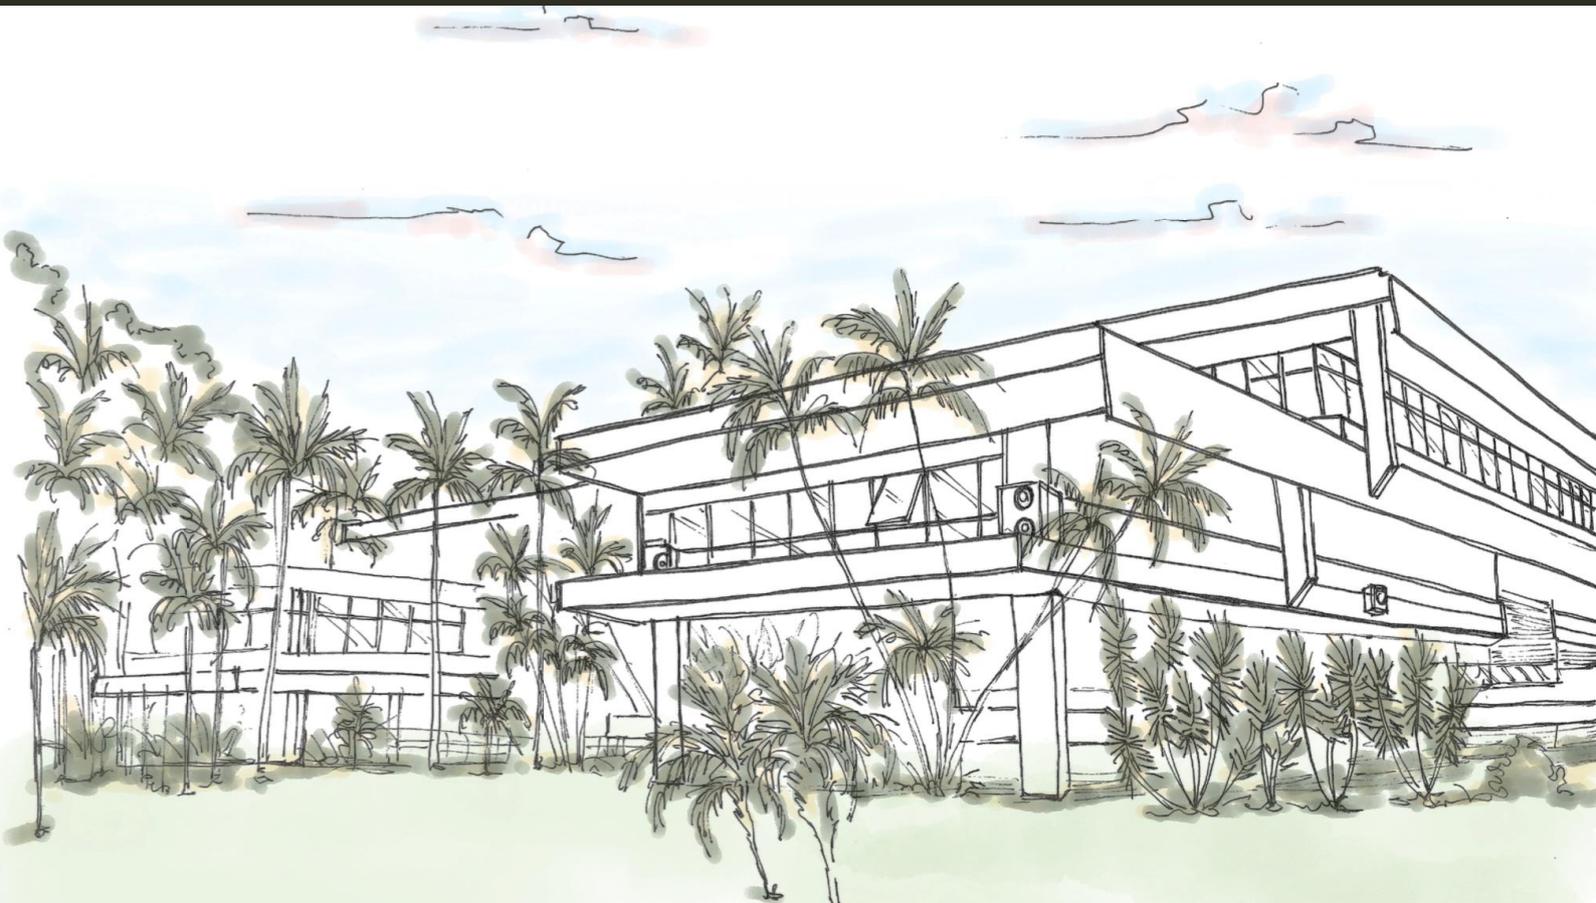


Tese de Doutorado | PPG FAU UnB

INSPEÇÃO PREDIAL EM SISTEMAS DE COBERTURA PLANA: USO DE TECNOLOGIAS DIGITAIS DE AQUISIÇÃO DE IMAGENS E PROCESSOS AUTOMATIZADOS



Tese de Doutorado | PPG FAU UnB

INSPEÇÃO PREDIAL EM
SISTEMAS DE COBERTURA PLANA:
USO DE TECNOLOGIAS DIGITAIS DE AQUISIÇÃO DE IMAGENS E PROCESSOS AUTOMATIZADOS

Tese de Doutorado apresentada como requisito obrigatório para a obtenção do título de Doutor pelo Programa de Pesquisa e Pós-Graduação em Arquitetura e Urbanismo da Universidade de Brasília.

Área de concentração: Tecnologia, Ambiente e Sustentabilidade.

Linha de pesquisa: Tecnologia de produção do ambiente construído.

Orientadora: Dra. Vanda Alice Garcia Zaroni

Brasília, fevereiro de 2025.





Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a):

SANTOS, LARA MONALISA ALVES DOS

Inspecção predial em cobertura plana: uso de tecnologias digitais de aquisição de imagens e processos automatizados. 247 p., 210 x 297 mm (PPG FAU UnB, Doutorado, Pós-Graduação em Arquitetura e Urbanismo, 2025).

Tese de Doutorado – Universidade de Brasília. Faculdade de Arquitetura e Urbanismo.
Departamento de Arquitetura e Urbanismo.

1. Manutenção. 2. Sistema de impermeabilização. 3. Degradação. 4. Fotogrametria.
5. Drone. 6. Visão Computacional. 7. *Deep learning*.

I. PPG FAU UnB

II. Título (Doutor)

REFERÊNCIA BIBLIOGRÁFICA

SANTOS, L. M. A. (2025). Inspecção predial em cobertura plana: uso de tecnologias digitais de aquisição de imagens e processos automatizados. Tese de Doutorado em Arquitetura e Urbanismo. Programa de Pós-Graduação da Faculdade de Arquitetura e Urbanismo da Universidade de Brasília, DF, 247 p.

As ilustrações apresentadas nesta tese foram elaboradas pela autora. As técnicas empregadas incluem a captura de imagens por drone, desenhos feitos à mão livre com o uso de papel vegetal e nanquim, posteriormente pintados digitalmente utilizando o visualizador de PDF do iPad Air, versão iPadOs 18.1.1.

Brasília, 24 de fevereiro de 2025.

Tese de Doutorado defendida no Programa de Pós-Graduação da Faculdade de Arquitetura e Urbanismo da Universidade de Brasília e aprovada pela Banca Examinadora constituída pelos membros:

Orientador (a)

Prof. Dra. Vanda Alice Garcia Zanoni

Departamento de Tecnologia da Arquitetura e Urbanismo
Faculdade de Arquitetura e Urbanismo da Universidade de Brasília (FAU UnB)

Examinador Externo

Prof. Dra. Claudia Terezinha de Andrade Oliveira

Departamento de Tecnologia da Arquitetura
Faculdade de Arquitetura e Urbanismo da Universidade de São Paulo (FAUUSP)

Examinador Externo

Prof. Dra. Heliara Aparecida Costa

Departamento de Arquitetura e Urbanismo
Universidade Federal de Tocantins (UFT), Campus Palmas (TO)

Examinador Interno

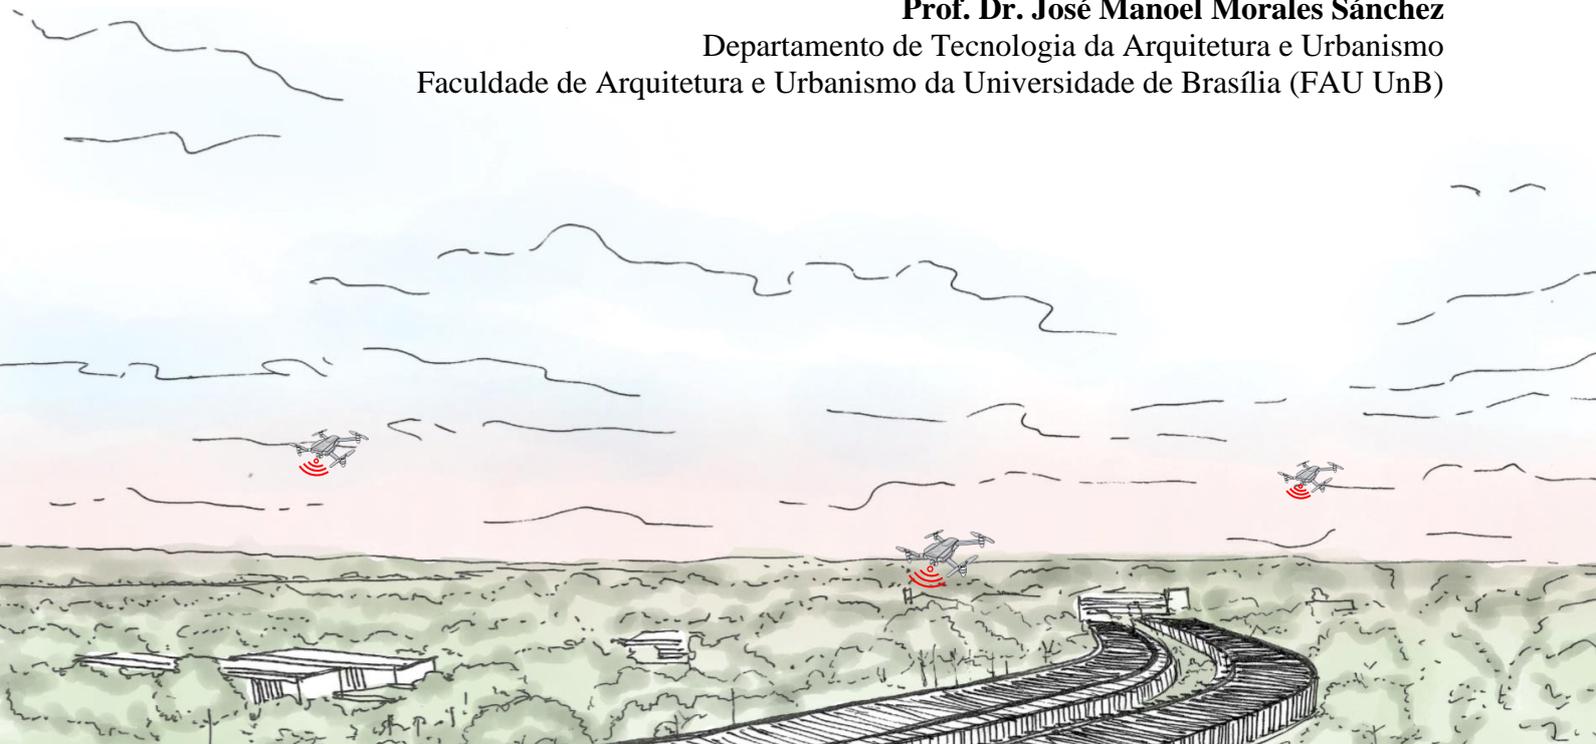
Prof. Dr. Lenildo Santos Silva

Departamento de Engenharia Civil e Ambiental
Faculdade de Tecnologia da Universidade de Brasília (FT UnB)

Suplente

Prof. Dr. José Manoel Morales Sánchez

Departamento de Tecnologia da Arquitetura e Urbanismo
Faculdade de Arquitetura e Urbanismo da Universidade de Brasília (FAU UnB)



À Nossa Senhora e ao meu Anjo da Guarda.

“Só eu sei cada passo por mim dado
nessa estrada esburacada que é a vida,
passei por coisas que até mesmo Deus duvida,
fiquei triste, capiongo, aperreado,
porém nunca me senti desmotivado,
me agarrava sempre numa mão amiga,
e de forças minha alma era munida
pois do céu a voz de Deus dizia:
– Suba o queixo, meta os pés, confie em mim,
vá pra luta que eu cuido das feridas.”

Bráulio Bessa.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus por me guiar ao longo desta jornada, repleta de desafios e superações.

Aos meus familiares, que sempre me incluíram em suas orações, expresso minha profunda gratidão. Aos meus pais, Uelton e Vanusa, e à minha irmã, Larissa, que, mesmo à distância, ofereceram apoio incondicional e compreenderam minha ausência durante esta caminhada. E ao meu avô Arnaldo, cuja preocupação constante e perguntas sobre a conclusão deste trabalho.

Ao meu esposo, Thiago, pelo suporte inabalável, pela paciência e por caminhar ao meu lado em todos os momentos difíceis.

À minha orientadora, Vanda Alice, pelo tempo dedicado e pelo conhecimento generosamente compartilhado ao longo de toda essa trajetória. Reconheço e aprecio sua dedicação em cada orientação, bem como sua disposição constante. Minha sincera gratidão por ter me acolhido como orientanda desde 2020.

Aos colegas do Programa de Pós-Graduação em Arquitetura e Urbanismo da Universidade de Brasília, em especial a Catariana, Tatiane e Matheus, que, além de companheiros de jornada, tornaram-se amigos.

Ao Exército Brasileiro, pelo apoio e compreensão ao longo deste período, desde minha trajetória como Aspirante até o posto de 1º Tenente.

À Universidade de Brasília e ao Programa de Pós-Graduação em Arquitetura e Urbanismo, pela oportunidade concedida para a realização deste doutorado.

Por fim, a todas as pessoas que, de alguma forma, contribuíram para a concretização desta tese, meu mais sincero agradecimento.

RESUMO

Os processos de inspeção predial, realizados periodicamente, servem para diagnosticar o estado de conservação e orientam o planejamento de manutenções. Em sistemas de cobertura, as inspeções prediais podem envolver dificuldade de acesso, riscos de segurança devido aos trabalhos em altura e tempo despendido para a realização das vistorias, além de requererem conhecimento técnico baseado em análises sensoriais. Na cobertura, é comum a ocupação intensiva das lajes impermeabilizadas para acomodar instalações e equipamentos, o que aumenta as dificuldades nos levantamentos in loco e na identificação de manifestações patológicas. Nesse contexto, as ações de reparos e substituições dos elementos ou componentes da laje impermeabilizada, ou em equipamentos dispostos sobre ela, apresentam uma situação de complexidade a ser pesquisada. Por meio de uma revisão sistemática da literatura, identificou-se uma lacuna na abordagem integrada para a inspeção de lajes planas impermeabilizadas, com diferentes níveis e configurações arquitetônicas, considerando as etapas do processamento digital para a geração de ortoimagens e a aplicação de técnicas de visão computacional para detecção de equipamentos e segmentação automatizada de manchas. Diante disso, questiona-se nesta pesquisa como tecnologias digitais e processos automatizados podem contribuir com a gestão da manutenção em sistemas de cobertura plana. Nesse sentido, o objetivo principal desta tese é promover o aprimoramento das inspeções prediais de sistemas de cobertura plana por meio de tecnologias digitais para aquisição de imagens e de processos automatizados. Fundamentada em uma abordagem qualitativa, a pesquisa combinou diferentes metodologias, integrando as etapas bibliográfica, exploratória e experimental. Essas abordagens foram empregadas para caracterizar os sistemas em foco, realizar os levantamentos de campo, aplicar tecnologias digitais e conduzir procedimentos experimentais em processos automatizados. O método proposto integra o uso do drone para inspeção visual por meio de imagens, a construção de uma base de imagens para a realização do processamento digital dessas imagens e a aplicação de técnicas de visão computacional. A amostra selecionada para os estudos constitui-se do conjunto de coberturas planas do Quartel General do Exército Brasileiro (QGEx) e outras quatro edificações da Universidade de Brasília (UnB), no campus Darcy Ribeiro: Biblioteca Central (BCE), Instituto Central de Ciências (ICC), Unidade da Criança e do Adolescente (UCA) e Reitoria. Os resultados obtidos mostram desempenho satisfatório na aplicação do processamento digital de imagens e de redes neurais convolucionais para detecção de equipamentos que interferem nas ações de manutenção e segmentação de manchas que afetam a impermeabilização das coberturas. Durante as inspeções, o campo de visão do drone difere do campo de visão do inspetor, mostrando que as tecnologias digitais podem contribuir para a inspeção visual dos manchamentos, uma vez que as manchas de umidade indicam processos de degradação que aceleram a infiltração de água e comprometem o desempenho e a durabilidade da cobertura. Com esta tese, espera-se contribuir para uma abordagem metodológica integrada como estratégia para dar celeridade às ações de manutenção preventiva e corretiva na gestão da manutenção e no monitoramento do sistema de cobertura.

Palavras-chave: Cobertura; Manutenção; Sistema de impermeabilização; Degradação; Fotogrametria; Drone; Visão Computacional; *Deep learning*.

ABSTRACT

Building inspections processes should be conducted periodically to assess the condition of structures and plan maintenance activities effectively. For roofing systems, building inspections can be associated with difficult access, safety risks due to working at height and the time it takes to carry out the inspections, as well as requiring technical knowledge based on sensory analyses. On flat roofs, waterproofing membranes are often used extensively to support installations and equipment, which increases the difficulty of on-site inspection and identification of pathological conditions. In this context, repairs and replacements to elements or components of the waterproofing slab, or to equipment placed on it, present a complex situation to be investigated. A systematic literature review identified a gap in the integrated approach to the inspection of waterproofing slabs with different levels and architectural configurations, taking into account the digital processing stages for the generation of orthoimages and the application of computer vision techniques for detecting equipment and automated stain segmentation. In this sense, this research questions how digital technologies and automated processes can contribute to the maintenance management on flat roof systems. The main objective of this thesis is to promote the improvement of building inspections of flat roof systems by means of digital technologies for image acquisition and of automated processes. Based on a qualitative approach, the research combined different methodologies, integrating the bibliographical, exploratory and experimental stages. These approaches were used to characterize the systems in question, carry out field surveys, apply digital technologies and conduct experimental procedures on automated processes. The proposed methodology integrates the use of a drone for visual inspection using images, the construction of a image base for the digital processing of these images and the application of computer vision techniques. The sample selected for the studies consists of the flat roofs of the Brazilian Army Headquarters (QGEx) and four other buildings of the University of Brasilia (UnB), located on the Darcy Ribeiro Campus: Central Library (BCE), Central Science Institute (ICC), Child and Adolescent Unit (UCA) and Rectory. The results obtained show satisfactory performance in the application of digital image processing and convolutional neural networks for the detection of equipment that interferes with maintenance operations and the segmentation of stains that affect the waterproofing of roofs. During the inspections, the drone's field of vision is different from the inspector's field of vision, showing that digital technologies can contribute to the visual inspection of stains, as these stains of humidity indicate degradation processes that accelerate water infiltration and compromise the performance and durability of the flat roof. With this work, we hope to contribute to an integrated methodological approach as a strategy for accelerating preventive and corrective maintenance actions in maintenance management and roof system monitoring.

Keywords: Flat Roof; Maintenance; Waterproofing System; Degradation; Photogrammetry; Drone; Computer Vision; Deep Learning.

LISTA DE FIGURAS

FIGURA 1 - CAMPO CONCEITUAL DO CONTEXTO TEMÁTICO DA TESE DE PESQUISA.	29
FIGURA 2 - ORGANIZAÇÃO DAS SEÇÕES DA PESQUISA.	35
FIGURA 3 – MATRIZ DE RELAÇÕES ENTRE AS EXIGÊNCIAS E REQUISITOS, COM BASE NA NORMA DE DESEMPENHO.	36
FIGURA 4 - DESEMPENHO AO LONGO DO TEMPO.	38
FIGURA 5 - RELAÇÃO DE CAUSA E FEITO ENTRE AGENTES.	41
FIGURA 6 - FATORES CONDICIONANTES PARA O PROCESSO DE DEGRADAÇÃO.	42
FIGURA 7 - CURVA DE DETERIORAÇÃO DE UMA COBERTURA.	43
FIGURA 8 - CLASSIFICAÇÃO DO SISTEMA DE IMPERMEABILIZAÇÃO QUANTO À FLEXIBILIDADE.	44
FIGURA 9 - REPRESENTAÇÃO DAS CAMADAS QUE COMPÕEM A COBERTURA COM O SISTEMA DE IMPERMEABILIZAÇÃO.	45
FIGURA 10 - ETAPAS E SUB ETAPAS DE MONITORAMENTO NO SISTEMA DE COBERTURA.	52
FIGURA 11 - ETAPAS DA INSPEÇÃO PREDIAL.	52
FIGURA 12 - CONDENSADORAS.	57
FIGURA 13 - SUBESTAÇÕES DE ENERGIA.	57
FIGURA 14 - ANTENA.	57
FIGURA 15 - PARA-RAIOS.	57
FIGURA 16 - CHAMINÉ / EXAUSTORES.	57
FIGURA 17 - PLACAS FOTOVOLTAICA.	57
FIGURA 18 - TORRE OU CABINE.	57
FIGURA 19 - SUPORTE PARA INSTALAÇÕES: BLOCO DE CONCRETO; ANCORAGEM METÁLICA; GRADES OU QUADROS.	57
FIGURA 20 - PALAVRAS-CHAVE DA BASE DE DADOS DA <i>WEB OF SCIENCE</i>	61
FIGURA 21 - PALAVRAS-CHAVE DA BASE DE DADOS DO <i>SCOPUS</i>	61
FIGURA 22 - PALAVRAS-CHAVE DA BASE DE DADOS DA <i>WEB OF SCIENCE</i>	64
FIGURA 23 - NUVEM DE PALAVRAS-CHAVE GERADO NA <i>WEB OF SCIENCE</i>	65
FIGURA 24 - ILUSTRAÇÃO DOS PROBLEMAS COM INSPEÇÕES TRADICIONAL DE LOCAIS DE DIFÍCIL ACESSO E LOCAIS DE ALTO RISCO (A, B, C). INSPEÇÕES BASEADAS EM DRONES COM UMA INTERFACE PARA ASSISTIR ÀS FILMAGENS EM TEMPO REAL (D, E, F).	72
FIGURA 25 - ILUSTRAÇÃO DOS SISTEMAS ASSISTIDOS POR INTELIGÊNCIA ARTIFICIAL (IA) DO PRESENTE PARA O FUTURO PARA PATRIMÔNIO CULTURAL.	73
FIGURA 26 - DELINEAMENTO DAS ETAPAS DE PESQUISA.	78
FIGURA 27 - QUARTEL GENERAL DO EXÉRCITO.	80
FIGURA 28 - COBERTURAS DAS EDIFICAÇÕES DO QGEX.	80
FIGURA 29 - CAMPUS DARCY RIBEIRO.	80
FIGURA 30 - LOCALIZAÇÃO DOS EDIFÍCIOS DE ESTUDO NO CAMPUS DARCY RIBEIRO DA UNB.	80

FIGURA 31 - PERSPECTIVA DA BCE.	81
FIGURA 32 - SISTEMA DE COBERTURA DA BCE.	81
FIGURA 33 - PERSPECTIVA DA REITORIA.	82
FIGURA 34 - SISTEMA DE COBERTURA DA REITORIA.	82
FIGURA 35 - VISTA PANORÂMICA DO GRANDE PLANO DA COBERTURA DO ICC-UNB.	83
FIGURA 36 - PERSPECTIVA DO ICC.	83
FIGURA 37 - SISTEMA DE COBERTURA DO ICC.	83
FIGURA 38 - PERSPECTIVA DA UCA.	84
FIGURA 39 - SISTEMA DE COBERTURA DA UCA.	84
FIGURA 40 - PROTOCOLO DE INSPEÇÃO COM DRONE E AS VARIÁVEIS DE ANÁLISE PARA OS SISTEMAS DE COBERTURA PLANA.	86
FIGURA 41 - PLANO DE VOO REALIZADO NO APLICATIVO <i>DRONEDEPLOY FLIGHT</i> - ICC A UNB.	89
FIGURA 42 - FLUXO ADOTADO PARA O PROCESSAMENTO DAS IMAGENS.	90
FIGURA 43 - ETAPAS DO PROCESSAMENTO DE IMAGEM.	91
FIGURA 44 - FLUXO DOS PROCESSOS AUTOMATIZADOS PARA DETECÇÃO E SEGMENTAÇÃO SEMÂNTICA.	93
FIGURA 45 - EQUIPAMENTOS DISPOSTOS EM COBERTURAS PLANAS.	94
FIGURA 46 - ETAPAS E PROCESSOS ADOTADOS PARA A DETECÇÃO DE EQUIPAMENTOS.	95
FIGURA 47 - CAIXA DE SELEÇÃO POR ROBOFLOW.	95
FIGURA 48 - ANOTAÇÃO DE CONDENSADORAS NO ROBOFLOW.	95
FIGURA 49 - HISTOGRAMA DE CONTAGEM DE OBJETOS POR IMAGEM.	96
FIGURA 50 - DISTRIBUIÇÃO ESPACIAL DAS ANOTAÇÕES NO BANCO DE IMAGEM.	96
FIGURA 51 - ETAPAS E PROCESSOS ADOTADOS PARA A SEGMENTAÇÃO SEMÂNTICA.	98
FIGURA 52 - MANCHAS CLARAS DE UMIDADE PRESENTES NA COBERTURA PLANA, APÓS PERÍODO DE CHUVA	99
FIGURA 53 - REGIÃO DE REFERÊNCIA PARA ANOTAÇÃO DAS MANCHAS ESCURAS.	99
FIGURA 54 - APLICAÇÃO DA <i>POLYGON TOOL</i>	99
FIGURA 55 - ANOTAÇÃO DE MANCHAMENTOS POR ROBOFLOW.	99
FIGURA 56 - INFORMAÇÃO SOBRE AS DIMENSÕES DAS IMAGENS ANOTADAS.	100
FIGURA 57 - DISTRIBUIÇÃO ESPACIAL DAS ANOTAÇÕES NO BANCO DE IMAGEM.	100
FIGURA 58 - REPRESENTAÇÃO DE CORES PARA TP = VERDE, FP = VERMELHO E FN = AZUL.	102
FIGURA 59 - CORTE LONGITUDINAL BCE – UNB.	105
FIGURA 60 - PLANO HORIZONTAL DO VOO ADOTADO EM UMA DIREÇÃO E LINHAS DE VOO MODO AUTOMÁTICO.	106
FIGURA 61 - PLANO HORIZONTAL DO VOO ADOTADO EM UMA DIREÇÃO E LINHAS DE VOO MODO AUTOMÁTICO.	106
FIGURA 62 - PLANO HORIZONTAL DO VOO CRUZADO ADOTADO EM CINCO DIREÇÕES E LINHAS DE VOO MODO AUTOMÁTICO.	106
FIGURA 63 – CORTE REPRESENTATIVO DAS EDIFICAÇÕES DO QGEX.	108

FIGURA 64 – PLANOS DE VOO PARA AQUISIÇÃO DE IMAGENS CAPTURADAS PELO DRONE.	108
FIGURA 65 – CORTE LONGITUDINAL.	109
FIGURA 66 – ZONEAMENTO DA EXECUÇÃO DOS PLANOS DE VOO NO ICC.	110
FIGURA 67 - CORTE LONGITUDINAL REITORIA-UNB.	114
FIGURA 68 - PLANO HORIZONTAL DO VOO ADOTADO EM DUAS DIREÇÕES E LINHAS DE VOO MODO AUTOMÁTICO.	114
FIGURA 69 - PLANO HORIZONTAL DO VOO ADOTADO EM DUAS DIREÇÕES E LINHAS DE VOO MODO AUTOMÁTICO PARA OS TRÊS VOOS REALIZADOS.	115
FIGURA 70 - CORTE LONGITUDINAL UCA-UNB.	116
FIGURA 71 - COMPARAÇÃO DA DEFINIÇÃO DAS BORDAS COM O USO DO PARÂMETRO <i>ULTRA- HIGH</i>	119
FIGURA 72 - COMPARAÇÃO ENTRE O PRIMEIRO E O SEGUNDO PROCESSAMENTO COM 1 DIREÇÃO.	135
FIGURA 73 - COMPARAÇÃO ENTRE O PRIMEIRO E O SEGUNDO PROCESSAMENTO COM 5 DIREÇÕES.	135
FIGURA 74 - VERIFICAÇÃO DA QUALIDADE DA ORTOIMAGEM PARA VISUALIZAÇÃO DO PADRÃO DE FISSURAS NA PROTEÇÃO MECÂNICA.	136
FIGURA 75 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO PROCESSAMENTO – 45 METROS - 1 DIREÇÃO.	137
FIGURA 76 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 45 METROS - 1 DIREÇÃO.	137
FIGURA 77 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 45 METROS - 5 DIREÇÕES.	138
FIGURA 78 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO.	140
FIGURA 79 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO.	140
FIGURA 80 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO.	140
FIGURA 81 - ORTOIMAGEM COM AS ÁREAS DO ÚLTIMO NÍVEL SEM PROCESSAMENTO.	142
FIGURA 82 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO –2 DIREÇÕES - 20 METROS.	142
FIGURA 83 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 20 METROS.	142
FIGURA 84 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 20 METROS.	143
FIGURA 85 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 32 METROS.	145
FIGURA 86 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 32 METROS.	145
FIGURA 87 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 32 METROS.	145

FIGURA 88 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 50 METROS.	147
FIGURA 89 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 50 METROS.	147
FIGURA 90 - PERSPECTIVAS DAS LATERAIS DO MODELO DIGITAL DE ELEVAÇÃO DO NOVO PROCESSAMENTO – 2 DIREÇÕES - 50 METROS.	148
FIGURA 91 - TESTE DA DIREÇÃO DAS LINHAS DE VOO DEFINIDAS NOS VOOS 2 E 4, COM FOCO NA ANÁLISE DOS SEGMENTOS DA COBERTURA COM PARTES LINEARES E CURVAS.	160
FIGURA 92 - RESULTADO DO SEGMENTO PROCESSADO DO PLANO DE VOO REALIZADO NO ICC - 14 METROS – 2 DIREÇÕES.....	160
FIGURA 93 - RESULTADO DO SEGMENTO PROCESSADO DO PLANO DE VOO REALIZADO NO ICC - 14 METROS – 2 DIREÇÕES.....	161
FIGURA 94 - INTERFACE DO SOFTWARE COM A JUNÇÃO DOS <i>CHUNK</i> PROCESSADOS DO BLOCO A.	162
FIGURA 95 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO BLOCO A.	164
FIGURA 96 – ENTULHOS IDENTIFICADOS NO SISTEMA DE COBERTURA.	164
FIGURA 97 – RETIRADA DAS PLACAS DE FECHAMENTO DAS VIGAS-CALHAS.	164
FIGURA 98 - A VEGETAÇÃO IMPEDE A VISUALIZAÇÃO DA COBERTURA.....	165
FIGURA 99 - CALHA SUJA.....	165
FIGURA 100 - PLACA MÓVEL OBSTRUINDO VIGA-CALHA, IMPEDINDO O ESCOAMENTO DE ÁGUA E ACUMULANDO SUJIDADES.	166
FIGURA 101 - QUANTIDADE DE <i>CHUNK</i> E <i>MERGED</i> DO BLOCO B.	166
FIGURA 102 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO BLOCO B COM A SINALIZAÇÃO DOS EQUIPAMENTOS OBSOLETOS E A PRESENÇA DE VEGETAÇÃO INVASIVA.....	168
FIGURA 103 - PERSPECTIVA DO MODELO DIGITAL DE ELEVAÇÃO DO BLOCO B.	169
FIGURA 104 - ORTOIMAGEM DO ICC NORTE E SUL.....	173
FIGURA 105 - ORTOIMAGEM A NÍVEL DO URBANISMO.	173
FIGURA 106 - LOCAIS DA CÂMERA E SOBREPOSIÇÃO DE IMAGENS.	173
FIGURA 107 - LOCAIS DA CÂMERA E SOBREPOSIÇÃO DE IMAGENS.	173
FIGURA 108 - ZOOM DE 100% NO SOFTWARE PHOTOSHOP CS6 - PROCESSAMENTO EM NÍVEL DO URBANO.	174
FIGURA 109 - ZOOM DE 30% NO SOFTWARE PHOTOSHOP CS6 PROCESSAMENTO GERAL DO ICC.	174
FIGURA 110 - ZOOM DE 161% NO SOFTWARE PHOTOSHOP CS6 PROCESSAMENTO EM NÍVEL URBANO.	175
FIGURA 111 - ZOOM DE 161% NO SOFTWARE PHOTOSHOP CS6 PROCESSAMENTO GERAL DO ICC.	175
FIGURA 112 - GRÁFICOS DE <i>BOXPLOT</i> PARA OS VALORES MEDIDOS EM CADA EXPERIMENTO.	178
FIGURA 113 - RESULTADOS DA CORRELAÇÃO DE PEARSON: RELAÇÃO ENTRE OS VALORES MEDIDOS E PREVISTOS.	179

FIGURA 114 - CURVAS DE PERDA: EVOLUÇÃO DA PERDA DURANTE O TREINAMENTO.	180
FIGURA 115 - ERROS DE DETECÇÃO DE CONDENSADORAS NA FACHADA PELA REDE FOVEA.	182
FIGURA 116 - ACÚMULO DE ÁGUA NA REGIÃO DAS CONDENSADORAS.	183
FIGURA 117 - REPARO REALIZADO NA MANTA DE IMPERMEABILIZAÇÃO.....	183
FIGURA 118 - ERRO NA DETECÇÃO DE CONDENSADORAS NA REDE RETINANET.....	184
FIGURA 119 - <i>BOXPLOT</i> DOS RESULTADOS.....	189
FIGURA 120 - SEGMENTAÇÃO USANDO FCN, DEEPLABV3 E SEGFORMER.....	191
FIGURA 121 - SEGMENTAÇÃO USANDO FCN COM OTIMIZADOR ADAGRAD EM DIFERENTES TAXAS DE APRENDIZADO.	192
FIGURA 122 - SEGMENTAÇÃO USANDO DEEPLABV3 COM OTIMIZADOR ADAGRAD COM DIFERENTES TAXAS DE APRENDIZAGEM.	192
FIGURA 123 – ACÚMULO DE ÁGUA PRÓXIMO AOS TUBOS DE DRENAGEM – DEEPLABV3 OTIMIZADA COM ADAGRAD E UMA TAXA DE APRENDIZAGEM DE 1E-4.	192
FIGURA 124 - SEGMENTAÇÃO DE FALSOS NEGATIVOS (FN=AZUL) EM MANCHAS PRÓXIMA AOS DUTOS DE DRENAGEM, EQUIPAMENTOS E PLATIBANDA – FCN OTIMIZADA COM ADAGRAD E UMA TAXA DE APRENDIZAGEM DE 1E-4.....	192
FIGURA 125 - MANCHAS DE UMIDADE CLARAS E ESCURAS NA PROTEÇÃO MECÂNICA COM ARGAMASSA – FCN OTIMIZADA COM ADAGRAD E UMA TAXA DE 1E-4.	193
FIGURA 126 - MANCHA DE UMIDADE CLARAS E ESCURAS NA MANTA ALUMINIZADA – DEEPLABV3 OTIMIZADA COM ADAGRAD E UMA TAXA DE 1E-2.	193
FIGURA 127 - MANTAS ALUMINIZADAS APLICADAS NO SENTIDO DO CAIMENTO PARA OS DUTOS DE DRENAGEM (TÉCNICA MAIS ADEQUADA PARA O ESCOAMENTO DAS ÁGUAS PLUVIAIS) - FCN COM OTIMIZADOR ADAGRAD E 1E-2.....	194
FIGURA 128 - SEGMENTAÇÃO FALSO POSITIVO DE ENTULHOS PRESENTES NO SISTEMA DE COBERTURA - FCN COM OTIMIZADOR ADAGRAD E UM TAXA DE APRENDIZAGEM DE 1E-4.	194
FIGURA 129 - CONTAGEM DE FALSO POSITIVO POR REDE.	196
FIGURA 130 - QUANTITATIVO DE FALSO POSITIVO DE TODAS AS REDES.....	197
FIGURA 131 - EXEMPLIFICAÇÃO DA SEGMENTAÇÃO DE FALSO POSITIVO – DEEPLABV3 OTIMIZADA COM ADAGRAD E UMA TAXA DE 1E-4.	198
FIGURA 132 - SEGMENTAÇÃO DE FALSO POSITIVO NO TERRENO – SEGFORMER ADAM 1E-3... ..	199
FIGURA 133 - CONTABILIZAÇÃO DE FALSO POSITIVO DO TERRENO PARA CADA REDE.....	199
FIGURA 134 – SEGMENTAÇÃO DE FALSO POSITIVO NA TUBULAÇÃO – SEGFORMER SGD 1E-2.	199
FIGURA 135 - CONTABILIZAÇÃO DE FALSO POSITIVO DA TUBULAÇÃO PARA CADA REDE.	199
FIGURA 136 - SEGMENTAÇÃO DE FALSO POSITIVO NA TUBULAÇÃO - SEGFORMER SGD 1E-2.. ..	199
FIGURA 137 - CONTABILIZAÇÃO DE FALSO POSITIVO DA TUBULAÇÃO PARA CADA REDE.	199
FIGURA 138 - SEGMENTAÇÃO DE FALSO POSITIVO NA PLACA DE CAMINHAMENTO – RESNET50 ADAGRAD 1E-4.....	200
FIGURA 139 - CONTABILIZAÇÃO DE FALSO POSITIVO DA PLACA DE CAMINHAMENTO PARA CADA REDE.	200
FIGURA 140 - SEGMENTAÇÃO DE FALSO POSITIVO NO VIDRO DA PLATIBANDA – SEGFORMER ADAM 1E-3.	200

FIGURA 141 - CONTABILIZAÇÃO DE FALSO POSITIVO DO VIDRO DA PLATIBANDA PARA CADA REDE.....	200
FIGURA 142 - SEGMENTAÇÃO DE FALSO POSITIVO DO VIDRO DA FACHADA – SEGFORMER ADAM 1E-3.	201
FIGURA 143 – CONTABILIZAÇÃO DE FALSO POSITIVO DE VIDRO DA FACHADA PARA CADA REDE.....	201
FIGURA 144 - SEGMENTAÇÃO DE FALSO POSITIVO DE ENTULHOS – SEGFORMER ADAM 1E-3.	201
FIGURA 145 - CONTABILIZAÇÃO DE FALSO POSITIVO DE ENTULHO PARA CADA REDE.....	201
FIGURA 146 - SEGMENTAÇÃO DE FALSO POSITIVO DA ESCADA – RESNET101 SGD 1E-3.....	202
FIGURA 147 - CONTABILIZAÇÃO DE FALSO POSITIVO DE ESCADA PARA CADA REDE.	202
FIGURA 148 - SEGMENTAÇÃO DE FALSO POSITIVO DE MANCHA DE FERRUGEM – RESNET101 ADAM 1E-3.	202
FIGURA 149 - CONTABILIZAÇÃO DE FALSO POSITIVO DE MANCHA DE FERRUGEM PARA CADA REDE.....	202
FIGURA 150 - SEGMENTAÇÃO DE FALSO POSITIVO DO BLOCO DE CONCRETO – SEGFORMER ADAM 1E-4.	203
FIGURA 151 - CONTABILIZAÇÃO DE FALSO POSITIVO DE BLOCO DE CONCRETO PARA CADA REDE.....	203
FIGURA 152 - SEGMENTAÇÃO DE FALSO POSITIVO DE CONTAINER – SEGFORMER SGD 1E-2. ...	203
FIGURA 153 - CONTABILIZAÇÃO DE FALSO POSITIVO DE CONTAINER PARA CADA REDE.	203
FIGURA 154 - ETAPA 1: CARREGAMENTO DAS FOTOS.	227
FIGURA 155 - ETAPA 2: ALINHAMENTO DAS FOTOS (PROCESSAMENTO BCE – 5D).....	228
FIGURA 156 - ETAPA 3: DENSE CLOUD (PROCESSAMENTO BCE – 5D).....	229
FIGURA 157 - ETAPA 3: BUILD MESH - 3D MODEL (PROCESSAMENTO BCE – 5D).	230
FIGURA 158 - ETAPA 4: TILED MODEL (PROCESSAMENTO BCE – 5D).....	231
FIGURA 159 - ETAPA 5: DEM (PROCESSAMENTO BCE – 5D).....	232
FIGURA 160 - ETAPA 6: ORTOIMAGEM (PROCESSAMENTO BCE – 5D).	233

LISTA DE TABELAS

TABELA 1 - VIDA ÚTIL DE PROJETO PARA COBERTURA.	38
TABELA 2 - CLASSIFICAÇÃO DAS CAUSAS ASSOCIADAS ÀS ANOMALIAS.	48
TABELA 3 - MODELO NÃO RESTRITIVO PARA A ELABORAÇÃO DO PROGRAMA DE MANUTENÇÃO PREVENTIVA DE UMA EDIFICAÇÃO HIPOTÉTICA.	55
TABELA 4 - ABREVIÇÕES ADOPTADAS PARA EDIFICAÇÕES ESTUDADAS.	91
TABELA 5 - DESCRIÇÃO DO CONJUNTO DE DADOS NA PLATAFORMA <i>ROBOFLOW: CLASS</i> <i>BALANCE</i> – CONDENSADORA.	96
TABELA 6 - DESCRIÇÃO DO CONJUNTO DE DADOS NA PLATAFORMA <i>ROBOFLOW: CLASS</i> <i>BALANCE</i> –MANCHA.	100
TABELA 7 - INFORMAÇÕES SOBRE OS VOOS REALIZADOS EM CADA SISTEMA DE COBERTURA DOS EDIFÍCIOS ESTUDADOS.	104
TABELA 8 – DADOS DA AQUISIÇÃO DE IMAGENS REALIZADO COM O DRONE NA BCE.	107
TABELA 9 – DADOS DA AQUISIÇÃO DE IMAGENS REALIZADA COM O DRONE NO QGEX.	109
TABELA 10 – PLANOS DE VOO PARA AQUISIÇÃO DE IMAGENS CAPTURADAS PELO DRONE NO ICC.	111
TABELA 11 - DADOS DA AQUISIÇÃO DE IMAGENS REALIZADO COM O DRONE NO ICC NORTE E SUL.	113
TABELA 12 - DADOS DA AQUISIÇÃO DE IMAGENS REALIZADA COM O DRONE NA REITORIA. .	115
TABELA 13 - DADOS DA AQUISIÇÃO DE IMAGENS REALIZADA COM O DRONE NA UCA.	116
TABELA 14 - PARÂMETROS DE ALINHAMENTO DE IMAGEM (<i>ALIGN PHOTOS</i>).	117
TABELA 15 - PARÂMETROS DA CONSTRUÇÃO DA NUVEM DENSA (<i>BUILD DENSE CLOUD</i>).	120
TABELA 16 - PARÂMETROS DA CONSTRUÇÃO DA MALHA (<i>BUILD MESH</i>).	121
TABELA 17 - PARÂMETROS DA CONSTRUÇÃO DA TEXTURA (<i>BUILD TEXTURE</i>).	122
TABELA 18 - PARÂMETROS DA CONSTRUÇÃO DO MODELO (<i>BUILD TILED MODEL</i>).	122
TABELA 19 - PARÂMETROS DA CONSTRUÇÃO DO MODELO DIGITAL DE ELEVAÇÃO (<i>BUILD</i> <i>DIGITAL ELEVATION MODEL - DEM</i>).	123
TABELA 20 - PARÂMETROS DA CONSTRUÇÃO DO ORTOMOSAICO (<i>ORTHOMOSAIC</i>).	124
TABELA 21 - RESULTADOS DO PROCESSAMENTO PARA A GERAÇÃO DAS ORTOIMAGENS OBTIDAS.	124
TABELA 22 - RESULTADOS DO PROCESSAMENTO PARA A GERAÇÃO DAS ORTOIMAGENS OBTIDAS.	131
TABELA 23 - DADOS DOS PARÂMETROS DA ETAPA DE PROCESSAMENTO.	132
TABELA 24 - DADOS DOS PARÂMETROS DA ETAPA DE PROCESSAMENTO.	154
TABELA 25 - RESULTADOS DO PROCESSAMENTO PARA A GERAÇÃO DAS ORTOIMAGENS OBTIDAS.	155
TABELA 26 - RESULTADOS DO PROCESSAMENTO PARA A GERAÇÃO DAS ORTOIMAGENS OBTIDAS.	169
TABELA 27 - RESULTADOS DO PROCESSAMENTO PARA A GERAÇÃO DAS IMAGENS OBTIDAS.	170

TABELA 28 - DADOS DOS PARÂMETROS DA ETAPA DE PROCESSAMENTO.....	172
TABELA 29 - MÉTODOS USADOS E VALORES DE MÉTRICAS DE DESEMPENHO.....	177
TABELA 30 - ERROS COMETIDOS DA DETECÇÃO DE OBJETOS SEMELHANTES.	181
TABELA 31 - CONTAGEM DAS ANOTAÇÕES.	185
TABELA 32 - RESULTADO DAS MÉTRICAS: PRECISION, RECALL, F-SCORE E IOU.	190
TABELA 33 - DADOS DOS PARÂMETROS DA ETAPA DE PROCESSAMENTO.....	234
TABELA 34 - DADOS DOS PARÂMETROS DA ETAPA DE PROCESSAMENTO.....	235
TABELA 35 - DADOS DOS PARÂMETROS DA ETAPA DE PROCESSAMENTO.....	236
TABELA 36 - DESCRIÇÃO DOS MÉTODOS DE DETECÇÃO DE OBJETOS.....	237
TABELA 37 - DESCRIÇÃO DOS HIPERPARÂMETROS USADOS NO EXPERIMENTO.....	238
TABELA 38 - DESCRIÇÃO DAS MÉTRICAS DE DESEMPENHO USADAS NA AVALIAÇÃO.	238

LISTA DE QUADROS

QUADRO 1 - PRINCIPAIS REQUISITOS E CRITÉRIOS ESTABELECIDOS PARA COBERTURA, BASEADOS NAS EXIGÊNCIAS DE DESEMPENHO.	37
QUADRO 2 - AGENTES DE DEGRADAÇÃO QUE AFETAM A VIDA ÚTIL DOS COMPONENTES DA CONSTRUÇÃO.	39
QUADRO 3 - AGENTES DE DEGRADAÇÃO QUANTO À SUA ORIGEM.	40
QUADRO 4 - PROCEDÊNCIA DOS AGENTES.	40
QUADRO 5 - CARACTERIZAÇÃO DAS ANOMALIAS E CAUSAS EM COBERTURAS PLANAS.	46
QUADRO 6 - CLASSIFICAÇÃO DAS ANOMALIAS.	52
QUADRO 7 - PATAMARES DE URGÊNCIA.	53
QUADRO 8 - TIPOS DE EQUIPAMENTOS IDENTIFICADOS NO SISTEMA DE COBERTURA PLANA.	57
QUADRO 9 - PERGUNTAS PARA A ESCOLHA E ANÁLISE DOS ARTIGOS.	59
QUADRO 10 - REVISÃO SISTEMÁTICA DA LITERATURA PARA INSPEÇÃO E VISÃO COMPUTACIONAL.	60
QUADRO 11 - ARTIGOS ENCONTRADOS SOBRE INSPEÇÃO E VISÃO COMPUTACIONAL.	62
QUADRO 12 - REVISÃO SISTEMÁTICA DA LITERATURA PARA A INSPEÇÃO E GERAÇÃO DE ORTOIMAGENS.	65
QUADRO 13 - ARTIGOS ESCOLHIDOS QUE TRATAM DO PROCESSAMENTO DIGITAL E ORTOIMAGEM.	65
QUADRO 14 - RESULTADO DO LEVANTAMENTO BIBLIOGRÁFICO SOBRE COBERTURAS E FACHADAS.	68
QUADRO 15 - VARÁVEIS DE ANÁLISE PARA O SISTEMA DE COBERTURA PLANA.	85
QUADRO 16 - PARÂMETROS DA CÂMERA DO DJI MAVIC 2 PRO E DJI AIR 2S.	88
QUADRO 17 - MÉTRICAS PARA IMAGEM I E CLASSE MANCHA.	101
QUADRO 18 - CRITÉRIOS QUE AFETAM A QUALIDADE NA ETAPA DE PROCESSAMENTO, CONFORME A DEFINIÇÃO DE ALTITUDE E DO MAGEAMENTO.	125
QUADRO 19 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA BCE – 23 METROS – 1 DIREÇÃO.	128
QUADRO 20 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA BCE – 45 METROS – 1 DIREÇÃO.	129
QUADRO 21 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA BCE – 45 METROS – 5 DIREÇÕES.	130
QUADRO 22 - RESULTADO DO REPROCESSAMENTO COM NOVOS PARÂMETROS DA BCE – 45 METROS – 1 DIREÇÃO.	133
QUADRO 23 - RESULTADO DO REPROCESSAMENTO COM NOVOS PARÂMETROS DA BCE – 45 METROS – 5 DIREÇÕES.	134
QUADRO 24 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA REITORIA – 20 METROS – 2 DIREÇÕES.	139
QUADRO 25 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA UCA – 20 METROS – 2 DIREÇÕES.	141

QUADRO 26 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA UCA – 32 METROS – 2 DIREÇÕES.....	144
QUADRO 27 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NA UCA – 50 METROS – 2 DIREÇÕES.....	146
QUADRO 28 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NO QGEX – 22 METROS – 2 DIREÇÕES.....	150
QUADRO 29 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NO QGEX – 22 METROS – 2 DIREÇÕES.....	151
QUADRO 30 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NO QGEX – 35 METROS – 2 DIREÇÕES.....	152
QUADRO 31 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NO QGEX – 22 METROS – 2 DIREÇÕES.....	156
QUADRO 32 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO REALIZADO NO QGEX – 22 METROS – 2 DIREÇÕES.....	157
QUADRO 33 - RESULTADO DO REPROCESSAMENTO DO PLANO DE VOO REALIZADO NO QGEX – 35 METROS – 2 DIREÇÕES.....	158
QUADRO 34 - RESULTADO DO PROCESSAMENTO DOS SEGMENTOS REALIZADOS NO ICC A – 14 METROS – 2 DIREÇÕES.....	162
QUADRO 35 - RESULTADO DO PROCESSAMENTO DOS SEGMENTOS REALIZADOS NO ICC B – 14 METROS – 2 DIREÇÕES.....	167
QUADRO 36 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 1 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	239
QUADRO 37 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 2 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	240
QUADRO 38 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 3 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	241
QUADRO 39 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 4 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	242
QUADRO 40 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 5 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	243
QUADRO 41 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 6 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	244
QUADRO 42 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 7 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	245
QUADRO 43 - RESULTADO DO PROCESSAMENTO DO PLANO DE VOO 8 REALIZADO NO ICC – 14 METROS – 1 DIREÇÃO.	246

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AECO	Arquitetura, Engenharia, Construção e Operação
ASTM	<i>American Society of Testing and Materials</i>
ATSS	<i>Adaptive Training Sample Selection</i>
BCE	Biblioteca Central
CEPLAN	Centro de Planejamento Oscar Niemeyer
CNN	Rede Neural Convolutacional
COCO	<i>Microsoft Common Objects in Context</i>
CPU	Unidade Central de Processamento
DJI	<i>Dà-Jiāng Innovations Science and Technology</i>
DL	<i>Deep Learning</i>
EBSERH	Empresa Brasileira de Serviços Hospitalares
EFM	Elementos Fontes de Manutenção
EPSG	Geodetic Parameter Dataset
FASTER R-CNN	<i>Region-Based Convolutional Neural Networks</i>
FAU	Faculdade de Arquitetura e Urbanismo
FCN	<i>Fully Convolutional Networks</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
FOVEA	FoveaBox
GB	Gigabites
GHz	Gigahertz
GLONASS	<i>Global Navigation System</i>
GNSS	<i>Global Navigation Satellite system</i>

GPS	<i>Geographic Positioning System</i>
GR	Graus de risco
GSD	<i>Ground Sample Distance</i>
HSV	<i>Hue, Saturation, Value</i>
IA	Inteligência Artificial
ICC	Instituto Central de Ciências
IOU	<i>Intersection over Union</i>
ISO	<i>Internacional Organization for Standardization</i>
LASUS	Laboratório de Sustentabilidade aplicada à Arquitetura e ao Urbanismo
mAP	<i>Mean Average Precision</i>
MAE	<i>Mean Absolute Error</i>
ML	<i>Machine Learning</i>
MP	<i>Megapixel</i>
NBR	Norma Brasileira
P	<i>Precision</i>
PMBOK	Guia do Conhecimento em Gerenciamento de Projetos
QG	Quartel General
QGE_x	Quartel General do Exército Brasileiro
<i>r</i>	Correlação de Pearson
R	<i>Recall</i>
RETINA-NET	<i>Focal Loss</i>
RMSE	<i>Root Mean Square Error</i>
RNA	Redes Neurais Artificiais
SABL	<i>Side-Aware Boundary Localization</i>
SC	<i>Sistemas de Coberturas</i>

SFM	<i>Structure-From-Motion</i>
SLAM	<i>Simultaneous Localization and Mapping</i>
TLS	<i>Terrestrial Laser Scanning</i>
TN	<i>True Negative</i>
TP	<i>True Positive</i>
UAV	<i>Unmanned Aerial Vehicle</i>
UCA	Unidade da Criança e do Adolescente
UNB	Universidade de Brasília
VIT	<i>Vision Transformer</i>
VU	Vida Útil
VUP	Vida Útil De Projeto
VFNET	<i>VarifocalNet</i>
WGS	<i>World Geodetic System</i>

SUMÁRIO

1 INTRODUÇÃO	27
1.1 CONTEXTUALIZAÇÃO DO TEMA.....	27
1.2 ENQUADRAMENTO DA PESQUISA.....	29
1.3 PROBLEMATIZAÇÃO, QUESTÃO DE PESQUISA E HIPÓTESE	31
1.4 OBJETIVOS	32
1.4.1 OBJETIVO GERAL.....	32
1.4.2 OBJETIVOS ESPECÍFICOS	33
1.5 JUSTIFICATIVA DA TESE.....	33
1.6 ESTRUTURA DA TESE	34
2 INSPEÇÃO PREDIAL EM COBERTURA PLANA.....	36
2.1 SISTEMAS DE COBERTURA: EXIGÊNCIAS DE DESEMPENHO	36
2.2 DURABILIDADE E DESEMPENHO DAS COBERTURAS	37
2.3 AGENTES E MECANISMOS DE DEGRADAÇÃO ATUANTES EM COBERTURAS	39
2.4 SISTEMAS DE IMPERMEABILIZAÇÃO DE LAJE DE COBERTURA	43
2.4.1 CLASSIFICAÇÃO DAS ANOMALIAS EM LAJES PLANAS	46
2.5 INSPEÇÃO PREDIAL E MANUTENÇÃO NO SISTEMA DE COBERTURA.....	51
2.5.1 PROCEDIMENTOS DE INSPEÇÃO DE COBERTURAS	51
2.5.2 REQUISITOS PARA A MANUTENÇÃO	53
2.5.2.1 <i>Tipos de Manutenção.....</i>	54
2.5.3 PROGRAMA DE MANUTENÇÃO PREVENTIVA	54
2.6 EQUIPAMENTOS NO SISTEMA DE COBERTURA	56
3 TECNOLOGIAS DIGITAIS E PROCESSOS AUTOMATIZADOS	59
3.1 REVISÃO SISTEMÁTICA DE LITERATURA: MÉTODOS DE INSPEÇÃO PREDIAL AUTOMATIZADO	59
3.2 RESULTADOS DA REVISÃO SISTEMÁTICA DE LITERATURA: INSPEÇÃO PREDIAL AUTOMATIZADA E VISÃO COMPUTACIONAL	60
3.3 RESULTADOS DA REVISÃO SISTEMÁTICA DE LITERATURA: PROCESSAMENTO DE IMAGENS ADQUIRIDAS POR DRONES E GERAÇÃO DE ORTOIMAGENS.	64

3.4 REVISÃO DE LITERATURA INTEGRANDO OS TEMAS E OUTRAS BASES DE DADOS	67
3.4.1 FACHADAS	69
3.4.2 TELHADOS	71
3.4.3 COBERTURA PLANA	73
3.4.4 CONSIDERAÇÕES SOBRE O ESTADO DA ARTE E AS LACUNAS DE PESQUISA.....	75
4 MÉTODO DE PESQUISA	77
4.1 SELEÇÃO E CARACTERIZAÇÃO DA AMOSTRA.....	79
4.1.1 QUARTEL GENERAL DO EXÉRCITO BRASILEIRO (QGEX).....	79
4.1.2 UNIVERSIDADE DE BRASÍLIA – CAMPUS DARCY RIBEIRO.....	80
4.2 AQUISIÇÃO DE IMAGENS	84
4.2.1 CARACTERIZAÇÃO DAS VARIÁVEIS DE ANÁLISE DA PESQUISA.....	84
4.2.2 PLANEJAMENTO DOS PLANOS DE VOO PARA A AQUISIÇÃO DAS IMAGENS	87
4.2.3 PROCEDIMENTOS PARA AQUISIÇÃO DAS IMAGENS	87
4.3 ETAPAS DO PROCESSAMENTO DIGITAL DAS IMAGENS.....	90
4.3.1 AGISOFT® METASHAPE 1.5.0 BUILD 7492	91
4.4 PROCESSOS AUTOMATIZADOS EM DEEP LEARNING	92
4.4.1 DETECÇÃO AUTOMATIZADA DE EQUIPAMENTOS	93
4.4.1.1 <i>Pré-Pocessamento das Imagens e Construção do Conjunto de Dados Anotados</i>	95
4.4.1.2 <i>Algoritmos de Detecção e Hiperparâmetros</i>	96
4.4.1.3 <i>Métricas de Desempenho</i>	97
4.4.2 SEGMENTAÇÃO SEMÂNTICA AUTOMATIZADA PARA MANCHAS EM COBERTURAS PLANAS	97
5 RESULTADOS E DISCUSSÕES	103
5.1 ANÁLISES DOS PROCESSOS DE INSPEÇÃO E AQUISIÇÃO DAS IMAGENS	103
5.1.1 INSPEÇÃO E AQUISIÇÃO DAS IMAGENS NA BCE.....	104
5.1.2 INSPEÇÃO E AQUISIÇÃO DAS IMAGENS NO QGEX.....	107
5.1.3 INSPEÇÃO E AQUISIÇÃO DAS IMAGENS DO ICC UNB	109
5.1.4 INSPEÇÃO E AQUISIÇÃO DAS IMAGENS NA REITORIA DA UNB	114
5.1.5 INSPEÇÃO E AQUISIÇÃO DAS IMAGENS NA UCA – HUB NA UNB	115
5.2 ANÁLISE DO PROCESSAMENTO DIGITAL E ORTOIMAGENS	117

5.3 ANÁLISE DO PROCESSAMENTO DIGITAL DE COBERTURAS COM DIFERENTES NÍVEIS	126
5.3.1 PROCESSAMENTO DIGITAL DAS COBERTURAS PLANAS DA BCE	126
5.3.1.1 <i>Análise do Processamento Utilizando Novos Parâmetros</i>	131
5.3.2 PROCESSAMENTO DIGITAL DAS COBERTURAS PLANAS DA REITORIA	138
5.3.3 PROCESSAMENTO DIGITAL DAS COBERTURAS PLANAS DO HUB – UCA.....	141
5.4 ANÁLISE DO PROCESSAMENTO DIGITAL DE COBERTURAS LINEARES ..	148
5.4.1 PROCESSAMENTO DIGITAL DAS COBERTURAS LINEARES DOS EDIFÍCIOS DO QGEX	149
5.4.1.1 <i>Análise do Processamento Utilizando Novos Parâmetros</i>	153
5.4.2 PROCESSAMENTO DIGITAL DAS COBERTURAS LINEARES DOS BLOCOS A E B DO ICC....	159
5.4.2.1 <i>Merged Chunk do Bloco A e B do ICC</i>	161
5.5 ANÁLISE DO PROCESSAMENTO DIGITAL EM NÍVEL URBANO.....	169
5.6 ANÁLISE DOS PROCESSOS AUTOMATIZADOS EM <i>DEEP LEARNING</i>.....	176
5.6.1 RESULTADOS DO PROCESSO AUTOMATIZADO PARA DETECÇÃO DE EQUIPAMENTOS	176
5.6.2 RESULTADOS DO PROCESSO AUTOMATIZADO PARA SEGMENTAÇÃO SEMÂNTICA DE MANCHAS DE UMIDADE.....	186
5.6.2.1 <i>Considerações Iniciais</i>	186
5.6.2.2 <i>Resultados do Experimento para Segmentação Semântica de Manchas de Umidade</i>	188
5.6.2.3 <i>Discussão dos Resultados para Segmentação Semântica de Manchas de Umidade</i> .	191
5.6.2.4 <i>Análise dos Tipos de Erros no Experimento Realizado</i>	195
6 CENÁRIOS DE APLICAÇÃO	205
6.1 CENÁRIOS DE APLICAÇÃO DA INSPEÇÃO PREDIAL AUTOMATIZADA	205
7 CONCLUSÃO DA TESE.....	211
7.1 CONSIDERAÇÕES FINAIS	211
7.2 OBJETIVOS ALCANÇADOS E CONTRIBUIÇÕES DA TESE.....	212
7.3 SUGESTÕES PARA TRABALHOS FUTUROS.....	216
REFERÊNCIAS	217
APÊNDICE A	227
APÊNDICE B.....	234

APÉNDICE C237

APÉNDICE D239

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO DO TEMA

Entre os sistemas que compõem a envoltória, a cobertura desempenha um papel essencial na proteção da edificação contra precipitações e na atenuação de variações térmicas. Suas funções, além de preservar a saúde e o bem-estar dos usuários, influenciam a durabilidade dos elementos que a constituem (ABNT, 2021b).

As exigências referentes ao desempenho termo energético são condicionantes para a habitabilidade e sustentabilidade do ambiente construído (ABNT, 2021a).

O conjunto de requisitos a serem verificados em um sistema de cobertura depende, além da função essencial de segurança estrutural, das funções específicas de uso, configurações arquitetônicas e processos construtivos adotados.

No entanto, os procedimentos de inspeção predial muitas vezes negligenciam a identificação prévia das manifestações patológicas, o que pode ocasionar problemas de manutenção corretiva (Bown; Miller, 2018). Se esses forem reparados dentro do prazo previsto de manutenção preventiva, podem manter níveis mínimos de intervenção (ABNT, 2020).

Um dos problemas gerados pela falta de manutenção, por exemplo, é a redução da vida útil do sistema construtivo, acelerada pela exposição contínua dos elementos, circulação de pessoas sobre o sistema de impermeabilização e operações de manutenção periódica em equipamentos posicionados sobre a cobertura. A manutenção oportuna e adequada do sistema de cobertura desempenha, portanto, um papel indispensável na mitigação de manifestações patológicas e no prolongamento da vida útil de suas partes (ABNT, 2012).

Nesse sentido, a inspeção é essencial no processo de manutenção predial, pois auxilia no diagnóstico dos danos presentes e no planejamento dos reparos e substituições que influenciam o desempenho do sistema e seus componentes. Assim, as atividades de reabilitação e manutenção são fatores-chave para a sustentabilidade e o aumento da vida útil da edificação (Ferraz *et al.*, 2016).

No entanto, os procedimentos tradicionais de inspeção predial são demorados e trabalhosos, podendo apresentar riscos à saúde e à segurança dos inspetores, especialmente quando realizados em altura, em coberturas de difícil acesso, e quando o tempo gasto nas inspeções é longo. Além disso, as inspeções geralmente são baseadas em análises sensoriais, visuais e subjetivas, dependendo da experiência dos inspetores (Kim *et al.*, 2017).

O setor da Arquitetura, Engenharia, Construção e Operação (AECO) vem investindo em novas tecnologias para facilitar os processos de inspeção predial. Uma das tecnologias que se

destacam é o uso de drones, cujo crescimento rápido na última década tornou a realização de diferentes trabalhos mais flexível. Dessa forma, é possível reduzir o tempo, o risco de acidentes e os erros na coleta e processamento de dados (Silveira; Melo; Costa, 2020).

Uma das vantagens no uso de drones, quando comparado aos métodos tradicionais de inspeção, está na facilidade de adaptação da tecnologia a diferentes condições operacionais (Nex; Remondino, 2019; Rakha *et al.*, 2018), proporcionando mobilidade na aquisição de dados e capacidade de voo em diferentes alturas, com alta resolução das imagens digitais (Banaszek; Banaszek; Cellmer, 2017). Destaca-se, por exemplo, a captação de imagens aéreas orientadas via GPS para a modelagem 3D (Roca *et al.*, 2013; Nex; Remondino, 2019). A captura de imagens digitais por meio de drones facilita o levantamento físico em campo, a detecção de manifestações patológicas e o monitoramento do estado de conservação. Esta etapa é necessária para o projeto *as built* e para a automação de mapas de danos baseados em padrões de imagens (Llamas *et al.*, 2017).

Diferente das inspeções manuais tradicionais, as inspeções com uso de tecnologias digitais geram bancos de imagens e dados digitais que permitem o armazenamento e a gestão da informação, garantindo a comparação de resultados de inspeções programadas ao longo do tempo. Por isso, nos últimos anos, houve um aumento de pesquisas com o uso do drone e a utilização de técnicas de processamento de imagens associadas a tecnologias de Inteligência Artificial (IA) para detectar e classificar manifestações patológicas (Ko; Prieto; Soto, 2021).

O uso de drone como ferramenta para a aquisição de imagens digitais potencializa a aplicação de algoritmos de aprendizagem de máquina associados a técnicas de visão computacional¹ em processos automatizados que contribuem para a gestão da manutenção. Na aprendizagem de máquina (*machine learning*), os algoritmos de redes neurais compõem os processos de aprendizagem profundo (*deep learning*). Para operar e aprender, o algoritmo utiliza múltiplas camadas de abstração por meio de redes neurais convolucionais. Os modelos de redes neurais podem ser aplicados com sucesso em tarefas de reconhecimento, detecção, classificação e segmentação de objetos ou cenas (Yin; Antonio, 2020). Nesse contexto, no campo da inspeção predial automatizada, é possível processar medições, identificar situações de risco, mapear danos e, por fim, avaliar as condições existentes para subsidiar a tomada de decisão sobre a manutenção dos edifícios e a supervisão das operações e serviços executados.

¹ Visão computacional é um campo da ciência que desenvolve algoritmos para o processamento e análise automática de dados visuais, permitindo a identificação de padrões e a extração de características de imagens, vídeos, expressões faciais, gestos e outros elementos visuais.

1.2 ENQUADRAMENTO DA PESQUISA

A presente pesquisa de doutorado insere-se no contexto nacional e internacional relacionado à inspeção predial automatizada em sistemas de coberturas planas com lajes impermeabilizadas. O tema da inspeção predial automatizada abordado neste estudo concentra-se no uso de tecnologia digital para aquisição de imagens por meio de drones, no processamento digital aplicado a coberturas com diferentes níveis e configurações arquitetônicas. A pesquisa está delimitada na identificação de falhas na superfície das coberturas, resultantes do processo de instalação de equipamentos e presença de manchas, analisados por técnicas de visão computacional, com uso de detecção e segmentação semântica. A Figura 1 apresenta uma síntese do campo conceitual deste estudo.

Figura 1 - Campo conceitual do contexto temático da tese de pesquisa.



Fonte: Elaborado pela autora.

Diversos estudos destacam o uso do drone como ferramenta para inspeção predial. Costa *et al.* (2022) utilizaram drones para captura de imagens, visando a modelagem 3D de uma edificação localizada no Rio Grande do Sul. Lopes *et al.* (2023) sistematizaram um processo de inspeção de fachadas utilizando drones para o mapeamento de danos causados pela degradação em revestimento argamassado, na cidade de Brasília. Ferreira *et al.* (2024) empregaram drones equipados com sensores infravermelhos para inspecionar padrões de coloração em manchas nas fachadas de um edifício localizado na cidade do Rio de Janeiro.

Para realizar inspeções em sistemas de cobertura, drones foram utilizados no trabalho de Banaszek, Banaszek e Cellmer (2017), que analisaram a relação entre a altura do voo e a qualidade das imagens na identificação de aspectos como estanqueidade, condições de calhas, inclinação dos panos de telhado e componentes danificados. Silveira, Melo e Costa (2020) desenvolvem um protocolo de voo para a captura de imagens de coberturas com drones, visando realizar inspeções pós-ocupação em conjuntos residenciais.

A integração de drones com redes neurais revela-se uma estratégia adequada para realizar inspeções de cobertura de maneira rápida e segura (Moore *et al.*, 2018). Hezaveh, Kanan e Salvaggio (2017) mapearam danos causados por granizo em telhados, utilizando um banco de imagens capturadas por drones para automatização por meio de *deep learning*, aplicando algoritmos de detecção em redes neurais convolucionais. Rakha e Gorodetsky (2018) abordaram o planejamento de voo para coleta de dados e fotogrametria, integrando visão computacional para segmentar imagens térmicas e detectar anomalias.

Os estudos no campo da visão computacional também estão presentes nos trabalhos de Ottoni, Novo e Costa (2022) que utilizaram modelos de *deep learning* para classificar imagens de telhados em duas classes: calhas sujas e calhas limpas. Para isso, os pesquisadores propuseram uma metodologia de ajuste de hiperparâmetros em redes neurais convolucionais.

Staffa *et al.* (2020) e Staffa Junior *et al.* (2023), vinculados aos trabalhos de pesquisa da professora Dayana B. Costa, da Universidade Federal da Bahia (UFBA), avaliaram o uso de técnicas de processamento de imagens para inspeção de telhados para fins de assistência técnica. Para identificar anomalias em imagens adquiridas por drones, foram realizados treinamentos e testes de algoritmos de processamento de imagens da ferramenta Custom Vision, da Microsoft. Esses estudos buscaram eliminar os riscos de segurança envolvidos em inspeções tradicionais manuais, proporcionando maior eficiência na coleta e análise de dados, além de reduzir o tempo necessário para as vistorias.

Em *deep learning*, as arquiteturas de redes neurais permitem que modelos computacionais compostos por várias camadas de processamento aprendam representações de dados em diferentes níveis de abstração (Yin; Antonio, 2020). Taoufiq, Nagy e Benedek (2020) investigaram o reconhecimento de objetos em sistemas de cobertura, utilizando inspeções automatizadas em tarefas dinâmicas e rápidas para verificar fixação de equipamentos, manutenções e estado de conservação do sistema.

A utilização de sistemas de inspeção automatizados exige algoritmos robustos de detecção e classificação, como as arquiteturas de redes neurais convolucionais (Hezaveh; Kanan; Salvaggio, 2017), que permitem o reconhecimento visual e a detecção de objetos em grandes conjuntos de dados (Lecun; Bengio; Hinton, 2015). Por esse motivo, as redes neurais convolucionais (CNN) têm sido amplamente aplicadas na classificação de imagens e detecção de objetos, devido à sua eficácia na identificação de estruturas complexas em conjuntos de dados (Staffa *et al.*, 2020).

Esse enquadramento da pesquisa evidencia como as tecnologias digitais para aquisição de imagens viabilizaram a construção de bancos de imagens e, portanto, estão impulsionando a

adoção de métodos e técnicas baseados em redes neurais e visão computacional. Assim, o campo conceitual delineado aponta que inspeções prediais automatizadas requerem processos de captura e processamento de imagens digitais de qualidade, capazes de formar uma base informacional essencial para aplicações em inteligência artificial.

