidade para o voo;
- capacidade de coletar imagens e gravar vídeos em alta resolução, além do uso de diversos sensores acoplados;
- maior facilidade na operação, necessitando apenas de um operador no comando da estação de controle, controlando a aeronave e os dispositivos acoplados, e pelo menos um observador, apoiando a operação;
- maior segurança, possibilitando aproximação de estruturas, objetos e áreas de risco ou de difícil acesso, evitando a exposição da vida humana;
- maior acessibilidade em relação aos custos, tanto no equipamento em si, quanto aos custos de manutenção e operação;
- maior capacidade para transferência de dados em tempo real entre o drone e a estação de tratamento, além do armazenamento de dados a bordo.

Apesar de todas estas vantagens, os drones apresentam certas limitações, especialmente os menores e mais leves. Por conta do seu tamanho reduzido, apenas dispositivos pequenos e com pesos compatíveis podem ser acoplados à plataforma. Esta limitação também impacta no tamanho e capacidade de suas baterias, uma vez que a principal fonte de energia dos RPAS é a energia elétrica (principalmente os menores de asas rotativas), reduzindo a autonomia de voo. Além disso, outro aspecto afetado pelo baixo peso da aeronave é a sensibilidade do seu sistema de voo, o qual sofre interferência direta de mudanças meteorológicas, como chuvas e ventos mais fortes (MORGENTHAL; HALLERMANN, 2014).

3.2 VISÃO COMPUTACIONAL

A visão computacional pode ser definida como a área de estudo que busca reproduzir a visão humana quanto a capacidade de extrair das imagens suas características, permitindo interpretar e descrever essas imagens e os elementos nelas presentes (SZELISKI, 2010; JUNIOR; BACKES, 2016). A visão humana é capaz de identificar, de maneira natural, as características de pessoas e objetos, interpretando de forma precisa os elementos observados, como cores, formas e luminosidade, podendo realizar classificações desses elementos (SZELISKI, 2010).

O alcance do propósito da visão computacional não é uma tarefa trivial, principalmente quando a imagem possui muitos elementos. A maioria das aplicações que utiliza visão computacional necessita realizar diversos pré-processamentos para tratar a imagem de entrada, para, então, extrair ou identificar os elementos desejados por meio de algoritmos teorizados e desenvolvidos (PRINCE, 2012).

Segundo Szeliski (2010), a visão computacional é composta por subáreas, em que cada uma possui seu conjunto de técnicas, utilizada por sistemas cuja entrada seja uma imagem, um conjunto de imagens ou vídeo. Dentre as subáreas, tem-se:

- Processamento;
- Segmentação;
- Detecção;
- Reconhecimento e classificação.

O processamento de imagem é responsável por “melhorar” a imagem, isto é, retirar ruídos, realçar bordas e suavizar a imagem (JUNIOR; BACKES, 2016). Na maioria das vezes é realizado durante a fase de pré-processamento de um sistema de visão computacional, ou seja, antes de quaisquer outras técnicas serem utilizadas, buscando preparar e corrigir a imagem quanto a cor, brilho, contraste, ruídos ou posicionamento (SZELISKI, 2010). A Figura 9 apresenta um exemplo de processamento de uma imagem, onde a figura (a) representa a imagem natural, a figura (b) recebe uma correção de brilho e cor, a (c) aplicação de contraste e, por fim, a figura (d) rotacionada.

Figura 9 - Processamento de imagem



Fonte: Szeliski (2010).

A segmentação é responsável por particionar a imagem em regiões de interesse, ou seja, caracteriza-se por agrupar os pixels que possuem características semelhantes, criando diversos segmentos deles. Essa tarefa é realizada para que as análises e operações possam ser executadas de formas diferentes sobre esses grupos. O processo de segmentação pode ser realizado após, por exemplo, a detecção de bordas e extração do elemento desejado da imagem (JUNIOR; BACKES, 2016). Um exemplo dessa operação em uma imagem para remover o plano de fundo, destacando o elemento principal, é apresentado na Figura 10.

Figura 10 - Processamento de imagem



Fonte: Rother, Kolmogorov e Blake (2004).

A detecção de elementos em uma imagem é muito utilizada nas aplicações de visão computacional. Os algoritmos de detecção de face, de borda, pontos característicos, entre outros são bastante utilizados para localizar e delimitar o elemento foco de análise, para então, realizar as operações desejadas sobre o ponto ou área detectada, conforme Figura 11 (SZELISKI, 2010).

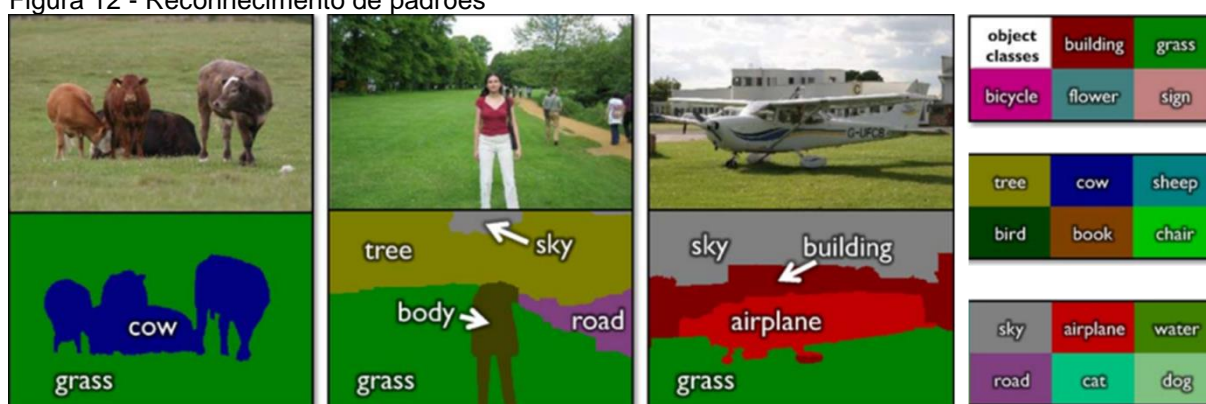
Figura 11 - Detecção de elementos



Fonte: Viola e Jones (2004).

O reconhecimento de padrões é responsável por classificar ou agrupar as imagens com base em seus conjuntos de características (Figura 12). Por exemplo, ao ver a imagem de uma laranja, é possível observar, com base em atributos como cor, rugosidade da casca, formato, tamanho etc., que ela pertence à classe das "laranjas" (JUNIOR; BACKES, 2016). No entanto, esse processo é uma das tarefas mais difíceis de ser implementada em visão computacional. Tal dificuldade provém das infinitudes de objetos possíveis no mundo real, que variam em formas, cores, e posição na imagem analisada. As técnicas de reconhecimento necessitam antes de realizar as devidas classificações, detectar o objeto desejado.

Figura 12 - Reconhecimento de padrões



Fonte: Shotton et al. (2007).

3.3 INTELIGÊNCIA ARTIFICIAL E SUBCONJUNTOS

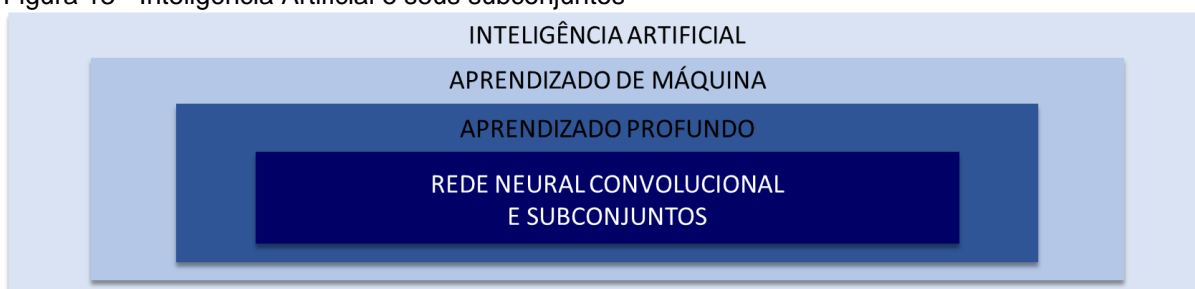
A Inteligência Artificial (IA) é um conceito amplo cujo objetivo é o desenvolvimento de sistemas que exibem características que estão associadas à inteligência no comportamento humano (MÜLLER; GUIDO, 2016). O advento da Inteligência Artificial provocou uma tentativa de replicar o raciocínio agudo e as capacidades de resolução de problemas do cérebro humano (BROOKS, 1991). Suas áreas de aplicação no início eram limitadas, já que esse campo tinha pouco reconhecimento (MCCORDUCK; CFE, 2004). No entanto, suas aplicações têm aumentado cada vez mais, principalmente, pelo aprimoramento de seus subconjuntos e surgimento de novos algoritmos.

Segundo Mondal (2020), a Inteligência Artificial pode ser subdividida em camadas ou em partes que a compõe, introduzindo, dessa forma, os conceitos de Aprendizado de Máquina, do inglês *Machine Learning*-ML e Aprendizado Profundo, do inglês *Deep Learning*-DL. Consiste basicamente em fornecer dados de entrada e,

assim, a máquina pode aprender com esses dados e elaborar saídas que satisfaçam a situação problema.

Dessa forma, o algoritmo permite que modelos que consistem em várias camadas de processamento operem e aprendam representações de dados usando vários níveis de abstração (ILIN; WATSON; KOZMA, 2017). Portanto, a Aprendizagem Profunda, conforme ilustrada na Figura 13, é um subconjunto da Aprendizagem de Representação, que é um subconjunto da Aprendizagem de Máquina, que também é um subconjunto da Inteligência Artificial.

Figura 13 - Inteligência Artificial e seus subconjuntos



Fonte: Adaptado de Mondal (2020).

3.3.1 Aprendizado de Máquina

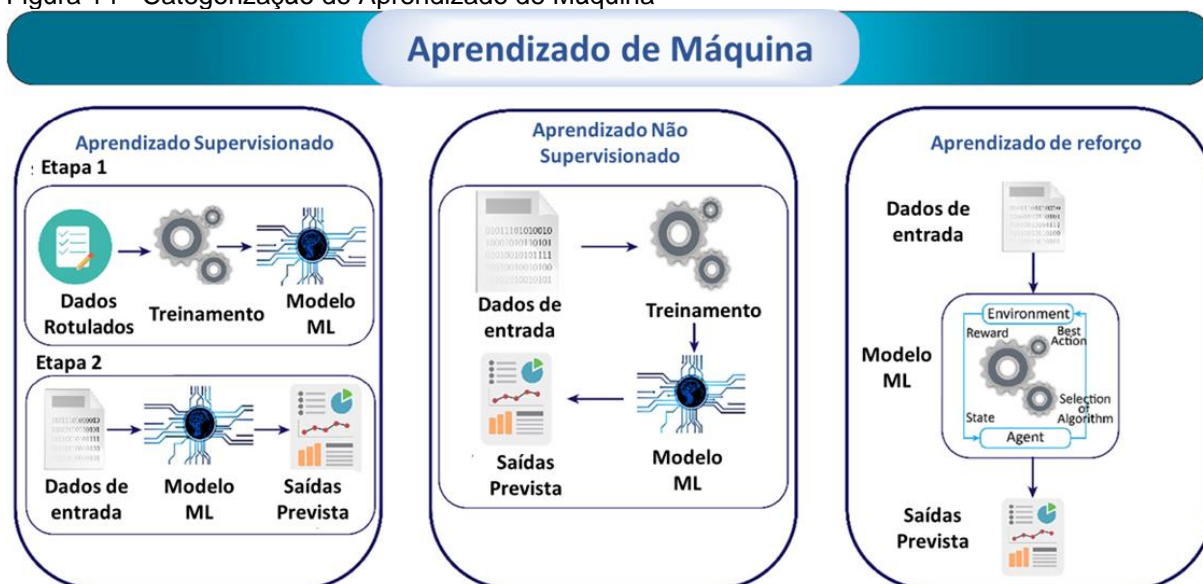
O aprendizado de máquina, do inglês Machine Learning (ML), é um ramo da ciência da computação e um subconjunto da IA que, por meio de experiências anteriores e através de treinamento de máquina, é capaz de aprender a reconhecer padrões (SINGH et al., 2020). O objetivo do ML é aprender com dados fornecidos de experiências antecessoras a fim de se extrair informações sobre o processo analisado (MAHESH, 2019; SINGH et al., 2020). O treinamento da máquina é feito mediante fornecimento de um conjunto de dados e aplicação de algoritmos específicos, para que seja possível aprender com os dados e fazer previsões ou classificações. Os dados fornecidos aos algoritmos de treinamento podem ser binários, nominais ou até mesmo contínuos (SINGH et al., 2020).

O ML é uma ferramenta poderosa para solucionar diversos tipos de problemas, facilitando tomadas de decisão e ações por meio de suas interpretações (MEKONNEN et al., 2020). Além disso, desempenham um papel importante, especialmente quando o processamento de grandes quantidades de dados traz um valor agregado significativo para economizar tempo e maximizar os recursos de computação (XU et al., 2021).

Além disso, os métodos de ML podem ser categorizados de várias maneiras. Um dos métodos proeminentes de categorização de modelos de ML é pela quantidade de

supervisão que eles recebem durante o processo de treinamento do modelo. Os modelos de ML podem ser categorizados como aprendizado supervisionado, aprendizado não supervisionado ou aprendizado por reforço, conforme mostra a Figura 14 (MEKONNEN et al., 2020; BADUGE et al., 2022).

Figura 14 - Categorização do Aprendizado de Máquina



Fonte: Traduzido de Baduge et al. (2022).

O aprendizado supervisionado é aquele em que são definidas variáveis de entrada e saída e um algoritmo que cria modelos capazes de relacioná-las (SINGH et al., 2020; MEKONNEN et al., 2020). Para que os modelos gerados sejam capazes de realizar previsões ou classificações, o conjunto de dados é dividido entre dados de treino e teste (MAHESH, 2019). A separação dos dados em teste e treino faz com que o aprendizado supervisionado forneça dados mais precisos e confiáveis (SINGH et al., 2020). Exemplos de algoritmos de aprendizado supervisionado são: Árvores de Decisões, Florestas Aleatórias, *Gradient Boosting* e Redes Neurais.

Já o aprendizado não supervisionado inclui apenas as variáveis de entrada e nenhuma saída (SINGH et al., 2020; MEKONNEN et al., 2020). Por não ter nenhuma saída relacionada com as entradas, o algoritmo precisa descobrir por conta própria uma estrutura para os dados. Esse tipo de técnica pode ser utilizado, por exemplo, para o agrupamento de dados em grupos com base nas suas similaridades, detecção de valores atípicos nos dados e redução de dimensionalidade (MAHESH, 2019; MEKONNEN et al., 2020). Exemplos de algoritmos de aprendizado não supervisionado são: K-means e Apriori.

Por fim, o aprendizado de reforço é um tipo de aprendizado em que a máquina aprende com os dados e tenta decidir qual a melhor ação a ser tomada de acordo com as condições em que os dados se encontram. Esse tipo de treinamento usa uma sequência de decisões para atingir uma meta em um ambiente incerto e complexo, sendo baseado em uma interação entre um agente e o ambiente. Por meio de tentativa e erro, a máquina encontra a solução para o problema. O objetivo é maximizar o resultado final. Um exemplo de algoritmo de aprendizado de reforço é o Q-learning. (DAYAN; NIV, 2008; MNIH et al., 2015).

Em relação aos algoritmos de aprendizagem supervisionada, é necessário realizar a separação dos dados em treino e teste. Os algoritmos são treinados e otimizados utilizando os dados de treino. Os dados de teste ficam inacessíveis ao algoritmo durante todo o treino. Ao final do treinamento e otimização, o modelo é avaliado com os dados de teste, simulando como seria o desempenho do modelo de ML ao classificar dados que ele nunca processou. Com essa técnica, pode-se prever como o modelo se sairia no mundo real, onde as entradas que são dadas ao modelo são desconhecidas no momento do treino. Um modelo que obtém ótimo desempenho com os dados que treinou pode ter apenas decorado os valores vistos durante o treino e ter um desempenho fraco com dados que nunca viu (GÉRON, 2019). Sendo assim, o desempenho de um modelo deve sempre ser avaliado com dados que ele não encontrou durante o treino, pois isso evita o descobrimento de falsas relações nos dados.

Existem dois problemas comuns que podem ocorrer durante o treinamento. O primeiro deles é o *Overfitting*, que é quando o algoritmo aprende os dados de entrada durante os treinamentos e consegue reconhecer apenas os dados treinados, ou seja, ao inserir novos dados durante os testes, ele não reconhece, como se o algoritmo tivesse apenas decorado os dados de treinamento. Para combater o *Overfitting*, pode utilizar o ajuste de parâmetros do modelo, ou regularização, com o intuito de limitar sua capacidade de aprendizado, evitando que ele aprenda o ruído dos dados (DIETTERICH, 1995; GÉRON, 2019).

O *Underfitting*, por sua vez, se refere à quando o modelo tem um desempenho fraco ao classificar instâncias de treino e de teste. Isso demonstra que o modelo que está sendo utilizado não tem a capacidade necessária para aprender o sinal de que estão presentes nos dados. A utilização de modelos mais complexos ou o ajuste de

parâmetros que tornam o modelo mais flexível podem ajudar a minimizar esse problema (DIETTERICH, 1995; GÉRON, 2019).

A avaliação de desempenho dos modelos de ML é um aspecto muito importante. Além disso, a melhor abordagem para avaliação do desempenho depende muito do problema a ser abordado (JAPKOWICZ; SHAH, 2015). Há diversos tipos de métricas para avaliar o desempenho de um algoritmo ML (HANDELMAN et al., 2019). Neste trabalho serão abordadas as métricas: Matriz de Confusão, Precisão, Recall, Acurácia, F1 Score e mAP.

- **Matriz de Confusão:** Uma classificação binária ou predição pode resultar em quatro resultados diferentes, conforme a combinação entre o valor predito pelo modelo e o valor atual, sendo eles: Verdadeiro-Positivo (VP), Verdadeiro-Negativo (VN), Falso-Positivo (FP) e Falso-Negativo (FN), conforme é demonstrada na Figura 14. Essa tabela também é chamada de Matriz de Confusão, pois evidencia exatamente onde o modelo está acertando ou cometendo erros (GÉRON, 2019).

Figura 15 - Matriz de Confusão

		Predito	
		Positivo	Negativo
Atual	Positivo	Verdadeiro-positivo (VP)	Falso-negativo (FN)
	Negativo	Falso-positivo (FP)	Verdadeiro-negativo (VN)

Fonte: Adaptado de Géron (2019).

O VP é quando o valor predito é positivo e a predição é correta. O VN é quando o valor predito é negativo e a predição é correta. O FP é quando o valor predito é positivo e a predição é incorreta (GÉRON, 2019). O FN é quando o valor predito é negativo e a predição é incorreta. Esses conceitos ajudam a identificar problemas quando uma classificação possui um desbalanceamento de classes. Um problema de classificação desbalanceado pode ser observado, por exemplo, quando existem poucas observações positivas a serem classificadas. Nesse caso, o alto valor de VN e baixo valor de FP do modelo pode apresentar resultados expressivos mesmo sem real desempenho do modelo (POZZOLO et al., 2015).

- **Precisão:** A precisão de um modelo é dada pela razão entre o número de previsões positivas identificadas corretamente e o número total da amostra da entrada (HANDELMAN et al., 2019). Ou seja, a precisão é a capacidade de um modelo para evitar rotular amostras negativas como positivas. A sua fórmula pode ser observada pela equação a seguir.

$$\textit{Precis\~{a}o} = \frac{VP}{VP + FP}$$

- **Recall:** é o percentual que mede o número de previsões positivas corretas feitas a partir de todas as previsões positivas que poderiam ter sido feitas. A precisão mostra o contexto geral sobre as predições positivas corretas de todas as predições positivas. O recall, por sua vez, pode mostrar as predições positivas perdidas. A otimização do recall tem como objetivo reduzir os falso-negativos. A sua fórmula pode ser observada pela equação a seguir.

$$\textit{Recall} = \frac{VP}{VP + FN}$$

- **Acurácia:** é o percentual de previsões que coincidem exatamente com os rótulos de classe verdadeiros. A acurácia é uma métrica para avaliar modelos de classificação. Internamente, a precisão é a fração das previsões que o modelo acertou. Formalmente, a precisão tem a seguinte definição:

$$\textit{Acurácia} = \frac{\textit{Número de previsões corretas}}{\textit{Número total de previsões}}$$

Para classificação binária, a acurácia também pode ser calculada em termos de positivos e negativos, da seguinte maneira:

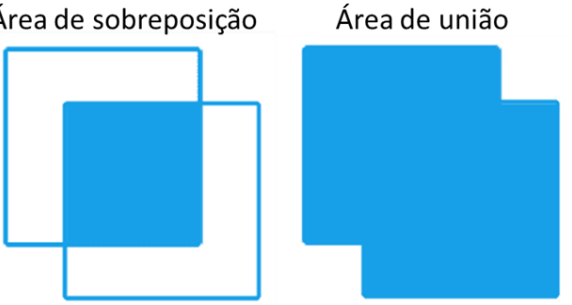
$$\textit{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN}$$

- **F1 Score:** é uma métrica que busca trazer equilíbrio entre a precisão e o recall é a pontuação F1, que traz a média harmônica entre as duas medidas. Os possíveis valores para a pontuação F1 vão de zero até um. A fórmula pode ser observada na equação a seguir.

$$\textit{F1 Score} = \frac{2 * (\textit{precis\~{a}o} * \textit{recall})}{\textit{precis\~{a}o} + \textit{recall}}$$

- **IoU:** A interseção sobre a união (*Intersection over Union* - IoU) é usada para avaliar o desempenho da detecção de objetos comparando a caixa delimitadora de verdade com a caixa delimitadora prevista, ou seja, é um número que quantifica o grau de sobreposição entre duas caixas (Figura 16).

Figura 16 - Fórmula da intersecção sobre a união

$$IoU = \frac{\text{Área de sobreposição}}{\text{Área de união}}$$


Fonte: Disponível em <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>, acesso em janeiro de 2023.

Em relação a classificação binária, essa métrica também pode ser calculada em termos de positivos e negativos, da seguinte maneira:

$$IoU = \frac{VP}{VP + FP + FN}$$

- **mAP:** A Média da Precisão Média, do inglês *mean Average Precision* (mAP), é comumente usada para analisar o desempenho de sistemas de detecção e segmentação de objetos como Fast R-CNN, YOLO, Mask R-CNN. O mAP é calculado encontrando a Precisão Média para cada classe e, em seguida, a média de várias classes. O mAP incorpora uma troca entre precisão e recall e considera falsos positivos e falsos negativos. Essa propriedade torna o mAP uma métrica adequada para a maioria dos aplicativos de detecção (SHAH, 2023). A fórmula geral do mAP é baseada nas submétricas matriz de confusão, intersecção sobre a união (IoU), precisão e recall. Essa fórmula pode ser observada na equação a seguir.

$$mAP = \frac{1}{n(\text{classes})} \sum_{k=1}^{k=n} AP_k$$

Diante do exposto, observa-se que existem diversas maneiras de avaliar o desempenho dos modelos que utilizam ML e demais subconjuntos de IA justificando a crescente aplicação para diversas finalidades. Além dos métodos de ML estarem evoluindo constantemente e sendo aplicado em várias áreas, seus subconjuntos vêm acompanhando essa evolução e difusão. Entre esses subconjuntos de algoritmos destaca-se o Aprendizado Profundo (MEKONNEN et al., 2020).

3.3.2 Aprendizado Profundo

O aprendizado profundo, do inglês Deep Learning ou DL é um subcampo de aprendizado de máquina e pode ser entendido como o estudo de redes neurais artificiais e de outros algoritmos de aprendizado de máquina relacionados que

consistem em mais de uma camada oculta. Portanto, o caminho de computação em um algoritmo de aprendizagem profunda tem várias etapas desde as entradas até as saídas (BADUGE et al., 2022). O DL aborda o desafio de construir representações complexas a partir de representações mais simples e tendo várias camadas de abstração. O algoritmo permite que modelos que consistem em várias camadas de processamento operem e aprendam representações de dados usando vários níveis de abstração (ILIN; WATSON; KOZMA, 2017).

O DL surgiu com o intuito de contornar situações em que existe certa complexidade na realização da tarefa por uma máquina. Um algoritmo de DL tem como objetivo gerar o aprendizado por meio da compreensão da hierarquia de conceitos (GOODFELLOW; BENGIO; COURVILLE, 2016).

Na hierarquia de conceitos a experiência do conhecimento é adquirida através do aprendizado de conceitos mais simples até aprender conceitos mais complicados (GOODFELLOW; BENGIO; COURVILLE, 2016). Pode-se entender por hierarquia de conceitos como um grafo profundo, ou seja, possui várias camadas que representam o processo de aprendizado. Essas diversas camadas são pontos fundamentais para os algoritmos de Aprendizado Profundo e seus subconjuntos.

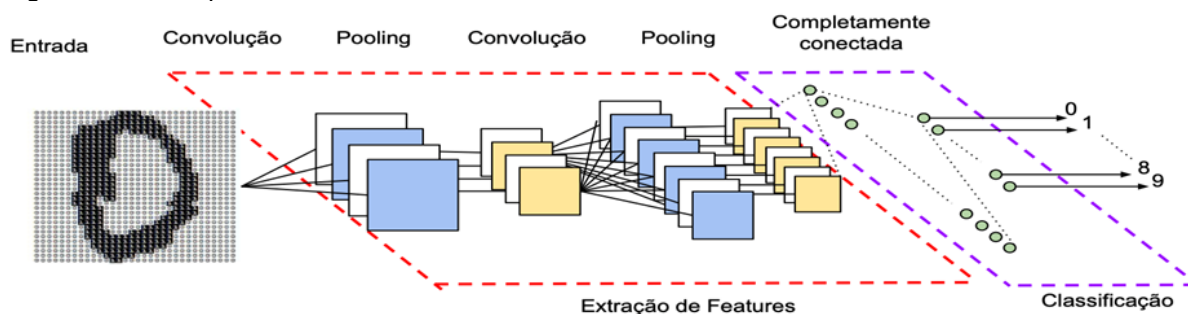
3.3.3 Redes Neurais Convolucionais e demais subconjuntos

A Rede Neural Convolucional (do inglês Convolutional Neural Network ou CNN) é um tipo especial de rede neural multicamada ou arquitetura de aprendizado profundo inspirada no sistema visual dos seres vivos (SULTANA; SUFIAN; DUTTA, 2018; GHOSH et al., 2020). Considerada adequada para diferentes campos de visão computacional e processamento de linguagem natural, principalmente, nas aplicações de classificação, detecção e reconhecimento em imagens e vídeos (VARGAS, PAES; VASCONCELOS, 2016).

Segundo Sultan, Sufian e Dutta (2018), a CNN, também chamada de ConvNet, é um tipo de Rede Neural Artificial que possui uma arquitetura de *feed-forward* profunda e pode aprender recursos altamente abstratos de objetos, especialmente dados espaciais, podendo identificá-los com mais eficiência. Esse tipo de rede neural consiste em um conjunto finito de camadas de processamento que pode aprender vários recursos dos dados de entrada como de uma imagem, por exemplo, acompanhado por vários níveis de abstração.

De acordo com Ghosh et al. (2020), a CNN é composta de um ou vários blocos de camadas de convolução e agrupamento, também chamado de *pool* ou *pooling*, seguidos por uma ou várias camadas totalmente conectadas e uma camada de saída ou classificação, conforme ilustra a Figura 17. As camadas iniciais aprendem e extraem os recursos de alto nível (com menor abstração), e as camadas mais profundas aprendem e extraem os recursos de baixo nível (com maior abstração).

Figura 17 - Exemplo de uma Rede Neural Convolutiva e suas camadas




Fonte: Vargas, Paes e Vasconcelos (2016).

Cada unidade do mapa de características está conectada a um campo receptivo da camada anterior. O novo mapa de recursos é gerado pela convolução da entrada com os *kernels* e pela aplicação da função de ativação não linear, elemento a elemento, no resultado convoluido. A propriedade de compartilhamento de parâmetros da camada convolucional reduz a complexidade do modelo, dessa forma, a camada de agrupamento, também conhecido como camada de *pooling*, ou sub amostragem utiliza uma pequena região da saída convolucional como entrada e a reduz, produzindo uma única saída. O *pooling* reduz o número de parâmetros a serem calculados, bem como torna a tradução da rede invariável (VARGAS, PAES; VASCONCELOS, 2016; GHOSH et al., 2020).

A camada convolucional é o bloco de construção central de uma CNN e tem como objetivo aprender as representações dos recursos de entrada (Figura 18). Essa camada é composta por vários filtros ou *kernels* de convolução apreensíveis que são usados para calcular diferentes mapas de recursos (GHOSH et al., 2020). Geralmente as imagens permanecem na natureza, isso significa que a formação de uma parte da imagem é semelhante à de qualquer outra parte. Dessa maneira, uma característica aprendida em uma região pode coincidir com o padrão semelhante em outra região (SULTANA; SUFIAN; DUTTA, 2018).

Figura 18 - Exemplo do processo de convolução




Fonte: Adaptado de Sultana, Sufian e Dutta (2018).

Muitos modelos avançados de CNN foram propostos nessas áreas em anos sucessivos. Essas áreas aplicam a CNN para obter alto desempenho na classificação de imagens, rastreamento e detecção de objetos, segmentação, estimativa de pose humana, detecção de texto, detecção de saliência visual, reconhecimento de ação, rotulagem de cena, resposta visual a perguntas, fala e processamento de linguagem natural, entre outras aplicações (SULTANA; SUFIAN; DUTTA, 2018; SULTANA; SUFIAN; DUTTA, 2020; ZAITOUN; AQEL, 2015).

3.4 ANÁLISE DO USO DE TECNOLOGIAS DIGITAIS PARA IDENTIFICAÇÃO AUTOMATIZADA DE MANIFESTAÇÕES PATOLÓGICAS EM CONSTRUÇÕES

Esta seção apresenta os resultados de uma Revisão Sistemática da Literatura (RSL) cujo propósito foi levantar quais as tecnologias digitais utilizadas para aquisição e processamento dados para identificação automatizada de manifestações patológicas em construções, bem como as limitações desses estudos. As etapas realizadas na RSL estão descritas no item 4.3.2, desta dissertação. Foram revisados 37 artigos distribuídos em 24 periódicos internacionais. A distribuição das publicações por periódico é apresentada na Figura 19a e número de publicações por ano na Figura 19b.

Figura 19 - Publicações: (a) por periódicos; e (b) por ano e tipo de construção



Fonte: O autor.

Os artigos foram agrupados de acordo com o tipo de construção em que os estudos foram realizados, sendo, 16 publicações realizaram estudos em construções de infraestrutura como pontes, estradas e estruturas de aço e concreto; 13 publicações usaram as tecnologias digitais em elementos de edificações como paredes, telhados e fachada e, por fim, 6 publicações foram consideradas como “ambos”, por utilizar as duas tipologias nos estudos. A lista dos artigos revisados é apresentada no Apêndice A. Além disso, a análise foi dividida em tecnologias digitais utilizadas para aquisição e processamento de dados e por fim, são apresentados alguns direcionamentos para novas pesquisas a partir dessa RSL.

3.4.1 Tecnologias digitais utilizadas para aquisição de dados

A amostra analisada apresentou várias tecnologias utilizadas para adquirir os dados utilizados para processamento digital a partir de algoritmos de aprendizado de máquina. Entre essas tecnologias estão os drones com câmeras acopladas, câmeras manuais e várias tecnologias integradas, como drones, câmeras e lasers. Além dessas tecnologias, alguns estudos utilizaram dados da literatura devido à necessidade de grandes bases de dados para treinamento dos algoritmos.

Dessa forma, a análise foi realizada a partir das tecnologias utilizadas para aquisição de dados e das tipologias construtivas onde os estudos da referida RSL foram realizados (Quadro 1).

Quadro 1 - Tecnologias utilizadas para aquisição de dados

Tecnologias utilizadas para aquisição de dados	Tipologias construtivas analisadas	Autores/trabalhos
Drones com câmera acoplada	Pontes	Ellenberg et al. (2016); Morgenthal et al. (2019); Yeum et al. (2019); Ayele et al. (2020); Potenza et al. (2020); Bianchi e Hebdon (2022); Yoon et al. (2022) e Munawar et al. (2022).
	Paredes e fachadas	Kang e Cha (2018); Jiang e Zhang (2020) e Bouzan et al. (2021); Draganic et al. (2022) e Ribeiro et al. (2022).
	Estruturas de concreto, aço ou de concreto armado	Hoskere et al. (2020); Ribeiro et al. (2020); Choi et al. (2021) Luo et al. (2021); Oring (2022); Liu e Chen (2022); Munawar et al. (2022).
	Estradas, ferrovias e túneis	Zhu et al. (2021) e Wu et al. (2021); Tilon et al. (2022)
	Telhados	Otoni, Novo e Costa (2022)
Câmera manual	Estrutura de concreto	Dorafshan et al. (2018).
	Fachadas	Kim et al. (2021).
Banco de dados existentes na Literatura	Estrutura de concreto	Flah et al. (2020); Ghosh et al. (2020); Le et al. (2021) e Mondal e Jahanshahi (2022)
	Fachadas	Liu et al. (2020).
Integração de várias tecnologias como drones, câmeras, lasers e imagens de satélite	Pontes	Valença et al. (2017).
	Telhados e fachada	Castagno e Atkins (2018); Vetrivel et al. (2018) e Oh Oh, Ham e Lee (2021);
	Concreto armado ou aço	Bhowmick et al. (2020) e Kung et al. (2021).

Fonte: O autor.

A amostra apresenta que as principais tecnologias digitais para aquisição de dados foram drones com câmeras acopladas (Figura 20). A maioria deles eram drones comerciais da Da-Jiang Innovations-DJI como o DJI Phantom com GoPro Hero 3 acoplada (Ellenberg et al., 2016), o DJI F550 (KANG; CHA, 2018), o DJI Matrice 100 (AYELE et al., 2020), o DJI Matrice 600 Pro (RIBEIRO et al., 2020; ZHU et al., 2021), o DJI Quadricóptero F450 (OH; HAM; LEE, 2021), o DJI RyzeTello (BOUZAN et al., 2021), entre outros modelos (MORGENTHAL et al., 2019; LIU et al., 2020; KUNG et al., 2021; OTTONI; NOVO; COSTA, 2022). Entretanto, devido ao custo de aquisição desses equipamentos, alguns autores propuseram modelos próprios, como drones de escalada (JIANG; ZHANG, 2020; HOSKERE et al., 2020).

Figura 20 - Exemplos dos drones utilizados



Fonte: Adaptado de: a) Kang e Cha (2018); b) Jiang e Zhang (2019); c) Ayele et al. (2020); d) Oh et al. (2021).

A maior parte dos estudos da amostra utilizou dados coletados por câmeras acopladas em drones (BIANCHI; HEBDON, 2022; YOON et al., 2022; MUNAWAR et al., 2022; DRAGANIC et al., 2022; RIBEIRO et al., 2022). No entanto, alguns dados necessitam da integração de outras tecnologias para sua identificação. Diante disso, alguns autores utilizaram imagens coletadas por drones, fotografias terrestres e varreduras a laser (VALENÇA et al., 2017). Assim como esses autores, Castagno e Atkins (2018) e Bouzan et al. (2021) utilizaram imagens georreferenciados de satélites e nuvens de pontos a partir de voos de drones equipados com aparelhos *Light Detection and Ranging*-LiDAR. Já Kim et al. (2021) utilizaram câmeras manuais de alta resolução para obter imagens com informações de profundidade e RGB⁴.

Segundo Kim e Cho (2018), para que os modelos que utilizam IA obtenham bom desempenho é necessário utilizar uma base de dados robusta para treinamento do algoritmo. No entanto, coletar uma grande base de dados não é algo trivial. Por isso, alguns autores utilizaram imagens de bancos de dados da literatura, disponibilizados na internet, devido à praticidade, quantidade e qualidade das imagens disponíveis para treinamento, visto que esses são fatores cruciais para a eficiência durante o treinamento e processamento digital (FLAH et al., 2020; GHOSH et al., 2020; LIU et al., 2020; LE et al., 2021).

3.4.2 Tecnologias digitais usadas para processamento de dados

O Quadro 2 apresenta as técnicas de visão computacional e os métodos de IA utilizado nos estudos identificados na revisão da literatura.

⁴ RGB é a sigla do sistema de cores aditivas formado pelas iniciais das cores em inglês *Red*, *Green* e *Blue*, que significa em português, respectivamente, Vermelho, Verde e Azul.