1.3 PROBLEMATIZAÇÃO, QUESTÃO DE PESQUISA E HIPÓTESE

Os sistemas de cobertura com laje impermeabilizada em geral estão sujeitas a processos naturais de envelhecimento. No entanto, as deficiências no projeto e na execução, uso e operação inadequados, não conformidade nas operações de limpeza e manutenção, alterações climáticas, níveis de poluição, além da qualidade dos materiais e da construção, comprometem a estanqueidade, causando infiltrações, vazamento, perda de funcionalidade, e acelerando a degradação dos componentes (ABNT, 2021a). Nesse sentido, as coberturas planas frequentemente demandam ações de manutenção que exigem equipes especializadas e capacitadas para operar em seus sistemas e nas condições em altura.

O uso inadequado das coberturas para acomodar equipamentos é uma situação muito frequente em conjuntos edificados com grandes lajes impermeabilizadas. Essa prática frequentemente resulta na presença de equipes terceirizadas responsáveis pela manutenção dos aparelhos e instalações, que nem sempre estão treinadas e sensibilizadas para proteger os sistemas de impermeabilização (Zanoni *et al.*, 2023). Além disso, os equipamentos instalados nessas áreas dificultam o escoamento das águas pluviais e o funcionamento adequado dos ralos, provocando empoçamentos. A presença de umidade sobre a superfície da cobertura acelera o processo de degradação da camada de impermeabilização, favorece o acúmulo de sujeira e causa infiltrações (Santos *et al.*, 2023).

As manchas de umidade que aparecem na camada de impermeabilização e em sua proteção mecânica após as chuvas têm como principais causas as irregularidades na superfície da cobertura e os declives inadequados, que comprometem o escoamento eficiente da água da chuva. As manchas são indicadores que sinalizam processos de degradação progressiva que comprometem a durabilidade dos componentes da cobertura (Santos *et al.*, 2025).

Na pesquisa bibliográfica realizada para este trabalho, foram identificados poucos estudos na literatura e nas práticas atuais no que se refere a utilização das técnicas de visão computacional para avaliar as condições de sistemas de cobertura plana, com foco na detecção de equipamentos instalados e na segmentação de manchas presentes nesse tipo de sistema.

Outro problema central identificado na pesquisa bibliográfica foi a limitada disponibilidade de referências e informações voltadas ao processamento digital de imagens

obtidas por drones em inspeções prediais de sistemas de cobertura plana com diferentes níveis e configurações arquitetônicas. O uso de processamento digital em processos automatizados revela-se essencial para a geração de ortomosaicos de alta qualidade, evitando retrabalhos decorrentes da adoção inadequada de parâmetros e procedimentos não planejados nas etapas das tarefas.

Poucas pesquisas têm se dedicado a correlacionar os processos de captura de imagens e o processamento digital com a qualidade dos ortomosaicos gerados, considerando as diferentes configurações e níveis de coberturas planas. A ausência de abordagens que integrem as tecnologias digitais compromete a eficácia das inspeções e do monitoramento desses sistemas. De forma geral, os estudos enfrentam dificuldades na obtenção de amplos conjuntos de dados relacionados a manifestações patológicas em sistemas de cobertura com manta ou membrana de impermeabilização. Dessa forma, destaca-se a necessidade de aprofundar o uso das ferramentas digitais e a adoção de parâmetros que influenciam diretamente as avaliações.

Com base nesses aspectos, foi formulada a seguinte questão de pesquisa para orientar o desenvolvimento do estudo:

- Como a utilização de tecnologias digitais e processos automatizados pode contribuir para o aprimoramento das inspeções prediais e da gestão da manutenção em sistemas de cobertura plana com grandes lajes impermeabilizadas?

HIPÓTESE: A implementação de tecnologias digitais e processos automatizados, como o uso de drones para captura de imagens, o processamento de dados por meio de visão computacional e a aplicação de métodos e técnicas em *machine learning*, contribuem para a melhoria significativa dos procedimentos de inspeção predial e da gestão da manutenção em sistemas de cobertura plana com lajes impermeabilizadas.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

O objetivo geral desta tese é propor parâmetros, procedimentos, diretrizes e estratégias para o aprimoramento de inspeções prediais de sistemas de cobertura plana por meio de tecnologias digitais para aquisição de imagens e de processamentos automatizados.

1.4.2 Objetivos Específicos

- Analisar a utilização de drones como ferramenta para captura de imagens e o processamento de dados para geração de ortoimagens, visando mapear e monitorar manchas de umidade e equipamentos em cobertura plana com lajes impermeabilizadas;
- Identificar a qualidade dos parâmetros para as inspeções prediais por imagens capturadas por drone, e posterior processamento digital das imagens;
- Explorar o uso de métodos e técnicas de visão computacional como estratégias para aprimorar a inspeção predial e a gestão da manutenção;
- Analisar a aplicação de redes neurais baseadas em *deep learning* para a segmentação semântica de manchas e a detecção de equipamentos em sistemas de cobertura plana; e,
- Delinear cenários para aplicação de inspeções prediais automatizadas em sistemas de cobertura plana impermeabilizadas, baseados em estratégias e diretrizes específicas para planos de voo destinados à captura de imagens de coberturas planas, tanto lineares quanto em níveis diferenciados.

1.5 JUSTIFICATIVA DA TESE

Conjuntos edificados complexos, como os edifícios públicos de propriedade de instituições governamentais, possuem uma administração centralizada para a contratação de empresas prestadoras de serviços, aquisição de materiais por meio de orçamentos e licitações fundamentadas em banco de dados. Os planos de manutenção e conservação, bem como os controles de ativos (instalações e equipamentos), são a motivação desta pesquisa e têm o potencial de impulsionar o avanço nas investigações tecnológicas em instituições ou organizações responsáveis por grandes complexos edificados.

A escassez de estudos direcionados aos sistemas de cobertura plana, especialmente em edificações de grande porte com diferentes níveis e configurações arquitetônicas, evidencia algumas lacunas significativas na literatura. Essa carência ressalta a relevância desta pesquisa, que propõe uma alternativa aos métodos tradicionais de inspeção. A investigação busca abordar as limitações dos processos tradicionais de inspeção, contribuindo para o avanço científico e tecnológico no campo da inspeção predial automatizada.

A presença de equipamentos desativados em coberturas, resultante de constantes atualizações tecnológicas nos sistemas instalados, seja devido ao seu processo de instalação ou à obsolescência técnica e funcional, exige controle adequado para descarte. Quando permanecem sobre a cobertura, além de favorecerem a proliferação de mosquitos, esses equipamentos podem obstruir ralos, causar infiltrações ou provocar empoçamentos, acelerando

a degradação da camada de impermeabilização. O uso de drones e técnicas de visão computacional permitem identificar e registrar equipamentos desativados e sem funcionalidade, contribuindo para a gestão de ativos mais eficiente.

A relevância da inspeção predial com processos automatizados está em sua capacidade de otimizar a tomada de decisão, facilitando o monitoramento e o planejamento das manutenções necessárias. Nesse contexto, o delineamento de diferentes cenários para a aplicação de inspeção predial automatizada oferece benefícios como o aprimoramento do monitoramento contínuo, a geração de documentação para comparações futuras e a possibilidade de análises integradas por equipes multidisciplinares. A criação desses cenários busca orientar as melhores práticas para a condução de inspeções prediais automatizadas, com ênfase no uso de tecnologias capazes de aprimorar o monitoramento e a gestão dos edifícios.

1.6 ESTRUTURA DA TESE

Esta tese está organizada em sete seções, além das seções de referências e apêndices, conforme ilustrado na Figura 2. Na Introdução, são apresentados a contextualização do tema, o enquadramento da pesquisa, a problematização, a justificativa, o objetivo geral e os objetivos específicos.

As seções dois e três abordam as bases conceituais e a fundamentação teórica relacionadas ao desempenho e à durabilidade das coberturas, incluindo os agentes e mecanismos de degradação, bem como a importância das inspeções e manutenções prediais desses sistemas. A seção três, especialmente, apresenta uma revisão sistemática da literatura, abrangendo artigos nacionais e internacionais recentes, com foco na inspeção predial e nos processos automatizados aplicados às coberturas, identificando lacunas no conhecimento.

A seção quatro descreve o método de pesquisa adotado para alcançar os objetivos propostos. São detalhados o levantamento de dados, a caracterização e justificativa da amostra, a aplicação de tecnologias para aquisição e processamento digital de imagens e as suas etapas. Adicionalmente, são esquematizadas as aplicações de processos automatizados com o uso de *deep learning*.

A seção cinco apresenta os resultados obtidos, incluindo análises e discussões sobre o processamento digital de imagens em coberturas com diferentes níveis e configurações arquitetônicas, selecionadas para compor a amostra. Além disso, são examinados os processos automatizados em *deep learning* aplicados à inspeção predial.

Na seção seis, em síntese, são delineados cenários com estratégias, diretrizes e recomendações para aplicação da inspeção predial automatizada.

Finalmente, a seção sete apresenta as conclusões da pesquisa e os objetivos alcançados, destacando as principais contribuições originais para o avanço no conhecimento científico, as limitações do estudo e as sugestões para trabalhos futuros.

Figura 2 - Organização das seções da pesquisa.

01	INTRODUÇÃO: <ul style="list-style-type: none"> Contextualização; Enquadramento; Problematização, questões de pesquisa e hipótese; Objetivos; Justificativa; Estrutura da tese.
02 03	INSPEÇÃO PREDIAL EM COBERTURA PLANA: <ul style="list-style-type: none"> Sistemas de cobertura: exigências de desempenho; Durabilidade e desempenho das coberturas; Agentes e mecanismos de degradação atuantes em cobertura; Sistema de impermeabilização em laje de cobertura; <ul style="list-style-type: none"> classificação das anomalias em lajes planas inspeção predial e manutenção no sistema de cobertura Equipamentos no sistema de cobertura. TECNOLOGIAS DIGITAIS E PROCESSOS AUTOMATIZADOS: <ul style="list-style-type: none"> Revisão sistemática da literatura; Tecnologias digitais de aquisição de imagens: inspeção de cobertura; e, Uso da inteligência artificial em cobertura.
04	MÉTODO DE PESQUISA: <ul style="list-style-type: none"> Amostra; Levantamento de dados; Etapas e procedimentos para aquisição de dados; e, Processamento digital de imagens.
05	RESULTADOS E DISCUSSÕES: <ul style="list-style-type: none"> Resultados do protocolo de inspeção predial em cobertura plana; Análise do processamento digital e ortoimagens; Análise do processamento digital de coberturas com diferentes níveis; Análise do processamento digital de coberturas lineares; Análise do processamento digital em nível urbano; e, Análise dos processos automatizados em <i>deep learning</i>.
06	CENÁRIOS DE APLICAÇÃO: <ul style="list-style-type: none"> Cenários de aplicação da inspeção predial automatizada.
07	CONCLUSÃO DA TESE: <ul style="list-style-type: none"> Considerações finais; objetivos alcançados, contribuições da tese e sugestões para trabalhos futuros.

Fonte: Elaborado pela autora.

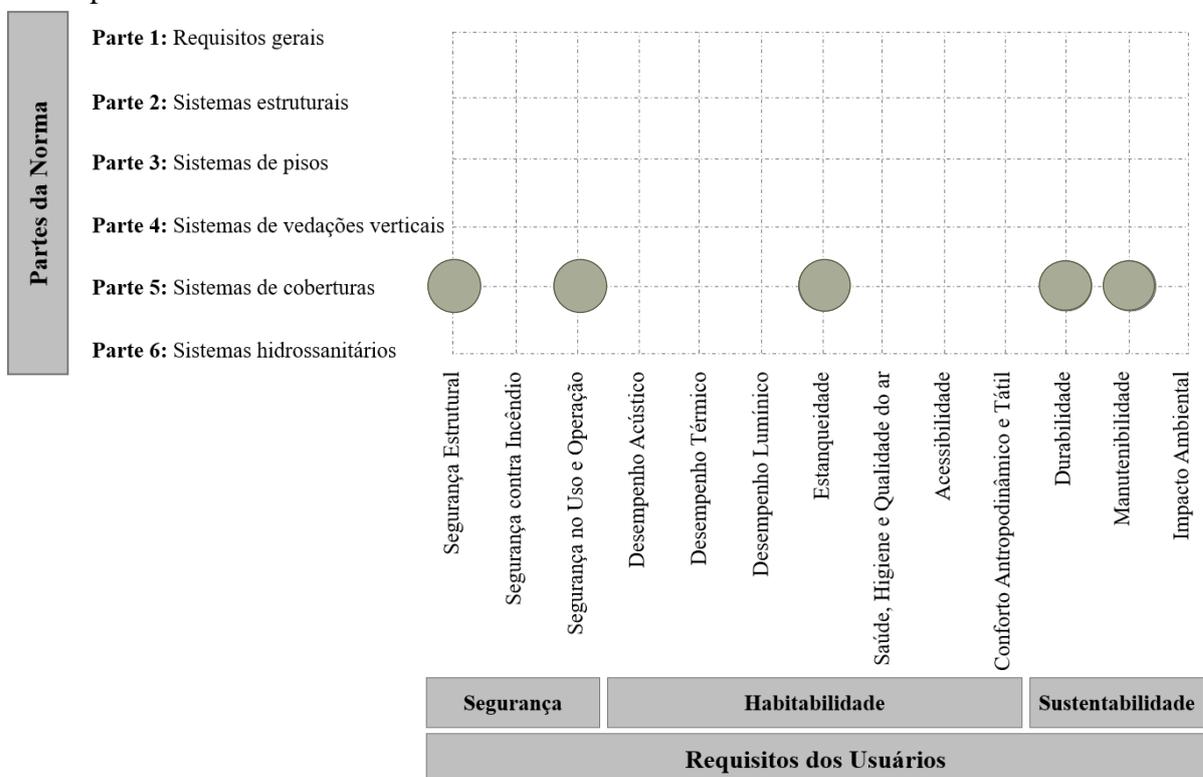
2 INSPEÇÃO PREDIAL EM COBERTURA PLANA

2.1 SISTEMAS DE COBERTURA: EXIGÊNCIAS DE DESEMPENHO

O sistema de cobertura é formado por elementos e componentes dispostos no topo da construção (ABNT, 2020), cuja função principal é assegurar a proteção e durabilidade dos demais sistemas da edificação e a preservação da saúde dos usuários. Os sistemas de coberturas (SC) devem impedir a infiltração de águas pluviais e umidade oriunda das condições de exposição, garantindo a estanqueidade, a salubridade e os ambientes habitáveis sem a proliferação de micro-organismos patogênicos (ABNT, 2021b).

Para atender às necessidades básicas do usuário, consideram-se os requisitos e critérios de segurança, habitabilidade e sustentabilidade, prescritos pelo conjunto de normas de desempenho, apresentado resumidamente no Quadro 1. A Figura 3 foi elaborada para ilustrar as exigências dos usuários e delimitar aquelas que estruturam o campo de interesse de pesquisa deste trabalho de tese. Na norma de desempenho, a vida útil das coberturas insere-se como um requisito de durabilidade e, no caso dos sistemas de coberturas, está fortemente associada aos requisitos de estanqueidade, manutenibilidade e segurança no uso e operação.

Figura 3 – Matriz de relações entre as exigências e requisitos, com base na norma de desempenho.



Fonte: Elaborado pela autora, baseado em Souza (2019) e na NBR 15575-1 (ABNT, 2021a).

Quadro 1 - Principais requisitos e critérios estabelecidos para cobertura, baseados nas exigências de desempenho.

Exigência de desempenho	Requisitos e critérios
Segurança no uso e na operação (NBR 15575-5)	Requisito 1: Integridade no sistema de cobertura. Critério: Risco de deslizamento de componentes.
	Requisito 2: Manutenção e operação. Propiciar condições seguras para sua montagem e manutenção, bem como para a operação de dispositivos instalados sobre ou sob o sistema de cobertura. Critério: Possibilidade de caminhamento de pessoas sobre o sistema de cobertura.
Estanqueidade (NBR 15575-5)	Requisito 1: Condições de salubridade no ambiente habitável. Critério: Estanqueidade para sistema de cobertura impermeabilizado.
Durabilidade e manutenibilidade (NBR 15575-5)	Requisito 1: Vida útil de projeto dos sistemas de cobertura. Critério: Vida útil de projeto.
	Requisito 2: Manutenibilidade das coberturas. Critério: Premissas de projeto: a) características gerais de funcionamento dos componentes, aparelhos ou equipamentos que fazem parte da cobertura, interferem nela ou possuem relação direta com seu desempenho; b) recomendações gerais para prevenção de falhas e acidentes decorrentes de utilização inadequada; c) periodicidade, forma de realização e forma de registro de inspeções e manutenções.
Funcionalidade e acessibilidade (NBR 15575-5)	Requisito 1: Possibilitar a instalação, manutenção e desinstalação de dispositivos e equipamentos necessários à operação da edificação.
	Requisito 2: Manutenção dos equipamentos e dispositivos ou componentes constituintes e integrantes do sistema de cobertura. Critério: O sistema de cobertura deve ser passível de proporcionar meios pelos quais permitam atender fácil e tecnicamente às vistorias, manutenções e instalações previstas em projeto.

Fonte: Baseado na NBR 15575-5 (ABNT, 2021b).

Portanto, para garantir que os requisitos de desempenho sejam atendidos (Quadro 1), devem ser tomados os cuidados necessários na fase de projeto, especificação dos materiais, seleção das técnicas de construção e execução do processo construtivo. Para atender aos critérios de manutenibilidade, no entanto, o sistema de cobertura deve possuir um plano de manutenção adequado, para o que a vida útil mínima de projeto seja obedecida.

2.2 DURABILIDADE E DESEMPENHO DAS COBERTURAS

A durabilidade pode ser definida como a capacidade da edificação ou de seus sistemas de desempenhar suas funções ao longo do tempo e sob condições de uso e manutenção especificadas no manual de uso, operação e manutenção (ABNT, 2021a). Por outro lado, a degradação é uma consequência do processo de envelhecimento natural, associado à exposição da edificação às condições climáticas (BS, 2012).

A durabilidade é um dos requisitos qualitativos determinados pela NBR 15575-1 (ABNT, 2021a). As medidas de desempenho e vida útil são critérios quantitativos do requisito de durabilidade; são métricas passíveis de serem verificadas. Um elemento de uma construção irá atingir o fim da sua vida útil quando deixar de desempenhar as suas funções, devido às alterações de desempenho requeridas em relação à utilização destinada (Zanoni, 2015, Souza; 2019, ABNT, 2021a).

A Tabela 1 apresenta os valores estimados para a vida útil de projeto (VUP) para o sistema de cobertura e suas partes. Recomenda-se que a VUP da cobertura tenha um tempo mínimo de 20 anos e superior de 30 anos ou mais, definido em projeto e garantido por meio de manutenções programáveis sob a responsabilidade do usuário. A vida útil pode ser prolongada por meio das ações de manutenção.

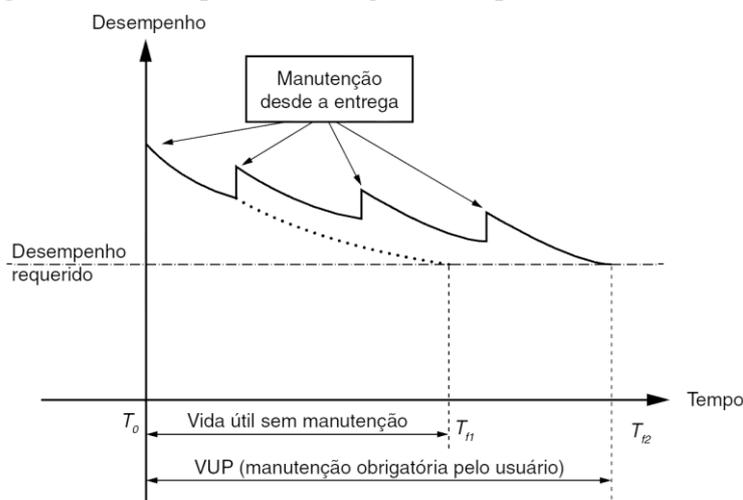
Tabela 1 - Vida Útil de Projeto para cobertura.

SISTEMA	Vida Útil de Projeto (VUP)		
	Mínimo	Intermediário	Superior
COBERTURA	≥ 20	≥ 25	≥ 30
Estrutura da cobertura e coletores de águas pluviais embutidos	≥ 20	≥ 25	≥ 30
Telhamento	≥ 13	≥ 17	≥ 20
Calhas de beiral e coletores de águas pluviais aparentes, subcoberturas facilmente substituíveis	≥ 4	≥ 5	≥ 6
Rufos, calhas internas e demais complementos (de ventilação, iluminação, vedação)	≥ 8	≥ 10	≥ 12
Sem quebra de revestimentos			
- Componentes de juntas e rejuntamentos; mata-juntas, sancas, golas, rodapés e demais componentes de remate	≥ 4	≥ 5	≥ 6
- Impermeabilização de caixa d'água, jardineiras, áreas externas com jardins, coberturas não utilizáveis, calhas e outros	≥ 8	≥ 10	≥ 12
Com quebra de revestimentos			
- Impermeabilização de áreas internas, de piscina, de áreas externas com pisos, de coberturas utilizáveis, de rampas de garagem, etc.	≥ 20	≥ 25	≥ 30

Fonte: Adaptado de NBR 15575-1 (ABNT, 2021a).

A Figura 4 ilustra a forma como os edifícios se comportam ao longo do tempo. Ao longo do tempo, a exposição dos sistemas construtivos aos agentes de degradação afeta o desempenho dos edifícios ou de seus elementos. Conseqüentemente, a capacidade de responder às exigências dos usuários diminui, surgindo as anomalias. As ações de manutenção podem evitar a redução do desempenho a um nível inaceitável ou abaixo do desempenho requerido (Mota, 2021).

Figura 4 - Desempenho ao longo do tempo.



Fonte: Adaptado de NBR 15575-1 (ABNT, 2021a).

A redução do desempenho tende a ser maior quanto mais sensível o elemento for à degradação e quanto mais extremas forem as condições de exposição. Os elementos e

componentes que constituem a cobertura são vulneráveis à degradação devido à contínua e prolongada exposição aos agentes de degradação (Morgado, 2012). É considerável caracterizar as operações de manutenção pertencentes a uma estratégia de proteção proativa e assim minimizar a degradação prematura dos elementos construtivos durante a sua vida útil (Morgado, 2012).

Deste modo, a manutenibilidade é o grau de facilidade de um sistema, elemento ou componente de ser mantido ou recolocado no estado no qual possa desempenhar suas funções requeridas, sob condições de uso especificadas, desde que a manutenção seja executada sob condições determinadas, por procedimentos e meios prescritos (ABNT, 2021b).

2.3 AGENTES E MECANISMOS DE DEGRADAÇÃO ATUANTES EM COBERTURAS

De acordo com a ISO 15686-2 (BS, 2012) e a NBR 15575-1 (ABNT, 2021a), a degradação é definida como qualquer ação que resulte na perda de uma ou mais propriedades de um componente e que reduza seu desempenho. A degradação é, portanto, resultado de fenômenos naturais que causam mudanças química e/ou físicas dos sistemas e do uso do edifício; é a causa da redução do desempenho devido à atuação de um ou de vários agentes de degradação.

Os agentes de degradação podem ser classificados conforme a sua natureza e forma de atuação em um edifício ou em suas partes afetando o seu desempenho. Externamente à edificação, a origem dos agentes pode ser a atmosfera ou o solo, enquanto internamente à edificação, a origem está relacionada à ocupação, projetos ou construção (BS, 2012). O Quadro 2 mostra a classificação dos agentes de degradação de acordo com a sua natureza e classe.

Quadro 2 - Agentes de degradação que afetam a vida útil dos componentes da construção.

Natureza dos agentes de degradação	Classe
Agentes mecânicos	Gravidade Cargas e deformações impostas ou restringidas Energia cinética Vibrações e ruídos
Agentes eletromagnéticos	Radiação Eletricidade Magnetismo
Agentes térmicos	Níveis extremos ou alterações bruscas de temperatura
Agentes químicos	Água e solventes Agentes oxidantes Agentes redutores Ácidos Bases Sais Agentes quimicamente neutros (poeira, gordura, sílica)
Agentes biológicos	Vegetais (plantas, raízes) Microbiano (bactérias, fungos e bolor) Animal (insetos, aves, roedores, cupim) Algas

Fonte: ISO 15686-2 (BS, 2012), adaptado de ISO 6241 (BS, 1984) e Zaroni (2015).

Os elementos construtivos que constituem um edifício encontram-se especificados para responder a determinada exigência, principalmente no que se refere à garantia de adequada qualidade de vida aos seus usuários. No entanto, a degradação que os elementos da construção sofrem ao longo da sua vida útil resulta da ocorrência de anomalias, as quais podem conduzir a menores níveis de desempenho desses elementos (Pereira, 2017; Portugal, 2006).

O Quadro 3 apresenta os agentes de degradação quanto à sua origem (BS, 2011). De acordo com a ASTM E-632 (1996), os agentes de degradação podem ser classificados em função da sua procedência, identificando o tipo e a faixa de fatores de degradação aos quais o componente ou material será exposto. A procedência dos agentes e suas causas estão listadas no Quadro 4.

Quadro 3 - Agentes de degradação quanto à sua origem.

Origem Externa	Atmosférica	Chuva Dilatações térmicas e higroscópicas Ventos Choques	Radiação solar Choque térmico Umidade do ar Contaminantes do ar
	Solo	Pressão da terra Sismos Calor	Água da superfície e subterrânea Ácidos
Origem Ocupação Interna	Ocupação/Uso	Sobrecargas Vibrações Calor emitido	Projeção de água Condensação
	Consequência de projeto	Cargas permanentes Fluência Forças	Deformações Vibrações Infiltrações

Fonte: Adaptado de ISO 15686-1 (BS, 2011).

Quadro 4 - Procedência dos agentes.

Procedência dos agentes	Causas
Fatores climáticos	Radiação Temperatura Água Contaminantes do ar Gelo e Degelo Vento
Fatores de uso	Projeto Instalação Desgaste natural ou por uso Falta de manutenção
Fatores biológicos	Microrganismos Fungos Bactérias
Fatores de carregamento	Carregamentos periódicos e/ou permanentes
Incompatibilidades	Físicas Químicas

Fonte: Adaptado de ASTM E632 (1996).

O conhecimento dos agentes de degradação dos materiais permite tomar decisões no desenvolvimento do projeto, que podem proporcionar maior proteção aos componentes e o aumento da vida útil, mesmo quando são mantidas as condições de exposição (Zanoni, 2015).

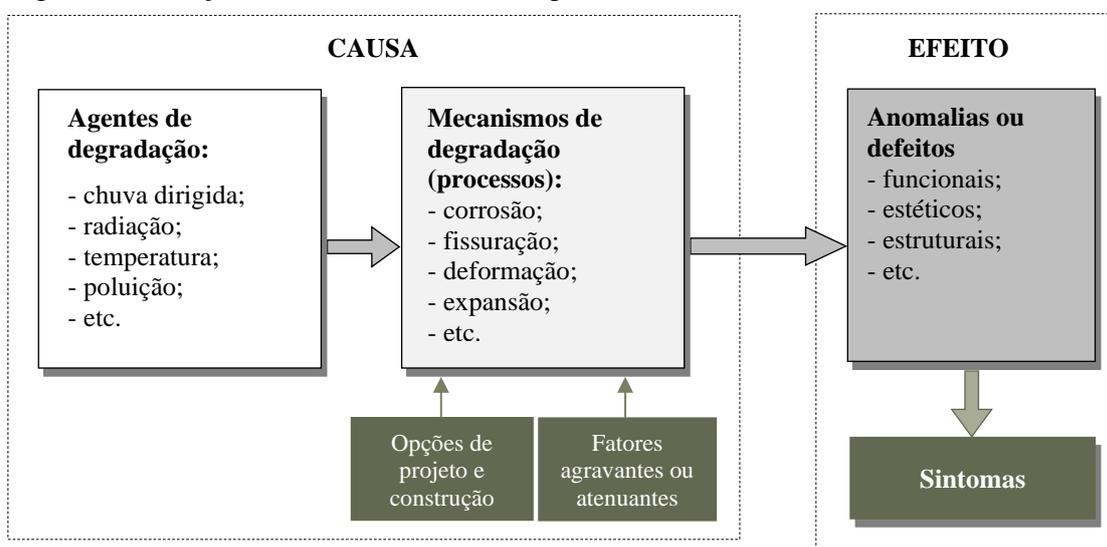
As condições de exposição da envoltória do edifício constituem-se em um conjunto de ações que afetam a sua durabilidade. As ações externas de origem climática estão entre os principais agentes de degradação que reduzem o desempenho ao longo do tempo de vida útil e aceleram os mecanismos de envelhecimento (Zanoni, 2015).

A degradação pode ser entendida, portanto, como a perda de desempenho de um edifício e de seus sistemas devido à atuação de agentes que afetam negativamente o desempenho dos componentes e materiais do edifício e, conseqüentemente, reduzem sua vida útil (Santos, 2018). Na construção civil, as edificações devem ser capazes de resistir à ação dos agentes de degradação por um tempo predeterminado ou previsto (Santos Junior *et al.*, 2021).

A ASTM E-632 (1996) define os mecanismos de degradação como a sequência de mudanças químicas, físicas, ou ambas, que leva a modificações prejudiciais em uma ou mais propriedades de um componente ou material de construção quando exposto a um ou mais fatores de degradação. Esses podem ser qualquer grupo de fatores externos que afetam adversamente o desempenho de componentes e materiais de construção, como fatores climáticos, biológicos, de incompatibilidade e uso (ASTM, 1996). Em suma, a degradação é um processo pelo qual uma ou mais propriedades do material são afetadas pela ação dos agentes de degradação (BS, 2008).

Nesse sentido, as anomalias sucedem a ação dos agentes de degradação, os quais, por mecanismos específicos, levam a deterioração ou queda de desempenho dos edifícios e seus elementos (Mota, 2021). A evolução da degradação ao longo do tempo, juntamente com a ação contínua dos agentes de degradação, é acompanhada por alterações dos mecanismos iniciais causadores das anomalias (Bauer; Souza; Mota, 2021). A Figura 5 ilustra as relações entre agentes, mecanismos e anomalias.

Figura 5 - Relação de causa e efeito entre agentes.



Fonte: Adaptado de Cóias (2009).

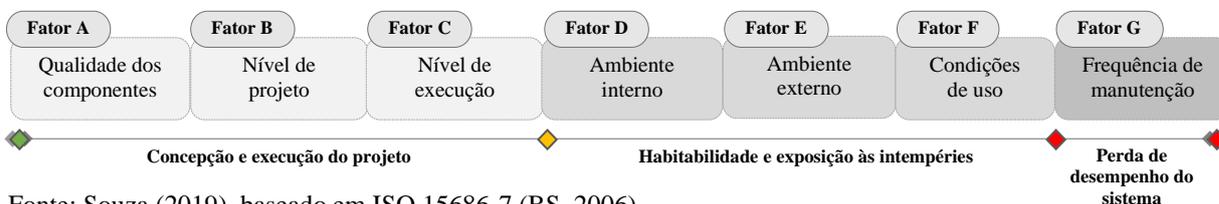
Assim, os agentes de degradação podem agir isoladamente ou em sinergia, atuar de diferentes formas, associadas ou não, simultâneas ou sequenciais, considerando as diferentes condições de exposição (Zanoni, 2015). A NBR 15575-1 (ABNT, 2021a) define as condições de exposição como um conjunto de ações atuantes sobre a edificação, o que inclui cargas gravitacionais, ações externas e ações resultantes da ocupação.

Os processos de degradação de uma cobertura conduzem, portanto, a um conjunto de prejuízos que podem ser reduzidos com um plano de manutenção e inspeção eficaz. Este deve permitir acompanhar periodicamente a cobertura, detectar e reparar, por meio de ações de manutenção, todas as possíveis anomalias (Morgado, 2012).

Segundo Zanoni (2015), os principais mecanismos de degradação relacionados aos agentes climáticos incluem as movimentações higroscópicas, principalmente as causadas pelos processos de umidificação e secagem. A umidificação e a secagem dos materiais dependem, assim, de suas propriedades higrotérmicas e das condições de exposição aos agentes climáticos (radiação solar, temperatura do ar, umidade relativa, vento, precipitação). Segundo Freitas (1992), os fluxos de secagem são mais elevados nas orientações onde as temperaturas superficiais são mais elevadas, ou seja, onde a radiação é maior, como por exemplo, a cobertura.

Portanto, a degradação é um processo paulatino de redução do desempenho de um elemento ou sistema, pela ação de seus agentes ao longo do tempo. A condição de degradação pode ser avaliada pelos seus indicadores que representam a alteração de característica de desempenho de um componente do edifício (Souza, 2019). Quando é previsto o fenômeno de degradação, os agentes podem ser divididos em fatores condicionantes para o processo de degradação. A norma ISO 15686-7 (BS, 2006) descreve as classes de fatores condicionantes de degradação e durabilidade que estão dispostos na Figura 6.

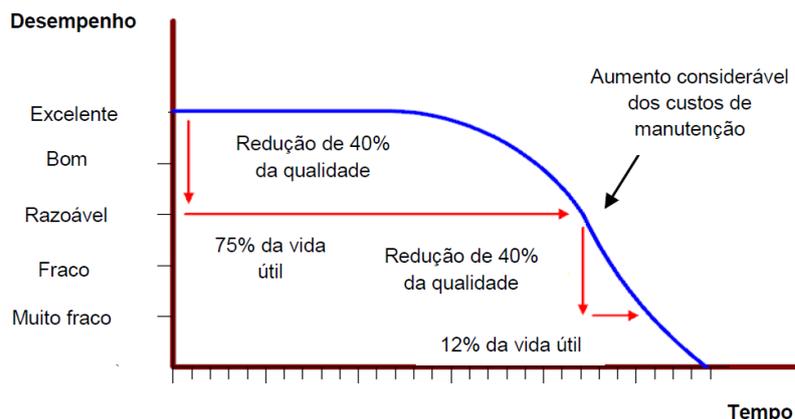
Figura 6 - Fatores condicionantes para o processo de degradação.



Fonte: Souza (2019), baseado em ISO 15686-7 (BS, 2006).

A degradação prematura e contínua do sistema de cobertura provoca aumento dos custos de manutenção (Hodges, 1999). Dessa forma, cada sistema apresenta uma curva característica de degradação, conforme ilustrado na Figura 7, para um sistema de cobertura.

Figura 7 - Curva de deterioração de uma cobertura.



Fonte: Hodges (1999) e Morgado (2012).

A degradação de um edifício depende de vários fatores, entre eles o comportamento na perspectiva de manutenção dos elementos que o constituem, pois cada um deles apresenta mecanismos próprios de degradação. Morgado (2012) utiliza os elementos fonte de manutenção (EFM) para identificar quais desses elementos devem receber as ações de manutenção. Cada elemento possui mecanismos de degradação e níveis de desempenho distintos.

Portanto, a redução do desempenho de um elemento ou do sistema requer um processo de manutenção continuada, que permita o monitoramento da cobertura do edifício ao longo do tempo (Zanoni *et al.*, 2023).

2.4 SISTEMAS DE IMPERMEABILIZAÇÃO DE LAJE DE COBERTURA

Segundo a NBR 9575 Impermeabilização - Seleção e Projeto (ABNT, 2010), o sistema de impermeabilização é definido como: conjunto de materiais, técnicas e procedimentos utilizados para proteger elementos construtivos contra a ação deletéria de fluídos, líquidos e vapores, impedindo ou dificultando sua passagem. Composto por uma ou mais camadas, os sistemas de impermeabilização da cobertura tem por finalidade conferir estanqueidade à construção, impedindo as infiltrações e vazamento.

Assim, para que uma impermeabilização seja estanque à água, deve possuir as seguintes propriedades (Cunha; Neumann, 1979):

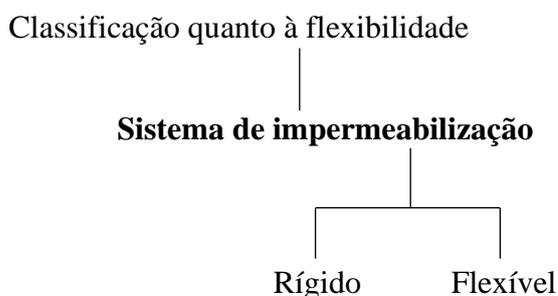
- a) **Impermeabilidade do material:** o material que constitui a impermeabilização deve ser capaz de impedir que a água o atravesse, nas pressões de utilização. Para tanto, deve ser um material que apresente valores baixos de absorção de água;
- b) **Continuidade do material:** além de impermeável, o material que constitui a impermeabilização deve formar um revestimento contínuo, sem poros, fissuras ou outras falhas, que possam servir de passagem para a água. Considerar também as soluções de continuidade tais como, juntas, sobreposições, e as soluções de

especificação de projeto e de execução de obra para evitar falhas, entre elas as fissuras resultantes da incompatibilidade entre capacidade de deformação do substrato e do sistema de impermeabilização. Estas condições implicam em mais uma propriedade que a impermeabilização deve possuir, no caso dos suportes fissuráveis;

- c) **Flexibilidade:** o material que constitui a impermeabilização deve possuir flexibilidade compatível com os gradientes de temperatura de utilização, de forma a acompanhar os movimentos normais que lhe são impostos em condições normais e previsíveis de utilização, sem perder a continuidade pelo surgimento de fissuras, ranhuras, rompimentos ou outras falhas.

A classificação dos sistemas de impermeabilização quanto à flexibilidade são apresentados na Figura 8.

Figura 8 - Classificação do sistema de impermeabilização quanto à flexibilidade.



Fonte: Elaborado pela autora.

As impermeabilizações rígidas são um conjunto de materiais que não apresentam características de flexibilidade, aplicáveis às partes construtivas não sujeitas à movimentação do elemento construtivo (Cunha; Neumann, 1979; Picchi, 1986). As impermeabilizações flexíveis conseguem absorver as movimentações estruturais, por meio da sua capacidade de deformação e flexibilidade, de modo a não apresentar fissuras ou falhas que possam prejudicar o seu desempenho (Sena *et al.*, 2020).

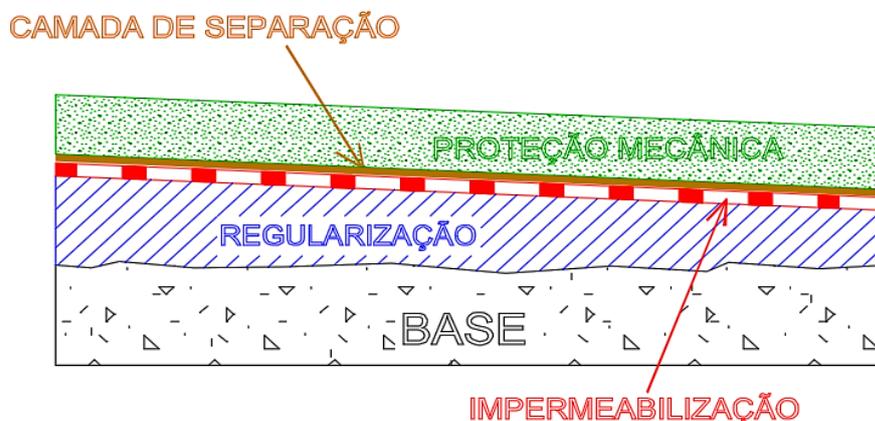
De acordo com a ABNT NBR 9574:2008 e a ABNT NBR 9575:2010, um sistema de impermeabilização flexível, com mantas ou membranas totalmente aderidas ao substrato, expostas às intempéries, com ou sem proteção mecânica, podem conter as seguintes camadas:

- a) **Camada Estruturante:** parte da cobertura destinada a resistir ao peso próprio e às solicitações, que constitui o suporte da impermeabilização, ou sobre a qual repousa este suporte.
- b) **Camada de Suporte:** parte da construção sobre a qual é aplicada diretamente a impermeabilização.

- c) **Camada de regularização:** camada destinada a preparar o suporte da impermeabilização para o seu recebimento. Possui a função de regularizar o substrato, o que proporciona uma superfície uniforme de apoio. Nessa camada é dada a inclinação (caimento), formando o diagrama de escoamento da água direcionada para os ralos ou drenos. A espessura da camada de regularização varia de acordo com o caimento necessário, proporcionando o adequado acabamento a cantos e arestas, e propicia um caimento mínimo de 1% em direção aos coletores de águas pluviais.
- d) **Impermeabilização:** composto por uma ou mais camadas que tem por finalidade proteger as construções contra a ação deletéria de líquidos, fluidos e vapores. Na cobertura, se torna um componente essencial como uma barreira estanque à água, inclusive os detalhes de proteção dos cantos, ralos emergentes, juntas de dilatação, etc.
- e) **Camada de separação:** elemento colocado entre duas camadas para impedir a aderência entre os materiais; permitindo movimentos diferenciais.
- f) **Isolação térmica:** elemento constituído de uma ou várias camadas de materiais ou produtos isolantes, cuja função é reduzir as trocas de calor entre o interior e o exterior do edifício.
- g) **Camada de proteção mecânica:** prepara a superfície para o recebimento das ações de uso, operações e exposição às intempéries. Essa camada é frequentemente executada com argamassa de cimento e areia, isenta de aditivos, hidrofugantes ou plastificantes.

Um corte esquemático com a representação das camadas que compõem a cobertura com o sistema de impermeabilização flexível é apresentado na Figura 9.

Figura 9 - Representação das camadas que compõem a cobertura com o sistema de impermeabilização.



Fonte: Resende (2017).

No caso das coberturas planas, o sistema de impermeabilização mais indicado são os sistemas flexíveis com mantas ou membranas asfálticas ou poliméricas. Sua declividade mínima deve ser de 1% em direção aos pontos de coleta ou drenagem, o que evita o empoçamento de água. Os rodapés devem garantir uma altura mínima de 20 cm acima do nível do piso acabado ou do nível máximo que a água pode atingir. As tubulações, quando aparentes, devem ser executadas no mínimo 10 cm acima do nível do piso acabado, depois de terminada a impermeabilização e seus complementos. As tubulações externas às paredes devem ser afastadas entre elas ou dos planos verticais no mínimo 10 cm. O diagrama de caimento deve considerar que o enchimento de argamassa necessário para garantir o escoamento das águas pode prejudicar soleiras, platibandas, tubulações expostas, e pode necessitar de um grande volume de argamassa, cujo peso deve ser levado em consideração no cálculo estrutural.

No entanto, os sistemas de impermeabilização existentes possuem diferenças na concepção, no princípio de funcionamento, nos materiais, nas técnicas de aplicação, etc. Estas variações servem de base para diversas classificações, que podem auxiliar na compreensão e comparação dos sistemas disponíveis no mercado (Picchi, 1986). Além disso, os sistemas de impermeabilização das coberturas devem receber inspeções de rotina a fim de identificar e corrigir algum dano eventual (Gonçalves *et al.*, 2019).

2.4.1 CLASSIFICAÇÃO DAS ANOMALIAS EM LAJES PLANAS

As anomalias ou manifestações patológicas ocorrem como irregularidades decorrentes de problemas no projeto ou na execução da construção, ou pela perda de funcionalidade resultante do envelhecimento natural dos elementos ou componentes do sistema construtivo. Além disso, também podem ocorrer devido a falhas na manutenção, no uso ou na operação dos sistemas e suas partes (ABNT, 2020; 2012).

As anomalias de coberturas planas podem resultar da contribuição de diversos fatores. Em um estudo em 60 coberturas, Morgado (2012) identificou as principais anomalias, e suas causas, conforme apresentadas no Quadro 5.

Quadro 5 - Caracterização das anomalias e causas em coberturas planas.

PONTOS SINGULARES	
Anomalias	Causas
Arrancamento (Levantamento da impermeabilização)	Redução da camada de proteção
	Sistema de colagem
	Número insuficiente de peças de amarração
Arrancamento do revestimento	Aplicação do revestimento sem proteção pesada
	Perda de aderência do revestimento ao suporte (número insuficiente de peças de fixação)
	Arrancamento do revestimento pelo vento devido ao descolamento das juntas de sobreposição
	Arrancamento da proteção pesada devido à ação do vento (espessura insuficiente de elementos soltos)
Fissuras na manta	Ações transmitidas pelas camadas subjacentes ou sobrejacentes

Continuação

	Movimentos diferenciais
	Retração ou expansão
	Incompatibilidade de materiais
	Ação do calor
	Envelhecimento natural e/ou prematuro do material de impermeabilização
	Retração inicial e movimentos térmicos da camada de suporte devida à natureza do material constituinte
	Perda de material volátil por ação do calor provocando endurecimento e retração do revestimento
	Aplicação inadequada (processo construtivo, mão-de-obra)
	Variações de origem térmica do suporte
	Inexistência de dessolidarização entre o revestimento e a proteção mecânica
	Ausência de juntas de dilatação da proteção mecânica
	Ausência de caminhos de circulação em coberturas de acesso limitado
	Deficiente aderência no granulado mineral nos revestimentos de impermeabilização
Fissuração dos remates	Inexistência de proteção térmica das platibandas altas e rígidas com material isolante eficaz
	Inexistência de proteção vertical do remate
	Diferenças entre a estrutura resistente e o elemento emergente, tendo em consideração o comportamento térmico e mecânico
	Inexistência de uma junta de fracionamento na camada de proteção, a uma distância de 0,30 metros dos seus paramentos
Fissuração dos remates nas juntas de dilatação	Execução de um sistema de proteção rígido sem interrupção sobre a junta de dilatação
	Execução de remates das juntas de dilatação na superfície da cobertura, em que ela se encontra sujeita a ações mecânicas devido à circulação de pessoas
	Inexistência de uma peça metálica (empanque) que sirva de suporte ao remate
Insuficiente altura dos remates	Definição ineficaz das camadas a aplicar sobre a impermeabilização
	Sobre-elevação insuficiente da soleira das portas relativamente à superfície corrente da cobertura
	O prolongamento do remate da impermeabilização sob a soleira da porta não foi executado
Fluência ou deslizamento dos remates	Ação da temperatura
	Desenvolvimento demasiado significativo em altura do remate de impermeabilização
Inadequado capeamento do coroamento das platibandas	Remate do revestimento de impermeabilização não recobre o paramento horizontal
	Utilização de capeamentos desapropriados às suas funções
Descolamento dos remates	Irregularidade dos paramentos (reboco inadequado, teor de umidade dos materiais de suporte superior ao recomendado)
	Quantidade insuficiente de produto de colagem
	Aplicação dos remates em condições atmosféricas desfavoráveis
	Inexistência de juntas de sobreposição
	Inadequada proteção do bordo superior do remate
	Processo deficiente de fixação dos remates de impermeabilização às tubagens emergentes
Descolamento das juntas de sobreposição	Aplicação do revestimento em condições atmosféricas desfavoráveis (ação de sucção do vento)
	Largura reduzida das juntas de sobreposição
	Sentido incorreto de aplicação do revestimento de impermeabilização
	Ataque do revestimento por raízes de plantas
	Quantidade insuficiente do produto de colagem
Perfurações	Cargas pontuais
	Fixação de objetos
	Peças de fixação
	Ausência de proteção
	Cargas pontuais de natureza dinâmica (curta duração, queda de objeto)
	Cargas pontuais de natureza estática (permanentes, instalação de suporte)
	Ausência de caminhos de circulação
	Fixação inadequada de equipamentos diversos e guarda de proteção
	Deficiente fixação mecânica (ação de peça de fixação)
Perfurações nas guardas das platibandas	Colagem insatisfatória
	Inexistência de braçadeira e mastigues
	Deficiente ajuste dos remates aos montantes
Permanência prolongada de água	Ligação deficiente do revestimento com os dispositivos de evacuação de água

Continuação

	Solução inadequada do sistema de drenagem de águas pluviais
	Desenvolvimento de vegetação parasitária
	Obstrução de caleiras
	Inclinação deficiente
Formação de Pregas	Ação do calor
	Ação dos ultravioletas
	O revestimento não acompanha os movimentos de deformação das juntas ou fissuração do suporte
	Material sem estabilidade dimensional ao calor; tipo de armadura
	Deficiente aplicação do revestimento de impermeabilização
	Falta de proteção face ao calor
Empolamentos (elevações da impermeabilização)	Formação de bolsas de ar e vapor de água sob pressão
	Revestimentos de impermeabilização sem as características adequadas
	Colagem inadequada das camadas do revestimento de impermeabilização
	Presença de materiais estranhos confinados entre o revestimento e o suporte
	Falta de nivelamento e encurvamento do suporte de painéis isolantes
	Existência de bolsas de ar e vapor de água entre o revestimento e o suporte
	Ausência de proteção do revestimento de impermeabilização
Armazenamento indevido dos rolos de revestimentos de impermeabilização	
Sistema de drenagem	
Anomalias	Causas
Acumulação de água e manchas junto a tubos de queda e caleiras	Regularização deficiente das superfícies acabadas
	Limpeza deficiente do suporte
	Umidade
	Acumulação de detritos
	Ausência de manutenção e inspeções
	Estrangulamento dos pontos de evacuação
Fissuração das caleiras metálicas	Concepção deficiente dos pontos de evacuação de águas pluviais
	Ação da temperatura e da radiação ultravioleta
	Envelhecimento natural do material
Entupimento dos ralos	Acumulação de detritos
	Alteração das condições de utilização
Inexistência de ralos de embocadura	Concepção deficiente dos pontos de evacuação das águas pluviais
	Controle deficiente da qualidade
	Movimentos diferenciais acentuados entre a estrutura resistente e o elemento emergente
Ruptura das juntas entre caleiras	Concepção deficiente das juntas de dilatação
	Execução inadequada da proteção superior do remate
	Controle deficiente da qualidade
	Ação da temperatura e da radiação ultravioleta
	Envelhecimento natural do material

Fonte: Adaptado de Morgado (2012).

Os autores Walter, Brito e Lopes (2005) também listaram as possíveis causas das anomalias em sistemas de impermeabilização em coberturas planas, e ainda apresentaram os erros de projeto, aplicação, ações mecânicas, ambientais e a falta de manutenção. Segundo os autores, as ações ambientais (Tabela 2) englobam os principais fatores de exposição solar, a temperatura, o envelhecimento / desgaste da camada de impermeabilização, o efeito da ação da água e os ciclos de umidificação e secagem.

Tabela 2 - Classificação das causas associadas às anomalias.

Erros de projeto
Desenho/detalhamento deficiente das camadas a serem aplicadas
Desenho/detalhamento deficiente da camada de proteção
Desenho/detalhamento deficiente das juntas de movimento
Projeto/detalhamento deficiente dos apoios
Projeto/detalhamento deficiente das saídas

Continuação

Desenho/detalhamento deficiente dos elementos de proteção	
Projeto de vento deficiente	
Desenho geométrico inadequado	
Desenhos incompletos/ contraditórios / excessivamente compactos	
Escolha errada dos materiais	
Falta de articulações	
Falta de tiras de separação	
Falta de isolamento térmico	
Projeto hidráulico deficiente	
Outros erros de projeto de drenagem	
Design errado / ausente	
Difícil acesso / impossível às superfícies	
Sem elementos de proteção / planejamento de rufos	
Sem planejamento mínimo de inclinação nas superfícies quase horizontais	
Especificações de contrato deficientes	
Erros de aplicação	
Erro na interpretação do projeto	Quantidade de material insuficiente
Inexperiência do pessoal	Fixação mecânica deficiente à estrutura
Armazenamento deficiente/transporte de materiais	Má execução da colagem
Aplicação em clima úmido/chuvoso	Má execução da soldagem
Uso de materiais inadequados	Má execução das articulações de movimento
Superfícies acabadas sem uniformidade	Proteção inadequada da borda superior intermitente
Limpeza deficiente do suporte	Inexistente/supervisão suficiente/controlado de qualidade
Posicionamento de impermeabilização deficiente	Prazo de entrega excessivamente curto
Ações mecânicas externas acidentais	
Impacto de objetos	Instalação de equipamentos
Circulação de carrinhos de mão	Vandalismo
Posicionamento de escoramento ou andaime	
Ações ambientais	
Vento	Umidade
Calor	Envelhecimento natural
Radiação ultravioleta	Ciclos secos e úmidos
Falta de manutenção	
Falta de limpeza dos detritos na superfície	Vegetação/ninho de pássaros
Acúmulo de detritos nas saídas dos tubos de queda	Falta de inspeções
Parafusos de fixação ausentes/soltos	

Fonte: Adaptado de Walter, Brito e Lopes (2005).

Ainda, segundo os autores Walter, Brito e Lopes (2005), as ações externas de origem mecânica caracterizam-se pelas:

- Cargas pontuais de natureza dinâmica (curta duração): são situações como a queda de objetos, seja durante a execução do revestimento de impermeabilização ou posteriormente a circulação de carrinhos de mão.
- Cargas pontuais de natureza estática (longa duração): colocação sobre o sistema de cobertura de suportes de instalações ou equipamentos diversos (condensadoras, subestação de energia, antenas, para-raios, chaminé/exaustor, placa fotovoltaica e torre/cabine).

As infiltrações podem ocorrer devido às fissuras existentes pelas deformações dos acabamentos, pelas juntas de dilatação e das interfaces de chaminés, pelos dutos de ventilação, pelas manutenções realizadas em elevadores e escadas, e em torno de claraboias. De acordo

com o estudo realizado por Carretero-Ayuso, Moreno-Cansado e Brito (2017), os problemas significativos estão relacionados à presença de água por serem facilmente perceptíveis pelos usuários. Com relação ao aparecimento de umidade no teto do pavimento inferior ao sistema de cobertura, o problema pode estar na impermeabilização. No entanto, a água (da umidade), pode originar de fissuras e de acabamentos defeituosos entre as interfaces dos equipamentos, e em muitos casos, origina-se de calhas mal fixadas. Esta água pode percorrer e percolar um longo caminho horizontalmente (Gili, 1980).

Uma situação que é frequente é a manta de impermeabilização não estar bem-acabada nos pontos singulares. Estes pontos singulares exigem uma execução cuidadosa e podem se deteriorar com o tempo (Carretero-Ayuso; Moreno-Cansado; Brito, 2017; Gili, 1980). Outra questão a ser destacada é a impermeabilização como parte integrante do projeto do edifício. Na fase de elaboração de projeto, a falta de previsão dos detalhes necessários para aplicação e as improvisações feitas geram grandes números de falhas (Picchi, 1986).

O uso de equipamentos no sistema de cobertura são causadores de manifestações patológicas quando fixados e localizados em locais incorretos. Os equipamentos devem ser agrupados em um local central, e não devem ser instalados diretamente sobre o sistema de impermeabilização. É recomendado que os equipamentos sejam instalados sobre placas ou blocos de concreto, com pelo menos 20 centímetros de espessura. Passarelas, corrimões e escadas devem ser fornecidos para a realização da manutenção dos equipamentos (HDA, 1993).

No que se refere à durabilidade das impermeabilizações, observa-se que a camada de proteção mecânica, a depender do caso, mitiga as ações de intemperismo e as condições de utilização do sistema de cobertura (Cruz, 2003).

Segundo Zanoni *et al.*, (2023), a perda da estanqueidade pode ser causada principalmente pelas seguintes falhas:

- Perfuração de mantas asfálticas causados por usuários com o uso de objetos e sapatos pontiagudos;
- Danos provenientes de obras (entulho e equipamentos);
- Perfuração da impermeabilização para a passagem de tubulações, sem a realização de reparos;
- Perfuração da impermeabilização para a fixação de equipamentos;
- Falha e falta de qualidade na mão de obra, durante o processo de aplicação;
- Queda de objetos perfurantes ou pontiagudo sobre a área impermeabilizada;
- Incompatibilidade entre os materiais aplicados.

A execução da impermeabilização nas coberturas planas é um dos aspectos mais importantes, uma vez que a estanqueidade do sistema depende do desempenho desta camada (Walter; Brito; Lopes, 2005). A camada de impermeabilização da cobertura plana exige atenção, pois pode ser submetida a um processo de degradação acelerado. Sua principal função é conferir estanqueidade ao edifício, mas também deve resistir às ações dos agentes atmosféricos, movimentações, componentes estruturais, usuários que realizam a manutenção e a instalação de equipamentos (Gonçalvez *et al.*, 2019).

As falhas da impermeabilização provenientes de infiltrações no último pavimento das edificações, podem, ainda, ocasionar riscos de curto-circuito na rede elétrica, perdas de equipamentos, além de perda de documentações e arquivos.

A Norma brasileira NBR 15575-1 (ABNT, 2021a) alerta que a vida útil de projeto (VUP) é resultado da adequada atuação dos projetistas, fornecedores de materiais, construtores e dos usuários (ABNT, 2021a).

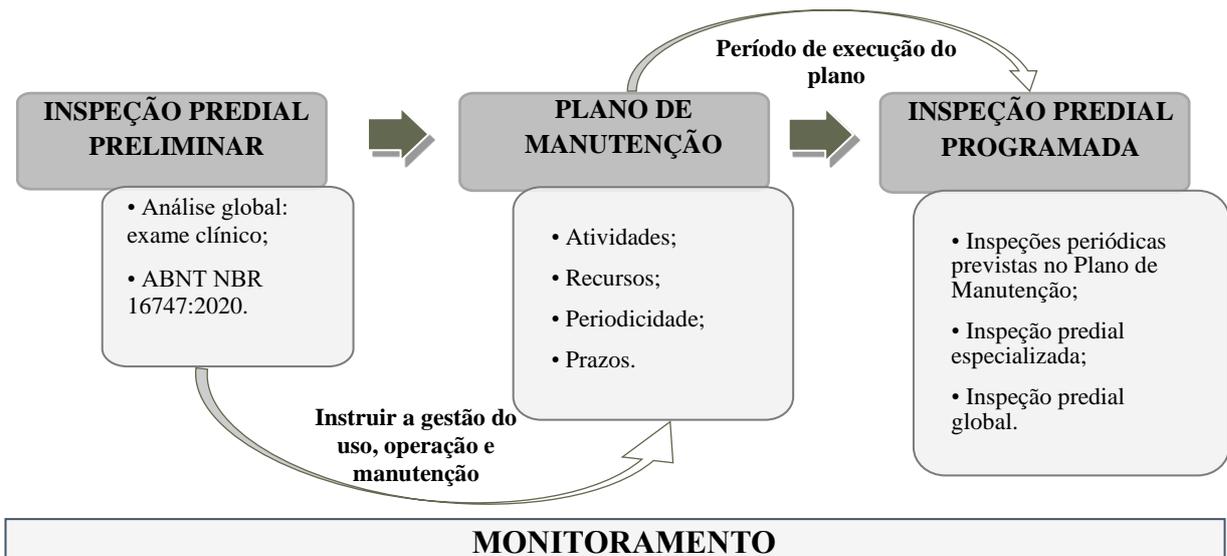
2.5 INSPEÇÃO PREDIAL E MANUTENÇÃO NO SISTEMA DE COBERTURA

A Norma de Inspeção Predial (ABNT, 2020) estabelece os procedimentos de inspeção, constatação do estado de conservação e funcionamento da edificação, seus sistemas e subsistemas, de forma a permitir um acompanhamento sistêmico do comportamento em uso ao longo da vida útil.

2.5.1 Procedimentos de Inspeção de Coberturas

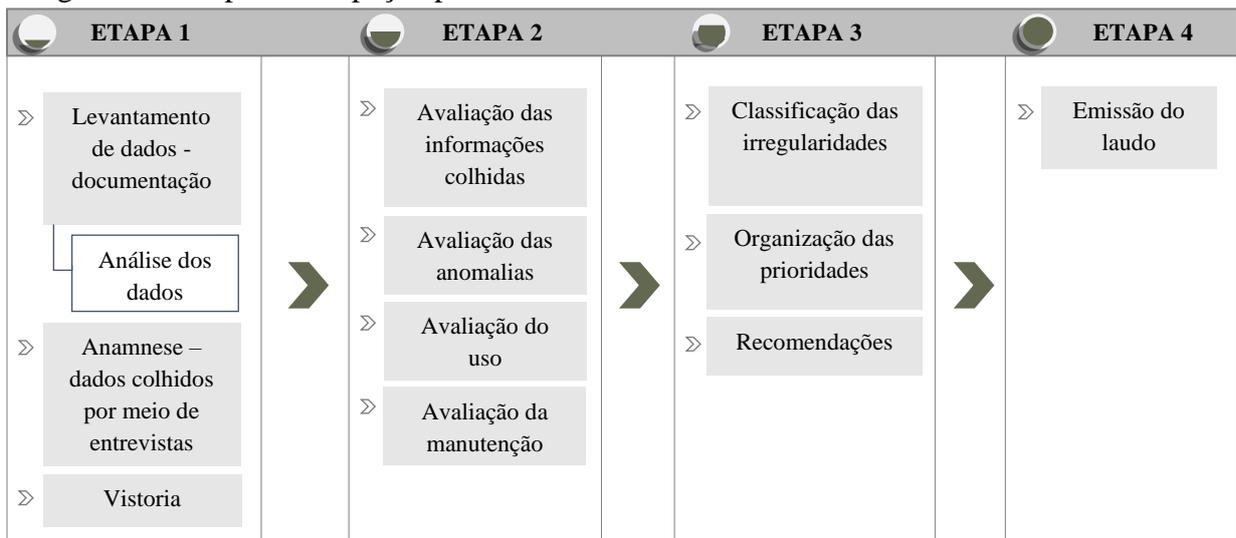
A inspeção predial é um processo de avaliação das condições técnicas, de uso, operação, manutenção e funcionalidade da edificação e de seus sistemas e subsistemas construtivos, de forma sistemática e predominantemente sensorial. Pelo seu caráter fundamentalmente sensorial, o reconhecimento de problemas na inspeção predial é feito pela identificação de funcionamento inadequado, sintomas ou sinais aparentes em ensaios específicos (ABNT, 2020). A Figura 10 apresenta as etapas e sub etapas de monitoramento no sistema de cobertura, e a Figura 11 detalha as etapas a serem realizadas em uma inspeção predial.

Figura 10 - Etapas e sub etapas de monitoramento no sistema de cobertura.



Fonte: Santos, Zanoni e Almeida (2021).

Figura 11 - Etapas da inspeção predial.



Fonte: Santos, Zanoni e Almeida (2021).

A classificação das irregularidades encontradas nas edificações está descrita na NBR 16747 (ABNT, 2020), separadas em anomalias ou falhas. As anomalias caracterizam-se pela perda de desempenho de um elemento, subsistema ou sistema construtivo e são divididas em três classes, conforme apresenta o Quadro 6.

Quadro 6 - Classificação das anomalias.

CLASSIFICAÇÃO DAS ANOMALIAS	
Anomalia	Descrição
Anomalia Endógena ou Construtiva	Perda de desempenho proveniente da própria construção (Projeto, execução e materiais)
Anomalia Exógena	Perda de desempenho proveniente de fatores externos à edificação, provocados por terceiros
Anomalia Funcional	Perda de desempenho proveniente do envelhecimento natural e consequente término da vida útil.

Fonte: Adaptado de NBR 16747 (ABNT, 2020).

Já as falhas caracterizam-se pela perda de desempenho de um elemento, subsistema ou sistema construtivo, decorrentes do uso, operação e manutenção. Segundo a NBR 16747 (ABNT, 2020), as falhas devem ser classificadas em patamares de urgência, como descrito no Quadro 7.

Quadro 7 - Patamares de urgência.

PATAMARES DE URGÊNCIA PARA CORREÇÃO DAS IRREGULARIDADES	
Prioridade	Descrição
1	Perda de desempenho que compromete a saúde e/ou a segurança dos usuários, e/ou a funcionalidade dos sistemas construtivos, com possíveis paralisações; Comprometimento de durabilidade (vida útil) e/ou aumento expressivo de custo de manutenção e de recuperação.
2	Perda parcial de desempenho (real ou potencial) que tem impacto sobre a funcionalidade da edificação, sem prejuízo à operação direta de sistemas e sem comprometer a saúde e segurança dos usuários.
3	Perda de desempenho (real ou potencial) que pode ocasionar pequenos prejuízos à estética ou quando as ações necessárias são atividades programáveis e passíveis de planejamento, além de baixo ou nenhum comprometimento do valor da edificação, das operações e a saúde dos usuários.

Fonte: Adaptado de NBR 16747 (ABNT, 2020).

De acordo com NBR 5674 (ABNT, 2012), as edificações apresentam uma característica que as diferenciam por serem construídas para atender aos requisitos dos usuários. Assim e, ao longo do tempo de serviço, essas devem apresentar condições adequadas ao uso a que se destinam, além de resistir aos agentes ambientais e de uso que alteram suas propriedades técnicas iniciais.

Sendo assim, o conjunto de atividades a serem realizadas para recuperar a capacidade funcional da edificação e de suas partes constituintes, deve atender às necessidades de segurança e qualidade destes usuários. Para que se mantenham os níveis de desempenho ao longo da vida útil projetada, torna-se necessário a realização de um programa de manutenção corretiva e preventiva, considerado como um meio de reduzir a probabilidade de manifestações patológicas e melhorar o desempenho (Carretero-Ayuso *et al.*, 2021).

2.5.2 Requisitos para a Manutenção

Os requisitos mínimos da manutenção a serem adotados para os sistemas de coberturas das edificações estão fundamentados em procedimentos organizados em um sistema de gestão da manutenção, conforme a NBR 5674 (ABNT, 2012):

- a) Tipologia da edificação;
- b) Uso efetivo da edificação;
- c) Tamanho e complexidade da edificação e seus sistemas;
- d) Localização e implicações do entorno da edificação.

A gestão do sistema de manutenção inclui meios para:

- a) Preservar as características originais da edificação;

- b) Prevenir a perda de desempenho decorrente da degradação dos seus sistemas, elementos ou componentes.

A manutenção deve ser orientada por um conjunto de diretrizes que vise:

- a) Preservar o desempenho previsto em projeto ao longo do tempo, minimizando a depreciação patrimonial;
- b) Estabelecer as informações pertinentes e o fluxo da comunicação;
- c) Estabelecer as incumbências e autonomia de decisão dos envolvidos.

2.5.2.1 Tipos de Manutenção

O sistema de cobertura com manta ou membrana de impermeabilização deve passar por manutenções dos seus elementos e componentes identificados por meio da inspeção predial. A NBR 5674 (ABNT, 2012) define o sistema de manutenção como o “conjunto de procedimentos organizados para gerenciar os serviços de manutenção”, no qual o serviço de manutenção é a “intervenção realizada na edificação e seus sistemas, elementos ou componentes constituintes” (ABNT, 2012; p. 3), assim classificados:

- a) **Manutenção rotineira:** caracterizada por um fluxo constante de serviços, padronizados e cíclicos, como, por exemplo, limpeza geral e lavagem de áreas comuns;
- b) **Manutenção corretiva (não planejada):** caracterizada por serviços que demandam ação ou intervenção imediata a fim de permitir a continuidade do uso dos sistemas, elementos ou componentes das edificações. Esta corresponde aos trabalhos de diagnóstico, prognóstico, reparo, reabilitação e proteção das estruturas que já apresentam manifestações patológicas (correção de problemas evidentes);
- c) **Manutenção preventiva (planejada):** caracterizada por serviços cuja realização seja programada com antecedência e priorize as solicitações dos usuários, estimativas da durabilidade esperada dos sistemas, elementos ou componentes das edificações em uso, tais como, limpeza de calha, renovação ou construção de rufos, pingadeiras e beirais. Deve-se também realizar um levantamento da gravidade e urgência, em relatórios de verificações periódicas sobre o seu estado de conservação.

2.5.3 Programa de Manutenção Preventiva

O programa de manutenção preventiva consiste na determinação das atividades essenciais de manutenção, sua periodicidade, os responsáveis pela execução, documentos de referência, referências normativas e recursos necessários. Os elementos, componentes e equipamentos do programa devem ser referidos individualmente ao sistema.

Para os sistemas e elementos/componentes de cobertura (Tabela 3), portanto, a periodicidade de manutenção deve ser anual. Nesses sistemas, é verificada a integridade

estrutural dos componentes, vedações, fixações, e deve reconstituir e tratar, onde for necessário (ABNT, 2012).

Dessa forma, o programa de manutenção pode ser elaborado considerando a orientação dos fornecedores, profissionais e empresas especializadas, em detrimento da tipologia da edificação, das condições de uso, da complexidade dos sistemas e equipamentos empregados, e das características dos materiais aplicados. O programa de manutenção deve, portanto, ser atualizado periodicamente e considerados os projetos, memoriais, orientação dos fornecedores e manual de uso, operação e manutenção (quando houver), conforme a NBR 5674 (ABNT, 2012).

Tabela 3 - Modelo não restritivo para a elaboração do programa de manutenção preventiva de uma edificação hipotética.

Periodicidade	Sistema	Elemento/ Componente	Atividade	Responsável
A cada ano		Sistema de cobertura	Verificar a integridade estrutural dos componentes, vedações, fixações, e reconstituir e tratar, onde necessário	Equipe de manutenção local/Empresa especializada
	Impermeabilização	Áreas molhadas internas e externa, piscinas, reservatórios, coberturas, jardins, espelhos d'água	Verificar sua integridade e reconstituir a proteção mecânica, sinais de infiltração ou falhas da impermeabilização exposta	Equipe de manutenção
	Equipamentos industrializados	Sistemas de proteção contra descargas atmosféricas	Inspecionar periodicamente de acordo com a legislação vigente. Em locais expostos à corrosão severa, reduzir os intervalos entre verificações	Empresa especializada
		Sistemas de proteção contra descargas atmosféricas	Inspecionar sua integridade e reconstituir o sistema de medição de resistência conforme legislação vigente	Empresa especializada
A cada mês	Sistemas hidrossanitários	Ralos, grelhas, calhas e canaletas	Limpar o sistema das águas pluviais e ajustar a periodicidade em função da sazonalidade, especialmente na época de chuvas intensas	Equipe de manutenção local
	Equipamentos industrializados	Ar-condicionado	Manutenção recomendada pelo fabricante e atendimento à legislação vigente	Empresa especializada
		Iluminação de emergência	Efetuar teste de funcionamento de todo o sistema conforme instruções do fornecedor	Equipe de manutenção local

Fonte: Adaptado de NBR 5674 (ABNT, 2012).

A norma NBR 5674 (ABNT, 2012) define que o programa de manutenção deve considerar projetos, memoriais, orientação dos fornecedores e manual de uso, operação e manutenção (quando houver), além de características específicas de sistemas, materiais e equipamentos.

2.6 EQUIPAMENTOS NO SISTEMA DE COBERTURA

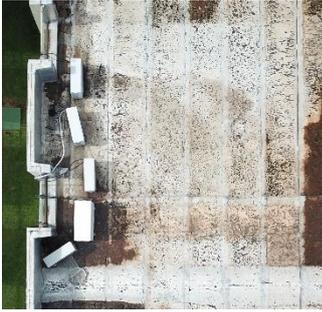
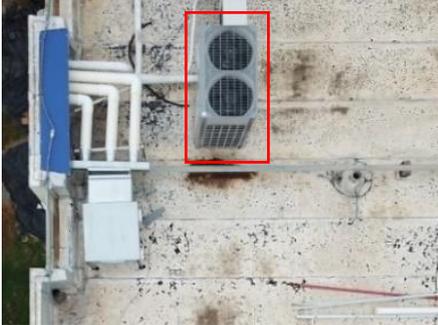
Atualmente, os sistemas de coberturas apresentam um desafio relativo à sua capacidade de acomodar novas funções complementares ao seu uso. Um caso frequente refere-se ao uso das coberturas planas para a instalação de equipamentos, em um espaço que nem sempre foi originalmente projetado para isso. Os ambientes precisam ser capazes de oferecer condições para novos usos. As novas tecnologias para condicionamento de ar e eficiência energética tem transformado uma cobertura técnica em um espaço acessível e com necessidades permanentes de vistoria e manutenção (Santos *et al.*, 2023).