Quadro 2 - Aplicação de visão computacional e subconjuntos de IA

Técnica utilizada	Autores/trabalhos	Método ou arquitetura utilizada
Classificação	Castagno e Atkin (2018); Yeum et al. (2019); Liu et al. (2020); Flah et al. (2020); Kim et al. (2021) e Luo et al. (2021); Bouzan et al. (2021); Ottoni, Novo e Costa (2022)	ML; ML; ML; ML; Algoritmo de fusão de sensores; ML; ML; DL e DL.
Detecção	Valença et al. (2017); Kang e Cha (2018); Vetrivel et al. (2018); Dorafshan et al. (2018); Gosh et al. (2020); Jiang e Zhang (2020); Potenza et al. (2020); Ribeiro et al. (2020); Kung et al. (2021); Oh, Ham e Lee. (2021); Zhu et al. (2021); Choi et al. (2021); Wu et al. (2021); Yoon et al. (2022); Munawar et al. (2022); Liu et al. (2022); Ribeiro et al. (2022); Munawar et al. (2022); Bianchi; Hebdon (2022); Tilon et al. (2022); Draganic et al. (2022) e Oring (2022).	Algoritmo ISODATA; DL; DL; DL; DL; DL; Classical RGB Method (C-RGB) e Bounded RGB Method (B-RGB); Caixa de ferramentas de processamento de imagem baseada em métodos heurísticos de extração de recursos; DL; Sobel, Laplacian e Canny; DL; DL; DL; DL; DL; Recursos Heuréticos e DL; DL; DL; DL; Fotogrametria; DL.
Segmentação	Ellenberg et al. (2016); Hoskere et al. (2020); Ayele et al. (2020) e Bowmick et al. (2020).	ML; DL; DL; DL.

Fonte: O autor.

3.4.2.1 Técnicas de Classificação

Castagno e Atkins (2018) propuseram um método de classificação de telhados utilizando modelos baseados em CNN. Foram escolhidas as arquiteturas Resnet50, Inceptionv3 e Inception-ResNet. O Resnet foi o modelo que apresentou melhor desempenho para entrada de dados com uso do LiDAR, alcançando 83,3% de precisão, superando o Inceptionv3 que obteve 83,1%. No entanto, o estudo apenas classifica o formato do telhado e não classifica nenhuma manifestação patológica.

Alguns estudos utilizaram algoritmos de DL para a classificação de borrões em imagens embaçadas (LIU et al., 2020), classificação de regiões de interesse em estruturas de aço e concreto (YEUM et al., 2019), classificação dos tipos de fissuras (FLAH et al., 2020; KIM et al., 2021). No entanto, esses estudos classificaram apenas um tipo de anomalia. Nesse sentido, Luo et al. (2021), propuseram a classificação de quatro tipo de corrosões em superfícies metálicas. Os autores compararam o desempenho entre o algoritmo PADENet e Faster R-CNN, YOLO e SSD. O estudo demonstrou que o PADENet apresentou maior desempenho na classificação de corrosão da barra, corrosão do fixador, corrosão saliente e esfoliação, apresentando precisão de 80,78%, 92,41%, 87,81% e 88,36%, respectivamente. Por mais satisfatórios que tenham sido os resultados, os autores focaram apenas na classificação de corrosões.

Bouzan et al. (2021), utilizando redes de CNN para classificação de três manifestações patológicas. Esse estudo mostrou que, em relação a profundidade da fissura, mancha de ferrugem e as manifestações patológicas de eflorescência, o algoritmo *Random Forests* apresentou valores com aproximadamente 70% de precisão para cada anomalia detectada. Referente a manifestação patológica de armadura exposta, os algoritmos *Decision Trees* e *Random Forests* apresentaram valores de aproximadamente 50% de precisão. No entanto, o estudo analisa apenas manifestações patológicas em edificações durante a fase de uso e ocupação.

Otoni, Novo e Costa (2022), propuseram uma metodologia para ajuste de hiperparâmetros de CNN para classificação de imagens de telhados de edificações. As imagens foram classificadas em (1) telhados com calhas limpas e (2) telhados com calhas sujas. Os resultados apresentaram valores médios de precisão na validação (100 %) e etapas de teste (90 %) para arquitetura CNN com 12 camadas. Além disso, os hiperparâmetros recomendados pelo algoritmo *Hyper Tuning SK* obtiveram os melhores resultados de teste para outras duas arquiteturas da literatura: Densenet121 (85,7%) e VGG16 (84,4%). No entanto, foi apenas avaliado o nível de classificação de um item, enquanto existem outros itens em telhados que poderiam ser testados.

3.4.2.2 Técnicas de Detecção

O estudo de Vetrivel et al. (2018) utilizou algoritmos de DL para detectar regiões danificadas por terremotos, através de imagens de telhados. Foram treinados modelos supervisionados com base em recursos da CNN, combinando recursos de nuvem de pontos 3D. Essa integração produziu uma melhoria extra em termos de precisão, aumentando de 91% para 94%. No entanto, por maior que seja a contribuição desse estudo na literatura e por mais alta que seja a precisão do modelo, esse estudo não identifica nenhuma manifestação patológica.

Alguns estudos foram realizados com o objetivo de comparar os algoritmos. Dorafshan et al. (2018) comparou algoritmos de bordas comum com redes de DL para detecção de fissuras em estruturas de concreto. Com o mesmo objetivo, Oh, Ham e Lee (2021) comparam o desempenho dos algoritmos Sobel, Laplacian e Canny na detecção de contorno de fissuras. Ambos foram testados apenas para detecção de fissuras, no entanto, os estudos poderiam ter uma abordagem mais profunda, realizando além da detecção a medição da largura e comprimento dessa anomalia.

O estudo de Kung et al. (2021) utilizou um algoritmo de DL para detecção automatizada das manifestações patológicas eflorescência, fragmentação, fissuras e desfiguração. Os resultados apresentaram alta acurácia e recall, com taxas respectivas de 91% e 80% para eflorescência, 76% e 100% para fragmentação, 86% e 86% para trincas e 98% e 78% para desfiguração. No entanto, apesar dos autores terem incluídos as quatro anomalias nesse estudo, existem outras que também são consideravelmente importantes.

Outros autores utilizam algoritmos de DL para detecção de anomalias em estradas, pavimentos e pontes (ZHU et al., 2021; BIANCHI; HEBDON, 2022; TILON et al., 2022; YOON et al., 2022; MUNAWAR et al., 2022; LIU et al., (2022), em trilhos de ferrovias (WU et al., 2021), em estruturas de concreto armado (GHOSH et al., 2020; KANG; CHA, 2018; ORING, 2022; MUNAWAR et al., 2022), em vergalhões de aço (Ribeiro et al., 2020) e em pontes de concreto (VALENÇA et al., 2017; POTENZA et al., 2020). No entanto, por mais que os estudos apresentaram modelos com desempenhos satisfatórios nenhum deles dedicaram esforços na identificação automatizada de anomalias em fachadas de edifícios.

No estudo de Choi et al. (2021) foi proposto um framework para detectar trincas em estruturas de concreto. A arquitetura VGG-16 foi usada para detectar eventuais rachaduras na imagem que foi dividida em várias seções para rotular rachaduras em várias regiões da imagem. Os autores concluíram que o modelo forneceu resultados precisos para detecção de trincas, no entanto, os valores desse indicador não foram apresentados no estudo. Em relação a detecção, Jiang e Zhang (2020) também propuseram um método de detecção em tempo real de fissuras, utilizando dispositivos móveis e CNNs. A validação do método proposto foi realizada através de uma inspeção de uma edificação, em que o resultado alcançou 94,48% de precisão na detecção de fissuras. Entretanto, por melhor que tenha sido o desempenho do modelo, os autores focaram apenas em fissuras.

Assim como os autores acima, Le et al., (2021) desenvolveram um modelo de DL para a classificação de imagens com e sem fissuras, capturadas em superfícies de concreto. O modelo obteve excelente desempenho de classificação para o conjunto de dados de treinamento, nos quais a precisão, recall, especificidade, F1-score e acurácia alcançaram 99,5%, 99,8%, 99,5%, 99,7% e 99,7%, respectivamente; enquanto para o conjunto de dados de teste, a precisão, recall, especificidade, F1-score e acurácia foram 96,5%, 98,8%, 96,6%, 97,7% e 97,7%, respectivamente. No

entanto, os autores focaram apenas em trincas e se tratando de manifestações patológicas de estruturas de concreto, existem outras anomalias que requerem a mesma atenção, como por exemplo, a corrosão da armadura.

Em relação a inspeção automatizada de fachadas, os autores Draganić et al. (2022) propuseram um método baseado em ortofachada para detecção de trincas e determinação da localização e parâmetros geométricos da trinca detectada. O trabalho apresentou um esforço para a melhoria da tomada de decisão informada sobre manutenção, reparo, reforma ou outras ações durante a fase de exploração do ambiente construído. No mesmo sentido, Ribeiro et al. (2022) propuseram uma metodologia de visão computacional para a detecção de fissuras em fachadas usando drones e duas técnicas diferentes de processamento de imagens: uma baseada em recursos heurísticos e outra baseada em aprendizado profundo. Segundo os autores, os resultados foram bastante satisfatórios e promissores. No entanto, embora as inspeções de fachadas tenham apresentado resultados satisfatórios, esses estudos focaram apenas em fissuras.

3.4.2.3 Técnicas de Segmentação

A segmentação é a técnica que busca extrair característica de uma imagem (JUNIOR; BACKES, 2016). Dessa forma, na amostra analisada, alguns estudos concentraram-se na utilização de algoritmos de ML e DL para o processamento de imagens com o objetivo de extrair características como tipo de material, ruídos, fissuras e sombras de estruturas de pontes (ELLENBERG et al., 2016; AYELE et al., 2020). Outros estudos utilizaram a mesma técnica para identificar o tipo de material da estrutura, bem como rastrear os danos nessas estruturas, nesses estudos especificamente, em estruturas de aço e concreto armado (HOSKERE et al., 2020; BHOWMICK et al., 2020). No entanto, em relação às manifestações patológicas, os estudos utilizaram essa técnica apenas para identificação de fissuras.

3.5 CONSIDERAÇÕES ACERCA DO CAPÍTULO 3

A incorporação de tecnologias digitais na construção civil vem se tornando cada vez mais evidente. O uso de drones para inspeção de estruturas civis como pontes, pavimentos, telhados e fachadas vem crescendo muito devido suas diversas vantagens que vão desde a agilidade e baixo custo, até a segurança do profissional que realiza essa atividade. Além dos drones, o uso de algoritmos de inteligência

artificial, aprendizado de máquina e aprendizado profundo têm aprimorado ainda mais essas atividades.

A utilização dessas tecnologias tem possibilitado melhor aquisição e análise de dados, trazendo maior eficiência e celeridade para diversas atividades que antes eram realizadas através somente da ação humana. Tanto a inteligência artificial e seus subconjuntos quanto às técnicas de visão computacional auxiliam os gestores nas tomadas de decisão, prevendo problemas futuros através de algoritmos treinados com problemas passados. Além disso, essas técnicas vêm sendo cada vez mais aprimoradas e a detecção de problemas, como manifestações patológicas, por exemplo, é cada vez mais preciso.

Em relação ao uso dessas tecnologias para inspeções de fachadas, ambas apresentam viabilidade e diversas vantagens. Os drones podem superar dificuldades para visualizar a fachada completa, locais em altura, cobertura, entre outros pontos que não podem ser observados facilmente pela ação humana. Além disso, os drones trazem maior celeridade na aquisição de dados, são capazes de coletar dados de alta qualidade, proporcionando uma análise minuciosa dos dados coletados, além dessas vantagens, oferecem maior segurança para os inspetores.

O uso de drone em si já traz bastante celeridade para o processo de inspeção. A inclusão de algoritmos de IA para realizar a análise dessas imagens automaticamente torna ainda melhor essa atividade, principalmente quando os resultados dessa inspeção são utilizados para apoiar decisões em tempo hábil. Em relação a isso, o emprego dessas tecnologias para apoiar o controle da qualidade durante a execução de paredes de concreto moldadas in loco são fundamentais, pois muitos problemas podem ser evitados, por se tratar de um elemento construtivo que envolve várias etapas para sua realização.

Essa análise de dados por sistemas computacionais foi possível com a chegada das redes e algoritmos de Aprendizado Profundo, como as Redes Neurais Convolucionais. A partir disso, a análise de dados realizada por máquina passou a ser mais eficiente e precisa. Além disso, devido à crescente utilização na indústria da construção, esses algoritmos vêm sendo melhorados a cada ano devido a diversas aplicações práticas, como este trabalho por exemplo.

4. MÉTODO DE PESQUISA

Este capítulo apresenta o método de pesquisa utilizado para o desenvolvimento deste trabalho, incluindo a descrição da estratégia de pesquisa adotada, o delineamento do estudo e o detalhamento de cada etapa de pesquisa definida, visando alcançar o objetivo proposto.

4.1 ESTRATÉGIA DE PESQUISA

A estratégia de pesquisa adotada para o desenvolvimento deste trabalho é a *Design Science Research* (DSR), ou também conhecida como Pesquisa Construtiva (*Constructive Research*), que envolve a ação do pesquisador sobre um determinado panorama, compreendendo um problema, concebendo e validando uma possível solução (HEVNER; CHATTERJEE, 2010). Esta estratégia foi adotada por ser um método investigativo que procura desenvolver e planejar soluções para melhorar sistemas existentes, resolver problemas ou, ainda, criar novos artefatos que contribuam para melhorar a atuação humana, seja na sociedade ou nas organizações (IIVIARI; VENABLE, 2009; DRESCH; LACERDA; ANTUNES, 2015).

Os artefatos podem ser definidos como objetos artificiais que podem ser caracterizados em termos de objetivos, funções e adaptações. Assim, o cumprimento de um propósito, ou adaptação a um objetivo, envolve uma relação entre o propósito, o caráter do artefato e o ambiente em que eles funcionam. Dessa forma, um artefato pode ser considerado como uma interface entre um ambiente interno, a substância e organização do próprio artefato e um ambiente externo (SIMON, 1996).

Os artefatos podem ser apresentados através de Constructos, Modelos, Métodos e Instanciações ou Implementações (MARCH; SMITH, 1995). De acordo com Vaishnavi e Kuechler (2015) e Van Aken e Berends (2018), as etapas que compõem o ciclo para desenvolvimento de um artefato são:

- a) **Conscientização:** consiste no levantamento do estado atual do tema abordado, identificando e compreendendo a problemática abordada através da revisão da literatura;
- b) **Sugestão:** consiste no estudo exploratório prático em canteiro de obras para teste das ferramentas utilizadas e entendimento dos processos relacionados ao método apresentado, resultando na elaboração da proposta preliminar;
- c) **Desenvolvimento:** consiste na estruturação e refinamento do escopo do método proposto, a partir da implantação em estudos de caso;

- d) **Avaliação:** consiste em avaliar o método e os resultados obtidos na implementação dos estudos de casos, a partir da definição de constructos e variáveis da pesquisa;
- e) **Conclusão:** consiste na formalização do método proposto, incluindo a apresentação de sua estrutura concluída e de recomendações para sua implementação.

Na DSR, o pesquisador utiliza-se do conhecimento científico para compreender problemas práticos e prescrever uma solução apropriada para eles, atuando não somente como observador, mas também como construtor e avaliador do artefato. Além disso, a DSR pode usar todos os métodos conhecidos para coletar e analisar dados, entretanto, as estratégias de pesquisa tendem a ser baseadas em casos e estratégias colaborativas e intervencionistas. Estratégias colaborativas aprofundam a compreensão do problema e das alternativas de intervenção, enquanto as intervencionistas facilitam o entendimento da dinâmica e nos testes dos vários conceitos de solução (VAN AKEN; ROMME; 2009).

Dessa forma, este trabalho se enquadra na lógica da DSR por se tratar de um problema de fato existente e relevante na construção civil, que ocorre devido à dificuldade para realizar o controle da qualidade através de inspeção de fachadas de forma rápida, segura e confiável. Portanto, para a construção de uma solução que possa ser aplicada a esta realidade, propõe-se o uso de tecnologias digitais como drone e algoritmos de aprendizado de máquina, compondo um artefato a ser implementado e avaliado em casos reais.

Este trabalho propõe como artefato um método de inspeções automatizadas de manifestações patológicas em fachadas de paredes de concreto utilizando drones e subconjuntos de Inteligência Artificial, gerando informações em tempo hábil para apoiar os gestores no processo de controle da qualidade durante a execução. A escolha por um artefato do tipo método está relacionada ao fato deste apresentar um conjunto de passos propostos para que determinado resultado seja obtido.

4.2 DELINEAMENTO DA PESQUISA

Para construção do artefato proposto, a presente pesquisa foi realizada de acordo com as etapas apresentadas na Figura 21.

Figura 21 - Delineamento geral da pesquisa

ETAPAS	ATIVIDADES	PRODUTOS
Revisão da Literatura		
1 - Conscientização	<p>Investigação do problema teórico através de uma RSL Questões de pesquisa utilizadas para guiar a RSL:</p> <ul style="list-style-type: none"> ▪ Quais tecnologias digitais estão sendo utilizadas para a identificação automatizada de patologias em construções? ▪ Como essas tecnologias auxiliam os gestores na tomada de decisão? e, ▪ Quais as tendências futuras para o uso dessas tecnologias? <p>Investigação do problema prático em campo</p>	<p>Definição de:</p> <ul style="list-style-type: none"> ▪ Problemas de pesquisa; ▪ Questões de pesquisa; ▪ Objetivos da pesquisa; e ▪ Estratégia de pesquisa.
2 - Sugestão	<p>Estudo de Caso A</p> <ul style="list-style-type: none"> Mapeamento do sistema construtivo e levantamento dos principais problemas decorrentes Aquisição de imagens por meio de câmeras e drones com câmeras acopladas Testes com as imagens coletadas a partir do software Custom Vision 	<p>Definição de equipamentos para aquisição e processamento de dados</p> <p>Proposta preliminar do método envolvendo protocolo de aquisição de dados e protocolo de processamento de dados</p>
3 - Desenvolvimento	<p>Estudo de Caso B e C</p> <pre> graph TD A[Implementação do método preliminar nas obras] --> B[Integração dos relatórios no processo de controle de qualidade de fachadas] B --> C[Feedbacks da equipe de gestão para melhoria contínua] C --> A </pre>	<p>Método estruturado e refinado a partir das implementações em campo</p>
4 - Avaliação	<p>Definição dos constructos, variáveis e fontes de evidência</p> <p>Constructos avaliados</p> <ul style="list-style-type: none"> Transparência Eficiência Utilidade 	<p>Avaliação do desempenho do artefato e identificação de limitações</p>
5 - Conclusão	<p>Formalização do método</p> <ul style="list-style-type: none"> Considerações finais Comunicação dos resultados Publicações 	<p>Dissertação e artigos científicos</p> <p>Recomendações para utilização do método de inspeção automatizada com drones e DL.</p>

Fonte: O autor.

A revisão da literatura se estendeu durante toda a pesquisa, pois a fundamentação teórica auxilia na compreensão do problema prático e na concepção do artefato, bem como permite a reflexão sobre a contribuição para o avanço do conhecimento. Além da revisão bibliográfica, na fase de conscientização e sugestão foi realizada uma Revisão Sistemática da Literatura para identificação das lacunas de pesquisa e compreender a contribuição teórica deste trabalho. Além disso, foram realizados estudos empíricos em obras da Empresa X para identificação e

compreensão dos problemas práticos, das rotinas de execução das fachadas de paredes de concreto moldadas in loco e do processo de controle da qualidade.

O desenvolvimento e avaliação do artefato proposto neste trabalho ocorreu a partir da implementação nas obras do estudo de caso B e C. Ao final da pesquisa foram identificadas as contribuições práticas e teóricas do estudo, assim como as limitações e o impacto das recomendações propostas. A seguir será apresentado a categorização da empresa e das obras, na qual os estudos foram desenvolvidos, além da caracterização das tecnologias digitais utilizadas para aquisição e processamento de dados.

4.2.1 Caracterização geral da Empresa participante

A empresa construtora, denominada Empresa X, selecionada para realização deste estudo é uma organização de grande porte que atua no mercado brasileiro na área da construção desde 1979. Presente em mais de 150 cidades brasileiras e 22 estados, além do Distrito Federal, a empresa atua no segmento de imóveis residenciais para a classe média e média baixa, realizando atividades nas áreas de concepção do projeto, incorporação e construção.

Esta empresa foi selecionada, pois possui parceria com o Grupo de Pesquisa e Extensão em Gestão e Tecnologia das Construções- GETEC desde 2017, grupo ao qual o autor desta pesquisa faz parte. Ao longo dessa parceria foram desenvolvidas diversas pesquisas, tais como de Álvares (2019), Melo (2020), Rey (2020), Lima (2021) e Nogueira, Júnior e Costa (2022), portanto, existe interesse e comprometimento por parte da empresa para o desenvolvimento do estudo.

4.2.2 Caracterização das Obras estudadas

O estudo foi realizado em três obras da Empresa X, denominados de Obra A, B e C. Na **Obra A** (Figura 22) ocorreu a investigação do problema prático e visitas iniciais de campo nas etapas de Conscientização e Sugestão. Essa obra está localizada em Lauro de Freitas, região metropolitana de Salvador. O canteiro de obras estudado possui uma área de 7.514,84 m² e 17.757,07 m² de área construída. O empreendimento é composto por 2 torres, cada uma com 10 pavimentos. Cada andar é formado por 8 apartamentos, totalizando 160 unidades.

Figura 22 - Ilustração do empreendimento da Obra A.



Fonte: Empresa X.

Na **Obra B** (Figura 23) ocorreu o mapeamento do sistema construtivo e manifestações patológicas recorrentes, bem como a aquisição de imagens com drone e treinamento das imagens no Custom Vision, contemplando a fase de Sugestão e Desenvolvimento. Essa obra está localizada em Lauro de Freitas, região metropolitana de Salvador. O canteiro de obras estudado possui uma área de 18.758,35 m², sendo 15.121,54 m² referente à área construída. Após a conclusão, o empreendimento será composto por quatro torres, cada uma com 10 pavimentos (térreo mais nove). Cada andar é formado por 8 apartamentos, ou seja, 320 unidades.

Figura 23 - Ilustração do empreendimento da Obra B.



Fonte: Empresa X.

Na **Obra C** (Figura 24) foi realizado o estudo de campo para a aplicação e refinamento do método na etapa de Desenvolvimento. Essa obra está localizada em Salvador, o canteiro de obras possui uma área com aproximadamente 9.511,23 m²,

sendo 18.585,53m² de área construída. Após a conclusão, o empreendimento será composto por três torres, cada uma com 15 pavimentos (térreo mais 14). Cada andar é formado por oito apartamentos, totalizando 360 unidades.

Figura 24 - Ilustração do empreendimento da Obra C.



Fonte: Empresa X.

4.2.3 Caracterização das tecnologias digitais utilizadas para aquisição de dados

A tecnologia utilizada neste estudo para aquisição de dados foi o uso de drones do tipo quadricóptero, ou seja, aeronaves de asas rotativas com quatro hélices. Suas características são apresentadas no Quadro 3. Além disso, também são descritas as características das ferramentas auxiliares como celulares e aplicativos para visualização das imagens e vídeos durante os voos.

Quadro 3 - Drones utilizados no estudo

Equipamento		
Marca	DJI	DJI
Linha/ Modelo	Phantom 4	Air 2S
Tamanho Diagonal	350mm	302mm
Peso de decolagem	1.388 Kg	0.595 Kg
Autonomia máxima de voo	28 minutos	31 minutos
Velocidade máxima	72 Km/h	68.4 km/h
Câmera - resolução de foto	20 MP	20 MP
Câmera - resolução de vídeo	4K 60FPS, 1080p 120FPS	5.4K - 4K - 2.7K - Full HD
Posicionamento por Satélite	GPS/GLONASS	GPS/GLONASS/GALILEO
Armazenamento interno	-	8 GB
Armazenamento externo	Micro SD de até 128GB	Micro SD de até 256 GB

Fonte: DJI.

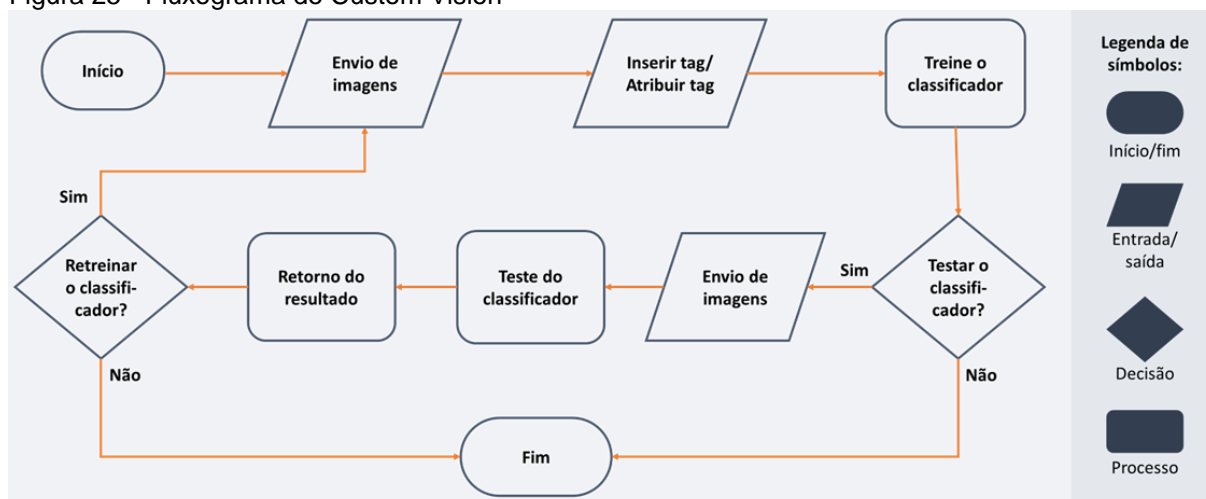
Para operação do DJI Phantom 4, foram utilizados o aplicativo DJI Go 4 e um smartphone Android Samsung Galaxy A5 para visualização das imagens durante o

voos. Em relação ao DJI Air 2S, estão sendo utilizados o aplicativo DJI FLY e um iPhone 11 Pro Max com sistema iOS para visualização das imagens. Ambos os equipamentos foram escolhidos por serem tecnologias acessíveis e comercializadas, com características que facilitam a operação em canteiros de obras.

4.2.4 Caracterização da tecnologia utilizada para processamento de dados

Neste estudo, para processamento das imagens coletadas com drone foi utilizado o serviço de visão personalizada da *Azure Cognitive Services*, chamado Microsoft Custom Vision. Esse software é uma API⁵ baseada em nuvem que nos possibilita a rápida construção e prototipagem de classificadores de imagens usando algoritmos de aprendizado de máquina para rotular conjuntos de imagens e treinar modelos (PEJČINOVIĆ, 2019; STAFFA et al., 2020). A Figura 25 apresenta um fluxograma proposto por Koehrsen (2018) de como o software funciona.

Figura 25 - Fluxograma do Custom Vision



Fonte: Adaptado de Koehrsen (2018).

A visão personalizada do Azure é um serviço de Inteligência Artificial que permite que os computadores imitem recursos do cérebro humano, como aprendizado, compreensão e reconhecimento de padrões sem precisar ser explicitamente codificado para isso, como geralmente fazemos com algoritmos. O aprendizado de máquina é um subconjunto da IA que treina um sistema de computador para fazer previsões com base nos dados disponíveis, como é o caso do Custom Vision (PETTER et al., 2023).

API é uma interface de programação de aplicativo que vem do inglês *Application Programming Interfaces*.

Além do Custom Vision ser uma API com redes de algoritmos pré-prontas, uma grande vantagem para sua utilização é a capacidade de trabalhar com um pequeno conjunto de dados (ALI; ISHAK, 2020). Além disso, Segundo Ali e Ishak (2020), outra importante consideração para selecionar os classificadores de imagem do Custom Vision é a capacidade de exportar o modelo treinado para a Plataforma Azure e outras plataformas onde ele pode ser executado (ALI; ISHAK, 2020). Como exemplo disso, Staffa et al. (2022) desenvolveram uma Plataforma web para inspeção de estruturas de telhados inclinados para fins de assistência, com uso de drones e inteligência artificial. Nessa API é possível fazer o upload de imagens coletadas por drones, onde elas são enviadas ao Custom Vision e feito o reconhecimento automatizado das não conformidades presentes nessa estrutura. Após essa análise, são gerados relatórios com os resultados das inspeções auxiliando os gestores na tomada de decisão.

Em relação ao uso do Custom Vision, após a criação de um projeto, é possível fazer o upload das imagens e rotular os objetos que deseja identificar automaticamente. Essa API é otimizada para reconhecer as principais diferenças entre as imagens, mas para tal vantagem, é necessário que o conjunto de dados tenha pelo menos 50 imagens de cada objeto rotulado. Caso essa quantidade seja inferior, provavelmente o modelo não forneça bons indicadores (AZURE, 2022). O valor dos indicadores de desempenho do Custom Vision depende da qualidade das imagens, do conjunto de dados utilizado e da variedade dos dados rotulados (PEJČINOVIĆ, 2019; AZURE, 2022).

Além de prever classes diretamente, alguns modelos de ML geram vetores de probabilidade de pertencimento a cada uma das classes para cada observação na amostra. A classe predita de cada observação é a classe que supera um parâmetro estabelecido pelo pesquisador. Esse parâmetro é denominado valor limiar, do inglês *Threshold Value*. A mudança no valor desse parâmetro aumenta ou diminui a sensibilidade no reconhecimento das classes rotuladas (STACKOVERFLOW, 2022). Neste trabalho o valor limiar estabelecido foi de 30% para todos os modelos.

Além disso, neste trabalho serão utilizados os indicadores **Precisão**, **Recall** e **mAP** para avaliar os modelos criados. Esses indicadores são exibidos automaticamente no Custom Vision e isso permite verificar o desempenho de todo o modelo, e também o desempenho de cada tag e como a tag afetou o modelo como um todo. Isso pode ser usado para alterar os conjuntos de dados para criar um modelo mais preciso (PAPADOPOULOS, GONZALEZ, 2021). Além disso, o **mAP** inclui em

seu cálculo outros subindicadores como a matriz de confusão, apresentando o desempenho geral do modelo criado no Custom Vision. Outro indicador utilizado neste estudo é o **F1 Score**, trazendo uma média entre o recall e a precisão, trazendo o equilíbrio entre os dois indicadores.

4.3 ETAPA DE CONSCIENTIZAÇÃO

A conscientização compreendeu as etapas de levantamento de informações sobre os temas envolvidos através de uma revisão da literatura, a identificação de lacunas do conhecimento por meio de uma Revisão Sistemática da Literatura e investigação e formalização do problema prático desta pesquisa.

4.3.1 Revisão da literatura

A revisão da literatura é uma atividade que está sendo desenvolvida durante toda a pesquisa. Essa atividade envolve a localização, análise, sintetização e interpretação da investigação relacionada com a área de estudo, por meio de livros, periódicos, publicações em congressos, entre outras fontes (CARDOSO; ALARCÃO; CELORICO, 2010; BENTO, 2012). A partir da revisão da literatura, sentiu-se a necessidade de realizar uma Revisão Sistemática da Literatura para identificar as lacunas de pesquisa e direcionar a contribuição teórica deste trabalho.

4.3.2 Revisão Sistemática da Literatura (RSL)

A RSL é caracterizada pela revisão de uma pergunta formulada de forma clara e objetiva que utiliza métodos sistemáticos para selecionar, identificar e analisar pesquisas (KITCHENHAM; 2004; MOHER et al., 2009). De acordo com Kitchenham (2004), a RSL tem como possíveis objetivos: (a) resumir a evidência existente relativa a uma tecnologia, (b) identificar lacunas em uma pesquisa atual para sugerir investigações mais aprofundadas, e (c) fornecer uma estrutura ou escopo para posicionar, de maneira adequada, novas atividades de pesquisa.

Dessa forma, para guiar as análises da RSL, o estudo buscou responder as seguintes questões de pesquisa: (a) “Quais tecnologias digitais estão sendo utilizadas para a identificação automatizada de manifestações patológicas em construções?”; (b) “Como essas tecnologias auxiliam os gestores na tomada de decisão?”; e (c) “Quais as tendências futuras para uso dessas tecnologias?”.

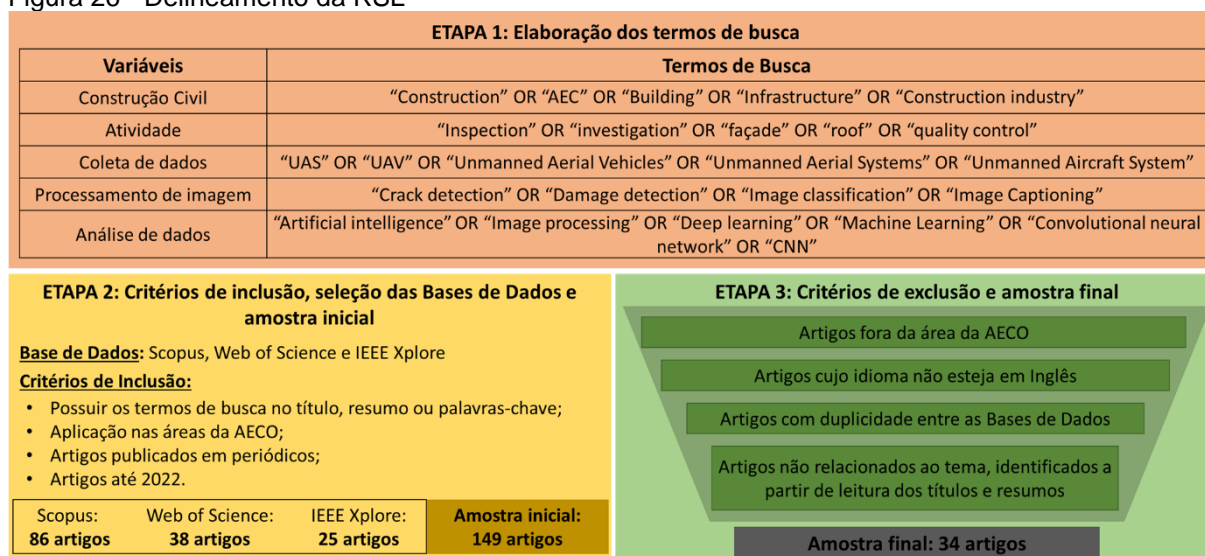
A metodologia utilizada para condução da RSL contemplou as seguintes etapas: (1) Delimitação dos termos de busca; (2) Seleção das bases de dados e definição dos critérios de inclusão; e por fim (3) Definição dos critérios de exclusão.

Etapa 1 - Delimitação dos termos de busca: como auxílio na delimitação dos termos de busca, utilizou-se a estratégia PICO, que no português esse acrônimo significa População, Intervenção, Comparação e Desfecho (DONATO; DONATO; 2019). Nessa RSL, a População é composta pelo setor da construção civil, a Intervenção considerada são as atividades realizadas para investigar e inspecionar os elementos construtivos e a Comparação são os métodos de coleta, processamento e análise de dados.

Etapa 2 - Seleção das bases de dados e critérios de inclusão: as bases selecionadas foram Scopus, IEEE Xplore e Web of Science, para a condução da RSL, seguiu-se as diretrizes PRISMA (*Preferred Reporting Items of Systematic Reviews and Meta-Analyses*) limitando as buscas com critérios de inclusão e exclusão após as buscas. O critério de inclusão estabelecido na amostra foi de que os artigos deveriam possuir algum dos termos de busca no título, resumo ou palavra-chave, suas aplicações deveriam contemplar as áreas da AECO, além das áreas de infraestrutura e edificação. Foram estabelecidos também a seleção apenas de artigos publicados em periódicos internacionais.

Etapa 3 - Critérios de exclusão: os artigos que não contemplavam o tema foram excluídos, além de artigos que não eram da subárea da Engenharia, não era escritos no idioma inglês, e outros tipos de documentos, que não eram artigos. Além disso, foram excluídos os artigos com duplicidade entre as três bases de dados. Os resultados e discussões obtidos a partir da RSL foram apresentados na Seção 3.4. A Figura 26 ilustra e resume as etapas e os procedimentos adotados nessa RSL.

Figura 26 - Delineamento da RSL



Fonte: O autor.

4.3.3 Investigação do Problema Prático

Inicialmente, foi realizada uma reunião online com aproximadamente 70 profissionais da área de qualidade da Empresa X, que levou cerca de 30 minutos para explicar o objetivo e a relevância do trabalho. Além disso, a reunião teve como intuito encorajar a equipe a responder um questionário desenvolvido para levantar as principais manifestações patológicas identificadas nas fachadas das obras desta empresa (Apêndice B).

O questionário foi elaborado através do *Google Forms* e antes de ser enviado aos profissionais da Empresa X foi realizado um pré-teste para verificação da funcionalidade. Após isso, o questionário foi enviado aos colaboradores na data de 05/11/2021, ficando disponível para resposta até 12/11/2021. As informações referentes aos participantes desse levantamento são descritas no Quadro 4.

Quadro 4 - Perfil dos entrevistados

Quantidade de entrevistados		Cargo ocupado	Local de atuação
2		Analista da qualidade e pós entrega	Centro-Oeste
			Oeste Paulista
3		Coordenador da qualidade e pós entrega	Campinas - SP
			Nordeste 1
			Belo Horizonte - MG
3		Engenheiro da qualidade e pós entrega	Ribeirão Preto – SP
Total	8 pessoas	3 cargos	6 regiões

Fonte: O autor.

Esse levantamento de dados foi realizado de forma online e uma das principais vantagens disso foi a participação de gestores da Empresa X de outras regiões do Brasil, ampliando o alcance do estudo. Inicialmente, os problemas foram descritos como “defeitos” ou “manifestações patológicas”, para que os entrevistados pudessem informar todos os problemas identificados. No questionário, foi solicitado aos profissionais que contribuíssem com imagens dos problemas informados no levantamento, buscando melhorar a compreensão do problema em questão, além da contribuição para a elaboração da base de dados inicial.

A partir desse levantamento a pesquisa se direcionou ao campo, sendo realizado um estudo para identificar e compreender o problema em questão, além de coletar imagens das manifestações patológicas para ampliar a base de dados. Nesta fase, as imagens enviadas no levantamento foram analisadas e verificado quais das manifestações patológicas fariam parte do escopo do trabalho. Diante dessa verificação, observou-se que das onze manifestações patológicas enviadas no levantamento, apenas quatro foram possíveis de ser identificadas com drone e por subconjuntos de Aprendizado de Máquina.

4.4 ETAPA DE SUGESTÃO

O Estudo de Caso A foi realizado na etapa de sugestão e ocorreu na Obra A entre março e abril de 2022 (Quadro 5). Essa etapa teve como objetivos compreender o processo construtivo de paredes de concreto moldadas in loco, identificar os principais problemas nas fachadas, mapear o processo de controle da qualidade, bem como coletar imagens para treinamentos no Custom Vision.

Quadro 5 - Visitas à obra

Etapa	N ^a da Visita e Data	Obra	Atividade realizada	Profissional da Empresa X	Duração da visita
Estudo de Caso A	1 ^a visita 17/03/2022	A	Conhecimento geral da obra	Auxiliar de Engenharia	01h 28 min
	2 ^a visita 21/03/2022	A	Acompanhamento de execução das paredes de concreto e do controle da qualidade, além de registros fotográficos	Estagiário (Controle da Qualidade)	01h 54 min
	3 ^a visita 29/03/2022	A	Voo com drone para captura de imagens	Estagiário (Controle da Qualidade)	01h 35 min
	4 ^a visita 29/04/2022	A	Voo com drone para captura de imagens	Auxiliar de Engenharia	01h 17 min

Fonte: O autor.

A seguir são descritas as principais atividades desenvolvidas neste estudo.

4.1 Mapeamento do sistema construtivo de parede de concreto, com foco na fachada e em seu controle de qualidade

Nessa atividade foram realizadas visitas na Obra A com o objetivo de conhecer a obra, bem como as características do canteiro, do processo de execução e andamento da obra. A primeira visita realizada teve o acompanhamento do Auxiliar de Engenharia (AE) que apresentou a obra e o processo de controle de qualidade na execução das paredes de concreto, foco deste estudo. Além disso, nessa visita, com a colaboração do AE, foi realizado o mapeamento do sistema construtivo de paredes de concreto moldadas in loco, que consiste nas seguintes etapas:

- a) Marcação das linhas auxiliares para montagem das formas;
- b) Armação das telas de aço entre as paredes e lajes;
- c) Montagem das formas;
- d) Concretagem;
- e) Desforma.

Além dessas etapas, durante o processo de execução o setor da qualidade inspeciona todas as atividades avaliando se a execução de cada uma delas está sendo realizada corretamente. Em alguns casos, o tratamento da fachada é realizado conforme a desforma, já em outras obras, essa atividade é realizada após a execução da fachada toda, e acontece como uma atividade antecessora a pintura.

Além do mapeamento desses processos, foi levantado os procedimentos utilizados durante a execução desse elemento. Foram coletados para análise o Procedimento de Execução de Serviço (PES) e a Ficha de Verificação de Serviço (FVS). O PES acompanha os profissionais durante todo o processo de execução. Para apoio ao processo de controle da qualidade é utilizada a FVS, verificando se as atividades ocorreram conforme constavam na PES. Por meio da FVS é possível inspecionar desde os sistemas de segurança de guarda corpo e plataforma utilizada, até montagem da forma e pós desforma, apresentando o método de verificação, a tolerância e os ambientes que foram inspecionados.

4.2 Aquisição de imagens com drone

Nessa atividade realizaram-se coletas de imagens das fachadas de parede de concreto utilizando drones. Nos locais de limitação para o uso de drones, utilizou-se aparelhos celulares. Essa atividade teve o objetivo de ampliar a base de dados, buscando o maior número possível de imagens, pois, a partir dessas imagens, serão realizados os treinamentos e testes no Custom Vision. O Quadro 6 apresenta as informações referentes aos voos com drone.


Quadro 6 - Características de voos da Obra A

Data	Piloto	Observador	Equipamento utilizado	Duração do voo (min)	Distância total percorrida (m)	Altitude máxima (m)	Número de fotos
21/03/2022	Alisson	Rafaela	DJI Phantom 4	36	636	40	177
29/03/2022	Alisson	Rafaela	DJI Phantom 4	11	477	40	113
29/04/2022	Alisson	Rafaela	DJI Phantom 4	15	518	24	68
TOTAL				01:02:00	-	-	358

Fonte: O autor.

A partir da coleta, as imagens foram analisadas manualmente e separadas de acordo com as manifestações patológicas presentes em cada imagem. Foram identificadas e classificadas quatro manifestações patológicas, sendo elas: (1) fissuras; (2) falta de remoção das faquetas; (3) armadura exposta; e (4) ninhos de concretagem (Figura 27).

Figura 27 - Manifestações patológicas identificadas com drone



Fonte: O autor.

Após essa atividade, observaram-se quais manifestações patológicas poderiam ser identificados a partir das imagens coletadas por drones e quais poderiam ser treinados no software para reconhecimento automatizado. Além disso, durante essa atividade de aquisição de imagens observou-se a necessidade da elaboração de um protocolo para aquisição de imagens que apresente as etapas e procedimentos necessários para a realização dessa atividade. Esse protocolo tem como objetivo padronizar essa atividade que se repetirá durante todos os estudos de caso.

4.3 Testes utilizando as imagens coletadas para treinamento do algoritmo

Nesta etapa foram realizados testes iniciais no Custom Vision com o objetivo de testar a ferramenta em relação as imagens já coletadas e as manifestações patológicas presentes nelas. Além disso, teve o objetivo de identificar as limitações e elaborar estratégias para superá-las nas etapas posteriores deste estudo.

Dessa forma, após as imagens terem sido coletadas e classificadas de acordo com cada manifestação patológica presente na imagem, foram realizados treinamentos dos algoritmos, avaliando o desempenho do software em relação aos dados obtidos. Esse processo contemplou os seguintes procedimentos: (1) adicionar as imagens coletadas; (2) marcar as manifestações patológicas presentes nas imagens; (3) treinar o modelo criado e, por fim; (4) testar o modelo criado com novas imagens, conforme ilustrado na Figura 28.

Figura 28 - Etapas de utilização do Custom Vision



Fonte: O autor.

Na etapa de adicionar imagens, é realizado o upload dos dados adquiridos em campo, respeitando o tamanho máximo de 3MB, sendo um requisito do próprio sistema. Após o upload das imagens, utilizando o recurso detector de objetos, no qual as classes são rotuladas pelo usuário para em seguida treinar o algoritmo. Assim que é realizada a marcação das manifestações patológicas nas imagens, o software possibilita o treinamento do modelo criado, onde é executado um processo chamado *k-fold cross validation* determinando a precisão do algoritmo.

Além da apresentação do desempenho geral do modelo criado, o software apresenta o desempenho de cada item treinado, no nosso caso, de cada manifestação patológica treinada, possibilitando a identificação de qual item necessita de mais dados de entrada para treinamento. Quando o número de imagens enviadas é inferior a 50 imagens o software indica a necessidade do envio de mais imagens, para aumentar o desempenho do modelo.

Dessa forma, foram criados dois modelos no Custom Vision. O primeiro modelo utilizou 97 imagens coletadas em campo durante as primeiras visitas. Já o segundo modelo treinado acrescentou ao primeiro modelo imagens de uma base de dados fornecida por um professor do Departamento de Construção e Estruturas da Escola Politécnica da Universidade Federal da Bahia⁶ (Figura 29).

Figura 29 - Exemplo de imagens com manifestações patológicas compartilhadas



Armadura exposta

Fissuras

Ninhos de concretagem

Fonte: Professor Dr. Francisco Gabriel.

A utilização das imagens de outra base de dados ocorreu devido a necessidade de um número maior de imagens com as manifestações patológicas foco deste estudo. Diante disso, foram realizadas duas interações, ou seja, foram criados dois modelos com quantidades diferentes de imagens, observando o desempenho de cada um deles (Quadro 7).

Quadro 7 - Treinamento no Custom Vision

Modelo/ Interação	Tempo de treinamento (h)	Número de fotos por manifestação patológicas				TOTAL
		Falta de remoção de faquetas	Armadura Exposta	Fissuras	Ninhos de Concretagem	
M1	4h	45	22	15	15	97
M2	4h	45	88	46	19	198
TOTAL	8h	90	110	61	34	295

Fonte: O autor.

A partir dessas atividades, assim como na etapa de aquisição de imagens, identificou-se a necessidade de elaborar um protocolo para processamento das imagens que apresente as etapas e procedimentos necessários para realização dessa atividade no Custom Vision. Este protocolo tem o objetivo de padronizar as atividades de processamento de imagens, que foram implementados e testados nos estudos de caso na etapa de desenvolvimento.

⁶ Professor Dr. Francisco Gabriel Santos Silva

4.5 ETAPA DE DESENVOLVIMENTO DO ARTEFATO

Esta etapa da pesquisa envolveu a estruturação e refinamento do escopo do método proposto, a partir de sua implementação nos Estudos de Caso B e C. Inicialmente, para desenvolvimento desta etapa, as implementações tiveram como principal referência a proposta preliminar do método, idealizada a partir da etapa de sugestão do artefato com suporte do Estudo de Caso A.

Dessa forma, foram realizados dois estudos de caso, sendo um na Obra B, com o objetivo de implementar o método proposto e identificar oportunidades de melhorias, para então fazer adaptações no método, com as melhorias propostas, aplicando-o na Obra C. Na obra C o método proposto foi refinado a partir das implementações anteriores.

4.5.1 Estudo de Caso B

O estudo de Caso B foi realizado na Obra B em três fases sendo, aquisição de imagens com drone, processamento das imagens coletadas e implementação das informações em obra em dois ciclos. As informações sobre as visitas realizadas nessa fase estão descritas no Quadro 8.

Quadro 8 - Visitas à obra B

Etapa	Nª da Visita e Data	Obra	Atividade realizada	Profissional da Empresa X	Duração da visita	
1º Ciclo de Implementação	Estudo de Caso B	1ª visita 02/06/2022	B	Conhecimento geral da obra;	Auxiliar de Engenharia	01h 30 min
		2ª visita 10/06/2022	B	Acompanhamento de execução das paredes de concreto e do controle da qualidade, além de registros fotográficos;	Auxiliar Administrativo	2h
		3ª visita 17/06/2022	B	Voo com drone para captura de imagens;	Auxiliar Administrativo	1h 45 min
		4ª visita 05/08/2022	B	Voo com drone para captura de imagens;	Auxiliar Administrativo	1h
		5ª visita 12/08/2022	B	Voo com drone para captura de imagens, elaboração de relatório e reunião breve com o setor de Engenharia;	Engenheiro Civil	02h 15 min
2º Ciclo de Implementação	Estudo de Caso B	6ª visita 26/08/2022	B	Voo com drone para captura de imagens, elaboração e envio de relatório;	Engenheiro Civil	2h 08 min
		7ª visita 27/10/2022	B	Discussão sobre o relatório enviado e voo com drone para aquisição de imagens;	Engenheiro Civil	2h 29 min
		8ª visita 16/12/2022	B	Voo com drone para captura de imagens, elaboração e envio de relatório;	Auxiliar de Engenharia	2h 07 min
		9ª visita 12/01/2023	B	Entrevista com o gestor A	Engenheiro Civil	1h 45 min

Etapa	Nº da Visita e Data	Obra	Atividade realizada	Profissional da Empresa X	Duração da visita
	10ª visita 16/01/2023	B	Entrevista com o gestor B	Engenheiro Civil	50 min

Fonte: O autor.

O primeiro ciclo de implementação ocorreu durante cinco visitas, entre junho e agosto de 2022, compreendendo em atividades semelhantes ao Estudo de Caso A. Esse ciclo teve como objetivo conhecer a obra, acompanhar o processo de execução e coletar imagens de manifestações patológicas para treinamento dos algoritmos no Custom Vision. Além disso, durante esse ciclo foram implementados e testados os protocolos elaborados na etapa de sugestão, observando os pontos de melhorias a serem aprimorados no próximo ciclo de implementação.

Aquisição de imagens com drone

Essa atividade foi realizada utilizando o protocolo de aquisição de dados proposto na etapa anterior. Durante essa atividade realizou-se coletas de imagens das fachadas de parede de concreto utilizando drones. Essa atividade teve o objetivo de ampliar a base de dados, buscando imagens que continham manifestações patológicas, pois, a partir dessas imagens, foram realizados os treinamentos no Custom Vision. Além disso, nessa atividade, as imagens coletadas foram analisadas de forma manual e proposto o primeiro esboço da implementação das informações no processo de qualidade da obra. As informações referentes aos voos com drone dessa atividade são apresentadas no Quadro 9.

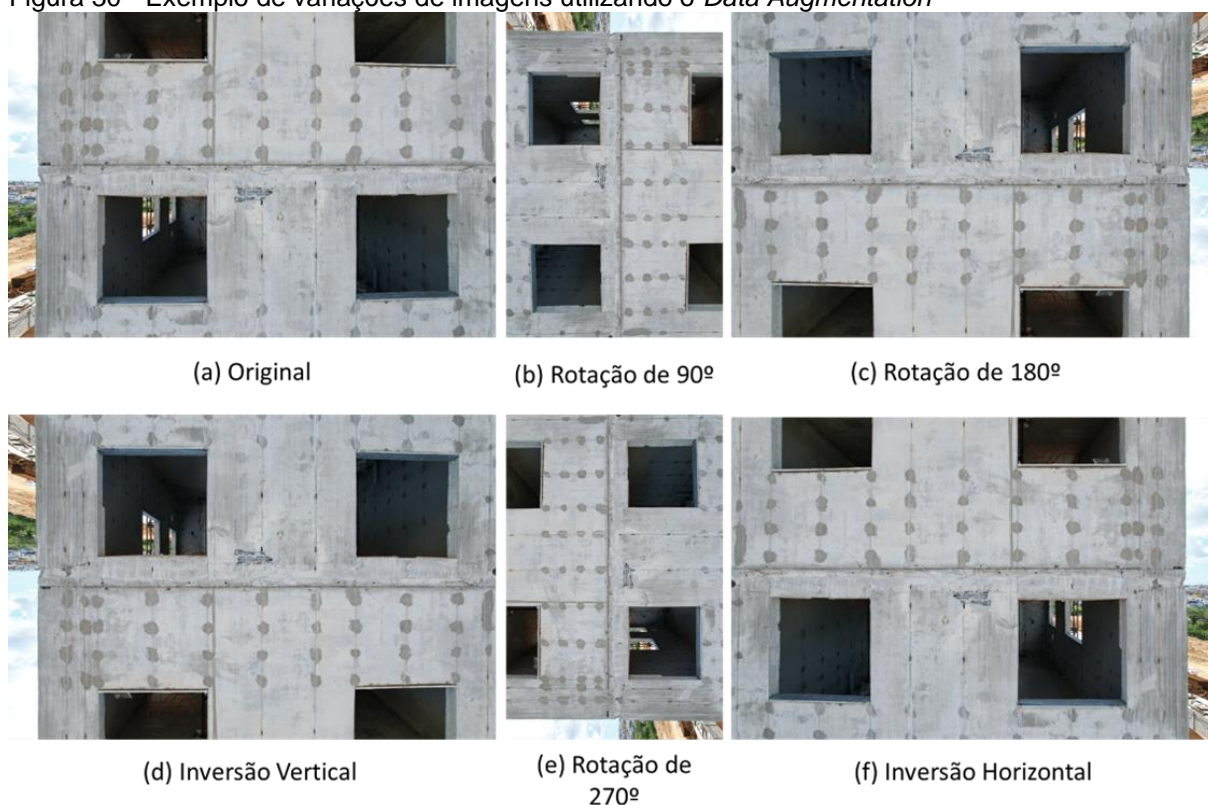
Quadro 9 - Características de voos da Obra B

Data	Piloto	Observador	Equipamento utilizado	Duração do voo (min)	Distância total percorrida (m)	Altitude máxima (m)	Número de fotos
02/06/2022	Alisson	Roseneia	-	-	-	-	-
10/06/2022	Alisson	Roseneia	DJI Phantom 4	36	1136	106	182
05/08/2022	Alisson	Roseneia	DJI Phantom 4	42	1315	107	333
12/08/2022	Alisson	Roseneia	DJI Phantom 4	43	1531	53	54
26/08/2022	Alisson	Roseneia	DJI Air 2S	48	1772	29	268
27/10/2022	Alisson	Leonardo	DJI Air 2S	44	1736	45	128
16/12/2022	Alisson	Leonardo	DJI Air 2S	23	1086	39	191
TOTAL				04:33:00			1156

Fonte: O autor.

Durante a aquisição de dados, foram coletadas imagens que ampliaram a base de dados, no entanto, as imagens que continham as manifestações patológicas foram consideradas insuficientes para o treinamento dos algoritmos. Diante dessa necessidade, foi adotado uma técnica, também usada no estudo de Staffa et al. (2020), chamada *Data Augmentation*, que possibilita a criação de imagens orgânicas a partir das imagens naturais. Essa técnica possibilitou a criação de cinco imagens a partir de uma imagem original, conforme mostrado na Figura 30.

Figura 30 - Exemplo de variações de imagens utilizando o *Data Augmentation*



Fonte: O autor.

A adoção dessa técnica contou com o apoio de um aluno de Iniciação Científica⁷ que desenvolveu um sistema utilizando códigos de linguagens em *Phyton* para a multiplicação automática da base de dados existente. A técnica desenvolvida foi capaz de gerar cinco novas imagens a partir de modificações como rotação de 90°, 180°, 270° e inversão vertical e horizontal. Essa atividade possibilitou grande avanço em relação ao aumento de dados para treinamento dos algoritmos, uma vez que as imagens com manifestações patológicas coletadas em campo eram poucas.

Em relação ao protocolo de aquisição de imagens com drone, inicialmente, foi testado no primeiro ciclo de implementação da Obra B e após sua implementação,

⁷Leonardo Gonçalves Gonzaga (Engenharia de Controle e Automação).

notou-se que os objetivos de tornar essa atividade mais célere e prática foram alcançados. Embora os protocolos tenham apresentado boa utilidade, eles foram aprimorados e refinados durante sua implementação nos estudos de caso, com isso eles foram validados compondo o método proposto.

Processamento de imagens

Nessa atividade foi criado um terceiro modelo no Custom Vision. Esse modelo contou com as imagens utilizadas no Modelo 1 e 2. Além da soma das imagens dos dois modelos foi empregado a técnica de aumento de dados chamada *Data Augmentation*. Essa técnica utiliza uma foto natural para criar fotos orgânicas a partir de várias foi realizada a partir de modificações em imagens originais. As informações deste modelo são apresentadas no Quadro 10.

Quadro 10 - Treinamento no Custom Vision

Modelo/ Interação	Tempo de treinamento (h)	Número de fotos por manifestação patológicas				TOTAL
		Falta de remoção de faquetas	Armadura Exposta	Fissuras	Ninhos de Concretagem	
M3	4	280	350	220	75	965

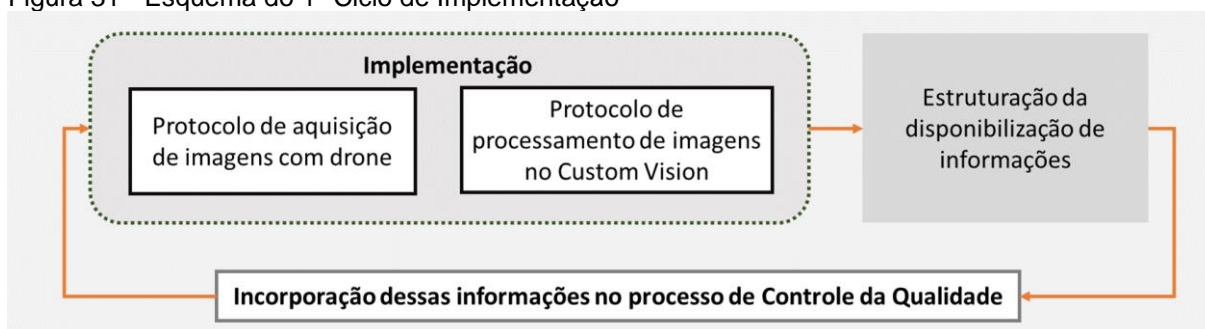
Fonte: O autor.

O protocolo de processamento de dados foi útil para a realização desta atividade pois apresentou quais as etapas necessárias para realizar o treinamento dos algoritmos no Custom Vision. O passo a passo fez com que não faltasse nenhuma informação, além de padronizar essa atividade.

Implementação das informações

Além de avaliar a implementação dos protocolos, durante essa fase foi pensado na estruturação da disponibilização das informações oriundas das visitas. A partir dessa estrutura foi analisado como seria a incorporação dessas informações no processo de Controle de Qualidade (Figura 31), seja em forma de relatórios, do envio de imagens e reuniões para discussão.

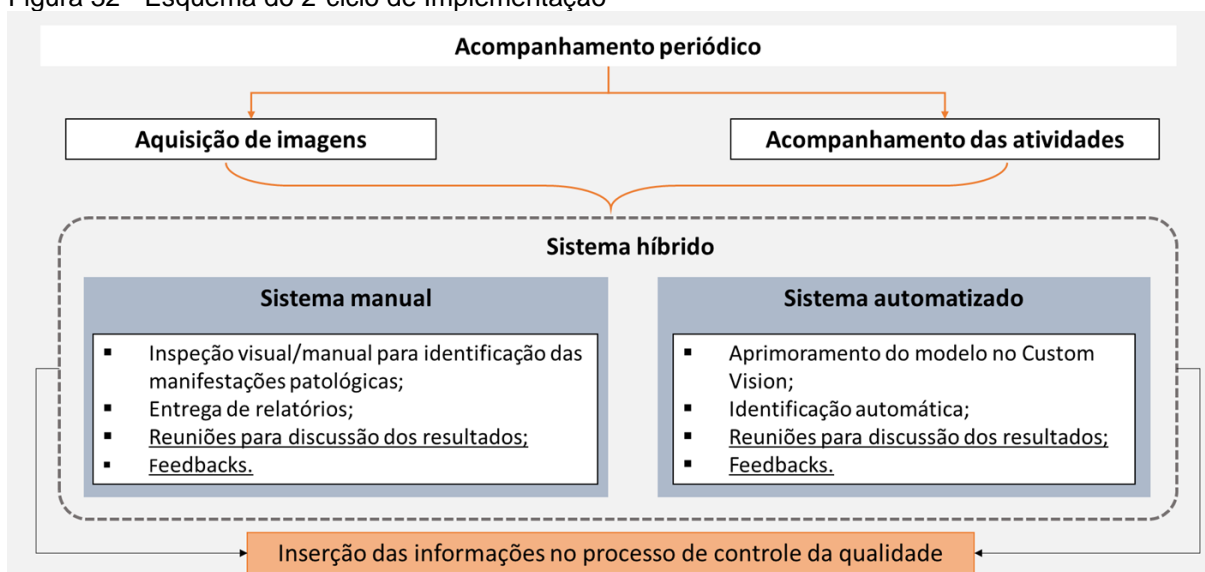
Figura 31 - Esquema do 1º Ciclo de Implementação



Fonte: O autor.

No segundo ciclo de implementação, além das visitas para aquisição de dados, foi proposto o envio de relatórios sobre as manifestações patológicas identificadas durante as inspeções para a equipe de gestão. Mesmo a análise das imagens sendo de forma manual, o objetivo do relatório foi dar *feedbacks* para a equipe de gestão da obra sobre as manifestações patológicas identificadas. O relatório proposto nessa fase é resultado de um sistema híbrido, em que a coleta de imagens é realizada com drones e análise das imagens e elaboração do relatório manualmente (Figura 32).

Figura 32 - Esquema do 2º ciclo de Implementação



Fonte: O autor.

Durante o segundo ciclo de implementação foi realizada uma breve reunião com um dos Engenheiros responsáveis pela Obra B, em que foi discutido sobre o ciclo de envio do relatório e reunião para *feedbacks* sobre as ações tomadas a partir das informações geradas nas inspeções. Após essa reunião, o relatório proposto no 2º ciclo dessa obra sofreu intervenções para as inspeções acontecerem ao final da execução de cada torre, ao invés de semanalmente, já que as intervenções corretivas eram realizadas após a conclusão da estrutura. Isso acontece a depender da dinâmica

adotada na obra. Em alguns casos, o engenheiro pode optar por fazer esse tratamento por pavimento, enquanto a plataforma de trabalho ainda está montada.

4.5.2 Estudo de Caso C

O Estudo de Caso C ocorreu de novembro de 2022 a janeiro de 2023 e aconteceu de maneira semelhante ao Estudo de Caso B. Inicialmente foi realizada uma visita para conhecer a obra e o processo de execução das paredes de concreto, bem como coletar informações iniciais. A proposta para esse estudo foi a realização de visitas quinzenais, com envio dos relatórios assim que fosse realizado a inspeção, pois o tratamento das fachadas, nesta obra, era realizado após a desforma, antes da subida da plataforma de trabalho para o próximo pavimento. As atividades propostas para esse estudo de caso são apresentadas no Quadro 11.

Quadro 11 - Visitas à obra C

Etapa	Nª da Visita e Data	Obra	Atividade realizada	Profissional da Empresa X	Duração da visita	
Implementação	Estudo de Caso C	1ª visita 17/11/2022	C	Conhecimento geral da obra, apresentação do projeto e registros fotográficos internos e voo com drone na fachada;	Auxiliar de Engenharia e Engenheiros Civis	02h 00 min
		2ª visita 30/11/2022	C	Voo com drone para captura de imagens;	Auxiliar de Engenharia	1h 45 min
		3ª visita 19/12/2022	C	Voo com drone para captura de imagens;	Estagiária de Engenharia	1h 38 min
		4ª visita 20/01/2023	C	Entrevista e voo com drone para captura de imagens;	Estagiária de Engenharia	3h 10 min
		5ª visita 27/01/2023	C	Reunião com os gestores para discussão dos resultados.	Equipe de gestão e estagiários	2h 40 min

Fonte: O autor.


A primeira visita foi realizada com apoio de um Auxiliar de Engenharia que apresentou a obra, a sequência produtiva e apontado quais eram os problemas recorrentes, nas fachadas de paredes de concreto. Sendo assim, buscando ampliar a base de dados para treinamento dos algoritmos foi realizado, nessa visita, um levantamento fotográfico na parte interna da torre. Esse levantamento aconteceu, pois foram identificadas algumas anomalias pós desforma e as imagens coletadas internamente contribuiriam para os treinamentos no Custom Vision.

Aquisição de dados com drone

Nessa atividade o protocolo de aquisição passou por um refinamento no sentido de que as fotos fossem coletadas com uma cobertura visual de dois pavimentos,

conforme é mostrado na Figura 33a. Além disso, durante a aquisição de imagens, foram feitas imagens de outro ângulo das laterais de cada fachada da torre. Isso aconteceu com o objetivo de visualizar a fachada de outro ângulo, aumentando a possibilidade de identificar as manifestações patológicas, como o caso da falta de remoção das faquetas (Figura 33b).

Figura 33 - a) Cobertura do voo; b) Foto tirada de outro ângulo



Fonte: O autor.

Esse aperfeiçoamento ocorreu, pois, fazendo apenas fotos da frente da fachada, as marcas das faquetas poderiam ser facilmente confundidas com os vazios que ficam na parede após a sua remoção. A Figura 34 apresenta um mosaico, unindo as fotos coletadas durante a inspeção.

Figura 34 - Mosaico das imagens coletadas



Fonte: O autor.

Após a inspeção das fachadas, as imagens eram descarregadas em um computador e, posteriormente, eram enviadas para uma pasta na nuvem. Esse compartilhamento fazia com que as imagens fossem acessadas pela equipe da obra. As informações referentes aos voos realizados nesse estudo de caso estão descritas no Quadro 12.

Quadro 12 - Características de voos da Obra C

Data	Piloto	Observador	Equipamento utilizado	Duração do voo (min)	Distância total percorrida (m)	Altitude máxima (m)	Número de fotos
17/11/2022	Alisson	Rose	DJI Air 2S	47	1253	110	162
30/11/2022	Alisson	Leonardo	DJI Air 2S	26	923	29	186
19/12/2022	Alisson	Leonardo	DJI Air 2S	24	862	37	88
20/01/2023	Alisson	Leonardo	DJI Air 2S	39	1493	38	133
TOTAL				2h e 16min			569

Fonte: O autor.

Além das imagens coletadas nesse estudo serem disponibilizadas para a equipe da obra, elas foram analisadas de forma manual e separadas para criação de novos modelos no Custom Vision. Já que o Custom Vision aceita imagens com até 3MB, as imagens coletadas pelo drones tiveram seu tamanho redimensionado, ou seja, imagens com aproximadamente 6MB foram reduzidas para 3MB, a partir do editor de fotos online iLoveIMG. Esses novos modelos foram criados com características diferentes aos modelos anteriores e a partir disto, avaliar qual modelo teria melhor desempenho em relação aos indicadores.

Processamento de imagens

Nessa atividade foram criados seis modelos no Custom Vision. O primeiro modelo, chamado de M4 contempla as imagens de todas as obras visitadas desde o início desta pesquisa (Estudo de Caso A, B e C). O segundo modelo recebeu o nome de M5 e foi dividido em quatro submodelos sendo, o M5a composto apenas com imagens de armadura exposta, o M5b apenas com imagens de fissuras, o M5c apenas com imagens de falta de remoção das faquetas e, por fim, o M5d contendo apenas imagens com ninhos de concretagem. O último modelo, chamado de M6, foi criado utilizando as imagens do M4 multiplicadas com a técnica do *Data Augmentation*. As informações referentes aos modelos criados nessa fase são apresentadas no Quadro 13.

Quadro 13 - Treinamento no Custom Vision

Modelo/ Interação	Tempo de treinamento (h)	Número de fotos por manifestação patológicas				
		Falta de remoção de faquetas	Armadura Exposta	Fissuras	Ninhos de Concretagem	TOTAL
M4	4	194	139	84	303	720
M5a	4	-	139	-	-	139
M5b	4	-	-	84	-	84
M5c	4	194	-	-	-	194
M5d	4	-	-	-	303	303
M6	4	834	504	1164	1818	4320

Fonte: O autor.

Além do treinamento, para uma avaliação mais minuciosa dos modelos, foi realizado o teste em todos os modelos. Devido à baixa quantidade de imagens não foi estabelecido uma proporção de imagens conforme alguns estudos da literatura que utilizaram como 90/10, 80/20 ou 70/30, por exemplo. Nesses testes utilizamos 10 imagens para testar cada manifestação patológica rotulada.

Implementação em obra

Neste estudo de caso, a implementação das informações aconteceu de maneira diferente ao Estudo de Caso B. Isso porque a dinâmica adotada nessa obra difere da obra anterior. Como o tratamento da fachada acontece ainda quando a plataforma de trabalho está retirando as formas, o recebimento de informações sobre a situação da fachada auxiliaria os profissionais no tratamento necessário para cada fachada do edifício.

Diante disso, como as inspeções aconteceram com a periodicidade de quinze dias, foram enviados relatórios a cada inspeção realizada, indicando quais manifestações patológicas foram encontradas, sua localização e a quantidade. Essas informações foram enviadas a equipe de gestão da obra, bem como para a equipe de controle de qualidade. Além do relatório, foram enviadas as imagens com a mesma qualidade que foram coletadas em campo, além de um plano de ação no final do relatório (Figura 35).

Figura 35 - Esquema de implementação das informações



Fonte: O autor.

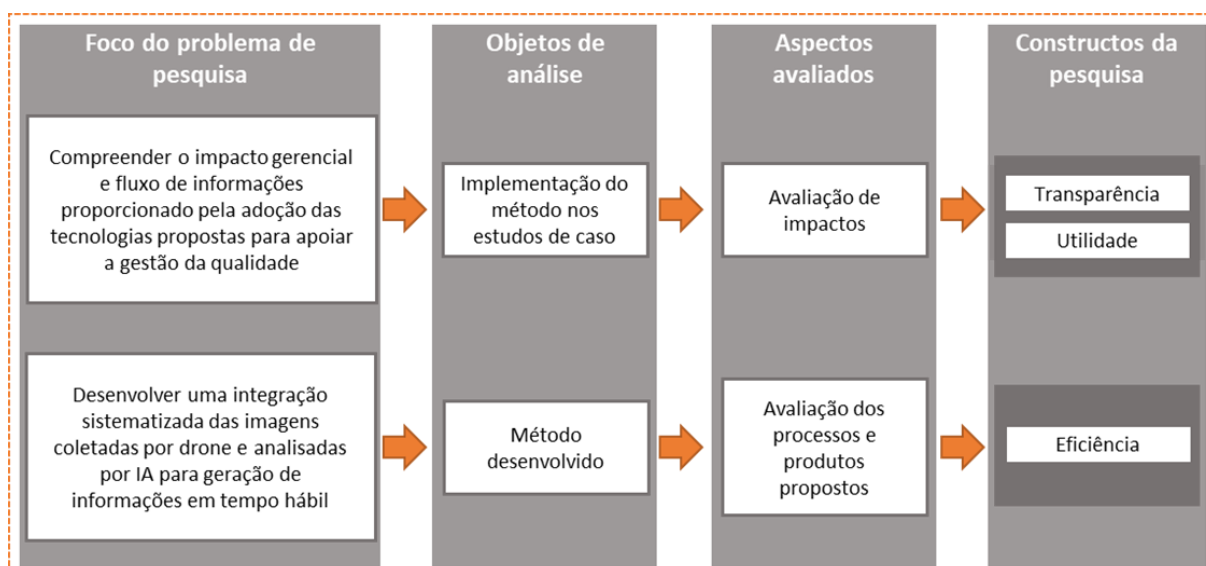
4.6 ETAPA DE AVALIAÇÃO DO ARTEFATO

Esta etapa tem por objetivo determinar o progresso alcançado através do desenvolvimento e implementação de um artefato relacionado ao problema identificado e os objetivos propostos no projeto (MARCH; SMITH, 1995). Para identificar sistematicamente o progresso alcançado, as avaliações devem ser guiadas por critérios de avaliação (SONNENBERG; VOM BROCKE, 2012), ou seja, por constructos, que são entendidos como uma assertiva genérica do conceito em relação ao mundo real, baseado em variáveis (MARTINS; PELISSÁRIO, 2005).

Para a definição dos constructos deste trabalho, levaram-se em consideração os dois focos principais do problema de pesquisa definido como: “compreender o impacto gerencial e como será o fluxo de informações proporcionado pela adoção das tecnologias digitais” e “desenvolver uma integração sistematizada entre as tecnologias digitais de coleta e processamento de dados, visando à geração de informações em tempo hábil para apoio ao sistema de gestão da qualidade”.

Dessa maneira, foram definidos constructos relacionados a dois principais objetos de análise: (1) a implementação do artefato nos estudos de caso (resultados obtidos a partir da implementação do método), e (2) o artefato desenvolvido, ou seja, o método proposto. A Figura 36 apresenta o fluxo da estrutura analítica simplificada, em que são ilustradas as principais conexões entre os focos do problema de pesquisa, objetos de análise, aspectos avaliados no estudo e constructos de pesquisa definidos.

Figura 36 - Estrutura analítica simplificada da pesquisa



Fonte: O autor.

A estrutura analítica completa do trabalho inclui também variáveis de pesquisa e fontes de evidências de dados, associadas a cada um dos constructos. As variáveis foram definidas com base na revisão da literatura, nos dados coletados e nos resultados preliminares obtidos na pesquisa. Diante disso, os conceitos dos constructos selecionados para este estudo foram:

- **Transparência:** associa-se à capacidade de um processo de produção (ou de suas partes) em se comunicar com as pessoas, tornando os principais fluxos e informações visíveis e compreensíveis, por meios físicos e organizacionais, medições e exibição visual e clara de informações (KOSKELA, 1992; FORMOSO; SANTOS; POWELL, 2002). Neste trabalho, a transparência será avaliada a partir das variáveis: contribuição para o compartilhamento de informações entre as equipes de produção e de qualidade e facilidade de entendimento das informações.

- **Eficiência:** esse constructo refere-se à agilidade na geração de informações sobre as inspeções automatizadas e a celeridade que essas informações chegam até os gestores. Além disso, esse constructo refere-se ao desempenho que o modelo criado no software de inteligência artificial alcança ao identificar automaticamente as manifestações patológicas treinadas. Dessa forma, neste trabalho, serão avaliadas as variáveis: celeridade na geração de informações e os indicadores **Precisão**, **Recall** e **mAP**.