Existem diversos fatores que podem interferir e influenciar no desempenho das superfícies de uma cobertura e um dos mais recorrentes são as perfurações. As principais causas do aparecimento das perfurações no sistema de impermeabilização ou na camada impermeabilizante do sistema de cobertura são decorrentes da falta de medidas de proteção adequadas durante a realização de trabalhos de instalação e manutenção de equipamentos. Outro efeito agravante é a ação de cargas pontuais de natureza dinâmica (curta duração) e as cargas pontuais de duração estática (longa duração) (Walter; Lopes; Brito, 2003).

As cargas pontuais de longa duração são caracterizadas pelos equipamentos, e um dos motivos para a ocorrência das manifestações patológicas. As ações de manutenção resultante das cargas estáticas ou dinâmicas da aplicação inadequada de andaimes ou escadas para a instalação de equipamentos por exemplo, de antenas, são, ainda, causa de perfuração no sistema de impermeabilização. A perfuração da manta ou membrana pode resultar, também, das ações das peças de fixação sobre o revestimento (Walter; Lopes; Brito, 2003).

O Quadro 8 apresenta os principais equipamentos identificados em coberturas planas, a partir do estudo piloto realizado para este trabalho.

Quadro 8 - Tipos de equipamentos identificados no sistema de cobertura plana.

EQUIPAMENTOS			
01	 <p>Figura 12 - Condensadoras</p>	02	 <p>Figura 13 - Subestações de energia</p>
03	 <p>Figura 14 - Antena</p>	04	 <p>Figura 15 - Para-raios</p>
05	 <p>Figura 16 - Chaminé / Exaustores</p>	06	 <p>Figura 17 - Placas fotovoltaica</p>
07	 <p>Figura 18 - Torre ou Cabine</p>	08	 <p>Figura 19 - Suporte para Instalações: Bloco de concreto; Ancoragem metálica; Grades ou quadros</p>

Fonte: Elaborado pela autora.

A cobertura plana deve ser estanque em todas as suas partes e as causas da umidade podem ser diversas. Entre os fatores que podem comprometer o desempenho do sistema de

cobertura, destaca-se a perfuração da impermeabilização. As perfurações mais comumente encontradas, conforme Effisus (2020), são causadas por: (i) instalações hidráulicas (drenagem de águas pluviais); (ii) sistema de ar-condicionado; (iii) perfis metálicos; (iv) passagem de cabos; (v) fixação de painéis fotovoltaicos e painéis solares; (vi) tubos de ventilação; (vii) guarda-corpo.

Para que as falhas de impermeabilização sejam evitadas, é necessário atenção nos pontos críticos na impermeabilização: ruptura devido aos movimentos da estrutura; falta de acabamento ou acabamento de má qualidade; entupimento de dutos e ralos do sistema de drenagem; dutos de respiro abertos; danos causados por vegetações invasivas; materiais armazenados provocando acúmulo de água por interrupção do escoamento; entulho de construção e a instalação de equipamentos sem projeto.

Os processos de instalação de equipamentos exigem um projeto de execução e fixação. Nesse sentido, é necessário melhorar e regulamentar as ações de manutenção periódica, com a fiscalização rigorosa de vários pontos críticos, entre eles: remoção de detritos, entulhos, equipamentos em desuso e materiais armazenados; verificação da fixação do acabamento das mantas, rufos e rodapés; verificação de tráfegos e localização específica das passarelas para caminhamento; previsão de pontos de parada para carga e descarga dos equipamentos; verificação de todos os ralos, drenos e calhas.

3 TECNOLOGIAS DIGITAIS E PROCESSOS AUTOMATIZADOS

A pesquisa bibliográfica apresentada nesta seção foi realizada por meio de uma revisão da literatura, com o objetivo de identificar o estado da arte do conhecimento relacionado à temática em questão. Foi desenvolvida uma revisão sistemática da literatura (RSL) cuja estratégia de busca baseou-se em dois temas de interesse: a) inspeção predial automatizada com o uso de visão computacional; b) processamento de imagens adquiridas por drones e geração de ortoimagens. Para tanto, foram estabelecidas duas chaves de busca (*string* de busca), uma para cada tema de interesse. Os resultados da RSL permitiram identificar algumas lacunas no conhecimento. As análises dessas lacunas são destacadas ao longo do texto, inclusive são citadas na seção de introdução, como justificativa para essa tese e sua contribuição.

3.1 REVISÃO SISTEMÁTICA DE LITERATURA: MÉTODOS DE INSPEÇÃO PREDIAL AUTOMATIZADO

Para a revisão sistemática da literatura (RSL), as pesquisas foram realizadas nas bases de dados *Web of Science* e *Scopus*, restringindo-se a artigos publicados em periódicos indexados, redigidos em inglês. Como critérios de exclusão, foram considerados: artigos duplicados; artigos de revisão; artigos de congressos; e artigos que não abordavam o tema de interesse. A aplicação dos critérios de exclusão permitiu uma triagem rigorosa, conduzindo à seleção dos estudos mais alinhados aos objetivos desta tese. O recorte temporal para a seleção dos artigos foi 2020-2024.

O resultado inicial passou pela primeira triagem, considerando título do artigo, resumo e palavras-chave. As publicações pré-selecionadas nesta triagem foram lidas na sua íntegra e selecionadas com base no Quadro 9 que mostra o roteiro de perguntas utilizadas para a verificação da qualidade e aderência do artigo ao tema de interesse.

Quadro 9 - Perguntas para a escolha e análise dos artigos.

Perguntas para análise dos artigos	
Q1	Qual lacuna é apresentada que justifica o desenvolvimento da pesquisa?
Q2	Qual foi o objetivo geral do artigo?
Q4	Qual a área de pesquisa do artigo?
Q5	Qual método é utilizado?
Q6	Qual o tipo de artigo? Teórico, de revisão, empírico ou experimental?
Q7	Em qual país foi feita a pesquisa?
Q8	Qual tecnologia é utilizada para a coleta de dados?
Q9	Tema 01 - O uso de tecnologias para inspeção predial automatizada e visão computacional é tratado no artigo? Como ele é abordado?
	Tema 02 - Processamento de imagens adquiridas por drones e geração de ortoimagens são tratados no artigo? Como ele é abordado?

Fonte: Elaborado pela autora.

As perguntas discriminadas no Quadro 9 orientaram a escolha dos artigos relevantes. Estudos focados em aplicações de sensoriamento remoto e segmentação de áreas de desastre foram excluídos por não apresentarem pertinência direta ao objetivo desta tese. Esses critérios asseguraram a relevância e a especificidade do corpus de literatura analisado para fundamentar a investigação proposta.

3.2 RESULTADOS DA REVISÃO SISTEMÁTICA DE LITERATURA: INSPEÇÃO PREDIAL AUTOMATIZADA E VISÃO COMPUTACIONAL

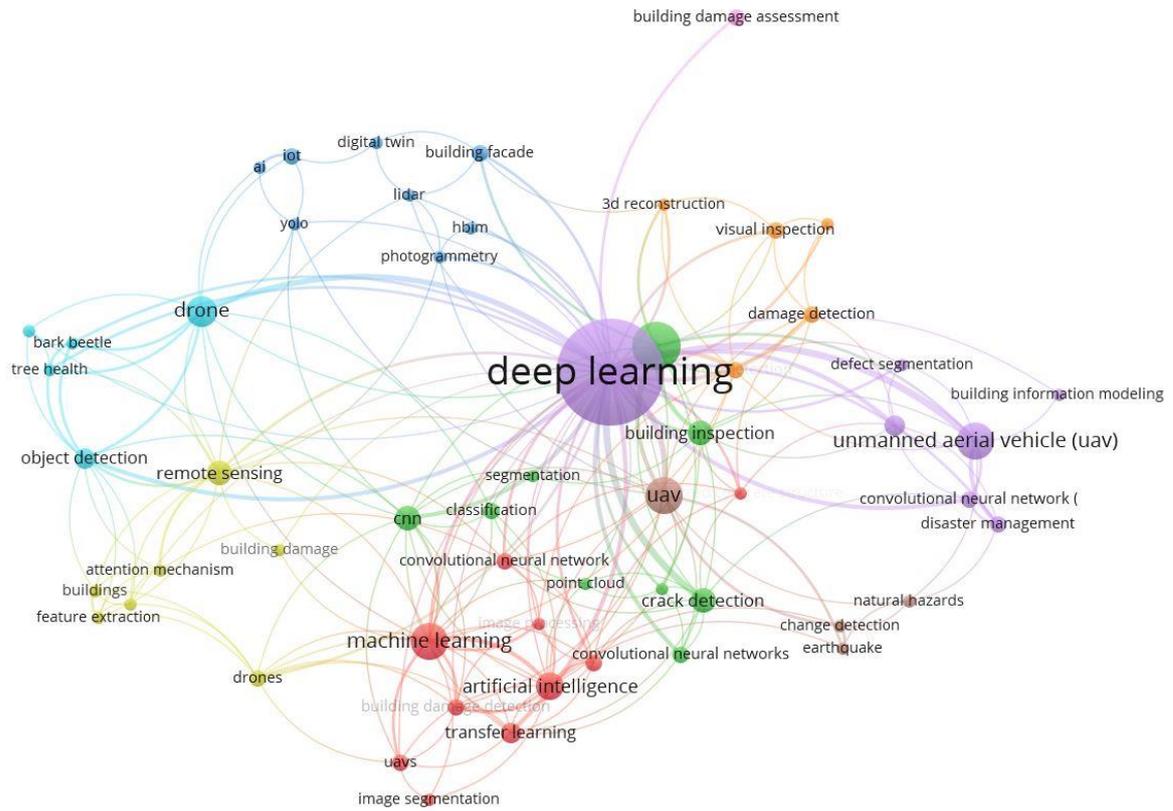
O Quadro 10 apresenta os resultados da *string* de busca para o tema: inspeção predial automatizada com o uso de visão computacional. Além disso, lista os quantitativos de artigos inicialmente selecionados nas bases de dados consultadas, dos documentos pré-selecionados e, finalmente, dos artigos classificados para a análise detalhada de seu conteúdo. O Quadro 11 apresenta os artigos que foram analisados para responder à pergunta e evidenciar o estado da arte e a lacuna de pesquisa.

As Figuras 20 e 21 ilustram as palavras-chave mais frequentes nos artigos selecionados. Utilizando o software *VOSviewer*, o termo *deep learning* destacou-se como a palavra-chave predominante, seguido por outros termos empregados na *string* de busca.

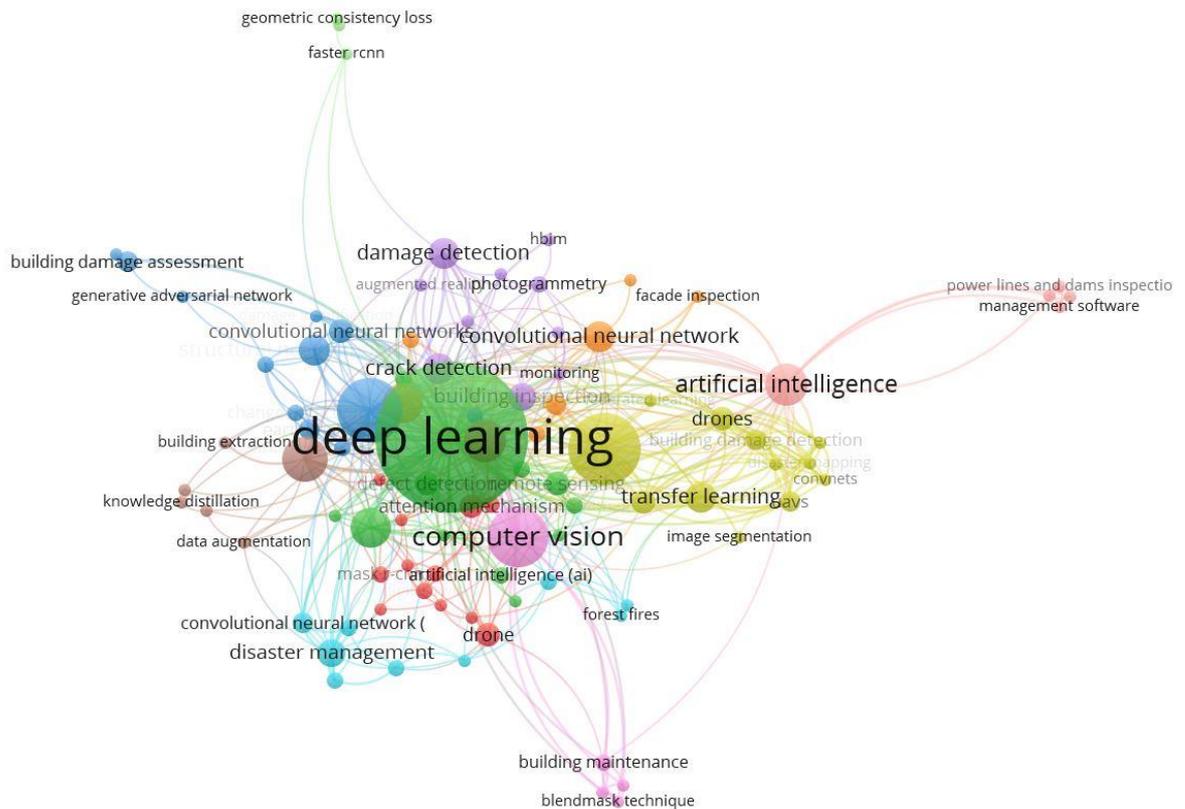
Quadro 10 - Revisão sistemática da literatura para inspeção e visão computacional.

Busca	Palavras-chave		Ano 2020 - 2024			
			Critérios de pesquisa	Base de dados	Resultado inicial	Documentos pré-selecionados
Data da pesquisa 03/11/2024	<i>Strings</i> de busca nas bases		Título do artigo, resumo e palavras-chave	Web of Science	84	44
	<i>“machine learning” OR “deep learning” OR “artificial intelligence”</i>	AND				
	<i>“building inspection” OR “drone” OR “UAV” OR “scanner”</i>	AND		Scopus	185	90
	<i>“detection” OR “classification” OR “mapping” OR “identification” OR “segmentation” OR “pathological manifestation”</i>	AND				
	<i>“building” OR “facade” OR “roof systems”</i>	AND				
	<i>“degradation” OR “maintenance” OR “damage” OR “mechanisms”</i>	AND				
Critérios de exclusão	Critério de exclusão: artigos duplicados; artigos de revisão; artigos de congressos; e artigos que não abordavam a inspeção predial com o uso do drone e da visão computacional.			Artigos selecionados: 06		

Fonte: Elaborado pela autora.

Figura 20 - Palavras-chave da base de dados da *Web of Science*.

Fonte: *VOSviewer*, 2024.

Figura 21 - Palavras-chave da base de dados do *Scopus*.

Fonte: *VOSviewer*, 2024.

Quadro 11 - Artigos encontrados sobre inspeção e visão computacional.

Data	Autor	Tipologia do sistema			Ferramenta utilizada	Utilizou software para processamento da imagem		Utilizou a visão computacional	
		Cobertura plana	Telhado	Fachada		Sim	Não	Sim	Não
2023	Fiorillo, Perfetti e Cardani		x		Drone			x	
2023	Lemos, Cabral, Ribeiro, Santos, Alves e Dias		x		Drone		x	x	
2023	Malche, Tharewal e Dhanaraj			x	Drone		x	x	
2023	Torres-González, Valença, Santos, Silva e Mendes			x	Câmera fotográfica de alta resolução	<i>Composition Editor version X</i>		x	
2024	Qiu, Zhang, Zhuo, Xiao, Chen e Tian		x		Drone		x	x	
2024	Fiorini, Conti, Pellis, Bonora, Masiero e Tucci			x	Drone	<i>Agisoft Metashape</i>		x	

Fonte: Elaborado pela autora.

Na Itália, Fiorillo, Perfetti e Cardani (2023) integraram drones e técnicas de *deep learning* para classificação automática de danos em telhado de edifício histórico. O estudo utilizou um planejamento de voo detalhado, considerando altura de voo de 25 metros com uma altitude acima do último nível do sistema de 10 metros, sobreposição de imagens de 80% e distância entre as linhas do plano de voo de 5 metros, o que resultou em uma resolução de 3 mm por pixel (GSD – *Ground Sample Distance*). Essa abordagem garantiu a criação de um modelo tridimensional preciso e a geração de ortoimagens. No entanto, a segmentação automática apresentou dificuldades, especialmente na classificação de diferentes tipos de telhas, devido às variações de cor e textura e à presença de danos.

Lemos *et al.* (2023) desenvolveram uma metodologia voltada para a detecção automática de corrosão em telhas metálicas sanduíche, com foco em grandes edifícios industriais. A pesquisa utilizou drones associados à inteligência artificial para aprimorar a eficiência e a precisão das inspeções e manutenções de estruturas industriais. Apesar dos avanços apresentados, o estudo identificou desafios relacionados ao tipo de telha analisada, principalmente devido à presença de fundos complexos e condições de iluminação variáveis, que dificultaram a identificação precisa das anomalias.

Os resultados quantitativos do estudo evidenciaram um total de 2.514 verdadeiros positivos (áreas corretamente identificadas como corrosão), 18% falsos negativos (áreas com

corrosão não detectadas) e 20% falsos positivos (áreas incorretamente classificadas como corrosão). Esses números fornecem uma visão clara sobre o desempenho do modelo em termos de acurácia e os desafios associados à detecção de corrosão em condições industriais adversas. O trabalho destaca a necessidade de ajustes nos parâmetros de captura e processamento de imagens para lidar com as limitações impostas por fundos heterogêneos e variações de luminosidade.

Malche, Tharewal e Dhanaraj (2023) investigaram a detecção de danos em superfícies de concreto e asfalto. Esses estudos empregaram tecnologias de visão computacional, *deep learning* e imagens obtidas por drones para identificar diferentes tipos de deterioração, como fissuras e degradação do material. O uso dessas tecnologias automatizou o processo de inspeção, promovendo maior agilidade e precisão na identificação das patologias estruturais em pavimentos.

Torres-González *et al.* (2023) apresentam e validam o método *StainView*, uma abordagem eficiente para o mapeamento de manchas em fachadas de edifícios, utilizando a classificação de imagens em espaços de cores HSV e CIELab. A técnica proposta busca facilitar a inspeção e avaliação do estado de conservação em fachadas, especialmente para profissionais que não dominam o conhecimento em visão computacional. O estudo apresenta uma contribuição para a evolução das práticas de manutenção e conservação na construção civil, alinhando-se as tendências da Construção 4.0 e a adoção de tecnologias digitais na gestão de edifícios.

Qiu *et al.* (2024) enfatizam a carência de dados sobre o patrimônio arquitetônico histórico em partes da China e em regiões do Sudeste Asiático, ressaltando que essa limitação restringe a aplicabilidade de modelos preexistentes. A pesquisa utilizou drones para captura de imagens e redes neurais convolucionais para detecção de patologias e segmentação de instâncias em edifícios históricos, com base em ortoimagens. O foco principal foi a identificação e o monitoramento de danos estruturais nesses edifícios.

O estudo de Qiu *et al.* (2024) representa um avanço significativo no campo do conhecimento científico ao integrar tecnologias de inspeção automatizada para a análise de construções históricas. Contudo, o objeto do estudo restringe-se a telhados inclinados compostos por telhas de argila sinterizada, caracterizadas por sua coloração vermelha, o que pode limitar a generalização dos resultados para outros tipos de coberturas e materiais construtivos.

Fiorini *et al.* (2024) investigam o potencial de técnicas automatizadas de monitoramento e segmentação de imagens adquiridas por drone para identificar áreas vulneráveis nas fachadas

do *Palazzo Pitti* em Florença, Itália. O estudo visou desenvolver abordagens que auxiliassem na conservação do patrimônio cultural, considerando a crescente frequência e intensidade de eventos climáticos extremos que aceleram processos de degradação das construções históricas. O artigo destaca a importância da integração de tecnologias avançadas, como aprendizado de máquina e drones, para aprimorar a eficiência e a eficácia no monitoramento e conservação de patrimônios construídos, assegurando sua proteção diante de riscos climáticos.

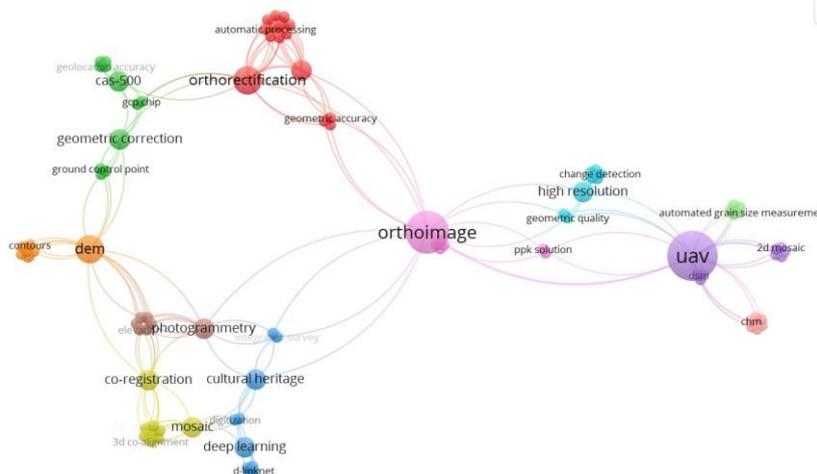
Os autores encontraram dificuldades durante o uso de drones para a captura de imagens, com desafios relacionados ao planejamento das rotas de voo e na captura de imagens em áreas com obstruções, como gradeamentos e redes de proteção. O planejamento das operações exigiu estratégias para evitar lacunas ou sobreposições nas imagens, demandando a realização dos voos em vários dias devido às limitações de tempo.

3.3 RESULTADOS DA REVISÃO SISTEMÁTICA DE LITERATURA: PROCESSAMENTO DE IMAGENS ADQUIRIDAS POR DRONES E GERAÇÃO DE ORTOIMAGENS.

O Quadro 12 apresenta os resultados da *string* de busca para o tema: processamento de imagens adquiridas por drones e geração de ortoimagens. Além disso, lista os quantitativos de artigos inicialmente selecionados nas bases de dados consultadas, dos documentos pré-selecionados e, finalmente, dos artigos classificados para a análise detalhada de seu conteúdo. O Quadro 13 apresenta os artigos que foram analisados para responder à pergunta e evidenciar o estado da arte e a lacuna de pesquisa.

As Figuras 22 e 23 ilustram as palavras-chave mais frequentes nos artigos selecionados. Utilizando o software *VOSviewer*, o termo drones destacou-se como a palavra-chave predominante, seguido por outros termos como ortoimagem, processamento e DEM (*Digital Elevation Model*).

Figura 22 - Palavras-chave da base de dados da *Web of Science*.



Fonte: *VOSviewer*, 2024.

Os autores Shoab, Singh e Ravibabu (2021) realizaram uma comparação entre a precisão das ortoimagens digitais geradas a partir de imagens capturadas por drones. O estudo focou na análise da qualidade geométrica das ortoimagens produzidas por dois softwares de fotogrametria, utilizando a mesma configuração e conjuntos de dados de diversas áreas. Embora o estudo tenha o objetivo de contribuir para a melhoria dos processos de geração de ortoimagens, ele se concentra na área de sensoriamento remoto. Nessa área, a qualidade geométrica das imagens é predominantemente influenciada pela relação entre o tamanho do pixel e a escala do mapa, além de fatores como contraste, condições atmosféricas e a altura do sol, entre outros aspectos.

Os autores apresentam conjuntos de dados provenientes de áreas urbanas densas e favelas, bem como os parâmetros de configuração para os processos realizados nos softwares Pix4D Mapper e Agisoft. O *Point Cloud Densification* foi configurado utilizando a metade da imagem, e o *Point Density* foi otimizada com a razão de quatro, dividida pela escala da imagem. O DSM/DEM foi processado com a configuração automática de ambos os softwares. No entanto, apesar de a pesquisa mencionar alguns parâmetros de processamento, não há um detalhamento completo das configurações aplicadas.

Em termos de resultados da pesquisa de Shoab, Singh e Ravibabu (2021), o software Agisoft apresentou maior distorção angular em áreas urbanas densas e favelas em comparação com o Pix4D Mapper. Por outro lado, em áreas com vegetação, o Agisoft demonstrou maior precisão. Contudo, essa comparação entre os softwares é superficial, já que o banco de imagens utilizado foi obtido por sensoriamento remoto e o artigo não detalha as taxas de sobreposição nem as configurações específicas dos parâmetros de processamento. Além disso, cabe investigar as razões pelas quais o Agisoft apresentou resultados mais favoráveis em áreas com vegetação do que em áreas com edificações.

O uso de combinações de tecnologias como o *laser scanner*, fotogrametrias e drone tem se mostrado eficaz na criação de modelos 3D detalhados e precisos de edificações e infraestruturas urbanas. Pierdicca *et al.* (2023) destacam a aplicação dessas tecnologias para a conservação patrimonial, abordando restauração de edifícios históricos por meio de levantamentos aéreos e terrestres realizados com drones e processados no Agisoft Metashape. A pesquisa salienta que a integração de tecnologias pode mitigar limitações individuais, como a dependência de geometria ou condições ambientais, fornecendo uma representação visual detalhada e adaptada às necessidades do modelo 3D e ortoimagens.

Segundo Pierdicca *et al.* (2023), a inspeção automatizada destaca-se como uma abordagem inovadora, integrando novas técnicas de aquisição de dados que automatizam tanto

a coleta quanto o processamento das informações. A combinação de técnicas fotogramétricas e de *laser scanner* possibilita a obtenção de modelos de alta resolução, sendo reconhecida como uma estratégia eficaz para melhorar a eficiência e a precisão no levantamento e documentação de estruturas arquitetônicas complexas. Essa abordagem demonstra a importância de selecionar tecnologias de levantamento adequadas às necessidades específicas do modelo 3D final, especialmente em contextos que envolvem geometrias complexas.

O processamento das imagens realizado no software Agisoft não foi discutido no trabalho de Pierdicca *et al.* (2023). A ortomagem apresentou imperfeições devido às limitações na captura de dados, como a complexidade da geometria da edificação e a cobertura das imagens ou na captura de dados em áreas específicas, que pode comprometer a qualidade da documentação. Outro ponto, o trabalho foi realizado em condições climáticas desafiadoras, com altas temperaturas, que podem afetar o processo de levantamento de campo. Condições de baixa visibilidade ou reflexos podem interferir na captura de imagens e na geração da nuvem de pontos.

Embora os autores tenham destacado a relevância das tecnologias utilizadas, o estudo não aprofundou a análise sobre o processamento das imagens no Agisoft, tampouco apresentou estratégias para superar as limitações observadas, o que evidencia a necessidade de investigações futuras voltadas para a otimização desses processos.

Abordagens mais eficientes e precisas de documentação e representação de estruturas de patrimônio cultural foram investigadas por Agrafiotis, Talaveros e Georgopoulos (2023) em uma pesquisa experimental. Os autores propuseram a aplicação de redes adversárias generativas condicionais (cGANS) para geração de desenhos 2D a partir de ortomagens, oferecendo uma representação mais automatizada e precisa. Essa abordagem facilita a interpretação e atualização das informações estruturais. A pesquisa avança no conhecimento com o uso da rede para o treinamento de um conjunto de dados composto por ortomagens de edifícios e seus correspondentes desenhos 2D, a partir de novas ortomagens não incluídas no conjunto de treinamento. Essa conversão automatizada permitiu a transformação rápida das imagens em formato vetorial editáveis, otimizando o processo de documentação e representação de edificações patrimoniais.

3.4 REVISÃO DE LITERATURA INTEGRANDO OS TEMAS E OUTRAS BASES DE DADOS

Algumas publicações não foram capturados pelas chaves de busca da revisão sistemática da literatura apresentada nos itens anteriores. Por essa razão, decidiu-se ampliar a revisão

bibliográfica para mapear melhor os temas de forma integrada e construir uma visão ampla do estado da arte.

Como estratégia de pesquisa, as referências selecionadas na RSL levaram a novos artigos e outras fontes bibliográficas, em um processo conhecido por bola de neve. Dessa forma, foi possível expandir a pesquisa bibliográfica, inclusive para os artigos de pesquisadores brasileiros.

Os artigos analisados estão apresentados no Quadro 14. Esses trabalhos utilizaram abordagens integradas, combinando o levantamento de imagens por drones com a aplicação de *deep learning*, em estudos voltados para a inspeção predial automatizada. Foram selecionados estudos que abrangem sistemas de coberturas planas, telhados e fachadas, ampliando, assim, o campo de referência da pesquisa e destacando suas limitações e contribuições para a pesquisa proposta neste trabalho de tese.

Quadro 14 - Resultado do levantamento bibliográfico sobre coberturas e fachadas.

Data	Autor	Tipologia do sistema			Ferramenta utilizada	Utilizou software para processamento da imagem		Utilizou a visão computacional	
		Cobertura plana	Telhados	Fachada		Sim	Não	Sim	Não
2012	Eschmann, Kuo, Kuo e Boller			x	Drone	Corel Photo-Paint			x
2017	Hezaveh, Kanan e Salvaggio		x		Drone		x	x	
2017	Melo Júnior, Evangelista Júnior, Silva e Nepomuceno			x	Drone	Agisoft Metashape		x	
2017	Banaszek, Banaszek e Cellmer	x			Drone	Pix4D			x
2018	Yudin, Naumov, Dolzhenko e Patrakova	x			Drone		x	x	
2018	Bown e Miller		x		Drone		x		x
2018	Rakha e Gorodetsky	x		x	Drone	Pix4D e Rhino3D CAD			x
2020	Gajjar e Burgett	x			Drone	ContextCapture			
2020	Silveira, Melo e Costa		x		Drone		x		x
2020	Staffa Junior, Sá, Lima e Costa		x		Drone	Custom Vision		x	
2022	Otoni, Novo e Costa		x		Drone		x	x	
2023	Lopes, Souza, Souza, Silva e Bauer			x	Drone	Agisoft Metashape			x
2024	Costa, Fernandes, Muta, Isatto e Costa	x		x	Drone	Recap			x

Fonte: Elaborado pela autora.

3.4.1 Fachadas

Eschmann, Kuo, Kuo e Boller (2012) contribuíram ao destacar a importância de aprimorar a estabilização dos voos, sistemas de navegação e planejamento das linhas de voo, visando automatizar o processo de inspeção. O estudo enfatizou a influência da orientação das linhas de voo sobre fachadas: linhas verticais podem amplificar distorções causadas pelas lentes, enquanto linhas horizontais exigem velocidades controladas devido às rápidas mudanças de ângulo e inclinação. Esses aspectos mostram a relevância de ajustes técnicos para aumentar a eficiência e segurança nas inspeções.

Melo Júnior *et al.* (2018) aplicou uma metodologia para geração automática de mapas de danos em ortoimagens de fachadas de edifícios, utilizando o drone para a captura de imagens e processamento no software Agisoft. O estudo abordou a geração de nuvens de pontos esparsas e densas, investigando o impacto de diferentes níveis de sobreposição de imagens em dois modelos da fachada em concreto aparente da Biblioteca Central da UnB.

As principais dificuldades encontradas por Melo Júnior *et al.* (2018) foram a sobreposição de imagens, o tempo de processamento e classificação de danos a partir das ortoimagens. Para os modelos avaliados, foram utilizados parâmetros de sobreposição longitudinal e lateral. O modelo 1 utilizou 80% e 40%, respectivamente, enquanto o modelo 2 utilizou 80% em ambas as direções. O modelo 1 incluiu 65 imagens, enquanto o modelo 2 utilizou 193. Apesar da maior quantidade de imagens e da sobreposição no modelo 2, os resultados da ortoimagem não apresentaram diferenças significativas em relação ao modelo 1.

O tempo de processamento do modelo 2, entretanto, foi quase quatro vezes superior ao do modelo 1, demonstrando que o aumento da complexidade do processamento, devido ao maior volume de dados, nem sempre resulta em melhorias na qualidade do produto. Este aspecto destaca a necessidade de se otimizar a coleta e o processamento de dados para equilibrar eficiência e qualidade.

Melo Júnior *et al.* (2018) cita outro fator que pode ter influenciado diretamente os resultados: a condição climática no momento da captura das imagens. Diferenças na coloração das imagens, atribuídas ao céu nublado, indicam que variabilidade das condições climáticas pode impactar a qualidade das ortoimagens. Além disso, o estudo não especificou a distância entre o drone e a fachada durante a captura, limitando a reprodutibilidade dos experimentos. Os resultados finais não apresentaram significância estatística para a geração automática de mapas de danos em ortoimagens de fachadas de edifícios, mas a metodologia proposta contribuiu para a aplicação dos processos automatizados.

Pesquisas recentes têm explorado o uso de drones como ferramenta de inspeção predial, utilizando modelos digitais para avaliar as condições em canteiro. Costa *et al.* (2024) propuseram um protocolo de voo em três etapas: verificação de condições de voo (com obstáculos), condições climáticas e posicionamento estratégico do piloto e do observador. Apesar de focarem na captura de imagens de canteiros de obras e edifícios específicos, os autores não definiram as linhas de voo conforme a tipologia das edificações, o que comprometeu a coleta de dados otimizados.

Lopes *et al.* (2023) evidenciam a relevância dos parâmetros de captura de imagens por drones em fachadas. Os autores destacam o cuidado necessário com o posicionamento e a proximidade da câmera, essenciais para obter imagens detalhadas e de alta qualidade. O estudo utilizou o software Agisoft Metashape para o processamento digital de imagens, com foco no mapeamento de danos e quantificação de degradação. As dificuldades enfrentadas incluíram obstáculos durante os voos e condições climáticas diversas. Lopes *et al.* (2023) ressaltaram que falhas no planejamento do voo comprometem significativamente a qualidade da ortoimagem e a identificação precisa de manifestações patológicas. Além disso, a obtenção de imagens em 2D com alto nível de detalhe e precisão depende da ortogonalização e da alta sobreposição, devido à quantidade de imagens a serem adquiridas.

Mendes *et al.* (2022) realizaram um estudo utilizando a fachada como objeto de análise, com o objetivo de gerar mapas de danos por meio de fotogrametria e imagens termográficas. Os autores definiram parâmetros detalhados para a captura das imagens, incluindo o tipo de drone, as linhas do plano de voo e aspectos técnicos como altitude, distância e sobreposição das imagens. Para o Museu Zoroastro Artiaga, as imagens foram capturadas a uma altitude de aproximadamente 1,80 metros, exigindo no mínimo 13 voos verticais, com registros fotográficos a cada 1,80 metros, para garantir uma sobreposição de 60% a 80%. A distância do drone ao plano da fachada foi mantida em 6 metros.

O processamento das ortoimagens foi realizado no software Agisoft, resultando em modelos fotográficos de alta qualidade, uma alternativa prática e eficiente para gerar mapas de danos. Contudo, os autores destacaram dificuldades relacionadas às condições de iluminação, sobreposição das imagens e acesso às áreas elevadas da fachada. A iluminação não uniforme foi identificada como um fator crítico, capaz de gerar sombras que comprometem a qualidade das imagens. Em edifícios históricos, como o museu, a altura da fachada e o acesso limitado a áreas elevadas representaram desafios significativos. Nesse contexto, o uso do drone permitiu capturar imagens de alta qualidade, atingindo até mesmo as partes mais altas do edifício.

3.4.2 Telhados

Hezaveh, Kanan e Salvaggio (2017) exploraram a detecção de danos em telhados, especificamente em telhas de asfalto danificadas por granizo de diferentes tamanhos. A pesquisa utilizou drones em conjunto com técnicas de *deep learning* para análise dos dados coletados. As imagens capturadas foram processadas por algoritmos que identificaram e classificaram os danos, oferecendo subsídios para decisões relacionadas à manutenção.

No contexto de coberturas inclinadas, Bown e Miller (2018) exploraram diferentes altitudes e níveis de detalhamento visual. O estudo conclui que a proximidade do drone com o telhado aumenta a quantidade de detalhes capturados, permitindo uma análise mais aprofundada das condições do sistema. No entanto, os voos foram realizados manualmente, sem planejamento estruturado, o que limitou a aplicabilidade dos resultados. Os autores sugerem, para futuras pesquisas, a adoção de planos de voo programados e o uso de câmeras mais avançadas, especialmente em coberturas que apresentam restrições específicas de acesso e visibilidade.

Os autores não analisaram as obstruções visuais que podem afetar a aquisição de imagens e os processos automatizados, por exemplo, presença de uma quantidade significativa de antenas nas proximidades das calhas. Essas antenas podem interferir nas anotações das imagens, dificultando a detecção e classificação das condições das calhas.

Silveira, Melo e Costa (2020) desenvolvem um protocolo de voo para a captura de imagens de coberturas com drones, visando realizar inspeções pós-ocupação em conjuntos residenciais. No entanto, os autores não discutem o impacto de um planejamento detalhado das linhas de voo na qualidade dos resultados obtidos.

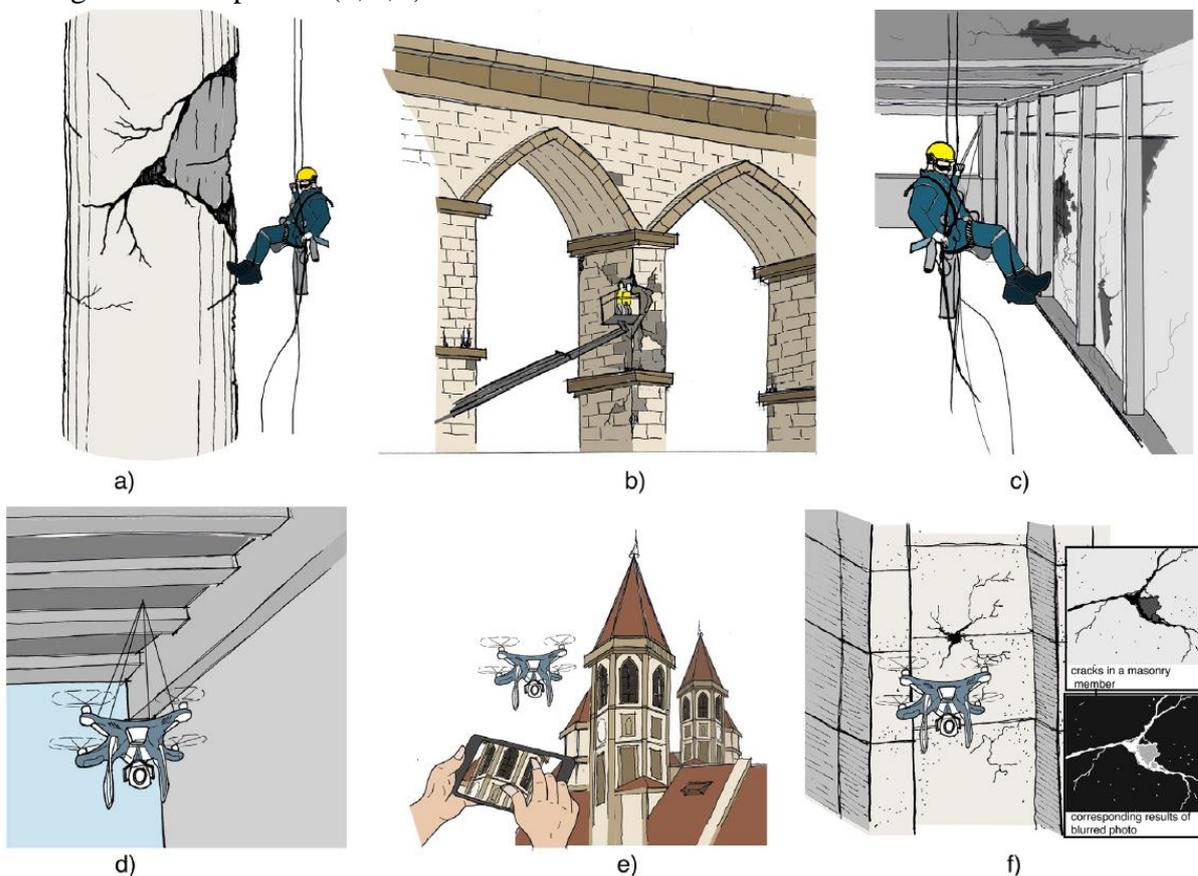
Otoni, Novo e Costa (2022) abordaram as dificuldades inerentes à inspeção de telhados, especialmente em relação às limitações de acessibilidade. A automação por meio do uso de drones foi apresentada como uma solução eficaz para promover uma análise mais detalhada e eficiente das condições do telhado, com foco nas telhas de fibrocimento. O trabalho se concentrou em algoritmos de classificação para duas categorias: calhas limpas e calhas sujas. A distinção foi feita com base na integridade e limpeza das calhas, uma irregularidade recorrente na avaliação de telhados. Uma contribuição significativa da pesquisa foi o ajuste de hiperparâmetros de redes neurais convolucionais para a classificação de imagens de telhados.

Staffa Junior *et al.* (2020) e Staffa Junior *et al.* (2023) exploraram o desenvolvimento de processos automatizados baseados em visão computacional em plataforma web. Utilizando o drone DJI Phantom 4 e o aplicativo DJI Go, o estudo capturou 3.404 imagens de telhados com telhas de fibrocimento, para identificar manifestações patológicas em um setor

habitacional de média e baixa renda. O plano de voo foi realizado em uma única direção, sem considerar particularidades específicas das edificações. As imagens obtidas foram processadas na plataforma *Custom Vision*, onde foram realizadas a detecção automatizada para identificar manifestações patológicas. O estudo alcançou um índice de acerto de 77,08% nos testes de desempenho das redes neurais convolucionais para detecção da manifestação patológica, evidenciando o potencial da tecnologia na avaliação de sistemas de cobertura, embora delimitado ao tipo de telhado analisado.

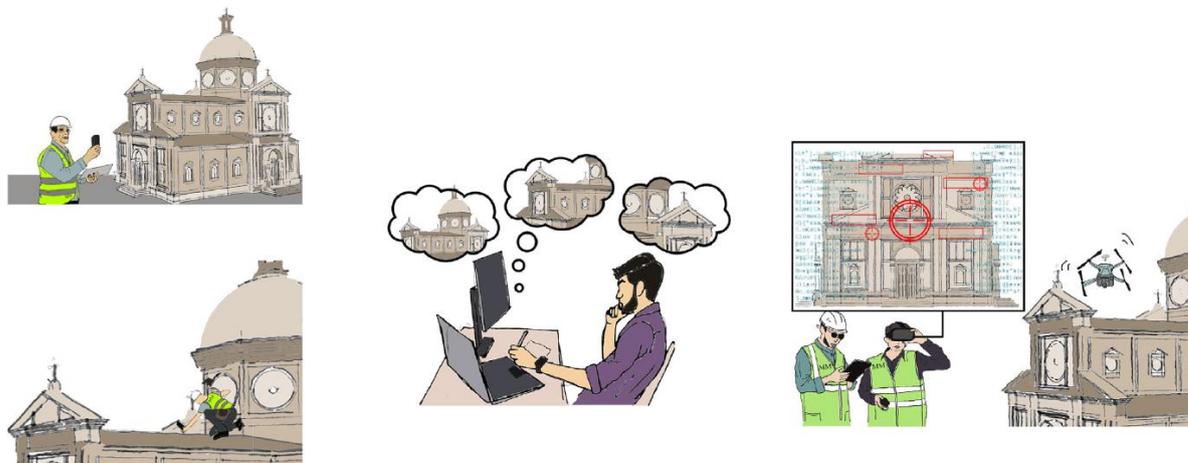
Mishra e Lourenço (2024), abordaram inspeções prediais automatizadas em contextos patrimoniais, sem foco específico em coberturas planas, mas ilustrando limitações das práticas tradicionais e benefícios das tecnologias emergentes (Figuras 24 e 25).

Figura 24 - Ilustração dos problemas com inspeções tradicionais de locais de difícil acesso e locais de alto risco (a, b, c). Inspeções baseadas em drones com uma interface para assistir às filmagens em tempo real (d, e, f).



Fonte: Adaptado de Mishra e Lourenço (2024).

Figura 25 - Ilustração dos sistemas assistidos por inteligência artificial (IA) do presente para o futuro para patrimônio cultural.



(a) Sistemas assistidos por IA presentes

(b) Sistemas assistidos por IA futuros

Fonte: Adaptado de Mishra e Lourenço (2024).

Costa *et al.* (2024) avaliaram os procedimentos de desenvolvimento e a qualidade de modelos 3D gerados por fotogrametria a partir de imagens capturadas por drone, investigando como as práticas adotadas na coleta de dados afetam a precisão dos modelos ou das nuvens de pontos geradas. A pesquisa teve como objetivo aprimorar a qualidade dos modelos *as-built*. As imagens foram capturadas por drone e processadas no software *Autodesk ReCap Photo*, que permitiu a criação de malhas tridimensionais com texturas, nuvens de pontos georreferenciadas e fotografias ortogonais.

O estudo apresentado por Costa *et al.* (2024) não detalhou as configurações específicas utilizadas no processamento das ortoimagens e na geração do modelo 3D, nem forneceu informações sobre as linhas de voo e as tomadas fotográficas empregadas na captura das imagens. Apenas o percurso do drone no canteiro de obras foi mencionado. Essa ausência de informações ressalta a necessidade de melhorias nos procedimentos de coleta e processamento de imagens para aumentar a precisão e a confiabilidade dos modelos gerados por fotogrametria. Além disso, evidencia a importância de documentar e analisar detalhadamente os parâmetros adotados para garantir a reprodutibilidade e a validade científica dos resultados.

3.4.3 Cobertura Plana

O uso do drone para inspeção de edificações de grande porte é um tema explorado por Banaszek, Banaszek e Cellmer (2017), que demonstraram o potencial dessa tecnologia para avaliações visuais de condições técnicas de coberturas em grande escala. Foram utilizados drones para avaliar visualmente as condições técnicas de coberturas planas por meio de

ortoimagens e nuvens de pontos, permitindo a identificação de falhas como danos nas calhas e problemas de estanqueidade.

No estudo de Banaszek, Banaszek e Cellmer (2017), foram realizados voos em diferentes altitudes (80, 60, 40 e 20 metros) para avaliar as condições técnicas das coberturas, com processamento no Pix4D e uso do QGIS para vetorização de falhas. A análise baseada em nuvens de pontos e imagens digitais forneceu subsídios técnicos para a avaliação de danos.

Embora a análise tenha demonstrado a eficácia da tecnologia de drones na coleta de dados e na geração de nuvens de pontos, o estudo apresenta limitações importantes. Os autores não discutiram como as configurações dos planos de voo influenciaram na detecção e identificação das manifestações patológicas. Aspectos como a direção das linhas de voo, a sobreposição entre as imagens e o impacto das diferentes altitudes na qualidade dos dados não foram analisados, o que deixa lacunas sobre como otimizar o planejamento de voos para inspeções mais eficazes.

Yudin *et al.* (2018) propuseram o desenvolvimento de um software específico para detecção de defeitos em coberturas planas, utilizando imagens aéreas capturadas por drones. O sistema automatizado baseia-se em um mecanismo de segmentação binária, capaz de identificar áreas nas imagens que apresentam irregularidades, como a estagnação de água após as chuvas. A principal finalidade do software é automatizar o processo de inspeção predial, contribuindo para a manutenção e o reparo na construção civil. No entanto, o estudo limita-se à identificação de irregularidades pela delimitação do objeto por retângulos (*bounding box*), sem detalhar o seu contorno como utilizado na segmentação semântica de objeto. Portanto, o trabalho de Yudin *et al.* (2018) propõem o reconhecimento de áreas propensas à estagnação de água após a chuva sem abordar de forma detalhada o contexto e os locais mais suscetíveis em sistemas de cobertura plana.

Rakha e Gorodetsky (2018) apresentaram parâmetros de trajetória de voo para inspeções de coberturas e fachadas, enquanto compararam inspeções tradicionais e automatizadas, utilizando modelagem 3D a partir de imagens capturadas por drone.

Gajjar e Burgett (2020) discutem o potencial de substituição das inspeções presenciais por modelos 3D gerados a partir de imagens capturadas por drones, utilizando software *structure-from-motion* (SfM). O estudo foi conduzido em uma cobertura plana construída em 1999, com o objetivo de avaliar a eficácia do modelo 3D na identificação de manifestações patológicas em comparação com o método de inspeção tradicional. Os resultados mostraram que o modelo 3D foi capaz de identificar 191 manifestações patológicas, enquanto o método tradicional detectou 200.

No entanto, o estudo de Gajjar e Burgett (2020) apresenta limitações relevantes. Os autores não analisaram como as configurações do modelo 3D impactaram os resultados obtidos, especialmente no que se refere à visualização de problemas específicos, como calhas e tubos de queda entupidos em áreas críticas do sistema de cobertura. Não foram encontradas informações detalhadas sobre os parâmetros técnicos utilizados na geração do modelo, incluindo a resolução das imagens, a sobreposição e as técnicas de processamento adotadas.

3.4.4 Considerações sobre o estado da arte e as lacunas de pesquisa

A pesquisa bibliográfica revelou três categorias principais de análise: fachada, telhado (cobertura inclinada com telha) e cobertura plana (laje impermeabilizada). Em geral, a aplicação mais frequentemente abordada pelas pesquisas é a visão computacional em telhados, seguido por fachadas. Em relação ao processamento de imagens, as fachadas e os telhados são mais estudados que as coberturas planas. Apesar dos avanços no uso de tecnologias digitais para inspeções prediais, o tema relacionado a sistemas de cobertura plana ainda é pouco explorado, evidenciando a necessidade de estudos mais aprofundados e direcionados a essa área específica.

O uso de drones para a captura de imagens de telhados sob diferentes ângulos e condições oferece um levantamento detalhado e abrangente das superfícies, permitindo identificar manifestações patológicas que podem passar despercebidas em inspeções tradicionais. Quando integradas a técnicas de inteligência artificial, como *deep learning*, essas imagens possibilitam uma solução eficiente para diversos tipos de edificações, superando as limitações das inspeções presenciais. Essa abordagem não apenas reduz riscos, como quedas, mas também diminui o tempo e os custos associados, além de melhorar significativamente a qualidade das avaliações.

Dados precisos obtidos por drones viabilizam análises detalhadas das condições das edificações e permitem comparações com futuras avaliações, contribuindo para o monitoramento contínuo, a identificação de manifestações patológicas ao longo do tempo e o prolongamento da vida útil das edificações. No entanto, os estudos existentes apresentam lacunas significativas, sobretudo no que diz respeito à utilização de processos automatizados em *deep learning* para detecção e segmentação semântica, com foco no monitoramento eficaz de sistemas de cobertura plana.

Embora a literatura demonstre o potencial dos drones na inspeção predial, desafios relacionados ao planejamento de voos comprometem a qualidade das ortoimagens e dos modelos digitais de elevação gerados. Falhas como a falta de definição para as direções de voo e de critérios específicos para coleta de imagens reforçam a necessidade de estratégias mais robustas, capazes de garantir resultados mais precisos e abrangentes. A criação de bancos de

imagens obtidas por drones consolidou-se como uma ferramenta inovadora para o monitoramento e manutenção de edificações.

As tecnologias digitais e processos automatizados permitem levantamentos ágeis e eficientes, especialmente em coberturas com diferentes níveis, destacando-se pela maior eficiência em relação aos métodos tradicionais. Entretanto, os estudos revisados indicam que as metodologias existentes ainda carecem de abordagens específicas para sistemas de cobertura plana, o que limita sua aplicação em casos mais complexos.

Apenas um estudo aborda a detecção de manchamentos em coberturas planas, e ainda com técnicas que não detalham o contorno da irregularidade, evidenciando a necessidade de maior aprofundamento na área. Para aplicações em maior escala ou em edificações com geometria arquitetônica complexa, é fundamental aprimorar os processos de captura e modelagem para alcançar maior precisão nos resultados. Ao abordar essas lacunas, contribuiu-se significativamente para o avanço das metodologias voltadas à inspeção de sistemas de cobertura plana, ampliando o campo do conhecimento científico e técnico.

Enfim, após a leitura e análise desses marcos referenciais da bibliografia, destaca-se a importância e a originalidade da abordagem integrada desta tese, que até o momento tem sido tratada de maneira limitada. A análise reflete uma lacuna significativa no campo da inspeção predial automatizada de coberturas planas, enfatizando a necessidade de avanços no desenvolvimento de soluções tecnológicas para monitoramento e manutenção desse tipo de sistema.

4 MÉTODO DE PESQUISA

Este trabalho fundamenta-se em uma abordagem qualitativa, integrando diferentes tipos de pesquisa. Nas seções 2 e 3, foi apresentada a pesquisa bibliográfica, que abrangeu uma revisão sistemática da literatura, bem como a análise de outros referenciais teóricos e normativos para subsidiar os conteúdos do campo conceitual estabelecido e as investigações realizadas. A pesquisa exploratória incluiu levantamentos de campo e inspeções prediais em coberturas planas realizadas com drones, processamento digital de imagens e construção de um banco de imagens necessário para os processos automatizados. A pesquisa experimental concentrou-se em experimentos de detecção de equipamentos e segmentação semântica de manchas, envolvendo visão computacional e processos automatizados em *deep learning*.

Nesta seção, são detalhadas as abordagens metodológicas adotadas, suas respectivas etapas, métodos, técnicas, recursos e procedimentos, conforme delineamento no fluxograma apresentado na Figura 26.

Figura 26 - Delineamento das etapas de pesquisa.



Fonte: Elaborado pela autora.

4.1 SELEÇÃO E CARACTERIZAÇÃO DA AMOSTRA

Para os levantamentos de campo em inspeções prediais com drones em coberturas planas, foi selecionada uma amostra composta por edifícios que atenderam aos seguintes critérios:

- Edificações com sistema de cobertura plana e lajes impermeabilizadas;
- Edificações com mais de um pavimento, com diferentes níveis e configurações arquitetônicas; e,
- Edificações com extensas coberturas, pertencentes a complexos institucionais públicos, que representam exemplares de interesse cultural.

Assim, foram escolhidas quatro edificações da Universidade de Brasília, no campus Darcy Ribeiro (UnB), e o conjunto de edificações do Quartel General do Exército Brasileiro (QGEx), localizado no setor militar urbano em Brasília. As coberturas escolhidas apresentam características estruturais e construtivas semelhantes, com lajes de concreto armado e sistema de impermeabilização com manta asfáltica. São elas:

- 9 coberturas do Quartel General do Exército Brasileiro (QGEx);
- Cobertura da Biblioteca Central (BCE) da UnB;
- Instituto Central de Ciências (ICC) da UnB;
- Unidade da Criança e do Adolescente (UCA) da UnB;
- Reitoria da UnB.

Serão apresentadas cada uma das edificações que compõem a amostra.

4.1.1 Quartel General do Exército Brasileiro (QGEx)

O Quartel General do Exército Brasileiro (QGEx) é sede do comando da força militar na capital do Brasil. Trata-se, portanto, de um complexo arquitetônico de caráter simbólico e representativo do poder militar. Intitulado como Forte Caxias, é formado por 9 edifícios que abrigam 34 órgãos administrativos do Exército, ocupando uma área de 117.000 m² (Figura 27).

O projeto arquitetônico, datado de 1969, é assinado pelo arquiteto Oscar Niemeyer. O conjunto foi inaugurado em 1974 e tombado pela Secretaria do Patrimônio do Distrito Federal em 2011. As edificações são blocos lineares, dispostas paralelamente à Praça Duque de Caxias, próximas ao Teatro Pedro Calmon, à Concha Acústica e ao Obelisco (Figura 28).

Figura 27 - Quartel General do Exército.



Fonte: Campos (2020).

Figura 28 - Coberturas das edificações do QGEx.



Fonte: a própria autora.

4.1.2 Universidade de Brasília – Campus Darcy Ribeiro

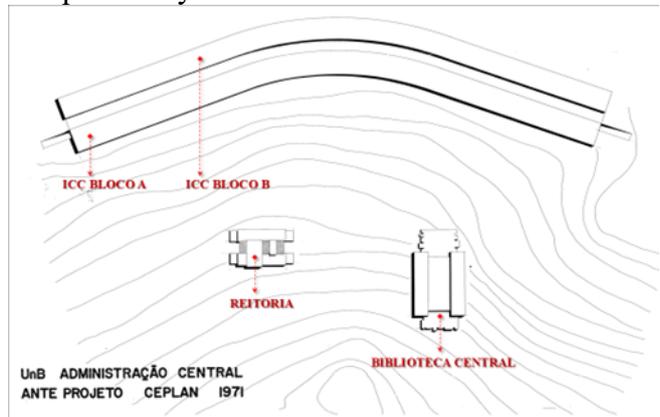
A UnB é uma instituição pública brasileira de ensino superior, localizada em Brasília, DF. Seu principal campus é o Darcy Ribeiro (Figura 29), com uma área de 3.950.569,70 m², cuja inauguração ocorreu em 1962. A UnB foi idealizada por Darcy Ribeiro e Anísio Teixeira e concebida pelo arquiteto Oscar Niemeyer. A Figura 30 apresenta o ICC, a Reitoria e a Biblioteca Central, edifícios que compõem a amostra desta pesquisa.

Figura 29 - Campus Darcy Ribeiro.



Fonte: Viana (2019).

Figura 30 - Localização dos edifícios de estudo no campus Darcy Ribeiro da UnB.



Fonte: Adaptado do Ceplan.

a. Biblioteca Central (BCE)

O edifício da BCE-UnB projetado pelos arquitetos José Galbinski e Miguel Pereira, foi inaugurado em 1973 com uma área construída de 17.955m². Apresenta uma configuração complexa, dividida em três diferentes volumes, sendo constituído por um bloco central, com uma altura de 12 metros, e dois blocos nas suas extremidades. As fachadas do bloco central possuem placas verticais de sombreamento em concreto armado que formam, em conjunto com os *sheds* da cobertura, um sistema de pórticos com telhamento metálico. As coberturas

compostas pelas lajes recebem um sistema de impermeabilização flexível com manta asfáltica e proteção mecânica (Figuras 31 e 32). Em 2024, a envoltória da BCE começou a ser restaurada, com limpeza e proteção do concreto aparente da fachada e nova impermeabilização da cobertura, com mantas asfálticas e proteção mecânica com argamassa.

Figura 31 - Perspectiva da BCE.



Fonte: A própria autora.

Figura 32 - Sistema de cobertura da BCE.



Fonte: A própria autora.

Embora boa parte do prédio possua três pavimentos, os grandes painéis verticais de concreto aparente que funcionam como brises-soleil nas fachadas principais (norte e sul) imprimem uma unidade visual ao volume. Na direção longitudinal da edificação, o sistema de pórticos com telhamento metálico configuram-se como painéis com curvatura que se projetam como beirais sobre as fachadas e sobre a grande laje impermeabilizada da cobertura plana.

b. Reitoria

A Reitoria foi projetada pelo arquiteto Paulo de Melo Zimbres e construída entre 1972 e 1975. A edificação em concreto aparente, possui uma área construída de 8.001m². O projeto arquitetônico resulta da interação entre dois blocos retangulares, que são paralelos e afastados entre si (Schlee *et al.*, 2014). Cada pavimento possui um desnível de meio pé-direito em relação ao bloco adjacente inferior, formando um sistema de rampas transversais e contínuas que conecta todos os níveis, onde cada patamar representa um pavimento. Entre os dois blocos, existe um amplo jardim com uma cobertura em grelha que alterna entre seções vazadas e cegas. Os espaços considerados mais nobres do ponto de vista hierárquico estão localizados nos níveis mais elevados. O volume do auditório se destaca, sendo sustentado por tirantes fixados na estrutura da cobertura (Schlee *et al.*, 2014).

As Figura 33 e 34 mostram o edifício da Reitoria composto por cinco diferentes níveis, com alturas de 3,04 m, 6,30 m, 1,60 m, 15,66 m e 17,90 metros. Ao longo do tempo, as lajes de cobertura sofreram ações de reparo em diferentes partes da camada de impermeabilização, sendo identificados: membrana polimérica com reforço em tela de poliéster; manta aluminizada e manta asfáltica com proteção mecânica.

Figura 33 - Perspectiva da Reitoria.



Fonte: A própria autora.

Figura 34 - Sistema de cobertura da Reitoria.



Fonte: A própria autora.

c. Instituto Central de Ciências (ICC)

O ICC é um edifício linear que abriga a maioria dos institutos, faculdades, salas de aula, laboratórios e anfiteatros da instituição. Este edifício começou a ser construído em 1963, pela extremidade sul, com seu volume linear e curvo, com 696 m de extensão, composto de dois blocos paralelos (A e B), afastados um do outro por uma faixa ajardinada de 15 m.

O Bloco B, voltado para oeste, possui 25 m de largura e foi pensado para acomodar anfiteatros e salas de professores distribuídos ao longo de seus dois pavimentos, mezaninos e subsolo. Por sua vez, o bloco orientado para leste – Bloco A, possui uma largura de 30 m e incorpora uma sessão com mezanino e pé-direito duplo. Este bloco foi pensado para abrigar, em seus dois pavimentos e mezaninos, diversos laboratórios e salas de aula da instituição (Schlee *et al.*, 2014). A grande cobertura plana, com mais de 42.000 m² de impermeabilização e proteção mecânica (Figura 35), cobre dois blocos paralelos em curvatura, com aproximadamente 720 m de comprimento (Santos *et al.*, 2024). Desde os croquis de Niemayer indicando o ICC maior que 600 m, a extensão linear do ICC varia conforme os diversos autores que descrevem, pesquisam e medem o edifício.

Figura 35 - Vista panorâmica do grande plano da cobertura do ICC-UnB.



Fonte: A própria autora.

O sistema estrutural em concreto armado aparente do ICC é definido pelos grandes pórticos pré-fabricados, espaçados a intervalos de 3 m (Schlee *et al.*, 2024). As vigas protendidas com perfil em “T” que vencem vãos de até 30 metros, apresentam seção de geometria variável, com três transeptos como enrijecedores intermediários. Internamente, essas vigas se prolongam em seção retangular, formando os pergolados que se estendem até o apoio dos pilares internos (Figura 36 e 37). Externamente, os pilares apoiam vigas-calha longitudinais, que, por sua vez, servem de apoio aos painéis pré-moldados das lajes, sem formarem uniões rígidas entre si (Silva; Vasconcellos; Sánchez, 2019).

Figura 36 - Perspectiva do ICC.



Fonte: A própria autora.

Figura 37 - Sistema de cobertura do ICC.



Fonte: A própria autora.

d. Unidade da Criança e do Adolescente (UCA)

A Unidade da Criança e do Adolescente (UCA) foi inaugurado no primeiro semestre de 2023, com uma área de 6.247m². Este edifício foi construído com o objetivo de atender às necessidades de crianças e adolescente que necessitam do serviço de saúde. O formato da edificação é configurado conforme o fluxo e as atividades assistenciais oferecidas, o que resultou em pavimentos com diferentes níveis, proporcionando a instalação de equipamentos

necessários para o suprimento das atividades hospitalares. A cobertura possui um sistema de impermeabilização flexível com manta e proteção mecânica. No edifício principal, as alturas dos três diferentes níveis são de 4,55m, 11,56m e 18,40m (Figuras 38 e 39).

Figura 38 - Perspectiva da UCA.



Fonte: A própria autora.

Figura 39 - Sistema de cobertura da UCA.



Fonte: A própria autora.

4.2 AQUISIÇÃO DE IMAGENS

O levantamento de campo consistiu em uma etapa de inspeção visual *in loco* e coleta de dados dos sistemas de cobertura dos edifícios da amostra, por meio de vistorias e registros da situação atual para documentação do estado de conservação, utilizando drones equipados com sensores de fotogrametria para a captura de imagens. Após essa etapa de aquisição de imagens, foi realizado o processamento digital das imagens para a geração de ortomagens das coberturas e a construção de um banco de imagens (*dataset*) para os processos automatizados em *deep learning*.

4.2.1 Caracterização das Variáveis de Análise da Pesquisa

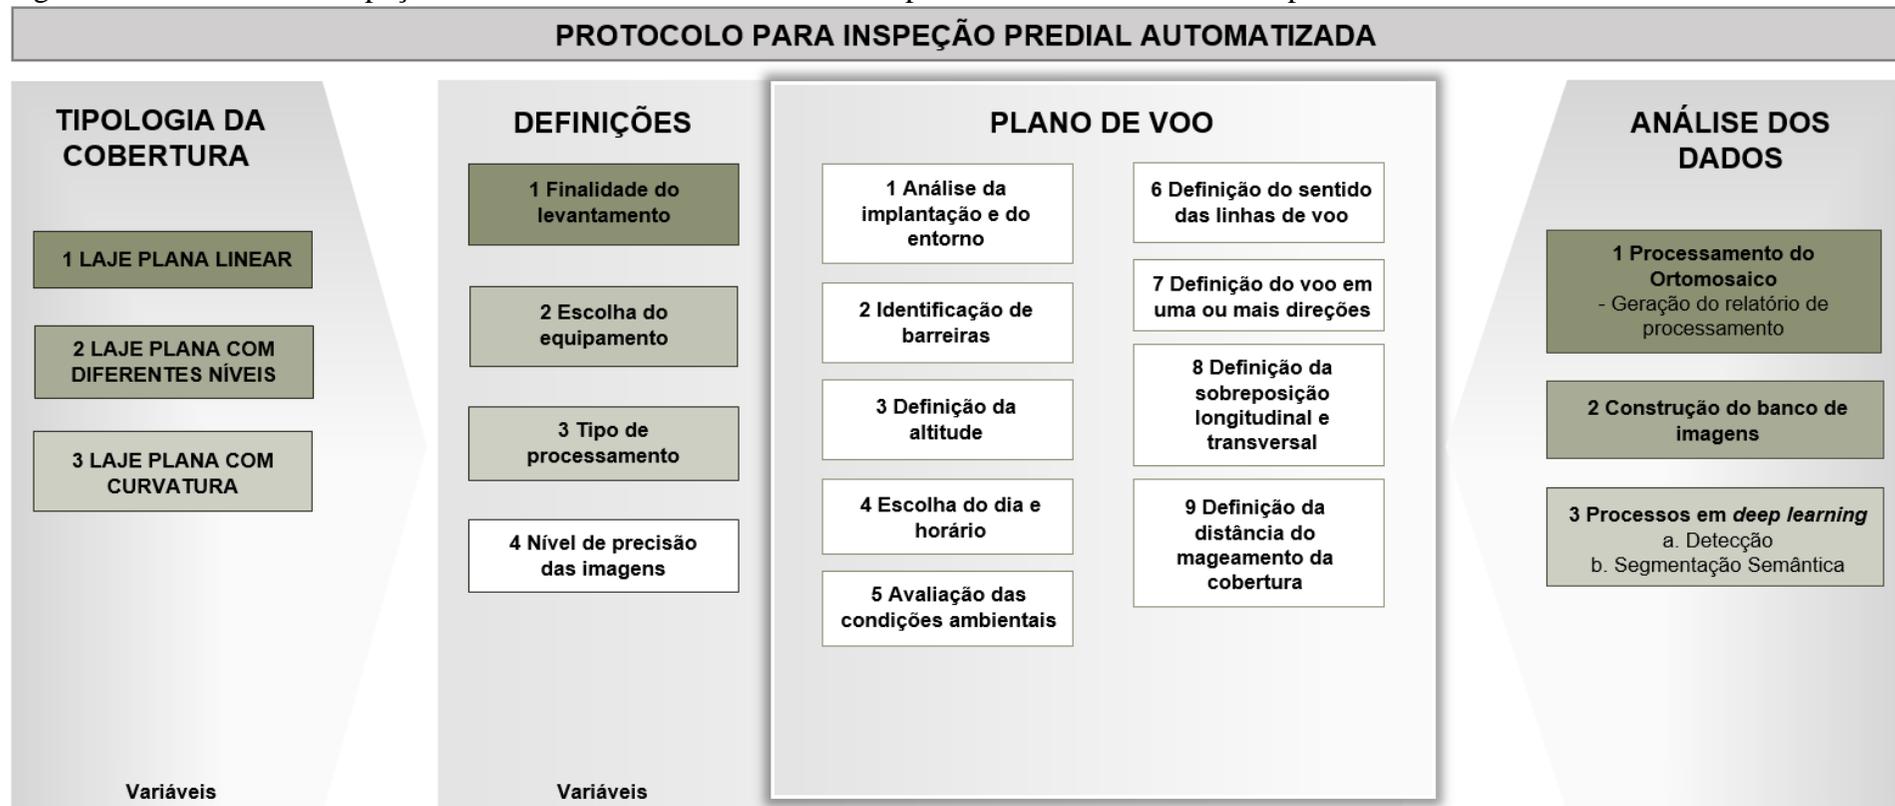
O Quadro 15 apresenta as variáveis de análise para o sistema de cobertura plana, organizadas em cinco grupos. Essas variáveis são determinantes nas definições dos planos de voos, na captura de imagens com drones e no processamento digital. A partir das variáveis definidas, foi criado um protocolo para a inspeção predial automatizada para cobertura plana, com o uso do drone, ilustrado na Figura 40. A complexidade que envolve a realização da inspeção do sistema de cobertura requer atenção aos requisitos de segurança e o uso adequado do equipamento.

Quadro 15 - Variáveis de análise para o sistema de cobertura plana.

Variáveis de análise	
i. Configurações de cobertura	<ul style="list-style-type: none"> - Cobertura plana linear - Cobertura plana linear com curvatura - Cobertura plana com diferentes níveis
ii. Planejamento do voo	<ul style="list-style-type: none"> - Finalidade do levantamento - Escolha do equipamento - Tipo do processamento - Nível de precisão das imagens
iii. Plano de voo	<ul style="list-style-type: none"> - Vistoria prévia - Análise da implantação e do entorno - Identificação de barreiras - Definição da altitude - Escolha do dia e horário - Avaliação das condições ambientais (vento e clima) - Definição do sentido das linhas de voo - Definição do voo em uma, duas ou mais direções - Definição da sobreposição longitudinal e transversal - Definição da distância da margem da cobertura - Acessibilidade: autorização de voo
iv. Processamento	<ul style="list-style-type: none"> - Definição dos parâmetros de processamento - Escolha e eficiência do <i>hardware</i> e do sistema computacional
v. Processo automatizado	<ul style="list-style-type: none"> - Definição da quantidade de imagens do banco de imagens - Caracterização do objeto para detecção ou segmentação semântica

Fonte: Elaborado pela autora.

Figura 40 - Protocolo de inspeção com drone e as variáveis de análise para os sistemas de cobertura plana.



Fonte: Elaborado pela autora.

4.2.2 Planejamento dos Planos de Voo para a Aquisição das Imagens

Para o levantamento físico in loco, o plano de voo para a captura de imagens com drone deve considerar o detalhamento e objetivo da missão. Além disso, deve ser definido o equipamento a ser utilizado, verificada a implantação do edifício, sua tipologia, o tipo do sistema construtivo a ser inspecionado e as condições meteorológicas, tendo em vista a finalidade das informações coletadas e o tipo de processamento de imagem.

O planejamento dos voos sobre as coberturas planas baseou-se em três etapas para a sua execução, sendo elas:

- Definições: a finalidade do levantamento de voo, o tipo de equipamento a ser utilizado de acordo com o nível de detalhamento que se deseja alcançar para a captura de imagens, e o tipo de processamento a ser realizado após a captura;
- Plano de voo: o planejamento no aplicativo *Drone Deploy Flight* e *DJI Fly*, permitindo planejar o voo no modo automático. Esta etapa foi de extrema importância devido às variáveis consideradas para cada voo realizado;
- Processamento de imagem: definição dos parâmetros de processamentos utilizados nos voos realizados nos casos de estudo.