- **Utilidade:** visa avaliar se a solução proposta funciona ou proporciona alguma melhoria (MARCH; SMITH, 1995). O constructo “utilidade” está relacionado à contribuição do método proposto para uma gestão da informação na assistência

técnica eficaz, de modo que o artefato desenvolvido consiga colaborar com coleta de dados mais estruturada e com as tomadas de decisões dos diferentes agentes, visando a melhoria de novos projetos e processos de produção (BAZZAN, 2019). Neste trabalho, a utilidade será avaliada com base nas variáveis: contribuições para o planejamento das ações corretivas e preventivas, das contribuições para a melhoria do controle da qualidade e do auxílio na tomada de decisão.

O Quadro 14 apresenta os componentes da estrutura analítica completa, incluindo os constructos, variáveis e fontes de evidência. Além disso, para avaliar os constructos e variáveis propostos nesta pesquisa foram utilizadas múltiplas fontes de evidência, avaliadas de acordo com cada etapa do método, ou seja, **aquisição**, **processamento** e **implementação** dos dados em obra. Em relação às fontes de evidência, estas estão classificadas como entrevistas com a equipe da obra, análise documental por meio de relatórios e os planos de ação enviados para a equipe de gestão, além de indicadores de desempenho fornecidos pelo Custom Vision. Além dessas fontes de evidência será analisada a observação direta e participante.

Quadro 14 - Constructos, variáveis e fontes de evidência para avaliação

Constructo	Variáveis	Etapas do método	Fontes de evidência					
			Entrevistas	Análise Documental			Observação	
			Equipe da obra	Relatórios	Plano de ação	Desempenho do Software	Direta	Participante
Transparência	Contribuição para o compartilhamento de informações entre as equipes de qualidade e tratamento das não conformidades;	Aquisição e Implementação	X		X			X
	Facilidade de entendimento das informações;	Implementação	X		X			X
	Clareza dos resultados gerados a partir da análise dos dados;	Implementação	X		X			X
Eficiência	Celeridade na geração de informações;	Aquisição e Processamento					X	
	Precisão: Indica qual a probabilidade do modelo predizer corretamente uma nova imagem;	Processamento				X	X	
	Recall: Indica a capacidade de lembrança do modelo em classificar corretamente as imagens que foram utilizadas no treinamento dele;	Processamento				X	X	
	mAP (Precisão média): indica o desempenho geral do detector de objetos em todas as classes;	Processamento				X	X	
Utilidade	Contribuição para o planejamento das ações corretivas;	Aquisição e Implementação	X	X	X			X
	Contribuições para o planejamento das ações preventivas;	Implementação	X	X	X			X
	Contribuições para a melhoria do controle da qualidade.	Aquisição e Implementação	X	X	X			X

Fonte: O autor.

A avaliação do artefato ocorreu em dois momentos. O primeiro foi em relação ao constructo Eficiência. Este foi realizado após a geração de cada modelo no Custom Vision, ou seja, a cada modelo criado foram gerados as métricas Precisão, Recall e mAP. Em relação às demais avaliações do artefato, foram realizadas entrevistas para avaliação dos constructos Transparência e Utilidade ao final de cada estudo. Todas as entrevistas ocorreram no mês de janeiro de 2023 envolvendo a equipe de gestão da obra e a equipe que realizava o controle da qualidade.

O Quadro 15 apresenta a caracterização dos entrevistados e das entrevistas realizadas com a equipe de gestão e de controle de qualidade da obra. Estas entrevistas foram orientadas por um questionário composto por 3 questões fechadas e 15 abertas (Apêndice D).

Quadro 15 - Entrevistas.

Participante	Cód.	Tempo de experiência na construção civil	Tempo de experiência no cargo atual	Data	Duração da entrevista
Engenheiro Civil (Produção)	ECP1	9 anos	4 anos	12/01/23	1h 05 min
Engenheiro Civil (Analista)	ECA1	6 anos	7 meses	16/01/23	33 min
Estagiária de Engenharia Civil (Controle da Qualidade)	EEC	3 anos	8 meses	20/01/23	38 min
Engenheiro Civil (Produção)	ECP2	7 anos	1 ano e 5 meses	01/02/23	48 min
Engenheiro Civil (Analista)	ECA2	12 anos	4 anos	01/02/23	48 min

Fonte: O autor.

Além das entrevistas ao final de cada estudo, foi realizado um workshop com a equipe geral da Empresa X, apresentando os resultados da pesquisa e o método proposto. A partir disso, realizou-se uma discussão acerca do assunto apresentado sobre a necessidade e utilidade para implementação do método, com isso, obtendo a percepção dos profissionais. A caracterização dos profissionais participantes do workshop está descrita no Quadro 16. Os protocolos de entrevistas utilizados nessa etapa são apresentados no Apêndice D e Apêndice E.

Quadro 16 - Caracterização dos participantes do workshop

Participante	Cód.	Tempo de experiência na construção civil	Tempo de experiência no cargo atual	Data da reunião
Gestor de Produção	GP	18 anos	2 anos	27/01/23
Auxiliar de Engenharia Civil	AEC1	4 anos	3 anos	
Auxiliar de Engenharia Civil	AEC2	3 anos	2 anos	
Auxiliar de Engenharia Civil	AEC3	9 anos	5 anos	
Eng. de Segurança do Trabalho	EST	16 anos	6 anos	
Téc. em Segurança do Trabalho	TST1	8 anos	7 anos	
Téc. em Segurança do Trabalho	TST2	20 anos	1 ano e 4 meses	

Fonte: O autor.

4.7 ETAPA DE CONCLUSÃO DO ARTEFATO

A última etapa desta pesquisa contempla a formalização da estrutura final do método proposto (artefato de pesquisa), definida após as implementações, avaliações e refinamentos durante os três estudos de caso, bem como desenvolvimento de um conjunto de recomendações para sua implementação. Essas recomendações visam orientar a adoção e implementação do método em contextos reais, buscando a integração efetiva de suas atividades e produtos às práticas de controle da qualidade na execução de fachadas de paredes de concreto moldadas in loco. Além disso, as recomendações foram criadas com o intuito de possibilitar o aproveitamento dos potenciais oferecidos pelo método, em relação a geração de informações em tempo hábil.

5. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Neste capítulo são apresentados e discutidos os resultados do presente estudo. O capítulo está dividido em cinco seções, que incluem: (1) os resultados das etapas de Conscientização e Sugestão, apresentando os resultados do Estudo de Caso A; (2) os resultados da etapa de Desenvolvimento, incluindo os resultados dos Estudos de Caso B e C; (3) os resultados da etapa de avaliação, com base nos constructos, variáveis e fontes de evidências; (4) a discussão dos resultados em relação à literatura e, por fim, (5) a estrutura final do método e as recomendações para sua implementação.


5.1 RESULTADOS DAS FASES DE CONSCIENTIZAÇÃO E SUGESTÃO

Esta seção apresenta os resultados do levantamento e do Estudo de Caso A realizado na Empresa X. Essas atividades foram realizadas para identificação do problema prático, colaborando para a compreensão do problema de pesquisa, das características e especificidades do objeto de estudo.

5.1.1 Levantamento inicial de dados realizado com membros da Empresa X

O levantamento de dados contou com a participação de oito entrevistados da Empresa X, de várias regiões do Brasil, que contribuíram para o direcionamento inicial da pesquisa. Os principais problemas levantados foram: (1) armadura exposta; (2) fissura; (3) falta de remoção das faquetas; (4) falha na calafetação das esquadrias; (5) junta fria; (6) alinhamento entre pavimentos; (7) ondulações; (8) falha a aplicação da textura e pintura final; (9) umidade e infiltração; (10) ninhos de concretagem; e (11) manchas e mudança na tonalidade da fachada. Além disso, cada entrevistado indicou quais manifestações patológicas eram recorrentes nas obras que ambos atuavam (Figura 37).

Figura 37 - Resultado o levantamento



Fonte: O autor.

A partir dessas informações, foi criada uma base de dados que se iniciou com as imagens enviadas pelos gestores no levantamento de dados (Figura 38). Além disso, essa base de dados foi alimentada com as imagens coletadas pelo pesquisador durante a investigação prática nas obras da Empresa X.

Figura 38- Imagens de alguns problemas recebidas no levantamento



Fonte: Empresa X.

5.1.2 Mapeamento do sistema construtivo de Paredes de Concreto moldadas in loco, com foco na fachada e no controle da qualidade

A partir da primeira visita realizada na obra da Empresa X foi realizado o mapeamento do sistema construtivo de paredes de concreto moldadas in loco. As principais atividades desse método construtivo são:

1) Marcação: É realizado a marcação das linhas auxiliares para montagem das formas de paredes (Figura 39). Para auxiliar essa marcação, primeiro define-se no projeto dois eixos de referência (**X e Y**), sendo um em cada direção. A marcação inicia-se partindo da junta de dilatação, marcando as faces internas e externas de cada parede. Utiliza-se distanciadores ou pinos para paredes internas e externas. Para realizar a marcação das lajes, é necessário o projeto detalhado com todas as medidas internas, linha para marcação, além de pó xadrez com cores de destaque e trena para aferimento.


Figura 39 - Marcação das linhas auxiliares para montagem das formas de paredes



Fonte: O autor.

2) Armação entre paredes e lajes: É utilizado telas de aço soldada, de acordo com as especificações do projeto (Figura 40). Utilizando os pontos de arranques das lajes inferiores é feita a amarração das telas de aço, deixando-as no eixo da parede com o uso de espaçadores. É necessário que se utilize no máximo 1 (um) distanciador a cada metro linear no eixo **x** horizontal e no eixo **y** vertical utilizando no mínimo 3 espaçadores. Nos encontros de paredes/paredes e paredes/lajes, são executados reforços de tela conforme projeto estrutural, evitando o aparecimento de fissuras. Os reforços de verga e contra verga devem seguir projeto.

Figura 40 - Armação entre paredes e lajes



Fonte: O autor.

3) Montagem das formas: O sistema de formas é composto por painéis de parede e seus complementos pré-montados no local com parafusos para serem içados com um guindaste ou grua, permitindo a redução do tempo de montagem, transferência e desforma. Antes da montagem de cada ciclo de concretagem é necessária a aplicação de uma camada de desmoldante (com base de óleo vegetal) em todas as placas da forma, na face de contato e na lateral. O sistema de forma inclui alguns alinhadores inferiores e superiores para evitar a articulação dos painéis e garantir o alinhamento da forma (Figura 41).

Figura 41 - Montagem das Formas



Fonte: O autor.

Para iniciar a montagem da forma é necessário ter o projeto de modulação de formas em mãos e atentar-se às dimensões de cada ambiente e, às placas da forma, a posição das escoras de nivelamento de lajes e demais acessórios de instalação e travamento das formas. Para a junção das peças que compõem as formas, são utilizados elementos chamados faquetas/gravatas fixados com pinos e cunhas ao

longo de toda a forma. Para facilitar a retirada dessas faquetas/gravatas após cada concretagem, elas serão envoltas por “camisinhas”, material de polietileno expandido.

Para que o concreto não vaze por baixo das formas da parede onde houver rebaixo de laje e onde forem observadas pequenas frestas, é feito o uso de “calafetação” utilizando uma “massa pobre” ou EVA (Espuma Vinílica Acetinada) no pé da forma nesses lugares. Após a montagem de todas as formas das paredes dos cômodos são montadas as formas das lajes. As lajes serão escoradas conforme projeto e devem ser conferidas com nível a laser. A retirada do escoramento deve ocorrer quando o concreto atingir resistência de no mínimo 15MPa e com pelo menos 7 dias de concretagem.

Após esse processo é necessário conferir prumo, esquadro e alinhamento das formas em todos os cômodos. Na parte externa da forma, é necessário conferir o prumo de todas as quinas das formas conforme imagens abaixo. Após a conclusão da montagem da forma, deve ser realizada a conferência da instalação dos alinhadores, esquadros, tensores, escoras, e a conferência do prumo da forma com um prumo de face em todos os cômodos. Este prumo deve aferir a parede que será concretada com o primeiro pavimento. Para os demais pavimentos é necessário que a conferência seja feita com um topógrafo, a cada 3 pavimentos executados.

4) Concretagem: A concretagem deve iniciar no encontro de 4 paredes (centro do bloco entre os apartamentos), deixando o concreto preencher toda parte inferior da forma e somente depois iniciado a concretagem dos painéis de periferia (Figura 42). Na chegada do concreto, deve-se realizar o *Slump Test*, quando necessário, sendo aceitável um abatimento de aproximadamente 6+-1cm ou conforme carta traço. Após o teste de Slump, adicionar o aditivo e realizar o processo de mistura por 1 minuto /m³, realizamos o *Slump Flow Test* para verificação do espalhamento. Na chegada do concreto autoadensável (CAA) deve-se realizar o teste *Flow* sendo aceitável o resultado de 70cm+- 5 (Tipo SF 2), e para concreto Superfluido deve-se realizar o Slump Test 22+- 3.

Figura 42 - Concretagem das paredes



Fonte: O autor.

5) Desforma: Mesmo com a utilização de desmoldastes, sempre ficam resíduos de concreto fixados nas formas. Dessa forma, antes de iniciar uma nova montagem, é necessário retirar o concreto grudado nas formas utilizando espátulas. A não retirada dos resíduos acarreta o aumento das dimensões da forma. Quanto mais cedo for retirado o concreto, mais fácil será a remoção do resíduo. Após a desforma, as paredes devem apresentar uma superfície uniforme, sem armaduras expostas e concreto desagregado. Esse processo executivo ocorre de andar por andar, em que, geralmente é construído um andar por semana (Figura 43).

Figura 43 - Desforma após a concretagem



Fonte: O autor.

Ao final da execução das paredes de cada torre ou bloco é realizado o tratamento das fachadas, reparando todos os defeitos causados nas fachadas durante a etapa de construção. Essa atividade acontece ao fim da estrutura, e é realizado por profissionais terceirizados que montam um balanço na torre pronta e realizam o tratamento por face da edificação, o que é chamado de “tratamento por pano” (Figura 44).

Figura 44 - Tratamento de fachada



Fonte: O autor.

Além do mapeamento do processo executivo, foi levantado os procedimentos utilizados para o controle da qualidade. Diante disso, a Empresa X utiliza a Ficha de Verificação de Serviço (FVS) para acompanhar o desenvolvimento das atividades, verificando se elas estão sendo desenvolvidas de acordo com as normas técnicas com o objetivo de que o produto final atinja o máximo de qualidade. O controle da qualidade é realizado em duas etapas sendo uma inspeção antes da concretagem e outra após a desforma. Cada FVS apresenta as condições para início das atividades propostas, seja de montagem ou desmontagem das formas.

A FVS utilizada na primeira etapa é dividida em quatro grandes áreas, consistindo em Sistema de Segurança; Montagem de Armação; Montagem da Forma; e Lançamento do Concreto. Essas atividades são compostas por 26 itens que são verificados nessas atividades. Além disso, na FVS é apresentado o método de verificação para cada um desses itens, a tolerância considerada para cada um deles e os equipamentos necessários para a inspeção. Os itens inspecionados são classificados em Aprovados; Reprovados; Aprovados Após Reinspeção; A verificar; e Não se Aplica.

Já a FVS utilizada na segunda etapa, de pós concretagem, consiste na grande área de Pós Desforma, possuindo 14 itens que são verificados durante as inspeções (Figura 45). Em relação ao formato a ser preenchido, as duas FVS são iguais, ou seja, ambas apresentam a mesma estrutura que no final delas, contém um campo para descrição das não conformidades identificadas, bem como da data de ocorrência, descrição da não conformidade, solução proposta e data de conclusão. A partir disso, os responsáveis envolvidos no Processo de Controle da Qualidade assinam esses documentos, liberando a continuidade dos serviços.

Figura 45 - FVS utilizada na Empresa X

FVS 45A2 - PAREDE DE CONCRETO _ESTRUTURA - PÓS DESFORMA		Identificação: FVS 45A2 Revisão: 03 Referência: PES 45A2	Folha: 01/02																
OBRA:		LOCAL DE INSPEÇÃO:																	
LEGENDAS	LOCAL DE INSPEÇÃO	<input checked="" type="checkbox"/> REPROVADO <input type="checkbox"/> APROVADO <input checked="" type="checkbox"/> APROVADO APÓS REINSPEÇÃO <input type="checkbox"/> A VERIFICAR <input type="checkbox"/> NÃO SE APLICA																	
CONDIÇÕES PARA INÍCIO		NOTAS																	
- A desforma deve ser liberada apenas quando o resultado do concreto atingir 3MPa		- Na desforma se atentar ao armazenamentos dos acessórios em balde e organização dos painéis																	
ITEM	MÉTODO DE VERIFICAÇÃO	TOLERÂNCIA	KIT CONFERÊNCIA	AMBIENTE												HALL	PLATIBANDA	OUTROS: ()	
				APTO FINAL 1	APTO FINAL 2	APTO FINAL 3	APTO FINAL 4	APTO FINAL 5	APTO FINAL 6	APTO FINAL 7	APTO FINAL 8	APTO FINAL 9	APTO FINAL 10	APTO FINAL 11	APTO FINAL 12				
PÓS DESFORMA	VI DESFORMA	Conferir se a desforma foi liberada apenas quando o resultado do concreto atingir 3MPa	Não há Tolerância	-															
	VF LIMPEZA DA FORMA	Verificar a limpeza com uso de desengraxante, palha de aço e espátula sem resíduos de concreto das laterais e superfícies das placas	Não há Tolerância	-															
	VF INTEGRIDADE DA FORMA	Verificar visualmente a integridade dos painéis da forma, não deve estar abauladas e amassadas de modo a comprometer o acabamento final	Não há Tolerância	-															
	VF PRUMO	Na parte interna conferir com prumo de face ou régua de 5 bolhas todas as paredes dos cômodos. Externamente com prumo de face todas as quinas das formas e, com prumo calango, a parede concretada com o pavimento anterior. Em Torre checar o prumo com topógrafo a cada 3 pavimentos	±5mm	Prumo de Face Régua de 5 Bolhas Prumo Calango Estação Total															
	VF PLANIQUIDADE	Conferir parede e teto com uso de régua de 5 bolhas em ambas as direções (horizontal e vertical) e em pelo menos dois pontos em cada elemento avaliado	Conforme	Régua de 5 Bolhas															
	VF NIVELAMENTO DO PISO	Realizar a verificação do nível em todos os ambiente, no centro e nas suas quatro extremidades	Conforme	Nível à Laser															
	VF ESQUADRO	Verificar esquadro entre paredes e parede x teto. Para esquadro em platibanda ou estrutura de reservatório superior, a verificação de esquadro deve ocorrer em todos os encontros de parede e vãos (janela/porta)	±3mm	Esquadro Metálico															
	VF DIMENSÕES	Com uma trena metálica conferir dimensão dos vãos de porta e janela, bem como todas as medidas internas de paredes em 2 pontos (o mais próximo do piso e do teto possível)	Conforme Projeto	Trena Metálica															
	VF NIVELAMENTO ALTURA DAS CAIXINHAS ELÉTRICAS	Com a régua de 5 bolhas conferir o alinhamento entre as caixinhas elétricas e com trena metálica a altura das mesmas	Conforme Projeto	Régua de 5 Bolhas Trena Metálica															
	VF REMOÇÃO DE ACESSÓRIOS DE TRAVAMENTO	Verificar após a desforma se foi realizada a retirada de todos os acessórios de travamento das formas na parede de concreto	Não há Tolerância	-															
PÓS DESFORMA	VF ACABAMENTO FINAL DO CONCRETO - INTERNO	As paredes e lajes devem apresentar após a desforma, uma superfície uniforme sem ondulações, imperfeições, sem armaduras expostas e concreto desagregado	Não há Tolerância	-															
	VF LIMPEZA DA PAREDE E LAJE	Verificar visualmente a limpeza das paredes e lajes, não deve haver resíduos de desmoldante e retirar com espátula de aço todas as rebarbas entre painéis de parede laje, imediatamente após a desforma da parede e laje	Não há Tolerância	-															
	VF ESTUCAGEM	Verificar se todas as faixetas e "camisinhas" foram retiradas e tamponadas com ACII em parede externa. Para paredes internas, o tamponamento pode ser realizado com uso de argamassa tipo ACII, podendo também ser utilizado argamassa cimentícia validada	Não há Tolerância	-															

Fonte: Empresa X.

Em relação aos 14 itens da FVS de após a Desforma, os quatro últimos itens foram considerados pelo pesquisador itens de difícil preenchimento, por se tratar de locais de difícil acesso. Esses itens são: (a) remoção de acessórios de travamento, (b) acabamento final do concreto – externo, (c) limpeza da parede e laje, e (d) estucagem. No entanto, o uso de drone oferece maior segurança e confiabilidade para preencher tais itens, pois o controle da qualidade não necessita subir na plataforma para essa inspeção. Além disso, os dados coletados podem ser arquivados e verificados após o tratamento dos itens atribuídos como “não conforme”.

5.1.3 Estudo de Caso na Obra A

A partir das quatro visitas realizadas na Obra A durante o estudo de caso, observou-se quais das manifestações patológicas indicadas no levantamento inicial de dados com os gestores da qualidade da Empresas X seriam possíveis de identificar automaticamente utilizando as imagens coletadas por drone e os algoritmos de aprendizado de máquina. No levantamento, foram indicadas onze manifestações patológicas, das quais, apenas quatro apresentaram características que possibilitaria o reconhecimento automatizado, sendo elas: a) fissuras; b) armadura exposta; c) falta de remoção das faquetas; e d) ninhos de concretagem.

Em relação às características que dificultam o reconhecimento automatizado das anomalias nas imagens, observou-se que a sutileza da manifestação patológica em relação ao local encontrado, além do contraste entre a manifestação patológica e a parede de concreto dificultaria a análise dos algoritmos de aprendizado de máquina. Dessa forma, as outras manifestações patológicas indicadas foram retiradas do escopo dessa pesquisa, pois apresentavam essas características ou, necessitavam da integração de outras tecnologias para sua identificação.

Como resultado das visitas de campo, em relação à aquisição de imagens, foram levantadas um total de 556 imagens e dessas apenas 97 apresentaram manifestações patológicas nas imagens coletadas. A partir dessa atividade de aquisição e classificação das manifestações patológicas foi possível direcionar a pesquisa para os testes de processamento digital de imagens a partir do software de aprendizado de máquina.

O primeiro modelo criado no Custom Vision, também chamado de M1, foi elaborado a partir de 97 imagens, distribuído em quatro manifestações patológicas, conforme identificadas nessas imagens. O Quadro 17 apresenta os resultados de

desempenho de cada manifestação patológica, além da quantidade de fotos utilizada para treinamento.

Quadro 17 - Desempenho do Modelo 1 gerado no Custom Vision

Modelo 1				
Manifestação Patológica (Tag)	Nº de fotos	Precisão	Recall	mAP
Armadura exposta	22	100%	100,0%	100%
Falta de remoção das faquetas	45	58,3%	93,3%	89,5%
Fissuras	15	75,0%	100,0%	91,7%
Ninhos de concretagem	15	75,0%	42,9%	52,4%
TOTAL	97	-	-	-

Fonte: O autor.

É possível observar que nesse modelo todas as manifestações patológicas contêm menos de 50 imagens, que é considerada a quantidade mínima de dados de entrada que o Custom Vision sugere para que o modelo tenha um resultado satisfatório. Embora o modelo tenha apresentado alguns valores de indicadores alcançando 100% de desempenho, devido ao baixo número de imagens o modelo tenderia a confundir as anomalias a serem identificadas. Diante disso, foi criado um novo modelo utilizando além das imagens do M1, as imagens da base de dados compartilhada, apresentando novos valores de desempenho (Quadro 18).


Quadro 18 - Desempenho do Modelo 2 gerado no Custom Vision

Modelo 2				
Manifestação Patológica (Tag)	Nº de fotos	Precisão	Recall	mAP
Armadura exposta	88	63,6%	72,4%	69,8%
Falta de remoção das faquetas	45	50,0%	84,2%	76,1%
Fissuras	46	27,6%	61,5%	31,6%
Ninhos de concretagem	19	28,6%	50,0%	52,1%
TOTAL	198	-	-	-

Fonte: O autor.

Além do Custom Vision apresentar o desempenho individual de cada objeto criado, ou seja, rótulo, *tag* ou, em nosso caso de cada manifestação patológica, ele calcula automaticamente uma média chamada de desempenho geral do modelo, em que é calculado a média da precisão, recall e mAP. Esse cálculo considera o valor do desempenho de cada objeto criado no modelo e a quantidade de imagens utilizada para cada item marcado. A comparação entre o desempenho geral dos modelos M1 e M2 é apresentado na Figura 45.

Figura 46 - Desempenho geral dos Modelos 1 e 2 criados no Custom Vision



Fonte: O autor.

É possível observar que o número de imagens de alguns rótulos do M2 aumentou, no entanto, o valor dos indicadores diminuiu (Figura 44). Isso pode ter acontecido devido ao tipo de fachada que as manifestações patológicas foram identificadas. Por exemplo, as imagens coletadas na obra, presentes no M1, são de fachadas de paredes de concreto, já as imagens da base compartilhada são de fachadas argamassadas com cores diferentes. No entanto, durante a elaboração desses modelos, considerou-se que quanto maior for o número de imagens utilizadas como entrada para treinar o algoritmo, maior seria o entendimento do software em relação aos problemas a serem detectados.

O valor de **precisão** dos modelos criados nos primeiros testes foi considerado baixo em relação a outros estudos, como o de Staffa et al. (2020), por exemplo. Isso pode ter acontecido por conta da pouca quantidade de imagens de algumas manifestações patológicas. Além disso, devido às paredes de concreto moldadas *in loco* apresentarem marcas das formas após as concretagens e tonalidades diferentes entre uma concretagem e outra, estas características contribuem para o baixo desempenho no reconhecimento automático.

Protocolo de aquisição de imagens com drone

O Protocolo de Aquisição de Imagens com drone foi elaborado a partir da experiência do pesquisador durante o Estudo de Caso A, observando a necessidade para tal. Esse protocolo consiste em quatro etapas (Figura 47), conforme será descrito a seguir.

Figura 47 - Protocolo de aquisição de imagens com drone



Fonte: O autor.

A primeira etapa consiste na verificação preliminar de voo, bem como da localização onde o voo será realizado, identificando se a área possui permissão para o uso de drone, como áreas militares e próximas a aeroportos. Além disso, é necessária a verificação prévia das condições climáticas para o dia do voo, pois, segundo o Regulamento Brasileiro da Aviação Civil Especial nº94 da ANAC (2022), somente é permitido iniciar uma operação de aeronave não tripulada se, o vento e demais condições meteorológicas forem acessíveis, possibilitando autonomia suficiente para realizar o voo e pousar em segurança no local previsto.

A segunda etapa consiste na montagem do equipamento e verificações dos componentes da aeronave através do preenchimento do Checklist para missão de RPA e formulário de dados do voo (*UAS Mission Checklist and Flight Log Data Form*), usado para preparação do voo, controle, e operação de pouso e decolagem com o objetivo de tornar o voo mais eficiente, considerando os requisitos de segurança e o uso apropriado do equipamento (Apêndice C).

A terceira etapa consiste na elaboração da trajetória de voo, que tem como objetivo facilitar a aquisição e análise de dados. Mesmo tendo um plano de voo determinado, ressalta-se que, em determinados casos, o voo pode sofrer alterações, pois existem alguns fatores que podem influenciar a missão do voo, tais como,

edifícios vizinhos muito próximos, árvores, vegetações ou paisagismo muito próximos a fachada, além de áreas sem visão do observador, entre outros.

Na quarta etapa, a aquisição de imagens é realizada a partir de dois voos por edificação, ou seja, o piloto e o observador se posicionam próximo a edificação, visando às duas laterais (Figura 48). O voo é realizado em formato **L**, facilitando que o observador mantenha o contato visual com a aeronave, além de evitar a locomoção no canteiro de obras durante o voo. O local ideal para os pilotos se alocarem deve ser de preferência aberto, para que o drone decole e pouse com segurança. Em relação a distância entre o drone e a edificação, os voos foram realizados entre 4,5 e 9 metros de distância entre o drone e a fachada.

Figura 48 - Posição dos operadores de drone durante o voo



Fonte: O autor.

Durante o voo, o drone segue um percurso partindo desde uma extremidade da fachada, iniciando os registros fotográficos nas laterais do edifício, até a outra extremidade (Figura 49). Após isso, o drone desce para um ângulo de visada possibilitando a captura de imagens de uma zona abaixo da registrada anteriormente, fazendo com que o mapeamento ocorra em toda a fachada. Esse método é realizado nas quatro fachadas da edificação e, ao final do voo é necessário fazer uma foto *overview*, ou seja, de toda a fachada, para ser usada como base durante a análise manual, além de indicar qual fachada foi inspecionada.

Figura 49 - Trajetória de voo nas fachadas



Fonte: O autor

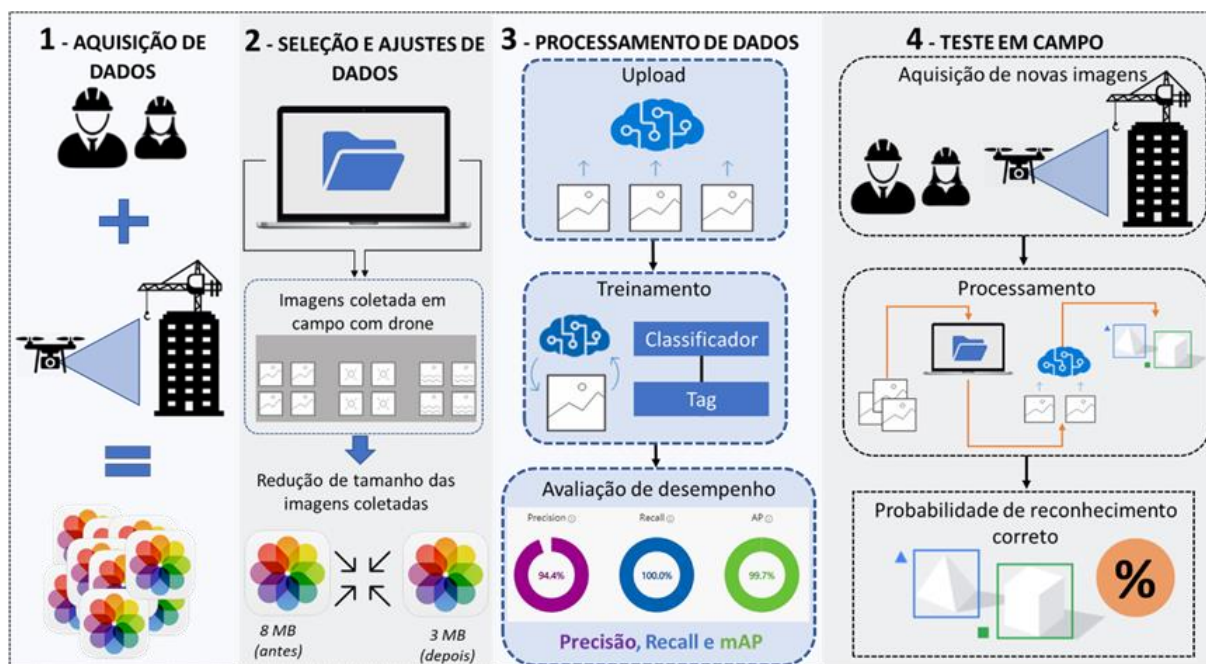
É importante observar durante o voo a influência que as condições climáticas podem causar sobre às imagens coletadas. A posição solar, por exemplo, pode afetar a visibilidade dos problemas ou manifestações patológicas através de sombra na fachada ou pelo contraste entre a luz do sol e cor da fachada. Diante disso, é relevante analisar se essa influência é imperceptível ou se pode prejudicar as imagens coletadas. Além da posição solar, analisar os impactos que os ventos podem causar nas imagens é um fator considerável, uma vez que ventos excessivos podem afetar diretamente a qualidade das fotos, fazendo registros tremidos.

Após inspecionar todas as fachadas, o piloto deve pousar o drone em um local seguro e, após isso, o drone deve ser desmontado e guardado, devidamente seguro, seguindo os itens do Checklist para Fim de Missão (Apêndice C). Após As imagens serem coletadas, elas podem ser transferidas para um notebook ou nuvem para posteriormente serem analisadas e classificadas.

Protocolo de Processamento de imagens

O protocolo proposto nessa etapa tem como objetivo padronizar a atividade de processamento de imagens para identificar automaticamente manifestações patológicas em fachadas de concreto moldadas in loco, durante o processo de execução. Ele é composto por quatro etapas (Figura 50), conforme será descrito a seguir.

Figura 50 - Protocolo de Processamento de imagens



Fonte: O autor

A primeira etapa desse protocolo consiste na realização das atividades propostas no protocolo de aquisição de imagens com drone, descrito no item anterior. Essa etapa busca coletar imagens para treinamento e processamento digital a partir do software Custom Vision. A segunda etapa consiste na atividade de selecionar e classificar as imagens de acordo com as manifestações patológicas encontradas. Essa etapa tem como objetivo facilitar a etapa de treinamento, em que as imagens coletadas são analisadas manualmente, dispensando o envio de imagens sem manifestações patológicas ao software.

A partir da análise prévia das imagens, classificando-as de acordo com cada manifestação patológica, as imagens são enviadas ao Custom Vision e cada manifestação patológica presente na imagem é marcada manualmente com a ferramenta detecção de objeto (*objetc detecetion*). Após o envio das imagens, o software notifica o sucesso do *upload*, se alguma imagem exceder o limite estabelecido pelo software e a existência de imagens duplicadas.

Após a marcação das imagens é realizado o treinamento do modelo, que consiste avaliar o entendimento do modelo baseado nas imagens marcadas. Após a realização do treinamento, o software apresenta o desempenho do modelo criado, a partir dos indicadores **Precisão**, **Recall** e **Map**. Além da apresentação do desempenho geral do modelo criado, o software apresenta o desempenho de cada rótulo treinado, facilitando identificar o item que necessita de mais dados de entrada.

Além da apresentação dos rótulos ou *tags* e dos valores dos indicadores, é apresentado a quantidade de imagens enviadas ao Custom Vision. Quando o número de imagens enviadas é inferior a 50 imagens o software indica a necessidade do envio de mais imagens, para melhorar o desempenho do modelo.

A etapa subsequente ao treinamento é o teste em campo. Essa etapa consiste em repetir todo o processo desde a aquisição de imagens até o envio ao Custom Vision. Essa etapa tem como objetivo adquirir novas e diferentes imagens das que foram utilizadas na etapa de treinamento. Após a aquisição dessas imagens é realizado o envio ao Custom Vision para realizar o processamento automático das manifestações patológicas. Após o teste, o modelo gera o mesmo indicador de desempenho da etapa de treinamento, podendo ser avaliado o quão satisfatório foi o reconhecimento das imagens.

Esses protocolos foram propostos na etapa de Conscientização e Sugestão com o objetivo de serem testados, avaliados e refinados durante a etapa de Desenvolvimento, dando suporte às atividades de aquisição de imagens com drone e processamento de imagens no Custom Vision.

5.2 RESULTADOS DA ETAPA DE DESENVOLVIMENTO

Esta seção apresenta os resultados dos Estudos de Caso B e C realizados nas obras da Empresa X. Essas atividades foram realizadas para avaliação e refinamento dos protocolos de aquisição e processamento de dados, bem como da implementação das informações no Sistema de Gestão da Qualidade do processo executivo de paredes de concreto moldadas in loco.

5.2.1 Estudo de Caso B

Nesta subseção são apresentados os resultados do Estudo de Caso B. Esse estudo foi dividido em dois ciclos de implementação em que o primeiro foi composto pelas atividades de aquisição de imagens para treinamento no Custom Vision e estruturação da disponibilização das informações. O segundo ciclo contemplou as atividades de aquisição de imagens com drone, processamento das imagens no Custom Vision e implementação das informações no processo de qualidade.

5.2.1.1 Aquisição de imagens com drone

A aquisição de imagens no Estudo de Caso B foi realizada a partir de sete visitas, coletando um total de 1.314 imagens. A coleta de imagens seguiu as etapas do **Protocolo de Aquisição de Imagens**, proposto no Estudo de Caso A. Após

coletadas, as imagens foram analisadas manualmente e classificadas de acordo com as manifestações patológicas presente em cada imagem. O quantitativo das manifestações patológicas levantadas por visita é apresentado no Quadro 19.

Quadro 19 - Manifestações patológicas levantadas no Estudo de Caso B

Visitas	Número de imagens por manifestações patológicas				Número total de fotos
	Armadura exposta	Falta de remoção das faquetas	Fissuras	Ninhos de concretagem	
02 de junho	0	0	0	0	0
10 de junho	3	6	1	10	174
17 de junho	7	36	4	0	165
05 de agosto	18	54	35	85	334
12 de agosto	1	7	4	4	54
26 de agosto	17	34	5	9	268
27 de outubro	18	3	1	19	128
16 de dezembro	8	17	1	8	191
Total	72	157	51	135	1314

Fonte: O autor.

Ressalta-se que o número de imagens com manifestações patológicas representa a quantidade de imagens com essas anomalias e que, em muitos casos, uma mesma manifestação patológica aparece em mais de uma imagem. Sendo assim, a partir dessas imagens coletadas e classificadas de acordo com as anomalias presentes em cada imagem, utilizou-se a técnica de *Data Augmentation* ampliando-se a base de dados seis vezes mais que a quantidade original. O Quadro 20 apresenta o código de linguagem utilizada nessa técnica.

Quadro 20 - Algoritmo da técnica *Data Augmentation*

Linha	Algoritmo
1	#Importando bibliotecas
2	Importglob
3	import os
4	from PIL import Image
5	frompathlibimport Path
6	Fromtkinterimportfiledialog
7	#declarando variavel do incrementador
8	i = 0
9	#atribuindo à variaveis as pastas selecionadas
10	#path é a pasta onde os arquivos estão
11	#path1 é pasta de destino das fotos editadas
12	path = filedialog.askdirectory()
13	path1 = filedialog.askdirectory()
14	
15	#atribuindo a lista com as fotos da pasta de origem
16	imagens = glob.glob(path + '/*.JPG', recursive = True)

Linha	Algoritmo
17	#Laço de repetição
18	
19	for imagem in imagens:
20	#Importação das imagens
21	imagem = Image.open(imagens[i])
22	#Descrição das dimensões das imagens
23	width, height = imagem.size
24	print(imagem.size)
25	#transformando o incrementador em string
26	ic = str([i])
27	#rotacionando a imagem em 180 graus
28	img180 = imagem.rotate(180)
29	img180 = img180.save(path1 + "/imagem180.JPG")
30	#enumerando as imagens editadas
31	os.rename(path1 + '/imagem180.JPG',path1 + "/imagem180 %s.JPG"%ic)
32	#rotacionando a imagem em 90 graus
33	img90 = imagem.rotate(90, expand=True)
34	img90 = img90.save(path1 + "/imagem90.jpg")
35	#enumerando as imagens editadas
36	os.rename(path1 + '/imagem90.jpg',path1 + "/imagem90 %s.jpg"%ic)
37	#rotacionando a imagem em 270 graus
38	img270 = imagem.rotate(270, expand=True)
39	img270 = img270.save(path1 + "/imagem270.jpg")
40	#enumerando as imagens editadas
41	os.rename(path1 + '/imagem270.jpg',path1 + "/imagem270 %s.jpg"%ic)
42	#espelha a imagem horizontalmente
43	hori_flippedIma = imagem.transpose(Image.FLIP_LEFT_RIGHT)
44	hori_flippedIma = hori_flippedIma.save(path1 + "/imagem270.jpg")
45	#enumerando as imagens editadas
46	os.rename(path1 + '/imagem270.jpg',path1 + "/imagemhori_flipped %s.jpg"%ic)
47	#espelha a imagem verticalmente
48	Vert_flippedImage = imagem.transpose(Image.FLIP_TOP_BOTTOM)
49	Vert_flippedImage = Vert_flippedImage.save(path1 + "/imagem270.jpg")
50	#enumerando as imagens editadas
51	os.rename(path1 + '/imagem270.jpg',path1 + "/imagemVert_flipped %s.jpg"%ic)
52	
53	
54	#incrementador
55	i = i + 1
56	
57	
58	print('Concluido')
59	#fim do programa

Fonte: GETEC.

5.2.1.2 Processamento de imagens do Custom Vision

Além de testar o protocolo de aquisição, durante o Estudo de Caso B, os dados coletados nas visitas foram classificados de acordo com as manifestações patológicas presentes em cada imagem e realizado treinamentos no Custom Vision. As atividades de treinamento seguiram as etapas propostas no Protocolo de Processamento de Imagens, buscando avaliar o desempenho dos modelos criados, a partir dos indicadores **Precisão, Recall, F1 Score e mAP**.

A partir disso, foi criado um terceiro modelo no Custom Vision utilizando a soma das imagens dos Modelos 1 e 2, realizados no Estudo de Caso A, resultando em 198 imagens. Essas imagens foram multiplicadas utilizando a técnica de *Data Augmentation* resultando em 1.188 imagens. O resultado do desempenho desse terceiro modelo é apresentado no quadro a seguir (Quadro 21).

Quadro 21 - Terceiro modelo criado no Custom Vision

Modelo3				
Manifestação Patológica (Tag)	Nº de fotos	Precisão	Recall	mAP
Armadura exposta	460	78,3%	77,7%	76,1%
Falta de remoção das faquetas	127	62,4%	82,4%	60,8%
Fissuras	298	48,0%	37,5%	36,6%
Ninhos de concretagem	303	48,5%	55,8%	61,1%
TOTAL	1.188	-	-	-

Fonte: O autor.

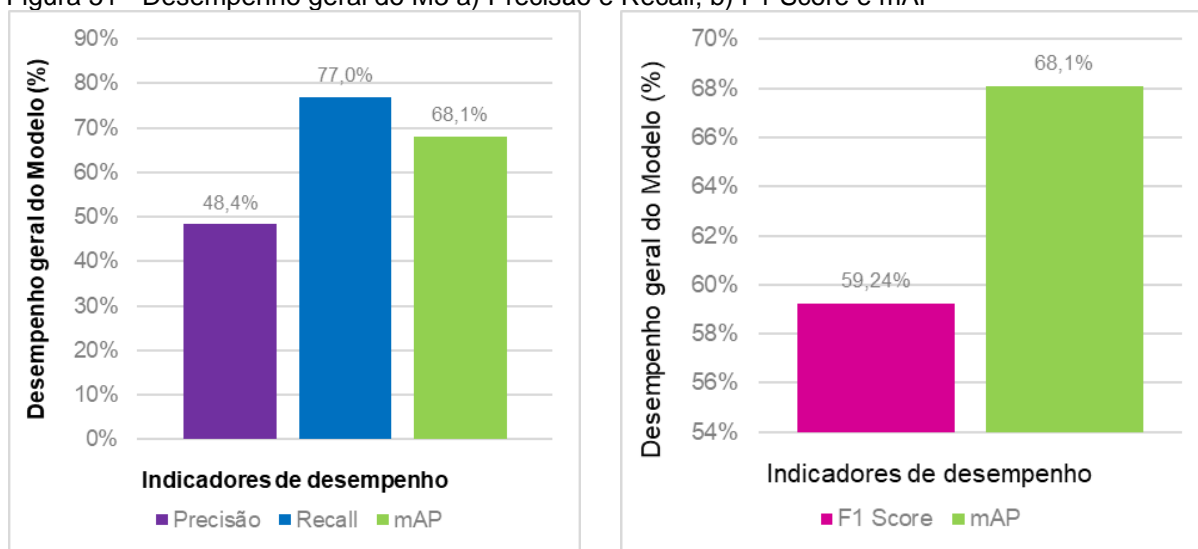
Observando individualmente o desempenho das manifestações patológicas do M3 que em relação a precisão, a armadura exposta apresentou melhor desempenho, seguida da falta de remoção das faquetas. Já as duas outras anomalias pertencentes a esse modelo apresentaram valores a abaixo de 50%. Em relação as manifestações patológicas que apresentaram menor valor de precisão, isso pode ter acontecido devido o detector ter identificado manifestações patológicas onde não tinha, ou seja, identificado mais falso positivos, causando redução de valor para precisão. Essa mesma análise pode ser feita para o indicador Recall, no entanto, nesse caso, os valores foram quase todos acima da média (50%). Isso pode ter acontecido devido a quantidade de classes acertadas durante a detecção, ou seja, a quantidade de verdadeiros positivos foi maior que a de falso negativo.

Em relação ao mAP do M3, o desempenho das tags para as manifestações patológicas armadura exposta, falta de remoção das faquetas e ninho de concretagem apresentaram boas métricas, excedendo 50% desse indicador. Já a tag de fissura apresentou valor menor que a média (50%), isso pode ter acontecido devido à

dificuldade de identificar uma fissura em paredes de concreto, já que as paredes possuem marcas da forma que podem ser confundidas com uma fissura.

O desempenho apresentado pelo Custom Vision a partir dos indicadores Precisão, Recall e mAP são apresentados na Figura 51a. Após esses valores, utilizando a fórmula descrita no item 3.3.1 foi calculado a métrica F1 Score, que busca uma média entre os indicadores Precisão e Recall (Figura 51b). É possível observar que o valor de F1 Score do modelo geral foi baixo por conta da média entre a precisão e recall e por conta de os valores de cada rótulo apresentarem uma variação entre alto e baixo, ou seja, como a avaliação é realizada através do modelo geral, a média é feita entre os valores.

Figura 51 - Desempenho geral do M3 a) Precisão e Recall; b) F1 Score e mAP



Fonte: O autor.

Analisando os valores dos três modelos criados, ou seja, M1, M2 e M3, observa-se que o desempenho dos três indicadores do M3 caiu. Essa redução de desempenho pode ter sido causada pela inserção das imagens da base de dados compartilhada, pois as imagens dessa base possuem características diferentes da base própria, como por exemplo, a cor da fachada. Além disso, a técnica de *Data Augmentation* utilizada apenas rotacionou as imagens originais, mantendo a mesma característica da base de dados original, com isso, o modelo pode ter confundido as manifestações patológicas durante o treinamento.

A partir da avaliação desses três modelos, observou-se que outros modelos poderiam ser criados no Custom Vision para avaliação dos indicadores de desempenho e exploração do potencial uso dessa API. A partir disso, foram criados novos modelos no Custom Vision, fazendo novas combinações de quantidades de

imagens diferentes dos três primeiros modelos, além da criação de modelos individuais para cada manifestação patológica.

5.2.1.3 Implementação das informações na gestão da qualidade

A implementação das informações referente às inspeções, propostas no segundo ciclo de implementação do Estudo de Caso B aconteceu a partir do envio de relatórios aos gestores da Obra B, indicando a quantidade e quais manifestações patológicas foram encontradas nas fachadas durante cada inspeção. A implementação dessas informações no processo de produção e de qualidade aconteceu seguindo o ciclo PDCA, conforme mostra a Figura 52.

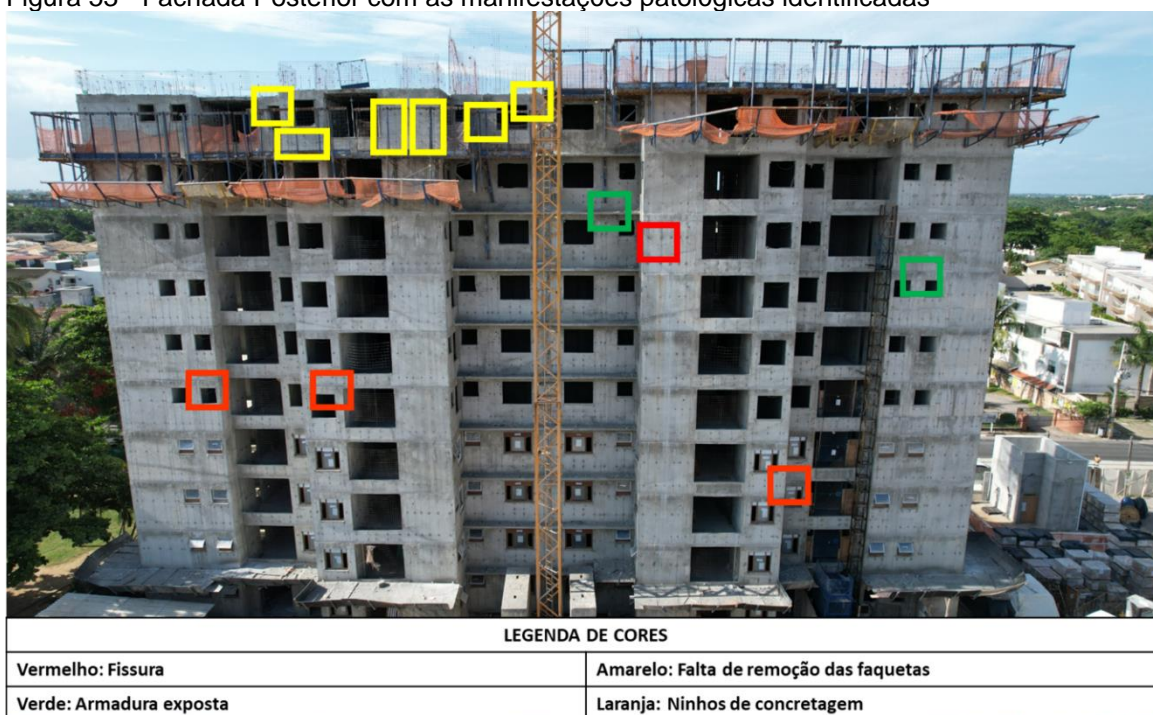
Figura 52 - Ciclo PDCA utilizado nos estudos de caso



Fonte: o autor.

Em relação ao **PDCA (Plan, Do, Check e Act)**, a fase “**Plan**” consistiu na reunião com os gestores da Obra B levantando quais os principais problemas recorrentes na execução de fachadas de paredes de concreto. A fase “**Do**” contemplou a aquisição de documentos, como PES e FVS, e imagens coletadas com drone. A partir dessas atividades, na fase “**Check**” as informações foram disponibilizadas à equipe da Obra B em formato de relatório, informando quais as manifestações patológicas existiam nas fachadas, a quantidade delas e o local onde essas foram identificadas nas quatro fachadas (Figura 53).

Figura 53 - Fachada Posterior com as manifestações patológicas identificadas



Fonte: O autor.

Em relação à última fase do Ciclo PDCA, no **Act** foi enviado a equipe da Obra B um Plano de Ação indicando as manifestações patológicas e as fontes de evidências para classificação de cada manifestação patológica encontrada (Figura 54). Além disso, foi proposto o preenchimento desse plano de ação de acordo com as ações corretivas e preventivas realizadas.

Figura 54 - Plano de ação enviado

MANIFESTAÇÃO PATOLÓGICA IDENTIFICADA	FONTES DE EVIDÊNCIA	TRATAMENTO	AÇÃO	
			DATA*	RESPONSÁVEL**
Fissuras	Presença de fissuras à 45° em pés das paredes			
	Presença de fissuras a 45° próximo a laje			
	Presença de fissuras diversas na superfície do concreto			
	Presença de fissuras vertical e horizontal em paredes de concreto			
	Presença de fissuras em paredes extensas e em vãos de janelas e portas			
Segregação de Concreto e Armadura Exposta	Presença de vazios entre a nata de cimento e o agregado graúdo do concreto			
	Ausência de ponte de ligação entre os agregados e a nata de cimento (esfarelamento)			
	Evidência de falta de recobrimento adequado de parte da armadura de concreto			
	Falha moderadas na concretagem de um elemento de concreto deixando parte da armadura exposta			
Falha da remoção de Faquetas	Presença de faquetas após a remoção das formas			
Outros:				

* Data prevista para executar a atividade (prazo);

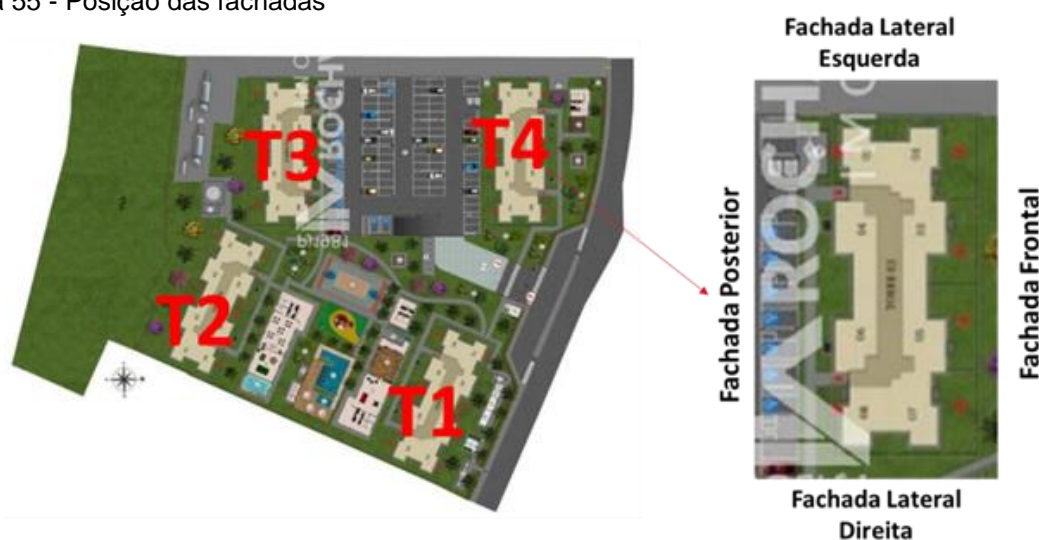
** Responsável pela execução da ação;

*** Ainda será avaliada a possibilidade de inspeção visual com drone.

Fonte: O autor.

Todas as outras fachadas foram marcadas de acordo com as manifestações patológicas encontradas, assim como na Figura 51. Além disso, essa atividade se estendeu em todas as fachadas, de todas as torres da Obra B. Cada fachada foi nomeada de acordo com a posição de projeto, sendo elas: fachada frontal, fachada posterior, fachada lateral direita e fachada lateral esquerda (Figura 55).

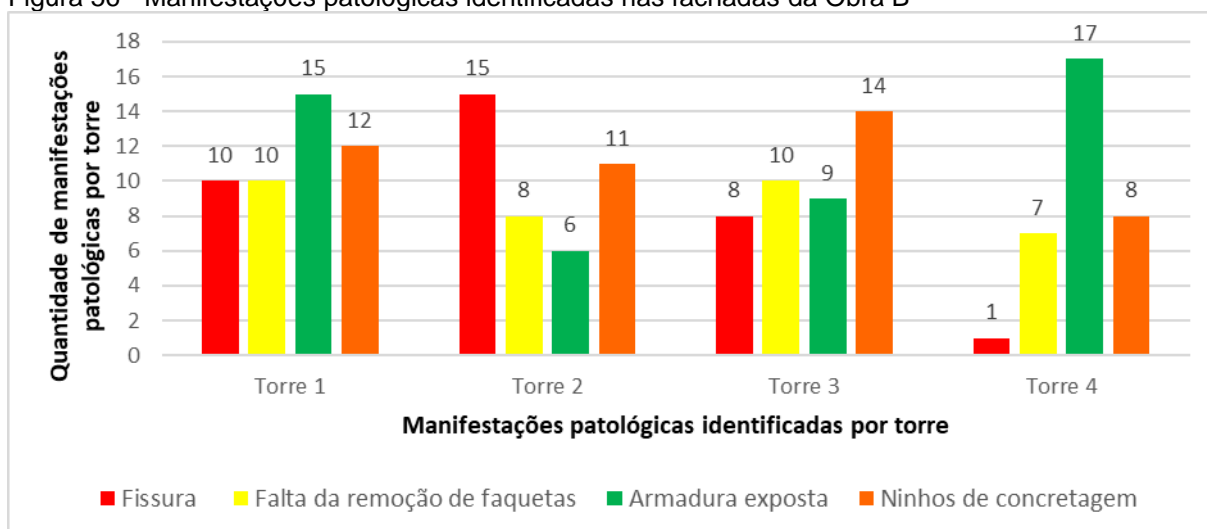
Figura 55 - Posição das fachadas



Fonte: O autor.

O acompanhamento da execução da Obra B foi realizado durante as etapas construtivas das quatro torres, com foco na execução das fachadas de paredes de concreto moldadas in loco. Ao final desse estudo, foi identificado um total de 124 manifestações patológicas, distribuídas por torre, conforme mostra a Figura 56. Dessas 124, é possível observar que a armadura exposta é a não conformidade de maior recorrência, isso pode estar associado ao tipo de concreto utilizado, bem como ao lançamento do concreto. Observa-se também que as torres que possuem as fachadas mais voltadas para o lado Norte apresentam maior recorrência de fissuras, como é o caso das Torres 1 e 2. Além do envio de relatórios com tais informações, as imagens coletadas na obra foram compartilhadas com a equipe da obra.

Figura 56 - Manifestações patológicas identificadas nas fachadas da Obra B



Fonte: O autor.

5.2.2 Estudo de Caso C

Nesta subseção são apresentados os resultados do Estudo de Caso C. Esse estudo contemplou as atividades de aquisição de imagens com drone, processamento das imagens no Custom Vision e implementação das informações no processo de qualidade.

5.2.2.1 Aquisição de imagens com drone

A aquisição de dados na Obra C foi realizada a partir de quatro visitas onde foram coletadas um total de 569 imagens. A partir da aquisição dessas imagens, as imagens foram analisadas manualmente e o resultado dessas análises foram disponibilizadas em formato de relatório. Além disso, as imagens analisadas foram utilizadas para treinamento do algoritmo no Custom Vision, a relação e o quantitativo das manifestações patológicas são apresentadas no Quadro 22.

Quadro 22 - Manifestações patológicas levantadas no Estudo de Caso C

Visitas	Número de imagens por manifestações patológicas				Número total de fotos
	Armadura exposta	Falta de remoção das faquetas	Fissuras	Ninhos de concretagem	
17 de novembro	2	1	1	4	162
30 de novembro	3	7	0	7	186
19 de dezembro	10	4	9	3	88
16 de janeiro	38	14	11	13	133
Total	53	26	21	27	569

Fonte: O autor.

Além da aquisição de novas imagens, nesse estudo de caso foram criados outros modelos no Custom Vision, utilizando todas as imagens coletadas até o dia 19 de novembro de 2022. A partir das imagens coletadas no Estudo de Caso A, foram criados os dois primeiros modelos (M1e M2) e no Estudo de Caso B, foi criado o terceiro modelo (M3) utilizando as imagens dessa obra. Por fim, no Estudo de Caso C foram criados os modelos M4, M5 e M6.

O M5 subdividiu-se em quatro modelos, ou seja, um modelo para cada manifestação patológica. Todos os modelos criados neste estudo de caso utilizaram as imagens coletadas no Estudo de Caso A, B e C, com exceção da visita realizada no dia 16 de janeiro, pois essas imagens foram utilizadas para testes de desempenho do modelo (Quadro 23).

Quadro 23 - Relação dos modelos criados de acordo com as obras estudadas

Modelos criados no Custom Vision	Imagens utilizadas		
	Estudo de Caso A	Estudo de Caso B	Estudo de Caso C
M1 (Contendo as quatro manifestações patológicas)	X		
M2 (Contendo as quatro manifestações patológicas)	X		
M3 (Contendo as quatro manifestações patológicas)		X	
M4 (Contendo as quatro manifestações patológicas)	X	X	X
M5a (Contendo apenas Armadura exposta)	X	X	X
M5b (Contendo apenas falta de remoção das faquetas)	X	X	X
M5c (Contendo apenas fissura)	X	X	X
M5d (Contendo apenas ninho de concretagem)	X	X	X
M6 (Contendo as quatro manifestações patológicas)	X	X	X

Fonte: O autor.

5.2.2.2 Processamento de imagens no Custom Vision

Esta atividade está dividida entre apresentação dos resultados obtidos durante os treinamentos e discussão dos resultados obtidos durante os treinamentos e testes no Microsoft Custom Vision.

Apresentação dos resultados dos Modelos M4, M5 e M6

O quarto modelo criado no Custom Vision, também chamado de M4, foi composto pela soma de todas as imagens coletadas nas obras, exceto as imagens da última da visita do dia 16 de janeiro. Essas imagens não fizeram parte do modelo devido elas terem sido utilizadas nos testes para avaliação do desempenho dos

modelos. O M4 contemplou as quatro anomalias do estudo e o desempenho individual de cada uma dessas classes treinada nesse modelo é apresentado no Quadro 24.

Quadro 24 - Modelo 4 criado no Custom Vision

Modelo 4				
Manifestação Patológica (Tag)	Nº de fotos	Precisão	Recall	mAP
Armadura exposta	139	63,60%	73,70%	72,50%
Falta de remoção das faquetas	194	56,30%	62,80%	55,40%
Fissuras	84	71,40%	83,30%	77,20%
Ninhos de concretagem	303	45,10%	69,50%	55,10%
TOTAL	720	-	-	-

Fonte: O autor.

A partir do M4 foi preparado o quinto modelo, chamado de M5. Este modelo foi dividido em cinco submodelos, ou seja, foi criado um modelo para cada manifestação patológica. O objetivo desse modelo foi avaliar o desempenho do modelo por manifestação patológica, tendo em vista que as outras manifestações patológicas presentes nas outras imagens poderiam atrapalhar o reconhecimento automático das anomalias. A quantidade de imagens utilizada para o treinamento individual de cada submodelo, bem como o desempenho desses submodelos é apresentado no Quadro 25.

Quadro 25 - Modelo 5 e submodelos criados no Custom Vision

Modelo 5					
Submodelo	Manifestação Patológica (Tag)	Nº de fotos	Precisão	Recall	mAP
M5a	Armadura exposta	139	50,00%	73,70%	70,90%
M5b	Falta de remoção das faquetas	194	69,70%	83,60%	79,10%
M5c	Fissuras	84	53,80%	77,80%	76,20%
M5d	Ninhos de concretagem	303	40,80%	75,30%	68,10%
TOTAL		720	-	-	-

Fonte: O autor.

O M5 é composto pela mesma quantidade de imagens do M4, o que difere os modelos é sua composição. O M4 é composto por quatro rótulos, ou seja, quatro manifestações patológicas, já o M5 é composto por apenas uma manifestação patológica por submodelo. Após a criação dos modelos descritos anteriormente, foi proposto um sexto modelo, chamado de M6 (Quadro 26). Esse último modelo é composto pela junção de todas as imagens coletadas durante os três estudos de caso, com exceção das imagens coletadas na visita do dia 16 de janeiro, e multiplicadas utilizando a técnica de *Data Augmentation*.


Quadro 26 - Modelo 6 criado no Custom Vision

Modelo 6				
Manifestação Patológica (Tag)	Nº de fotos	Precisão	Recall	mAP
Armadura exposta	834	55,30%	83,00%	67,80%
Falta de remoção das faquetas	1164	49,90%	83,90%	72,20%
Fissuras	504	42,40%	70,70%	63,30%
Ninhos de concretagem	1818	20,40%	76,00%	44,20%
TOTAL	4320	-	-	-

Fonte: O autor.

Após o treinamento de todos os modelos propostos no Estudo de Caso C, analisou-se o desempenho de cada modelo. No entanto, o Custom Vision apresenta automaticamente os valores gerais para **precisão**, **recall** e **mAP**, conforme consta a Figura 57. O desempenho geral do modelo é constituído pela soma do desempenho individual de cada rótulo presente no modelo, mais a soma da quantidade de imagens. A análise dos resultados comparando qual modelo obteve melhor desempenho foi realizado a partir dessa média geral.

Figura 57 - Desempenho geral dos modelos criados no Estudo de Caso C



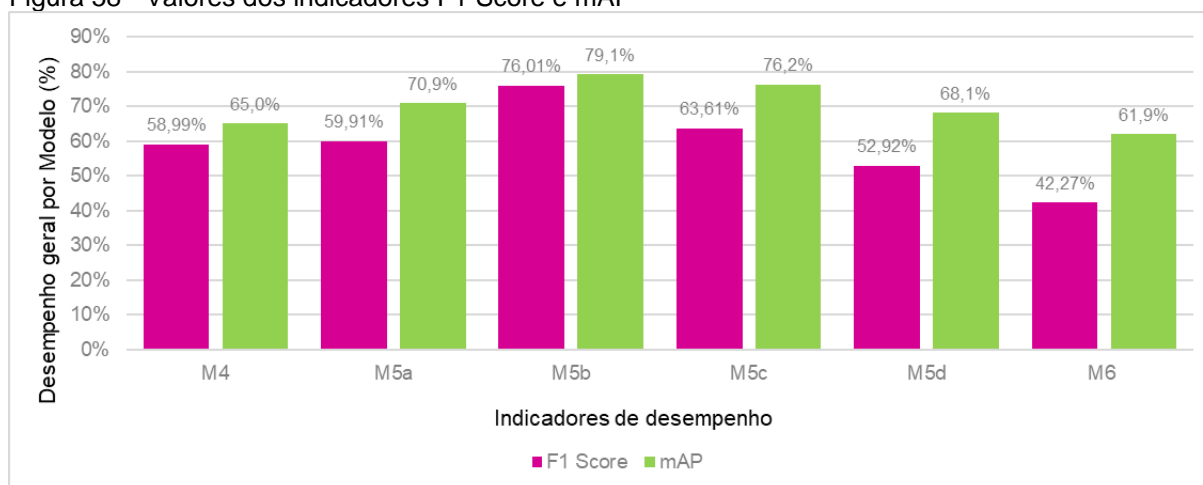
Fonte: O autor.

De acordo com a Figura 56, observa-se que o desempenho geral do M6 não foi tão bom quando o esperado, já que foi o modelo que utilizou o maior número de imagens para treinamento. Comparando todos os seis modelos, esse foi o modelo que apresentou menor desempenho. Essa redução pode estar associada à quantidade de imagens similares utilizadas em sua composição, ter confundido o algoritmo durante a marcação das demais manifestações patológicas, ou seja, por se tratar de anomalias em paredes de concreto, os detalhes conseqüentemente são semelhantes e sutis. Além disso, neste caso, o uso de *Data Augmentation* pode ter influenciado

nessa redução pois, por mais que a base de dados tenha aumentado, as imagens foram as mesmas.

A partir desses valores de precisão e recall foi calculado a média entre essas métricas a partir do indicador F1 Score. O cálculo do F1 Score foi realizado para melhorar a análise do desempenho entre os modelos, já que esse indicador traz o equilíbrio harmônico entre as métricas de precisão e recall. Para o cálculo deste indicador foi utilizado a fórmula descrita na seção 3.3.1 e os valores desse indicador são apresentados na Figura 58.

Figura 58 - Valores dos indicadores F1 Score e mAP



Fonte: O autor.

Analisando os valores de indicadores da Figura 58 é possível observar que as métricas F1 Score e mAP do M5 tiveram melhor desempenho que os modelos M4 e M6, com exceção ao F1 Score do M5d (modelo de ninho de concretagem). O fato dos modelos M5a, M5b e M5c apresentarem melhor desempenho que os modelos M4 e M6 pode ter acontecido devido os dados utilizados para treinamento não serem confundidos com as outras tags, ou seja, o modelo tinha que detectar apenas uma manifestação patológica. Em relação ao baixo desempenho do F1 Score do M5d comparado aos outros modelos do M5, isso pode ter acontecido devido o valor da precisão desse modelo, conforme apresentado no Quadro 27. Possivelmente, o modelo previu que na imagem tinha ninho de concretagem, mas não tinha, ou seja, o valor de falso positivo foi maior que os valores de verdadeiro positivo, resultando no baixo valor de precisão.

Em relação ao desempenho do M5d comparado aos outros modelos observa-se uma redução sutil de F1 Score em relação ao M4 (Figura 58). Analisando o desempenho do M5d, no Quadro 26, observa-se que a precisão na identificação dos

ninhos de concretagem foi menor que o rótulo dessa manifestação patológica no M4 (Quadro 25). Isso pode ter acontecido devido às características visuais dessa manifestação patológica, ou seja, devido ao ninho de concretagem apresentar características semelhantes às marcas nas paredes de concreto, principalmente nas juntas de cada pavimento. Desta forma, o modelo pode ter identificado mais problemas onde não tinha, sendo assim, os valores de falsos positivos foram maiores que os verdadeiros positivos, ocasionado baixa precisão.

Análise dos resultados dos modelos criados no Custom Vision

Após a realização dos treinamentos de todos os modelos, eles foram testados para avaliar qual a probabilidade de reconhecimento automatizado de cada uma das manifestações patológicas rotuladas. O Quadro 27 apresenta o resumo de todos os modelos propostos, contemplando a quantidade de imagens utilizadas para treinamento e teste, o formato das imagens, os indicadores de desempenho e o valor limiar utilizado durante os testes e a probabilidade média de reconhecimento.


Diante disso, analisando os indicadores de desempenho de todos os modelos propostos neste trabalho, observa-se que os dois primeiros modelos (M1 e M2) apresentaram bons indicadores de F1 Score e mAP, durante o treinamento. No entanto, durante os testes os modelos não acertaram nenhuma predição, ou seja, os modelos identificavam faquetas no lugar de ninhos de concretagem, fissuras ao invés armadura expostas, entre outras confusões durante os testes. Por conta disso, foi atribuído o valor 0 nas médias de probabilidade de reconhecimento automatizado.

O terceiro modelo (M3), assim como os dois primeiros confundiu várias manifestações patológicas durante os testes. Mesmo apresentando bons indicadores de F1 Score e mAP, o modelo confundiu algumas classes rotuladas. No entanto, diferentemente dos primeiros modelos, esse modelo previu corretamente algumas manifestações patológicas como armadura exposta, falta de remoção das faquetas e fissuras. Essa confusão no reconhecimento das manifestações patológicas durante os testes, por esses três modelos, pode estar associada ao conjunto de dados utilizados em sua composição, ou seja, durante o treinamento não foram utilizados apenas imagens de fachadas de paredes de concreto.

Quadro 27 - Resumo de todos os modelos

Modelos criados no Custom Vision	Treinamento dos modelos					Teste dos modelos		
	Imagens			Indicadores de desempenho		Valor Limiar (%)	Quantidade de imagens	Probabilidade média de reconhecimento (%)
	Quantidade	Formato	Tempo de treinamento (h)	Precisão (%)	Recall (%)			
M1	97	jpeg	4 horas	57,40%	83,80%	30%	10	0
M2	198	jpeg	4 horas	48,70%	74,30%	30%	10	0
M3	1.188	jpeg	4 horas	48,40%	77,00%	30%	10	12,46%
M4	720	jpeg	4 horas	51,80%	68,50%	30%	10	44,40%
M5a	139	jpeg	4 horas	50,00%	73,70%	30%	10	33,40%
M5b	194	jpeg	4 horas	69,70%	83,60%	30%	10	57,00%
M5c	84	jpeg	4 horas	53,80%	77,80%	30%	10	28,44%
M5d	303	jpeg	4 horas	40,80%	75,30%	30%	10	49,86%
M6	4.320	jpeg	4 horas	28,90%	78,70%	30%	10	20,81%

Desempenho geral dos modelos



Fonte: O autor.

Diferentemente dos três primeiros modelos, o modelo que apresentou melhor probabilidade de reconhecimento automatizado das manifestações patológicas foi o M4 (Quadro 29). Esse modelo apresentou 58,99% de F1 Score e 65% de mAP durante os treinamentos. Já durante os testes, o modelo atingiu a probabilidade de 44,40% de reconhecimento automatizado das manifestações patológicas rotuladas.

Além do quarto modelo (M4), os submodelos do M5 também apresentaram bons valores durante o treinamento e teste. No entanto, os modelos de armadura exposta (M5a), falta de remoção das faquetas (M5b) e ninhos de concretagem (M5d) foram previstos com maior probabilidade do que o modelo de fissura (M5c). Como já mencionado anteriormente, devido às características sutis das fissuras e a semelhança com outros detalhes nas paredes de concreto podem ter influenciado o menor valor de reconhecimento automatizado durante os testes. No entanto, os indicadores podem ser aprimorados com a retroalimentação de imagens, tornando o detector cada vez mais capaz de diferenciar um detalhe de uma anomalia.

Em relação ao último modelo, o M6, por se tratar do modelo com a maior quantidade de imagens utilizadas durante o treinamento, esperava-se que seu desempenho fosse maior que os demais modelos, no entanto, isso não aconteceu. Comparando todos os modelos, o que obteve menor desempenho de indicadores foi o M6. Além disso, durante os treinamentos esse modelo não previu várias manifestações patológicas, apresentando apenas 20,81% de probabilidade média de reconhecimento das classes rotuladas. Isso pode ter acontecido devido a quantidade de imagens ter confundido o modelo na marcação das demais manifestações patológicas, por se tratar de anomalias em paredes de concreto, onde os detalhes consequentemente são sutis. A segunda possibilidade para essa redução está associada ao uso das técnicas de *Data Augmentation*, pois, por mais que a base de dados tenha aumentado, as imagens eram as mesmas, mudando apenas o ângulo.

5.2.2.3 Implementação das informações na gestão da qualidade

A implementação das informações na Obra C ocorreu desde a primeira visita. No total foram quatro visitas até o término da primeira torre (Figura 59). As visitas aconteceram quinzenalmente e na última visita teve um intervalo maior por conta do recesso de final de ano. No entanto, as informações foram implementadas através do envio das imagens, de breves reuniões para discussão das inspeções realizadas, troca de mensagens e com o envio do relatório.

Figura 59 - Acompanhamento da execução da fachada da torre 1



Fonte: O autor.