Foi necessária a realização de um voo preliminar (pré-teste) ao redor dos edifícios para definição do plano de voo programado, utilizando os aplicativos *Drone Deploy Flight* e *DJI Fly* baseados na navegação por *waypoints*, definidos por coordenadas geográficas através do sistema GPS.

4.2.3 Procedimentos para Aquisição das Imagens

Os drones DJI Mavic Pro, DJI Mavic 2 Pro e DJI Air 2S foram escolhidos para a realização dos voos e aquisição das imagens. O DJI Mavic Pro foi utilizado nos voos realizados no QGEx, o DJI Mavic 2 Pro nos estudos realizados na BCE e o DJI Air 2s utilizado na Reitoria, ICC e UCA. O que diferenciou os drones, além das configurações apresentadas no Quadro 16, foi o tipo de sistema de coordenadas utilizado.

DJI Mavic Pro e DJI Mavic 2 Pro utilizaram o *Geographic Positioning System* (GPS) sistema norte americano, já o DJI Air 2s utiliza o sistema *Global Navigation Satellite System* (GNSS) que incluem o Galileo da Europa, o sistema de posicionamento global (GPS), o *Global Navigation System* (GLONASS) da Rússia e o Sistema de Navegação por Satélite BeiDou da China.

Os drones DJI Mavic 2 Pro e DJI Air 2s foram cedidos pelo Laboratório de Sustentabilidade aplicada à Arquitetura e ao Urbanismo (LaSUS FAU UnB) para esta pesquisa.

Quadro 16 - Parâmetros da câmera do DJI Mavic 2 Pro e DJI Air 2S.

DJI MAVIC PRO	DJI MAVIC 2 PRO
<ul style="list-style-type: none"> • Configurações da câmera: • Tamanho da imagem: 4000 x 3000; • Sensor: 12.35 M; • Comprimento focal: 35.0 mm; • Peso de decolagem: 734 g. 	<ul style="list-style-type: none"> • Configurações da câmera: • Tamanho da imagem: 5472 x 3648; • Sensor: 12.71 M; • Comprimento focal: 35.0 mm; • Peso de decolagem: 970g. 
DJI AIR 2S	
<ul style="list-style-type: none"> • Configurações da câmera: • Tamanho da imagem: 5472 x 3648; <ul style="list-style-type: none"> • Sensor: 20 MP; • Comprimento focal: 35.0 mm; • Peso de decolagem: 595g. 	

Fonte: Elaborado pela autora.

A Figura 41 mostra a interface do aplicativo *DroneDeploy Flight* com os parâmetros utilizados para a realização do plano de voo em uma parte do ICC UnB. Os critérios e parâmetros utilizados variam conforme o tipo de voo.

A Figura 41a mostra que é necessário definir a altitude do voo. É importante verificar se a mensagem de perigo aparece, por causa da baixa altitude definida, mostrando a necessidade de verificação de segurança, bem como a identificação in loco de objetivos maiores que a altitude do voo, a fim de se evitar a colisão com obstáculos. A Figura 41b mostra a aba que aparece ao clicar no *Advanced*. É importante verificar se a opção *Automatic Setting* ficou desativada.

Conforme ilustrado na Figura 41, existem variáveis que são importantes para as tomadas de decisão quanto aos parâmetros e preenchimento no aplicativo no momento da execução do voo. Entre elas, podem ser considerados os seguintes critérios e parâmetros:

- *Front Overlap* (sobreposição transversal): considerar 80% para sobreposição entre imagens consecutivas capturadas durante o voo do drone. Em projetos que requerem alta precisão, a sobreposição pode ser aumentada;
- *Side Overlap* (sobreposição longitudinal): considerar 75% para a sobreposição entre imagens laterais, capturadas nas linhas paralelas;
- *Flight Direction* (direção de voo): definir as linhas de direção do drone. No caso do ICC UnB, foi necessário ajustar em todos os planos de voo esse parâmetro, por causa da configuração da cobertura da edificação;

- *Mapping Flight Speed* (mapeamento de velocidade): adotar 2 m/s para a velocidade de deslocamento do drone durante a captura de imagens;
- *Starting Waypoint* (ponto de partida): refere-se ao primeiro ponto de uma rota de voo programado, onde o drone começa a sua missão. Este quesito é definido pela coordenada geográfica;
- *Gimbal Angle* (ângulo de gimbal): considerar o ângulo de -90° , em que a câmera ficou posicionada em relação ao solo;
- *Perimeter 3D* (perímetro 3D): deve permanecer ativado até a finalização do voo, garantindo a captura de todo o perímetro da edificação para uma melhor visualização das fachadas e utilização no processamento.
- *Obstacle Avoidance* (evitar obstáculos): deve sempre estar ativado para que o drone possa desviar de qualquer obstáculo que se aproxime durante o plano de voo. É necessário tomar cuidado, pois os sensores podem estar localizados apenas na parte frontal do equipamento. Se a opção do Perímetro 3D estiver habilitada, existe uma grande chance de colisão com árvores ou equipamentos muito próximos ao sistema de cobertura.

Figura 41 - Plano de voo realizado no aplicativo *DroneDeploy Flight* - ICC A UnB.



Fonte: Elaborado pela autora.

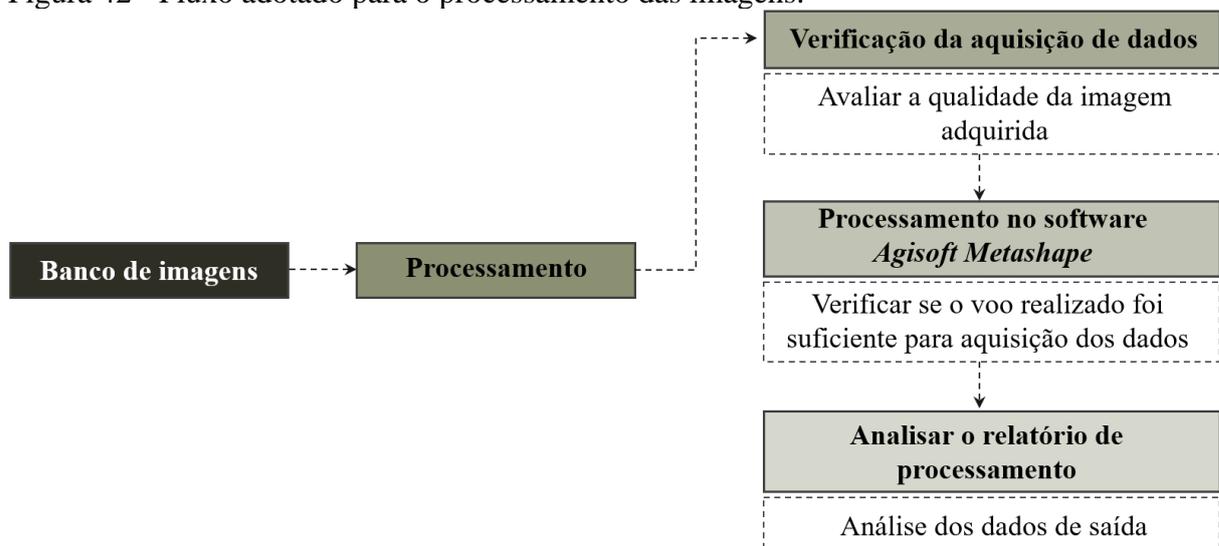
Além dos requisitos do planejamento já listados, para todos os planos de voo realizados nos edifícios estudados, foram aplicados os seguintes critérios:

- Dia ensolarado, mas com nuvens, para obter luz difusa e evitar sombras;
- Verificação se a velocidade do vento exerce influência na estabilidade do drone;
- Voo manual para verificação de antenas e árvores circundantes às edificações;
- Transferência das imagens coletadas imediatamente após a realização dos voos, assim como as anotações das configurações utilizadas.

4.3 ETAPAS DO PROCESSAMENTO DIGITAL DAS IMAGENS

Após a aquisição das imagens, os dados foram armazenados em um dispositivo eletrônico com capacidade adequada para a etapa de tratamento e processamento digital. A Figura 42 apresenta as etapas do processamento até a análise do relatório final.

Figura 42 - Fluxo adotado para o processamento das imagens.



Fonte: Elaborado pela autora.

Com o arquivo digital, a primeira providência foi excluir as imagens que apresentavam algum problema. Em seguida, as imagens foram carregadas no software Agisoft Metashape e iniciada as etapas de processamento e posterior análise do relatório. A partir do relatório gerado, foi possível verificar a necessidade de realizar novos voos ou ajustar os parâmetros definidos no processamento para a construção da ortoimagem. As etapas do processamento digital no software são descritas no item 4.3.1.

Utilizou-se para os três primeiros experimentos da BCE um computador com sistema operacional Windows 10 Pro de mesa (*desktop*) com processador Intel (R) Core (TM) i7-9700 CPU @ 3.00 GHz, 16 GB de memória instalada (RAM), sistema operacional de 64 bits.

Para os demais processamentos utilizou-se um computador *Precision Tower 7810*, com sistema operacional Windows 10 Pro de mesa (*desktop*) com processador Intel (R) Xeon ® CPU E5-2620 v4 @ 2.10GHz, 64 GB de memória instalada (RAM), sistema operacional de 64 bits.

4.3.1 Agisoft® Metashape 1.5.0 build 7492

O Agisoft Metashape 1.5.0 *build 7492* possui uma sequência de etapas definidas no menu *workflow* e uma interface intuitiva para os processamentos apresentados na Figura 43. O fluxo de trabalho do processamento das imagens capturadas inicia-se com o seu carregamento no software Agisoft Metashape 1.5.0 *build 7492* até a geração da ortoimagem.

Para os processamentos, as ações executadas foram: carregamento das imagens; alinhamento das imagens e construção do modelo de nuvens de pontos esparsas; construção da nuvem densa de pontos; construção da malha; aplicação da textura; construção de modelo de elevação (DEM); e construção da ortoimagem. As configurações e interface de cada etapa estão no Apêndice A. O sistema de coordenada utilizado para o processamento da ortoimagem foi o WGS 84 (EPSG:4326).

Figura 43 - Etapas do processamento de imagem.



Fonte: Elaborado pela autora.

Para o carregamento da etapa de *Align Photos*, foram descartas as imagens capturadas no solo, na parada para a troca de bateria, e imagens que possuíam algum erro de captura. Destaca-se que nas etapas de alinhamento (*Align Photos*), obtenção de nuvem densa (*Build Dense Cloud*), obtenção de modelo (*Build Mesh*) e construção do modelo (*Build Tiled Model*) buscou-se utilizar acurácia (*accuracy*), qualidade (*quality*) - que variou entre *ultra-high* e *medium* -, nuvem densa (*dense cloud*) e contagem de faces (*face count*).

Ao final de cada processamento, foram gerados relatórios para cada voo, no qual foi possível observar o tamanho do pixel, quantidade de sobreposição de imagens em cada parte do modelo, área total mageada e a altura do voo. Na Tabela 4 estão apresentadas as abreviações para os parâmetros adotados para os edifícios estudados, descritos no Apêndice B.

Tabela 4 - Abreviações adotadas para edificações estudadas.

CASO DE ESTUDO				
Quartel General do Exército	Instituto Central de Ciências	Biblioteca Central da UnB	Reitoria	Unidade da Criança e do Adolescente
QGE	ICC	BCE	R	UCA

Fonte: Elaborado pela autora.

Os relatórios dos processamentos foram gerados e exportados em formato PDF, contendo os parâmetros básicos do projeto, os resultados do processamento e a precisão. A opção de exportação está disponível somente para projetos georreferenciados. O relatório apresenta os seguintes dados:

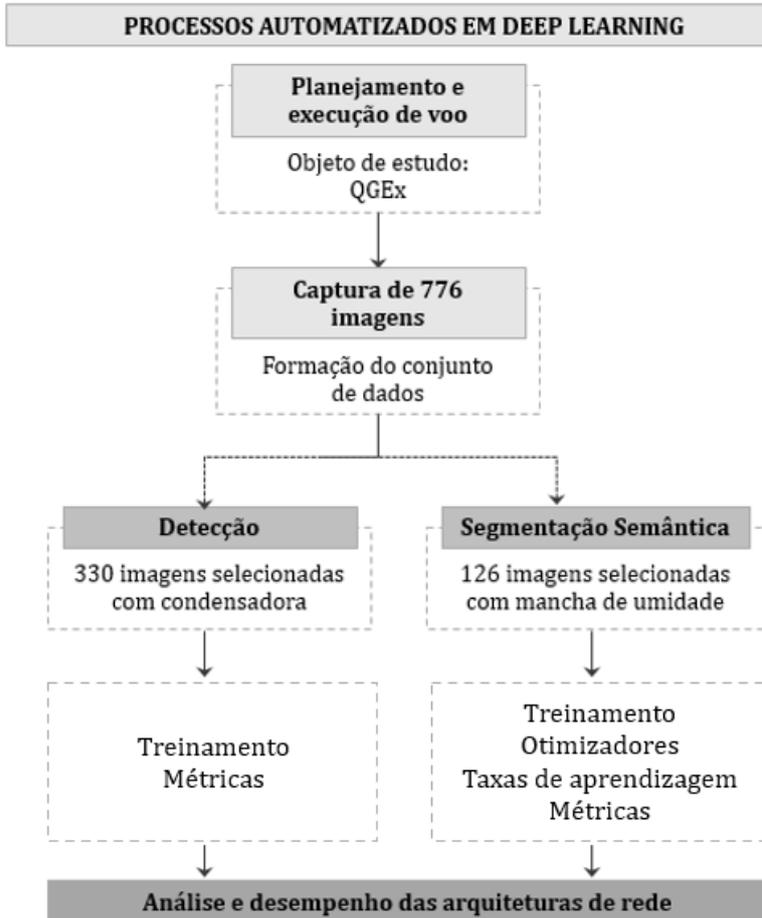
- Esboço da ortoimagem;
- Dados da pesquisa, incluindo área de cobertura, altitude de voo, GSD (*Ground Sample Distance*), informações gerais da(s) câmera(s), bem como estatísticas de sobreposição;
- Resultados da calibração da câmera: figuras e uma ilustração para cada sensor envolvido no projeto;
- Estimativas de erros de posicionamento e orientação da câmera;
- Estimativas de erro de controle de solo e pontos de verificação;
- Barras de escala, distâncias estimadas e erros de medição;
- Esboço do Modelo Digital de Elevação com informações de resolução e densidade de pontos; e,
- Parâmetros de processamento usados em cada etapa do projeto.

4.4 PROCESSOS AUTOMATIZADOS EM *DEEP LEARNING*

Esta etapa da pesquisa experimental, referente aos processos automatizados em *deep learning*, utilizou o banco de imagens gerados na etapa inicial do processamento digital, cujas imagens foram capturadas por drones no levantamento de campo realizado no conjunto de coberturas planas das edificações do QGEx.

A Figura 44 apresenta o fluxo metodológico adotado para a detecção de equipamentos e segmentação de manchas, utilizando modelos de redes neurais convolucionais e técnicas de visão computacional.

Figura 44 - Fluxo dos processos automatizados para detecção e segmentação semântica.



Fonte: Elaborado pela autora.

4.4.1 Detecção Automatizada de Equipamentos

Para a detecção de equipamentos, como as condensadoras de ar-condicionado em coberturas planas com sistemas de impermeabilização, foi utilizado um conjunto de nove edifícios situados no Quartel General do Exército Brasileiro (QGEx). As dimensões das coberturas variam em função da configuração de cada edificação, apresentando medidas entre 200,40 m x 12,50 m e 250,80 m x 14,90 m. Na Figura 45, observa-se a presença de diversos equipamentos instalados sobre as lajes impermeabilizadas do QGEx.

Figura 45 - Equipamentos dispostos em coberturas planas.



Fonte: A própria autora.

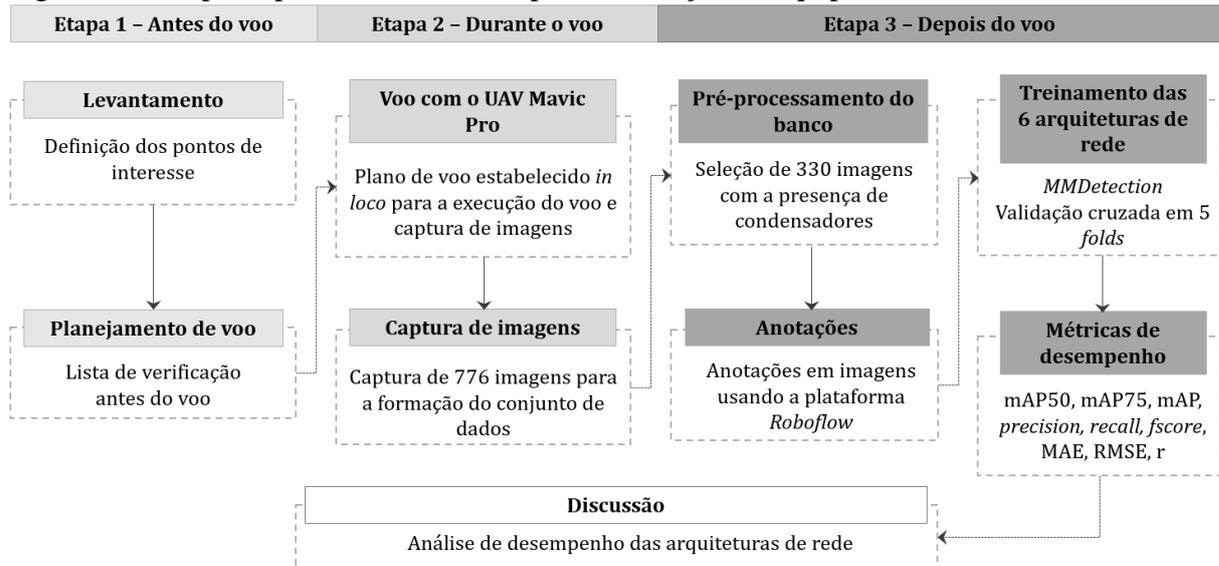
O conjunto de dados foi obtido por meio de imagens capturadas com o drone Mavic Pro, fabricado pela DJI (2023). As coletas ocorreram durante a execução de três planos de voo planejados no software DJI FLY (2023). As inspeções e aquisição de dados das condensadoras de ar-condicionado foram realizadas com base na navegação por waypoints, definidos a partir de coordenadas geográficas fornecidas pelo Sistema de Posicionamento Geográfico (GPS).

O processo teve início com a definição de três planos de voo, considerando as condições locais e as barreiras físicas das coberturas do QGEx, para determinar a altitude mais adequada. Em seguida, foram capturadas 776 imagens, que compuseram o conjunto de dados de entrada do processo. Durante a etapa de pré-processamento e construção do conjunto de dados, foi estabelecido um critério de seleção que resultou na escolha de 330 imagens, priorizando aquelas que apresentavam a presença de condensadoras. Essas imagens selecionadas apresentaram alta resolução e condições adequadas de luminosidade, atendendo aos requisitos para anotação na plataforma *Roboflow*.

Posteriormente, as imagens selecionadas foram anotadas na plataforma *Roboflow* (2022), e as anotações resultantes foram exportadas para o processamento automatizado de detecção de equipamentos. Neste experimento, foram treinadas seis arquiteturas de rede utilizando a caixa de ferramenta de detecção de objeto *MMDetection 2.12.0.*, com validação cruzada em cinco *folds*. Por fim, foram aplicadas nove métricas para avaliar o desempenho das arquiteturas de rede, com base nos resultados obtidos em análises estatísticas.

A Figura 46 ilustra o fluxo de trabalho adotado nos experimentos computacionais para detecção automatizada de equipamentos.

Figura 46 - Etapas e processos adotados para a detecção de equipamentos.



Fonte: Elaborado pela autora.

4.4.1.1 Pré-Pocessamento das Imagens e Construção do Conjunto de Dados Anotados

O experimento teve como objetivo principal identificar os equipamentos instalados diretamente sobre as lajes, sua localização e como isso poderia influenciar no processo de degradação da impermeabilização do sistema de cobertura.

As anotações do conjunto de dados foram realizadas na plataforma *Roboflow*, que hospeda diversos conjuntos de dados, incluindo o formato *COCO (Microsoft Common Objects in Context)*. Esse formato foi utilizado para rotular os equipamentos nas imagens (Figura 47 e Figura 48), permitindo a exportação dos dados e a conversão em modelos de visão computacional. Para realizar o treinamento dos modelos, foi utilizado a biblioteca *MMDetection* na versão 2.12.0.

Figura 47 - Caixa de seleção por Roboflow. Figura 48 - Anotação de condensadoras no Roboflow.



Fonte: A própria autora.



Fonte: A própria autora.

As 330 imagens anotadas na plataforma *Roboflow* compõem um conjunto de dados cujas características estão detalhadas na Tabela 5. A Figura 49 ilustra a distribuição da

contagem de equipamentos por imagem, evidenciando que a maioria das imagens contém entre 2 e 4 equipamentos. Adicionalmente, a Figura 50 apresenta uma distribuição espacial das anotações no banco de imagem que demonstra a distribuição espacial das posições das condensadoras identificados no banco de imagens.

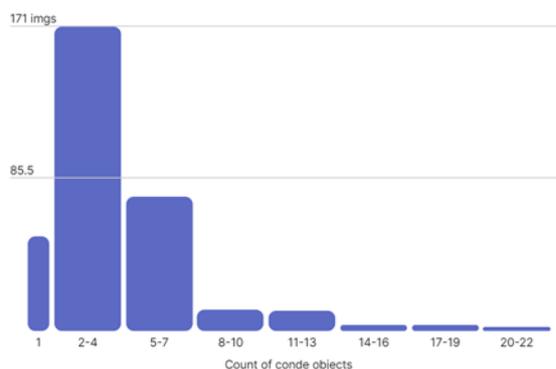
Nesse mapa, as anotações variaram entre 0 e 1372, considerando os pixels dentro de cada retângulo delimitador. As áreas representadas em tons de verde claro indicam os locais com maior frequência de ocorrência dos equipamentos, evidenciando padrões de instalação e possíveis concentrações em determinadas regiões das coberturas analisadas.

Tabela 5 - Descrição do conjunto de dados na plataforma *Roboflow: Class Balance* – Condensadora.

Imagens	Anotações	Tamanho Médio da imagem	Proporção Mediana da imagem
330	1.372	3.15 mp	2048 x 1680

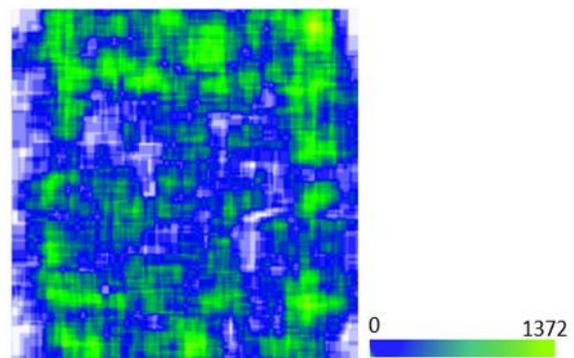
Fonte: Elaborado pela autora.

Figura 49 - Histograma de contagem de objetos por imagem.



Fonte: Roboflow (2024).

Figura 50 - Distribuição espacial das anotações no banco de imagem.



Fonte: Roboflow (2024).

4.4.1.2 Algoritmos de Detecção e Hiperparâmetros

O conjunto de dados composto por 330 imagens anotadas foi exportado da plataforma *Roboflow* para o *MMDetection* 2.12.0, uma estrutura que oferece um conjunto de ferramentas para métodos de detecção de objetos, com componentes e módulos relacionados a esses processos. Para iniciar a fase de treinamento, os pesos pré-treinados da COCO foram utilizados no conjunto de dados, proporcionando um ponto de partida para o treinamento das redes neurais.

O treinamento foi realizado em seis diferentes redes neurais convolucionas (profundas), sendo elas, *Faster R-CNN*, *Retina-Net*, *Atss*, *Vfnet*, *Sabl* e *Fovea*. Para avaliar e comparar o desempenho dessas redes, foi adotada a técnica de validação cruzada, a qual envolve a reorganização dos conjuntos de dados em diferentes partes (*folds*) para realizar treinamentos e

testes. No presente experimento, foram utilizados cinco *folders*, o que resultou na divisão do conjunto de imagens em cinco partes, sendo 60% para treinamento (198 imagens), 20% para validação (53 imagens) e 20% para teste (66 imagens).

Durante o treinamento, os seguintes hiperparâmetros foram configurados: *Epochs*; *Classifier Threshold*; *Intersection Over Union* (IoU) e *Learn Rate*. As redes neurais convolucionais (CNNs) foram treinadas por 15 épocas (*Epochs*) com uma taxa de aprendizado (*Learn Rate*) de 0,01. Foi considerado um valor de 0,5 para o *Classifier Threshold* e 50% para a *Intersection Over Union* (IoU).

4.4.1.3 Métricas de Desempenho

As seis arquiteturas de rede foram avaliadas quanto ao desempenho na detecção de equipamentos do tipo condensadora posicionadas em telhados planos. Para essa análise, foram utilizados *scripts* prontos processados pelo laboratório do grupo de pesquisa INOVISÃO da UCDB², capaz de processar as arquiteturas de rede em *deep learning* e gerar estatísticas detalhadas de desempenho. Nove métricas foram usadas para analisar o desempenho dos modelos de detecção de objetos. Para cada método testado, foram calculadas as métricas *Precision*, *Recall*, *F1-Score*, mAP (*Mean Average Precision*), mAP50, mAP75, MAE (*Mean Absolute Error*), RMSE (*Root Mean Square Error*) e o coeficiente de correlação *r*.

Para este experimento foi utilizado o código *detectors_json_k_folds*, desenvolvido e disponibilizado pelo grupo de pesquisa INOVISÃO.

4.4.2 Segmentação semântica automatizada para manchas em coberturas planas

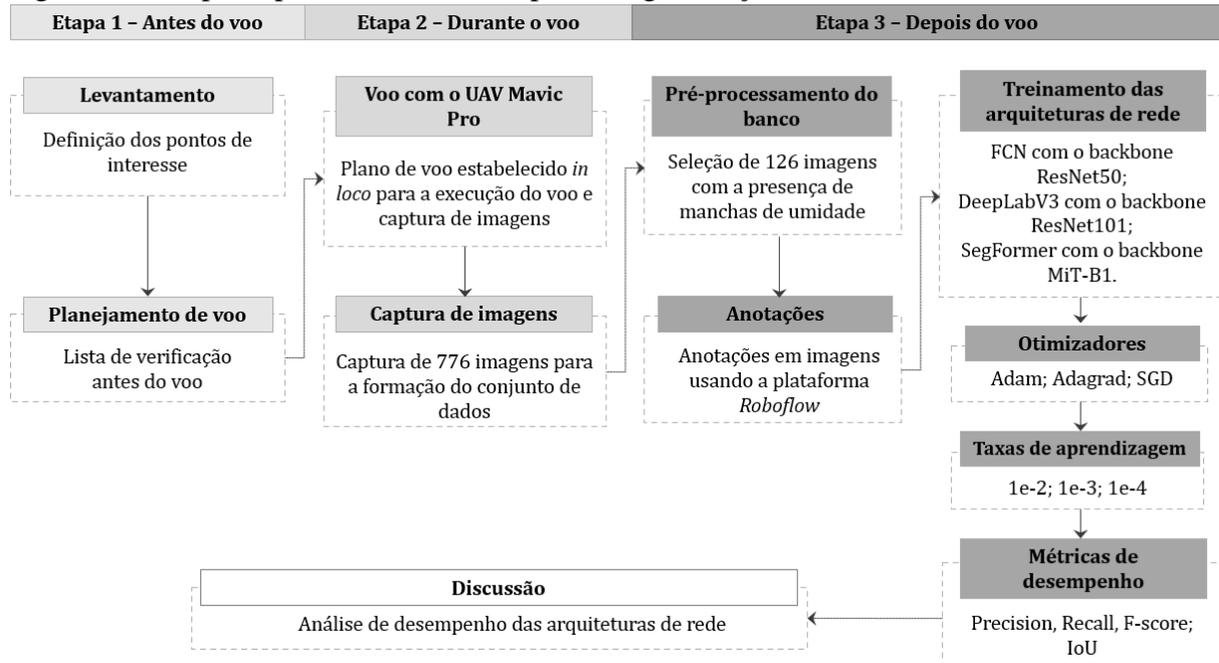
Para o experimento proposto, utilizou-se o mesmo conjunto de dados coletados nos nove edifícios localizados no Quartel General do Exército Brasileiro. O procedimento seguiu os mesmos parâmetros definidos nas Etapas 1 e 2, conforme descrito no item 4.4.1.

Os três planos de voo realizados resultaram na aquisição de 776 imagens adquiridas pelo UAV Mavic Pro. Desse total, 126 imagens foram selecionadas por conterem manchas claras e escuras resultantes de processos de molhagem e secagem e da deposição de detritos, conforme critérios de análise para anotação.

A Figura 51 ilustra o fluxo de trabalho adotado nos experimentos computacionais para segmentação semântica de manchas de umidade em processos automatizados.

² O Inovisão, laboratório de pesquisa em Visão Computacional, foi responsável pela condução dos experimentos em *deep learning*, por meio do desenvolvimento dos algoritmos, códigos e scripts necessários aos processamentos computacionais do banco de imagens e resultados das métricas. Ao Prof. Dr. Hemerson Pistori e seus orientandos, os nossos agradecimentos.

Figura 51 - Etapas e processos adotados para a segmentação semântica.



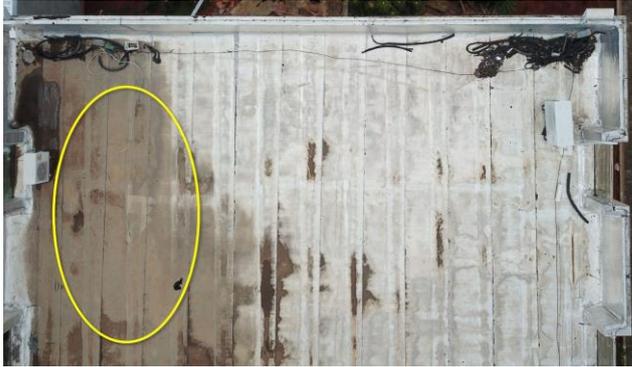
Fonte: Elaborado pela autora.

Após período de chuva, é comum ocorrerem empoçamentos de água que, ao secarem, deixam manchas claras de umidade. Esse fenômeno é consequência natural da exposição às intempéries e do desbotamento dos materiais de construção. A Figura 52 ilustra essas manchas claras, que não representam interesse para este estudo e, por isso, não foram anotadas nem consideradas como alvos para segmentação semântica.

Por outro lado, as manchas mais escuras revelam a presença contínua de umidade e água estagnada. Essas condições estão associadas à deposição de sujeira e à colonização biológica, fatores que aceleram a degradação da impermeabilização da cobertura e podem indicar infiltrações. A Figura 53 exemplifica uma mancha escura, caracterizada por maior intensidade de cor, indicativa de condições mais graves. Estas manchas foram os alvos principais da segmentação semântica proposta na pesquisa experimental.

As manchas escuras foram identificadas nas imagens por um especialista, utilizando procedimentos padrão adotados em inspeções realizadas *in loco* após períodos de chuva. Essa abordagem garante maior precisão na seleção e classificação dos alvos para o estudo.

Figura 52 - Manchas claras de umidade presentes na cobertura plana, após período de chuva.



Fonte: Elaborado pela autora.

Figura 53 - Região de referência para anotação das manchas escuras.



Fonte: Elaborado pela autora.

Após a captura de imagens e a definição da amostra de referência, as 126 imagens selecionadas foram anotadas para segmentação binária, considerando-se pixels de mancha e fundo. Inicialmente, as imagens coloridas foram convertidas para o espaço de cor HSV (*Hue*, *Saturation*, *Value*), em que H corresponde à matiz, S à saturação e V ao valor.

Para a etapa de anotação, foi utilizada a plataforma *Roboflow* (2024), a qual hospeda conjuntos de dados públicos, permitindo sua exportação em vários formatos, incluindo o formato COCO (*Microsoft Common Objects in Context*) utilizado para anotar as manchas. A técnica de anotação selecionada foi a *polygon tool* (Figura 54), que permite desenhar coleções de coordenadas, onde uma coleção de coordenadas é desenhada em torno de uma imagem, evitando a captura de informações de fundo. As anotações poligonais (Figura 55) permitem definições com menor incerteza do próprio objeto que está sendo rotulado, o que pode levar a um aumento no desempenho nos resultados do treinamento.

Figura 54 - Aplicação da *Polygon tool*.



Fonte: Elaborado pela autora.

Figura 55 - Anotação de manchamentos por ROBOFLOW.



Fonte: Elaborado pela autora.

A Tabela 6 apresenta as características das 126 imagens anotadas na plataforma *Roboflow* (2024). A Figura 56 mostra um gráfico das resoluções das imagens anotadas. A

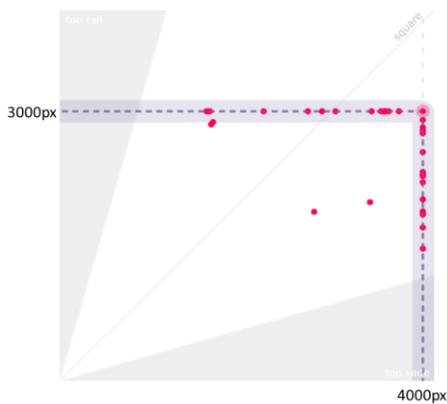
Figura 57 apresenta a distribuição das posições em que os manchamentos aparecem no banco de imagens, variando de 0 a 2501 anotações, considerando os pixels contidos em cada polígono.

Tabela 6 - Descrição do conjunto de dados na plataforma *Roboflow: Class Balance* –Mancha.

Imagens	Anotações	Tamanho médio da imagem	Proporção mediana da imagem
126	2501	4.76 MP	4000 x 3000

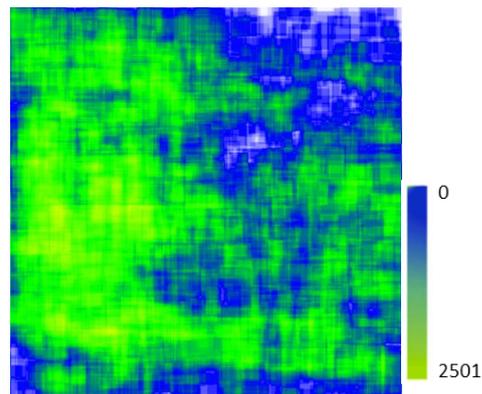
Fonte: Elaborado pela autora.

Figura 56 - Informação sobre as dimensões das imagens anotadas.



Fonte: Elaborado pela autora.

Figura 57 - Distribuição espacial das anotações no banco de imagem.



Fonte: Elaborado pela autora.

No experimento realizado, foram utilizados três modelos: duas redes neurais convolucionais, sendo elas a *DeepLabV3* (Chen *et al.*, 2017) com a ResNet101 como backbone e a FCN (Long; Shelhamer; Darrell, 2015) com a ResNet50 como *backbone*; e uma rede baseada em *transformers*, a SegFormer (Xie *et al.*, 2021) com *backbone* MiT-B1. Para otimização, foram testados os algoritmos Adam, Adagrad and SGD para cada uma das arquiteturas. Em cada caso, foram avaliadas as taxas de aprendizagem 1e-2, 1e-3 e 1e-4, totalizando nove diferentes estratégias de otimização para cada arquitetura de rede neural.

Os modelos foram avaliados usando uma abordagem de validação cruzada em 10 *folds*. Das 126 imagens disponíveis, 70% foram alocadas para o conjunto de treinamento, 20% para validação e 10% para teste em cada dobra. Todas as imagens foram redimensionadas para 512 por 512 pixels e submetidas às seguintes técnicas de aumento de dados durante o treinamento: *horizontal flip*, com probabilidade de 50%; *random brightness contrast*, ajustando aleatoriamente o brilho e o contraste, ambos com um fator de até 20%, positivo ou negativo; *random sun flare*, simulando raios solares com uma probabilidade de ocorrerem de 20%; *random fog*, adicionando uma névoa sutil com uma intensidade de 20%; e *Rotate*, aplicando aleatoriamente rotações de -25 a 25. Este último foi implementado para permitir que a rede detectasse objetos de interesse em diferentes orientações.

O tamanho do lote (batch) foi definido em 6, e a função de perda utilizada foi a entropia cruzada. O treinamento foi limitado a um máximo de 1000 épocas, com uma estratégia de parada antecipada implementada após 50 épocas consecutivas sem redução na perda observada durante a validação.

O desempenho dos modelos foi então avaliado usando quatro métricas: *Precision*, *Recall*, F-score e Intersecção sobre União (IoU), com suas definições no Apêndice C (Tabelas 36, 37 e 38). Para uma dada imagem i , o número de verdadeiros positivos (TP), o número de falsos positivos (FP), o número de verdadeiros negativos (TN) e o número de falsos negativos (FN) foram calculados. Máscara é a máscara anotada manualmente, e Predição é a predição dada pela rede neural. Finalmente, a pontuação final no conjunto de teste para cada *fold* foi dada como uma média em todas as imagens. Para uma dada imagem i , P_i , R_i , $F1_i$ e IoU_i foram considerados, conforme mostrado no Quadro 17 e Equações 1, 3, 5 e 7. Para uma determinada classe (neste caso, coloração), as métricas foram definidas como P, R, F e IoU, onde N é o número de imagens de teste, conforme mostrado nas Equações 2, 4, 6 e 8.

Quadro 17 - Métricas para imagem i e Classe Mancha.

	Metrics for image i		Metrics for class (stain)
<i>Precision</i>	$P_i = \frac{TP_i}{TP_i + FP_i} \quad (1)$		$P = \left(\frac{1}{N}\right) \sum_{i=1}^N P_i \quad (2)$
<i>Recall</i>	$R_i = \frac{TP_i}{TP_i + FN_i} \quad (3)$		$R = \left(\frac{1}{N}\right) \sum_{i=1}^N R_i \quad (4)$
F-score (specifically F1-score)	$F1_i = 2 \cdot \frac{P_i \cdot R_i}{P_i + R_i} \quad (5)$		$F1 = \left(\frac{1}{N}\right) \sum_{i=1}^N F1_i \quad (6)$
<i>Intersection over Union (IoU)</i>	$IoU_i = \frac{Mask_i \cap Prediction_i}{Mask_i \cup Prediction_i} \quad (7)$		$IoU = \left(\frac{1}{N}\right) \sum_{i=1}^N IoU_i \quad (8)$

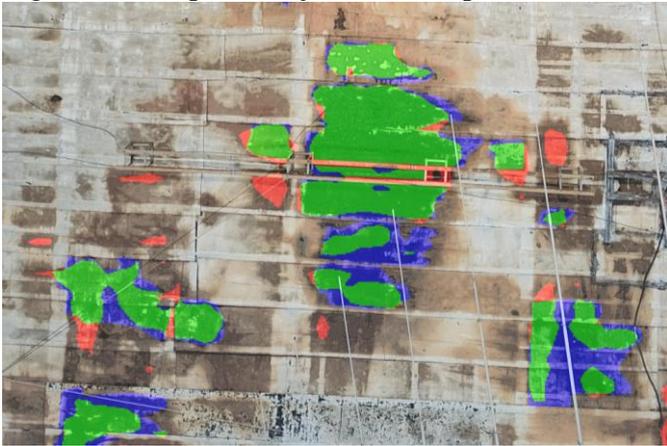
Fonte: Adaptado pela autora, baseado nos dados processados no laboratório INOVISÃO.

Para a seção de discussão dos resultados, as métricas de desempenho utilizadas foram *Precision* (P) e *Recall* (R). *Precision* (P), pois representam a fração de verdadeiros positivos (TP) em relação ao total de resultados relevantes. Já a métrica de *Recall* (R) mede a capacidade de um classificador em identificar todos os rótulos relevantes em um conjunto de dados.

A Figura 58 apresenta uma amostra ilustrativa das cores usadas pelos modelos para representar a segmentação de manchas a nível de pixel: verde para verdadeiros positivos (TP), vermelho para falsos positivos (FP) e azul para falsos negativos (FN). Cada pixel na imagem

segmentada é comparado com a máscara de referência. Se um pixel é classificado corretamente como parte de uma mancha, ele contribui para o valor de TP. Se é erroneamente classificado como parte de uma mancha, contribui para FP. Pixels na máscara de referência que não são detectados na segmentação contribuem para FN.

Figura 58 - Representação de cores para TP = verde, FP = vermelho e FN = azul.



Fonte: Elaborado pela autora.

Com os resultados das métricas estatísticas de desempenho, foram gerados *Boxplots* para as análises, interpretação e discussão dos resultados. Por fim, quando pertinente para a discussão, as métricas Precisão (*Precision-P*) e Revocação (*Recall-R*) foram calculadas pontualmente para determinadas imagens de interesse para a análise.

5 RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados obtidos no presente estudo, englobando:

- Análise dos processos de inspeção e aquisição de imagens com o uso de drones para a formação de um banco de imagens de coberturas planas;
- Análise dos processamentos digitais e das ortoimagens geradas a partir das imagens adquiridas, com avaliação da qualidade dos resultados obtidos;
- Análise do processamento digital de coberturas planas com diferentes níveis;
- Análise do processamento digital de coberturas planas lineares;
- Processos automatizados em *deep learning* para detecção de equipamentos em cobertura plana;
- Processos automatizados em *deep learning* para segmentação semântica de manchas em coberturas plana; e,
- Cenários para aplicação de tecnologias digitais em processos automatizados.

5.1 ANÁLISES DOS PROCESSOS DE INSPEÇÃO E AQUISIÇÃO DAS IMAGENS

As inspeções realizadas com o uso de drones para aquisição de imagens e processamento de ortoimagens abrangeram os edifícios: QGEx, BCE, ICC, Reitoria e UCA. As operações de voo adotaram diferentes configurações, definidas com base nos parâmetros e critérios estabelecidos no protocolo proposto e nas instruções descritas na seção de método de pesquisa para sistema de cobertura plana.

Um aspecto relevante foi a definição da altitude e das distâncias entre as linhas de captura fotogramétrica, garantindo a sobreposição necessária das imagens em cada plano de voo. Para assegurar a precisão na captação, a câmera foi posicionada perpendicular ao plano da cobertura, caracterizado por lajes horizontais, o que foi viabilizado pela operação programada do drone.

De acordo com o software Agisoft (2024), em levantamentos aéreos, recomenda-se uma sobreposição longitudinal de 60% e transversal de 80% para áreas vegetadas. Entretanto, para os voos realizados sobre os sistemas de cobertura plana em análise, foram adotados valores de sobreposição superiores aos recomendados, visando alcançar maior detalhamento das imagens capturadas.

A Tabela 7 resume os planos de voos realizados em cada sistema de cobertura dos edifícios da amostra, considerando a área, o tempo, a altitude e a quantidade de imagens que foram capturadas.

Tabela 7 - Informações sobre os voos realizados em cada sistema de cobertura dos edifícios estudados.

Cobertura	Amostra	Área (m ²)	Tempo	Altitude (m)	GSD (cm/pix)	Nº imagens capturadas
QGEx (1)	A1.1	2 hectares	0:23:04	22	1,0	495
	A1.2	2 hectares	0:26:01	22	1,0	472
	A1.3	5 hectares	0:22:09	35	1,0	338
ICC (2)	A1.1	6.640 m ²	0:28:51	14	1,0	468
	A2.2	9.750 m ²	0:29:47	14	1,0	536
	A2.3	1 hectare	0:34:59	14	1,0	532
	A2.4	1 hectare	0:38:10	14	1,0	567
	A2.5	1 hectare	0:42:26	14	1,0	703
	A2.6	1 hectare	0:59:58	14	1,0	991
	A2.7	1 hectare	0:36:23	14	1,0	568
	A2.8	1 hectare	1:31:43	14	1,0	1496
	A2.9	11 hectares	1:07:11	50	1,1	1157
BCE (3)	A3.1 – 1D	7.576 m ²	0:20:41	23	0,43	477
	A3.2 – 1D	11.296 m ²	0:08:49	45	0,85	137
	A3.3 – 5D	9.231m ²	0:15:25	45	0,85	493
Reitoria (4)	A4.1	1 hectare	0:47:44	20	1,0	651
UCA (5)	A5.1	4.681 m ²	0:41:05	20	1,0	549
	A5.2	1 hectare	0:28:39	32	1,0	238
	A5.3	1 hectare	0:18:35	50	1,1	98
Total		33 hectares 9.174 m ² (8,3 m ² /s)	11:21:40	-	-	10.966

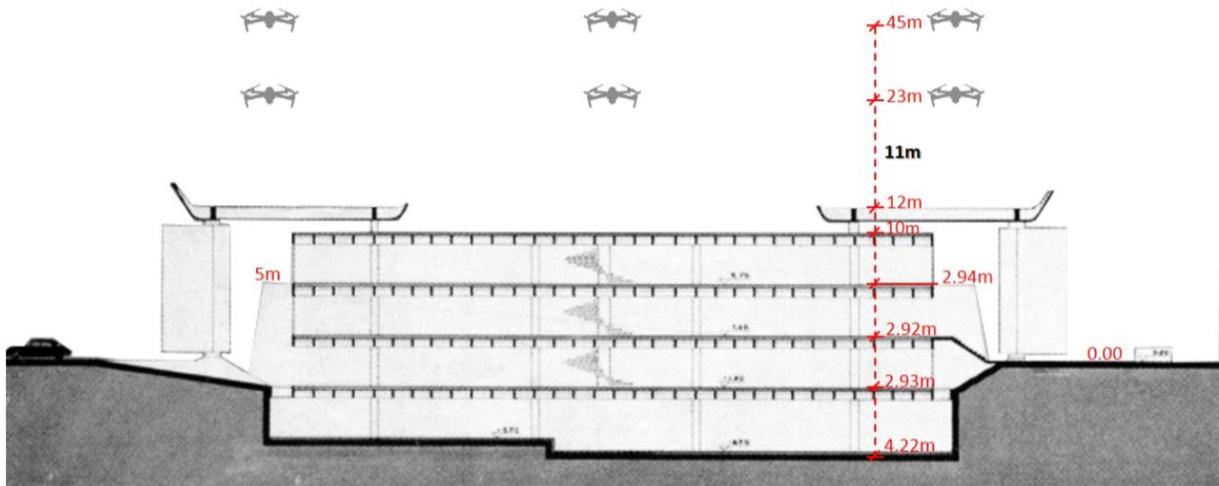
Fonte: Elaborado pela autora.

A seguir, são apresentados detalhadamente os resultados das inspeções e aquisições de imagens de cada um dos edifícios da amostra.

5.1.1 Inspeção e Aquisição das Imagens na BCE

Para a realização dos dois planos de voo na BCE UnB, foi considerada a altitude de 45 metros acima do plano de cobertura, ilustrado pelo corte longitudinal na Figura 59. O experimento foi realizado no mês de maio e, para isso, tornou-se necessário o levantamento das condições meteorológicas, que apresentaram uma temperatura máxima de 28°C com céu limpo e uma velocidade máxima do vento de 14,8 m/s. A adoção da altitude de 45 m deveu-se a existência de uma árvore presente no local com altura aproximada de 35 m, impedindo que os voos fossem realizados com uma altura inferior.

Figura 59 - Corte longitudinal BCE – UnB.



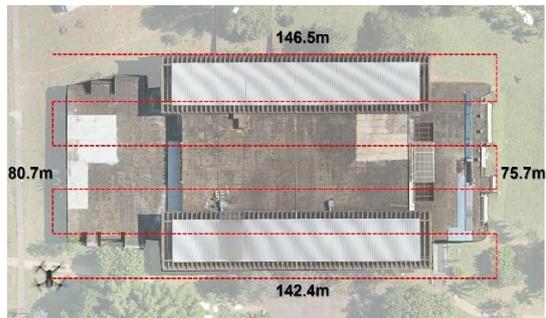
Fonte: Adaptado de Revista Acrópole, ano 31, número 369.

Os parâmetros apresentados na Tabela 7 foram definidos após a realização de testes em campo. Devido às diferentes volumetrias, níveis e sistemas de cobertura da edificação, foi necessário realizar uma simulação inicial do voo no local (pré-teste). A escolha do modelo de drone DJI Mavic 2 Pro baseou-se na sua capacidade de operar com segurança nas proximidades do sistema de cobertura. As imagens capturadas possuem resolução de 5472 x 3648 pixels (20MP).

Outro fator essencial na escolha do modelo de drone foi a duração da bateria. A autonomia da bateria do DJI Mavic 2 Pro, de até 31 minutos em condições sem vento, foi um critério significativo na decisão. Foi definido pontos específicos para decolagem e pouso no voo automático, bem como a quantidade de linhas de voo necessárias para a coleta de dados. O planejamento dos voos foi realizado com o software DJI PILOT, que permitiu ajustes de altitude e distância em relação às margens da edificação.

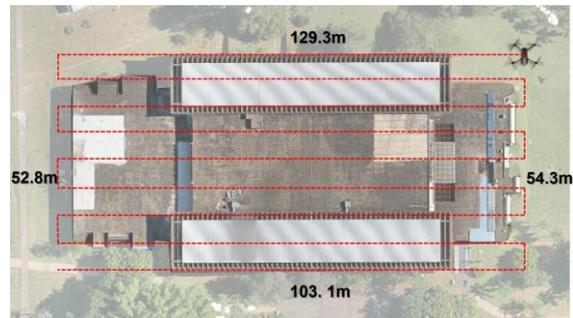
Foram realizados dois voos, ilustrados nas Figuras 60, 61 e 62, ambos a uma altitude de 45 metros acima do solo, no modo automático. O plano de voo foi orientado com o ângulo da câmera ajustado a 90° (perpendicular ao plano de cobertura). O primeiro voo incluiu 6 linhas de voo para a captura de dados, enquanto o segundo consistiu em um voo cruzado com 5 direções.

Figura 60 - Plano horizontal do voo adotado em uma direção e linhas de voo modo automático.



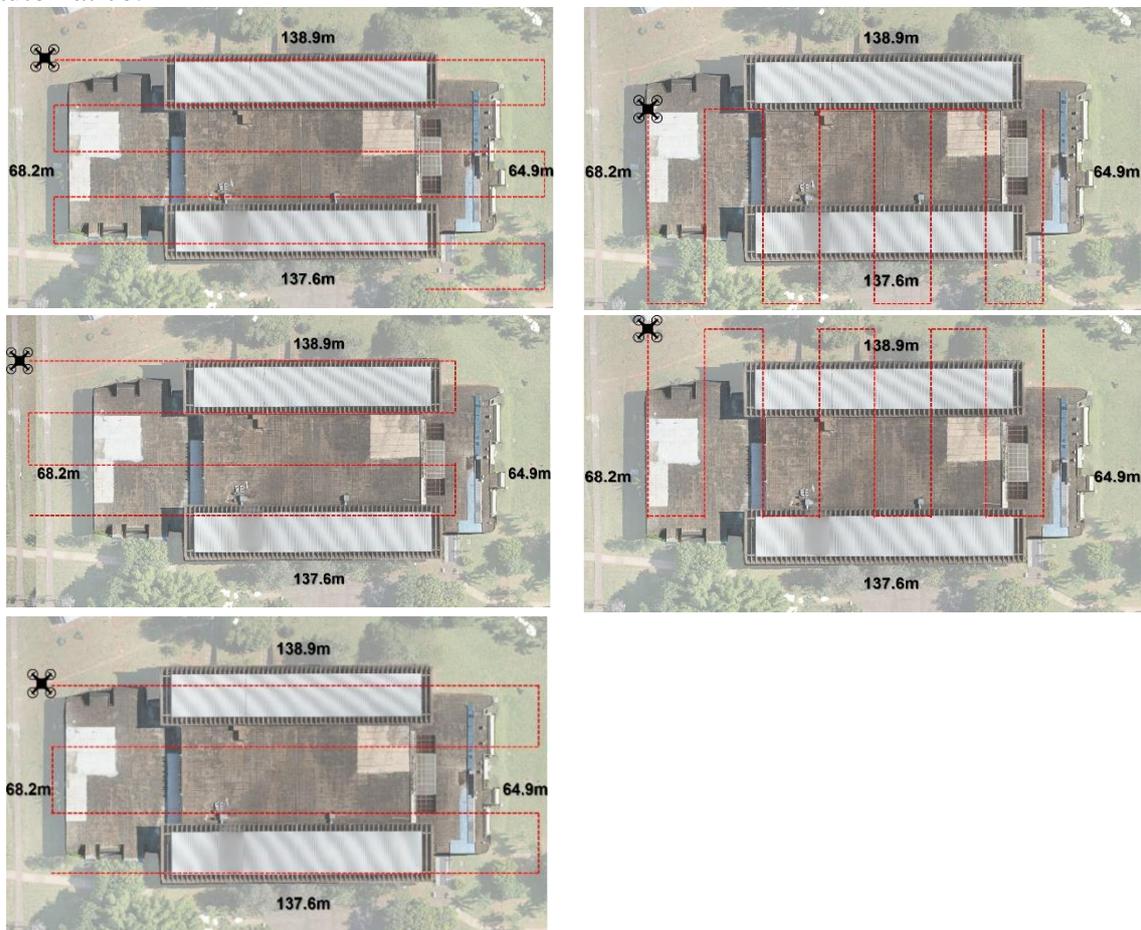
Fonte: Elaborado pela autora.

Figura 61 - Plano horizontal do voo adotado em uma direção e linhas de voo modo automático.



Fonte: Elaborado pela autora.

Figura 62 - Plano horizontal do voo cruzado adotado em cinco direções e linhas de voo modo automático.



Fonte: Elaborado pela autora.

Os parâmetros descritos na Tabela 8 foram adotados para a realização de três voos, todos com planos de voo horizontal no modo automático. Apenas o voo em cinco direções, também no modo automático, apresentou variações nos parâmetros estabelecidos para sobreposição longitudinal e transversal.

Tabela 8 – Dados da aquisição de imagens realizado com o drone na BCE.

Caso de estudo	Biblioteca Central		
	<i>Voo 1</i>	<i>Voo 2</i>	<i>Voo 3</i>
Voo			
Data	07/05/2021		
Altitude de voo	45 metros	45 metros	23 metros
Área	11.296 m ²	9.231 m ²	7.576 m ²
Tipo de voo	1 direção (Automático)	5 direções (Automático)	1 direção (Automático)
Nº fotos coletadas	137	493	477
Nº de voos	1	5	1
Drone	Mavic 2 Pro	Mavic 2 Pro	Mavic 2 Pro
Duração total do voo	8min 49s	15min 25s	20min 41s
Sobreposição transversal (%)	80%	70%	80%
Sobreposição longitudinal (%)	70%	60%	70%
Direção do voo	56°	54°	236°
Total de fotos coletadas	1107 imagens		
Duração total de todos os voos	44min 55s		

Fonte: Elaborado pela autora.

As imagens capturadas possuem resolução de 5472 x 3648 pixels (20 MP), conforme a configuração do equipamento. A capacidade do drone de se aproximar do sistema de cobertura permite capturar imagens de qualidade suficiente para identificar as manifestações patológicas e avaliar as condições de conservação. No entanto, essa aproximação pode ser limitada por fatores como a altitude selecionada ou a presença de obstáculos, o que pode dificultar a medição precisa de fissuras na cobertura.

5.1.2 Inspeção e Aquisição das Imagens no QGEx

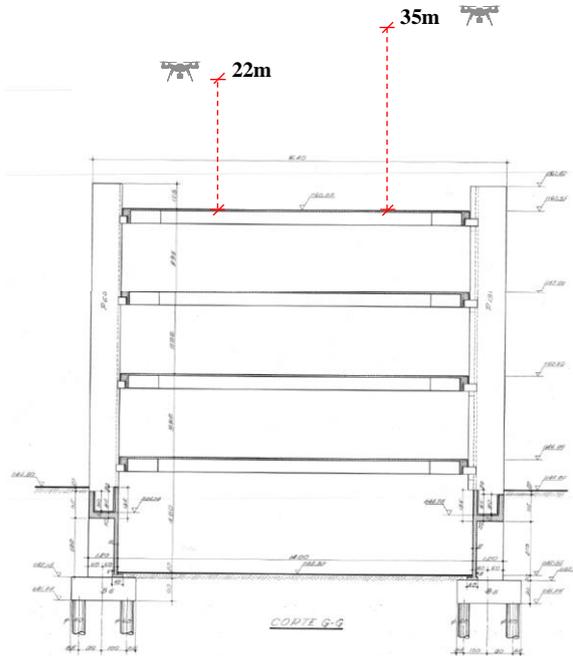
O plano de voo para aquisição de imagens capturadas pelo drone no Quartel-General do Exército Brasileiro (QGEx) foi realizado em um conjunto de 9 edifícios, conforme ilustrado na Figura 64. As imagens foram capturadas com o drone Mavic Pro, fabricado pela DJI (2023). As coberturas dos edifícios possuem dimensões que variam de 200,40 m x 12,50 m a 250,80 m x 14,90 m e possuem altura uniforme de 10,60 m, enquanto as caixas de escadas alcançam 15,80 m. Apenas um edifício se distingue dos demais, com altura de 8,45 m e uma antena de transmissão de aproximadamente 15 m de altura.

Foi estabelecido um protocolo para a execução de três planos de voo. Considerou-se a distância do drone em relação às coberturas para alcançar o nível desejado de precisão e detalhamento na aquisição das imagens. Para evitar colisões com a antena e com as torres de escadas, dois dos planos de voo apresentaram altitudes distintas, devido à presença desses obstáculos na área mapeada.

Os planos de voo foram realizados em dias distintos. O primeiro e o segundo voos ocorreram em 8 de dezembro de 2021, às 10:00 h, em um dia ensolarado, com temperatura de 19,7°C e velocidade do vento de 0,5 m/s. O terceiro voo foi realizado em 7 de março de 2022,

às 14:00 h, também em um dia ensolarado, com temperatura de 24,4°C e velocidade do vento de 3,6 m/s. A Figura 63 ilustra a altura considerada para os três planos de voo.

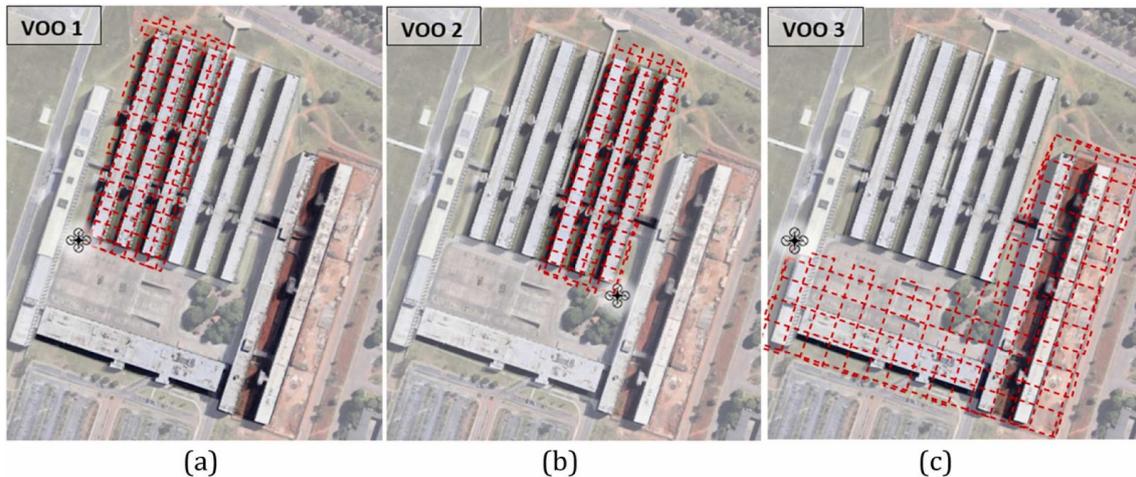
Figura 63 – Corte representativo das edificações do QGEx.



Fonte: Adaptado de Campos, 2020.

Os três voos realizados (Figura 64) para a captura de imagens das coberturas foram do tipo cruzado, abrangendo duas direções, com uma taxa de sobreposição transversal e longitudinal de 60%, conforme definido pelo operador responsável, devidamente titulado para a operação. Para assegurar a uniformidade das imagens, evitou-se variações nas posições e configurações do equipamento. Durante os voos, foi necessária a substituição das baterias, cuja autonomia era de 27 minutos.

Figura 64 – Planos de voo para aquisição de imagens capturadas pelo drone.



Fonte: Elaborado pela autora.

A Tabela 9 apresenta as informações sobre os voos executados, as condições climáticas no momento do voo e a quantidade de imagens adquiridas em cada operação.

Tabela 9 – Dados da aquisição de imagens realizada com o drone no QGEx.

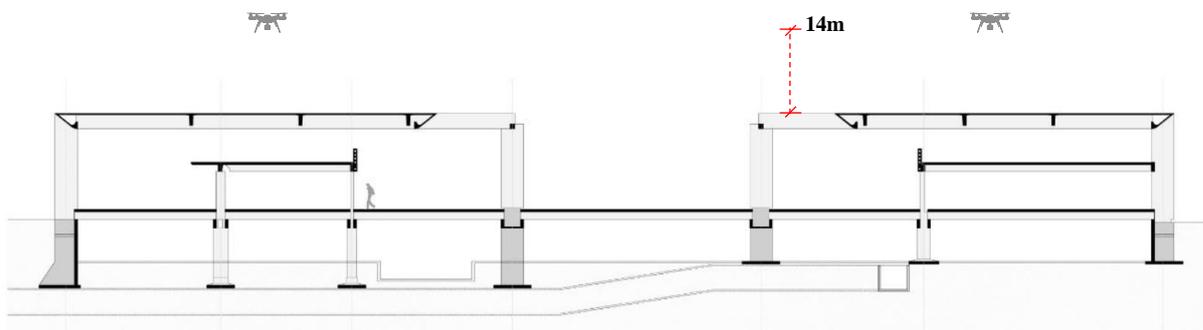
Caso de estudo	QGEx		
Voo	Voo 1	Voo 2	Voo 3
Data	08/12/2021	08/12/2021	07/03/2022
Altitude de voo	22 metros	22 metros	35 metros
Área (hectare)	2 hectares	2 hectares	5 hectares
Tipo de voo	2 direções (Automático)	2 direções (Automático)	2 direções (Automático)
Nº fotos coletadas	495	428	338
Nº de voos	1	1	1
Drone	Mavic Pro	Mavic Pro	Mavic Pro
Duração total do voo	23min 04s	26min 01s	22min 09s
Sobreposição transversal (%)	60%	60%	60%
Sobreposição longitudinal (%)	60%	60%	60%
Direção do voo	-71°	-71°	18°
Total de fotos coletadas	766 imagens		
Duração total de todos os voos	48min 10s		

Fonte: Elaborado pela autora.

5.1.3 Inspeção e Aquisição das Imagens do ICC UnB

Os voos realizados nas coberturas dos Blocos A e B do ICC foram segmentados em função do tempo de duração e da quantidade limitada de baterias disponíveis, no momento da execução dos planos de voo. As operações tiveram início no Bloco B, devido à presença de uma antena no sistema de cobertura, que determinou a altitude requerida para a realização dos voos, conforme ilustrado na Figura 65.

Figura 65 – Corte longitudinal.

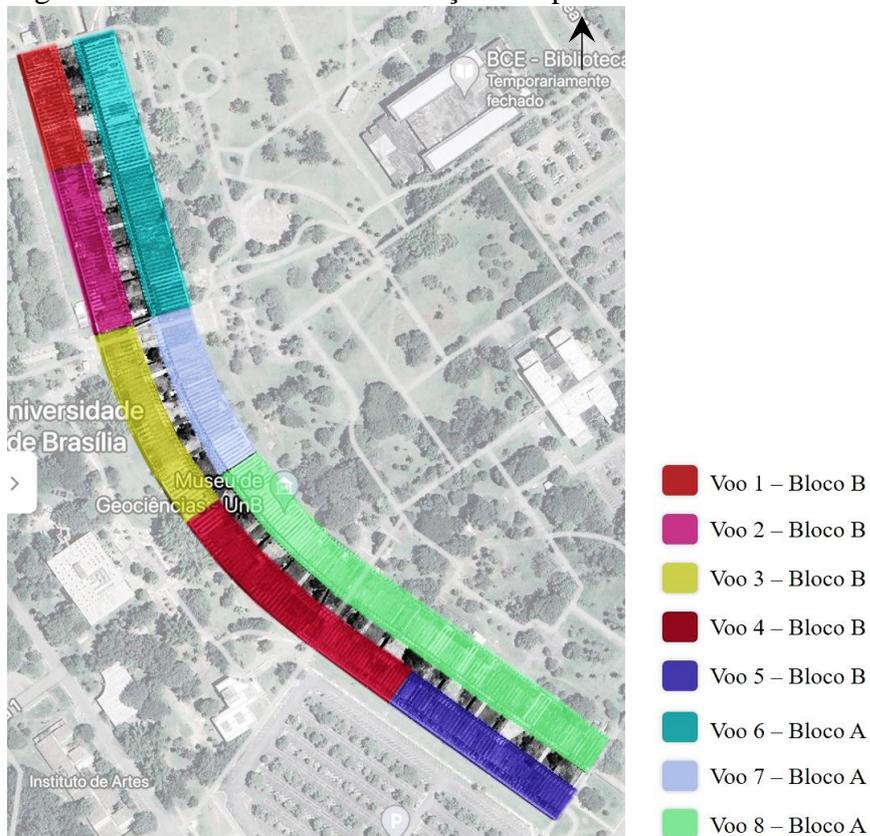


Fonte: Adaptado de Silva; Vasconcellos e Sánchez (2019).

A Figura 66 apresenta o zoneamento dos planos de voo realizados. No Bloco A, foi possível realizar voos de maior duração devido à disponibilidade adicional de baterias, o que permitiu um tempo de operação mais longo e uma maior capacidade de aquisição de imagens. Todos os voos ocorreram às 10:00 h, após a verificação das condições climáticas, incluindo

condições de céu e velocidade do vento. Apenas um voo precisou ser reprogramado devido às condições adversas.

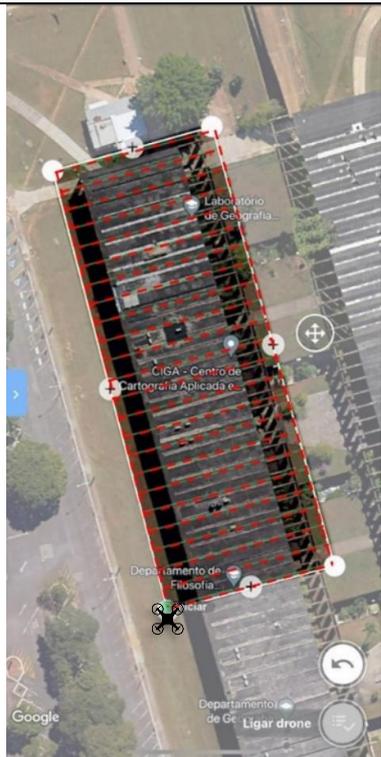
Figura 66 – Zoneamento da execução dos planos de voo no ICC.



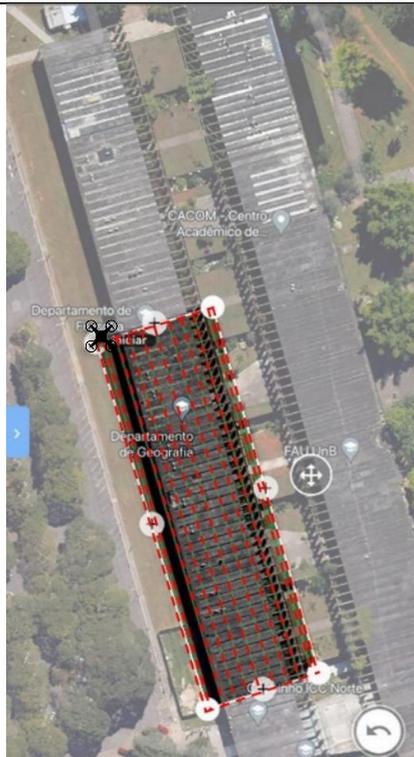
Fonte: Elaborado pela autora.

A Tabela 10 ilustra os oito planos de voo realizados para a aquisição das imagens. Apenas um dos voos (imagem d) foi conduzido como teste, com o objetivo de definir a orientação das linhas de voo e verificar o seu impacto no processamento. A questão a ser investigada era se a direção das linhas de voo, em relação à configuração curva do plano de cobertura, influenciaria o processamento e a geração da ortoimagem. Todos os voos foram executados em uma direção, seguindo a curvatura do edifício.

Tabela 10 – Planos de voo para aquisição de imagens capturadas pelo drone no ICC.



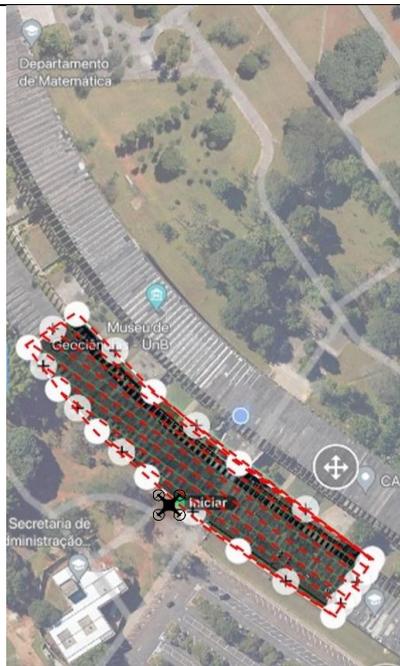
(a) Voo 1 – Bloco B



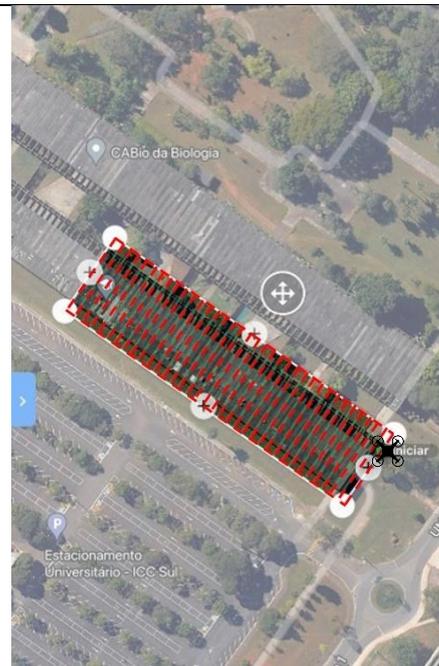
(b) Voo 2 – Bloco B



(c) Voo 3 – Bloco B



(d) Voo 4 – Bloco B



(e) Voo 5 – Bloco B

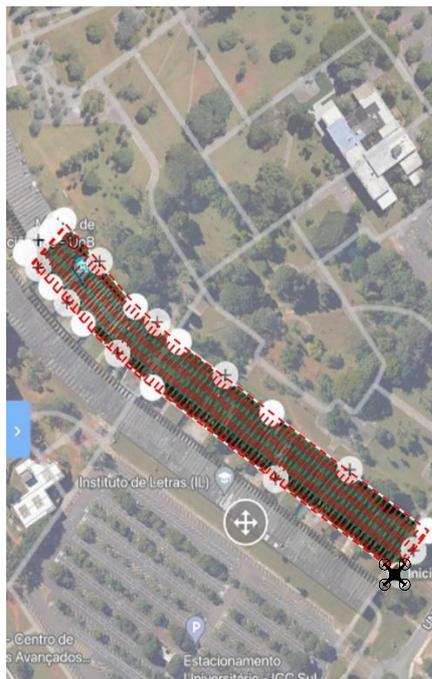


(f) Voo 6 – Bloco A

Continuação



(g) Voo 7 – Bloco A



(h) Voo 8 – Bloco A



(i) Voo 9 – Bloco A

Fonte: Elaborado pela autora.