Os relatórios foram enviados logo após a inspeção e sua estrutura era composta por sete páginas, em que eram descritas as informações em relação à inspeção das fachadas (Figura 60). Além disso, sua estrutura dispôs de uma página inicial com informações gerais sobre a obra e os profissionais envolvidos. Em seguida foram apresentados os resultados da inspeção de fachada, tais como, um esquema situando a localização de cada fachada inspecionada, um quadro geral indicando onde havia manifestações patológicas e um gráfico apresentando a incidência de manifestações patológicas por fachada. Por fim, nas páginas seguintes, foram apresentadas as imagens das fachadas inspecionadas, indicando a presença de manifestações patológicas.

Figura 60 - Estrutura do relatório entregue a Empresa X



Fonte: O autor.

Além dessas informações, foi proposto um plano de ação ao final do relatório, contendo informações sobre as manifestações patológicas que faziam parte do escopo deste trabalho, bem como sobre suas fontes de evidência. O intuito desse plano de ação foi que os colaboradores ao receber o relatório preencheriam o plano de ação conforme as atividades para resolver os problemas identificados. Após o recebimento do relatório, a equipe de qualidade analisava o relatório e realizava o tratamento das não conformidades encontradas, preenchendo o plano de ação conforme cada tratamento, indicando a data e o responsável por cada tratamento (Figura 61).

Figura 61 - Plano de ação preenchido por colaboradores da Empresa X

MANIFESTAÇÃO PATOLÓGICA IDENTIFICADA	FONTES DE EVIDÊNCIA	TRATAMENTO	AÇÃO	
			DATA*	RESPONSÁVEL**
Fissuras	Presença de fissuras à 45° em pés das paredes	Consultar o setor de projetos e posterior tratamento	22/12/22	Auxiliar
	Presença de fissuras a 45° próximo a laje	Consultar o setor de projetos e posterior tratamento	22/12/22	Auxiliar
	Presença de fissuras diversas na superfície do concreto	Consultar o setor de projetos e posterior tratamento	22/12/22	Auxiliar
	Presença de fissuras vertical e horizontal em paredes de concreto	Tratamento com PU ou mástique posterior demão de tinta	29/12/2022	Auxiliar
	Presença de fissuras em paredes extensas e em vãos de janelas e portas	Tratamento com PU ou mástique posterior demão de tinta	29/12/2022	Auxiliar
	Presença de fissuras em lajes	Abertura da fissura e preencher com chumbador químico	29/12/2022	Auxiliar
Segregação de Concreto e Armadura Exposta	Presença de vazios entre a nata de cimento e o agregado graúdo do concreto	Tratamento com ACIII	21/11/2022	Auxiliar
	Ausência de ponte de ligação entre os agregados e a nata de cimento (esfarelamento)	Tratamento dos pontos com ACIII	21/11/2022	Auxiliar
	Evidência de falta de recobrimento adequado de parte da armadura de concreto	Tratamento da armadura exposta e verificação com o projetista do que pode ser feito	21/11/2022	Auxiliar
	Falha moderadas na concretagem de um elemento de concreto deixando parte da armadura exposta	Tratamento da armadura com Bianco e posterior concretagem do elemento	19/12/2022	Auxiliar
	Falhas graves de concretagem	Preenchimento dos pontos com concreto e graute	19/12/2022	Auxiliar
Falta da remoção de Faquetas	Presença de faquetas após a remoção das formas	Retirada das faquetas com martetele e martelo	15/12/2022	Encarregado
Outros:				

* Data prevista para executar a atividade (prazo);


** Responsável pela execução da ação;

*** Ainda será avaliada a possibilidade de inspeção visual com drone.

Fonte: O autor.

Ao todo foram entregues a equipe da Obra C mais de 550 imagens coletadas durante a execução de fachadas com uso de drones, quatro relatórios e quatro planos de ação. O estudo encerrou após a conclusão da primeira torre e durante seu processo construtivo foram identificadas 21 fissuras, 29 faquetas sem serem removidas, 50 armaduras expostas e 27 ninhos de concretagem (Figura 62).

Figura 62 - Manifestações patológicas identificadas nas fachadas da Obra C



Fonte: O autor.

5.3 AVALIAÇÃO DAS IMPLEMENTAÇÕES DO MÉTODO PROPOSTO COM BASE NOS CONSTRUCTOS DE PESQUISA

Nesta seção serão apresentadas as avaliações dos resultados, obtidos a partir da implementação do método proposto nos Estudos de Caso. Esta avaliação será

baseada nas fontes de evidências obtidas através da observação direta, observação participante, análise documental (imagens coletadas com drone, indicadores de desempenho do Custom Vision, relatórios e planos de ação) e entrevistas realizadas para coleta de percepção dos profissionais da Empresa X. Os constructos avaliados foram transparência, eficiência e utilidade.

5.3.1 Transparência

A transparência foi avaliada a partir das variáveis: (1) Contribuição para o compartilhamento de informações entre as equipes de qualidade e tratamento das não conformidades; (2) facilidade de entendimento das informações; e; (3) Clareza dos resultados gerados a partir da análise dos dados. Além disso, esse constructo foi avaliado a partir das atividades de aquisição de dados e implementação das informações na obra. O Quadro 28 apresenta os resultados das entrevistas realizadas com a equipe da Obra A com relação ao constructo transparência.

Quadro 28 - Avaliação dos entrevistados - Constructo Transparência

TRANSPARÊNCIA					
Variáveis	Nível de percepção				
Produtos Implementados	Muito baixo	Baixo	Indiferente	Alto	Muito Alto
Ficha de inspeção por fachada				ECP1, ECA1, ECA2	ECP2, EEC
Gráfico de incidência de manifestação patológica por fachada				ECA1, ECP1	EEC, ECP2, ECA2
Mapeamento das manifestações patológicas nas imagens por fachada				ECA1	ECP1, EEC, ECP2, ECA2
Plano de ação				ECP1, ECP2, ECA1, ECA2	EEC

Fonte: O autor.

Os entrevistados avaliaram de uma forma geral que as informações fornecidas no relatório e plano ação contribuíram bastante para o aumento da transparência no processo de execução e tratamento das fachadas de paredes de concreto moldadas in loco, principalmente, apoiando o controle da qualidade em relação ao que fazer e de como fazer, conforme apresentado no plano de ação. Para a Estagiária de Engenharia Civil – EEC, essas informações podem ser acessadas e entendidas por

todos da engenharia, influenciando na agilidade e rendimento desse serviço de inspeção. Além disso, os entrevistados consideraram que as informações presentes no relatório eram de fácil entendimento, auxiliando-os na identificação das manifestações patológicas nas fachadas, indicando como nível de entendimento “alto” e “muito alto” para todos os itens avaliados.

As imagens coletadas por drone foram úteis para verificação do andamento da execução e, principalmente, para verificação da qualidade na execução desse serviço. A partir das imagens foi possível observar qual manifestação patológica tem aparecido com frequência e identificar o motivo do aparecimento dessas anomalias. Em relação a suficiência das imagens para o tratamento das fachadas, o entrevistado ECA1 da Obra B apontou que tanto as imagens coletadas por drone, quanto os relatórios são ferramentas excelentes para se basear, no entanto, existem outros aspectos importantes para realizar o tratamento das fachadas, bem como a mão de obra especializada para tratamento e conferência da fachada tratada.

Além disso, as imagens coletadas em obra foram utilizadas no Estudo de Caso C para mapeamento das fissuras na parte externa da edificação, ou seja, nas fachadas. Esse serviço acontecia apenas na parte interna, pois a responsável por essa atividade não conseguia realizar a atividade na parte interna e externa a tempo da plataforma de serviço estar no andar concretado. Além disso, só era realizado o mapeamento das fissuras e a partir desse estudo outras manifestações patológicas podem ser incluídas nesse mapeamento, como é o caso das armaduras expostas, ninhos de concretagem e falta de remoção das faquetas.

Foi perguntado aos entrevistados qual manifestação patológica são mais relevantes de serem identificadas e tratadas. Para a EEC, todas são fundamentais, já que se trata de manifestações patológicas. Para o ECP e ECA da obra B, todas são relevantes, mas as armaduras expostas apresentam maiores problemas para a edificação, já que interfere no desempenho estrutural das fachadas de paredes de concreto. Já para a ECP e ECA, as fissuras são as manifestações patológicas mais relevantes, já que elas podem surgir logo após a concretagem e podem facilitar a entrada de vários agentes agressivos para a estrutura, além de vários outros problemas.

Além das manifestações patológicas identificadas neste estudo, sugeriu-se pelos entrevistados que incluíssem a identificação de outros problemas ou manifestações

patológicas, como a falta de preenchimento de estuque após a remoção das faquetas, calafetação da base das paredes de concreto e desaprumo das torres.

Em relação às principais dificuldades na execução das fachadas de paredes de concreto, os entrevistados apontaram que o concreto ou a concretagem em si, são os principais causadores do surgimento das manifestações patológicas. Para eles, uma forma de evitar o surgimento dessas manifestações patológicas variam desde a contratação do fornecedor do material, do acompanhamento da execução dos serviços, principalmente das concretagens, exigindo que o concreto atenda às especificações de projeto, tanto em relação ao traço, quanto em relação ao fator água/cimento e, por fim, a utilização corretas dos materiais, como o uso de espaçadores e uso das camisinhas para as faquetas (camisinhas).

Em relação às melhorias na estruturação das informações presentes no relatório de forma a melhorar a transparência, foram sugeridas pelos entrevistados que em relação às fissuras, fossem indicadas a orientação que as manifestações se encontram. Além disso, em relação aos ninhos de concretagem e armadura exposta, foi destacada a necessidade de especificar a área dessas não conformidades para facilitar o tratamento delas, auxiliando os profissionais na quantidade de material a ser utilizado.

5.3.2 Eficiência

A eficiência foi avaliada a partir das variáveis: (1) celeridade na aquisição de imagens; (2) indicadores de desempenho do Custom Vision Precisão; Recall e mAP; e (3) celeridade na geração de informações. Além disso, esse constructo foi avaliado a partir das atividades de aquisição de dados e implementação das informações na obra.

A partir da observação direta do pesquisador e análise dos registros fotográficos realizados com drone notou que o uso do protocolo de aquisição de dados tornou a coleta de imagens mais célere. As coletas de imagens realizadas na Obra A levaram cerca de uma hora para coletar imagens das quatro fachadas da torre, utilizando três baterias para aquisição de imagens. Após a elaboração do protocolo essa atividade reduziu entre 20 e 25 minutos (Quadro 29).

Quadro 29 - Desempenho médio da aquisição de imagens com drone

Obra	Equipamento Utilizado	Média de duração de voo por Estudo de Caso (h)	Média de fotos coletadas
Obra A	DJI Phantom 4	01:02:00	358

Obra B	DJI AIR 2S	00:39:33	193
Obra C	DJI AIR 2S	00:34:00	142

Fonte: O autor.

Além da redução de tempo para a aquisição de imagens, o protocolo proporcionou maior agilidade nessa atividade. Isso aconteceu devido a padronização das atividades e elaboração de um plano de voo para todas as fachadas. Com isso, o piloto e observador conseguiram coletar menos imagens e obter toda a cobertura da fachada, além de, realizar tudo em menos tempo.

Em relação à celeridade na geração de informações, foi possível medir o tempo levado em todas as atividades, desde a coleta de imagens até o envio do relatório para a equipe de gestão da obra. O Quadro 30 apresenta todas as atividades realizadas e o tempo médio para cada uma delas. É importante ressaltar que os 40 minutos utilizados para a análise manual das imagens será reduzido significativamente a partir do reconhecimento automático das imagens com uso dos algoritmos do Custom Vision.

Quadro 30 - Tempo para inspeção de fachada e fornecimento das informações

Preparação e disponibilização das informações	Tempo médio (min)
Aquisição de imagens com drone	34
Descarregamento das imagens no computador	2
Análise manual das imagens e elaboração do relatório	40
Upload das imagens na nuvem para disponibilização para a equipe da obra;	5
Entrega de relatório por e-mail	5
Tempo total	01:26:00


Fonte: O autor.

Em relação a análise das imagens, Melo (2016) levou cerca de 90 minutos para a análise manual de imagens coletadas por drone em inspeções de segurança, já no trabalho de Lima (2021) o tempo gasto para a análise automática das imagens e upload para o relatório levou cerca de 13 minutos, reduzindo cerca de 77 minutos em relação à Melo (2016). Nesse sentido, Costa et al. (2023 *“to be published”*) utilizou o Custom Vision para processamento de imagens de telhados coletados por drone, levando cerca de 2 minutos para a análise automatizada das não conformidades. Dessa forma, espera-se que a partir da automatização na análise das imagens o tempo gasto para a inspeção de fachadas seja de aproximadamente 48 minutos, incluindo a aquisição de imagens com drone.

Além da celeridade na aquisição de imagens com drone utilizando o protocolo proposto e da celeridade na geração de informações em relação ao processo completo de inspeção, foi possível medir a eficiência da etapa de processamento de imagens no Custom Vision através dos indicadores de desempenho do próprio Custom Vision (Figura 64). Os modelos foram treinados por quatro horas e apresentaram diversos resultados dos indicadores. Esses indicadores foram discutidos na etapa anterior, ao longo do resultado dos estudos de caso.

Figura 63 - Avaliação dos indicadores de desempenho do Custom Vision

Indicadores de desempenho: Precisão, Recall e mAP					
Modelo 1 – M1			Modelo 1 – M2		
Precision ① 57.4%	Recall ① 83.8%	mAP ① 83.9%	Precision ① 48.7%	Recall ① 74.3%	mAP ① 65.1%
Modelo 3 – M3			Modelo 4 – M4		
Precision ① 48.4%	Recall ① 77.0%	mAP ① 68.1%	Precision ① 51.8%	Recall ① 68.5%	mAP ① 65.0%
Modelo 5a – M5a (Armadura Exposta)			Modelo 5b – M5b (Faquetas)		
Precision ① 50.0%	Recall ① 73.7%	mAP ① 70.9%	Precision ① 69.7%	Recall ① 83.6%	mAP ① 79.1%
Modelo 5c – M5c (Fissuras)			Modelo 5d – M5d (Ninhos de concretagem)		
Precision ① 53.8%	Recall ① 77.8%	mAP ① 76.2%	Precision ① 40.8%	Recall ① 75.3%	mAP ① 68.1%
Modelo 6 – M6					



Fonte: O autor.

5.3.3 Utilidade

A utilidade foi avaliada a partir das variáveis: (1) contribuição para o planejamento de ações corretivas; (2) contribuição para o planejamento de ações preventivas; e; (3) Contribuição para a melhoria do controle da qualidade. Além disso, esse constructo foi avaliado a partir das atividades de aquisição de dados e implementação das informações na obra. O Quadro 31 apresenta os resultados das entrevistas realizadas com a equipe da Obra A com relação ao constructo transparência.

Quadro 31 - Avaliação dos entrevistados - Constructo Utilidade

UTILIDADE					
Variáveis	Nível de percepção				
Práticas Implementadas	Muito baixo	Baixo	Indiferente	Alto	Muito Alto
Auxílio para o preenchimento da FVS de controle da qualidade durante a execução das fachadas			ECA2	ECP1, EEC, ECP2	ECA1
Identificação e mapeamento das não conformidades				ECP1	ECA1, ECC, ECP2, ECA2
Auxílio na tomada de decisão em tempo hábil para intervenção				ECA1 ECP2, ECA2	ECP1, ECC
Acompanhamento do tratamento das não conformidades		ECA1	ECP2, ECA2	ECP1	ECC
Especificação do tratamento de acordo com a manifestação patológica identificada	ECP1		EEC, ECP2, ECA2	ECA1	

UTILIDADE					
Variáveis	Nível de percepção				
Práticas Implementadas	Muito baixo	Baixo	Indiferente	Alto	Muito Alto
Fontes de evidência			ECP2, ECA2	ECP1, ECA1, EEC	
Atribuição de um responsável pelo tratamento para o melhor controle da atividade realizada			EEC, ECP2, ECA2	ECP1	ECA1
Definição de prazo para realização da ação corretiva visando o acompanhamento da execução da tarefa			ECP2, ECA2	ECP1, EEC	ECA1

Fonte: O autor.

Os entrevistados apontaram que os relatórios foram úteis para várias práticas, como o auxílio para preenchimento da FVS de controle da qualidade durante a execução das fachadas, para identificação e mapeamento das não conformidades, para auxílio na tomada de decisão em tempo hábil para intervenção e para o acompanhamento do tratamento das não conformidades. Em relação a essas práticas, os entrevistados avaliaram o nível de utilidade como “alto” e “muito alto”, exceto para o item “auxílio no preenchimento da FVS”, pois segundo o ECA1, independente do relatório essa atividade deve ser realizada.

Em relação ao acompanhamento do tratamento das não conformidades, o entrevistado ECA1 apontou que a utilidade do relatório é baixa, pois o tratamento das fachadas nessa obra foi realizado somente no final da execução, por uma empresa terceirizada e devido à falta de mão de obra interna essa inspeção após o tratamento não era realizado. Já os entrevistados ECP2 e ECA2 apontaram a utilidade do relatório como indiferente devido não realizarem essa atividade após o tratamento. Ou seja, os problemas foram apontados, mas necessitam de mão de obra para acompanhar o tratamento dessas anomalias apoiando o controle da qualidade na execução e entrega desse produto.

Em relação ao Plano de Ação, o item “especificação do tratamento das não conformidades, de acordo com as manifestações patológicas identificadas na inspeção”, o entrevistado ECA1 apontou a utilidade como “alta”, pois auxiliava os profissionais em qual atividade realizar. Já para os entrevistados EEC, ECP2, ECA2 e ECP1, o nível de utilidade dessas informações foi considerado “indiferente” e “muito

baixo” já que o próprio Procedimento de Execução de Serviço (PES) da empresa apresenta como cada não conformidade deve ser tratada, bem como específica qual material usar.

Os demais itens do Plano de Ação, tais como, as fontes de evidencia, atribuição de um responsável para o melhor controle da atividade realizada e da definição de um prazo para a realização da ação corretiva, visando o acompanhamento da execução da tarefa apontaram que o nível de utilidade dessas informações foi “alto” e “muito alto”, exceto para os entrevistados ECP2 e ECA2, que apontaram como indiferente, pois segundo eles as fontes de evidências já constam no PES e atribuir um responsável e um prazo para realização do tratamento não tinha como ser controlado. Além disso, segundo esses entrevistados, não tem como definir um prazo para o tratamento das não conformidades, pois essa atividade é realizada de acordo com a execução das paredes de concreto e pode ser realizada por qualquer profissional.

Em relação à periodicidade das inspeções, os entrevistados dos dois Estudos de Caso apontaram que atendeu a demanda de informações para o tratamento das fachadas. No Estudo de Caso B, por exemplo, a inspeção era realizada e o tratamento das fachadas só era realizado quase dois meses depois, segundo o entrevistado ECP1, responsável pela obra. Foram apontados pelos entrevistados como principais aspectos positivos relacionados ao estudo, a inovação em usar tecnologias digitais para realizar uma atividade que é desenvolvida manualmente e a redução de pessoas nesse processo. Além disso, para eles as informações presentes nos relatórios e planos de ação ficaram bem detalhadas, com informações claras e bem-sinalizadas, facilitando o entendimento de qualquer um profissional.

Além da entrevista com os colaboradores dos Estudos de Caso B e C, foi coletado a percepção dos profissionais da empresa X durante o workshop realizando para apresentação dos resultados do estudo (Figura 65). Em relação ao método proposto de inspeção de fachada utilizando drones e algoritmos de aprendizado de máquina para controle da qualidade durante a execução, os profissionais apontaram que o método apresenta várias vantagens para a empresa, tornando o acompanhamento da execução da obra em relação a qualidade das fachadas e preenchimento da FVS de forma mais prática e ágil. Além disso, eles apontaram que o método é inovador devido ao uso de tecnologias digitais acompanhando a transformação digital do setor da construção civil, inserindo a empresa nessa transformação.

Figura 64 - Workshop realizado no Estudo de Caso C



Fonte: O autor.

Em relação aos benefícios para a implementação do método proposto foram citados: a redução de mão de obra para realização do controle da qualidade, bem como a qualidade das informações obtidas, já que as imagens coletadas podem ser arquivadas e utilizadas para acompanhamento da qualidade. Além disso, foi apontado como aspecto fundamental a segurança dos profissionais na realização das inspeções na parte externa da edificação, já que os profissionais não precisariam subir na plataforma de trabalho para verificar os itens da FVS, podendo realizar isso com as imagens coletadas pelo drone.

Segundo os entrevistados, não existe nenhuma barreira para implementação do método, já que o investimento com os equipamentos como drone e treinamento para os profissionais seria algo que daria retorno ao longo do tempo com a redução de retrabalho e perdas. Além disso, o método proposto pode ser realizado pelos próprios colaboradores da Empresa X, mediante a treinamento, bem como da terceirização deste serviço, garantindo assim eficiência no processo de controle da qualidade, apoiando na boa execução dessa tão importante tarefa.

5.4 ESTRUTURA FINAL DO MÉTODO

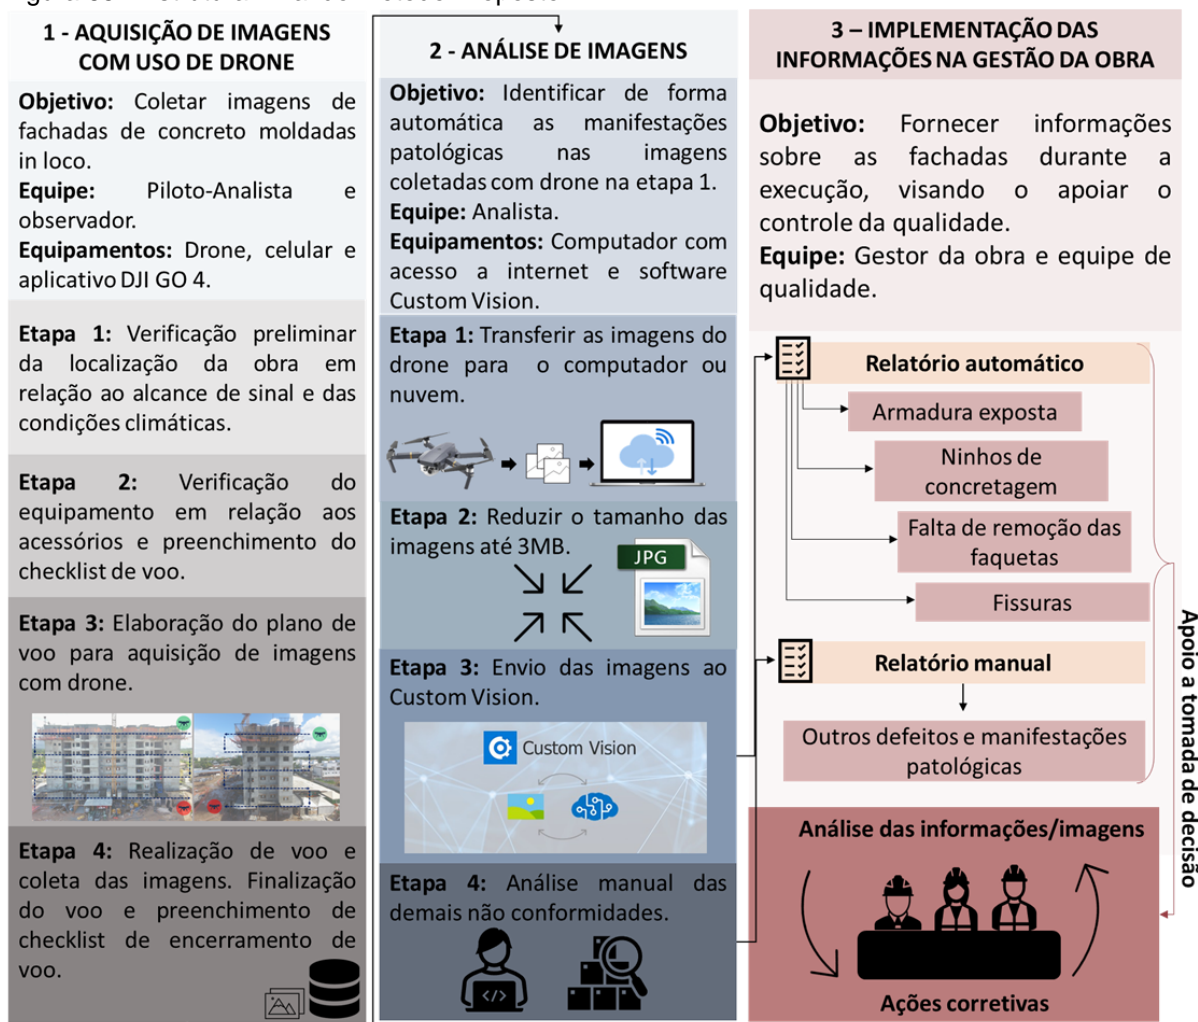
Nesta seção será apresentada a proposta de método para reconhecimento automatizado de manifestações patológicas na execução de fachadas com uso de drones e aprendizado de máquina, definida a partir dos refinamentos realizados durante os Estudos de Caso, considerando ainda a sua avaliação.

5.4.1 Apresentação da Estrutura Final do Método Proposto

O método proposto é composto por três etapas e cada uma delas apresenta um conjunto de sub etapas para serem realizadas, quais sejam: (1) Aquisição de imagens

com uso de drones; (2) Análise das imagens de forma manual e com uso de algoritmos de Aprendizado de Máquina; e (3) Implementação das informações na gestão da obra, conforme é apresentado na Figura 66 e descrito posteriormente.

Figura 65 - Estrutura Final do Método Proposto



Fonte: O autor.

Aquisição de Imagens com uso de Drones

Esta atividade tem como objetivo coletar imagens das fachadas de paredes de concreto moldadas in loco com uso de drones. Para esta atividade, inicialmente é necessário um drone, independente da marca e modelo, um aparelho celular com o aplicativo do drone instalado para controlar o voo e realizar as capturas das imagens. Para o método proposto foram utilizados Drones da marca DJI, bem como aplicativos dessa mesma marca. Além dos equipamentos, para que essa etapa seja realizada, são necessários dois profissionais, um piloto-analista e um observador.

O piloto-analista é quem conduz o equipamento, realizando o voo e tirando as fotos das fachadas, além disso, este pode ser o mesmo profissional que vai analisar as imagens na etapa posterior. Já o observador é responsável por manter o contato visual com o equipamento durante o voo, evitando que ele se choque com algum obstáculo ou ave. Em relação ao piloto-analista, este profissional necessita de um treinamento para pilotar o drone de acordo com as normas da ANAC, além de garantir a segurança dos profissionais durante a execução. Este profissional deve ter conhecimento das manifestações patológicas que se deseja identificar e do processo construtivo de paredes de concreto, ou seja, conhecimento específico sobre a inspeção que está realizando.

A primeira etapa dessa atividade consiste na verificação preliminar da localização da obra, verificando se é permitido sobrevoar com aeronaves remotamente pilotadas (drone), evitando ser uma área militar ou próxima a aeroportos, impossibilitando a troca de sinal entre o drone e o piloto com o controle operador. Outro ponto importante é verificar as condições climáticas previstas para a data da inspeção, evitando deslocar-se até o local e estar chovendo, ou precisar interromper o voo caso comece a chover.

A etapa posterior consiste na verificação do equipamento. É necessário analisar e garantir a integridade dos acessórios do equipamento, tais como as hélices e demais componentes. É necessário garantir que a câmera não esteja suja ou que tenha algum objeto que comprometa a qualidade das imagens coletadas. Para essa atividade foi utilizado um Checklist de voo, desenvolvido pelo GETEC em estudos anteriores (Apêndice C), seguindo um conjunto de etapas para que o voo seja eficiente.

A terceira etapa consiste na elaboração do plano de voo para aquisição das imagens. Nessa atividade é elaborada a trajetória de voo, que pode ser elaborada conforme cada tipologia construtiva, ou seja, construção de torre ou bloco. Para os Estudos de Caso B e C foi utilizado um plano de voo onde o piloto subia o drone até o último pavimento da edificação inspecionada e iniciava o percurso lateral, paralelo a fachada, realizando a captura de imagens. O drone manteve uma distância média de 4,5m da fachada, pois o objetivo dessa atividade é coletar imagens de até dois pavimentos por foto, garantido a qualidade da imagem e visualização das manifestações patológicas.

Por fim, a última etapa consiste na realização do voo. A inspeção pode ser realizada após analisadas a localização da obra, as condições climáticas e do

equipamento e ter elaborado o plano de voo. Recomenda-se que a equipe se posicione na lateral entre duas fachadas, mantendo um ângulo de visão em formato “L”, para evitar a circulação pela obra durante as atividades de construção, evitando distração da equipe de execução, e possíveis acidentes. Ao finalizar a aquisição de imagens e pousar o equipamento em um local seguro, o equipamento pode ser desmontando e guardado, seguindo as instruções do Checklist de encerramento de voo (Apêndice C).

Análise das Imagens

Esta atividade tem como objetivo identificar as manifestações patológicas presentes em fachadas de paredes de concreto moldadas in loco, a partir das imagens coletadas com drone. Os equipamentos necessários para a realização desta atividade são computadores ou notebooks com acesso à internet e ao software Custom Vision. Além desses equipamentos, nesta atividade é necessário apenas um profissional para análise das imagens, podendo ser o mesmo piloto do drone.

A primeira etapa é fazer o upload das imagens coletadas para um computador. Em seguida, é realizado o redimensionamento do tamanho das imagens já que as imagens coletadas pelos drones apresentam tamanho superior a 3MB e o Custom Vision só aceita imagens até esse tamanho. Após isso, essas imagens são enviadas as imagens ao Custom Vision, para a análise automatizada e identificação das manifestações patológicas presentes nessas imagens. Após o envio, será gerado um relatório automatizado com as manifestações patológicas identificadas pelo processamento de imagens no Custom Vision.

O escopo do método proposto inclui a identificação automatizada de quatro manifestações patológicas (armadura exposta, falta de remoção das faquetas, fissuras e ninhos de concretagem). No entanto, as imagens coletadas com drone podem ser analisadas manualmente e serem identificados outros problemas ou manifestações patológicas, contemplando assim, a última etapa desta atividade. Após essa análise manual, é gerado um relatório com os problemas identificados.

Implementação das Informações na Gestão da Obra

Esta atividade tem como objetivo a implementação das informações geradas a partir das duas primeiras atividades, apoiando os gestores na tomada de decisão em relação ao controle de qualidade durante a execução. Nesta atividade, os profissionais

envolvidos são os gestores da obra e a equipe de controle da qualidade para análise das informações e planejamento das ações corretivas e preventivas. Além disso, um dos membros da equipe de qualidade da empresa pode ser o piloto-analista.

A primeira atividade do método proposto tem como principal produto imagens das fachadas de paredes de concreto moldadas *in loco*, coletadas com drone durante a execução. Essas imagens podem ser utilizadas para preenchimento de documentos utilizados no processo de controle da qualidade, como as Fichas de Verificação de Serviço, apoiando os colaboradores no preenchimento das informações, agilizando as anotações e garantindo a segurança dos profissionais. Além disso, as imagens podem ser utilizadas para diversos fins em relação à gestão geral da obra, que vão desde analisar a qualidade das paredes de concreto até o uso correto de equipamentos de proteção individual e coletiva na execução das paredes de concreto.

Em relação à segunda atividade do método proposto, os principais produtos gerados são os relatórios e planos de ação. Após as imagens serem analisadas manualmente ou por algoritmos de aprendizado de máquina, as informações dessas análises são transcritas e disponibilizadas para a equipe de gestão da obra em formato de relatórios, apoiando a tomada de decisão em relação as ações a serem tomadas. O primeiro relatório apresenta os resultados da identificação automatizada a partir do processamento no Custom Vision das quatro manifestações patológicas. O segundo relatório apresenta os resultados da análise manual, identificando outros problemas ou manifestações patológicas além dos quatro identificados no relatório automático.

Ao final dos relatórios são propostos planos de ações para as manifestações patológicas identificadas. O intuito desse plano de ação é acompanhar o tratamento das anomalias encontradas através das ações corretivas, apoiando as discussões durante as reuniões de equipe. Os resultados das inspeções apresentados nas reuniões mostram quais manifestações patológicas tiveram maior incidência, quais foram as ações corretivas e quais ações preventivas podem ser tomadas, visando a redução de tais anomalias e garantindo a qualidade das fachadas de paredes de concreto moldadas *in loco*.

5.5 DISCUSSÃO DOS RESULTADOS

Os modelos propostos neste trabalho identificaram a existência e localização de manifestações patológicas como armadura exposta, falta de remoção das faquetas,

fissuras e ninhos de concretagem. O modelo que apresentou melhor desempenho durante os treinamentos atingiu 51,8% de precisão e 68,5% de recall. Comparado a estudos semelhantes como o de Silva e Lucena (2018) e Kim e Cho (2018), que propuseram modelos para reconhecimento automatizado de fissuras, este modelo apresentou menor desempenho, já que o modelo proposto por Silva e Lucena (2018) atingiu 92,27% de precisão e o de Kim e Cho (2018) apresentou 92,35% de precisão e 89,28% de recall. No entanto, mesmo que esses modelos tenham apresentado maior desempenho, eles focaram apenas em fissuras, além de não deixar claro a localização dessas não conformidades. Além disso, a base de dados utilizada neste trabalho foi de 720 imagens distribuídas entre as quatro manifestações patológicas, já a base de dados utilizada por Silva e Lucena (2018) foi de 3.500 imagens e a de Kim e Cho (2018) 42.000 imagens, ambas de uma única manifestação patológica, o que pode ter facilitado o entendimento do algoritmo em relação ao que detectar na imagem.

Após utilizar o método semelhante ao estudo de Staffa et al. (2020) para investigação de manifestações patológicas em fachadas de paredes de concreto moldadas *in loco*, observou o método proposto é viável, no entanto, assim como no trabalho desses autores, o modelo precisa ser retroalimentado com mais imagens para melhorar constantemente o desempenho dos indicadores, em relação ao reconhecimento automatizado das não conformidades. Além disso, o método para inspeção automatizada de telhados (STAFFA et al., 2020) e da presente pesquisa de inspeção automatizada de fachadas, pode ser replicado para demais estruturas como pontes, pavimentos, entre outras tipologias construtivas.

Ainda relacionado ao estudo de inspeção automatizada de telhados inclinados utilizando drones e aprendizado de máquina, proposto por Staffa et al. (2020), observou-se que assim como nesta pesquisa, que as manifestações patológicas mais sutis apresentaram menor desempenho do que problemas mais fáceis de identificar. No estudo de Staffa et al. (2020), o rótulo criado para “alçapão aberto ou fechado”, apontou 100% de precisão e 57,10% de recall, já para o rótulo “vedação do encontro entre rufos” apontou 42,9% de precisão e 6,8% de recall, o que mostra que quanto mais sutil a manifestação patológica, menor é o desempenho do detector.

O método proposto neste trabalho investiga a presença de quatro manifestações patológicas em fachadas de paredes de concreto moldadas *in loco* durante a execução. Semelhante a este estudo, Bouzan et al. (2021) propuseram um método

para identificação e classificação de quatro manifestações patológicas em fachadas de revestimento cerâmico, sendo fissuras, eflorescência, armadura exposta e mancha de ferrugem. No entanto, o modelo proposto por esses autores contemplou apenas edifícios na fase de uso e ocupação. Além disso, o tipo de material das fachadas é diferente, o que pode ter influenciado no melhor desempenho do modelo treinado, já que o modelo proposto por Bouzan et al. (2021) apresentou melhores indicadores, variando entre 65% e 90% de precisão. Além disso, Bouzan et al. (2021) utilizou 1.000 imagens, portanto, a base de dados foi maior que a base utilizada neste estudo.

Em relação à técnica de *Data Augmentation*, a adoção dessa técnica para ampliação da base de dados atingiu seu propósito, pois a base de dados original era de 720 imagens e após o uso dessa técnica aumentou para 4.320. Outro objetivo para o uso dessa técnica foi de aprimorar os modelos no Custom Vision para aumentar o desempenho dos indicadores, no entanto, isso não aconteceu. Os dois modelos que utilizaram essa técnica apresentaram os menores indicadores de desempenho, quando comparados aos outros modelos. Comparado a outros da literatura, o uso dessa técnica proporcionou além do aumento da base de dados, melhores indicadores após seu uso (CHOLLET; ALLAIRE, 2018; BANG et al., 2020; OTTONI; NOVO; COSTA, 2022; STAFFA et al., 2022). Diante disso, a redução dos valores de indicadores deste projeto pode estar associada às características do objeto de estudo ou das técnicas utilizadas, já que neste estudo as imagens foram apenas rotacionadas em ângulos diferentes.

Em relação às contribuições teóricas, este trabalho apresenta além da classificação de qual manifestação patológica foi identificada em imagens de fachadas de paredes de concreto, mas também apontam a localização dessas anomalias, fornecendo informações mais detalhadas aos profissionais da construção. Nesse sentido, alguns estudos sobre inspeções de fachadas focaram apenas na classificação de uma manifestação patológica, classificando em uma imagem uma categoria de defeitos (GUO et. al., 2020; GUO; LIU; YEOH; CHUA, 2020; WANG; LI, 2021). Além disso, este trabalho foi desenvolvido durante a etapa de execução e as informações identificadas subsidiaram a tomada de decisão em relação ao sistema de gestão da qualidade.

Em relação aos trabalhos desenvolvidos pelo grupo de pesquisa em que o pesquisador desta dissertação pertence, esse trabalho apresenta como contribuição o uso de drones para inspeção de fachadas. Assim como o trabalho de Álvares (2018)

que utilizou drones para coletar imagens da obra gerando nuvens de pontos e integrado ao BIM possibilitando o acompanhamento do progresso da obra, este trabalho contribui no avanço do uso de drones para apoiar o processo construtivo, buscando evitar retrabalhos, reduzir perdas e demais problemas que possam aumentar o custo da obra, bem como comprometer a qualidade do produto final.

Outros trabalhos desenvolvidos por pesquisadores do GETEC avaliaram o uso de drones para diversos fins, como a aplicabilidade de drones para inspeções de segurança em canteiros de obra (MELO et al., 2017), estudos exploratórios utilizando drones para mapeamento 3D em canteiros de obras (ÁLVARES; COSTA; MELO, 2018), uso de drones para inspeção de estruturas de telhados residenciais pós ocupação para fins de assistência técnica (SILVEIRA; MELO; COSTA, 2021) e o desenvolvimento e implementação de um sistema informatizado de inspeção de segurança para canteiros de obras usando drone e listas de verificação digitais (REY; MELO; COSTA, 2021).

Além disso, Lima e Costa (2022) propuseram recomendações e boas práticas para integração do monitoramento da segurança com drone ao planejamento e controle da qualidade de obras, Barbosa (2022) propôs um método para monitoramento visual do progresso da obra para o acompanhamento de atividades internas e externas, utilizando BIM, drones e câmera 360°, além de outros estudos utilizando essas e outras tecnologias digitais integradas.

Dessa forma, este trabalho traz como contribuições aos trabalhos que utilizam drones, desenvolvidos pelo GETEC, a integração de drones e algoritmos de aprendizado de máquina para automatizar o processo de inspeção de fachadas durante a execução. Este trabalho buscou além de testar o uso dessas tecnologias digitais para aquisição e processamento de imagens, também buscou implementar as informações geradas a partir dessas inspeções no processo de controle de qualidade da obra avaliando sua implementação em estudos de casos reais.

6. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Neste capítulo serão apresentadas as conclusões do presente trabalho, bem como sugestões para futuros trabalhos relacionados.

6.1 CONCLUSÕES DO TRABALHO

Esta dissertação teve como principal objetivo propor um método de reconhecimento automatizado para identificar falhas construtivas e manifestações patológicas em fachadas durante a execução com uso de drones e Aprendizado de Máquina visando melhoria na qualidade da obra. Para complementar o objetivo principal, foram definidos os seguintes objetivos específicos, que foram convertidos em subprodutos do estudo: (a) Identificar as possíveis manifestações patológicas em fachadas de concreto em plano vertical com imagens adquiridas com drone e analisadas por inteligência artificial durante a fase de execução de obras; (b) Utilizar algoritmos de Aprendizado de Máquina para reconhecimento automatizado de manifestações patológicas em fachadas de concreto; (c) Identificar as dificuldades e oportunidades de melhoria para incorporar os dados de inspeções de fachada na fase de execução utilizando drone e Aprendizado de Máquina no processo de controle qualidade da obra.

Diante do que foi apresentado e discutido ao longo desta dissertação é possível perceber que os objetivos propostos foram atendidos, tendo culminado nas contribuições da pesquisa. A principal contribuição deste trabalho é o método proposto que foi definido, implementado, avaliado e refinado a partir de três Estudos de Caso. Além dessa contribuição, os principais resultados do trabalho são abordados a seguir.

Identificação das possíveis manifestações patológicas em fachadas de concreto em plano vertical com imagens adquiridas com drone e analisadas por inteligência artificial durante a fase de execução de obras

Inicialmente, foram levantadas onze manifestações patológicas através de entrevistas com gestores da área de qualidade da Empresa X. A partir dos estudos em obra, observou-se que dessas onze, apenas quatro manifestações patológicas seriam possíveis de ser reconhecidas automaticamente, sendo: a) armadura exposta; b) falta de remoção das faquetas; c) fissuras; e d) ninhos de concretagem.

Essas manifestações patológicas foram selecionadas por conta de suas características em relação as demais anomalias. Ou seja, as manifestações patológicas que foram excluídas do escopo desse estudo apresentavam

características que inviabilizavam sua identificação apenas com imagens coletadas por drone, como as ondulações e alinhamento entre os pavimentos. Além disso, algumas manifestações patológicas eram mais sutis em relação a parede de concreto, como as manchas, infiltrações e tonalidades diferentes, o que dificultaria o treinamento com os algoritmos de Aprendizado de Máquina.

Uso de algoritmos de Aprendizado de Máquina para reconhecimento automatizado de manifestações patológicas em fachadas de concreto

Foram realizadas aproximadamente 20 visitas nas obras da Empresa X e no total, foram coletadas mais de 2500 imagens com uso de drones. Essas imagens foram analisadas manualmente e classificadas de acordo com as manifestações patológicas presentes nas imagens. Essa classificação subsidiou o treinamento dos algoritmos no Custom Vision. A partir dessas imagens, foram criados 6 modelos no Custom Vision que foram avaliados a partir de quatro indicadores de desempenho, sendo: **Precisão, Recall, mAP e F1 Score**.

O modelo que apresentou o melhor desempenho em relação aos indicadores Precisão, Recall, mAP e F1 Score foi o quarto modelo, também chamado de M4, apresentando 51,8%, 68,5%, 65% e 58,9%, respectivamente. Além desse modelo os modelos criados para cada manifestação patológica (M5a, M5b, M5c, M5d) apresentaram bons resultados de desempenho. Já o modelo que apresentou menor desempenho foi o sexto modelo. O que pode ter atribuído a esse baixo desempenho do M6, pode ter sido sua composição ter sido de aproximadamente 60% de imagens artificiais, a partir da utilização da técnica de *Data Augmentation*. Isso também aconteceu no desempenho do terceiro modelo (M3), que foi composto por imagens do M1 e M2, mas apresentou valores inferior aos dois modelos de origem.

Durante o trabalho observamos que a quantidade de imagens não foi o único fator preponderante para o bom desempenho dos modelos que utilizam algoritmos de Aprendizado de Máquina, pois alguns dos modelos treinados neste trabalho apresentaram bons valores durante o treinamento, mas durante os testes não reconheceram as classes rotuladas. Diante disso, observou-se que além da quantidade de imagens, a qualidade do conjunto de imagens, bem como da boa definição do problema a ser identificado em relação a imagem no geral, principalmente se tratando de manifestações patológicas em fachadas de paredes de concreto, são fatores importantes para o bom desempenho dos modelos.

Em relação as técnicas de *Data Augmentation* utilizadas neste trabalho para ampliação e estruturação da base de dados, observou-se que, por mais que em outros trabalhos essa técnica tenha contribuído para o aperfeiçoamento dos modelos, neste trabalho elas não agregaram tanto. Diante disso, as técnicas de rotação utilizadas nas imagens de fachadas de paredes de concreto moldadas in loco não apresentaram melhorias ao modelo treinado no Custom Vision.

Dificuldades e oportunidades de melhoria para incorporar os dados de inspeções de fachada na fase de execução utilizando drone e Aprendizado de Máquina no processo de controle qualidade da obra

As informações adquiridas por meio das inspeções foram incorporadas no processo de execução da obra através de relatórios, baseados no ciclo PDCA. As informações presentes nesses relatórios buscaram apoiar os gestores na tomada de decisão em relação ao controle da qualidade durante o processo construtivo. Além disso, foram realizadas reuniões com os gestores para discussão e refinamentos da melhor maneira de incorporar esse método no processo de execução da obra.

As dificuldades e oportunidade de melhoria foram discutidas na etapa de avaliação do artefato. Como forma de avaliar o método proposto, este trabalho buscou estabelecer constructos baseados na literatura e na experiência adquirida ao longo da pesquisa. Foram estabelecidos os constructos **Transparência, Eficiência e Utilidade**. Além dos constructos, foram definidos as variáveis e respectivas fontes de evidências. No total, foram estabelecidos 10 variáveis e três fontes de evidência, além disso, essas avaliações foram realizadas de acordo com as três etapas do método (aquisição, análise e implementação).

Diante disso, observou-se a oportunidade de que o método incluía outros problemas para serem reconhecidos automaticamente. Entre esses problemas, destacam-se a falta de estuque dos vazios deixados pelas faquetas e calafetação da base das paredes. Além disso, a depender da dinâmica adotada pela obra recomenda-se que o método proposto seja realizado após cada desforma, identificando as manifestações patológicas antes da plataforma de trabalho subir para o andar seguinte. Além disso, seria importante inspecionar a atividade, indicando a manifestação patológica identificada e na inspeção do próximo andar fazer a conferência se a anomalia foi tratada ou não.

Outro ponto identificado durante a avaliação do artefato foi o de alinhar a implementação com a dinâmica adotada pela obra, pois algumas realizam o

tratamento das fachadas durante a execução, antes de subir a plataforma de trabalho e outras apenas após a conclusão das paredes da torre. Além disso, é importante alinhar com os gestores quais os objetivos deles em relação ao controle da qualidade, identificando como essa atividade é realizada e como o método proposto pode auxiliar essa atividade.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

A partir das experiências obtidas nos estudos de caso, da análise geral das limitações do método proposto e com a intenção de dar continuidade a esta pesquisa, podem ser feitas as seguintes recomendações para trabalhos futuros:

- Integrar as três etapas do método proposto em uma API para automatizar ainda mais a inspeção de fachada. Nesse sentido, é necessário integrar a etapa de processamento de imagens no Custom Vision com as outras etapas reduzindo o tempo gasto com a análise manual e possibilitando a geração de relatórios automáticos em tempo hábil;
- Investigar mais obras buscando ampliar a base de dados para aprimoramento do modelo criado no Custom Vision, além de incluir outras classes de manifestações patológicas;
- Investigar e testar outras redes prontas de algoritmos para reconhecimento automatizado de manifestações patológicas em fachadas de paredes de concreto moldadas *in loco*, bem como a aplicação dessas redes em outras tipologias, elementos e sistemas construtivos, ampliando o escopo deste trabalho;
- Desenvolver uma rede própria de algoritmos para reconhecimento automatizado de manifestações patológicas em fachadas de concreto moldadas *in loco*, avaliando seu desempenho em relação aos conjuntos já existentes, com o intuito de superar as limitações dessas redes;
- Desenvolver um método para identificação de manifestações patológicas e outros defeitos em fachadas de paredes de concreto moldadas *in loco* em tempo real, com uso de drones e subconjuntos de inteligência artificial;

REFERÊNCIAS

- ALI, Omer. ISHAK, Mohamad Khairi. Bringing intelligence to IoT edge: Machine learning based smart city image classification using microsoft azure IoT and custom vision. In: **Journal of Physics: Conference Series**. p. 042076, 2020.
- ALI, Raza et al. Structural crack detection using deep convolutional neural networks. **Automation in Construction**, v. 133, p. 103989, 2022.
- ALMEIDA, L. A. **Mapeamento e diagnóstico da percepção dos colaboradores do setor de Construção Civil quanto aos Sistemas de Gestão de Qualidade**. 2015. Dissertação de Mestrado. Universidade Federal de Pernambuco.
- ÁLVARES, J. S. **Monitoramento visual do progresso de obras com uso de mapeamentos 3D de canteiros por VANT e modelos BIM 4D**. 2019. Dissertação de Mestrado, Universidade Federal da Bahia.
- ÁLVARES, J. S.; COSTA, D. B. Construction progress monitoring using unmanned aerial system and 4D BIM. **27th Annual Conference of the International Group for Lean Construction, IGLC 2019**, p. 1445–1456, 2019.
- ANDRADE, T.; SILVA, A.J.C. Patologia das Estruturas. In: ISAIA, Geraldo Cechella. (Ed) Concreto: In.: **Concreto: Ensino, Pesquisa e Realizações**. Editor: Geraldo Cechella Isaias. São Paulo: IBRACON, 2005.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). Regulamento Brasileiro da Aviação Civil Especial (RBAC-E nº94). Requisitos Gerais para Aeronaves Não Tripuladas de Uso Civil. Brasília: ANAC, 2021.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15575-1**: Edificações habitacionais - Desempenho - Parte 1: Requisitos gerais. Rio de Janeiro, 2021.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15575-2**: Edificações Habitacionais — Desempenho - Parte 2: Requisitos para os sistemas estruturais. Rio de Janeiro, 2013.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 16055**: Parede de concreto moldada no local para a construção de edificações – Requisitos e procedimentos. 1 ed. Rio de Janeiro: ABNT, 2022. 35 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT ISO 9001: 2015**: Sistema de gestão da qualidade. Ed. 3, ABNT, 2015.
- ATENCIO, E. et al. Analysis of optimal flight parameters of unmanned aerial vehicles (UAVs) for detecting potholes in pavements. **Applied Sciences (Switzerland)**, v. 10, n. 12, p. 1–33, 2020.
- AZEVEDO, M. T., Concreto: Ciência e Tecnologia: Retração e Fluência. **IBRACON**: Instituto Brasileiro do Concreto, São Paulo, 2011

AZURE, C. S. **Como aprimorar o modelo de Visão Personalizada**. 2022. Disponível em: <<https://learn.microsoft.com/pt-br/azure/cognitive-services/custom-vision-service/getting-started-improving-your-classifier>>. Acesso em 23 jan 2023.

AYELE, Yonas Zewdu et al. Automatic crack segmentation for UAV-assisted bridge inspection. **Energies**, v. 13, n. 23, p. 6250, 2020.

BACKES, André Ricardo; JUNIOR, Sá; DE MESQUITA, Jarbas Joaci. **Introdução à visão computacional usando Matlab**. Alta Books Editora, 2016.

BARTH, Fernando; VEFAGO, Luiz Henrique Maccarini. **Tecnologia de fachadas pré-fabricadas**. Letras Contemporâneas-Oficina Editorial Ltda., 2007.

BAUER, Elton et al. Relative importance of pathologies in the severity of facade degradation. **Journal of Building Pathology and Rehabilitation**, v. 5, n. 1, p. 7, 2020.

BAUER, E., et al. Facades inspection with infrared thermography: cracks evaluation. **Journal of Building Pathology and Rehabilitation**, v. 1, p. 1-7, 2016.

BADUGE, Shanaka Kristombu et al. Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. **Automation in Construction**, v. 141, p. 104440, 2022.

BIANCHI, Eric; HEBDON, Matthew. Development of Extendable Open-Source Structural Inspection Datasets. **Journal of Computing in Civil Engineering**, v. 36, n. 6, p. 04022039, 2022.

BENACHIO, G. L. F.; DUARTE, M. C.; SCHEER, S. Tecnologias emergentes para o controle da qualidade da construção civil. In: **SIMPÓSIO BRASILEIRO DE TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO NA CONSTRUÇÃO**, Campinas, SP. Anais [...]. Porto Alegre: ANTAC, 2019.

BENTO, A. Como fazer uma revisão da literatura: Considerações teóricas e práticas. **Revista JA (Associação Acadêmica da Universidade da Madeira)**, v. 7, n. 65, p. 42-44, 2012. Disponível em: <<http://www3.uma.pt/bento/Repositorio/Revisaodaliteratura.pdf>> Acesso em fev. de 2022.

BERR, L. R. **Proposta de um método para coleta, processamento e análise de dados da qualidade em obras de habitação de interesse social por um agente externo à produção**. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, UFRGS, Porto Alegre, 2010.

BOLINA, F. L, TUTIKIAN, B. F., HELENE, P. Patologia de Estruturas. **Oficina de Textos**, São Paulo, 2019.

BOUZAN, G. B. et al. Building Facade Inspection: A System Based On Automated Data Acquisition, Machine Learning, And Deep Learning Image Classification

Methods. **ARPN Journal of Engineering and Applied Sciences**, v. 16, n. 14, p. 1516–1527, 2021.

BOWN, Michael; MILLER, Kevin. The use of unmanned aerial vehicles for sloped roof inspections—considerations and constraints. **Journal of Facility Management Education and Research**, v. 2, n. 1, p. 12-18, 2018.

BOWMAN, M. et al. Investigation into Application of Artificial Intelligence to Facade. In: **EASEC16: Proceedings of The 16th East Asian-Pacific Conference on Structural Engineering and Construction, 2019**. Springer Singapore, p. 1321-1331, 2021.

BHOWMICK, Sutanu; NAGARAJAIAH, Satish; VEERARAGHAVAN, Ashok. Vision and deep learning-based algorithms to detect and quantify cracks on concrete surfaces from UAV videos. **Sensors**, v. 20, n. 21, p. 6299, 2020.

BRAGUIM, T. C. **Utilização de modelos de cálculo para projetos de edifícios de paredes de concreto armado moldadas no local**. São Paulo, 2013. Dissertação de Mestrado. Universidade de São Paulo.

BROOKS, R. A. Intelligence without representation. **Artificial intelligence**, v. 47, n. 1-3, p. 139-159, 1991.

CÂNDIDO, L. C. **Patologias em estruturas metálicas**. Ouro Preto: **UFOP**. 2005.

CARRILHO, J. A. R. S. **Utilização da tecnologia da informação com dispositivos móveis para gestão da qualidade na construção civil**. Monografia (Trabalho de conclusão de curso – Engenharia Civil) – Escola Politécnica, Universidade Federal da Bahia, Salvador, 2014.

CARDOSO, Teresa; ALARCÃO, Isabel; CELORICO, Jacinto Antunes. **Revisão da literatura e sistematização do conhecimento**. Porto Editora, 2010.

CASTAGNO, Jeremy; ATKINS, Ella. Roof shape classification from LiDAR and satellite image data fusion using supervised learning. **Sensors**, v. 18, n. 11, p. 3960, 2018.

CHA, Y.-J.; CHOI, W.; BÜYÜKÖZTÜRK, O. Deep learning-based crack damage detection using convolutional neural networks. **Computer-Aided Civil and Infrastructure Engineering**, v. 32, n. 5, p. 361-378, 2017.

CHAI, C. et al. Predicting the Service Life of Exterior Wall Painting: Techno-Economic Analysis of Alternative Maintenance Strategies. **Journal of Construction Engineering and Management**, v. 140, n. 3, p. 04013057, 2013.

CHEN, K. et al. Automated crack segmentation in close-range building façade inspection images using deep learning techniques. **Journal of Building Engineering**, v. 43, n. November 2020, p. 102913, 2021.

CHEN, L.; LUO, H. A BIM-based construction quality management model and its applications. **Automation in Construction**, v. 46, p. 64-73, 2014.

CHEN, Fu-Chen; JAHANSHAH, Mohammad R. Video-based crack detection using deep learning and Nave Bayes data fusion. In: **Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems**. p. 130-138, 2018.

CHENG, M.; KO, C. Object-oriented evolutionary fuzzy neural inference system for construction management. **Journal of Construction Engineering and Management**, v. 129, n. 4, p. 461-469, 2003.

CHEW, Michael YL. Façade inspection for falling objects from tall buildings in Singapore. **International Journal of Building Pathology and Adaptation**, n. ahead-of-print, 2021.

CHI, H. L.; WANG, J.; WANG, X.; TRUIJENS, M.; YUNG, P. A conceptual framework of quality-assured fabrication, delivery and installation processes for Liquefied Natural Gas (LNG) plant construction. **Journal of Intelligent & Robotic Systems**, v. 79, p. 433–448, 2015.

CHIARINI, Andrea. Industry 4.0, quality management and TQM world. A systematic literature review and a proposed agenda for further research. **The TQM Journal**, v. 32, n. 4, p. 603-616, 2020.

CHO, Y. S.; LIM, N. Y.; JOUNG, W. S.; JUNG, S. H.; CHOI, S. K. Management of construction fields information using low altitude close-range aerial images. **Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography**, v. 32, n. 5, p. 551–560, 2014.

CHOI, Daegyun et al. UAV-driven structural crack detection and location determination using convolutional neural networks. **Sensors**, v. 21, n. 8, p. 2650, 2021.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79-97, 2014.

COSTA, L. J. D. **Paredes de concreto moldadas *in loco* em condomínios horizontais: avaliação de desempenho pelos usuários**. 2013. 70 f. Trabalho de Diplomação (Graduação em Engenharia Civil) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

CORRÊA, Julio Marcelino. **Considerações Sobre Projeto e Execução de Edifícios em Paredes de Concreto Moldados In Loco**. 2012. 75. TCC – Departamento de Engenharia Civil, Universidade Federal de São Carlos, São Carlos, 2012.

CUBERO-FERNANDEZ, A. et al. Efficient pavement crack detection and classification. **EURASIP Journal on Image and Video Processing**, v. 2017, p. 1-11, 2017.

CUNHA, B. P. P.; **Atualização do Conceito de Qualidade na Construção Civil**. 2011. 72 f. Trabalho de Graduação (Engenharia Civil) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2011.

DAIS, D. et al. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning. **Automation in Construction**, v. 125, n. July 2020, 2021.

DADALT, D. R. **Comparação entre os processos construtivos de alvenaria estrutural e paredes de concreto sob o aspecto de custo e prazo: estudo de caso de um empreendimento de habitação de baixa renda**. 2020. TCC (Graduação) – Universidade Federal do Rio Grande do Sul, 2020. Disponível em: <https://www.lume.ufrgs.br/bitstream/handle/10183/218075/001121521.pdf?sequence=1>. Acesso em: 30 dez. 2022.

DAYAN, Peter; NIV, Yael. Reinforcement learning: the good, the bad and the ugly. **Current opinion in neurobiology**, v. 18, n. 2, p. 185-196, 2008.

DEMING, W. Edwards; **Qualidade: a revolução da administração**. Rio de Janeiro: Marques Saraiva, 1990.

DIETTERICH, Tom. Overfitting and undercomputing in machine learning. **ACM computing surveys (CSUR)**, v. 27, n. 3, p. 326-327, 1995.

DING, L. Y.; ZHOU, C. Development of web-based system for safety risk early warning in urban metro construction. **Automation in Construction**, v. 34, p. 45–55, 2013.

DONATO, H. DONATO, M. Stages for undertaking a systematic review. **Acta medica portuguesa**, v. 32, n. 3, p. 227-235, 2019.

DORAFSHAN S. ROBERT J. T., MARC M. "Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete." **Construction and Building Materials** 186 (2018): 1031-1045.

DRAGANIĆ, Suzana et al. Orthofaçade-Based Assisted Inspection Method for Buildings. **Applied Sciences**, v. 12, n. 11, p. 5626, 2022.

DRESCH, A.; LACERDA, D.P.; ANTUNES JR., J.A.V. **Design Science Research: A Method for Science and Technology Advancement**. Switzerland: Springer, 2015.

DUNG, Cao Vu. AHN, Le Duc. Autonomous concrete crack detection using deep fully convolutional neural network. **Automation in Construction**, v. 99, p. 52-58, 2019.

EDIS, E.; FLORES-COLEN, I.; DE BRITO, J. Passive thermographic detection of moisture problems in façades with adhered ceramic cladding. **Construction and Building Materials**, v. 51, p. 187-197, 2014.

ELLENBERG, A. et al. Bridge related damage quantification using unmanned aerial vehicle imagery. **Structural Control and Health Monitoring**, v. 23, n. 9, p. 1168-1179, 2016.

EMELIANOV, Sergey; BULGAKOW, Alexej; SAYFEDDINE, Daher. Aerial laser inspection of buildings facades using quadrotor. **Procedia Engineering**, v. 85, p. 140-146, 2014.

FANG, Q. et al. Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. **Automation in Construction**, v. 85, p. 1–9, 2018.

FERREIRA, J. B.; LOBÃO, V. W. N. **Manifestações patológicas na construção civil**. Aracaju: Universidade Tiradentes, 2018.

FILHO, C. V. M.; SOUZA, J. C. S.; BARREIROS, T. S. **Sistema Construtivo de Paredes de Concreto Moldadas no Local: Aspectos de Controle da Execução**. Concreto e Construções, 2013.

FLAH, Majdi; SULEIMAN, Ahmed R.; NEHDI, Moncef L. Classification and quantification of cracks in concrete structures using deep learning image-based techniques. **Cement and Concrete Composites**, v. 114, p. 103781, 2020.

FLYN, B.B.; SCHROEDER, R.G.; SAKAKIBARA, S. **A framework for quality management research and an associated measurement instrument**. Journal of Operations Management. v.11, p.339-366, 1994.

FOIATO, M.; REGINATO, L. A.; PIOVESAN, A. Z. **Avaliação da resistência à compressão do concreto curado em baixa temperatura**. Unoesc & Ciência-ACET, v. 4, n. 2, p. 149-156, 2013.

GAJJAR, Dhaval; BURGETT, Joseph. Evaluating the Use of Unmanned Aerial Systems (UAS) to Perform Low-Slope Roof Inspections. **EPiC Series in Built Environment**, v. 1, p. 214-222, 2020.

GALLETTO, Adriana; ANDRELLO, José Mario. Patologia em fachadas com revestimentos cerâmicos. In: **CINPAR–IX Congresso Internacional sobre Patología y Recuperación de Estructuras, João Pessoa (Brasil)**. 2013.

GARVIN, David. Competing on the eight dimensions of quality. **Harv. Bus. Rev.**, p. 101-109, 1987.

GARVIN, David A. **Gerenciando a qualidade: a visão estratégica e competitiva**. Qualitymark Editora Ltda, 1992.

GENTIL, V. Corrosão. 5. ed. Rio de Janeiro: LTC – Livros Técnicos e Científicos. **Editora S.A.**, 2007.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. " O'Reilly Media, Inc.", 2022.

GIROTTI, L. S.; BARBOSA, M. P.; MACIEL, G. F. Avaliação do comportamento reológico na retração plástica e na fissuração de argamassas de concreto auto-adensável. **Revista IBRACON de Estruturas e Materiais**, v. 7, p. 24-52, 2014.

GHOSH, A. et al. Fundamental concepts of convolutional neural network. In: **Recent Trends and Advances in Artificial Intelligence and Internet of Things**. Springer, p. 519-567, 2020.

GHOSH-MONDAL. T., et al. "Deep learning-based multi-class damage detection for autonomous post-disaster reconnaissance." **Structural Control and Health Monitoring** 27.4 (2020): e2507.

GOODFELLOW, I., BENGIO, Y., COURVILLE, A. **Deep learning**. MIT press, 2016.

GUO, Jingjing et al. Façade defects classification from imbalanced dataset using meta learning-based convolutional neural network. **Computer-Aided Civil and Infrastructure Engineering**, v. 35, n. 12, p. 1403-1418, 2020.

GUO, Jingjing; WANG, Qian; LI, Yiting. Semi-supervised learning based on convolutional neural network and uncertainty filter for façade defects classification. **Computer-Aided Civil and Infrastructure Engineering**, v. 36, n. 3, p. 302-317, 2020.

HAN, D. et al. Change detection in unmanned aerial vehicle images for progress monitoring of road construction. **Buildings**, v. 11, n. 4, p. 1–14, 2021.

HANDELMAN, Guy S. et al. Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods. **American Journal of Roentgenology**, v. 212, n. 1, p. 38-43, 2019.

HELENE, P. **Manual para reparo, reforço e proteção de estruturas de concreto**. São Paulo: Editora Pini. (1992).

HELENE, Paulo RL. Vida útil das estruturas de concreto. In: **IV Congresso Iberoamericano de Patologia das Construções. Anais... Porto Alegre, RS. 1997**.

HEVNER, A. CHATTERJEE, S. Design science research in information systems. **Design research in information systems: theory and practice**, p. 9-22, 2010.

HOANG, N. D. Image Processing-Based Recognition of Wall Defects Using Machine Learning Approaches and Steerable Filters. **Computational Intelligence and Neuroscience**, v. 2018, 2018.

HOSKERE, V., et al. "MaDnet: multi-task semantic segmentation of multiple types of structural materials and damage in images of civil infrastructure." **Journal of Civil Structural Health Monitoring**, v. 10, pp. 757-773, 2020.

HUBBARD, B.; HUBBARD, S. Unmanned aircraft systems (Uas) for bridge inspection safety. **Drones**, v. 4, n. 3, p. 1–18, 2020.

HYDRONORTH. Ficha técnica massa corrida. Disponível em: <https://www.hydrnorth.com.br/Static/Uploads/Site/Info/Pdf/lhMZQcQJD65LrNsOGINyAQ36fKkMsRVU8WNgc4BXkfg=.pdf>. Acesso em janeiro, 2023

ILIN, R.; WATSON, T.; KOZMA, R. Abstraction hierarchy in deep learning neural networks. In: **2017 International Joint Conference on Neural Networks (IJCNN)**. IEEE, p. 768-774, 2017.

ISHIKAWA, K. **Controle de qualidade total: à maneira japonesa**. Rio de Janeiro: Campos, p..79, 1993.

IIVARI, Juhani; VENABLE, John R. Action research and design science research- Seemingly similar but decisively dissimilar. 2009.

JALINOOS, F. et al. Experimental Evaluation of Unmanned Aerial System for Measuring Bridge Movement. **Journal of Bridge Engineering**, v. 25, n. 1, p. 04019132, 2020.

JANG, K. et al. Automated crack evaluation of a high-rise bridge pier using a ring-type climbing robot. **Computer-Aided Civil and Infrastructure Engineering**, v. 36, n. 1, p. 14-29, 2021.

JANUZZI, U. A.; VERCESI, C. **Sistema de gestão da qualidade na construção civil: um estudo a partir da experiência do PBQP-H junto às empresas construtoras da cidade de Londrina**. Revista Gestão Industrial, v. 06, n. 03, p. 136-160. 2010.

JIANG, Shang; ZHANG, Jian. Real-time crack assessment using deep neural networks with wall-climbing unmanned aerial system. **Computer-Aided Civil and Infrastructure Engineering**, v. 35, n. 6, p. 549-564, 2020.

JAPKOWICZ, Nathalie; SHAH, Mohak. Performance evaluation in machine learning. **Machine Learning in Radiation Oncology: Theory and Applications**, p. 41-56, 2015.

JORDAN, Michael I.; MITCHELL, Tom M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255-260, 2015.

JUCÁ, Tatiana Renata Pereira; OLIVEIRA, Janes Cleiton Alves de; ZANONI, Vanda Alice Garcia. Uso do drone como tecnologia disruptiva na inspeção de fachadas. In: **PATRIMÔNIO 4.0**, v. 3, 2022, Goiânia. Anais [...]. Goiânia: LASUS FAU, 2022. Disponível em: <https://www.patrimonio40.tec.br/anais>. Acesso em: 20 nov. 2022.

JURAN, J. M.; GRZYNA, Frank M.; JURAN, Controle de Qualidade. Handbook: Conceitos, políticas e filosofia da qualidade. **São Paulo: Makron, McGraw-Hill**, v.1, 1991.

JUNIOR, J. J. M. S.; BACKES, A. R. ELM based signature for texture classification. **Pattern Recognition**, v. 51, p. 395-401, 2016.

KANG, Dongho; CHA, Young-Jin. Autonomous UAVs for structural health monitoring using deep learning and an ultrasonic beacon system with geo-tagging. **Computer-Aided Civil and Infrastructure Engineering**, v. 33, n. 10, p. 885-902, 2018.

KAYNAK, H.; HARTLEY, J. L. Exploring quality management practices and high-tech firm performance. **The Journal of High Technology Management Research**, v. 16, n. 2, p. 255-272, 2005.

KIM, Byunghyun; CHO, Soojin. Automated vision-based detection of cracks on concrete surfaces using a deep learning technique. **Sensors**, v. 18, n. 10, p. 3452, 2018.

KIM, S.; IRIZARRY, J. Exploratory Study on Factors Influencing UAS Performance on Highway Construction Projects: as the Case of Safety Monitoring Systems. In: Conference on Autonomous and Robotic Construction of Infrastructure, 2015, Ames. **Proceedings...** Ames: Iowa State University, 2015.

KIM, Hyunjun et al. Crack identification method for concrete structures considering angle of view using RGB-D camera-based sensor fusion. **Structural Health Monitoring**, v. 20, n. 2, p. 500-512, 2021.

KUNG, Ren-Yi et al. Application of deep learning and unmanned aerial vehicle on building maintenance. **Advances in Civil Engineering**, v. 2021, p. 1-12, 2021.

TCHENHAM, B. Procedures for performing systematic reviews. **Technical Report TR/SE-0401**. Keele: Keele University and NICTA, p. 28, 2004.

KOEHRSEN W. **Beyond Accuracy: Precision and Recall. 2018**. Disponível em: <<https://willkoehrsen.github.io/statistics/learning/beyond-accuracy-precision-and-recall/>>. Acesso 16 dez. 2022.

KUMARAPU, K.; SHASHI, M.; KEESARA, V. R. UAV in Construction Site Monitoring and Concrete Strength Estimation. **Journal of the Indian Society of Remote Sensing**, v. 49, n. 3, p. 619–627, 2021.

KUNG, R.Y., et al. "Application of Deep Learning and Unmanned Aerial Vehicle on Building Maintenance." **Advances in Civil Engineering** 2021 (2021).

LACERDA, Daniel Pacheco et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & produção**, v. 20, p. 741-761, 2013.

LEAL, Ana Carolina Martelleto; RIBEIRO, Maria Izabel de Paula. Implantação do Sistema de Qualidade na construção civil com ênfase na inspeção de serviço. **Projectus**, v. 1, n. 4, p. 84-96, 2017.

LE, Tien-Thinh; NGUYEN, Van-Hai; LE, Minh Vuong. Development of deep learning model for the recognition of cracks on concrete surfaces. **Applied computational intelligence and soft computing**, v. 2021, p. 1-10, 2021.

LI, Gang et al. Automatic bridge crack identification from concrete surface using ResNeXt with postprocessing. **Structural Control and Health Monitoring**, v. 27, n. 11, p. e2620, 2020.

LIANG, X. Image-based post-disaster inspection of reinforced concrete bridge systems using deep learning with Bayesian optimization. **Computer-Aided Civil and Infrastructure Engineering**, v. 34, n. 5, p. 415–430, 2019.

LIMA, Mahara Iasmine Sampaio Cardoso. **Recomendações e boas práticas para integração do monitoramento de obras com VANT para a melhoria contínua do planejamento e controle da**. 2021. 183 f. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal da Bahia, Salvador.

LIN, C. et al. Real-time foreground object segmentation networks using long and short skip connections. **Information Sciences**, v. 571, p. 543–559, 2021a.

LIN, J. J. et al. Bridge Inspection with Aerial Robots: Automating the Entire Pipeline of Visual Data Capture, 3D Mapping, Defect Detection, Analysis, and Reporting. **Journal of Computing in Civil Engineering**, v. 35, n. 2, p. 04020064, 2021b.

LIN, K. Y. et al. A user-centered information and communication technology (ICT) tool to improve safety inspections. **Automation in Construction**, v. 48, p. 53–63, 2014.

LIU, Kangcheng; CHEN, Ben M. Industrial uav-based unsupervised domain adaptive crack recognitions: From system setups to real-site infrastructural inspections. **IEEE Transactions on Industrial Electronics**, 2022.

LIU, Y. F. et al. Image-based crack assessment of bridge piers using unmanned aerial vehicles and three-dimensional scene reconstruction. **Computer-Aided Civil and Infrastructure Engineering**, v. 35, n. 5, p. 511–529, 2020.

LIU, Y.; YEOH, J. K. W.; CHUA, D. K. H. Deep Learning–Based Enhancement of Motion Blurred UAV Concrete Crack Images. **Journal of Computing in Civil Engineering**, v. 34, n. 5, p. 04020028, 2020.

LOBO, R. N. **Gestão da Qualidade**, São Paulo: Ed. Érica, 1º Edição, 2010.

LOTTERMANN, Fabrício Nunes da. **Patologias em estruturas de concreto: estudo de caso**. Trabalho de Conclusão do Curso de Graduação em Engenharia Civil, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2013.

LUO, Cai et al. Autonomous detection of damage to multiple steel surfaces from 360 panoramas using deep neural networks. **Computer-Aided Civil and Infrastructure Engineering**, v. 36, n. 12, p. 1585-1599, 2021.

MAHESH, B. Machine learning algorithms -a review. *International Journal of Science and Research (IJSR)*, v. 01, 2019.

MANDAL, Vishal; UONG, Lan; ADU-GYAMFI, Yaw. Automated road crack detection using deep convolutional neural networks. In: **2018 IEEE International Conference on Big Data (Big Data)**. IEEE, p. 5212-5215, 2018.

MARCH, S. T.; SMITH, G. F. Design and natural science research on information technology. **Decision Support Systems**, v. 15, p. 251-266, 1995.

MARTINEZ, J.; GHEISARI, M.; ALARCÓN, L. UAV Integration in Current Construction Safety Planning and Monitoring Processes: Case Study of a High-Rise Building Construction Project in Chile. **Journal of Management in Engineering**, vol. 36 (3), 05020005, 2020.

MATTOS, A. D. **Planejamento e Controle de Obras**. São Paulo: Editora Pini, 2010. 244 p.