A Tabela 11 apresenta os parâmetros estabelecidos para o planejamento e execução dos voos, considerando o objetivo da missão, o equipamento utilizado, os valores de sobreposição e os resultados esperados. O Voo 9 foi realizado com o propósito de embasar melhor a discussão dos resultados, no item que trata da análise da resolução e do processamento à nível urbano.

Tabela 11 - Dados da aquisição de imagens realizado com o drone no ICC Norte e Sul.

Voo	Data da inspeção	Nº fotos coletadas	Nº de voos	Drone	Duração total do voo	Altitude	Tipo de Voo	Área coberta	Sobreposição Transversal (%)	Sobreposição Longitudinal (%)	Direção do voo ¹
1 ¹	12/07/23	468	1	Mavic Air 2S	0:28:51	14 m	Automático	1 hectare	80%	75%	-15°
2	16/06/23	536	1		0:29:47	14 m	Automático	3.617,30 m ²	80%	75%	76°
3	23/06/12	532	1		0:34:59	14 m	Automático	1 hectare	80%	75%	-24 °
4	30/06/23	567	1		0:38:10	14 m	Automático	1 hectare	80%	75%	-144 °
5	12/07/23	703	1		0:42:26	14 m	Automático	1 hectare	80%	75%	-56°
6	28/07/23	991	1		0:59:58	14 m	Automático	1 hectare	80%	75%	-16°
7	28/08/23	568	1		0:36:23	14 m	Automático	1 hectare	80%	75%	-24°
8	04/08/23	1496	1		0:91:43	14 m	Automático	1 hectare	80%	75%	-49°
9	09/08/23	1157	1		0:67:11	50 m	Automático	1 hectare	80%	75%	-39°
Total		7.018	9	-	7:9:28	-	-	83.617,30m²	-	-	-
3,25 m²/s											

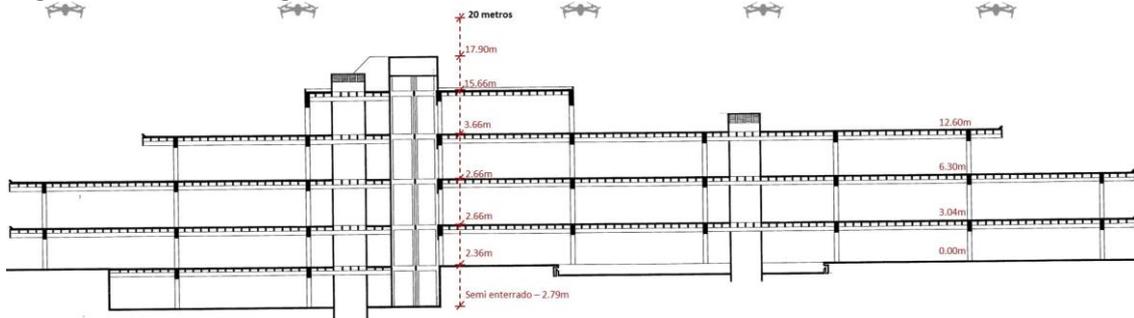
Fonte: Elaborado pela autora.

¹ Ângulo do Gimbal.

5.1.4 Inspeção e Aquisição das Imagens na Reitoria da UnB

Como mostrado na Figura 67, o plano de voo realizado na Reitoria da UnB considerou uma altitude de 20 metros para a execução do voo cruzado (em duas direções). As principais dificuldades encontradas durante o voo foram a presença significativa de vegetação ao redor da edificação, o que limitou a aproximação do drone ao sistema de cobertura.

Figura 67 - Corte longitudinal Reitoria-UnB.



Fonte: Adaptado do Centro de Planejamento Oscar Niemeyer (CEPLAN).

Optou-se pelo voo cruzado devido à complexidade do sistema de cobertura, caracterizado por diferentes níveis, com o objetivo de capturar um maior número de imagens tanto das lajes quanto de suas bordas. Essa estratégia viabilizou o processamento e a construção da ortoimagem. A Figura 68 ilustra as linhas do voo realizado em duas direções, além de mostrar as copas das árvores próximas à cobertura, que atuam como barreiras à inspeção e visualização de alguns trechos das lajes e das calhas de drenagem das águas pluviais presentes no local.

Figura 68 - Plano horizontal do voo adotado em duas direções e linhas de voo modo automático.



Fonte: Elaborado pela autora.

A Tabela 12 apresenta os dados empregados para a execução do plano de voo e a aquisição de imagens.

Tabela 12 - Dados da aquisição de imagens realizada com o drone na Reitoria.

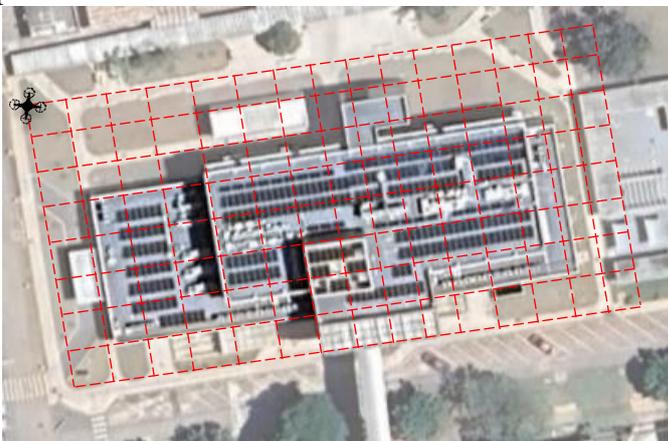
Caso de estudo	Reitoria
Voo	Voo A
Data	07/07/2023
Altitude de voo	20 metros
Área (hectare)	01 hectare
Tipo de voo	2 direções (Automático)
Nº fotos coletadas	651
Nº de voos	1
Drone	Mavic DJI Air 2s
Duração total do voo	47min 44s
Resolução	1,0 cm/pix
Baterias	03
Sobreposição Transversal (%)	80%
Sobreposição Longitudinal (%)	75%
Ângulo	90°
Direção de voo	55°

Fonte: Elaborado pela autora.

5.1.5 Inspeção e Aquisição das Imagens na UCA – HUB na UnB

O edifício da UCA foi recentemente inaugurado em junho de 2023. Trata-se de um sistema de cobertura com grande quantidade de equipamentos, característico de edificações voltadas para a saúde. Este edifício não possui vegetação próxima ao sistema de cobertura, o que possibilitou a realização de três planos de voo, em diferentes altitudes. O edifício possui diferentes níveis de cobertura, o que determinou a altura do voo de 18,40 m acima da cobertura mais alta. A Figura 69 apresenta o plano de voo adotado para a coleta de imagens.

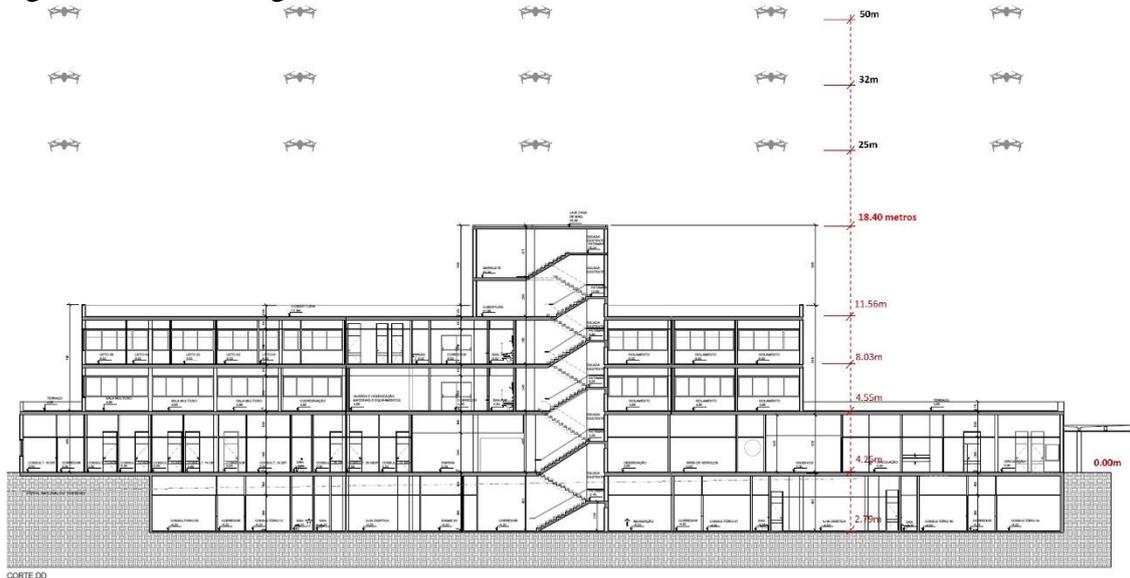
Figura 69 - Plano horizontal do voo adotado em duas direções e linhas de voo modo automático para os três voos realizados.



Fonte: Elaborado pela autora.

A Figura 70 apresenta um corte longitudinal, evidenciando os diferentes níveis da edificação e as altitudes adotadas para a execução dos planos de voo, que foram de 25 m, 32 m e 50 m.

Figura 70 - Corte longitudinal UCA-UnB.



Fonte: Adaptado da Empresa Brasileira de Serviços Hospitalares (EBSERH).

A Tabela 13 detalha os três planos de voo adotados, realizados no mesmo dia, incluindo a quantidade de imagens capturadas em cada um. Todos os voos foram realizados em duas direções.

Tabela 13 - Dados da aquisição de imagens realizada com o drone na UCA.

Caso de estudo		Hospital Universitário de Brasília – UCA		
Voo		Voo 1	Voo 2	Voo 3
Data		22/10/2023		
Altitude de voo		20 metros	32 metros	50 metros
Área (hectare)		4.681 m ²	1 hectare	1 hectare
Tipo de voo		2 direções (Automático)	2 direções (Automático)	2 direções (Automático)
Nº fotos coletadas		549	238	98
Nº de voos		1	1	1
Drone		Mavic DJI Air 2s	Mavic DJI Air 2s	Mavic DJI Air 2s
Duração total do voo		41min 05s	28min 39s	18min 35s
Resolução		1,0 cm/px	1,0 cm/px	1,1 cm/px
Baterias		3	2	2
Sobreposição transversal (%)		80%	80%	80%
Sobreposição longitudinal (%)		75%	75%	75%
Ângulo		65°	65°	65°
Direção de voo		81°	171°	171°
Total de fotos coletadas		885 imagens		
Duração total de todos os voos		88min 19s		

Fonte: Elaborado pela autora.

5.2 ANÁLISE DO PROCESSAMENTO DIGITAL E ORTOIMAGENS

Após o processamento digital no software Agisoft Metashape, foi realizada uma análise detalhada das ortofotomontagens geradas, com o objetivo de compreender o processamento e verificar a qualidade dos resultados obtidos. Para isso, cada parâmetro do fluxo de trabalho (*workflow*) foi analisado (Tabelas 14 a 20), avaliando como as configurações selecionadas influenciaram nos resultados das ortofotomontagens, em conformidade com as diretrizes estabelecidas no manual do software Agisoft (2024).

O alinhamento das imagens (*Align photos*) é o procedimento utilizado para determinar a posição e orientação da câmera no espaço quando cada fotografia foi registrada. Nesta etapa, foi construído um modelo de nuvem de pontos esparsa. Os parâmetros aplicados para avaliar esse processamento incluem *Accuracy*; *Generic preselection*; *Key point limit* e *Tie point limit*, conforme apresentado na Tabela 14.

Tabela 14 - Parâmetros de alinhamento de imagem (*Align photos*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo	Quant. imagens
ALIGN PHOTOS	QGEx.1	<i>Highest; Yes; 80,000; 8,000</i>		1h 25min	460
	QGEx.2	<i>Highest; Yes; 80,000; 8,000</i>		15min 11s	472
	QGEx.3	<i>Highest; Yes; 80,000; 8,000</i>		13min 02s	453
	ICC.1	<i>Highest; Yes; 80,000; 8,000</i>		11min 12s	279
	ICC.2		<i>High; Yes; 80,000; 8,000</i>	09min 07s	384
	ICC.3		<i>High; Yes; 80,000; 8,000</i>	08min 46s	579
	ICC.4		<i>High; Yes; 80,000; 8,000</i>	11min 01s	481
	ICC.5	<i>Highest; Yes; 80,000; 8,000</i>		08min 02s	422
	ICC.6	<i>Highest; Yes; 80,000; 8,000</i>		12min 51s	634
	ICC.7	<i>Highest; Yes; 80,000; 8,000</i>		06 min 16s	356
	ICC.8	<i>Highest; Yes; 80,000; 8,000</i>		1h 15min	963
	BCE.1		<i>Highest; Yes; 40,000; 10,000</i>	09min 13s	425
	BCE.2		<i>Highest; Yes; 40,000; 10,000</i>	02min 09s	135
	BCE.3		<i>Highest; Yes; 40,000; 10,000</i>	09min 22s	402
	R.1		<i>Highest; Enable; 80,000; 8,000</i>	30min 02s	496
	UCA.1		<i>Highest; Enable; 80,000; 8,000</i>	09min 13s	491
	UCA.2		<i>Highest; Enable; 80,000; 8,000</i>	02min 20s	160
	UCA.3		<i>Highest; Enable; 80,000; 8,000</i>	01min 06s	81

Fonte: Elaborado pela autora.

Na configuração de *Accuracy*, foi selecionado o parâmetro *Highest* para os três voos realizados no QGEx, quatro voos realizados no ICC, bem como para os voos da BCE, Reitoria e UCA. Para esses voos, foi obtida uma precisão elevada no alinhamento das imagens, aumentando sua escala em um fator de 4 (2 vezes de cada lado). Para os voos ICC.2, ICC.3 e ICC.4, foi utilizada a configuração de precisão *High*, na qual o software processou as imagens em seu tamanho original, sem aumento de escala.

A opção *Generic preselection* foi ativada nos voos do QGEx, ICC e BCE, permitindo um alinhamento de baixa precisão para pré-selecionar pares de fotos com sobreposição, otimizando o tempo de processamento nas etapas subsequentes de alinhamento. Nos pares selecionados, foram aplicados os parâmetros *Highest e High*. Sem essa opção, seria necessário

um computador com hardware de alto desempenho, pois o alinhamento de grandes conjuntos de imagens pode ser um processo demorado, com uma parte significativa desse tempo dedicado à correspondência de recursos detectados nas fotos.

Quando a opção de pré-seleção de pares de imagens (*Yes*) foi ativada, o processo foi acelerado pela seleção de um subconjunto de pares de imagens a serem combinados, reduzindo o número de correspondências necessárias e, conseqüentemente, o tempo de processamento.

A opção *Enable* foi ativada pelo software durante o processamento dos edifícios da Reitoria e da Unidade da Criança e do Adolescente, permitindo que as imagens selecionadas fossem utilizadas na construção da nuvem de pontos esparsa e contribuíssem para o cálculo preciso da posição e orientação da câmera no espaço. O software identificou correspondências e alinhou as imagens com base em pontos de referência comuns, assegurando maior precisão no modelo gerado.

O *key point limit* define o número máximo de pontos de características que foram detectados em cada imagem durante o processo de alinhamento. Nos processamentos realizados, os valores variaram entre 40.000 e 80.000, sendo a primeira configuração utilizada exclusivamente nos processamentos da BCE. Durante o processo de comparação entre *key points* de duas imagens, o software seleciona como *match points* os que possuíam assinaturas iguais, ou seja, pontos-chave que coincidem entre as imagens. Quanto mais próximo de zero for o valor definido, maior será a quantidade de *key points* em cada imagem, o que pode resultar em um aumento no número de pontos redundantes e, conseqüentemente, na redução da precisão do modelo gerado.

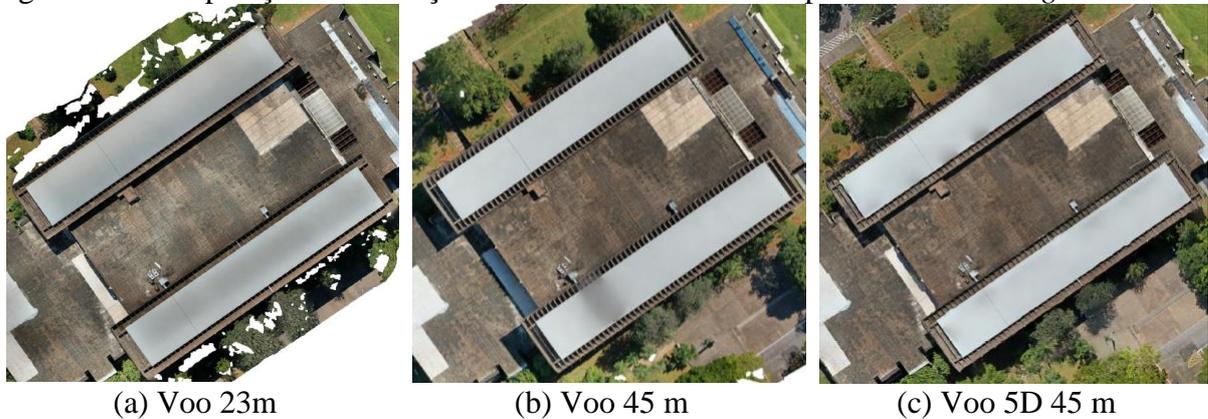
O parâmetro *tie point limit* foi configurado com valores de 8.000 e 10.000, definindo o número máximo de coincidências, ou *tie points*, entre duas imagens. Esse parâmetro permite considerar apenas os *key points* com as 1.000 melhores coincidências para a conversão em *tie points*, estabelecendo um limite superior para os pontos de correspondência em cada imagem. Caso o valor fosse zero, o software não aplicaria nenhuma filtragem nos pontos de correspondência, permitindo a inclusão de todos os *tie points* identificados, resultando em um modelo menos eficiente.

O segundo *workflow* trabalhado foi o *Build Dense Cloud*, cuja função é gerar a nuvem densa a partir das posições estimadas da câmera no momento da captura das imagens. Esse processo é essencial para construir o modelo 3D com precisão nos detalhes da cena fotografada. A geração da nuvem densa utiliza pares de fotos, uma vez que os *match points* já foram identificados e estabelecidos na fase de alinhamento das imagens.

Nesta etapa, também foram aplicados algoritmos de compatibilização para o par de imagens com a nuvem de pontos do conjunto de imagens. O resultado desse processamento é uma nuvem densa que revela, com textura e cores, a forma detalhada do objeto modelado.

Para o *workflow* da nuvem de pontos densa, conforme mostra a Tabela 15, foram considerados os parâmetros *Quality* e *Depth filtering*. O parâmetro *Quality* variou entre *Ultra-high* (adota a resolução mais alta da imagem); *Highest* (adota a imagem original); *High* (redução de 2x2) e *Medium* (redução de 4x4). Quanto menor o valor do parâmetro *Quality*, menor o tempo de processamento, e menor a qualidade da nuvem de pontos densa gerada. O *ultra-high* foi utilizado em projetos que exigiram maior definição, isso pôde ser verificado no processamento da BCE.2, onde as bordas tiveram melhores definições (Figura 71).

Figura 71 - Comparação da definição das bordas com o uso do parâmetro *ultra-high*.



Fonte: Elaborado pela autora.

O parâmetro filtragem de profundidade (*Depth filtering*) orienta o software a lidar com *outliers* durante a interpolação na geração da nuvem densa, visando aprimorar a qualidade da reconstrução. Na etapa de reconstrução da nuvem densa, o software calcula mapas de profundidade para cada imagem, ajustando-os de acordo com o nível de filtragem aplicado. Para o processamento, foram utilizados os níveis *Agressive* e *Moderate*. O nível *Agressive* é recomendado quando a captura de pequenos detalhes não é prioritária, pois aplica uma filtragem mais intensa para minimizar *outliers*. Já o *Moderate* representa um equilíbrio, retendo mais detalhes de superfície sem adicionar muito ruído. Embora o nível *Mild* não tenha sido aplicado neste projeto, ele permite uma redução dos *outliers* com maior retenção de detalhes, resultando em uma nuvem com mais ruído, ideal para superfícies que exigem alta precisão no detalhamento.

Tabela 15 - Parâmetros da construção da nuvem densa (*Build Dense Cloud*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo
BUILD DENSE CLOUD	QGEx.1	<i>Medium; Agressive</i>		11min 04s
	QGEx.2		<i>High; Agressive</i>	11min 58s
	QGEx.3		<i>Medium; Moderate</i>	49min 38s
	ICC.1	<i>Medium; Agressive</i>		22min 48s
	ICC.2	<i>Medium; Agressive</i>		35min 30s
	ICC.3		<i>Medium; Moderate</i>	1h 05min
	ICC.4		<i>Medium; Moderate</i>	30min 36s
	ICC.5	<i>Medium; Agressive</i>		38min 21s
	ICC.6	<i>Medium; Agressive</i>		30min 49s
	ICC.7	<i>Medium; Agressive</i>		13min 25s
	ICC.8	<i>Medium; Agressive</i>		2h 44min
	BCE.1		<i>Highest; Moderate</i>	1h 05min
	BCE.2		<i>Ultra-high; Moderate</i>	3h 48min
	BCE.3	-	-	-
	R.1	<i>Medium; Agressive</i>		2h 18min
	UCA.1	<i>Medium; Agressive</i>		3h 07min
	UCA.2	<i>Medium; Agressive</i>		18min 32s
UCA.3	<i>Medium; Agressive</i>		04min 15s	

Fonte: Elaborado pela autora.

O único processamento que não apareceu o parâmetro para o *Depth filtering* foi o voo realizado nas cinco direções com altitude de 45 m, devido à quantidade de planos de voo realizados.

O terceiro *workflow*, *Build mesh* (Tabela 16), utiliza a nuvem densa para interpolar uma malha e construir uma superfície 3D sobre os pontos da nuvem. Este processo infere uma superfície que representa a nuvem de pontos obtida anteriormente. No entanto, a precisão dessa reconstrução pode ser comprometida pela qualidade da nuvem de pontos e pelo esforço computacional necessário. Características como densidade, qualidade, nível de ruído, suavidade das formas, presença de cantos e oclusões influenciam diretamente o resultado da malha gerada.

Para o processamento, foram configurados os parâmetros *Source data*; *Surface type* e *Interpolation*. No *Source data*, é possível escolher entre a nuvem esparsa (gerada no alinhamento das imagens) e a nuvem densa. Neste estudo, a *Dense cloud* foi utilizada em todos os processamentos, resultando em um tempo de processamento longo, mas proporcionando um resultado de alta qualidade devido à riqueza de detalhes presentes na nuvem reconstruída.

O tipo de superfície *Arbitrary*, adotado em todos os processamentos, permitiu que o software não fizesse suposições sobre a forma do objeto modelado, embora tenha demandado um maior consumo de memória computacional. Este método de reconstrução de malha consistente de visibilidade é aplicável apenas à reconstrução de superfície 3D.

No parâmetro de *Interpolation*, foram consideradas as opções *Disable* e o *Enable*. A opção *Disable* forneceu uma reconstrução mais precisa, pois apenas as áreas correspondentes aos pontos da nuvem densa foram incluídas na malha. Já a opção *Enable* permitiu a interpolação

de superfícies em torno de um determinado raio para cada ponto da nuvem densa, resultando em um modelo final com menos buracos em comparação à opção *Disable*.

Devido à quantidade de *key point limit* e *tie point limit* estabelecidos para o processamento do voo da BCE, não foram obtidos resultados dos parâmetros para o *Build Mesh*, o *Build Texture* e o *Build Tiled Model*.

Tabela 16 - Parâmetros da construção da malha (*Build Mesh*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo
BUILD MESH	QGEEx.1	<i>Dense; Arbitrary; Disable</i>		1h 50min
	QGEEx.2		<i>Dense; Arbitrary; Enable</i>	2 dias 10h
	QGEEx.3	<i>Dense; Arbitrary; Disable</i>		58min 40s
	ICC.1	<i>Dense; Arbitrary; Disable</i>		51min 53s
	ICC.2		<i>Dense; Arbitrary; Enable</i>	38min 48s
	ICC.3	<i>Dense; Arbitrary; Disable</i>		53min 07s
	ICC.4	<i>Dense; Arbitrary; Disable</i>		1h 35min
	ICC.5	<i>Dense; Arbitrary; Disable</i>		1h 24min
	ICC.6	<i>Dense; Arbitrary; Disable</i>		1h 47min
	ICC.7	<i>Dense; Arbitrary; Disable</i>		1h 20min
	ICC.8	<i>Dense; Arbitrary; Disable</i>		15h 27min
	BCE.1	-	-	-
	BCE.2	-	-	-
	BCE.3	-	-	-
	R.1	<i>Dense; Arbitrary; Disable</i>		2h 18min
	UCA.1	<i>Dense; Arbitrary; Disable</i>		22min 38s
	UCA.2	<i>Dense; Arbitrary; Disable</i>		11min 04s
	UCA.3	<i>Dense; Arbitrary; Disable</i>		05min 24s

Fonte: Elaborado pela autora.

O *workflow Build Texture* (Tabela 17) definiu a forma como a textura do objeto foi sobreposta no atlas de textura. A escolha apropriada do modo de mapeamento de textura possibilitou uma sobreposição ideal, contribuindo para a melhoria da qualidade visual do modelo final.

Foram utilizados dois parâmetros, sendo eles, o modelo de mapeamento de textura (*Orthophoto*) e o método de combinação dos valores de pixel de diferentes imagens na textura final (*Mosaic*). No modo *Orthophoto*, a superfície do objeto foi texturizada por projeção ortográfica, resultando em uma textura mais compacta, ainda que com alguma perda da qualidade em áreas verticais.

No modo *Mosaic*, a abordagem seguiu duas etapas. Primeiramente, combinou-se o componente de baixa frequência para imagens sobrepostas, evitando o surgimento de linhas de junção. Em seguida, o componente de alta frequência — responsável pelos detalhes da imagem — foi extraído de uma única imagem que possuía boa resolução para a área específica de interesse, posicionada quase perpendicular à superfície reconstruída naquele ponto.

Para esses processamentos, o parâmetro *Hole Filling* foi ativado, permitindo o preenchimento de lacunas na textura (orifícios).

Tabela 17 - Parâmetros da construção da textura (*Build Texture*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo
BUILD TEXTURE	QG.1	<i>Orthophoto; Mosaic</i>		31min 29s
	QG.2	<i>Orthophoto; Mosaic</i>		21min 9s
	QG.3	<i>Orthophoto; Mosaic</i>		17min 57s
	ICC.1	<i>Orthophoto; Mosaic</i>		28min 48s
	ICC.2	<i>Orthophoto; Mosaic</i>		36min 15s
	ICC.3	<i>Orthophoto; Mosaic</i>		58min 23s
	ICC.4	-	-	-
	ICC.5	<i>Orthophoto; Mosaic</i>		35min 34s
	ICC.6	<i>Orthophoto; Mosaic</i>		57min 32s
	ICC.7	<i>Orthophoto; Mosaic</i>		33min 13s
	ICC.8	<i>Orthophoto; Mosaic</i>		4h 26min
	BCE.1	-	-	-
	BCE.2	-	-	-
	BCE.3	-	-	-
	R.1	<i>Orthophoto; Mosaic</i>		7h 10min
	UCA.1	<i>Orthophoto; Mosaic</i>		48min 24s
	UCA.2	<i>Orthophoto; Mosaic</i>		14min 43s
	UCA.3	<i>Orthophoto; Mosaic</i>		7min 38s

Fonte: Elaborado pela autora.

No *workflow Build Tiled Model*, foram adotados os parâmetros *Source Data (Dense Cloud)* e *Face Count (Low)*, apresentados na Tabela 18. A escolha do *Dense Cloud* se justificou por ser recomendado para grandes projetos, especialmente quando a construção da malha não é viável, devido ao alto custo de processamento. A configuração *Face count* (contagem das faces) foi ajustada para *Low* (baixa), a fim de reduzir o tempo total de processamento, ainda que isso limite o detalhamento da malha gerada.

Tabela 18 - Parâmetros da construção do modelo (*Build Tiled Model*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo
BUILD TILED MODEL	QGEx.1	<i>Dense cloud; Low</i>		31min 29s
	QGEx.2	-	-	-
	QGEx.3	-	-	-
	ICC.1	<i>Dense cloud; Low</i>		16h 14min
	ICC.2	-	-	-
	ICC.3	<i>Dense cloud; Low</i>		3h 59min
	ICC.4	<i>Dense cloud; Low</i>		4h 14min
	ICC.5	<i>Dense cloud; Low</i>		19h 8min
	ICC.6	<i>Dense cloud; Low</i>		14h 59min
	ICC.7	<i>Dense cloud; Low</i>		5h 35min
	ICC.8	<i>Dense cloud; Low</i>		1 dia 4h
	BCE.1	-	-	-
	BCE.2	-	-	-
	BCE.3	-	-	-
	R.1	<i>Dense cloud; Low</i>		7h 10min
	UCA.1	<i>Dense cloud; Low</i>		2h 25min
	UCA.2	<i>Dense cloud; Low</i>		53min 37s
	UCA.3	<i>Dense cloud; Low</i>		38min 53s

Fonte: Elaborado pela autora.

Para o *workflow Build Digital Elevation Model (DEM)*, mostrado na Tabela 19, foram considerados os parâmetros *Source data (Dense Cloud e Sparse Cloud)*, calculados a partir dos dados da nuvem de pontos densa. O parâmetro *Interpolation* foi configurado como *Enabled*

(*default*), instruindo o software a calcular o DEM para todas as áreas da cena visíveis em pelo menos uma imagem. Essa configuração é recomendada para a geração do DEM, pois melhora a cobertura e a consistência do modelo final.

Tabela 19 - Parâmetros da construção do modelo digital de elevação (*Build Digital Elevation Model - DEM*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo
BUILD DEM	QG.1	<i>Dense cloud; Enabled</i>		5min 3s
	QG.2	<i>Dense cloud; Enabled</i>		4min 5s
	QG.3	<i>Dense cloud; Enabled</i>		1min 14s
	ICC.1	<i>Dense cloud; Enabled</i>		3min 11s
	ICC.2	<i>Dense cloud; Enabled</i>		41s
	ICC.3	<i>Dense cloud; Enabled</i>		1min 42s
	ICC.4	<i>Dense cloud; Enabled</i>		2min 50s
	ICC.5	<i>Dense cloud; Enabled</i>		5min 21s
	ICC.6	<i>Dense cloud; Enabled</i>		6min 12s
	ICC.7	<i>Dense cloud; Enabled</i>		3min 37s
	ICC.8	<i>Dense cloud; Enabled</i>		35min 22s
	BCE.1	<i>Dense cloud; Enabled</i>		3min 33s
	BCE.2	<i>Dense cloud; Enabled</i>		3min 55s
	BCE.3		<i>Sparse cloud; Enabled</i>	13s
	R.1	<i>Dense cloud; Enabled</i>		2min 33s
	UCA.1	<i>Dense cloud; Enabled</i>		1min 8s
	UCA.2	<i>Dense cloud; Enabled</i>		34s
	UCA.3	<i>Dense cloud; Enabled</i>		16s

Fonte: Elaborado pela autora.

A exportação da ortoimagem foi utilizada para gerar imagens de alta resolução com base nas imagens de origem e no modelo reconstruído, facilitando a análise e inspeção posterior do sistema de cobertura. Os parâmetros considerados para a análise foram *Surface (Mesh e DEM)*, *Blending Mode (Mosaic)* e *Hole Filling (Yes)*, apresentados na Tabela 20. Os métodos *Mesh* (malha) e *DEM* (modelo digital de elevação) criaram a ortoimagem, sendo uma escolha eficiente para o processamento de levantamento aéreos, permitindo economizar tempo na etapa de geração de malha.

A principal diferença entre o uso do *Mesh* e *DEM* no parâmetro *Surface* do workflow *Build Orthomosaic* está relacionada à forma como a superfície de referência é utilizada para projetar as imagens na ortoimagem, afetando diretamente a precisão, a eficiência e as aplicações do modelo gerado.

O modo *Mosaic* implementou a abordagem que divide os dados em múltiplos domínios de frequência, que são combinados separadamente, melhorando a qualidade visual do resultado. Com o preenchimento de orifícios (*Hole Filling*) ativado, o software tratou de preencher as lacunas nas áreas sem dados, resultando em uma cobertura mais uniforme da ortoimagem final.

Tabela 20 - Parâmetros da construção do ortomosaico (*Orthomosaic*).

	Voos	Parâmetros semelhantes	Parâmetros com divergências	Tempo
BUILD ORTHOMOSAIC	QGE.x.1	<i>Mesh; Mosaic; Yes</i>		1 dia 20h
	QG.2		<i>DEM; Mosaic; Yes</i>	26min 9s
	QG.3		<i>DEM; Mosaic; Yes</i>	13min 48s
	ICC.1	<i>Mesh; Mosaic; Yes</i>		30min 4s
	ICC.2	<i>Mesh; Mosaic; Yes</i>		13min 13s
	ICC.3		<i>DEM; Mosaic; Yes</i>	35min 29s
	ICC.4		<i>DEM; Mosaic; Yes</i>	38min 29s
	ICC.5	<i>Mesh; Mosaic; Yes</i>		59min 6s
	ICC.6	<i>Mesh; Mosaic; Yes</i>		1h 15min
	ICC.7	<i>Mesh; Mosaic; Yes</i>		16h 53min
	ICC.8	<i>Mesh; Mosaic; Yes</i>		4h 54min
	BCE.1		<i>DEM; Mosaic; Yes</i>	21min 17s
	BCE.2		<i>DEM; Mosaic; Yes</i>	9min 12s
	BCE.3		<i>DEM; Mosaic; Yes</i>	15min 4s
	R.1	<i>Mesh; Mosaic; Yes</i>		1h 8min
	UCA.1	<i>Mesh; Mosaic; Yes</i>		4min 11s
UCA.2	<i>Mesh; Mosaic; Yes</i>		9min 41s	
UCA.3	<i>Mesh; Mosaic; Yes</i>		27min 18s	

Fonte: Elaborado pela autora.

A partir dos relatórios gerados em cada processamento, foi possível analisar informações como o tamanho dos pixels, a quantidade de sobreposição de imagens em cada região do modelo, a área total mageada, e a altitude do voo, entre outros aspectos. Para este estudo, é essencial utilizar o Modelo Digital de Elevação (*Digital Elevation Model - DEM*) como dado de saída, a fim de avaliar a resolução (cm/pix). Além disso, os Dados de Pesquisa (*Survey Data*) devem ser considerados para medir o erro de projeção (pixel), conforme apresentado na Tabela 21.

Tabela 21 - Resultados do processamento para a geração das ortoimagens obtidas.

	Amostras	Área (m ²)	Tempo (h)	Resolução (GB)	Digital Elevation Model – Resolution	Survey Data – Reprojection error
QGE.x	A1.1	2 hectares	24:20:00	2,58 GB	2,37 cm/pix	0,957 pix
	A1.2	2 hectares	0:26:09	2,82 GB	1,16 cm/pix	1,4 pix
	A1.3	5 hectares	0:13:48	2,36 GB	3,94 cm/pix	1,23 pix
ICC Norte e Sul	A2.1	6.640 m ²	0:30:04	2,06 GB	1,44 cm/pix	0,508 pix
	A2.2	9.750m ²	0:13:13	1,66 GB	1,95 cm/pix	0,647 pix
	A2.3	1 hectare	0:35:29	2,70 GB	1,91 cm/pix	0,689 pix
	A2.4	1 hectare	0:38:29	3,99 GB	1,36 cm/pix	0,587 pix
	A2.5	1 hectare	0:42:26	2,97 GB	1,46 cm/pix	0,525 pix
	A2.6	1 hectare	1:15:00	3,97 GB	1,49 cm/pix	0,541 pix
	A2.7	1 hectare	16:53:00	3,05 GB	1,33 cm/pix	0,533 pix
	A2.8	1 hectare	4:54:00	4,19 GB	1,36 cm/pix	0,517 pix
	A2.9	11 hectares	21:31:00	2,80 GB	6,85 cm/pix	0,66 pix
BCE	A3.1 – 23 m	151 m ²	0:21:17	2,66 GB	8,55 mm/pix	0,557 pix
	A3.2 – 45 m	256 m ²	0:09:12	3,13 GB	9,86 mm/pix	0,618 pix
	A3.3 – 45 m - 5D	330 m ²	0:15:04	974 MB	14,6 cm/pix	2,18 pix
Reitoria	A4.1	112 m ²	1:08:00	2,20 GB	1,7 cm/pix	0,716 pix

Continuação

HUB						
	A5.1	196 m ²	0:27:18	1,47 GB	2,64 cm/pix	0,609 pix
	A5.2	213 m ²	0:09:41	877 MB	3,63 cm/pix	0,548 pix
	A5.3	361 m ²	0:04:11	524 MB	6,15 cm/pix	0,564 pix

Fonte: Elaborado pela autora.

O Quadro 18 destaca, em resumo, a relação entre a qualidade do processamento das imagens capturadas e a definição da altitude acima da cobertura e das margens definidas (mageamento).

Quadro 18 - Critérios que afetam a qualidade na etapa de processamento, conforme a definição de altitude e do mageamento.

Qualidade do processamento das imagens capturadas	
Altitude do voo acima da cobertura	Mageamento da cobertura
<p>- O equilíbrio entre a quantidade de imagens capturadas e a eficiência da operação é resultante da escolha da altitude do voo:</p> <ul style="list-style-type: none"> • A maior altitude do voo aumenta a área coberta por cada imagem, o que reduz a quantidade total de fotos necessárias para o levantamento, tornando a execução do voo mais rápida, exigindo menos trocas de baterias e reduzindo o desgaste do equipamento; • O menor número de imagens geradas diminui a necessidade de espaço de armazenamento e simplifica o processamento das informações. <p>- A escolha da altitude ideal deve considerar as prioridades do projeto, balanceando eficiência operacional e qualidade dos dados obtidos, essencial para análises que requerem precisão como a avaliação do estado de conservação de sistemas:</p> <ul style="list-style-type: none"> • Os voos a altitudes mais baixas capturam imagens com maior detalhamento e resolução; • Altitudes mais baixas exigem mais tempo de operação, maior consumo de baterias e cartões de memória com maior capacidade para armazenar o volume ampliado de imagens. 	<p>- O voo a uma maior distância em relação à margem da cobertura permite capturar mais detalhes dos diferentes planos de cobertura e da borda.</p> <ul style="list-style-type: none"> • Essa configuração reduz significativamente a formação de buracos brancos próximos à cobertura, garantindo maior continuidade e precisão na área central da ortomagem; • Os dados capturados são mais confiáveis para análises gerais, o que beneficia projetos que demandam ampla cobertura com uniformidade visual e espacial. <p>- Ao diminuir a distância da margem, há uma maior probabilidade de surgirem buracos nas áreas próximas à borda do sistema de cobertura, especialmente após o processamento da ortomagem:</p> <ul style="list-style-type: none"> • Essa configuração limita o nível de detalhamento capturado nos planos de cobertura, o que pode dificultar análises específicas, como a avaliação do estado de conservação de pequenos dispositivos, equipamentos ou manifestações patológicas; • O planejamento do levantamento deve considerar a finalidade do projeto, equilibrando a abrangência e o detalhamento necessários.

Fonte: Elaborado pela autora.

Os voos em uma direção demonstraram ser adequados para visualização de coberturas planas lineares, atendendo às necessidades do plano de voo. Por outro lado, planos de voo em duas direções podem ser aplicados em coberturas com diferentes níveis, desde que não apresentem uma complexidade significativa, como extensões ou avanços sobre os diferentes

planos. Para edificações cuja cobertura possui níveis mais complexos, recomenda-se a realização de voos em cinco direções, possibilitando maior detalhamento no processamento e garantindo a obtenção de informações mais precisas e abrangentes.

5.3 ANÁLISE DO PROCESSAMENTO DIGITAL DE COBERTURAS COM DIFERENTES NÍVEIS

A análise das imagens capturadas pelos drones com diferentes níveis evidenciou a relação direta entre a proximidade do drone ao nível do sistema de cobertura e a quantidade de imagens obtidas. Esse fator impacta a qualidade da inspeção nas áreas mais próximas ao drone, resultando em um menor nível de detalhamento na ortoimagem. Quanto mais próximo o drone estiver da superfície do último nível, menor será a quantidade de imagens capturadas neste nível, comparativamente com os níveis inferiores, o que, conseqüentemente, reduz os resultados finais.

Além disso, o drone opera dentro de um limite de altitude de segurança durante a execução do plano de voo. Embora essa restrição garanta a segurança operacional, ela pode impactar negativamente a qualidade das imagens em áreas sobre os pequenos volumes (por exemplo, torre de caixa d'água ou casa de máquinas) presentes na cobertura, onde a área de captura se torna limitada.

Essa relação entre proximidade e qualidade de detalhes é aplicável aos sistemas de cobertura plana. No entanto, em coberturas planas com diferentes níveis, essa lógica não se aplica uniformemente. As variações de altura entre os diferentes níveis introduzem desafios adicionais, dificultando a captura homogênea dos detalhes. Mesmo com a aplicação das sobreposições transversal e longitudinal recomendadas, a quantidade de imagens obtidas pode não ser suficientes para garantir uma representação detalhada.

Com base nas características dos sistemas de cobertura inspecionadas, nos parâmetros e critérios descritos na seção anterior, serão apresentados e analisados os resultados obtidos para coberturas com diferentes níveis. Para uma análise estruturada, os casos de estudo foram organizados em três tópicos: o processamento digital da BCE, o processamento digital da Reitoria e, por fim, o processamento digital da UCA.

5.3.1 Processamento Digital das Coberturas Planas da BCE

O voo preliminar realizado na BCE identificou como obstáculo no terreno a presença de uma árvore com 34 metros de altura. Esse obstáculo limitou a aproximação do drone ao sistema de cobertura. Por essa razão, o planejamento do primeiro voo estabeleceu uma margem

de segurança para evitar colisões com a árvore, definindo uma altitude de voo de 23 metros acima do sistema de cobertura.

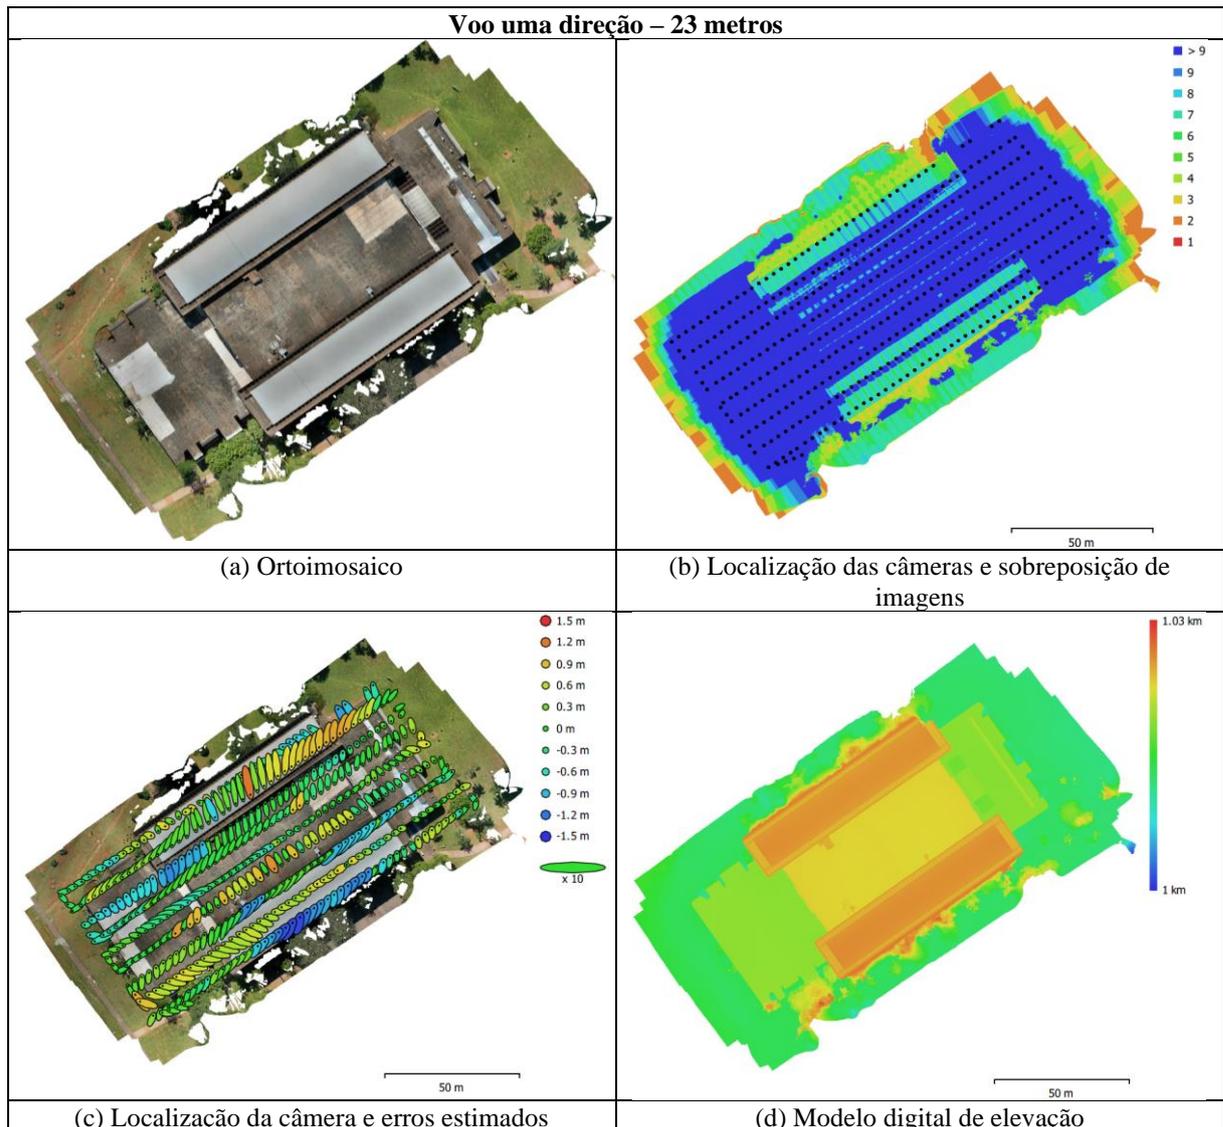
A análise do Quadro 19 revela, na imagem (a), o surgimento de buracos brancos na ortoimagem em áreas próximas à edificação. Isso ocorreu devido às características específicas das vegetações, como forma irregular, superfícies não sólidas compostas por folhas e galhos, e a dificuldade em detectar pontos de correspondência entre as imagens. Além disso, os movimentos da vegetação provocados pelo vento contribuíram para a inconsistência no alinhamento e na geração da nuvem de pontos. Outros fatores como textura homogênea, reflexões, sombras, altura e angulação do voo também influenciaram diretamente o processamento da ortoimagem.

Na imagem (b), observa-se a localização das câmeras variando de 1 a >9 nas bordas das imagens, onde há menor densidade de capturas. Esse comportamento é esperado devido ao ângulo de captura da câmera e à quantidade de linhas de voos realizadas na área. Identificou-se ainda menor sobreposição de imagens nos diferentes níveis do sistema de cobertura, uma vez que os níveis superiores estavam mais próximos da altitude definida para o voo do drone. Essa diferença de níveis torna-se evidente na imagem (d), que apresenta a elevação relativa do voo.

O erro de projeção foi de 0,557 pixels, resultando em uma resolução de solo de 4,28 mm/pixel, ou seja, menor que 1 pixel de erro. Esse valor de 1 pixel refere-se a um parâmetro de referência para precisão (Silva *et al.*, 2022), demonstrando a precisão alcançada pelo experimento realizado.

A imagem (c) indica o erro médio de localização das câmeras durante a captura das imagens no plano de voo. Observou-se que no telhado metálico dos pórticos, caracterizado por linhas repetitivas, não houve definição clara do elemento na ortoimagem. Essa limitação decorre das propriedades específicas dos materiais metálicos, como reflexões, brilho intenso e superfícies homogêneas e lisas, que oferecem poucos contrastes ou texturas visíveis, dificultando a identificação de pontos-chave (*key points*). Como consequência, a ortoimagem gerada apresentou áreas borradas nesse elemento arquitetônico.

Quadro 19 - Resultado do processamento do plano de voo realizado na BCE – 23 metros – 1 direção.



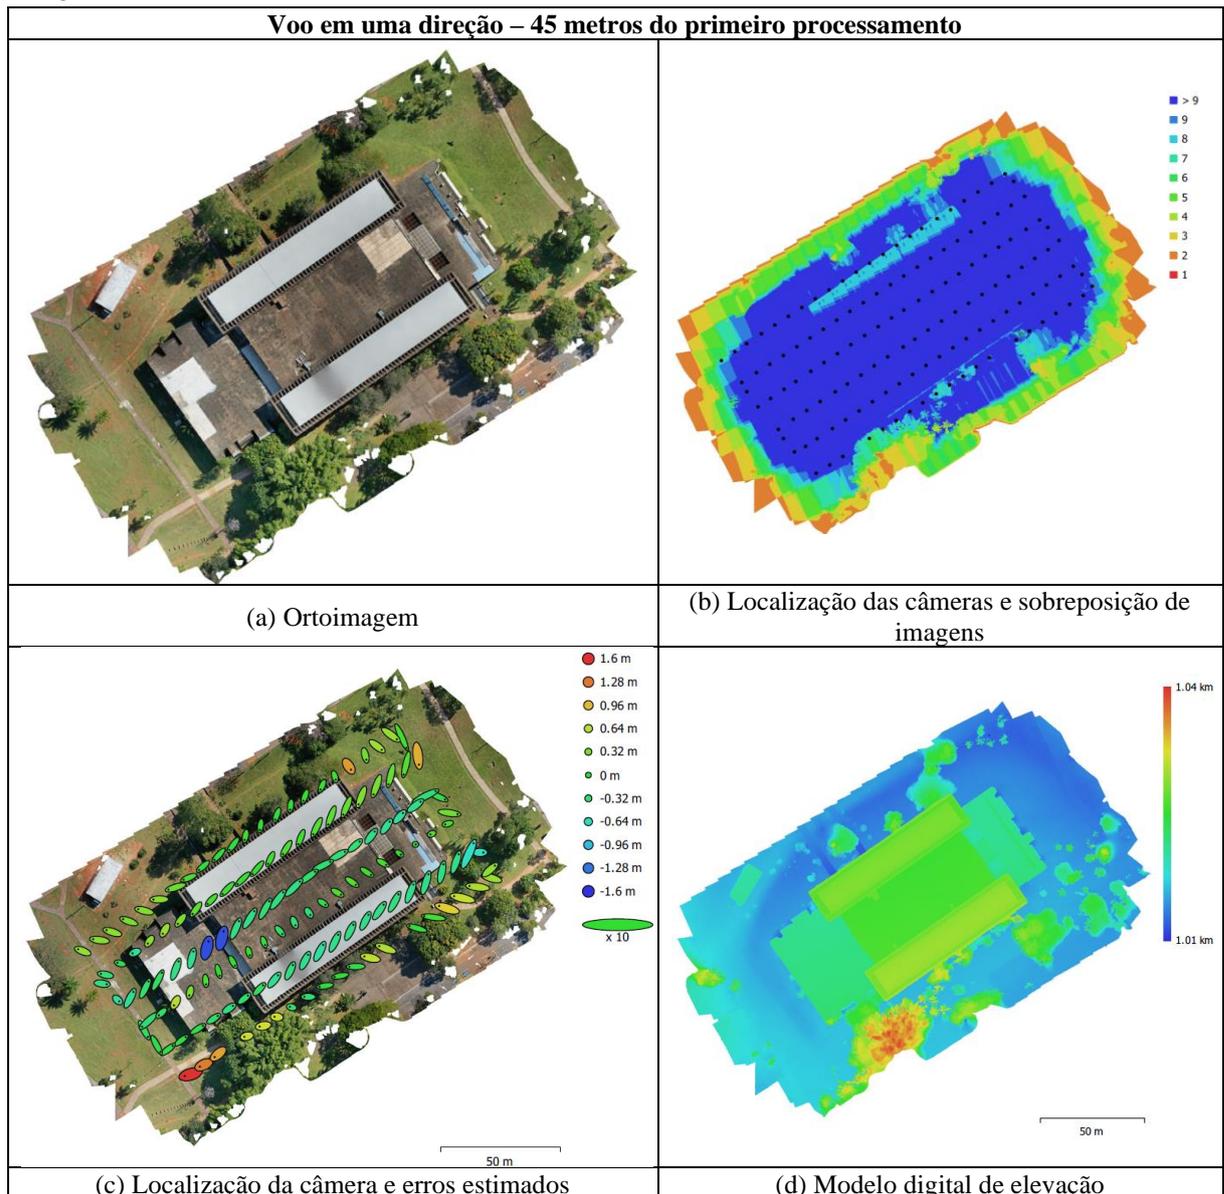
Fonte: Elaborado pela autora.

Um segundo voo foi realizado com a altitude ajustada para 45 metros acima do sistema de cobertura, permitindo uma área de mapeamento mais ampla. Como resultado no Quadro 20, verificou-se um aumento significativo na quantidade de imagens capturadas, com mais de nove sobreposições registradas na região central, especialmente nos pórticos do sistema de cobertura. Entretanto, nas bordas externas, observou-se uma redução na densidade de capturas, o que é esperado em áreas com menor número de linhas de voo realizadas nessas regiões. Essa distribuição reflete a configuração do plano de voo e o posicionamento das câmeras, resultando em uma maior captura de imagens na área central e uma menor densidade nas extremidades do sistema.

No modelo digital de elevação (DEM), é possível observar uma área com coloração avermelhada na região ocupada por um bambuzal, atribuída à dificuldade do software em

reconhecer pixels semelhantes durante o processamento. De maneira semelhante, a presença de uma mancha escura no telhamento em aço galvanizado deve-se a fatores como reflexões irregulares da luz, que comprometem a consistência das imagens capturadas. Além disso, a homogeneidade da textura e a falta de contrastes visíveis nesses materiais dificultam a identificação de pontos-chave (*key points*). Esses desafios contribuem para a inconsistência no alinhamento e na qualidade final da ortoimagem gerada para essas regiões.

Quadro 20 - Resultado do processamento do plano de voo realizado na BCE – 45 metros – 1 direção.



Fonte: Elaborado pela autora.

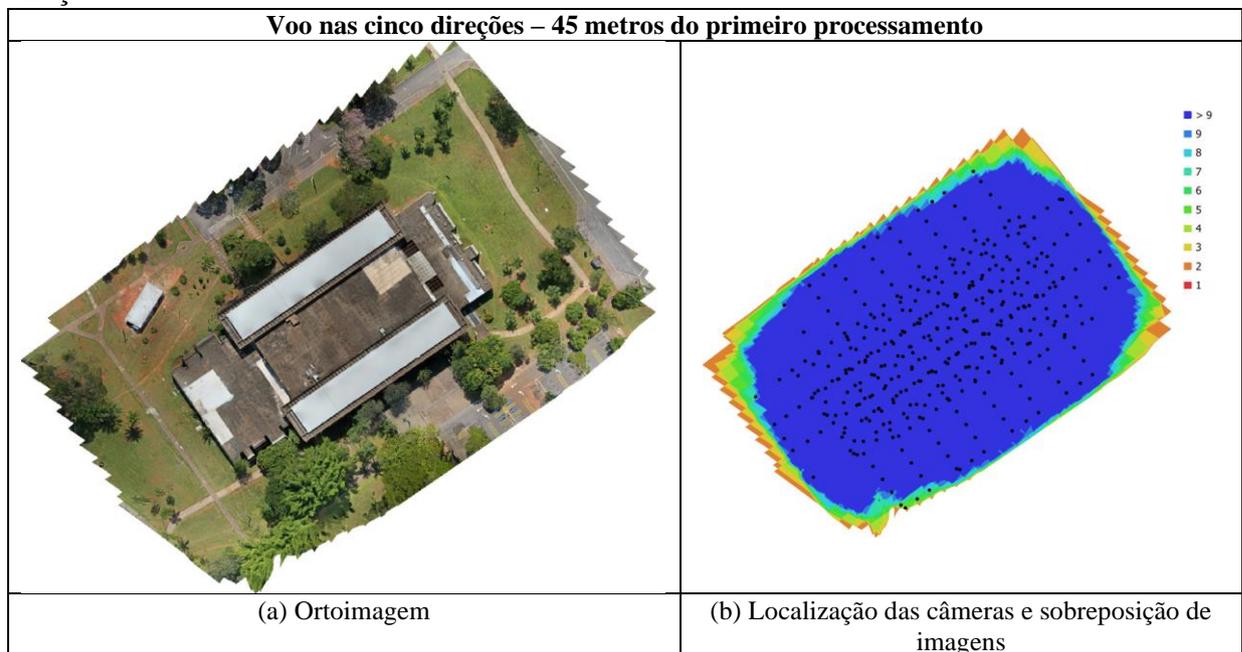
No terceiro processamento, foi observada uma área de mageamento ainda maior, resultando em uma definição superior da ortoimagem gerada, sem a presença de buracos brancos. Esse aprimoramento deve-se à realização de voos em cinco direções diferentes, o que

possibilitou a captura de uma grande quantidade de imagens, proporcionando maior cobertura e detalhes para o modelo final.

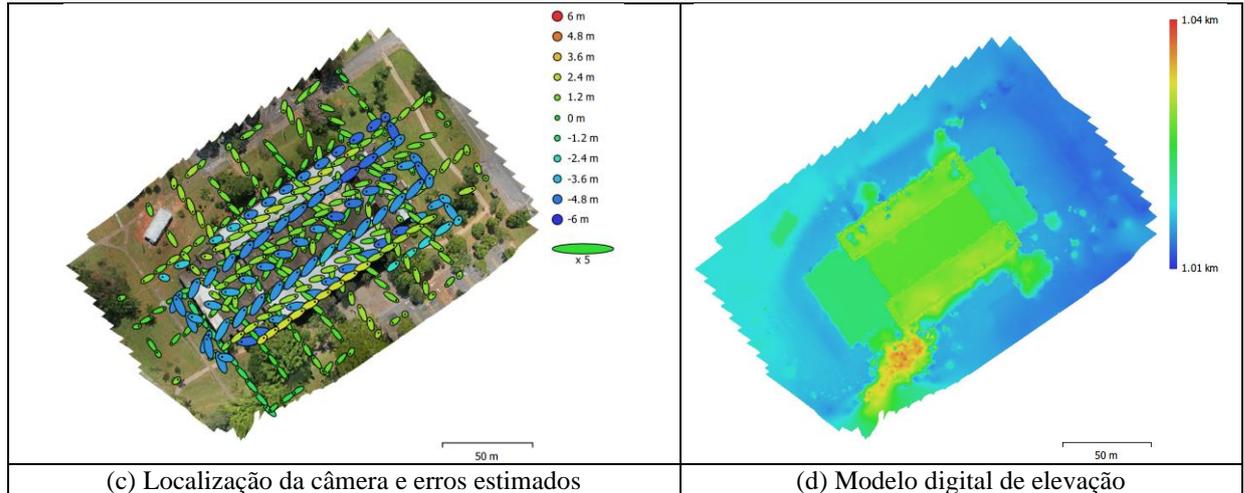
No modelo digital de elevação (DEM) do terceiro processamento, foi novamente identificada uma área avermelhada na região do bambuzal, embora em menor intensidade em comparação aos voos anteriores. Essa melhoria ocorreu devido à maior quantidade de imagens utilizadas no processamento, o que permitiu uma maior precisão na captura das informações da área em questão.

No processamento da ortoimagem, é possível observar esgarçamentos nas bordas e no telhamento em aço galvanizado, fato que reflete o que foi previamente justificado no Quadro 21. Embora a localização das câmeras e a sobreposição das imagens tenha sido superior a nove, o que deveria garantir uma maior cobertura e definição, o problema de esgarçamento persistiu. Isso pode estar relacionado aos parâmetros de processamento definidos, que influenciam a qualidade do alinhamento e interpolação das imagens. A combinação da densidade de pontos-chave, a qualidade das imagens e a presença de materiais com baixa textura, como o aço galvanizado, contribui para a inconsistência no processo de reconstrução, afetando a ortoimagem final.

Quadro 21 - Resultado do processamento do plano de voo realizado na BCE – 45 metros – 5 direções.



Continuação



Fonte: Elaborado pela autora.

5.3.1.1 Análise do Processamento Utilizando Novos Parâmetros

Com o objetivo de avaliar o padrão adotado para o processamento do ICC, Reitoria e UCA, os voos realizados na BCE e QGEx foram reprocessados utilizando o novo padrão configurado a partir do desempenho do computador, considerando o tempo e a agilidade do processamento. Essa abordagem buscou verificar melhorias na qualidade da ortomagem gerada. Para tanto, foram analisados apenas os voos realizados a 45 metros de altitude, dado que, embora possuíssem a mesma elevação, diferiam na quantidade de imagens capturadas.

Na Tabela 22, é apresentado o resultado desse novo processamento. Observa-se uma redução significativa no tempo de processamento da ortomagem referente ao voo em uma única direção (B1.1). Além disso, identificou-se uma diminuição no tamanho da ortomagem gerada, na resolução do Modelo Digital de Elevação (DEM) e no erro de projeção.

No caso do segundo processamento, referente ao voo em cinco direções (B1.2), houve um aumento no tempo de processamento e na resolução da ortomagem. Entretanto, a resolução do DEM diminuiu consideravelmente, o que contrasta com a redução do erro de projeção, indicando maior precisão nos resultados.

Esses dados sugerem que o novo padrão de processamento apresenta vantagens e desvantagens que variam de acordo com o tipo e a quantidade de dados de entrada, destacando a necessidade de ajustes nos parâmetros para alcançar um equilíbrio entre qualidade do produto e eficiência do processamento.

Tabela 22 - Resultados do processamento para a geração das ortomagens obtidas.

Amostras	Área (m ²)	Tempo (h)	Resolução (GB)	Digital Elevation Model - Resolution	Survey Data – Reprojection error
B1.1	256 m ²	0:06:58	1,04 GB	3,93 cm/pix	0,42 pix
B1.2	330 m ²	0:23:36	1,20 GB	4,23 cm/pix	1,59 pix

Fonte: Elaborado pela autora.

A Tabela 23 apresenta os parâmetros do processamento padrão estabelecidos para a realização dos novos experimentos realizados no edifício da BCE. As alterações destacadas em verde refletem ajustes implementados com o objetivo de solucionar problemas identificados no primeiro processamento.

Entre os ajustes realizados, destaca-se o aumento do valor do parâmetro *Key Point Limit*, que passou de 40.000 para 80.000, e a redução do valor do parâmetro *Tie Point Limit*, que foi ajustado de 10.000 para 8.000. Essas mudanças permitiram que o relatório detalhasse os parâmetros utilizados nos *workflows*, incluindo *Build Dense Cloud*, *Build Mesh*, *Build Texture* e *Build Tiled Model*.

Além disso, para o parâmetro *Surface* (superfície), optou-se pelo uso da malha (*Mesh*) na geração da ortoimagem. Essa escolha melhorou a qualidade do modelo final, aumentando a precisão da ortoimagem e garantindo um melhor alinhamento entre as etapas de processamento.

A utilização do *Mesh* é mais adequada para representar variações complexas, como superfícies detalhadas e irregulares (edifícios, fachadas ou telhados).

Tabela 23 - Dados dos parâmetros da etapa de processamento.

Parâmetros / Amostras	B1.1 – 1 direção	B1.2 – 5 direções
Align Photos		
Accuracy	Highest	Highest
Generic preselection	Yes	Yes
Key point limit	80,000	80,000
Tie point limit	8,000	8,000
Build Dense Cloud		
Quality	Medium	Medium
Depth filtering	Aggressive	Aggressive
Build Mesh		
Source data	Arbitrary	Dense
Surface type	Dense	Arbitrary
Interpolation	Disabled	Disabled
Quality	Medium	Medium
Build Texture		
Mapping mode	Orthophoto	Orthophoto
Blending mode	Mosaic	Mosaic
Build Tiled Model		
Source data	Dense cloud	Dense cloud
Face count	Low	Low
Build DEM		
Source data	Dense cloud	Dense cloud
Interpolation	Enabled	Enabled
Build Orthomosaic		
Surface	Mesh	Mesh
Blending mode	Mosaic	Mosaic
Hole filling	Yes	Yes

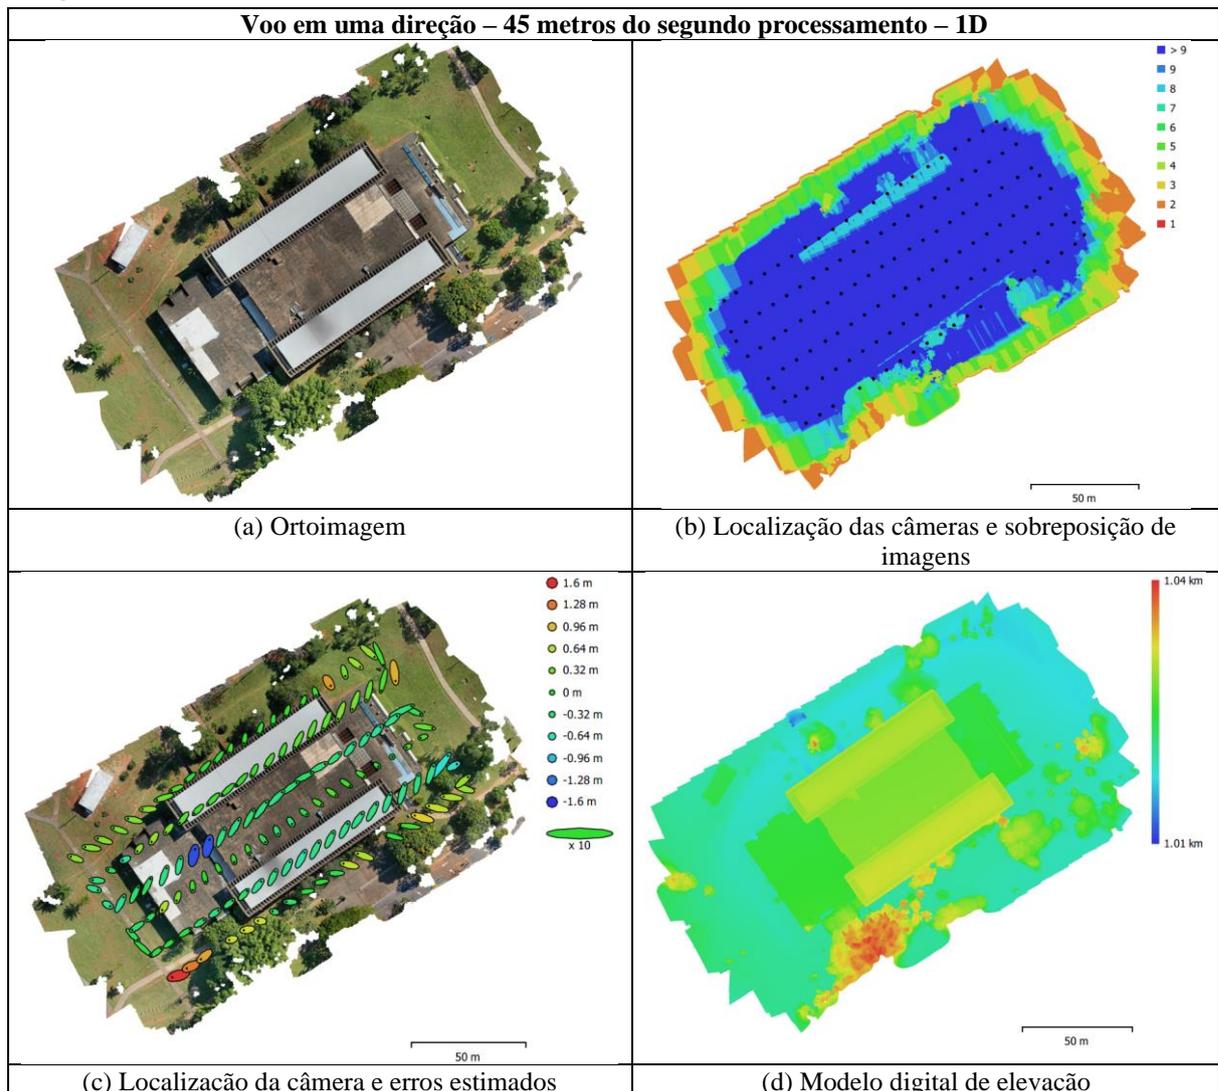
Fonte: Elaborado pela autora.

O novo processamento do voo em uma direção apresentou problemas relacionados à geração das bordas da ortoimagem, evidenciado pelo aumento na quantidade de buracos nas

áreas de vegetação (Quadro 22 e Quadro 23). Entretanto, houve uma melhora nas bordas dos pórticos do último nível do sistema de cobertura da BCE no modelo em cinco direções (Quadro 23), atribuída à alteração dos parâmetros *Key Point Limit* e *Tie Point Limit*.

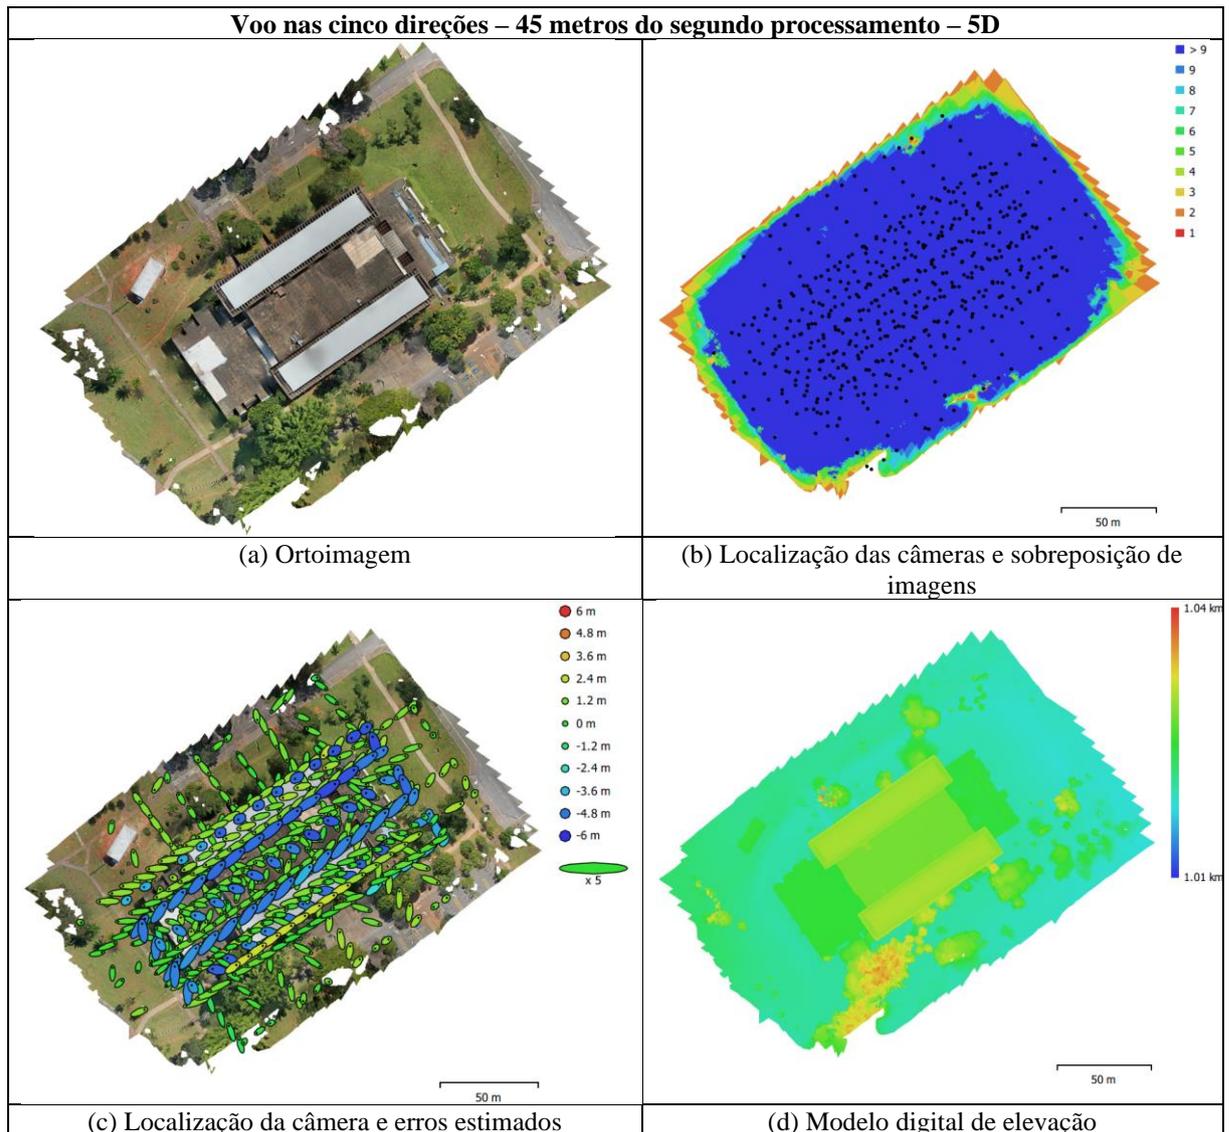
Os ajustes no *Key Point Limit* controlaram a quantidade de características extraídas por imagem, enquanto o *Tie Point Limit* regulou as correspondências úteis entre as imagens no alinhamento. Ambos os parâmetros influenciaram na ponderação entre a qualidade do modelo gerado e o tempo necessário para o processamento.

Quadro 22 - Resultado do reprocessamento com novos parâmetros da BCE – 45 metros – 1 direção.



Fonte: Elaborado pela autora.

Quadro 23 - Resultado do reprocessamento com novos parâmetros da BCE – 45 metros – 5 direções.



Fonte: Elaborado pela autora.

Na Figura 72, nota-se o surgimento de uma mancha escura no telhamento em aço galvanizado, semelhante à identificada no processamento realizado com voo em uma única direção a 45 metros de altitude. Essa recorrência, conforme já mencionado, sugere que o problema está associado às características intrínsecas do material metálico. Fatores como reflexões irregulares da luz e a homogeneidade da superfície comprometem a identificação de pontos-chave, impactando diretamente o alinhamento das imagens e a qualidade da ortorectificação gerada.

Figura 72 - Comparação entre o primeiro e o segundo processamento com 1 direção.



(a) Primeiro processamento 1 direção – 45m – Zoom de 28%.

(b) Segundo processamento 1 direção – 45 m – Zoom de 28%.

Fonte: A própria autora.

A realização desses processamentos visa à obtenção de representações precisas do sistema de cobertura e suas bordas, permitindo análises e avaliações detalhadas. Após o reprocessamento dos dois voos da BCE, constatou-se que a otimização dos parâmetros de configuração contribuiu significativamente para a geração de ortoimagens com menos imperfeições, conforme pode ser observado na Figura 73.

A principal preocupação reside na representação clara do sistema de cobertura e na identificação de vegetações circundantes, uma vez que estas podem comprometer a visualização do sistema devido ao sombreamento e à sobreposição da massa arbórea sobre a laje. Esses fatores destacam a importância do planejamento do voo e a configuração dos parâmetros do processamento para resultados precisos.

Figura 73 - Comparação entre o primeiro e o segundo processamento com 5 direções.



(a) Primeiro processamento 5 direções – 45 metros.

(b) Segundo processamento 5 direções – 45 metros.

Fonte: Elaborado pela autora.

Foi aplicado zoom de 70% em todos os quatro processamentos realizados, permitindo uma análise detalhada das ortoimagens (Figura 74), de modo a viabilizar a observação dos aspectos críticos da degradação do sistema de impermeabilização das coberturas. Verificou-se que, apesar das variações nos parâmetros e métodos de processamento, não houve diferenças significativas que comprometessem a visualização do sistema de cobertura. Esse resultado demonstra a consistência dos processamentos no que diz respeito à representação visual do sistema, mesmo com ajustes nos parâmetros de configuração.

Figura 74 - Verificação da qualidade da ortoimagem para visualização do padrão de fissuras na proteção mecânica.



(a) Primeiro processamento 1 direção – 45m – Zoom de 70%.



(b) Primeiro processamento 5 direções – 45 m – Zoom de 70%.



(c) Segundo processamento 1 direção – 45m – Zoom de 70%.



(d) Segundo processamento 5 direções – 45 m – Zoom de 70%.

Fonte: Elaborado pela autora.

O Modelo Digital de Elevação gerado pelo novo processamento do voo a 45 metros de altitude (Figura 75), realizado em uma única direção, apresentou dificuldades na definição da fachada que possuía os brises. Essas dificuldades ocorreram devido à baixa quantidade de imagens capturadas e à complexidade dos detalhes da edificação. A escassez de imagens contribuiu para a falta de pontos-chave necessários para uma reconstrução precisa, e a alta quantidade de detalhes na fachada dificultou a interpolação e a definição adequada das superfícies no modelo.

Figura 75 - Perspectiva do modelo digital de elevação do processamento – 45 metros - 1 direção.



Fonte: Elaborado pela autora.

A Figura 76 evidenciou dificuldades no processamento da parte inferior do pórtico da cobertura, o que impossibilitou a verificação da sobreposição dos sistemas de cobertura. Já na Figura 76b, por meio de uma inspeção in loco, permitiu identificar a presença de vegetação invasiva, resultante do acúmulo de água da chuva que se acumula no último nível do sistema e goteja para o nível inferior.

Figura 76 - Perspectiva do modelo digital de elevação do novo processamento – 45 metros - 1 direção.



Fonte: Elaborado pela autora.

A Figura 77 destaca as melhorias alcançadas no novo processamento digital realizado em cinco direções, quando comparado ao processamento em apenas uma direção. Na Figura 77a, observa-se uma construção mais detalhada do modelo dos brises, além de uma definição aprimorada da massa arbórea presente. Apesar da persistência de buracos no modelo digital, verifica-se uma diferença significativa, atribuída à maior diversidade de direções no plano de voo. Esse aumento na quantidade de imagens capturadas resultou em um volume superior de informações e em um reconhecimento mais eficiente dos pixels.

Figura 77 - Perspectiva do modelo digital de elevação do novo processamento – 45 metros - 5 direções.



Fonte: Elaborado pela autora.

5.3.2 Processamento Digital das Coberturas Planas da Reitoria

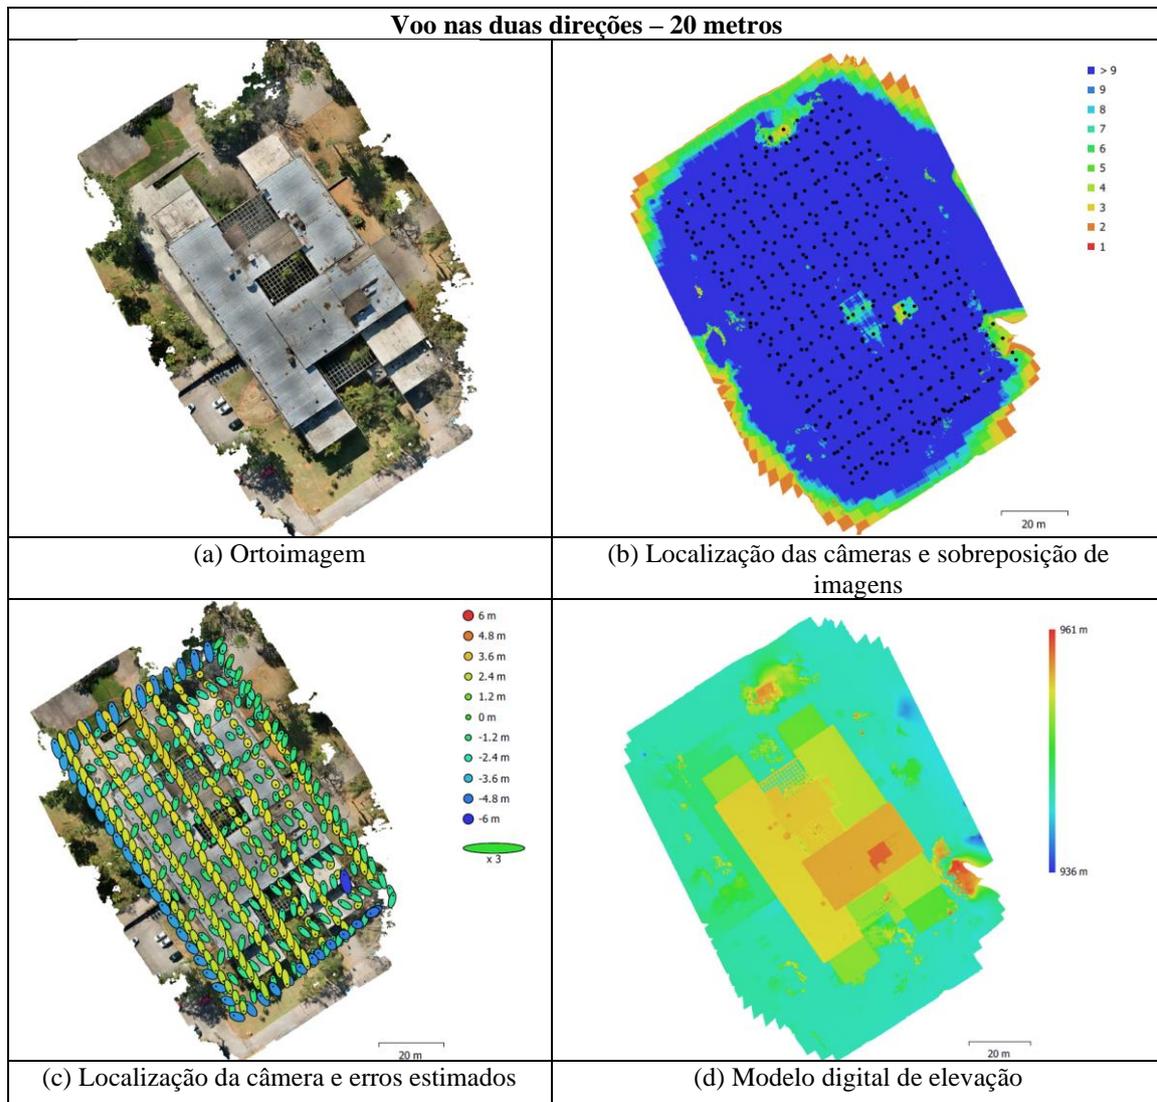
O processamento realizado no edifício da Reitoria demonstrou que quanto mais perto o drone da laje, menor será a quantidade de imagens obtidas para o processamento. Este fato pode ser observado (Quadro 24) quando comparadas a imagem (b) da localização das câmeras e sobreposição de imagens e a imagem (d) do modelo digital de elevação.

Diante disso, outra particularidade da Reitoria refere-se aos seus níveis que avançam uns sobre os outros, inviabilizando a correta visualização da ortoimagem gerada, sendo necessário a análise pelo modelo de elevação do processamento digital no software Agisoft, representado nas Figura 78, 79 e 80.

Um problema identificado foi na quantidade de vegetação que circundam a edificação, o que atrapalhou a construção do modelo digital de elevação. O outro fator são as sobreposições

dos planos de cobertura que inviabilizam a visualização da sua profundidade e a fachada envidraçada. A vegetação atuou como um elemento de obstrução, bloqueando a visão de áreas adjacentes e gerando zonas com informações insuficientes para uma interpolação precisa pelo software.

Quadro 24 - Resultado do processamento do plano de voo realizado na Reitoria – 20 metros – 2 direções.



Fonte: Elaborado pela autora.

O processamento realizado em duas direções a uma altitude de 20 metros mostrou-se insuficiente para lidar com a quantidade de vegetação que obstrui a visualização do sistema de cobertura. Esse tipo de obstáculo pode favorecer o acúmulo de folhas e provocar o entupimento de calhas e dutos, além de dificultar a análise de planos sobrepostos. Por essa razão, torna-se essencial a identificação desses pontos no Modelo Digital de Elevação (DEM) (Figura 82, Figura 83 e Figura 84) para posterior inspeção presencial pelo especialista, uma vez que tais sobreposições não são visíveis na ortofotografia gerada.

Outro fator que comprometeu a reconstrução da fachada no DEM foi a presença de áreas com vidro, devido às características específicas desse material. O vidro reflete a luz de maneira irregular, gerando reflexos e distorções que dificultam o reconhecimento preciso dos pontos-chave (*key points*) pelo software.

Figura 78 - Perspectiva do Modelo Digital de Elevação do novo processamento.



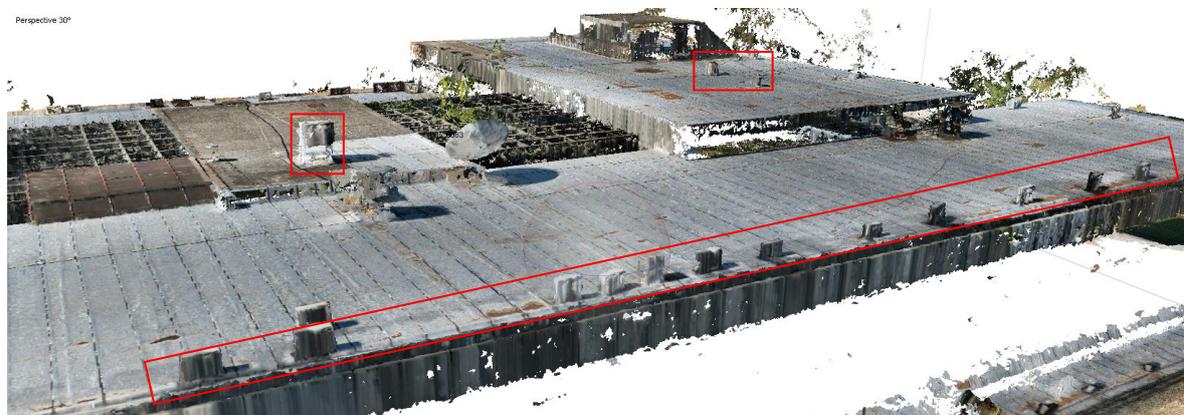
Fonte: Elaborado pela autora.

Figura 79 - Perspectivas das laterais do modelo digital de elevação do novo processamento.



Fonte: Elaborado pela autora.

Figura 80 - Perspectivas das laterais do modelo digital de elevação do novo processamento.



Fonte: Elaborado pela autora.

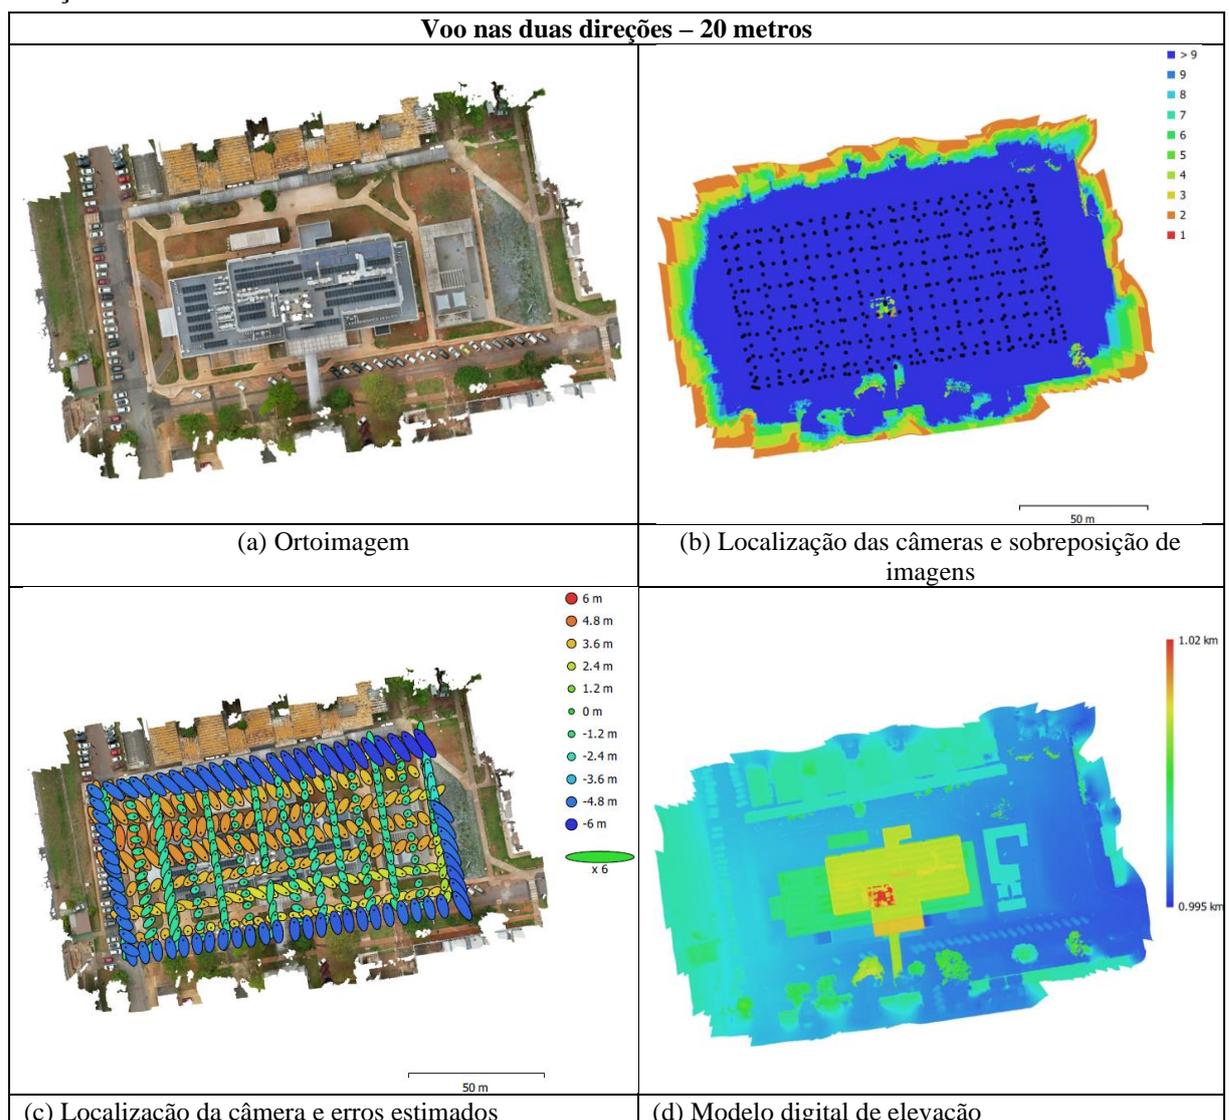
É possível identificar a presença dos equipamentos no sistema de cobertura, predominantemente localizados nas margens do sistema. Nessas áreas, as tubulações das

unidades condensadoras atravessam as placas de concreto da fachada. Adicionalmente, observa-se que os equipamentos situados na parte central do sistema de cobertura perfuram diretamente a laje para a passagem de tubulações, evidenciando um local que requer manutenção quanto à impermeabilização. Portanto, a qualidade do processamento digital nesses locais é relevante para os procedimentos de inspeção automatizada.

5.3.3 Processamento Digital das Coberturas Planas do HUB – UCA

O voo realizado a uma altitude de 20 metros em relação ao sistema de cobertura do edifício da UCA resultou em uma grande quantidade de imagens capturadas, com o plano de voo configurado em duas direções. No entanto, o último nível do sistema apresentou uma quantidade reduzida de imagens adquiridas, conforme ilustrado nas imagens (b) e (d) do Quadro 25 e na Figura 81. O resultado pode ser atribuído a reflexão do vidro dos equipamentos existentes e a proximidade entre eles, influenciando nas falhas do processamento.

Quadro 25 - Resultado do processamento do plano de voo realizado na UCA – 20 metros – 2 direções.



Fonte: Elaborado pela autora.

Figura 81 - Ortoimagem com as áreas do último nível sem processamento.



Fonte: Elaborado pela autora.

O modelo digital de elevação evidencia que, quanto menor a distância entre o drone e o sistema de cobertura, maior a quantidade de imagens capturadas, o que resulta em uma riqueza de detalhes na representação da edificação. As Figuras 82 e 83 ilustram esse nível de detalhamento, permitindo identificar com precisão o sistema de cobertura, bem como os equipamentos instalados, incluindo seu tipo e localização. No entanto, observa-se que o ângulo de captura utilizado pelo drone gerou inconsistências nas áreas próximas ao térreo, devido à menor quantidade de imagens adquiridas nessa região. Além disso, elementos como vidros e janelas, cujas propriedades ópticas dificultam o reconhecimento de pontos-chave pelo software, também contribuíram para as falhas observadas.

Figura 82 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 20 metros.



(a)



(b)

Fonte: Elaborado pela autora.

Figura 83 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 20 metros.



(a)



(b)

Fonte: Elaborado pela autora.

O modelo digital de elevação do último nível do sistema de cobertura, correspondente à caixa d'água, apresentou lacunas visíveis na Figura 84. Esses buracos resultam da proximidade entre esse nível e a altitude definida para a captura das imagens pelo drone, o que ocasionou uma menor quantidade de imagens registradas nessa região.

Figura 84 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 20 metros.

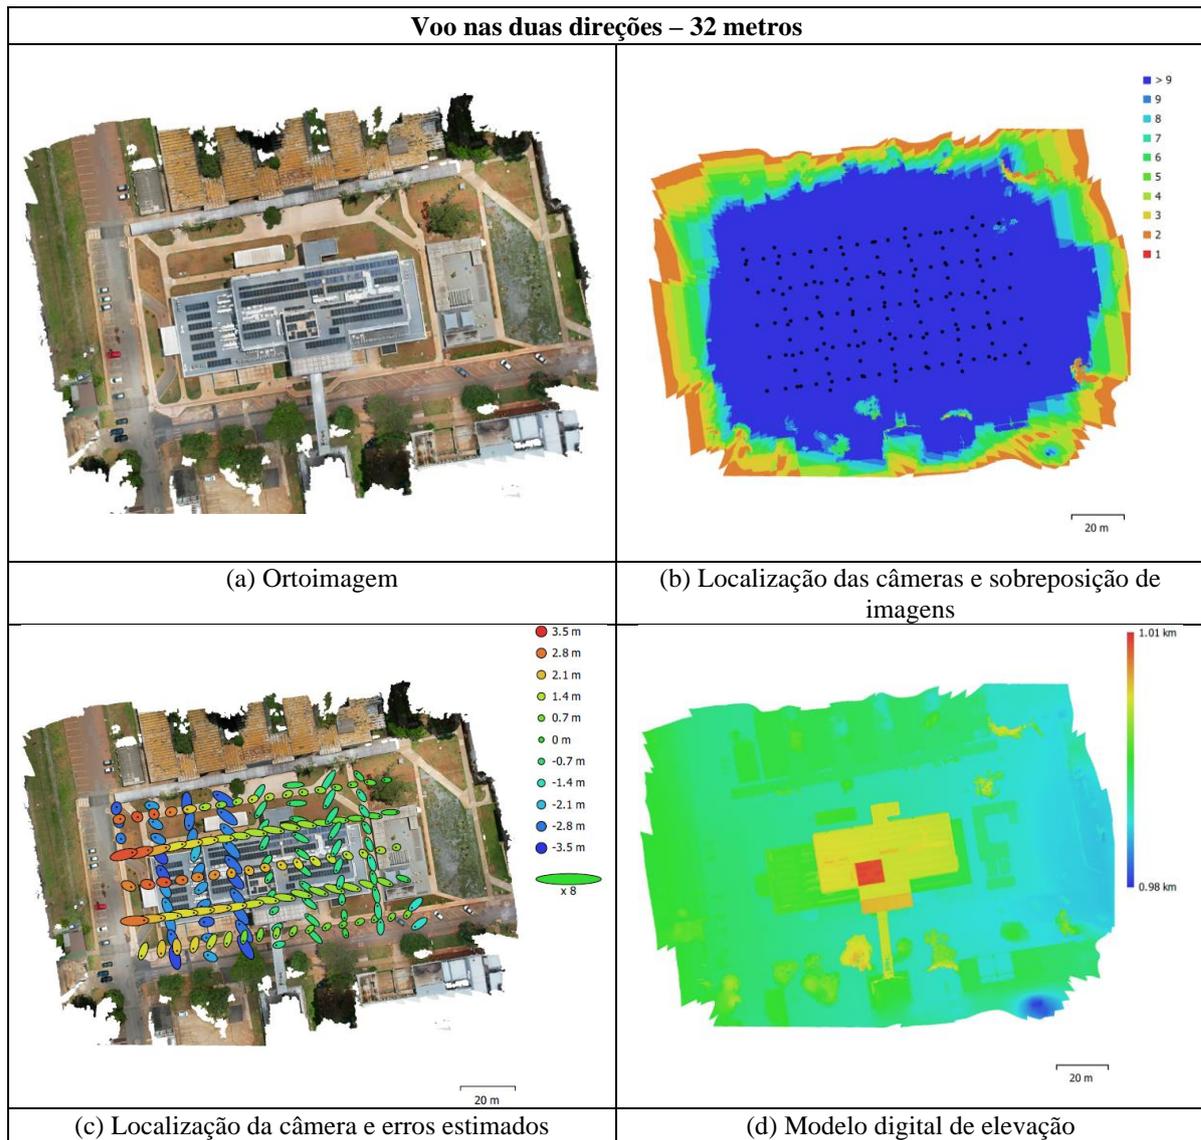


Fonte: Elaborado pela autora.

O plano de voo realizado a uma altitude de 32 metros revelou que o último nível do sistema de cobertura não apresentou áreas com menos de nove imagens sobrepostas, conforme observado na imagem (b) do Quadro 26. No entanto, no modelo digital de elevação (imagem d), o último nível é representado em vermelho, com valores próximos a 1,01 km na escala, indicando a representação digital da superfície associada a cada ponto. Esse dado confirma que o último nível da cobertura se encontra próximo à altitude definida para o plano de voo.

Verifica-se que, nessa altitude, o processamento não apresentou buracos significativos na edificação. O último nível do sistema de cobertura possui uma altura de 18,40 metros, resultando em uma diferença de 13,60 metros em relação à altitude do voo. Essa diferença foi considerada segura no aplicativo utilizado para a execução do plano de voo, garantindo a integridade das imagens e a qualidade do processamento realizado.

Quadro 26 - Resultado do processamento do plano de voo realizado na UCA – 32 metros – 2 direções.



Fonte: Elaborado pela autora.

O modelo digital de elevação (Figuras 85, 86 e 87) evidenciou que a quantidade de imagens capturadas não foi suficiente para uma definição adequada do modelo. Observou-se que as bordas da edificação foram melhor representadas, enquanto a fachada apresentou menor detalhamento. No entanto, vale salientar que o foco do estudo são os planos de cobertura. O resultado obtido decorre da altitude e do ângulo definidos para o plano de voo, bem como da quantidade reduzida de imagens capturadas nessas regiões, fatores que limitam a qualidade do modelo gerado.

Figura 85 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 32 metros.



Fonte: Elaborado pela autora.

Figura 86 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 32 metros.



Fonte: Elaborado pela autora.

A Figura 87 mostrou que a altitude de 32 metros foi adequada para a realização de uma inspeção detalhada no sistema de cobertura, permitindo a identificação dos tipos de equipamentos localizados nessa área. A captura das imagens nessas altitudes assegurou a visualização suficiente para análise, corroborando a eficácia do plano de voo para esse propósito específico.

Figura 87 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 32 metros.

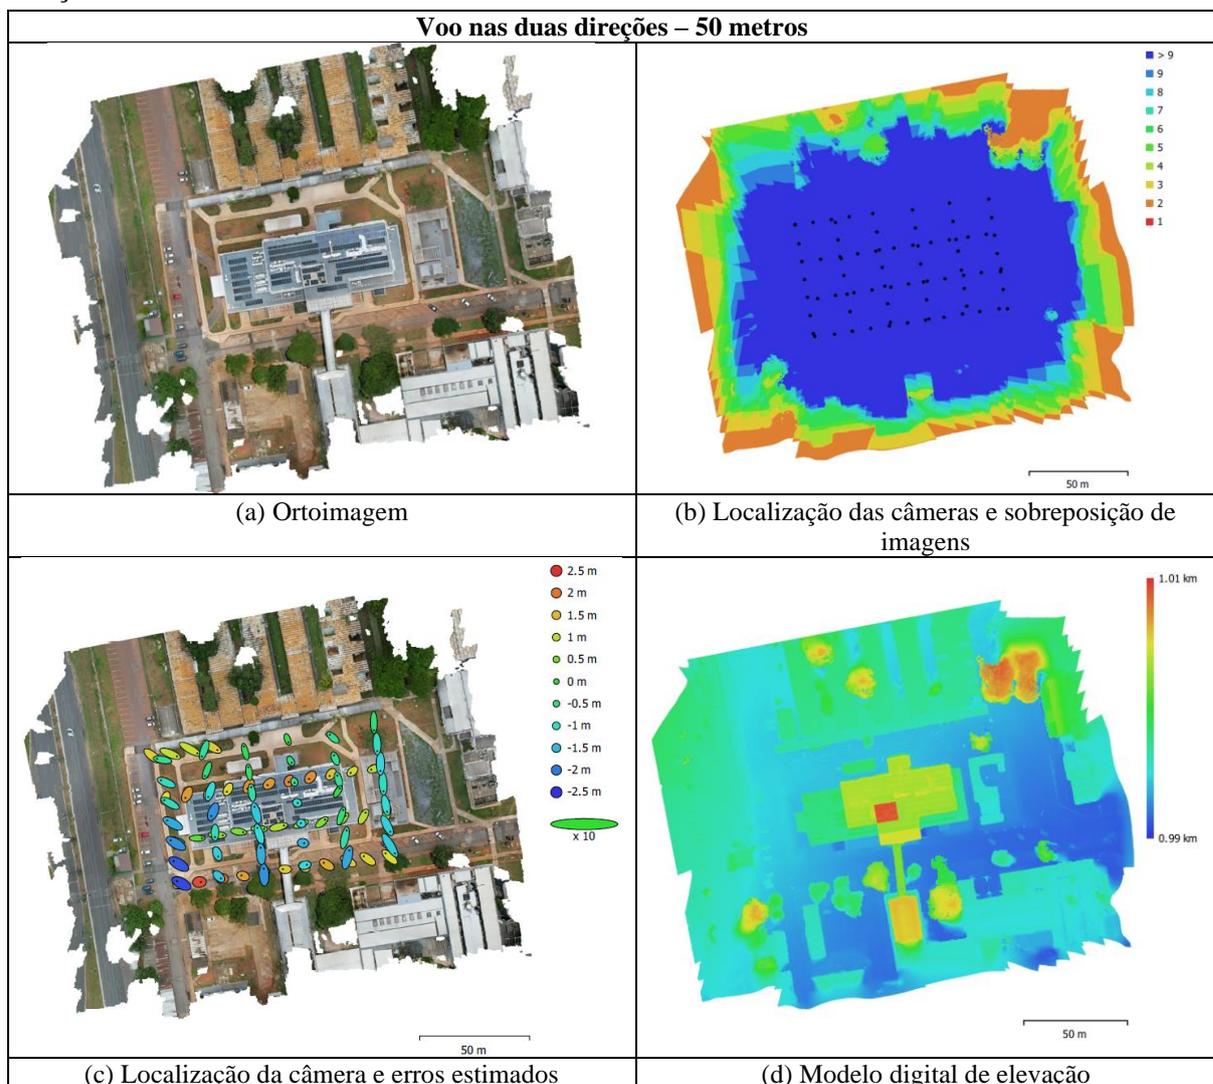


Fonte: Elaborado pela autora.

O último voo realizado no edifício da UCA, com uma altitude de 50 metros, apresentou a menor quantidade de imagens capturadas entre os três voos analisados. No modelo digital de elevação Quadro 27 (imagem d), o último nível do sistema de cobertura ainda aparece em vermelho, resultado da proximidade entre a altitude do plano de voo e a elevação do sistema. Essa condição evidencia as limitações da altitude do voo para a captura de detalhes mais precisos do último nível da edificação.

Adicionalmente, a resolução da ortoimagem diminuiu devido à menor quantidade de imagens capturadas e a maior distância entre o drone e o sistema de cobertura. Para esse voo, a ortoimagem apresentou uma resolução de 524 MB, abrangendo uma área superior à dos demais voos realizados, em função da altitude definida. Essas características reforçam o impacto da altura do voo na qualidade e no detalhamento das imagens capturadas.

Quadro 27 - Resultado do processamento do plano de voo realizado na UCA – 50 metros – 2 direções.



Fonte: Elaborado pela autora.

O modelo digital de elevação gerado para o voo realizado a 50 metros apresentou uma quantidade significativa de buracos em branco, consequência direta da reduzida quantidade de imagens capturadas. Em comparação com os voos realizados a 20 e 32 metros de altitudes, nota-se uma falta de definição mais evidente, especialmente na identificação de equipamentos localizados no sistema de cobertura, como observado na Figura 88, 89 e 90. Essa limitação dificulta a identificação precisa do tipo de equipamentos, seu modo de instalação e a identificação de manifestações patológicas no sistema de cobertura.

No caso de um edifício hospitalar, como o analisado, essa deficiência adquire maior relevância, considerando que tais equipamentos são essenciais para o funcionamento contínuo da edificação e a realização de suas atividades diurnas e noturnas. Além disso, a função primária desse tipo de edifício é promover a cura e o bem-estar dos pacientes. Portanto, a inspeção e a verificação adequada dos equipamentos no sistema de cobertura estão diretamente ligadas à qualidade do trabalho dos profissionais da saúde, tornando-se uma etapa indispensável na manutenção e operação segura do edifício.

Figura 88 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 50 metros.



Fonte: Elaborado pela autora.

Figura 89 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 50 metros.



(a)

(b)

Fonte: Elaborado pela autora.

Figura 90 - Perspectivas das laterais do modelo digital de elevação do novo processamento – 2 direções - 50 metros.



Fonte: Elaborado pela autora.

Ao determinar a altitude para a realização de um plano de voo, é fundamental considerar se as informações obtidas serão adequadas às necessidades do projeto, evitando escolhas que priorizem apenas a rapidez da execução em detrimento da eficiência e precisão dos resultados. Um plano de voo eficaz exige o levantamento do modelo digital de superfície. Mesmo com alta *accuracy*, pode-se obter resultados insatisfatórios em termos de precisão e definição da superfície.

Dessa forma, é essencial que os objetivos do inspetor sejam claramente definidos, incluindo os tipos de informações a serem coletadas e o grau de detalhamento necessário. A altitude e a quantidade de direções do voo são fatores determinantes para alcançar os requisitos estabelecidos. Um planejamento inadequado pode comprometer a qualidade do modelo gerado, reduzindo sua utilidade para inspeções e análises mais detalhadas, principalmente dos equipamentos presentes em coberturas.

5.4 ANÁLISE DO PROCESSAMENTO DIGITAL DE COBERTURAS LINEARES

Para a análise do planejamento de voos e processamento digital de coberturas lineares, foram selecionadas as coberturas dos edifícios do conjunto do QGEx assim como as dos blocos A e B do ICC. Os edifícios do QGEx destacam-se por suas características construtivas semelhantes, com elementos arquitetônicos repetitivos dispostos em blocos paralelos. Já o ICC foi escolhido devido à sua grande extensão linear, composto por dois blocos paralelos com curvatura.

Ambos os projetos foram concebidos pelo arquiteto Oscar Niemeyer, apresentando uma linguagem arquitetônica que reflete suas funções, em uma arquitetura modernista em elementos

pré-fabricados em concreto armado. Apesar das diferenças nos usos das edificações, os sistemas de cobertura expressam a linguagem dos grandes planos horizontais da arquitetura moderna.

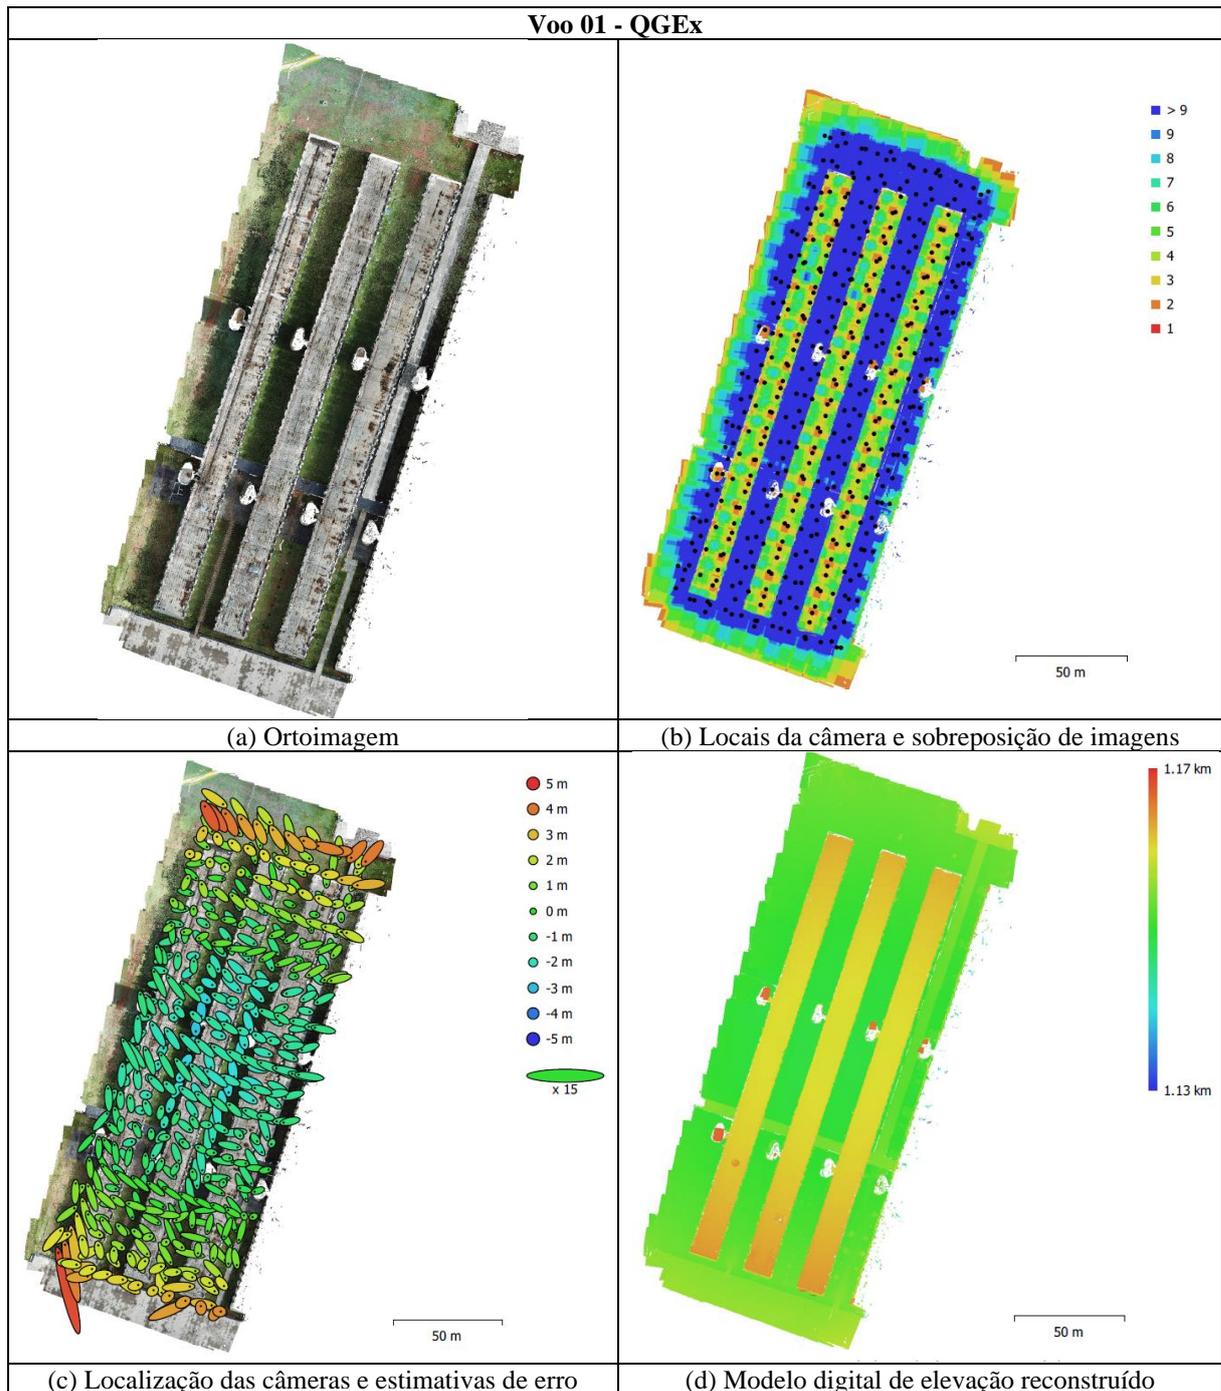
5.4.1 Processamento Digital das Coberturas Lineares dos Edifícios do QGEx

Para analisar o processamento de imagens do conjunto edificado do QGEx, foi planejado três planos de voo executados em dias diferentes, devido à limitação da quantidade de baterias disponíveis. A configuração longitudinal das edificações, implantadas em 9 blocos paralelos, destacou-se como um diferencial, influenciando significativamente o processamento das imagens.

No primeiro plano de voo, foram consideradas três edificações, com uma sobreposição transversal e longitudinal de 60%. Esse parâmetro foi escolhido para avaliar o impacto da sobreposição do processamento, especialmente na ocorrência de buracos nas imagens, que foram mais frequentes nas caixas d'água devido ao seu formato distinto em relação à geometria das lajes de cobertura das edificações. Devido à altitude adotada, a proximidade das caixas d'água ao drone durante o voo resultou em uma menor quantidade de imagens capturadas, acentuando as limitações no modelo gerado.

A imagem (b) da Quadro 28 evidencia que, mesmo com a execução de voos em duas direções, o número de linhas de voo foi insuficiente para a captura detalhada do sistema de cobertura, variando entre uma ou duas linhas por edificação. Essa limitação ocorreu em função da escolha dos valores de sobreposição e da altitude restrita a 22 metros, necessária para evitar o risco de colisão com as caixas d'água, que apresentam altura superior às demais estruturas. Como resultado, o processamento não atingiu uma resolução satisfatória para avaliação detalhada do sistema de cobertura. Contudo, o banco de imagens gerado foi de grande relevância para análises posteriores, realizadas por meio de processos automatizados.

Quadro 28 - Resultado do processamento do plano de voo realizado no QGEx – 22 metros – 2 direções.



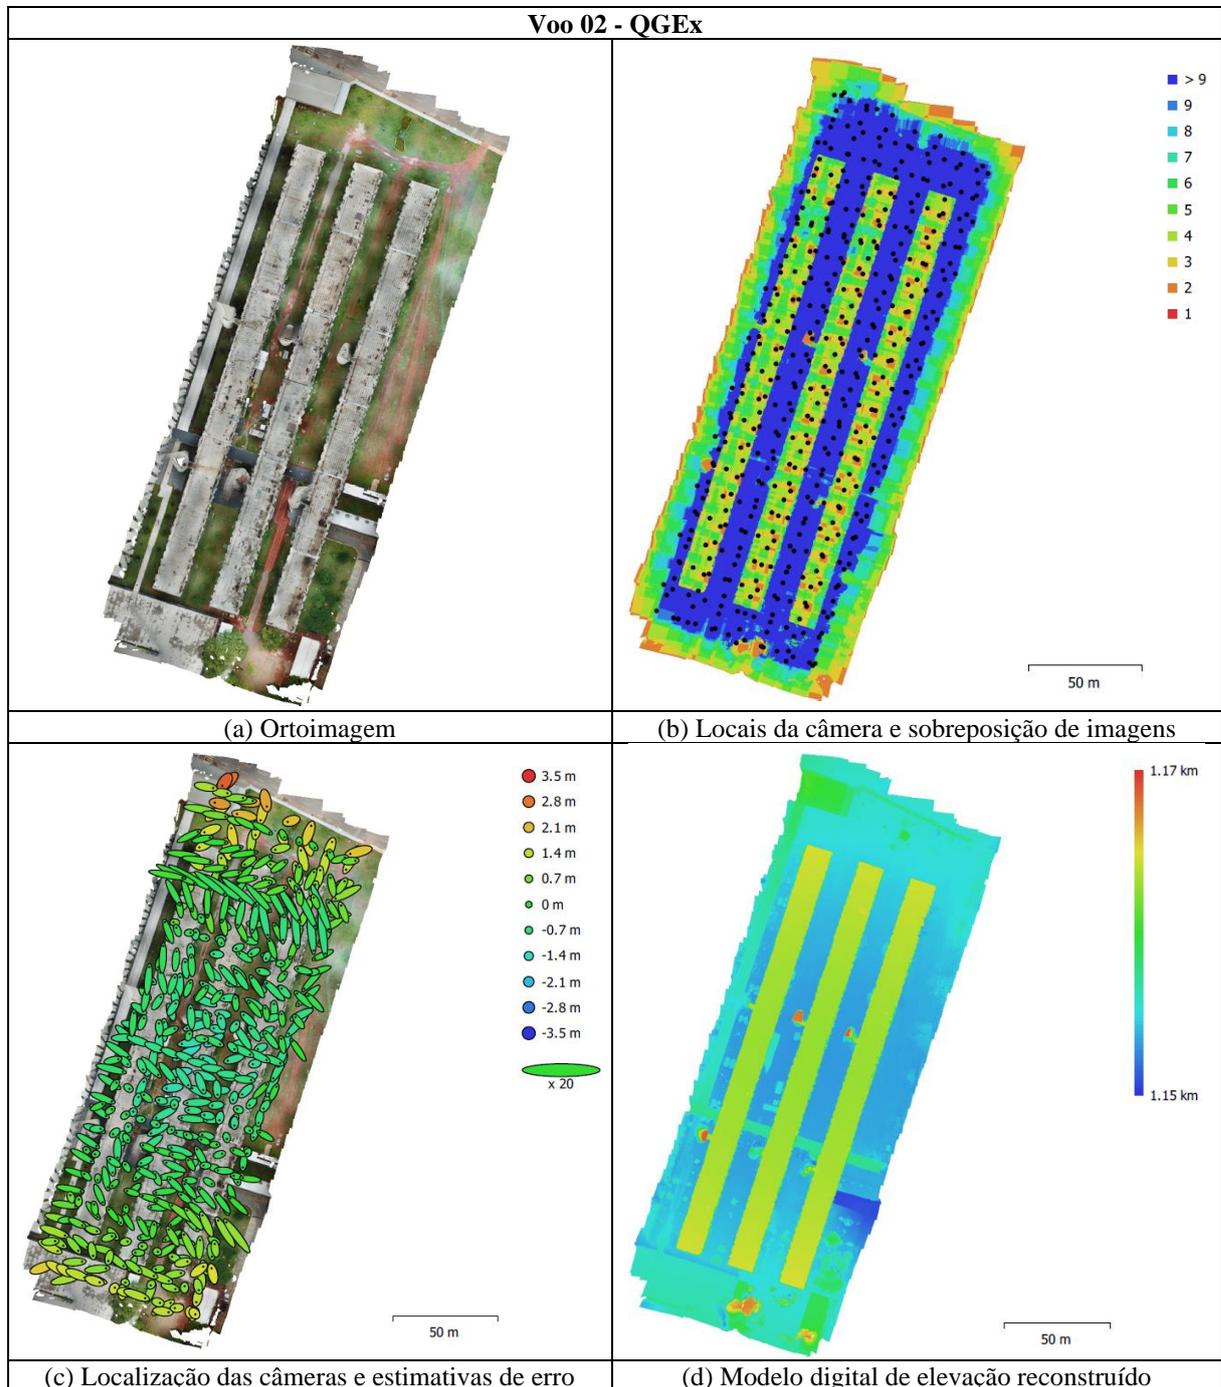
Fonte: Elaborado pela autora.

O segundo voo realizado apresentou problemas similares aos identificados no primeiro, relacionados à quantidade reduzida de linhas de voo e à sobreposição selecionada para o plano de voo. Esse aspecto é ilustrado na imagem (b) do Quadro 29. No entanto, diferentemente do primeiro voo, neste não foram observados buracos nas áreas das escadas.

Apesar de os mesmos parâmetros terem sido utilizados em ambos os processamentos, os voos ocorreram em dias diferentes, o que pode ter influenciado as condições climáticas para

a captura das imagens. Essas condições evidenciam a necessidade de ajustes e validações durante a execução dos planos de voo para assegurar a qualidade dos dados gerados.

Quadro 29 - Resultado do processamento do plano de voo realizado no QGEx – 22 metros – 2 direções.



Fonte: Elaborado pela autora.

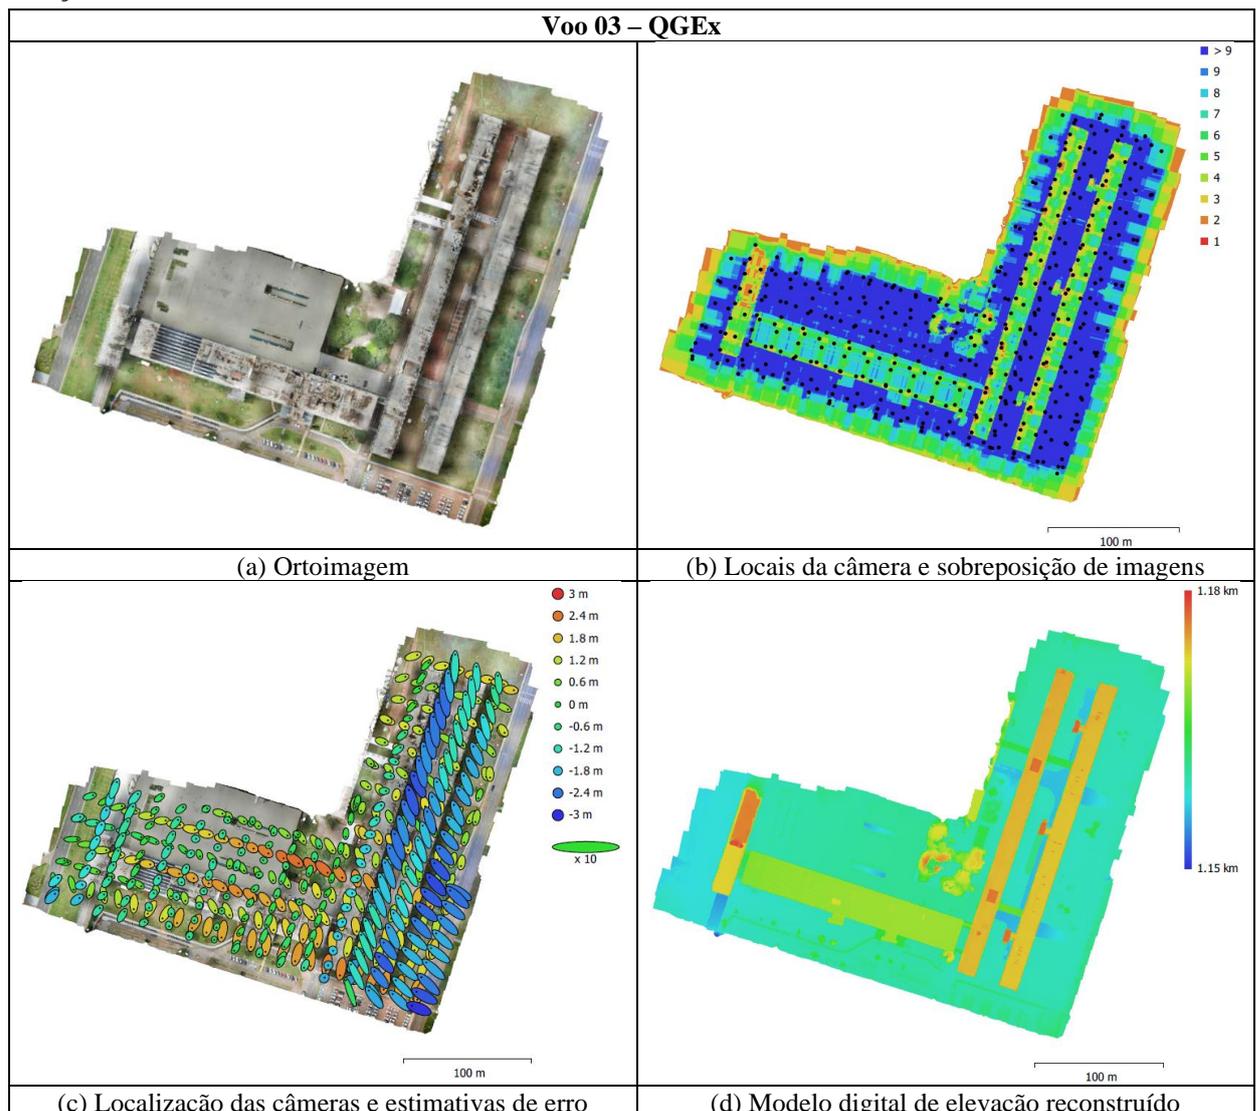
Para o terceiro e último voo, que abrangeu as três últimas edificações analisadas, foi definida uma altitude de 35 metros, devido à presença de uma antena de transmissão com 15 metros de altura posicionada acima do sistema de cobertura da edificação mais baixa, cuja altura é de 8,45 metros. Além disso, as duas últimas edificações à direita, que possuem alturas

superiores às demais, também influenciaram na escolha dessa altitude, diferenciando esse voo dos dois anteriores realizados no conjunto edificado.

Como apresentado no Quadro 30, a imagem (a) não atingiu uma qualidade satisfatória, com a ortomagem resultante apresentando manchas que comprometem a análise do sistema de cobertura. Adicionalmente, a imagem (b) evidenciou novamente o problema relacionado à quantidade limitada de imagens adquiridas, fator diretamente relacionado ao formato longilíneo e alongado das edificações. Esse formato resultou em um número insuficiente de linhas de voo para a captura adequada das imagens necessárias ao processamento, impactando a precisão e a qualidade dos resultados.

Ao analisar os dados constatou-se que os locais da captura da câmera e a sobreposição das imagens variou entre 3 e 8, reforçando a necessidade de ajustes nos parâmetros de voo para atender à especificidade geométrica das edificações e garantir resultados mais precisos.

Quadro 30 - Resultado do processamento do plano de voo realizado no QGEx – 35 metros – 2 direções.



Fonte: Elaborado pela autora.

5.4.1.1 Análise do Processamento Utilizando Novos Parâmetros

Os parâmetros de processamento foram ajustados para se adequarem à capacidade do *hardware* utilizado, permitindo avaliar como essas modificações impactam na geração da ortoimagem. Na Tabela 24, são apresentados os novos parâmetros aplicados, destacando em negrito e verde as diferenças.

No primeiro processamento (N1.1), todos os parâmetros foram mantidos iguais para todas as etapas realizadas, sendo a única diferença observada o tempo total de processamento, que aumentou em 1 minuto e 12 segundos.

Para o processamento N1.2, foram feitas alterações do parâmetro *Build Dense Cloud* (geração da nuvem de pontos densa), reduzindo a *Quality* de *High* para *Medium*. Essa mudança provocou uma redução de 4x4 na dimensão das imagens, o que diminuiu significativamente o tempo necessário para construir a nuvem de pontos densa, uma vez que o tamanho da amostra de cada imagem foi reduzido.

Outro ajuste significativo foi no parâmetro *Build Mesh* (geração da malha), que foi alterado de *Enabled* para *Disabled*. Com a *Interpolation* desativada (*Disabled*), áreas com maior densidade de pontos foram reconstruídas com maior precisão, eliminando reconstruções artificiais em regiões de baixa densidade de pontos. Essa modificação impactou drasticamente o tempo de processamento, que foi reduzido de 2 dias e 10 horas para apenas 1 hora e 32 minutos.

Os parâmetros *Build Texture* e *Build DEM* mantiveram suas configurações originais. O *Build Texture* define como os pixels de diferentes imagens serão combinados na textura final, melhorando a qualidade visual do modelo. Já o *Build DEM* calculou o Modelo Digital de Elevação (DEM) para todas as áreas visíveis em pelo menos uma imagem, sem alterações em relação aos processamentos anteriores.

No primeiro processamento do último voo, a etapa *Build Tiled Model* não foi configurada, possivelmente em função da prioridade dada à otimização do tempo de processamento e do uso eficiente dos recursos computacionais disponíveis. Essa etapa é responsável por criar modelos 3D em camadas e a sua ausência no processamento inicial pode indicar que o objetivo estava limitado à geração da ortoimagem, sem a intenção de desenvolver recursos adicionais para visualização tridimensional interativa.

Tabela 24 - Dados dos parâmetros da etapa de processamento.

Parâmetros/Amostras	N1.1	N1.2	N1.3
Align Photos			
Accuracy	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>
Generic preselection	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
Key point limit	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>
Tie point limit	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>
Tempo de processamento	<i>1h 29min</i>	<i>1h 5min</i>	<i>23min 22s</i>
Build Dense Cloud			
Quality	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
Depth filtering	<i>Aggressive</i>	<i>Aggressive</i>	<i>Aggressive</i>
Tempo de processamento	<i>11min 58s</i>	<i>11min 24s</i>	<i>13min 25s</i>
Build Mesh			
Source data	<i>Arbitrary</i>	<i>Dense</i>	<i>Dense</i>
Surface type	<i>Dense</i>	<i>Arbitrary</i>	<i>Arbitrary</i>
Interpolation	<i>Disabled</i>	<i>Disabled</i>	<i>Disabled</i>
Quality	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
Tempo de processamento	<i>1h 36min</i>	<i>1h 32min</i>	<i>1h 47s</i>
Build Texture			
Mapping mode	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>
Blending mode	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
Tempo de processamento	<i>42min 05s</i>	<i>1h 32min</i>	<i>1h 47min</i>
Build Tiled Model			
Source data	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>
Face count	<i>Low</i>	<i>Low</i>	<i>Low</i>
Tempo de processamento	<i>5h 51min</i>	<i>05h 33min</i>	<i>9h 52min</i>
Build DEM			
Source data	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>
Interpolation	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>
Tempo de processamento	<i>02min 22s</i>	<i>03min 05s</i>	<i>3min 43s</i>
Build Orthomosaic			
Surface	<i>Mesh</i>	<i>Mesh</i>	<i>Mesh</i>
Blending mode	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
Hole filling	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
Tempo de processamento	<i>25min e 32s</i>	<i>23h 40min</i>	<i>38min 3s</i>

Fonte: Elaborado pela autora.

A Tabela 25 apresentou as alterações resultantes das mudanças de parâmetros nos três processamentos realizados para a geração da ortoimagem. Em relação ao tempo de processamento, o N1.1 registrou um aumento de 1 minuto e 12 segundos, o N1.2 apresentou uma redução de 3 minutos e 31 segundos, e o N1.3 indicou um aumento de 25 minutos e 45 segundos. Esses dados evidenciam como a variação nos parâmetros afeta diretamente o tempo de execução.

Quanto à resolução da ortoimagem (em mm/pixel), o N1.1 manteve os valores do processamento digital, enquanto no N1.2 houve uma redução no tamanho do arquivo, passando de 2,82 GB para 2,25 GB, e no N1.3 verificou-se um aumento de 2,36 GB para 2,29 GB (Tabela 25). Observou-se uma relação direta entre o tempo de processamento e a resolução da

ortoimagem: tempos maiores resultam em maior resolução. Embora uma resolução alta seja essencial para análises detalhadas e inspeções prediais, sua relevância depende do contexto e do objetivo principal do plano de voo. Em certos casos, uma resolução mais baixa pode ser suficiente, desde que atenda aos requisitos específicos da análise.

Para o *Digital Elevation Model (DEM)*, a resolução manteve-se inalterada no N1.1 devido à manutenção dos parâmetros originais. No entanto, o N1.2 apresentou um aumento, passando de 1,16 cm/pixel para 2,34 cm/pixel, enquanto o N1.3 teve uma variação mínima, subindo de 3,94 cm/pixel para 3,95 cm/pixel.

No caso do *Survey Data – Reprojection Error*, os valores permaneceram constantes nos processamentos N1.1 e N1.3, mas diminuíram no N1.2, sugerindo uma leve melhoria na precisão de reprojeção das imagens nesse cenário. Esses resultados destacam a importância de ajustar os parâmetros de processamento com base no equilíbrio entre qualidade e produto, tempo de processamento e os objetivos específicos de cada aplicação.

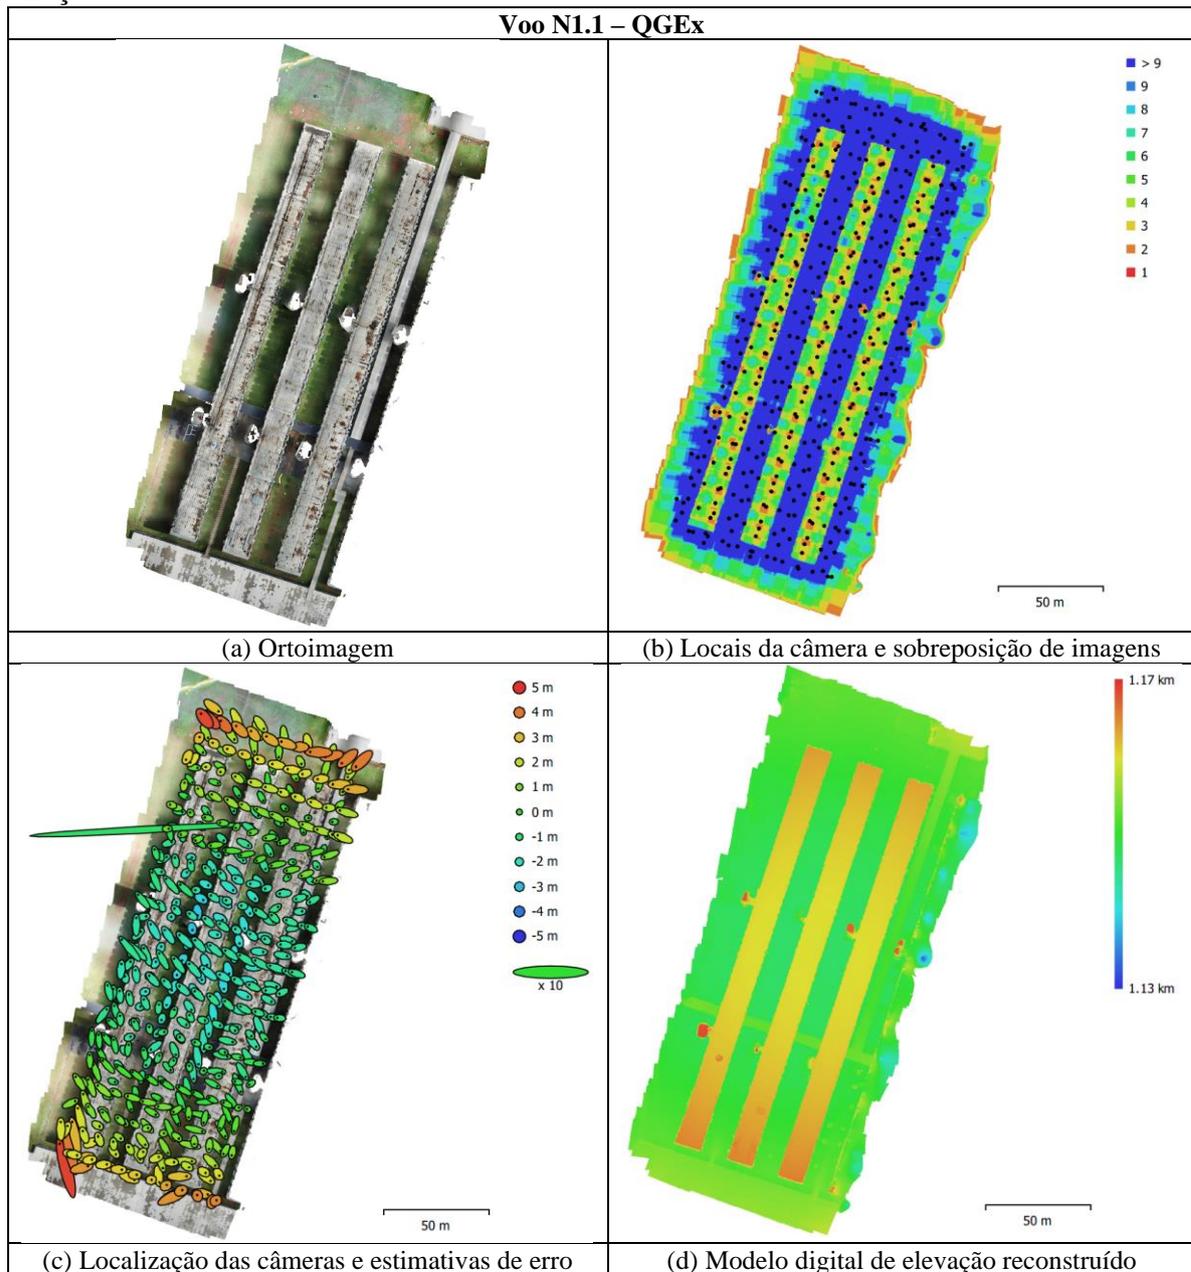
Tabela 25 - Resultados do processamento para a geração das ortoimagens obtidas.

Amostras	Área (m ²)	Tempo (h)	Resolução (GB)	Digital Elevation Model - Resolution	Survey Data – Reprojection error	
QGE _x	N1.1	2 hectares	0:25:32	2,58 GB	2,37 cm/pix	0,957 pix
	N1.2	2 hectares	0:23:40	2,25 GB	2,34 cm/pix	1,35 pix
	N1.3	5 hectares	0:38:03	2,29 GB	3,95 cm/pix	1,23 pix

Fonte: Elaborado pela autora.

Diante do exposto, o processamento N1.1 apresentou uma diferença específica na imagem (d), relacionada ao reconhecimento do formato da caixa de escada. Apesar dessa variação, não houve alterações significativas na ortoimagem gerada, conforme verificado no Quadro 31. Essa constatação demonstra que a manutenção dos parâmetros originais garantiu a consistência dos resultados, sendo as mudanças observadas limitadas a detalhes do modelo tridimensional, sem impacto relevante na qualidade geral da ortoimagem.

Quadro 31 - Resultado do processamento do plano de voo realizado no QGEx – 22 metros – 2 direções.



Fonte: Elaborado pela autora.

Tratando-se do formato deste sistema de cobertura do QGEx, o processamento do N1.2 sofreu uma alteração do parâmetro *Quality* para *Medium*, impactando diretamente a construção da nuvem de pontos densa (Quadro 32). Isso resultou na redução das imagens em uma escala de 4x4, comprometendo a obtenção de uma geometria detalhada e precisa, já que níveis maiores de detalhamento demandam mais tempo de processamento.

A escolha do *Depth filtering* em *Agressive* instruiu o software a eliminar a maior quantidade possível de *outliers*. Essa configuração é ideal para modelos que não necessitam de pequenos detalhes, sendo menos adequada para representações que requerem precisão máxima. Outras opções, como *Mild*, *Moderate* ou *Disable*, tendem a lidar de maneira permissiva com os

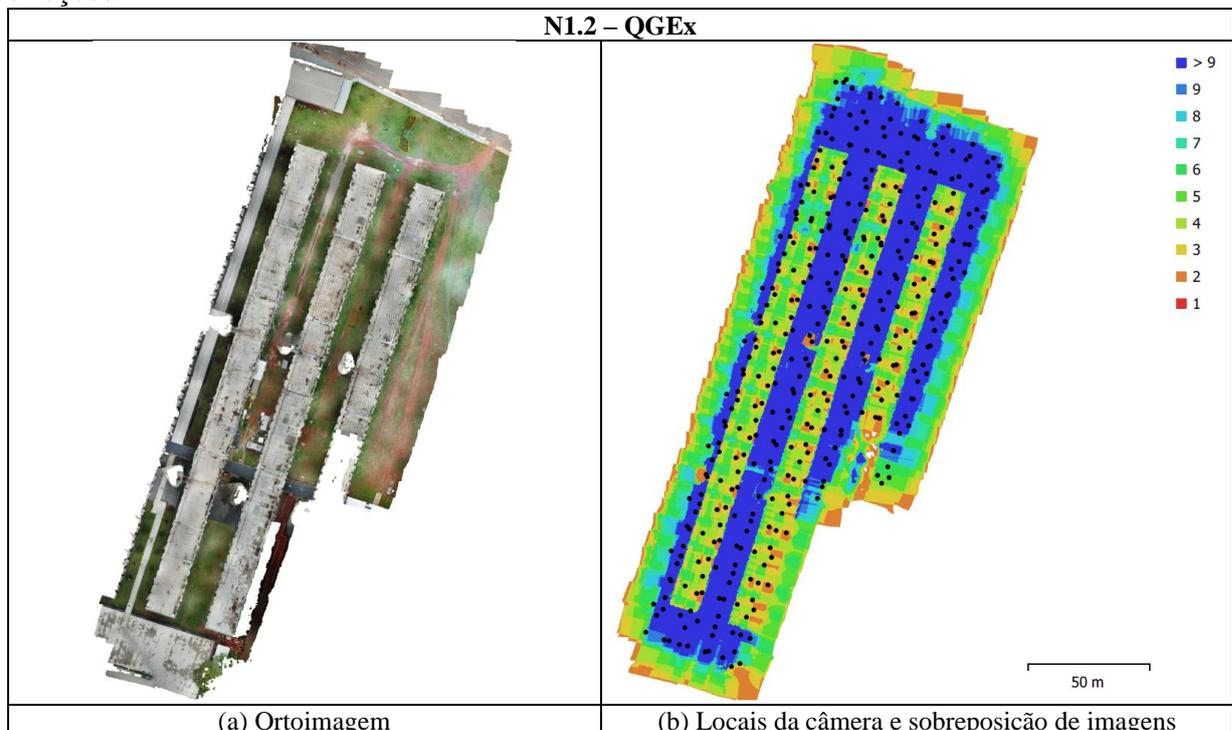
outliers, permitindo que o software represente mais detalhes da superfície, mas resultando em uma nuvem densa com mais ruídos. Em modelos com formas orgânicas ou superfícies complexas, a opção desabilitada pode ser mais vantajosa, apesar de introduzir maior quantidade de ruídos.

No estágio de geração da nuvem densa, o software calculou mapas de profundidade para cada imagem. Nesse caso, a configuração das edificações, os valores definidos para as taxas de sobreposição, e a quantidade reduzida de linhas no plano de voo influenciaram diretamente os problemas observados no processamento.