MAZER, W. **Patologia, recuperação e reforço de estruturas de concreto**. Engenharia civil. Universidade Tecnológica Federal Do Paraná, Curitiba, 2008.

MCCORDUCK, P.; CFE, C. **Machines who think: A personal inquiry into the history and prospects of artificial intelligence**. CRC Press, 2004.

MEDEIROS, H. **Doenças concretas**. Revista Técnica, São Paulo, n. 160, p. 62-68, jul. 2010.

MEDEIROS JUNIOR, Ronaldo Alves de; LIMA, Maryangela Geimba de; BALESTRA, Carlos Eduardo Tino. Identificação das Principais Manifestações Patológicas em Estruturas de Concreto Armado Pertencentes ao DCTA. In: **Congresso Internacional sobre Patologia e Reparação de Estruturas**, p. 1-9, 2013.

MELO, R. R. S. **Diretrizes para inspeção de segurança em canteiros de obra por meio de imageamento com veículo aéreo não tripulado (VANT)**. Salvador, 2016. 160 p. Dissertação (Mestrado em Engenharia Civil) - Escola Politécnica, Universidade Federal de Bahia, Salvador, 2016.

MELO, R. R. S. **Modelo para desenvolvimento e aperfeiçoamento dos potenciais para resiliência assistido por meio do monitoramento da segurança com VANT**. 2020. 261 f. Tese (Doutorado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal da Bahia, Salvador.

MELO, R. R. S. de; COSTA, D. B.; ÁLVARES, J. S.; IRIZARRY, J. Applicability of Unmanned Aerial System (UAS) for safety inspection on construction sites. **Safety Science**, v. 98, p. 174-185, 2017.

MÉSZÁROSOVÁ, L. TUMOVA, E. DROCHYTKA, R. Epoxy screed as possible protection of floor surfaces. In: **Advanced Materials Research**. Trans Tech Publications Ltd, p. 166-169, 2015.

MEKONNEN, Yemeserach et al. Machine learning techniques in wireless sensor network based precision agriculture. **Journal of the Electrochemical Society**, v. 167, n. 3, p. 037522, 2020.

MESOMO, M.F. **Manifestações patológicas em unidades habitacionais construídas com paredes de concreto moldadas in loco com fôrmas metálicas: análise das falhas observadas na etapa de execução**. Trabalho de Diplomação

apresentado à Comissão de Graduação do Curso de Engenharia Civil da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, 2018.

MIGUEL, P. A. C. **Qualidade: Enfoques e Ferramentas**, São Paulo: Artliber Editora, 2001.

MNIH, Volodymyr et al. Human-level control through deep reinforcement learning. **nature**, v. 518, n. 7540, p. 529-533, 2015.

MISURELLI, H.; MASSUDA, C. Como construir Paredes de Concreto. **Revista Técnica**, São Paulo, n. 147, 2009.

MONDAL, Bhaskar. Artificial intelligence: state of the art. **Recent Trends and Advances in Artificial Intelligence and Internet of Things**, p. 389-425, 2020.

MONDAL, Tarutal Ghosh; JAHANSHAH, Mohammad Reza. Applications of computer vision-based structural health monitoring and condition assessment in future smart cities. **The Rise of Smart Cities**, p. 193-221, 2022.

MONTOYA, M. D. A. et al. A context-driven model for the flat roofs construction process through sensing systems, internet-of-things and last planner system. **Sensors (Switzerland)**, v. 17, n. 7, 2017.

MOHER, D., LIBERATI A. TETZLAFF J. ALTMAN D.G. The PRISMA Group (2009) Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. **PLoS Med** 6(7): e1000097. <https://doi.org/10.1371/journal.pmed.1000097>

MOREIRA, A.B. **Deficiências na implantação e manutenção do sistema de gestão da qualidade pelas construtoras: estudo de caso**. Monografia (Trabalho de conclusão de curso – Engenharia Civil) - Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2016.

MORGENTHAL, G.; HALLERMANN, N. Quality Assessment of Unmanned Aerial Vehicle (UAV) Based Visual Inspection of Structures. **Advances in Structural Engineering**, v. 17, n. 3, p. 289-302, 2014.

MORGENTHAL, G., et al. "Framework for automated UAS-based structural condition assessment of bridges." **Automation in Construction**, v. 97, p. 77-95, 2019.

MUNAWAR, Hafiz Suliman et al. Civil infrastructure damage and corrosion detection: An application of machine learning. **Buildings**, v. 12, n. 2, p. 156, 2022.

MÜLLER, A. C.; GUIDO, S. **Introduction to machine learning with Python: a guide for data scientists**. " O'Reilly Media, Inc.", 2016.

NEMER, Pedro Curvello da Costa et al. Avaliação do sistema construtivo paredes de concreto moldado no local a luz das normas técnicas vigentes. 2016.

NESE, P. L. Gestão de Qualidade: Manual de Implantação para Empresas de Projetos de Edificações. São Paulo: **Pini**, 2013.

NETO, Natália; DE BRITO, J. Inspection and defect diagnosis system for natural stone cladding. **Journal of Materials in Civil Engineering**, v. 23, n. 10, p. 1433-1443, 2011.

NEVILLE, A.M. Propriedades do concreto. 5.ed. Porto Alegre: **Bookman**, 2016

NOCÊRA, R.J. **Planejamento e Controle de Obras com o MS-Project 2010**. 1. ed. São Paulo: RJN Publicações, 2010.

NOGUEIRA, J. L. T., JÚNIOR, L. B. S., COSTA, D. B. Plataforma web para inspeção de estruturas de telhados para fins de assistência técnica com uso de drone e inteligência artificial. In: **CUNHA, C. Prêmio Ademi de inovação acadêmica**. Salvador, 2022, pp. 32-43.

OLIVEIRA, Henrique; CORREIA, Paulo Lobato. Automatic road crack detection and characterization. **IEEE Transactions on Intelligent Transportation Systems**, v. 14, n. 1, p. 155-168, 2012.

OLIVEIRA, I. M. **Desenvolvimento de ferramenta computacional para obtenção automática de deslocamento e anotação de outros parâmetros em testes comportamentais do tipo campo aberto**. Dissertação (Mestrado em Física Aplicada) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2014.

OH, Sukjoon; HAM, Suyeon; LEE, Seongjin. Drone-assisted image processing scheme using frame-based location identification for crack and energy loss detection in building envelopes. **Energies**, v. 14, n. 19, p. 6359, 2021.

ORING, Alon. Fast and Robust Structural Damage Analysis of Civil Infrastructure Using UAV Imagery. In: **Proceedings of the 1st Conference of the European Association on Quality Control of Bridges and Structures: EUROSTRUCT** Springer International Publishing, p. 1251-1260, 2022.

OTTONI, André Luiz Carvalho; NOVO, Marcela Silva; COSTA, Dayana Bastos. Hyperparameter tuning of convolutional neural networks for building construction image classification. **The Visual Computer**, v. 39, n. 3, p. 847-861, 2022.

PALADINI, Edson Pacheco. Gestão da qualidade: teoria e prática. In: **Gestão da qualidade: teoria e prática**. 2ª ed. São Paulo: **Atlas**, p. 339-339, 2010.

PANELLA, F. et al. Deep learning and image processing for automated crack detection and defect measurement in underground structures. In: **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives**. ISPRS SC, p. 829-835. 2018.

PAPADOPOULOS, Ellena; GONZALEZ, Felipe. UAV and AI application for runway foreign object debris (FOD) detection. In: **IEEE Aerospace Conference**. IEEE, p. 1-8, 2021.

PEJČINOVIĆ, Matea. A review of custom vision service for facilitating an image classification. In: **Central European Conference on Information and Intelligent Systems**. Faculty of Organization and Informatics Varazdin, p. 197-208. 2019.

PETER, Angela Paul et al. Artificial intelligence model for monitoring biomass growth in semi-batch *Chlorella vulgaris* cultivation. **Fuel**, v. 333, p. 126438, 2023.

PICCHI, F. A. **Sistemas de Qualidade: uso em empresas de construção**, 1993. 178 f. Tese (Doutorado em Engenharia Civil) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1993.

POSSAN, E.; ALBERTO DEMOLINER, C. Desempenho, Durabilidade E Vida Útil Das Edificações: Abordagem Geral. **Revista Técnico-Científica**, v. 1, p. 14, 2013.

POZZOLO, Andrea et al. Calibrating probability with undersampling for unbalanced classification. In: **2015 IEEE symposium series on computational intelligence**. IEEE, p. 159-166, 2015.

POTENZA, F., et al. "A robotics and computer-aided procedure for defect evaluation in bridge inspection." **Journal of Civil Structural Health Monitoring** 10.3 (2020): 471-484.

PRINCE, S. J.D. **Computer vision: models, learning, and inference**. Cambridge University Press, 2012.

PURI, A. **A Survey of Unmanned Aerial Vehicles (UAV) for Traffic Surveillance**. Department of computer science and engineering, University of South Florida, 2005.

PURI, N.; TURKAN, Y. Bridge construction progress monitoring using lidar and 4D design models. **Automation in Construction**, v. 109, n. April 2019, p. 102961, 2020.

PROTOPAPADAKIS, Eftychios et al. Automatic crack detection for tunnel inspection using deep learning and heuristic image post-processing. **Applied intelligence**, v. 49, p. 2793-2806, 2019.

RAFIEI, M. H. et al. Supervised Deep Restricted Boltzmann Machine for Estimation of Concrete. **ACI Materials Journal**, v. 114, n. 2, p. 237–245, 2017.

RAFIEI, M. H.; ADELI, H. Novel Machine-Learning Model for Estimating Construction Costs Considering Economic Variables and Indexes. **Journal of Construction Engineering and Management**, v. 144, n. 12, p. 04018106, 2018a.

RAFIEI, M. H.; ADELI, H. A novel unsupervised deep learning model for global and local health condition assessment of structures. **Engineering Structures**, v. 156, n. July 2017, p. 598–607, 2018b.

RAKHA, Tarek; GORODETSKY, Alice. Review of Unmanned Aerial System (UAS) applications in the built environment: Towards automated building inspection procedures using drones. **Automation in Construction**, v. 93, p. 252-264, 2018.

RIBEIRO, D. et al. Remote inspection of RC structures using unmanned aerial vehicles and heuristic image processing. **Engineering Failure Analysis**, v. 117, p. 104813, 2020.

RIBEIRO, Diogo et al. Remote Inspection and Monitoring of Civil Engineering Structures Based on Unmanned Aerial Vehicles. In: **Proceedings of the 1st Conference of the European Association on Quality Control of Bridges and Structures: EUROSTRUCT**. Springer International Publishing, p. 695-703, 2022.

REN, Yupeng et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks. **Construction and Building Materials**, v. 234, p. 117367, 2020.

REY, R. O. **Sistema informatizado para inspeção da segurança em canteiros de obra apoiado por VANT, dispositivos móveis e técnicas de reconhecimento de padrão**. 2020. 254 f. (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Engenharia Civil, Universidade Federal da Bahia, Salvador.

ROTHER, Carsten; KOLMOGOROV, Vladimir; BLAKE, Andrew. "GrabCut" interactive foreground extraction using iterated graph cuts. **ACM transactions on graphics (TOG)**, v. 23, n. 3, p. 309-314, 2004.

ROCHA, A. F. Paredes de concreto moldadas "in loco" com revestimento cerâmico: estudo de caso das manifestações patológicas em obra de edifícios multifamiliares-Macaé/RJ. **Trabalho de Conclusão de Curso** (Engenharia Civil). Instituto Politécnico, Universidade Federal do Rio de Janeiro, Macaé, 2022.

RUIZ, R. D. B. et al. Unmanned aerial vehicles (UAV) as a tool for visual inspection of building facades in AEC+FM industry. **Construction Innovation**, 2021.

SAMPAIO, Grégory Gonçalves et al. PATOLOGIAS EM PAREDE DE CONCRETO. **Revista de Trabalhos Acadêmicos Universo, São Gonçalo**, Nº 1, 2016

SANTOS, C. F. **Patologia de estruturas de concreto armado**. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Universidade Federal de Santa Maria, Rio Grande do Sul, 2014.

SCARI, P., SANTOS, O., Patologia em Estruturas de Concreto Armado. **Revista Boletim de Gerenciamento**, v.24 n. 24, Politécnica UFRJ, Rio de Janeiro, 2021.

SILVA, A., de BRITO, J., GASPAS, P.L. Service life and durability of assemblies. **Methodologies for Service Life Prediction of Buildings: With a Focus on Façade Claddings**, p. 13-66, 2016.

SILVA, A. F. **Manifestações patológicas em fachadas com revestimentos argamassados: Estudo de caso em edifícios em Florianópolis**. 2007. Dissertação de Mestrado em Arquitetura e Urbanismo, Universidade Federal de Santa Catarina, Florianópolis, 2007.

SILVA, D. R. C.; FIGUEIREDO, F. B. **Patologia em estruturas de concreto armado: estudo de caso aplicado às obras inacabadas e concluídas do Campus II da UFGD**. 2018. Disponível em: <<https://repositorio.ufgd.edu.br/jspui/bitstream/prefix/1966/1/DanielaRodriguesCostaeSilva.pdf>>. Acesso: 07 de janeiro de 2022.

SILVA, Naiara Cristina; JUNIOR, Carlos Francisco Minari; FLORIAN, Fabiana. **Estudo comparativo entre alvenaria estrutural em blocos de concreto versus paredes em concreto moldadas no local da edificação: viabilização econômica.** RECIMA21-Revista Científica Multidisciplinar-ISSN 2675-6218, v. 3, n. 1, p. e3122496-e3122496, 2022. <https://doi.org/10.47820/recima21.v3i12.2496>

SILVA, Wilson Ricardo Leal da; LUCENA, Diogo Schwerz de. Concrete cracks detection based on deep learning image classification. In: **Proceedings.** MDPI, p. 489. 2018.

SILVA, F. B. D. **Patologia das construções: uma especialidade na engenharia civil.** Técnica, n. 174, setembro, 2011.

SILVEIRA, B.; MELO R.; COSTA D.B. (2021) Using UAS for Roofs Structure Inspections at Post-occupational Residential Buildings. In: Toledo Santos E., Scheer S. (eds) **Proceedings of the 18th International Conference on Computing in Civil and Building Engineering.** ICCCBE 2020. Lecture Notes in Civil Engineering, vol 98. Springer, Cham. https://doi.org/10.1007/978-3-030-51295-8_73

SILVESTRE, J. Dinis; DE BRITO, Jorge. Inspection and repair of ceramic tiling within a building management system. **Journal of Materials in Civil Engineering**, v. 22, n. 1, p. 39-48, 2010.

SIMON, H. A. **The Sciences of the Artificial.** 3ª ed. Cambridge: MIT Press, 1996.

SINGH, P. K. et al. (Ed.). **Proceedings of ICRIC 2019.** Springer International Publishing, 2020. Disponível em: <<https://doi.org/10.1007/978-3-030-29407-6>>, Acesso em 20 Dez 2022.

SIU, M. F.; LU, M. Augmented-reality visualizations of bored pile construction. **Proceedings of the Annual Conference of the Canadian Society for Civil Engineering**, v. 3, p. 2437-2446, 2011.

SHOTTON, Jamie et al. Textonboost for image understanding: Multi-class object recognition and segmentation by jointly modeling texture, layout, and context. **International journal of computer vision**, v. 81, n. 1, p. 2-23, 2007.

SOILÁN, M. et al. Review of laser scanning technologies and their applications for road and railway infrastructure monitoring. **Infrastructures**, v. 4, n. 4, 2019.

SOUZA, J. et al. Evaluation of the deterioration of ceramic claddings by application of artificial neural networks. **Journal of Performance of Constructed Facilities**, v. 34, n. 5, p. 1-10, 2020.

SOUZA, R. et al. **Sistema de Gestão de Qualidade para Empresas Construtoras.** São Paulo: Pini, 1995.

SOUZA, R.; ABIKO, A. **Metodologia para desenvolvimento e implantação de sistemas de gestão da qualidade em empresas construtoras de pequeno e médio porte.** São Paulo, v. 335, 1997.

SOUZA, V. C.; RIPPER, T. **Patologia, recuperação e reforço de estruturas de concreto**. São Paulo: Pini, 1998.

SOUZA, V. C. M.; RIPPER, T. **Patologia, Recuperação e Reforço de Estruturas de Concreto**. São Paulo: Pini, 2009.

SUKSTER, R. **A integração entre o sistema de gestão da qualidade e o planejamento e controle da produção em empresas construtoras**. 2005. 158 f. Trabalho de conclusão 98 (Mestrado Profissionalizante em Engenharia) - Escola de Engenharia, UFRGS, Porto Alegre, 2005.

SULTANA, F.; SUFIAN, A.; DUTTA, P. Advancements in image classification using convolutional neural network. In: **2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)**. IEEE. p. 122-129, 2018.

SULTANA, F.; SUFIAN, A.; DUTTA, P. A review of object detection models based on convolutional neural network. **Intelligent Computing: Image Processing Based Applications**, p. 1-16, 2020.

STAFFA, L. B. SÁ, L. S.V. LIMA, M. I. S. C. COSTA, D. B. Uso de técnicas de processamento de imagem para inspeção de estruturas de telhados de edificações para fins de assistência técnica. **Encontro Nacional De Tecnologia No Ambiente Construído**, p. 1-8, 2020.

STOCHINO, F. FADDA, M. L.; MISTRETTA, F. Low cost condition assessment method for existing RC bridges. **Engineering Failure Analysis**, v. 86, p. 56-71, 2018.

SZELISKI, R. **Computer vision: algorithms and applications**. Springer Science & Business Media, 2010.

TAKATA, Leandro Teixeira. **Aspectos executivos e a qualidade de estruturas em concreto armado: estudo de caso**. 2009.

TEZEL, A.; AZIZ, Z. From conventional to it based visual management: A conceptual discussion for lean construction. **Journal of Information Technology in Construction**, v. 22, p. 220–246, 2017.

TILON, Sofia et al. Towards Improved Unmanned Aerial Vehicle Edge Intelligence: A Road Infrastructure Monitoring Case Study. **Remote Sensing**, v. 14, n. 16, p. 4008, 2022.

THOMAZ, E. **Tecnologia, Gerenciamento e Qualidade na Construção**. São Paulo: Pini, 2001

THOMAZ, E., **Trincas em Edifícios**. **Oficina de Textos**, 2ª ed., São Paulo, 2020.

TUTIKIAN, B., MOLIN, D. D., **Concreto Autoadensável**, 3ªed. **Livraria e Editora Universitária de Direito**, São Paulo, 2021.

VAISHNAVI, V. K.; KUECHLER, W. K. **Methods and Patterns: Innovating Information and Communication Technology**. 2. ed. New York: Auerbach Publications, Taylor & Francis Group, 2015.

VALENÇA, J. et al. Assessment of cracks on concrete bridges using image processing supported by laser scanning survey. **Construction and Building Materials**, v. 146, p. 668-678, 2017.

VAN AKEN, Joan Ernst; BERENDS, Hans. **Problem solving in organizations**. Cambridge university press, 2018.

VAN AKEN, J. E., ROMME, G. Reinventing the future: adding design Science to the repertoire of organization and management studies. **Organization Management Journal**, v. 6, p. 5-12, 2009.

VARGAS, Ana Caroline Gomes; PAES, Aline; VASCONCELOS, Cristina Nader. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: **Proceedings of the xxix conference on graphics, patterns and images**. sn, 2016.

VETRIVEL, Anand et al. Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high resolution oblique aerial images, and multiple-kernel-learning. **ISPRS journal of photogrammetry and remote sensing**, v. 140, p. 45-59, 2018.

VIOLA, Paul; JONES, Michael J. Robust real-time face detection. **International journal of computer vision**, v. 57, n. 2, p. 137-154, 2004.

VOTORANTIM. Ficha técnica de produto: AC III Flexível Cinza – Votomassa. Disponível em <<https://www.votorantimcimentos.com.br/wpcontent/uploads/2015/12/votomassa-aciii-cinza-ficha-tecnica.pdf>>. Acesso em jan. 2023.

XU, Hongyan et al. Automatic bridge crack detection using a convolutional neural network. **Applied Sciences**, v. 9, n. 14, p. 2867, 2019.

XU, J.; GUI, C.; HAN, Q. Recognition of rust grade and rust ratio of steel structures based on ensembled convolutional neural network. **Computer-Aided Civil and Infrastructure Engineering**, v. 35, n. 10, p. 1160–1174, 2020.

XU, Yayin et al. Machine learning in construction: From shallow to deep learning. **Developments in the Built Environment**, p. 100045, 2021.

YOON, Sungsik et al. A novel approach to assess the seismic performance of deteriorated bridge structures by employing UAV-based damage detection. **Structural Control and Health Monitoring**, v. 29, n. 7, p. e2964, 2022.

YUSOF, H.; AHMAD, M. A.; ABDULLAH, A. M. T. Historical building inspection using the unmanned aerial vehicle (UAV). **International Journal of Sustainable Construction Engineering and Technology**, v. 11, n. 3, p. 12–20, 2020.

ZAITOUN, N. M.; AQEL M. J. Survey on image segmentation techniques. **Procedia Computer Science**, v. 65, p. 797-806, 2015.

ZHANG, A. et al. Automated Pixel-Level Pavement Crack Detection on 3D Asphalt Surfaces Using a Deep-Learning Network. **Computer-Aided Civil and Infrastructure Engineering**, v. 32, n. 10, p. 805–819, 2017.

ZHANG, C.; ARDITI, D. Advanced progress control of infrastructure construction projects using terrestrial laser scanning technology. **Infrastructures**, v. 5, n. 10, p. 1–18, 2020.

ZHANG, H. et al. Development of a Safety Inspection Framework on Construction Sites Using Mobile Computing. **Journal of Management in Engineering**, v. 33, n. 3, p. 04016048, 2016.

ZHANG, K.; CHENG, H. D.; ZHANG, B. Unified Approach to Pavement Crack and Sealed Crack Detection Using Preclassification Based on Transfer Learning. **Journal of Computing in Civil Engineering**, v. 32, n. 2, p. 04018001, 2018.

ZHOU, Y.; LUO, H.; YANG, Y. Implementation of augmented reality for segment displacement inspection during tunneling construction. **Automation in Construction**, v. 82, p. 112–121, 2017.

ZHU, Qiuchen et al. Hierarchical convolutional neural network with feature preservation and autotuned thresholding for crack detection. **IEEE Access**, v. 9, p. 60201-60214, 2021.

ZONNENSHAIN, Avigdor; KENETT, Ron S. Quality 4.0 - the challenging future of quality engineering. **Quality Engineering**, v. 32, n. 4, p. 614-626, 2020.

YEUM, Chul Min; CHOI, Jongseong; DYKE, Shirley J. Automated region-of-interest localization and classification for vision-based visual assessment of civil infrastructure. **Structural Health Monitoring**, v. 18, n. 3, p. 675-689, 2019.

WU, Yunpeng et al. Hybrid deep learning architecture for rail surface segmentation and surface defect detection. **Computer-Aided Civil and Infrastructure Engineering**, v. 37, n. 2, p. 227-244, 2022.

APÊNDICE A - LISTA DE ARTIGOS DA RSL

AUTOR	ANO	TÍTULO
Ellenberg et al.	2016	Bridge related damage quantification using unmanned aerial vehicle imagery
Valenca et al.	2017	Assessment of cracks on concrete bridges using image processing supported by laser scanning survey
Kang, Cha e Young-Jin	2018	Autonomous UAVs for Structural Health Monitoring Using Deep Learning and an Ultrasonic Beacon System with Geo-Tagging
Castagno e Atkins	2018	Roof shape classification from LiDAR and satellite image data fusion using supervised learning
Vetrivel et al.	2018	Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high-resolution oblique aerial images, and multiple-kernel-learning
Dorafshan, Thomas e Maguire	2018	Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete
Morgenthal et al.	2019	Framework for automated UAS-based structural condition assessment of bridges
Yeum, Choi e Dyke	2019	Automated region-of-interest localization and classification for vision-based visual assessment of civil infrastructure
GhoshMondal et al.	2020	Deep learning-based multi-class damage detection for autonomous post-disaster reconnaissance
Liu, Yeoh e Chua	2020	Deep Learning-Based Enhancement of Motion Blurred UAV Concrete Crack Images
Jiang e Zhang	2020	Real-time crack assessment using deep neural networks with wall-climbing unmanned aerial system
Hoskere et al.	2020	MaDnet: multi-task semantic segmentation of multiple types of structural materials and damage in images of civil infrastructure
Ayele et al.	2020	Automatic crack segmentation for uav-assisted bridge inspection
Potenza et al.	2020	A robotics and computer-aided procedure for defect evaluation in bridge inspection
Bhowmick, Nagarajaiah e Veeraraghavan	2020	Vision and deep learning-based algorithms to detect and quantify cracks on concrete surfaces from UAV videos
Ribeiro et al.	2020	Remote inspection of RC structures using unmanned aerial vehicles and heuristic image processing
Flah, Suleiman e Nehdi	2020	Classification and quantification of cracks in concrete structures using deep learning image-based techniques
Kung et al.	2021	Application of Deep Learning and Unmanned Aerial Vehicle on Building Maintenance
Oh, Ham e Lee	2021	Drone-assisted image processing scheme using frame-based location identification for crack and energy loss detection in building envelopes
Bouzan et al.	2021	Building Facade Inspection: A System Based On Automated Data Acquisition, Machine Learning, And Deep Learning Image Classification Methods
Kim et al.	2021	Crack identification method for concrete structures considering angle of view using RGB-D camera-based sensor fusion
Zhu et al.	2021	Hierarchical Convolutional Neural Network with Feature Preservation and Autotuned Thresholding for Crack Detection
Choi et al.	2021	UAV-Driven Structural Crack Detection and Location Determination Using Convolutional Neural Networks
Luo et al.	2021	Autonomous detection of damage to multiple steel surfaces from 360° panoramas using deep neural networks
Wu et al.	2021	Hybrid deep learning architecture for rail surface segmentation and surface defect detection

AUTOR	ANO	TÍTULO
Le, Nguyen e Le	2021	Development of deep learning model for the recognition of cracks on concrete surfaces
Draganić et al.	2022	Orthofaçade-Based Assisted Inspection Method for Buildings
Munawar et al.	2022	Civil Infrastructure Damage and Corrosion Detection: An Application of Machine Learning
Munawar et al.	2022	Inspecting buildings using drones and computer vision: A machine learning approach to detect cracks and damages
Liu e Chen	2022	Industrial UAV-based Unsupervised Domain Adaptive Crack Recognitions: From System Setups to Real-Site Infrastructural Inspections
Bianchi e Hebdon	2022	Development of Extendable Open-Source Structural Inspection Datasets
Ribeiro et al.	2022	Remote Inspection and Monitoring of Civil Engineering Structures Based on Unmanned Aerial Vehicles
Oring, A.	2022	Fast and Robust Structural Damage Analysis of Civil Infrastructure Using UAV Imagery
Tilon et al.	2022	Towards Improved Unmanned Aerial Vehicle Edge Intelligence: A Road Infrastructure Monitoring Case Study
Yoon et al.	2022	A novel approach to assess the seismic performance of deteriorated bridge structures by employing UAV-based damage detection
Mondal e Jahanshahi	2022	Applications of computer vision-based structural health monitoring and condition assessment in future smart cities
Ottoni, Novo e Costa	2022	Hyperparameter tuning of convolutional neural networks for building construction image classification

APÊNDICE B - LEVANTAMENTO DE DADOS (GOOGLE FORMS)

Investigação de defeitos ou manifestações patológicas em fachadas

Prezados,

Este formulário tem como objetivo coletar informações sobre problemas identificados durante a execução de fachada, visando aprimorar o sistema de gestão da qualidade. O questionário está sendo aplicado como etapa de levantamento de dados envolvendo um estudo mais amplo, vinculado a uma dissertação de mestrado desenvolvida no Programa de Pós-Graduação em Engenharia Civil da UFBA. Essa pesquisa tem como objetivo integrar as ferramentas digitais, como os Veículos Aéreos Não Tripulados-VANTs e Inteligência Artificial-IA, para identificação automática de defeitos ou manifestações patológicas em fachadas durante a execução.

Ressaltamos que as informações coletadas através deste questionário serão tratadas de forma anônima e apenas para fins de pesquisa científica.

At
Ac

alissssonsouza@gmail.com [Alternar conta](#)



A foto e o nome associados à sua Conta do Google serão registrados quando você fizer upload de arquivos e enviar este formulário.. Seu e-mail não faz parte da resposta.

***Obrigatório**

Nome *

Sua resposta

Cargo *

Escolher



Regional *

Sua resposta

Responda abaixo quais os principais defeitos encontrados em fachadas durante a execução da obra *

- Fissuras
- Falta da remoção de faquetas
- Junta fria
- Alinhamento entre pavimentos
- Falha na calafetação das esquadrias
- Armadura exposta
- Ondulações
- Outros (detalhar abaixo)

Detalhe aqui outros defeitos encontrados em fachadas *

Sua resposta

Detalhe aqui outros defeitos encontrados em fachadas *

Sua resposta

Responda abaixo quais os principais defeitos encontrados em fachadas no pós entrega *

- Fissuras
- Falta de remoção das faquetas
- Junta fria
- Alinhamento entre os pavimentos
- Falta de calafetação das esquadrias
- Armadura exposta
- Ondulações
- Defeitos no acabamento da pintura/elementos decorativos
- Outros (detalhar abaixo)

Detalhe aqui outros defeitos *

Sua resposta

Caso tenha fotos sobre alguns dos defeitos mencionados acima, anexe a seguir, para criação de um banco de dados.

Sua resposta

Fissuras

[↑ Adicionar arquivo](#)

Falta de remoção das faquetas

[↑ Adicionar arquivo](#)

Junta fria

[↑ Adicionar arquivo](#)

Alinhamento entre os pavimentos

[↑ Adicionar arquivo](#)

Falta de calafetação das esquadrias

[↑ Adicionar arquivo](#)

Armadura exposta

[↑ Adicionar arquivo](#)

Ondulações

 Adicionar arquivo

Defeitos no acabamento da pintura/elementos decorativos

 Adicionar arquivo

Outros

 Adicionar arquivo

Enviar

Limpar formulário

APENDICE C - CHECKLIST PARA MISSÃO DE VOO COM DRONE

Universidade Federal da Bahia (UFBA)
Escola Politécnica - Departamento de Construções e Estruturas (EP/DCE)
Grupo de Pesquisa e Extensão em Gestão e Tecnologia das Construções (GETEC)
Parceria: *Georgia Institute of Technology*



CHECKLIST PARA MISSÃO COM O RPA CLASSE 3 E CADASTRO DE DADOS DO VOO

Cadastro de Dados do Voo	Voo		
	Bateria 1	Bateria 2	Bateria 3
Data			
Localização			
Modelo de RPA			
Ponto de decolagem/pouso			
Condições climáticas			
Modalidade de voo (manual ou autônoma)			
Nome do piloto			
Observadores			
Objetivo do voo			
Horário de início			
Horário de término			

Itens do Checklist para Missão com VANT	Bateria 1	Bateria 2	Bateria 3
A) Checklist de Pré-voo			
1. Ligar roteador (tablet ou celular)	<input type="checkbox"/>		
2. Ligar controle remoto	<input type="checkbox"/>		
3. Levantar antenas	<input type="checkbox"/>		
4. Conectar cabo USB	<input type="checkbox"/>		
5. Encaixar hélices	<input type="checkbox"/>		
6. Remover proteção da câmera	<input type="checkbox"/>		
7. Inserir bateria no VANT e ligar	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
8. Colocar o VANT em lugar aberto e seguro para a decolagem e para que ele possa retomar a localização se a função “ <i>return to home</i> ” for acionada	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
9. Ligar aplicativo de controle (<i>DJI go, Pix4D Capture, ...</i>)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
10. Número de satélites			

Itens do Checklist para Missão com VANT	Bateria 1	Bateria 2	Bateria 3
11. Nível de bateria no início e fim do voo (%)			
12. Verificar a indicação de “safe to fly” no aplicativo de controle (DJI go)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
13. Para missão autônoma: programar parâmetros de voo e colocar controle no F	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
14. Iniciar a missão (decolar)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

E) Checklist de pré-pouso - Voo autônomo	Bateria 1	Coment.	Bateria 2	Coment.	Bateria 3	Coment.
1. Após o término do <i>grid</i> , acompanhar o retorno do VANT ao <i>Home Point</i> , assumindo o controle manual em caso de qualquer interferência	<input type="checkbox"/>		<input type="checkbox"/>		<input type="checkbox"/>	
2. Retomar o controle manual do VANT para pouso - Colocar controle remoto na posição manual (posição P)	<input type="checkbox"/>		<input type="checkbox"/>		<input type="checkbox"/>	
3. Pousar o VANT manualmente em local aberto e seguro	<input type="checkbox"/>		<input type="checkbox"/>		<input type="checkbox"/>	

F) Checklist para Fim da Missão	
1. Pousar em local aberto e seguro	<input type="checkbox"/>
2. Desligar bateria do VANT	<input type="checkbox"/>
3. Desligar controle remoto	<input type="checkbox"/>
4. Desligar roteador (tablet ou celular)	<input type="checkbox"/>
5. Remover bateria do VANT	<input type="checkbox"/>
6. Remover hélices	<input type="checkbox"/>
7. Colocar proteção da câmera	<input type="checkbox"/>
8. Guardar todos os equipamentos e acessórios na caixa	<input type="checkbox"/>

APÊNDICE D – PROTOCOLO DE ENTREVISTA 1

ROTEIRO PARA AVALIAÇÃO DO MÉTODO PROPOSTO

Dados Gerais

Nome do entrevistado: _____

Cargo/ Função na empresa: _____

Tempo de experiência no cargo atual: _____

Tempo de experiência na construção civil: _____

Formação: _____

Data da entrevista: _____

ETAPA DO MÉTODO: IMPLEMENTAÇÃO NO SISTEMA DE GESTÃO DA OBRA

Constructo: Utilidade

- 1- Qual o nível de atendimento das informações presentes no **relatório** para o controle de qualidade da execução da parede de concreto:

Práticas	Muito baixo	Baixo	Indiferente	Alto	Muito alto
Auxílio para o preenchimento da FVS de controle da qualidade durante a execução das fachadas					
Identificação e mapeamento das não conformidades					
Auxílio na tomada de decisão em tempo hábil para intervenção					
Acompanhamento do tratamento das não conformidades					

- 2- Os relatórios de inspeção de fachada foram utilizados para outras práticas incluindo ações preventivas? Se sim, cite exemplos de como utilizou as informações.
- 3- Na sua opinião, a periodicidade das inspeções atendeu a demanda de informações para o tratamento da fachada? Justifique-se.
- 4- Cite três aspectos positivos e três aspectos negativos do relatório de inspeção de fachada.
- 5- Possui alguma sugestão ou oportunidade de melhoria para a integração das informações presentes no relatório no processo de Controle da Qualidade?
- 6- Qual o nível de atendimento das informações presentes no **PLANO DE AÇÃO** para o controle de qualidade da execução da parede de concreto

Práticas	Muito baixo	Baixo	Indiferente	Alto	Muito alto
Especificação do tratamento de acordo com a manifestação patológica identificada					
Atribuição de um responsável pelo tratamento para o melhor controle da atividade realizada					
Definição de prazo para realização da ação corretiva visando o acompanhamento da execução da tarefa					

Constructo: Transparência

- 1- De forma geral, como acredita que as informações fornecidas no **relatório e plano de ação** contribuíram para o aumento da transparência nos de execução e tratamento da fachada? Por favor, cite exemplos.
- 2- Indique, em sua opinião, qual o nível de entendimento das informações presentes no relatório e plano de ação.

Produtos	Muito baixo	Baixo	Indiferente	Alto	Muito alto
Ficha de inspeção por fachada					
Gráfico de incidência de manifestação patológica por fachada					
Mapeamento das manifestações patológicas nas imagens por fachada					
Plano de ação					

- 3- Possui alguma sugestão ou oportunidade de melhoria para a estruturação das informações presentes no relatório de forma a melhorar a TRANSPARÊNCIA?
- 4- Em sua opinião, quais das manifestações patológicas do estudo são mais relevantes para tratamento?
- 5- As imagens e os relatórios das manifestações patológicas foram suficientes para o tratamento das fachadas?
- 6- Seria necessário a identificação de outras manifestações em fachadas de pares de concreto, além daquelas identificadas no relatório? Se sim, quais?
- 7- Em sua opinião, quais as principais dificuldades na execução de fachadas de paredes de concreto?
- 8- Como você acha que podemos evitar o surgimento das demais manifestações patológicas?

APÊNDICE E – PROTOCOLO DE ENTREVISTA 2

PERCEPÇÃO DOS GESTORES

- 1- Em relação ao método de inspeção de fachada utilizando drone e IA para controle da qualidade durante a execução, acredita que ele seja compatível e vantajoso com as práticas realizada pela empresa?
- 2- Quais os principais benefícios para implementação do método proposto?
- 3- Quais as principais barreiras para implementação do método proposto?
- 4- Em relação a aquisição dos equipamentos (drone, seguro e treinamento) ou terceirização desse serviço de inspeção, considera viável o investimento?