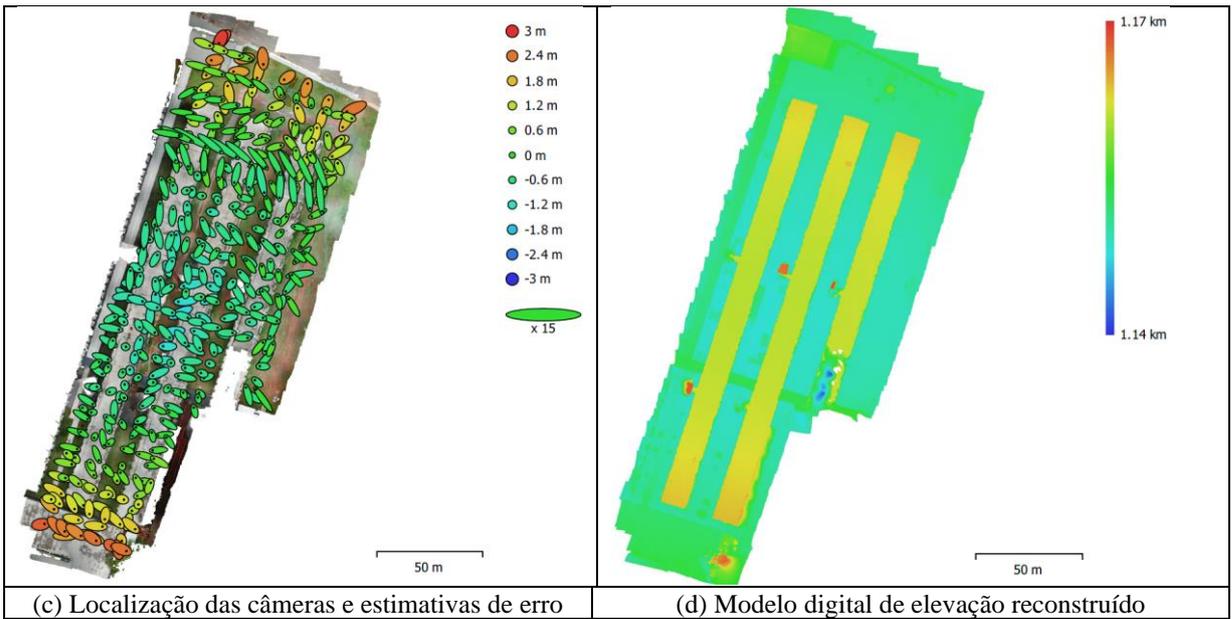
Nos primeiros processamentos realizados, os planos de voo QGEx 2 e QGEx 3 não aplicaram estágio *Build Tiled Model*, pois os parâmetros para essa etapa não foram configurados. No processamento N1.2, foi aplicada a construção da ortomagem utilizando a nuvem densa como fonte de dados (*Source data*) e configurando a contagem de faces (*Face count*) para *Low*, o que reduz a resolução da imagem em uma escala de 8x8.

Para o estágio *Orthomosaic*, o parâmetro DEM (modelo digital de elevação) foi substituído por *Mesh* (malha). Enquanto o DEM é eficiente para o processamento de levantamentos aéreos e otimiza o tempo na geração da malha, o *Mesh* possibilitou a criação de ortomagens mais definidas, adequados para aplicações que exigem maior precisão nos detalhes.

Quadro 32 - Resultado do processamento do plano de voo realizado no QGEx – 22 metros – 2 direções.



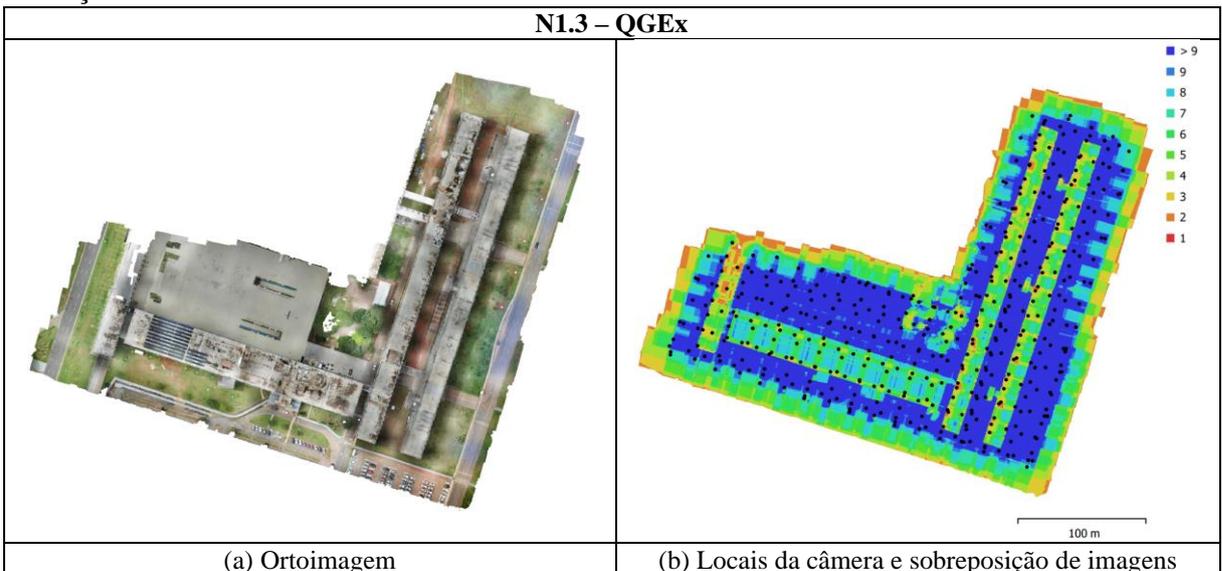
Continuação



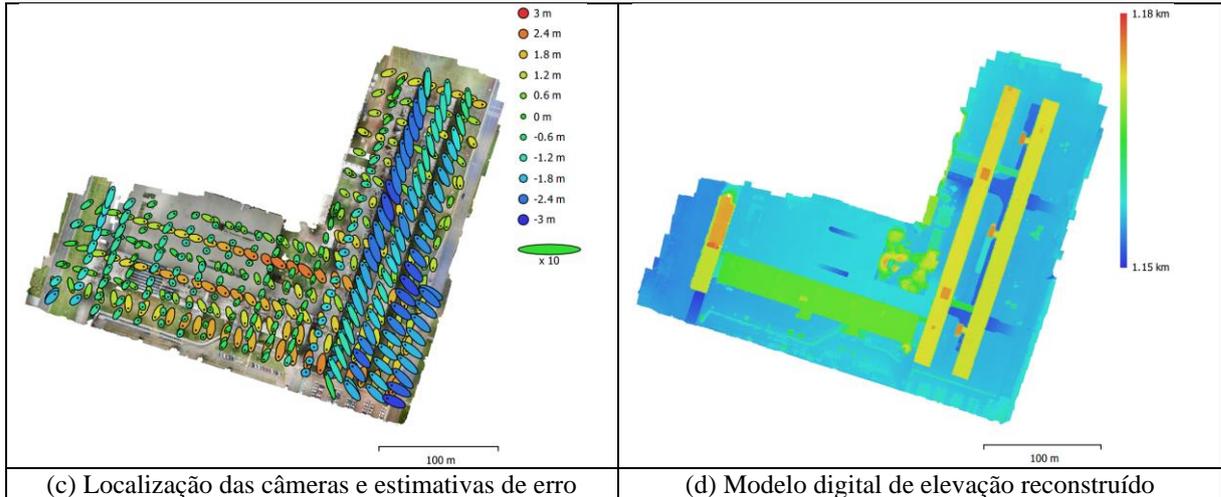
Fonte: Elaborado pela autora.

O Quadro 33 apresenta a imagem (d) com um Modelo Digital de Elevação (DEM) que possui cores mais próximas a 1,15 km. Embora essa alteração visual nas cores do DEM tenha ocorrido, ela não afetou a precisão ou a resolução do modelo de elevação gerado, mantendo a qualidade do processamento. Por outro lado, as demais imagens não apresentaram nenhuma diferenciação significativa em relação ao que foi observado no Quadro 30, indicando que as configurações de processamento não impactaram negativamente na resolução ou na qualidade dos resultados obtidos.

Quadro 33 - Resultado do reprocessamento do plano de voo realizado no QGEx – 35 metros – 2 direções.



Continuação



Fonte: Elaborado pela autora.

5.4.2 Processamento Digital das Coberturas Lineares dos Blocos A e B do ICC

No ICC, foram realizados oito planos de voo, iniciando pelo Bloco B e, posteriormente, pelo Bloco A. A sequência adotada visou definir a altitude ideal dos voos, considerando a presença de uma antena localizada sobre o Bloco B, que representava um elemento crítico para o planejamento e execução segura das operações. Os demais resultados dos processamentos dos Blocos A e B estão no Apêndice D.

No ICC ala Sul, os voos realizados tiveram como objetivo o ajuste dos parâmetros de acordo com os resultados obtidos. Nesse contexto, foram realizados cinco planos de voo no Bloco B, número limitado pela quantidade de baterias disponíveis no período da execução.

Um teste específico foi conduzido no Bloco B para avaliar a direção das linhas de voo. Nos voos 2 e 4 da Figura 91, as linhas foram ajustadas na direção longitudinal, visando identificar possíveis alterações no processamento dos segmentos da cobertura, especialmente nas áreas que apresentam seções em curvatura. Esses testes contribuíram para a análise da eficiência das diferentes orientações da linha no plano de voo.

A discussão acerca da definição da direção das linhas do plano de voo, bem como a integração de todos os voos segmentados, é abordada no item 5.4.1.1.

Figura 91 - Teste da direção das linhas de voo definidas nos voos 2 e 4, com foco na análise dos segmentos da cobertura com partes lineares e curvas.



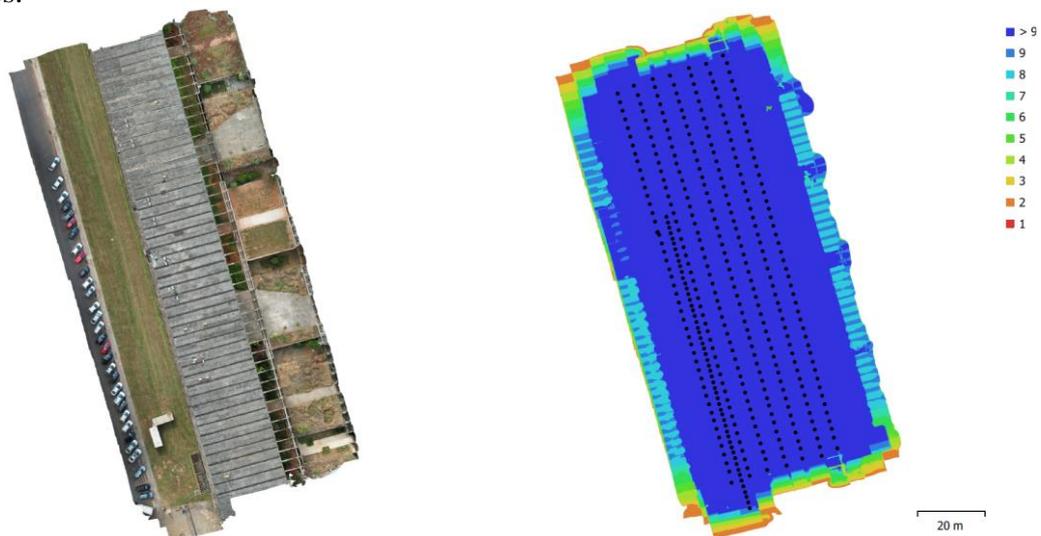
(a) Voo 2 – Bloco B

(b) Voo 4 – Bloco B

Fonte: Elaborado pela autora.

Com a segmentação escolhida para o Voo 2, foi possível observar que, devido ao formato retilíneo e a ausência de curvaturas do trecho, a direção da linha de voo não teve impacto significativo no processamento, nem na geração da ortoimagem (Figura 92). No entanto, no Voo 4, em que há uma curvatura no segmento, foi possível identificar a presença de buracos na ortoimagem, em razão da quantidade limitada de imagens capturadas. Esse problema pode ser visualizado nas Figuras 93 (a) e (b).

Figura 92 - Resultado do segmento processado do plano de voo realizado no ICC - 14 metros – 2 direções.

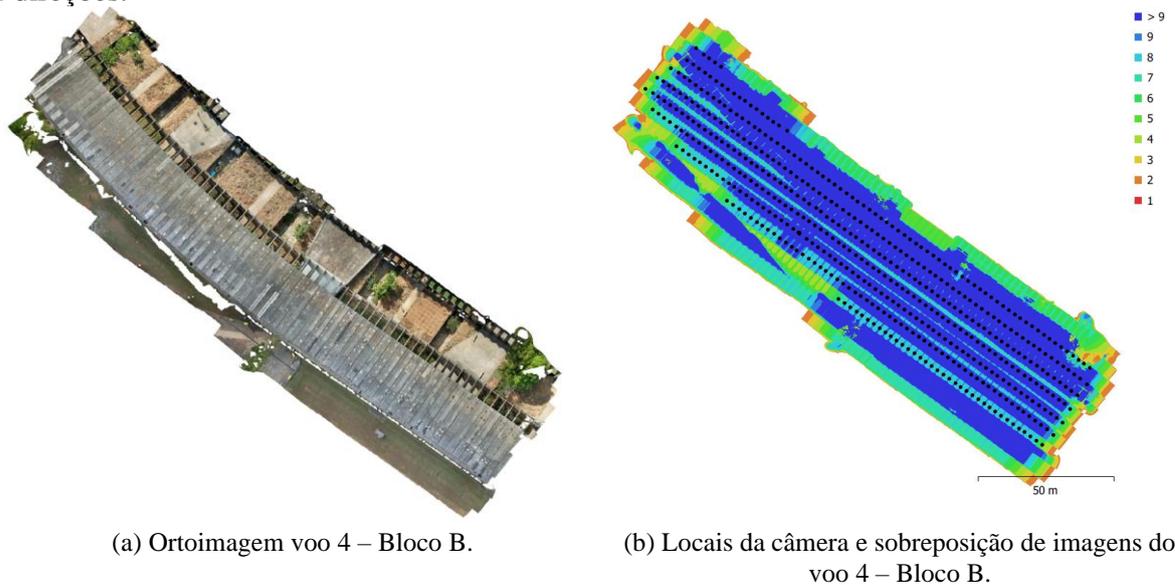


(a) Ortoimagem voo 2 – Bloco B.

(b) Locais da câmera e sobreposição de imagens do voo 2 – Bloco B.

Fonte: Elaborado pela autora.

Figura 93 - Resultado do segmento processado do plano de voo realizado no ICC - 14 metros – 2 direções.



(a) Ortoimagem voo 4 – Bloco B.

(b) Locais da câmera e sobreposição de imagens do voo 4 – Bloco B.

Fonte: Elaborado pela autora.

Além disso, a largura definida para as margens também impactou o processamento. A curvatura do modelo exigiu um aumento na largura da área de captura no plano de voo, o que afetou diretamente o tempo de execução do voo e a quantidade de baterias disponíveis para sua realização.

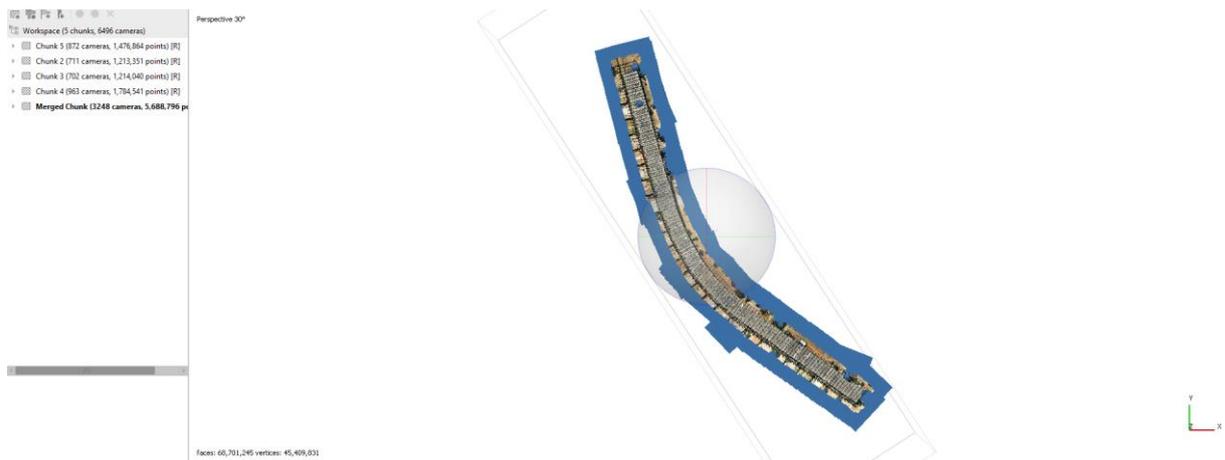
Os processamentos realizados no Bloco A não apresentaram problemas de buracos na ortomagem gerada. Esse resultado é devido à direção da linha de voo, que foi ajustada para seguir a mesma direção radial dos painéis de laje pré-moldada no sistema de cobertura. A hipótese de que as sobreposições poderiam ser responsáveis pelos problemas foi descartada, considerando-se os valores de 80% e 75% de sobreposição utilizados nos voos.

Observou-se que, em todas as imagens que retratam as localizações das câmeras e a sobreposição das imagens, a quantidade de imagens nas áreas dos sistemas de cobertura variou entre 8 e ≥ 9 em todos os voos realizados no ICC. Esse número de sobreposições foi suficiente para garantir a precisão e a qualidade da ortomagem gerada, permitindo ao software identificar e alinhar os pixels adequadamente, sem comprometer o resultado.

5.4.2.1 Merged Chunk do Bloco A e B do ICC

No processo realizado no Bloco A, foram carregados quatro *chunks* (Figura 94). Após a execução de todos os estágios de processamento em cada *chunk*, procedeu-se à sua junção por meio da ferramenta *Merged Chunk*. Essa técnica possibilitou a construção de um modelo de ortomagem eficiente para coberturas de grandes dimensões, garantindo a integração precisa das informações geradas em cada segmento.

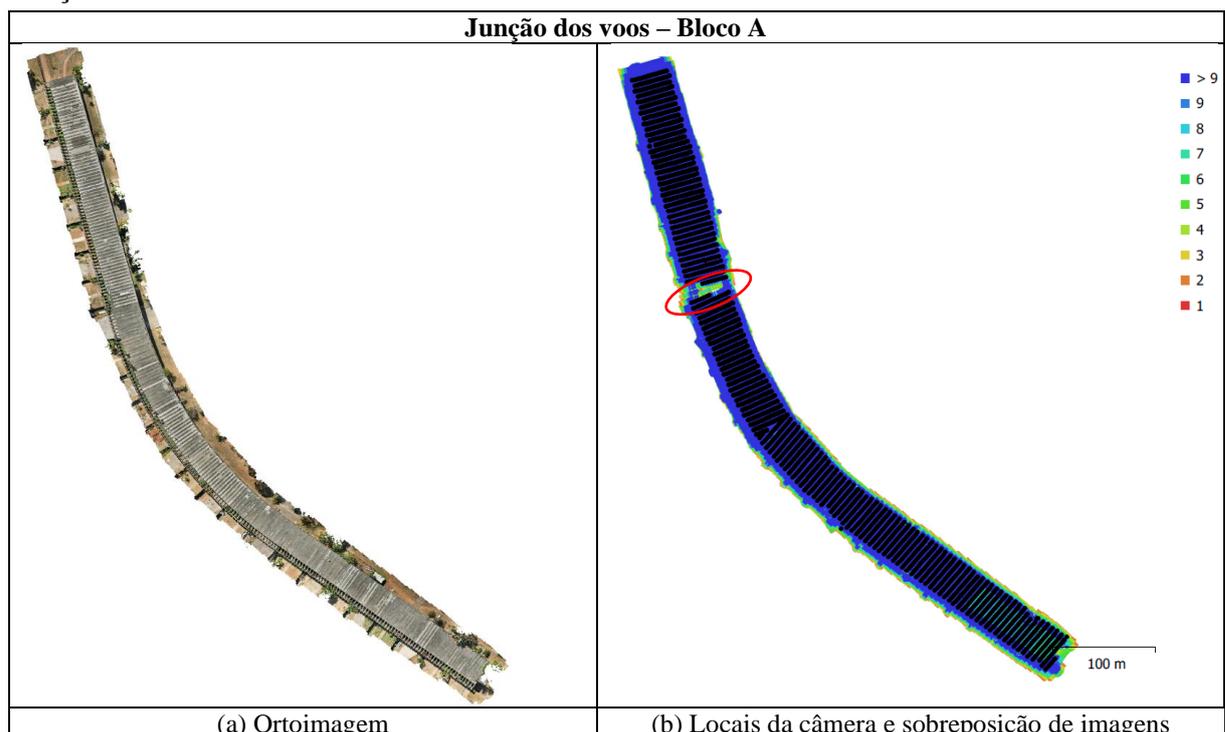
Figura 94 - Interface do software com a junção dos *Chunk* processados do Bloco A.



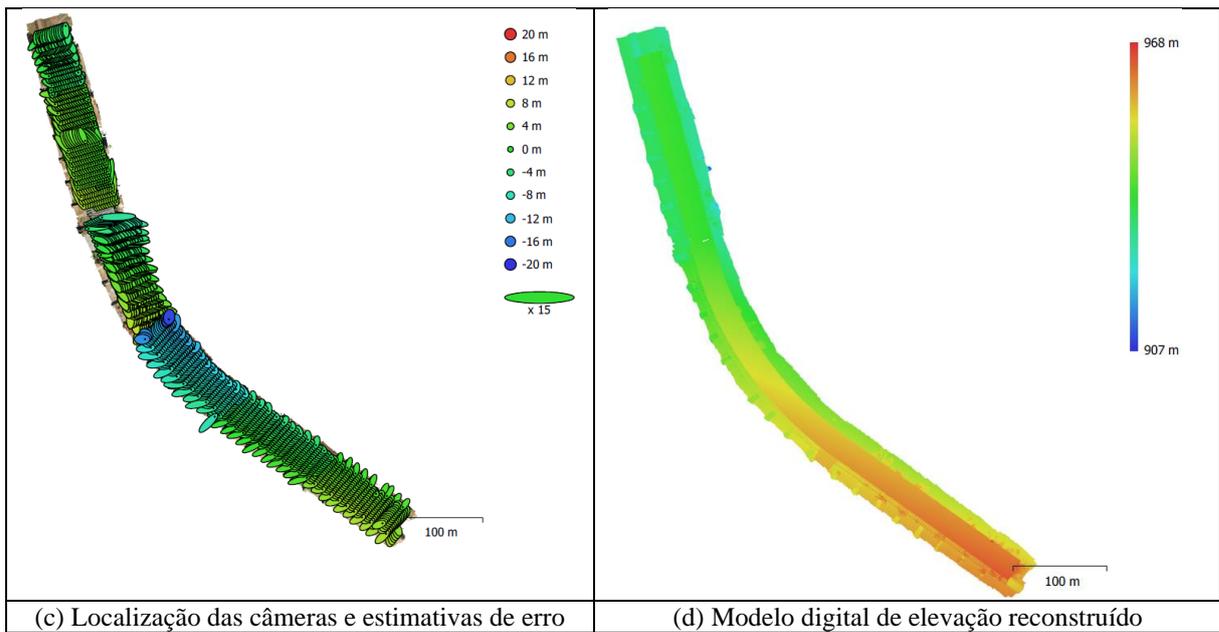
Fonte: Elaborado pela autora.

No Bloco A, não foram identificados problemas na junção dos *chunks* (Quadro 34), ao contrário do que ocorreu no Bloco B. Essa eficiência está relacionada à menor necessidade de seccionamento do plano de cobertura para a execução dos planos de voo. A imagem (a) apresenta a ortoimagem sem falhas na junção dos segmentos. Entretanto, a imagem (b) evidencia um espaço na cobertura sem linhas de voo (destacado pelo círculo em vermelho), resultante da falha na definição exata dos planos de voos para os segmentos. Contudo, observa-se que, devido à proximidade e ao reconhecimento dos *pixels* das imagens capturadas, foi possível realizar o *merged* dos *chunks* sem comprometer o processamento ou a qualidade das informações obtidas.

Quadro 34 - Resultado do processamento dos segmentos realizados no ICC A – 14 metros – 2 direções.



Continuação



Fonte: Elaborado pela autora.

A Figura 95 apresenta a perspectiva do modelo digital de elevação do Bloco A, permitindo uma análise detalhada do sistema de cobertura e das intervenções realizadas no sistema de impermeabilização, ao longo do tempo. O modelo permite identificar áreas danificadas, especialmente em regiões de perfurações nos elementos de concreto aparente, como painéis de laje e vigas-calha, feitas para a fixação de equipamentos e a passagem de tubulações. Essas intervenções podem comprometer tanto a integridade estrutural quanto a funcionalidade do sistema. A análise evidencia a importância de realizar inspeções regulares e aplicar soluções técnicas adequadas para mitigar os impactos dessas intervenções e garantir a segurança e a durabilidade do sistema. Além disso, as inspeções permitem monitorar e identificar intervenções realizadas em desacordo com as manutenções programadas, garantindo maior controle e conformidade com o planejamento estabelecido.

Figura 95 - Perspectiva do modelo digital de elevação do Bloco A.



Fonte: Elaborado pela autora.

A análise do modelo digital de elevação permitiu identificar diversos problemas existentes em intervenções realizadas por empresas terceirizadas. A Figura 96 evidencia a presença de entulhos provenientes de manutenções, resultantes de reparos na impermeabilização, realizados para corrigir danos decorrentes do envelhecimento natural dos componentes e sistemas. Além disso, foram observadas interferências causadas por sistemas prediais e instalações de equipamentos, bem como a presença de vegetação invasiva, que pode comprometer a estanqueidade da cobertura.

A Figura 97 destaca, ainda, a retirada das placas pré-moldadas de concreto, usadas no fechamento das vigas-calhas, elemento essencial para a feição dos grandes planos da arquitetura do edifício e proteção das calhas contra a queda de folhagens, sujeidade e entulho. Esses aspectos reforçam a importância de um monitoramento contínuo, do planejamento adequado das atividades de manutenção e a adoção de práticas que minimizem os impactos negativos no sistema de cobertura e, conseqüentemente, nos elementos estruturais.

Figura 96 – Entulhos identificados no sistema de cobertura.



Fonte: Elaborado pela autora.

Figura 97 – Retirada das placas de fechamento das vigas-calhas.



Fonte: elaborado pela autora.

A Figura 98 evidencia a retirada das placas de fechamento das vigas-calhas durante as tarefas de manutenção e reparos no sistema de impermeabilização com manta aluminizada. Após a realização do reparo, observou-se que as placas de fechamento não foram reinstaladas, comprometendo a proteção das vigas-calhas. Na mesma imagem, destaca-se uma distorção do modelo digital de elevação, localizada próxima a uma área onde havia uma árvore (indicada pelo círculo em vermelho). Essa distorção prejudica o grau de precisão do plano de voo e, conseqüentemente, a análise detalhada do sistema de cobertura.

Já na Figura 99, observa-se o acúmulo de folhagens nas vigas-calhas, agravado pela ausência das placas de fechamento. Essa condição pode levar ao entupimento dos bocais das tubulações de descida de águas pluviais, comprometendo o escoamento eficiente das águas e o aumento do risco de infiltrações e danos estruturais. Esses problemas reforçam a necessidade de manutenção preventiva e de inspeções periódicas para garantir a funcionalidade e a durabilidade do sistema de cobertura.

Figura 98 - A vegetação impede a visualização da cobertura.



Fonte: Elaborado pela autora.

Figura 99 - Calha suja.



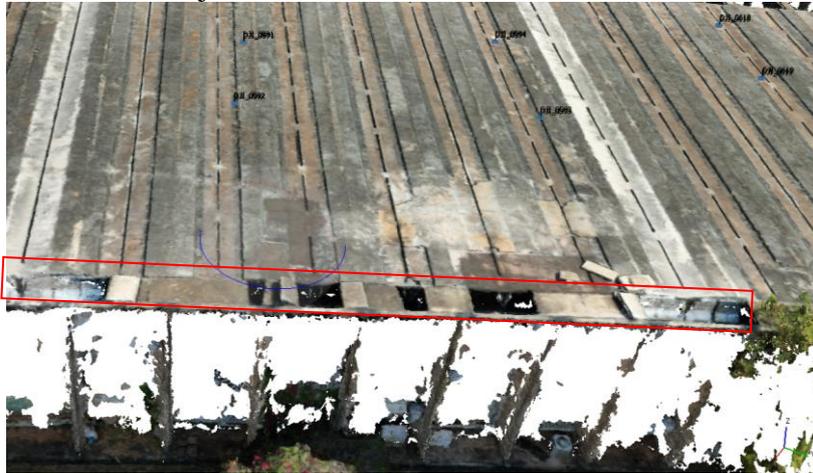
Fonte: Elaborado pela autora.

A Figura 100 evidencia a ausência das placas de fechamento da viga-calha, cuja fragilidade frequentemente resulta em quebras durante o manuseio. Os detritos de concreto provenientes dessas placas acabam bloqueando os tubos de descida das águas pluviais, prejudicando o funcionamento do sistema em períodos de chuva. Esse bloqueio facilita o acúmulo de sujeira, aumentando o risco de entupimentos, falhas no escoamento das águas pluviais e possíveis danos estruturais, além de problemas de infiltração nas lajes.

Com base na análise apresentada, evidencia-se as vantagens e contribuições do processamento digital como ferramenta para a inspeção de sistemas de cobertura. Esse recurso permite a identificação precisa de irregularidades, como o bloqueio de drenos e acúmulo de resíduos, auxiliando diretamente na tomada de decisões por parte dos inspetores. Dessa forma,

a tecnologia se mostra fundamental para o planejamento de intervenções corretivas e preventivas em grandes áreas de cobertura, garantindo maior eficiência na gestão das manutenções e prolongando a vida útil das edificações.

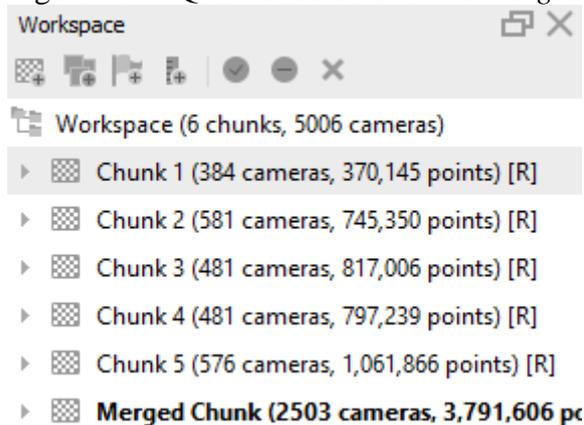
Figura 100 - Placa móvel obstruindo viga-calha, impedindo o escoamento de água e acumulando sujidades.



Fonte: Elaborado pela autora.

O Bloco B contou com cinco *chunks* para a realização do *merged* ao final dos processamentos (Figura 101). Os voos iniciais foram realizados nesse bloco, servindo como base para testes relacionados à direção das linhas de voo. Esses testes demonstraram que a direção adotada no plano de voo influenciou diretamente na junção dos *chunks*, impactando a qualidade final do modelo gerado.

Figura 101 - Quantidade de *Chunk* e *Merged* do Bloco B.

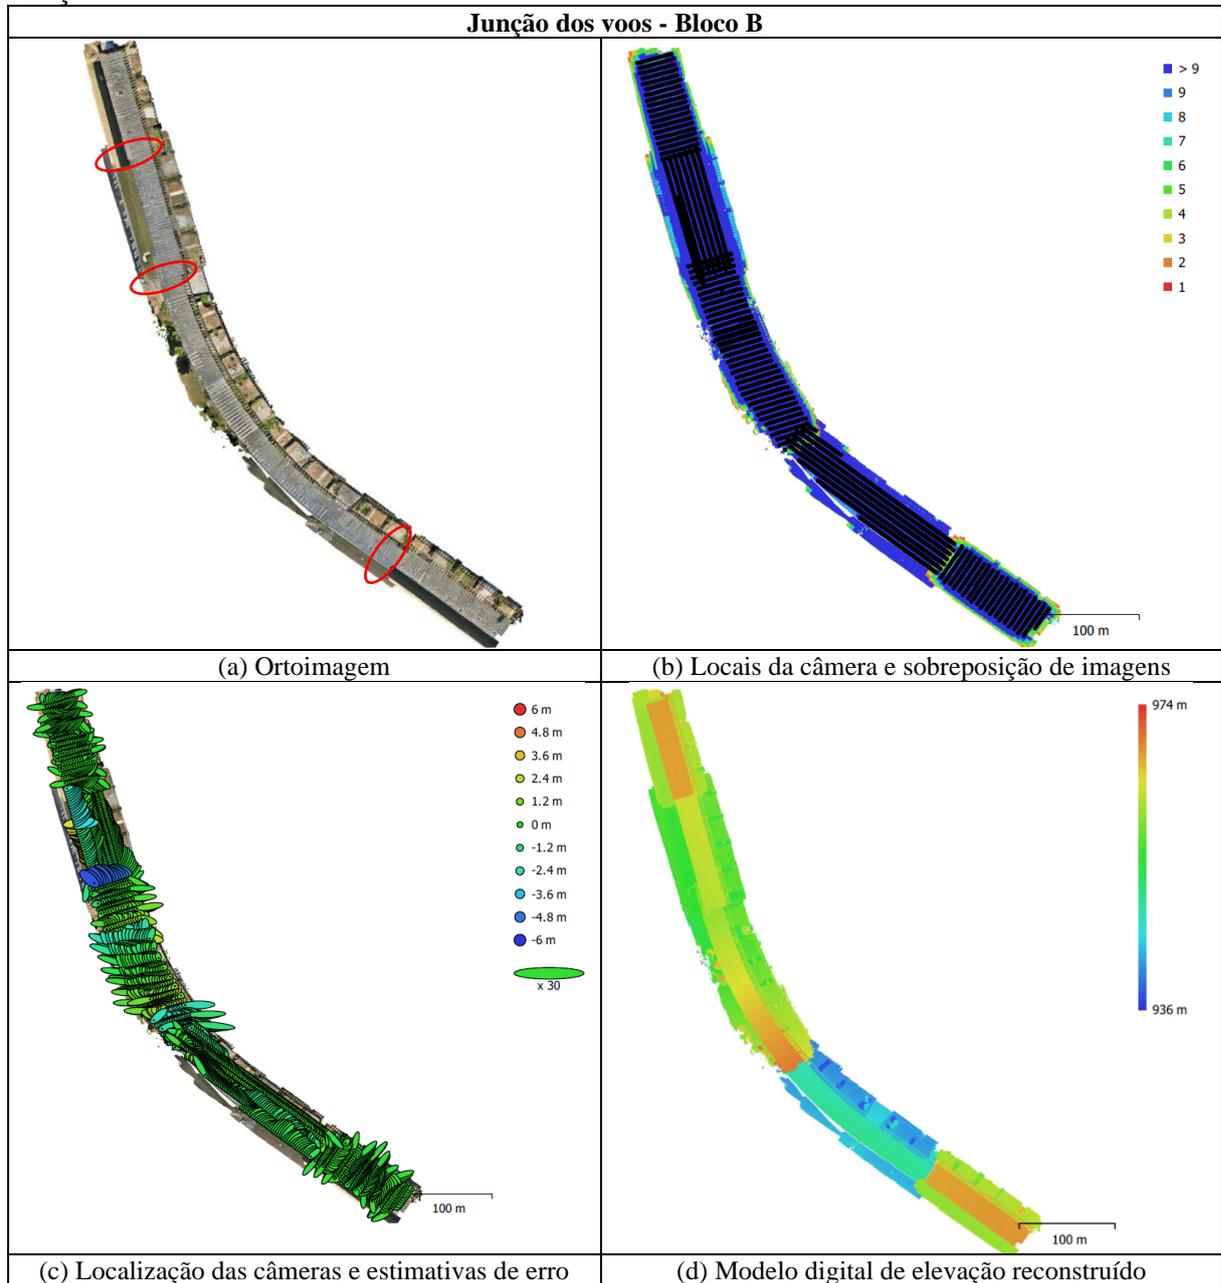


Fonte: Elaborado pela autora.

O Quadro 35 apresenta uma análise detalhada dos problemas identificados durante o processamento da ortoimagem, atribuídos à direção das linhas de voo estabelecidas. Na imagem (a), destacam-se falhas evidenciadas por três círculos em vermelho, localizadas nas áreas de junção com deslocamentos. Esses deslocamentos ocorrem devido à utilização de direções diferentes nas linhas de voo. O segundo círculo revela uma sobreposição gerada por dois voos distintos, resultado da delimitação definida no plano de voo.

Já na imagem (b), é possível observar a direção das linhas programadas no plano de voo, demonstrando como as direções selecionadas influenciaram diretamente nos erros registrados na construção da ortoimagem. Esses resultados reforçam a importância do planejamento e da uniformidade das direções de voo para evitar falhas no processamento.

Quadro 35 - Resultado do processamento dos segmentos realizados no ICC B – 14 metros – 2 direções.



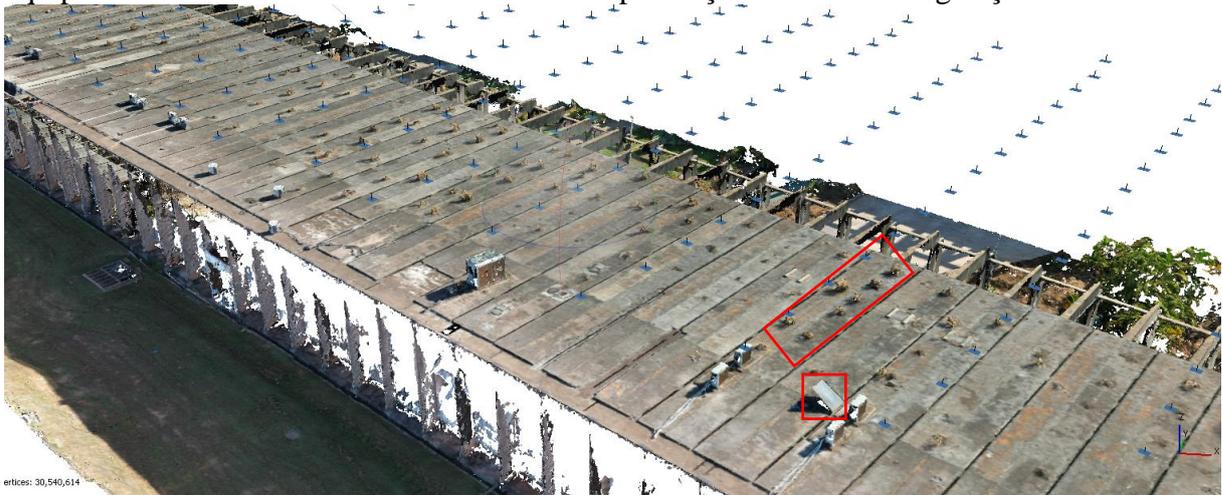
Fonte: Elaborado pela autora.

No modelo digital de elevação gerado para o Bloco B, é possível observar diversos elementos presentes no sistema de cobertura. Entre eles, destacam-se os equipamentos instalados, as carcaças de dispositivos obsoletos que estão em desuso, e a presença de vegetação invasiva (Figuras 102). Essa vegetação é caracterizada pelo crescimento de gramíneas e

pequenos arbustos sobre a cobertura, dentro das calhas e nos bocais dos tubos de queda, além do acúmulo de resíduos vegetais transportados pelo vento e pela ação de aves.

Esses fatores podem comprometer a integridade do sistema de cobertura, aumentando a necessidade de manutenções periódicas e intervenções planejadas para evitar danos estruturais e funcionais. O modelo digital de elevação demonstra sua eficácia ao identificar esses problemas, auxiliando nas tomadas de decisões e estratégias de ações de manutenção.

Figura 102 - Perspectiva do modelo digital de elevação do Bloco B com a sinalização dos equipamentos obsoletos e a presença de vegetação invasiva.



Fonte: Elaborado pela autora.

Na Figura 103 ilustra a disposição dos eletrodutos, fiações e outras tubulações das instalações prediais expostas sobre a laje de cobertura, além de passagens pelas fachadas ou no interior das vigas-calhas de concreto e das calhas transversais em alumínio. Observa-se que as placas pré-moldadas utilizadas para o fechamento superior das vigas-calhas são frequentemente removidas ou perfuradas para acomodar as tubulações. Em alguns casos, equipamentos são posicionados diretamente sobre essas placas, impedindo sua remoção para a limpeza do fundo das calhas e dos bocais das tubulações de descida de águas pluviais.

Destaca-se que as placas de fechamento das vigas-calhas desempenham um papel essencial na composição estética e funcional da cobertura, garantindo a continuidade visual dos planos horizontais. No entanto, devido ao peso próprio dessas peças de concreto armado e à corrosão das armaduras de distribuição, seu manuseio torna-se difícil, e a remoção frequente resulta em danos ou quebras. Essa condição evidencia a importância de um planejamento cuidadoso para intervenções que minimizem impactos na funcionalidade e na durabilidade do sistema de cobertura.

Figura 103 - Perspectiva do modelo digital de elevação do Bloco B.



Fonte: Elaborado pela autora.

Os processamentos realizados nos Blocos A e B apresentaram resultados similares (Tabela 26), com a principal diferença no tempo de execução. O Bloco A demandou maior tempo de processamento em função da maior quantidade de imagens capturadas nos planos de voo. Essa diferença reflete a relação direta entre o volume de dados adquiridos e o tempo necessário para a geração do modelo digital e da ortoimagem.

Tabela 26 - Resultados do processamento para a geração das ortoimagens obtidas.

Amostras	Área (m ²)	Tempo (h)	Resolução (GB)	Digital Elevation Model - Resolution	Survey Data – Reprojection error
Bloco A	430 m ²	16:22:00	3,99 GB	1,41 cm/pix	0,532 pix
Bloco B	446 m ²	02:08:00	3,99 GB	1,6 cm/pix	0,522 pix

Fonte: Elaborado pela autora.

É relevante destacar a diferença entre a área definida no plano de voo e a área efetiva do sistema de cobertura da edificação. O plano de voo considera uma área maior, pois abrange as margens da edificação para garantir uma melhor definição das bordas do sistema de cobertura nos modelos gerados.

Os formatos dos Blocos A e B, em planta, apresentam características similares, com uma extensão de 696 metros ou mais. Essa configuração influenciou diretamente o planejamento dos voos, determinando a área de cobertura necessária para a obtenção dos dados.

5.5 ANÁLISE DO PROCESSAMENTO DIGITAL EM NÍVEL URBANO

A discussão sobre o processamento digital em nível urbano considera os resultados de dois planos de voo com diferentes alturas, o que apresentaram impactos significativos no nível de detalhamento obtido e na qualidade da resolução final, conforme os dados apresentados na Tabela 27.

No primeiro plano de voo, realizado com uma altura de 50 metros, focados nos Blocos A e B do ICC, foi possível capturar detalhes mais precisos do sistema de cobertura. Essa altura proporcionou uma resolução superior, essencial para análises minuciosas, como a identificação de danos em componentes específicos, vegetação invasiva, ou equipamentos obsoletos na cobertura. Contudo, a área de abrangência foi limitada, restringindo a aplicação a um nível mais local.

O segundo plano de voo foi realizado pelo LAPIS³ (Pazos, 2024), a altura adotada foi de 130 metros, cobrindo uma área mais ampla em nível urbano. Embora essa abordagem seja eficiente para análises gerais de urbanismo, como mapeamento de grandes regiões e planejamento territorial, o aumento da altura impactou diretamente o nível de detalhamento do sistema de cobertura. Com uma resolução reduzida, tornou-se mais difícil identificar detalhes específicos no sistema de cobertura da edificação do ICC, limitando a aplicabilidade dos resultados para inspeções detalhadas.

Tabela 27 - Resultados do processamento para a geração das imagens obtidas.

Amostras	Área (m ²)	Tempo (h)	Resolução (GB)	Digital Elevation Model - Resolution	Survey Data – Reprojection error
U1.1	2.900 m ²	21:31:00	2,80 GB	6,85 cm/pix	0,66 pix
U1.2	8.950 m ²	0:07:09	1,31GB	10,6 cm/pix	2,22 pix

Fonte: Elaborado pela autora.

Na análise dos dados de processamento dos dois estudos, observou-se diferenças significativas ao adotar novos parâmetros no 2º processamento, que influenciaram diretamente nos resultados obtidos para inspeção predial no ICC e para o mapeamento urbano no Campus Darcy Ribeiro da UnB.

Para a *Accuracy* do *Align Photos* no processamento ICC, foi utilizada a resolução mais alta (*highest*), ampliando a escala da imagem em um fator de 4. Esse método permitiu maior detalhamento na identificação de pontos, adequado para inspeções prediais que requerem precisão na análise de pequenos elementos. Além disso, o ICC apresentou um número maior de pontos de amarração, o que melhora a precisão no alinhamento das imagens e na definição da geometria. No Campus Darcy Ribeiro da UnB, foi adotado o nível *High*, mantendo a imagem no tamanho original. Embora seja suficiente para estudos urbanos, essa abordagem reduz a precisão em relação a pequenos detalhes necessários para os mapeamentos de manifestações patológicas.

³ PAZOS, V. (2024). Relatório Técnico-Científico de Pesquisa de Desenvolvimento de Tecnologia Assistida no Campus Darcy Ribeiro. Coordenação do Laboratório de Prototipagem - Lapis, da Faculdade de Arquitetura e Urbanismo – FAU. Projeto financiado pela Diretoria de Acessibilidade - DACES/UnB.

Para o *Build Dense Cloud*, utilizou-se a qualidade *Medium* (redução de 4x4), reduzindo o tamanho da imagem para 1/16 do original, o que diminui o tempo de processamento. O *Depth filtering* foi configurado como *Aggressive*, eliminando a maioria dos *outliers* e resultando em uma nuvem mais limpa. Essa configuração é recomendada para mapeamentos de terrenos e superfícies com menos detalhes.

A configuração utilizada no Campus Darcy Ribeiro da UnB, onde se localiza o ICC, foi a *High* (redução de 2x2), diminuindo o tamanho da imagem para 1/4 do original. O *Depth filtering* foi ajustado para *Mild*, permitindo maior representação de detalhes, mas introduzindo ruídos devido à redução dos *outliers*.

Na geração da malha (*Build Mesh*), todos os parâmetros foram divergentes entre as duas análises. No *Surface Type* (tipo de superfície), foram utilizados a nuvem densa para o ICC e para o Campus da UnB, adotou-se a altura de campo (*Height field*), apropriada para áreas extensas e com topografia simplificada. Em cada processamento, foi selecionado um tipo de superfície a ser utilizada.

Para os dados de origem (*Source data*), foram utilizados no ICC o *Arbitrary* e, no segundo processamento, a nuvem de pontos. A escolha do *Arbitrary* permitiu que o software não fizesse suposições sobre o objeto modelado. Essa configuração consome mais memória, mas resulta em maior detalhamento. No processamento do Campus da UnB, a nuvem de pontos (*Point cloud*) foi utilizada como base, priorizando a eficiência computacional e abrangência em detrimento do detalhamento.

Entre os processamentos, a diferença na *Interpolation* foi estar ativada (*Enabled*) ou desativada (*Disabled*). A opção *Disabled* garantiu uma maior precisão ao reconstruir apenas áreas com alta densidade de pontos, evitando interpolação em regiões com poucos dados. Na opção *Enabled* ativada, permitiu ao software preencher lacunas na superfície. Apesar de oferecer uma aparência mais uniforme, pode gerar buracos residuais e menor precisão em áreas críticas.

A escolha dos parâmetros reflete os diferentes objetivos de cada estudo. Para as inspeções prediais no sistema de cobertura plana do ICC, foi priorizado o detalhamento e a precisão. Porém, para o processamento do Campus Darcy Ribeiro da UnB, objetivou-se a eficiência e a abrangência, adequando-se aos estudos urbanos que exigem menos detalhamento, mas abrangem áreas maiores (Tabela 28). Essas diferenças demonstram a importância de adaptar os parâmetros de processamento ao contexto e à finalidade da análise, equilibrando qualidade, tempo de processamento e recursos computacionais disponíveis.

Tabela 28 - Dados dos parâmetros da etapa de processamento.

Parâmetros / Amostras	Processamento ICC Norte e Sul	Processamento Campus UnB
Align Photos		
<i>Accuracy</i>	<i>Highest</i>	<i>High</i>
<i>Generic preselection</i>	<i>Yes</i>	<i>Yes</i>
<i>Key point limit</i>	<i>80,000</i>	<i>40,000</i>
<i>Tie point limit</i>	<i>8,000</i>	<i>4,000</i>
Build Dense Cloud		
<i>Quality</i>	<i>Medium</i>	<i>High</i>
<i>Depth filtering</i>	<i>Aggressive</i>	<i>Mild</i>
Build Mesh		
<i>Source data</i>	<i>Arbitrary</i>	<i>Point cloud</i>
<i>Surface type</i>	<i>Dense</i>	<i>Height field</i>
<i>Interpolation</i>	<i>Disabled</i>	<i>Enabled</i>
<i>Quality</i>	<i>Medium</i>	-
Build Texture		
<i>Mapping mode</i>	<i>Orthophoto</i>	<i>Orthophoto</i>
<i>Blending mode</i>	<i>Mosaic</i>	<i>Mosaic</i>
Build Tiled Model		
<i>Source data</i>	<i>Dense cloud</i>	-
<i>Face count</i>	<i>Low</i>	-
Build DEM		
<i>Source data</i>	<i>Dense cloud</i>	<i>Mesh</i>
<i>Interpolation</i>	<i>Enabled</i>	<i>Enabled</i>
Build Orthomosaic		
<i>Surface</i>	<i>Mesh</i>	<i>Mesh</i>
<i>Blending mode</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Hole filling</i>	<i>Yes</i>	<i>Yes</i>

Fonte: Elaborado pela autora.

As ortoimagens geradas são apresentadas nas Figuras 104 e 105, onde se observam problemas na construção das bordas do voo realizado no ICC em nível urbano. Tais inconsistências podem ser atribuídas a diversos fatores, como a altura limitada do voo, a quantidade de massa arbórea existente, e a escolha dos parâmetros durante o estágio de *Build Dense Cloud* e as configurações aplicadas no *Build Mesh*. Esses elementos são fundamentais para garantir a precisão e o detalhamento final das imagens processadas.

Além disso, a análise da direção das linhas de voo, conforme ilustrado nas Figuras 106 e 107, revela uma diferenciação clara na orientação das trajetórias em relação à cobertura do ICC. Essa orientação é fundamental, pois influencia diretamente na uniformidade e na qualidade da ortoimagem gerada, especialmente em áreas próximas às bordas e em regiões com sobreposição reduzida.

Figura 104 - Ortoimagem do ICC Norte e Sul.



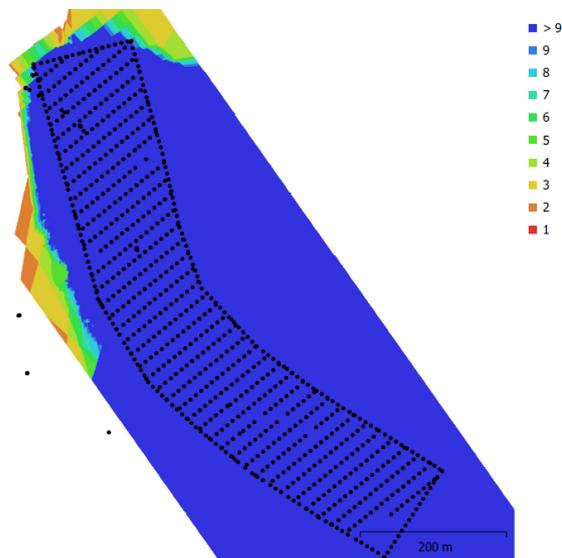
Fonte: Elaborado pela autora.

Figura 105 - Ortoimagem a nível do urbanismo.



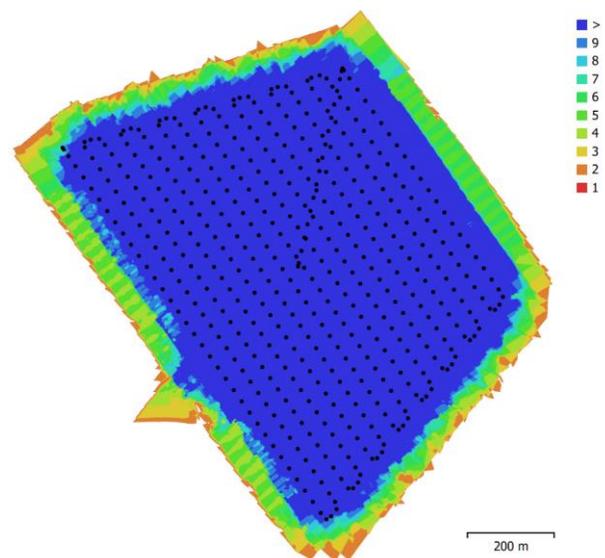
Fonte: Pazos (2024).

Figura 106 - Locais da câmera e sobreposição de imagens.



Fonte: elaborado pela autora.

Figura 107 - Locais da câmera e sobreposição de imagens.



Fonte: Pazos (2024).

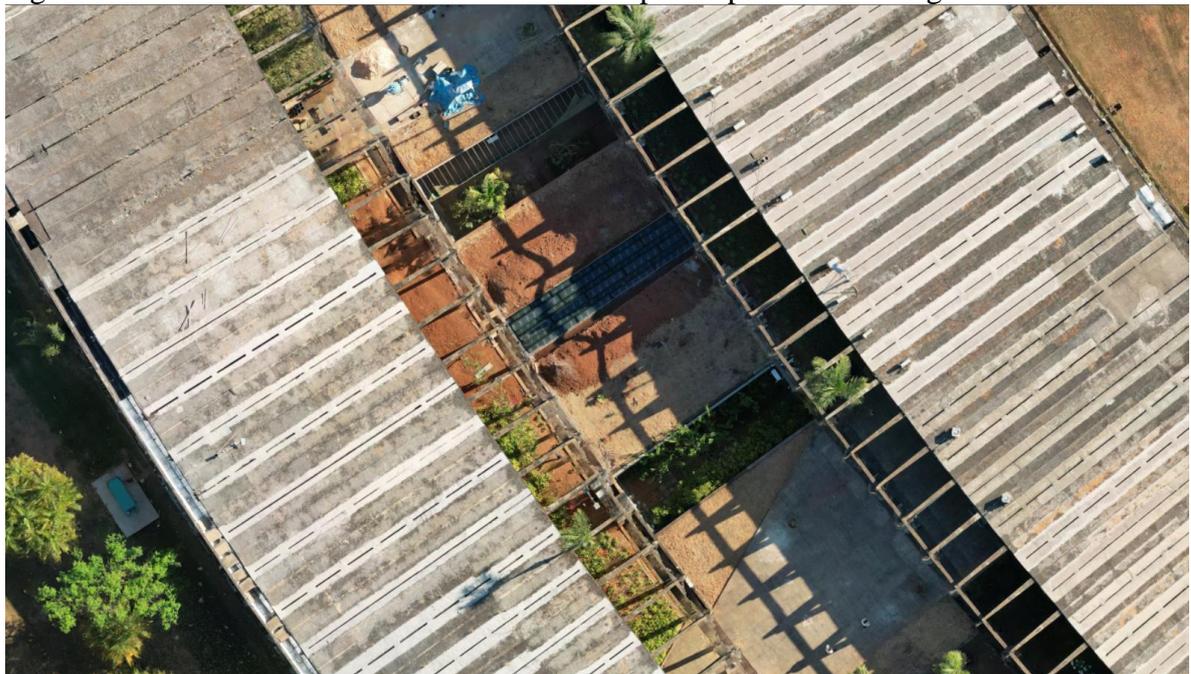
As ortomagens geradas apresentaram elementos relevantes para análise, destacando mudanças no sistema ao longo do tempo. Nas Figuras 108 e 109, podem ser observadas diferenças entre as condições capturadas no processamento realizado em nível urbano, em 02 de julho de 2024, e no ICC, em 22 de outubro de 2023. Essas diferenças evidenciam o impacto do processo de envelhecimento e da sujeira superficial na cobertura ao longo do período avaliado, além das ações de manutenção realizadas no período.

Figura 108 - Zoom de 100% no software Photoshop CS6 - processamento em nível do urbano.



Fonte: Pazos (2024).

Figura 109 - Zoom de 30% no software Photoshop CS6 processamento geral do ICC.



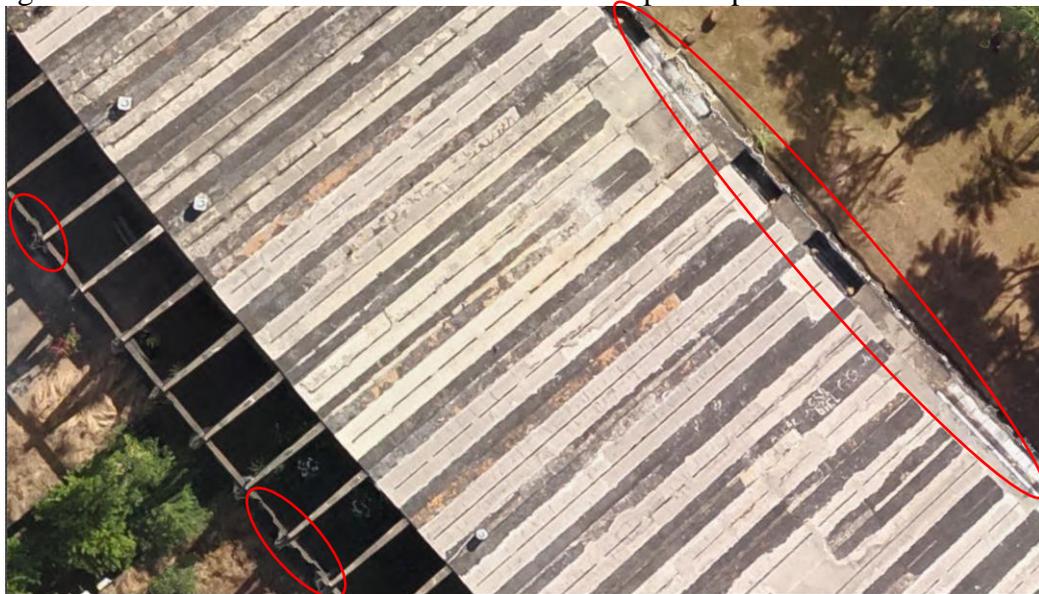
Fonte: Elaborado pela autora.

O processamento em nível urbano apresentou problemas na construção das bordas dos sistemas de cobertura devido à pouca quantidade de imagens que foram utilizadas para a realização do processamento. Entretanto, destaca-se a importância de um voo que abranja um grande conjunto edificado para o mapeamento e a visualização rápida de um objeto a ser inspecionado, sem a necessidade de detalhamento. É possível visualizar a quantidade de

equipamentos, as áreas que sofreram manutenções, os locais onde foram retiradas placas de fechamentos das vigas-calhas e a deposição de entulho.

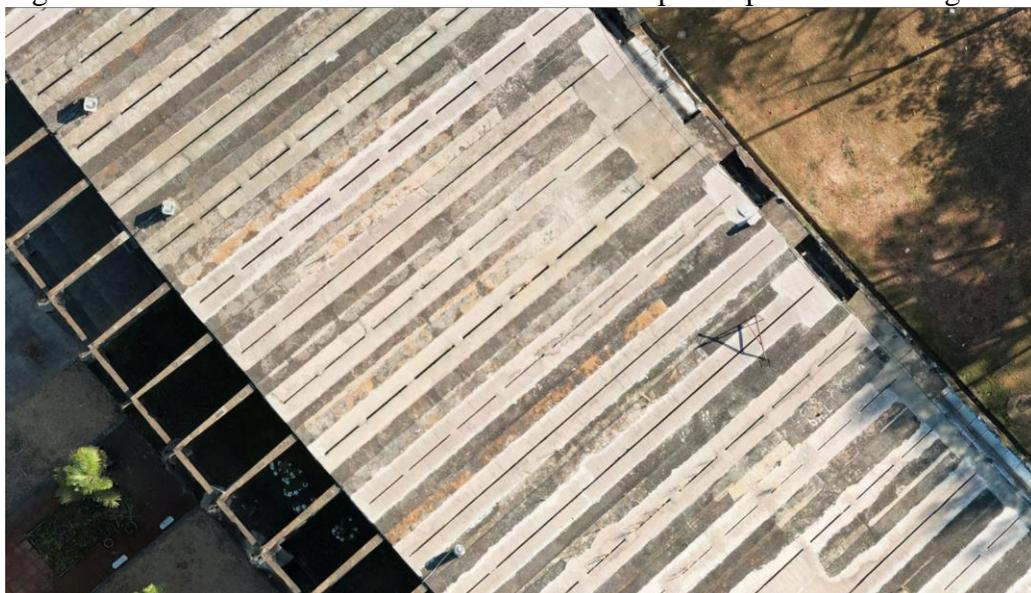
As Figuras 110 e 111 apresentam a diferença entre os resultados dos parâmetros utilizados. Na Figura 110 é possível visualizar os problemas de definição das bordas sinalizados nos círculos em vermelho. Já na Figura 111 esses problemas não aparecem devido ao plano de voo definido e aos parâmetros definidos para a realização do processamento. É possível identificar no voo do ICC realizado no ano de 2023 a existência de uma antena que já não aparece no voo realizado em nível urbano no ano de 2024. Isso retrata a importância do monitoramento - registro e acompanhamento que pode ser realizado com o uso da inspeção predial automatizada.

Figura 110 - Zoom de 161% no software Photoshop CS6 processamento em nível urbano.



Fonte: Pazos (2024).

Figura 111 - Zoom de 161% no software Photoshop CS6 processamento geral do ICC.



Fonte: Elaborado pela autora.

A definição do objetivo para a realização do plano de voo é determinante para orientar as tomadas de decisão no processamento e análise dos dados fotogramétricos. Neste contexto, o sistema de cobertura do ICC, um dos pontos centrais desta tese de doutorado, é analisado de maneira comparativa, destacando como os resultados obtidos podem influenciar diretamente na inspeção predial e na avaliação de sua integridade.

5.6 ANÁLISE DOS PROCESSOS AUTOMATIZADOS EM *DEEP LEARNING*

A inspeção é uma tarefa essencial para os serviços de manutenção predial, pois é o processo que auxilia no diagnóstico dos danos presentes, visando os reparos e as substituições que influenciam o desempenho do sistema construtivo. Principalmente, destaca-se o interesse nos processos automatizados para otimizar a tomada de decisões para o planejamento da manutenção.

Este experimento em *deep learning* foi motivado pela necessidade de identificação e registro dos equipamentos instalados em grandes coberturas em conjuntos edificados. As coberturas selecionadas para este estudo pertencem ao Quartel-General do Exército Brasileiro (QGEx). O experimento proposto para detectar equipamentos do tipo condensadoras de ar-condicionado foi realizado em 9 coberturas planas impermeabilizadas do conjunto edificado do QGEx. Esses equipamentos dispostos na cobertura podem estar desativados, sem funcionalidade, impedindo o funcionamento dos ralos ou provocando empoçamentos de água, o que acelera a degradação da camada de impermeabilização e causa infiltrações de umidade.

O levantamento de campo com drone para a detecção das condições *as built* e manifestações patológicas foi uma etapa necessária para a criação de um banco de imagens, conforme tratado nas seções e subseções anteriores desta tese. No sistema de cobertura, as imagens adquiridas registram e favorecem o inventário de equipamentos por meio de técnicas de detecção de objetos.

Os recursos tecnológicos dados pela *deep learning* e redes neurais convolucionais (CNN) aplicadas em visão computacional proporcionaram a análise de seis algoritmos aplicados à detecção de objetos. O objetivo foi avaliar como essas tecnologias podem contribuir para a tomada de decisão em manutenção predial por meio de processos automatizados.

5.6.1 Resultados do Processo Automatizado para Detecção de Equipamentos

Conforme descrito na Seção 4 – Método de pesquisa, item 4.4.1, as anotações realizadas na plataforma *Roboflow* foram exportadas para o *framework MMDetection*, onde as seis arquiteturas de rede foram treinadas utilizando a técnica de validação cruzada em cinco *folds*. Foram utilizadas nove métricas que permitiram uma avaliação do desempenho dos modelos testados.

A Tabela 29 sintetiza os resultados das nove métricas de desempenho utilizadas no estudo. Os valores apresentados correspondem às médias aritméticas das métricas calculadas ao longo das cinco *folds*, garantindo a confiabilidade dos resultados.

Tabela 29 - Métodos usados e valores de métricas de desempenho.

	mAP	mAP 50	mAP 75	Precision	Recall	F- score	MAE	RMSE	r
Faster R-CNN	0,654	0,944	0,814	0,927	0,934	0,930	0,439	0,914	0,959
Retina-Net	0,513	0,750	0,628	0,713	0,730	0,721	1,324	2,024	0,746
Atss	0,665	0,943	0,825	0,959	0,835	0,893	0,706	1,527	0,907
Vfnet	0,399	0,569	0,492	0,537	0,549	0,543	1,976	2,779	0,699
Sabl	0,659	0,951	0,816	0,920	0,893	0,906	0,549	1,177	0,934
Fovea	0,642	0,935	0,796	0,919	0,889	0,903	0,597	1,208	0,931

Legenda: O melhor desempenho O segundo melhor desempenho O terceiro melhor desempenho

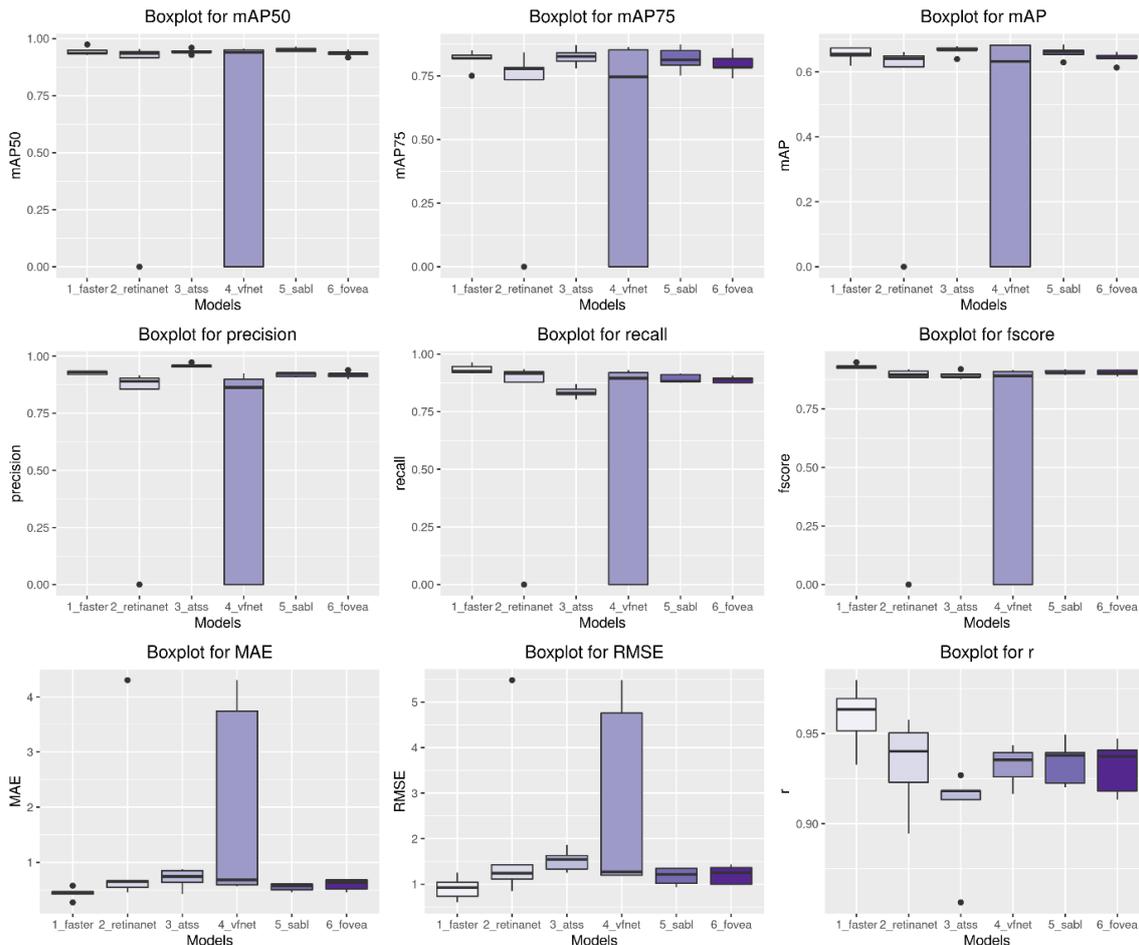
Fonte: Elaborado pela autora.

No geral, analisando os resultados da Tabela 29, verifica-se que todas as CNNs testadas apresentaram bom desempenho, com destaque para Faster R-CNN seguido por SABL, Fovea e ATSS. As redes neurais Retina-Net e Vfnet foram as que apresentaram os menores valores nas nove métricas testadas.

Para comparar estatisticamente os valores das métricas de desempenho dos seis métodos de CNN, foi aplicada a ANOVA e o teste post-hoc de Tukey, após a verificação da condição de homogeneidade dos grupos e distribuição normal. Para o teste de hipótese ANOVA unidirecional, foi adotado um nível de significância de 5%. Além disso, foi aplicado o teste não paramétrico de Kruskal-Wallis para refinamento das comparações.

Após as comparações, não é possível afirmar que há diferenças estatísticas entre essas CNNs, mas que ATSS (0,835) difere de Faster R-CNN e que Retina-Net e Vfnet tiveram os piores desempenhos. Faster R-CNN teve o melhor Fscore (0,930), seguido por SABL (0,906) e Fovea (0,903).

A Figura 112 apresenta os *boxplots* que ilustram a distribuição dos valores das métricas obtidas para cada um dos métodos analisados durante o processamento. A análise revela que, com exceção do método Vfnet, os demais métodos apresentam baixa variabilidade na distribuição dos valores medidos. Por outro lado, o método Vfnet mostra uma dispersão grande em todas as métricas quando comparado aos outros métodos, exceto para a métrica r (*Correlação de Pearson*).

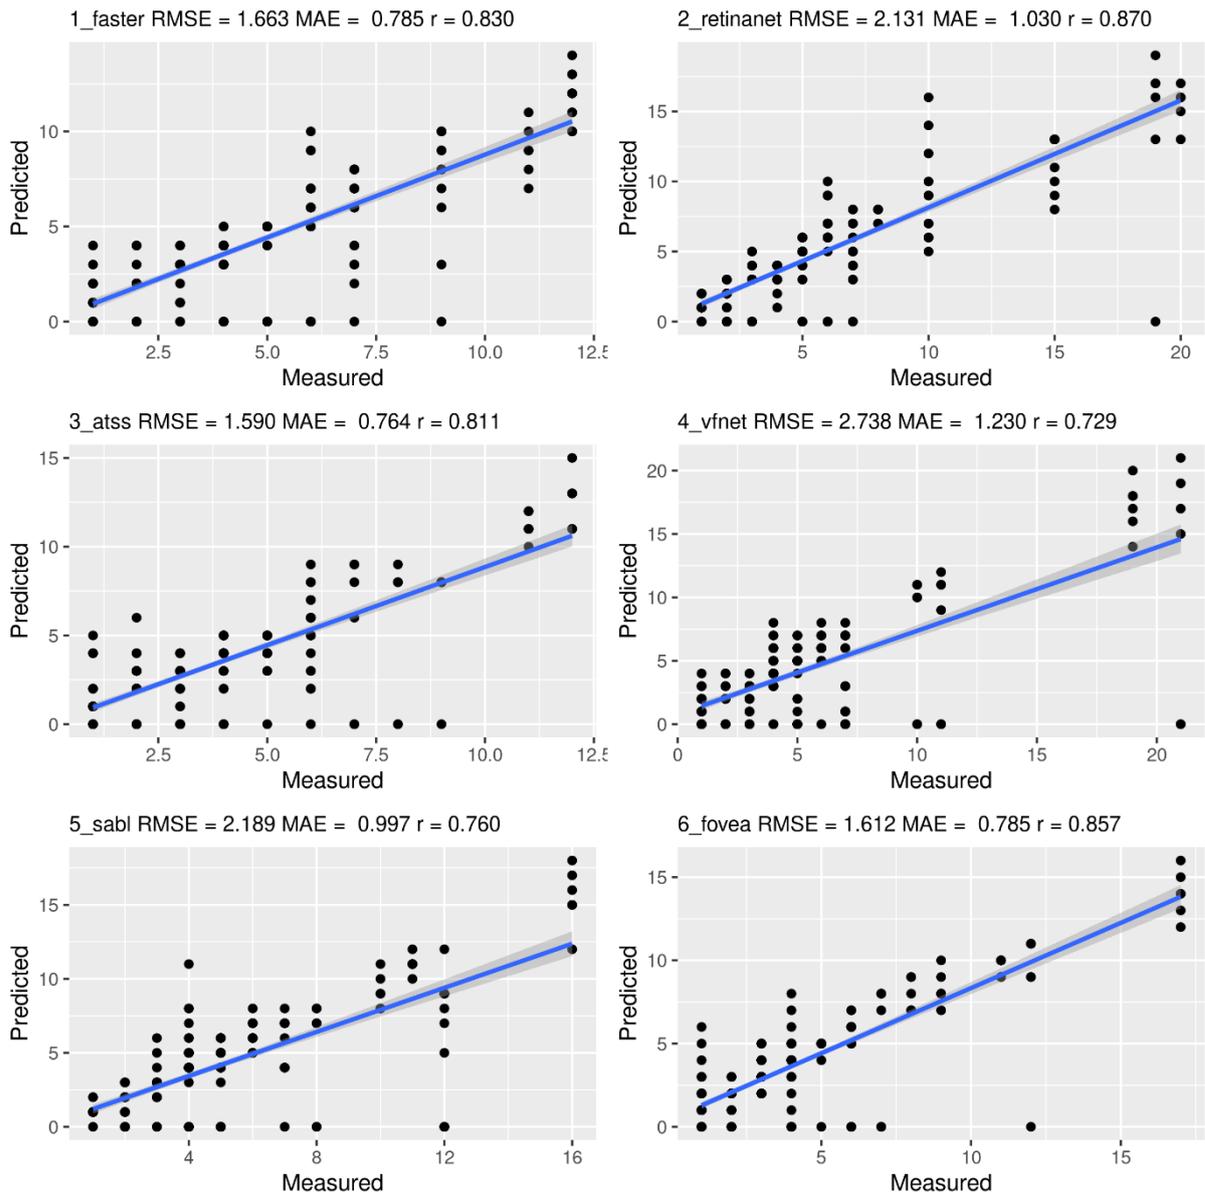
Figura 112 - Gráficos de *boxplot* para os valores medidos em cada experimento.

Fonte: Elaborado pela autora.

A Figura 113 apresenta os gráficos de regressão linear para cada método, permitindo a análise detalhada da Correlação de *Pearson* (r). Os resultados mostram que todos os métodos obtiveram $r > 0,72$, indicando uma relação forte e positiva entre as variáveis medidas e os valores previstos.

O Retina-Net demonstra uma melhor correlação ($r=0,87$), seguido pela Fovea ($r=0,857$) e pelo Faster R-CNN ($r=0,83$), respectivamente. Os gráficos mostram as retas de regressão que foram construídas usando todas as imagens de teste das 5 *folds*. Essa é a razão que explica a diferença no valor das métricas RMSE, MAE e r apresentadas nos gráficos da Figura 113, em relação aos valores das métricas calculados por *folds*, mostrados na Tabela 29.

Figura 113 - Resultados da Correlação de Pearson: relação entre os valores medidos e previstos.



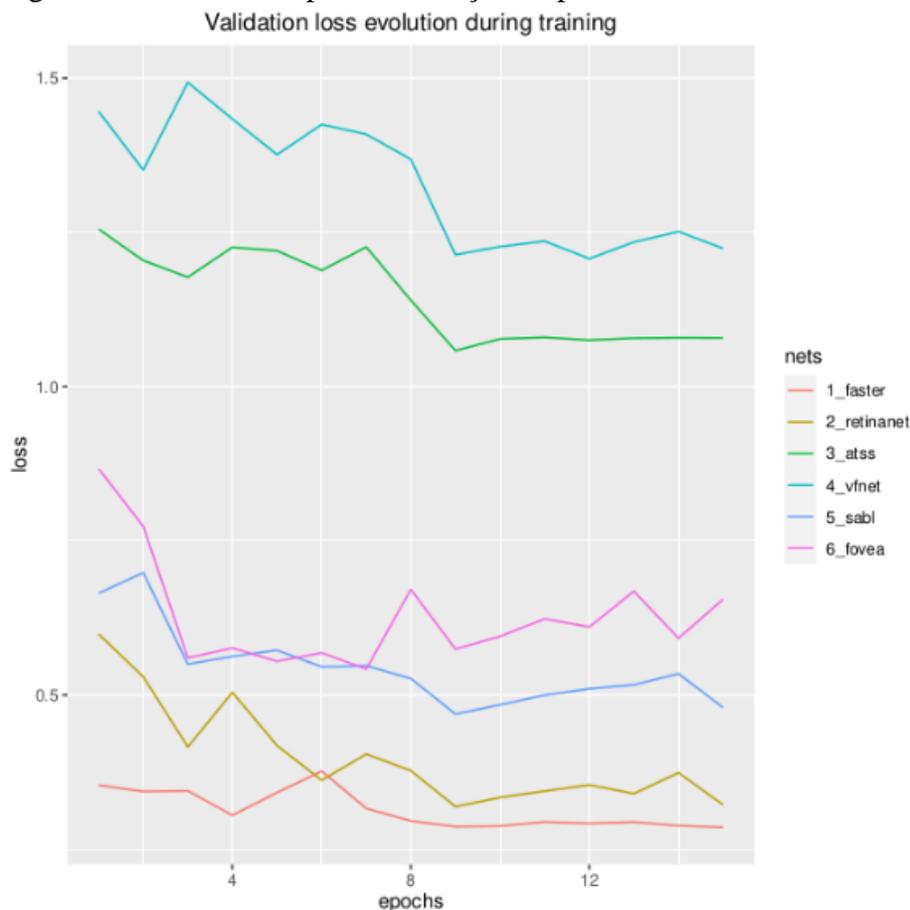
Fonte: Adaptado pela autora, baseado nos dados processados no laboratório INOVISÃO.

As curvas de aprendizagem dos métodos treinados são apresentadas na Figura 119. De modo geral, todos os métodos demonstraram aprendizado durante o treinamento. Em primeiro lugar, observa-se a diminuição da perda nas curvas durante o processo de validação, de acordo com as épocas. Isso significa que os algoritmos foram capazes de generalizar o problema usando os dados durante a etapa de treinamento.

Além disso, a evolução da perda durante o treinamento mostra que os métodos Faster R-CNN e Atss apresentaram estabilização a partir da décima época. No entanto, os métodos Retina-Net, Vfnet, Sabl e Fovea apresentaram instabilidade na etapa de aprendizado, com eventual tendência de aumento dos erros.

As variações nas curvas de perda (Figura 114) mostram a importância de se adotar muitas épocas para treinar os algoritmos, quando é possível verificar se ocorreu o processo de estabilização do aprendizado da rede e a não ocorrência de *Overfitting*. Se a perda não estiver diminuindo, pode-se deduzir que o algoritmo, nessa situação, não consegue generalizar devido a um pequeno conjunto de dados de validação ou treinamento ou, ainda, indica um problema de *Overfitting*. Por outro lado, o comportamento da curva pode indicar que a taxa de aprendizado adotada foi alta, o que dificulta o aprendizado de alguns métodos.

Figura 114 - Curvas de perda: evolução da perda durante o treinamento.



Fonte: Adaptado pela autora, baseado nos dados processados no laboratório INOVISÃO.

A partir da análise estatística realizada, foi possível verificar que as CNN's testadas mostram bom desempenho, com destaque para as redes Faster R-CNN, seguida pela Sabl e Fovea e Atss. As redes neurais Retina-Net e Vfnet foram aquelas que apresentaram os valores mais baixos nas nove métricas testadas.

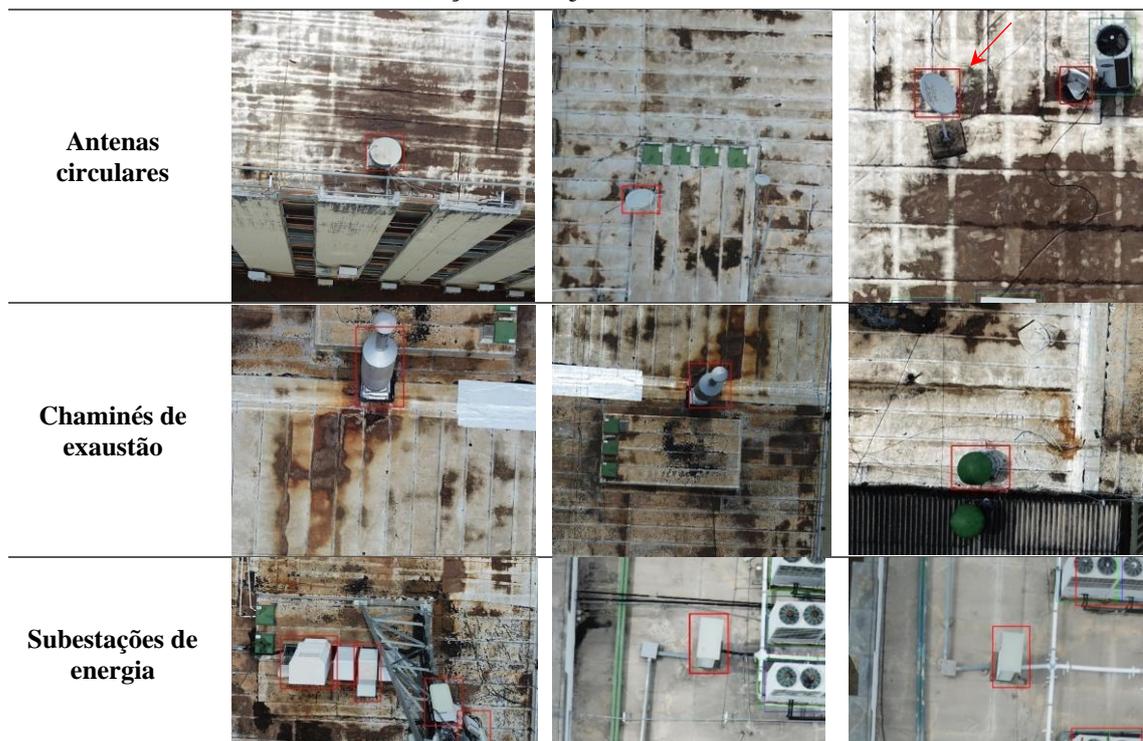
No geral, embora as redes neurais convolucionais tenham apresentado um bom desempenho, o principal objetivo desta discussão é analisar as razões pelos quais os erros ocorreram, visto que o banco de imagens utilizado é original, foi criado especificamente para este estudo e ainda não havia sido testado anteriormente. Ademais, o problema abordado neste trabalho representa uma lacuna na pesquisa, uma vez que não foram encontradas publicações

na revisão bibliográfica que tratem da detecção de equipamentos em cobertura, utilizando redes neurais. Assim, é primordial mapear os erros e identificar suas causas, com base nas anotações realizadas.

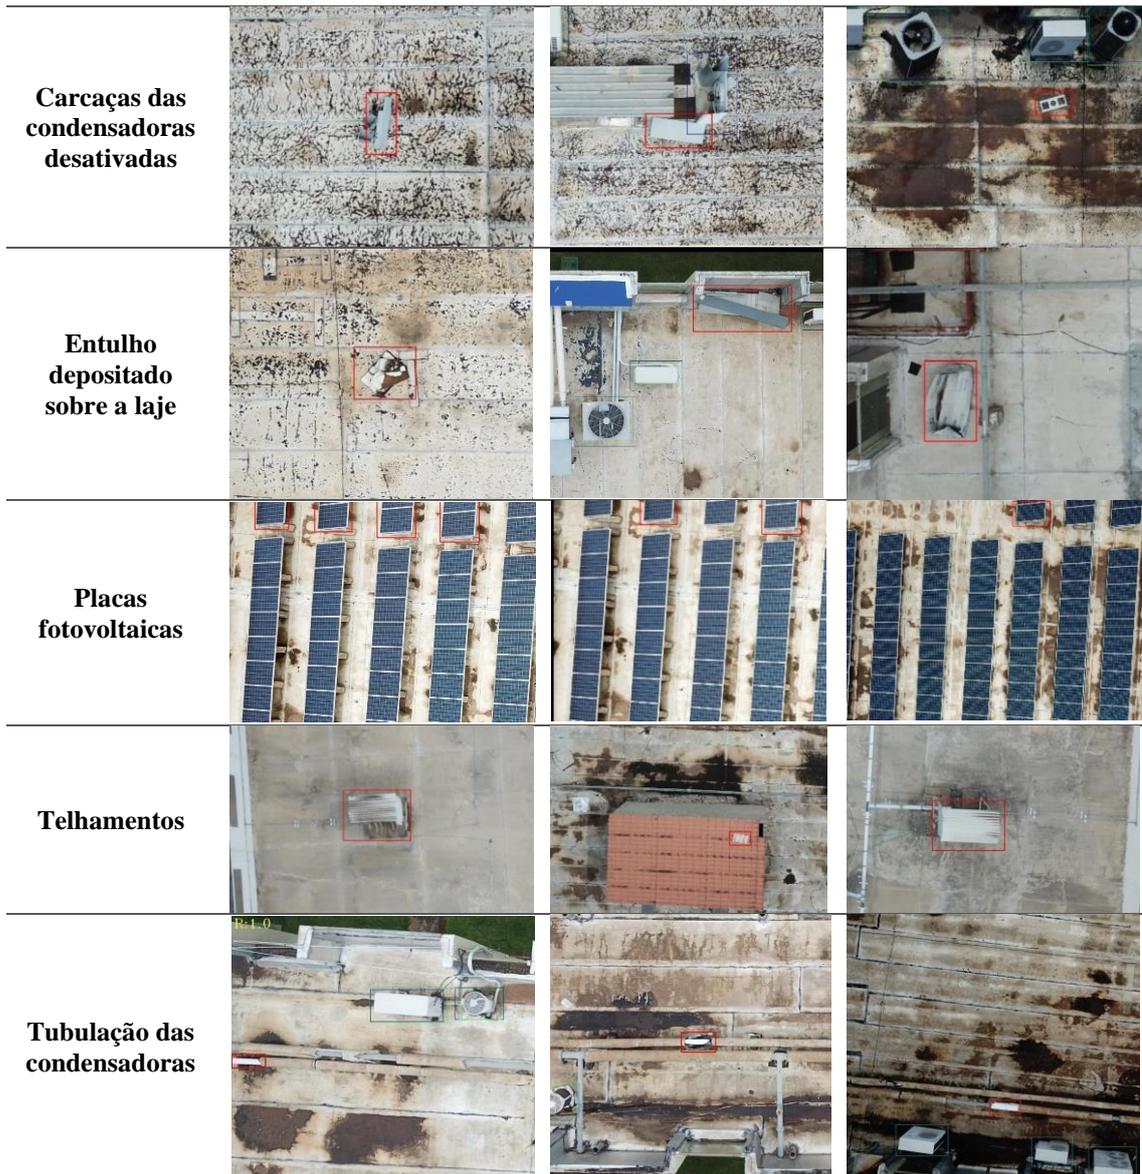
Após o treinamento das CNN, onde foram feitas de 0 a 1372 anotações em um banco de imagens com 330 imagens, foi possível analisar as condensadoras que foram identificadas corretamente e os erros cometidos pelas redes. Quando comparadas as anotações manuais (feitas pelo especialista) e automáticas (feitas pelas redes), verificou-se que a Faster R-CNN foi a rede que fez mais anotações corretas. Por outro lado, o erro mais recorrente foi a duplicação de anotação automática (Figura 114), principalmente pela Retina-Net e pela Sabl. Um outro importante erro identificado foram as perdas das anotações das imagens feitas na plataforma *Roboflow*, mas que não foram transportadas para as redes neurais treinadas no *MMDetection*.

A detecção de objetos semelhantes também foi um dos tipos de erros mais cometidos por todas as redes. No caso da cobertura plana em estudo, para as redes neurais testadas, os objetos semelhantes são as antenas com formatos circulares, as chaminés de exaustão da cozinha, as subestações retangulares das antenas de comunicação presentes na cor branca, carcaças de aparelhos desativados, entre outras situações mais esporádicas como entulho depositado sobre a laje, placas fotovoltaicas, telhamentos e tubulação das condensadoras (Tabela 30). Os objetos detectados incorretamente possuem formatos retangulares ou circulares, com características semelhantes às condensadoras.

Tabela 30 - Erros cometidos da detecção de objetos semelhantes.



Continuação



Fonte: Elaborado pela autora.

Muitos objetos foram identificados mesmo não tendo sido anotados. Por exemplo, destacam-se as anotações automáticas feitas nas condensadoras existentes nas fachadas dos edifícios (Figura 115) e os carros na cor branca (ambulância) presentes na calçada do pavimento térreo. Esse tipo de erro foi cometido principalmente pela Fovea.

Figura 115 - Erros de detecção de condensadoras na fachada pela rede Fovea.



Fonte: Elaborado pela autora.

A Figura 116 mostra o empoçamento de água que ocorre próximo aos ralos, ocasionado pela falta de inclinação no diagrama de caimento do sistema de cobertura até os dutos de queda e da alta concentração dos equipamentos ali instalados. A imagem capturada pelo drone possui boa resolução, o que permite ilustrar como esses equipamentos posicionados nos locais inadequados aceleram o processo da degradação da camada de impermeabilização devido à presença de umidade e sujeira, impactando no desempenho dos sistemas construtivos.

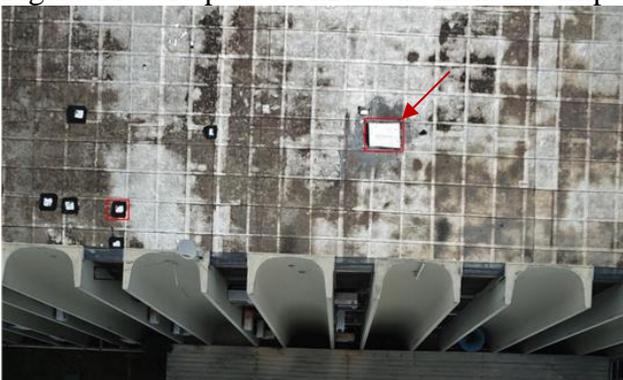
Figura 116 - Acúmulo de água na região das condensadoras.



Fonte: Elaborado pela autora.

As manutenções realizadas na manta de impermeabilização acarretaram diferença de coloração e, por isso, foram detectadas. Esses reparos na impermeabilização se destacam pelo formato retangular e pela coloração mais clara em relação à cor mais escura do fundo. A Figura 117 mostra a detecção dos reparos na impermeabilização, identificados como erro nas redes Faster R-CNN, RetinaNet, Vfnnet, Sabl e Fovea. Algumas situações ocasionaram a identificação equivocada da caixa delimitadora, que ficou deslocada do objeto anotado manualmente, influenciando um baixo valor de IoU. São os casos em que havia condensadoras com dois ou mais exaustores, ou mesmo condensadoras muito próximas umas das outras, devido à duplicidade do objeto pela anotação automática.

Figura 117 - Reparo realizado na manta de impermeabilização.



Fonte: Elaborado pela autora.

As redes neurais tiveram dificuldades em detectar as condensadoras nas imagens em que o ângulo de captura em relação ao objeto estava muito próximo do ângulo reto (90°) e nas imagens com fundo despigmentado. Essas áreas descoloridas podem ter interferido na homogeneidade da imagem, causando ruídos na imagem que podem influenciar na correta convolução dos pixels para identificação do formato e padrão das condensadoras. As imagens obtidas no voo de maior altitude apresentaram uma baixa resolução na dimensão das condensadoras e, por consequência, os algoritmos tiveram dificuldades em realizar a sua identificação. As imagens que as redes neurais não conseguiram identificar corretamente impactaram a métrica Recall.

A RetinaNet foi a rede que obteve pior desempenho na detecção, apresentando o maior número de erros (Figura 118). Os erros encontrados na rede RetinaNet concentraram-se nas detecções de condensadoras que já haviam sido anotadas, na detecção das condensadoras presentes nas fachadas e na detecção de subestações com formato e núcleos semelhantes às condensadoras.

Figura 118 - Erro na detecção de condensadoras na rede RetinaNet.



Fonte: Elaborado pela autora.

Quando tal desempenho é analisado à luz da teoria, discute-se o fato de que a RetinaNet é uma rede de detecção de um estágio, que busca alcançar o desempenho das redes de dois estágios e manter a complexidade computacional reduzida. No experimento realizado, tal suposição não se confirmou, visto que seu desempenho não superou as outras arquiteturas de rede, inclusive a Faster R-CNN que é uma rede de dois estágios para a detecção. Por outro lado, a Atss é um método que preenche a lacuna entre detectores baseados em âncoras e livres de âncoras. Ao analisar o bom desempenho da Atss para um valor de *Precision* = 0,959 (maior entre todas as redes testadas), discute-se as vantagens de um método especializado em detecção

poder selecionar automaticamente as amostras positivas e negativas, de acordo com as características do objeto.

Foi realizada uma análise detalhada das anotações no banco dos resultados das 330 imagens processadas pelas seis redes neurais profundas avaliadas. A Tabela 31 mostra os dados consolidados dessa análise, distribuídos em três colunas. A primeira coluna foi atribuída ao número total da quantidade de anotações realizadas na plataforma *Roboflow*, somando 1372 anotações no total para cada rede. Essas anotações correspondem aos objetos de interesse, especificamente as condensadoras, anotados manualmente.

A segunda coluna são os verdadeiros positivos, as anotações identificadas pela rede, apresentando o número de anotações que as redes neurais foram capazes de identificar corretamente como condensadoras. Este dado reflete o bom desempenho das redes na detecção do objeto-alvo, mostrando a capacidade de aprendizado dos modelos treinados.

A terceira coluna são os falsos positivos, corresponde aos erros de detecção em que as redes confundiram as condensadoras com outros objetos ou formas semelhantes. Esse tipo de erro ocorreu principalmente devido ao formato e cor que se assemelham às condensadoras.

Tabela 31 - Contagem das anotações.

Redes	Anotação manual	Anotação automática	Falso positivo
Faster R-CNN	1372	1327	100
Retinanet	1372	1113	120
Atss	1372	1193	49
Vfnet	1372	849	90
Sabl	1372	1329	105
Fovea	1372	1327	108

Fonte: Elaborado pela autora.

Os dados apresentados na Tabela 31 confirmam as observações anteriores sobre o desempenho das redes avaliadas. As redes RetinaNet e Vfnet demonstraram os piores resultados, evidenciados pela quantidade reduzida de acertos nas anotações, sinalizada em vermelho na segunda coluna da tabela. A Vfnet apresentou o menor número de detecções corretas, seguida pela RetinaNet, o que reforça suas limitações em relação às demais arquiteturas no contexto específico do estudo.

Por outro lado, as redes Faster R-CNN e Fovea obtiveram resultados equivalentes ao processo manual em relação ao total de anotações, comprovando seu desempenho na detecção correta. Contudo, ambas apresentaram incidência de falsos positivos.

Na análise dos falsos positivos (terceira coluna), a rede Atss destacou-se por apresentar a menor quantidade de erros, demonstrando maior confiabilidade na identificação de condensadoras e menor tendência a confundir características visuais similares. Por outro lado, a RetinaNet apresentou um volume expressivamente maior de detecções incorretas, o que indica

fragilidade em lidar com objetos que compartilham características visuais semelhantes ao objeto de interesse.

Em síntese, o experimento conduzido nas coberturas planas do Quartel-General do Exército Brasileiro (QGEx) para detecção de condensadoras de equipamentos de ar-condicionado destacou-se pelo seu caráter pioneiro. Ao testar seis redes neurais convolucionais, avaliadas em nove métricas, foi possível identificar os erros cometidos pelos algorítmicos, bem como as suas causas. Além disso, os erros foram mapeados por meio de comparações entre as anotações manuais e as automatizadas. Essa análise, relacionada à avaliação dos modelos, é relevante para o processo de aquisição de imagens destinadas à composição do banco de imagens.

5.6.2 Resultados do processo automatizado para segmentação semântica de manchas de umidade

5.6.2.1 Considerações Iniciais

A estanqueidade das coberturas planas é assegurada pelos sistemas de impermeabilização, os quais devem manter o desempenho requerido frente às condições de exposição impostas. Após um período de chuva, é frequente a presença de empoçamentos e manchas de umidade sobre a camada de impermeabilização e sua proteção mecânica. As irregularidades da superfície ou a declividade insuficiente para o escoamento das águas pluviais estão entre as principais causas dos danos.

Na aplicação do sistema de impermeabilização, a depender do posicionamento longitudinal ou transversal das faixas de mantas em direção aos tubos de drenagem, as sobreposições e emendas das mantas e suas interseções geram problemas de empoçamento de água. Além disso, os ressaltos nas mantas e os reparos de manutenção favorecem a deposição de sujeira, colonização biológica e crescimento de vegetação invasiva, irregularidades responsáveis pelo surgimento das manchas de umidade.

A maioria das manchas é prejudicial, pois na fase inicial afetam a parte estética, mas se permanecerem, contribuem para o agravamento de outras manifestações patológicas (Flores-Colen; Brito; Freitas, 2008). Os manchamentos podem indicar locais com ocorrência de infiltrações de água que aceleram os mecanismos de degradação, implicando na perda das condições de habitabilidade. Por vezes, para se encontrar a origem das infiltrações, é necessário remover camadas de revestimento, argamassa e proteções (Torres-González et al., 2023; Santos et al., 2023; González-Domínguez, 2020).

Neste experimento, buscou-se tratar as manchas de umidade como indicadores de pontos ou regiões da laje de cobertura onde ocorrem as infiltrações que comprometem o

desempenho do sistema construtivo. As manchas de umidade sobre a cobertura podem variar em tamanho, cor, tonalidade e gravidade; a depender da exposição à insolação e aos ventos, podem secar. Porém, as manchas sinalizam processos evolutivos de degradação que afetam a durabilidade dos componentes da cobertura.

Nas inspeções prediais em sistemas de cobertura, o campo visual do inspetor responsável pela vistoria é diferente do campo de visão das câmeras do drone, durante o sobrevoo. Por isso, a inspeção tradicional nem sempre identifica a presença das manchas e sua gravidade, na totalidade da superfície da cobertura.

Nos últimos anos, os métodos para inspeções prediais automatizadas avançaram na detecção de manifestações patológicas. Apesar do rápido progresso das tecnologias digitais e dos tipos de processamentos de dados baseados em *deep learning* (DL), ainda há um espaço enorme para a investigação e o seu desenvolvimento (Cha *et al.*, 2024). Nesse sentido, Cao (2023) considera que os danos em superfícies de componentes arquitetônicos recebem pouca atenção, visto que predominam os estudos sobre o *structural health monitoring* (SHM) com o uso de DL, voltado à detecção de fissuras e deformações estruturais.

Vários estudos têm se dedicado ao uso da segmentação semântica de imagens (Mo *et al.*, 2022) para a detecção de manifestações patológicas em edificações (Dais *et al.*, 2021; Midwinter; Al-Sabbag; Yeum, 2023). A segmentação semântica atribui um rótulo de categoria a cada pixel de uma imagem, fornecendo informações de categoria no nível do pixel, e isto tem sido aplicado na detecção de danos (Hao; Zhou; Guo, 2020). A utilização da segmentação semântica associada às imagens capturadas por drone, com anotações de imagens em coberturas, têm apresentado resultados significativos.

Na literatura, foram encontrados poucos estudos que tratam de segmentação semântica em coberturas. Especialmente, quando se trata de manchas em coberturas planas, destaca-se a pesquisa de Yudin, Naumov e Patrakova (2018) que utilizam anotações da região de interesse em máscaras binárias e aplicam unicamente o modelo Fully Convolutional Networks (FCN) como arquitetura de rede, o que motiva o interesse desse experimento em comparar outros modelos de segmentação semântica baseado em *deep learning* para o aprofundamento e aprimoramento da sua aplicação.

Nesse contexto, o objetivo deste estudo experimental é analisar o uso da segmentação semântica baseada em *deep learning* com imagens adquiridas por drone, para mapear e monitorar as manchas de umidade durante os processos de inspeção predial automatizada em sistemas de cobertura plana. Este experimento testou dois tipos de redes neurais convolucionais

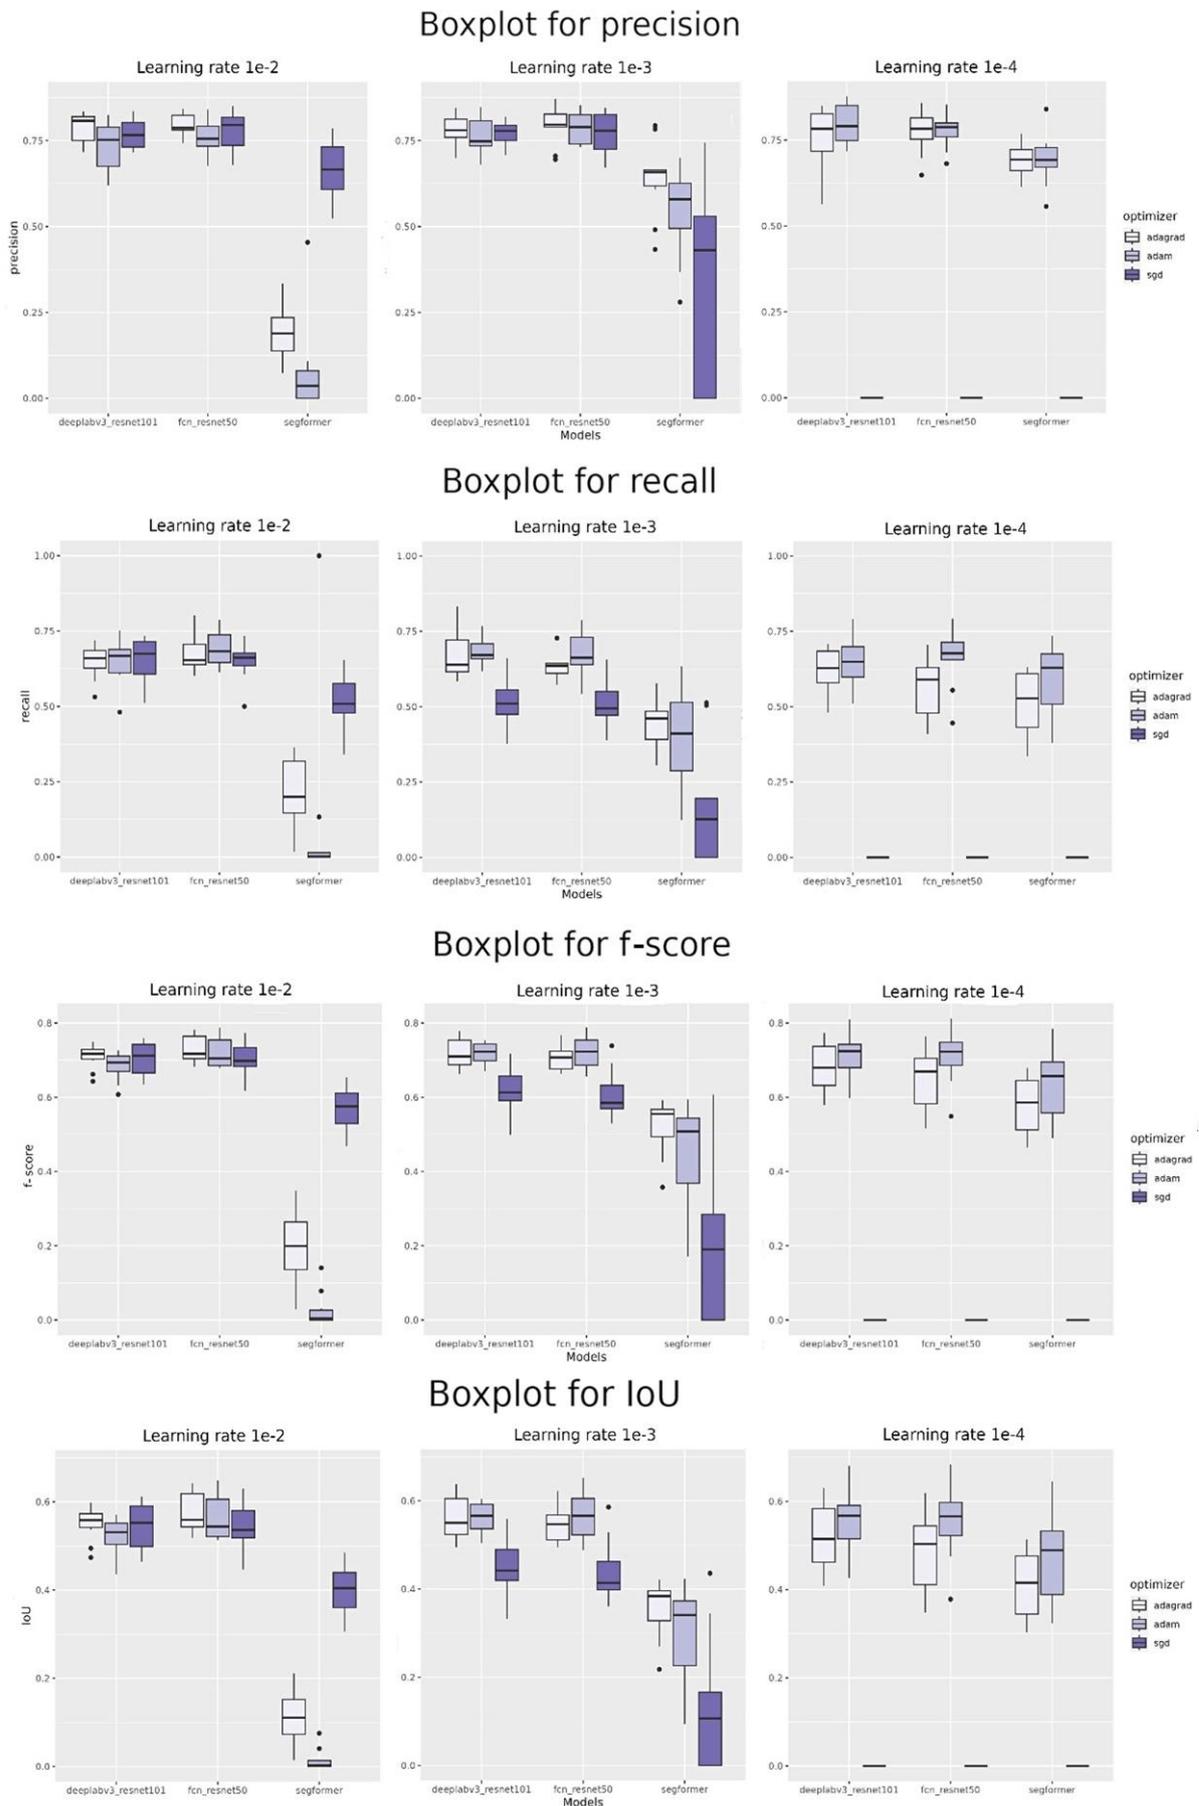
de segmentação semântica (FCN e DeepLabV3) e uma rede neural artificial profunda do tipo transformer (SegFormer), que foram comparadas mediante quatro métricas de desempenho.

5.6.2.2 Resultados do Experimento para Segmentação Semântica de Manchas de Umidade

Os resultados das métricas de desempenho dos modelos testados são apresentados detalhadamente na Tabela 32. As métricas *precision*, *recall*, *f-score* e *IoU* estão agrupadas em combinações de *a* até *e*, conforme os resultados da ANOVA e dos testes de hipótese de Tukey. A Figura 119 representa os resultados em gráficos do tipo *boxplot* que ilustram comparativamente a dispersão dos valores em torno da mediana, conforme as arquiteturas, otimizadores e taxas de aprendizagem adotadas.

Ao examinar a Tabela, foi observado que as maiores médias para todas as métricas foram obtidas pela FCN, quando otimizada por Adagrad com uma taxa de aprendizagem de $1e-2$. As médias obtidas nesse caso para *precision*, *recall*, *F-score* e *IoU* foram, respectivamente: 79,69%, 67,81%, 73,09% e 57,70%. Por outro lado, observa-se que várias das técnicas utilizadas obtiveram médias estatisticamente semelhantes em todas as métricas. Isso ocorreu principalmente com as redes DeepLabV3, mas ocasionalmente também com a arquitetura SegFormer. Esta, porém, obteve resultados estatisticamente inferiores nas quatro métricas, com a maior parte das estratégias de otimização utilizadas. Além disso, pode-se observar que em alguns casos a performance das redes foi zero, ou próxima a zero. Isso se deve, possivelmente, à ocorrência de problemas de otimização, como *exploding gradients* (Glorot; Bengio; 2010). Isso ocorreu com todas as redes neurais otimizadas por SGD a uma taxa de $1e-4$.

Figura 119 - *Boxplot* dos resultados.



Fonte: Adaptado pela autora, baseado nos dados processados no laboratório INOVISÃO.

Tabela 32 - Resultado das Métricas: precision, recall, F-score e IoU.

Métricas	Arquiteturas	Otimizador	Taxa de aprendizagem	CLD	Mean (\pm sd) [%]	Median (IQR) [%]
Precision	FCN	Adagrad	1e-2	a	79,69 (\pm 3,06)	78,73 (4,32)
	DeepLabV3	Adam	1e-4	a	79,43 (\pm 5,97)	79,03 (10,24)
	SegFormer	Adam	1e-4	ab	69,35 (\pm 7,54)	69,25 (5,68)
Recall	FCN	Adagrad	1e-2	a	67,81 (\pm 6,27)	65,36 (6,77)
	DeepLabV3	Adam	1e-4	a	65,00 (\pm 8,82)	64,90 (10,09)
	SegFormer	Adam	1e-4	ab	59,61 (\pm 12,29)	62,88 (16,72)
F-score	FCN	Adagrad	1e-2	a	73,09 (\pm 3,53)	71,74 (6,00)
	DeepLabV3	Adam	1e-3	a	71,91 (\pm 3,03)	72,29 (4,50)
	SegFormer	Adam	1e-4	abcd	63,61 (\pm 9,60)	65,70 (13,70)
IoU	FCN	Adagrad	1e-2	a	57,70 (\pm 4,42)	55,93 (7,50)
	DeepLabV3	Adam	1e-3	ab	56,23 (\pm 3,67)	56,61 (5,50)
	SegFormer	Adam	1e-4	abcde	47,29 (\pm 10,25)	48,93 (14,40)

Fonte: Adaptado pela autora, baseado nos dados processados no laboratório INOVISÃO.

Em particular, a rede FCN, otimizada com o algoritmo Adagrad, demonstrou uma sólida capacidade de distinguir manchas de outros objetos. Ao mesmo tempo, o DeepLabV3 teve um bom desempenho em regiões propensas à estagnação de água, locais que frequentemente causam confusão e tendem a dificultar o trabalho de outros modelos algorítmicos tradicionais (Brar *et al.*, 2025).

Em relação às métricas, F-measure e IoU foram úteis para avaliar a robustez do modelo, fornecendo um equilíbrio entre *precision e recall*. Observando essas métricas, podemos entender melhor como os modelos lidam com tarefas simples e complexas, como a segmentação semântica (Rainio; Teuho; Klén, 2024). Especialmente em casos complexos, onde detalhes finos ou objetos pequenos estavam envolvidos, a precisão dos modelos tendia a ser menor, indicando espaço para melhorias.

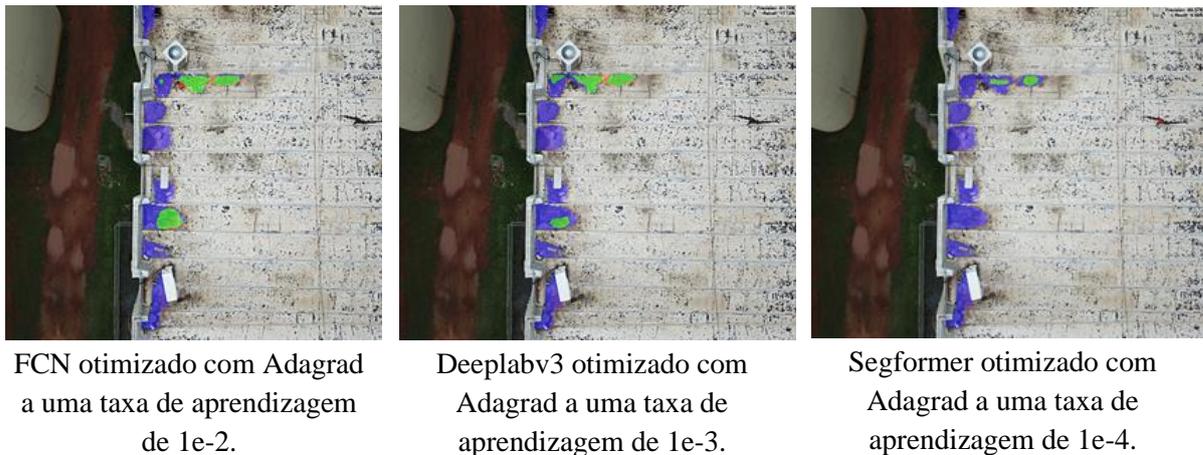
Os resultados alcançados pelas redes SegFormer indicam que otimizar essas arquiteturas de rede é uma tarefa muito desafiadora, possivelmente porque são baseadas em *transformers* em vez de convoluções. Desde a concepção do *Vision Transformer* (ViT) por Dosovitskiy *et*

al., (2020), tem sido geralmente aceito que o desempenho de redes neurais baseadas em *transformers* pode ser melhor do que o de CNNs, desde que os conjuntos de dados usados para treinamento sejam maiores. Isso pode ter ocorrido no caso da SegFormer, embora a tarefa a ser realizada seja a segmentação (Thisanke *et al.*, 2023). Portanto, essa arquitetura pode ser reavaliada em trabalhos futuros com conjuntos de dados maiores.

5.6.2.3 Discussão dos Resultados para Segmentação Semântica de Manchas de Umidade

Dadas as características visuais complexas das superfícies de lajes planas, especialmente quando as imagens são capturadas por drones, é importante avaliar a robustez dos modelos usados para segmentação de manchas. Neste estudo, constatou-se que as redes neurais avaliadas foram capazes de identificar efetivamente manchas de umidade, mesmo em áreas com a presença intensa de tubos de drenagem, equipamentos e detritos. Especialmente, as redes FCN e DeepLabV3 segmentaram com sucesso manchas escuras perto de platibandas e drenos, apesar da interferência visual de objetos ao redor. Esse desempenho pode ser observado na Figura 120, onde as segmentações realizadas pelas redes são claramente visíveis.

Figura 120 - Segmentação usando FCN, Deeplabv3 e SegFormer.



Fonte: Elaborado pela autora.

As Figuras 121 a 124 mostram a sobreposição das previsões feitas por modelos FCN e DeepLabV3 para uma imagem da região próxima à platibanda. Em parte dos casos, os erros cometidos pelos modelos testados estão próximos aos dutos de drenagem, platibandas e equipamentos. Essas regiões são mais críticas porque, frequentemente, ocorrem estagnação de água por falta de limpeza dos ralos, entupimentos dos dutos de drenagem e pela presença de equipamentos instalados inadequadamente.

Figura 121 - Segmentação usando FCN com otimizador Adagrad em diferentes taxas de aprendizado.



Taxa de aprendizagem de $1e-4$

Precision: 49.08%

Recall: 32.66%

Taxa de aprendizagem de $1e-3$

Precision: 52.68%

Recall: 70.70%

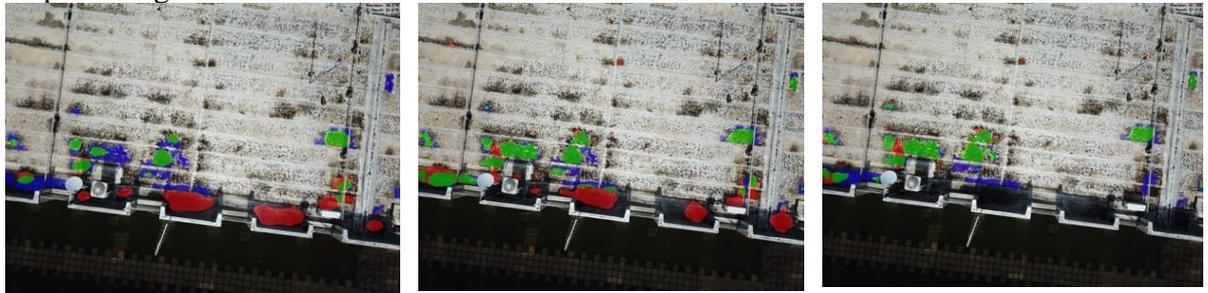
Taxa de aprendizagem de $1e-2$

Precision: 53.50%

Recall: 68.47%

Fonte: Elaborado pela autora.

Figura 122 - Segmentação usando DeepLabV3 com otimizador Adagrad com diferentes taxas de aprendizagem.



Taxa de aprendizagem de $1e-4$

Precision: 36.57%

Recall: 34.67%

Taxa de aprendizagem de $1e-3$

Precision: 51.44%

Recall: 68.14%

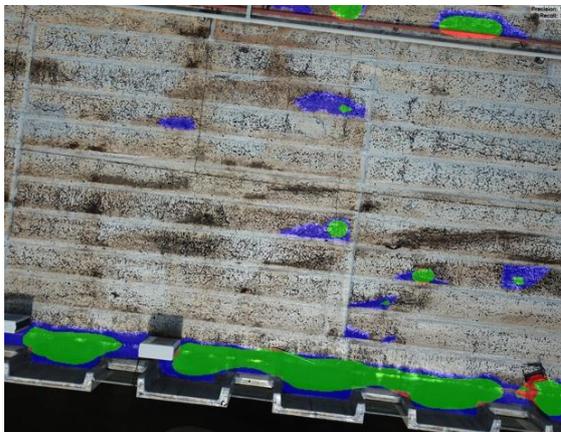
Taxa de aprendizagem de $1e-2$

Precision: 81.18%

Recall: 57.41%

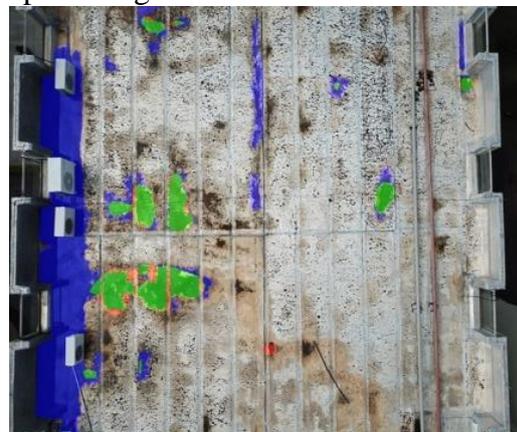
Fonte: Elaborado pela autora.

Figura 123 - Acúmulo de água próximo aos tubos de drenagem - DeepLabV3 otimizada com Adagrad e uma taxa de aprendizagem de $1e-4$.



Fonte: Elaborado pela autora.

Figura 124 - Segmentação de falsos negativos (FN=azul) em manchas próxima aos dutos de drenagem, equipamentos e platibanda - FCN otimizada com Adagrad e uma taxa de aprendizagem de $1e-4$.



Fonte: Elaborado pela autora.

Como a ocorrência de manchas pode ser mais comum nessas regiões, é possível que as decisões tomadas pelas redes estejam sendo influenciadas por informações espaciais e por

características visuais das platibandas, e não por aspectos relacionados às manchas, o que leva a uma quantidade maior de falsos positivos. Por outro lado, a presença de falsos negativos nas regiões próximas à platibanda em determinadas imagens indica que, embora a posição em relação a mesma possa não ser relevante, ela pode estar influenciando a segmentação. Se assim for, é possível que a coleta de novos dados, bem como o uso de técnicas diferentes de aumento de dados e de uniformização possam contribuir para o aumento da performance dos modelos.

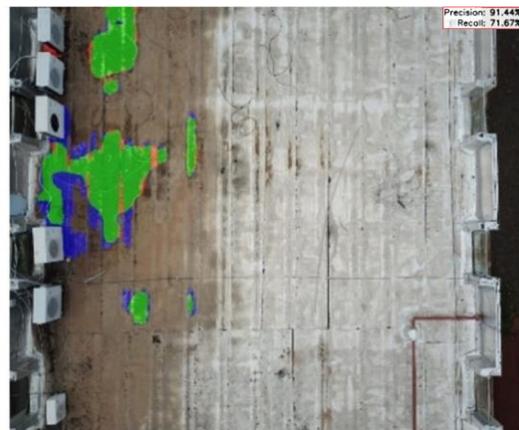
O banco de imagens utilizado no experimento contém imagens tanto de mantas asfálticas com proteção mecânica por camada de argamassa (Figura 125) como mantas asfálticas com proteção por película aluminizada (Figura 126). As manchas mais claras ou mais escuras ocorrem da mesma forma sobre ambos os tipos de materiais. Ao longo do tempo, a película de alumínio se desgasta, sem causar necessariamente empoçamento de água ou concentração de umidade. As redes aprenderam bem ao identificar as manchas escuras em ambas as situações, sem grandes confusões.

Figura 125 - Manchas de umidade claras e escuras na proteção mecânica com argamassa – FCN otimizada com Adagrad e uma taxa de $1e-4$.



Fonte: Elaborado pela autora.

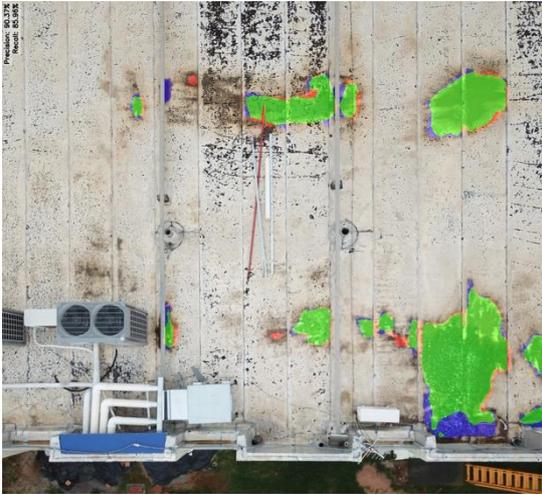
Figura 126 - Mancha de umidade claras e escuras na manta aluminizada – DeepLabV3 otimizada com Adagrad e uma taxa de $1e-2$.



Fonte: Elaborado pela autora.

O sentido de instalação das faixas de manta asfáltica de impermeabilização implica em maior acúmulo de água da chuva e sujeidade, pois impactam diretamente no escoamento da água para os dutos de drenagem. A técnica de colocação das faixas de manta contrária ao escoamento das águas é indevida, por isso é maior a quantidade das manchas segmentadas no sentido paralelo às platibandas (Figura 127). Inclusive, na imagem é possível identificar pontilhamento na película aluminizada. Porém, o desempenho das redes mostra que não houve distinção entre ambas as soluções técnicas de proteção e tampouco foram segmentados os pontilhamentos. Isso demonstra que a película de alumínio não prejudicou na segmentação, e a aprendizagem dos modelos foi conforme o esperado.

Figura 127 - Mantas aluminizadas aplicadas no sentido do caimento para os dutos de drenagem (técnica mais adequada para o escoamento das águas pluviais) - FCN com otimizador Adagrad e 1e-2.



Fonte: Elaborado pela autora.

Em algumas partes da cobertura foi identificada a presença de entulhos deixados sobre a laje impermeabilizada, decorrente das ações de manutenção. Restos de vidros e carcaças de condensadoras em desuso foram segmentados pelas redes como falso positivo (FP=vermelho), possivelmente por causa da coloração do entulho (Figura 128).

Figura 128 - Segmentação falso positivo de entulhos presentes no sistema de cobertura - FCN com otimizador Adagrad e um taxa de aprendizagem de 1e-4.



Fonte: Elaborado pela autora.

Na pesquisa realizada, o desafio para identificar as manchas está relacionado à segmentação de objetos de tamanho, forma e cor variáveis, em imagens de ambientes complexos devido às condições de exposição ao meio natural e a presença de uma diversidade de dispositivos acoplados na superfície de estudo. A presença de pixels semelhantes tanto nas manchas claras como nas manchas escuras e nos detritos na superfície da cobertura plana pode confundir os operadores, dificultando o treinamento eficaz do modelo de segmentação.

A métrica *F-score* foi fundamental para equilibrar as métricas *precision* e *recall*, oferecendo uma visão geral mais clara dos dados resultantes dos modelos. Isso facilitou a análise dos resultados de forma mais integrada. Além disso, a métrica *Intersection over the Union* (IoU) proporcionou uma avaliação mais detalhada da localização dos objetos de estudo identificados pelos modelos. Esses resultados reforçam a hipótese de que o conjunto de dados

é complexo e apresenta uma variação considerável, o que contribui para as dissimilaridades observadas entre os dados.

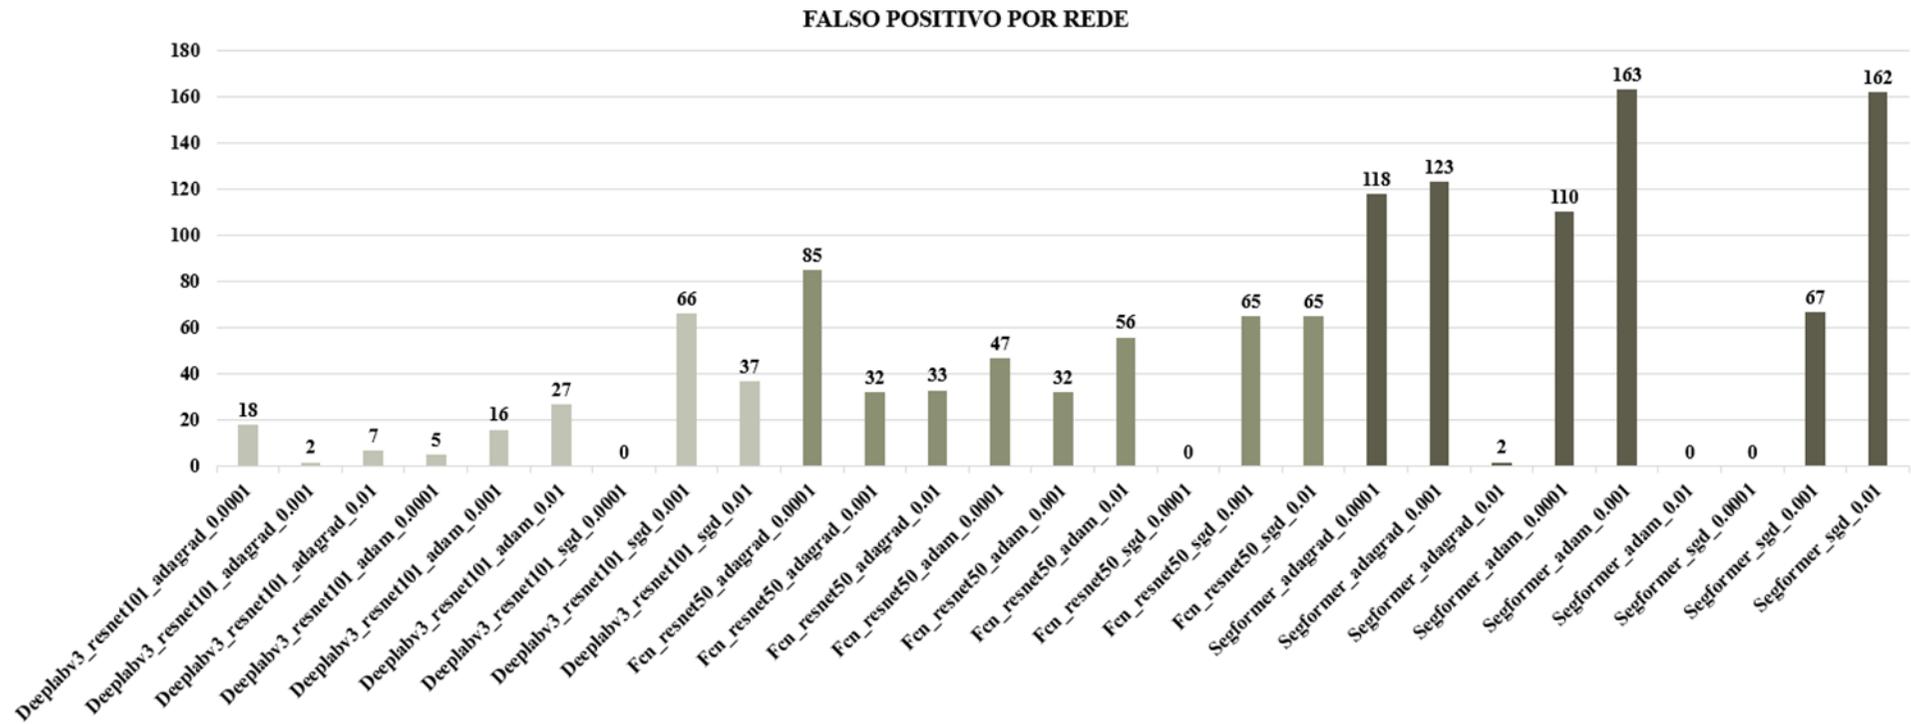
5.6.2.4 *Análise dos Tipos de Erros no Experimento Realizado*

Para aprofundar o entendimento do experimento, foram analisados os tipos de erro cometidos pelos três modelos de redes neurais convolucionais (ResNet101 e ResNet50) e uma rede neural do tipo transformer (SegFormer). Foram revisitadas 27 pastas, cada uma contendo 126 imagens, totalizando 3.402 imagens revisadas de resultados processados pelas redes neurais artificiais.

Com base nessas análises de erros, foi sistematizada a contagem de falsos positivos por rede (FP=vermelho). A Figura 129 apresenta um gráfico da contagem de falso positivo por rede, permitindo identificar aquelas que apresentaram maior ou menor propensão a erros. A Figura 130 mostra o quantitativo de cada tipo de rede, cometido por todas as redes. Essas informações são importante para que os processos de segmentação possam ser melhorados em experimentos futuros. Além disso, são informações que ajudam na construção de um banco de imagens.

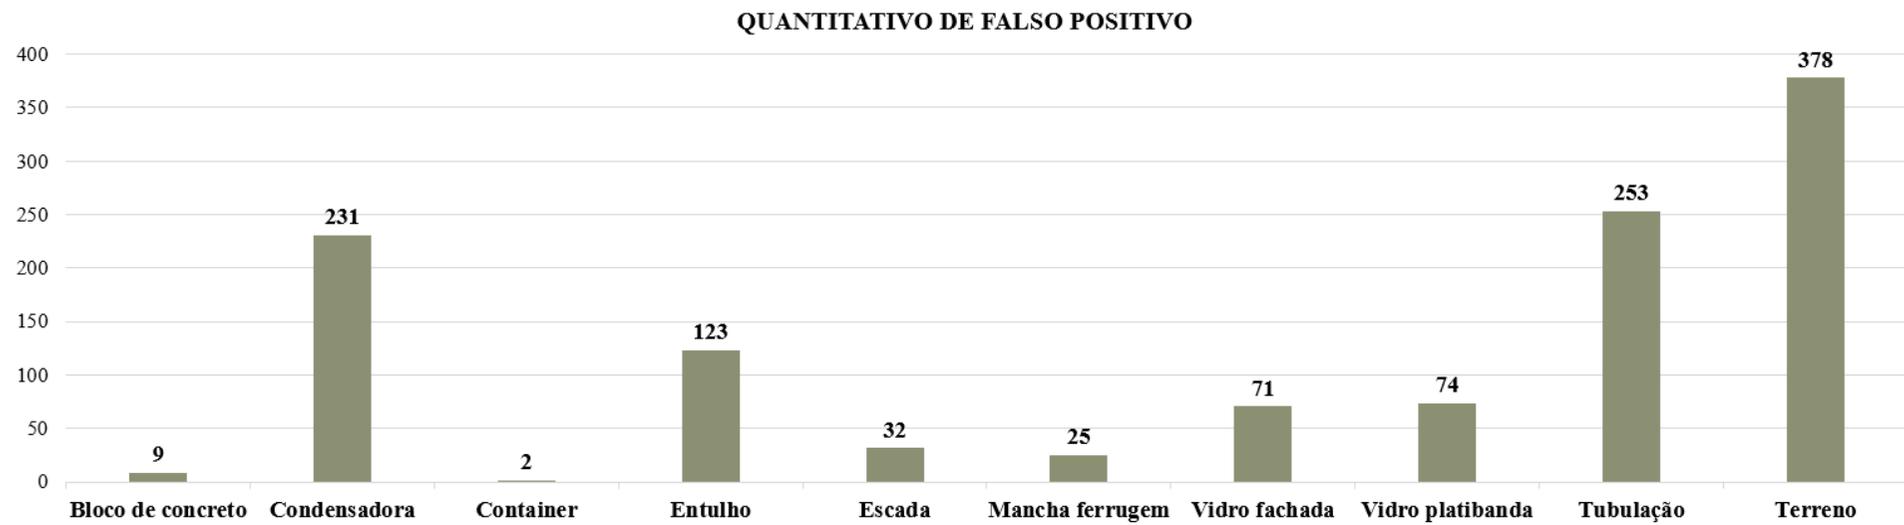
A SegFormer mostrou o maior número de segmentações incorretas, com 745 imagens, representando 65% das análises realizadas com este modelo. A ResNet50 aparece como a segunda rede com maior incidência de falsos positivos em 415 imagens, equivalente a 36% do total analisado. A ResNet101 apresentou o menor percentual de falsos positivos entre as redes analisadas, com 178 imagens (15% do total). Esses resultados evidenciam as redes mais adequadas à solução do problema proposto, pois apresentam menor confusão na segmentação das manchas clara e manchas escuras.

Figura 129 - Contagem de falso positivo por rede.



Fonte: Elaborado pela autora.

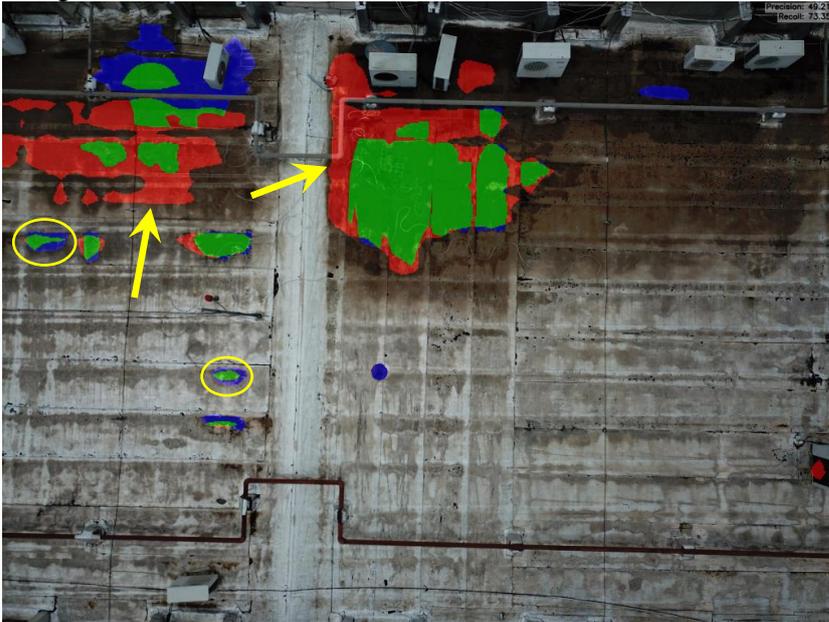
Figura 130 - Quantitativo de falso positivo de todas as redes.



Fonte: Elaborado pela autora.

Na Figura 131, observa-se que, em algumas áreas da segmentação realizada, as manchas aparecem em verde com bordas azuis ou verde como bordas vermelhas. A região central da mancha, destacada em verde, indica que a rede conseguiu identificar parcialmente a mancha anotada. No entanto, as bordas em azul mostram que o modelo teve dificuldade em determinar a delimitação exata da mancha escura, possivelmente devido à transição de cor e textura para as bordas mais claras, o que pode ter confundido o algoritmo.

Figura 131 - Exemplificação da segmentação de falso positivo – DeepLabV3 otimizada com Adagrad e uma taxa de $1e-4$.



Fonte: Elaborado pela autora.

As Figuras 132 e 133 mostram os falsos positivos que ocorreram na segmentação de regiões do terreno capturadas nas imagens. A semelhanças entre a cor do solo e as manchas pode ser a causa da confusão. Destaca-se que a ausência de uma delimitação geométrica prévia da área de cobertura a ser analisadas nas imagens contribuiu para esses erros de segmentação.

Em particular, a rede SegFormer apresentou um total de 249 segmentações de falso positivo atribuídas ao terreno. A semelhança de tonalidade entre as manchas de interesse e o terreno levou a uma confusão nos padrões aprendidos pela rede, destacando um aspecto crítico na preparação e seleção do conjunto de dados.

Figura 132 - Segmentação de falso positivo no terreno – SegFormer Adam 1e-3.



Fonte: Elaborado pela autora.

A análise dos falsos positivos revelou que, além do terreno, as tubulações também foram frequentemente confundidas com manchas devido à similaridade de cor, conforme mostram as Figura 134 e Figura 135.

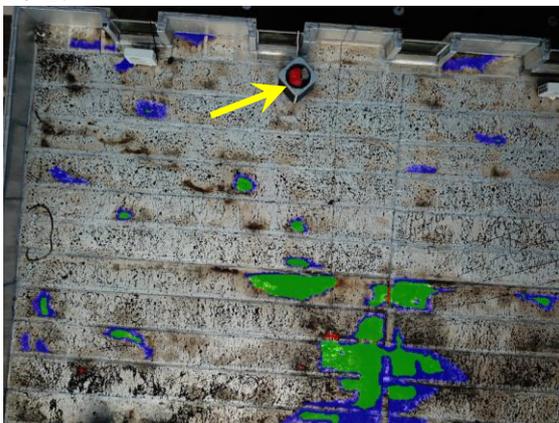
Figura 134 – Segmentação de falso positivo na tubulação – SegFormer SGD 1e-2.



Fonte: Elaborado pela autora.

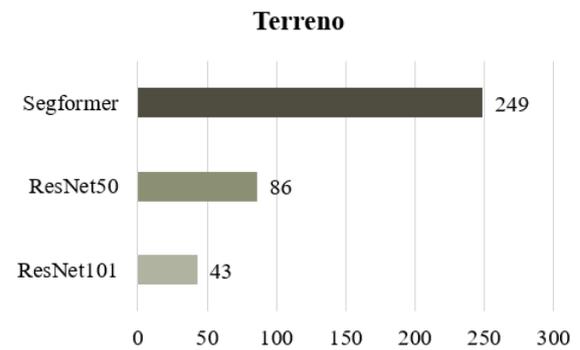
As condensadoras estão presentes em grande quantidade no sistema de cobertura plana. Os falsos positivos ilustrados nas Figuras 136 e 137 mostram que a segmentação de condensadoras é um tipo de erro muito frequente cometido pelas redes neurais.

Figura 136 - Segmentação de falso positivo na tubulação - SegFormer SGD 1e-2.



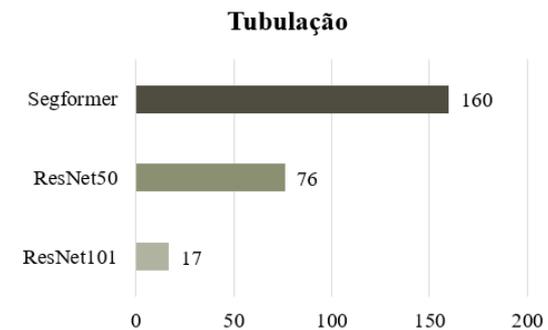
Fonte: Elaborado pela autora.

Figura 133 - Contabilização de falso positivo do terreno para cada rede.



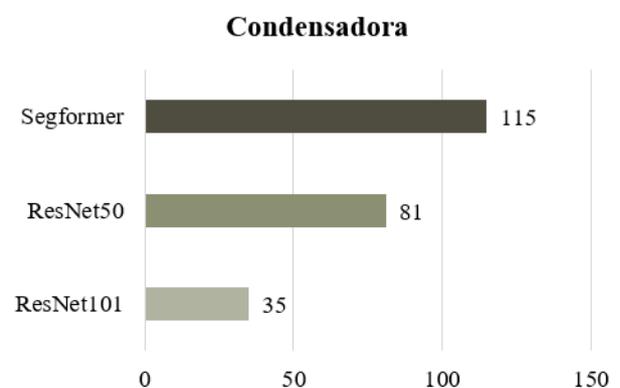
Fonte: Elaborado pela autora.

Figura 135 - Contabilização de falso positivo da tubulação para cada rede.



Fonte: Elaborado pela autora.

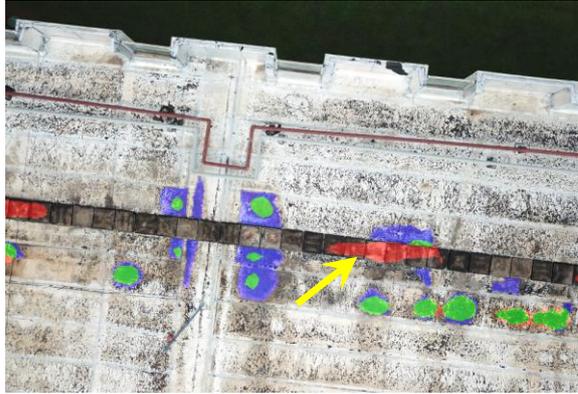
Figura 137 - Contabilização de falso positivo da tubulação para cada rede.



Fonte: Elaborado pela autora.

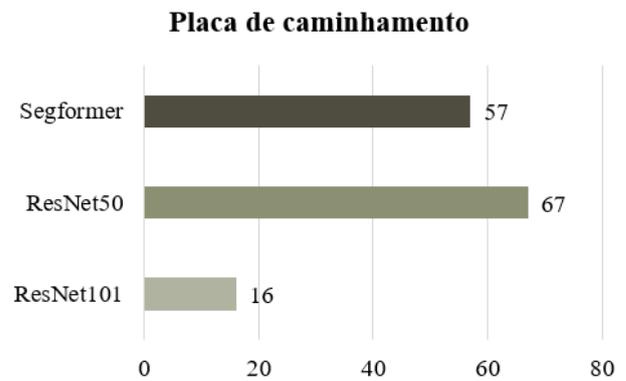
A segmentação com maior número de erros foram as placas de caminhamento sobre o sistema de impermeabilização da laje de cobertura (Figura 138 e Figura 139). Esses resultados podem ser atribuído à cor mais escura do piso argamassado das placas em relação ao fundo.

Figura 138 - Segmentação de falso positivo na placa de caminhamento – ResNet50 Adagrad 1e-4.



Fonte: Elaborado pela autora.

Figura 139 - Contabilização de falso positivo da placa de caminhamento para cada rede.



Fonte: Elaborado pela autora.

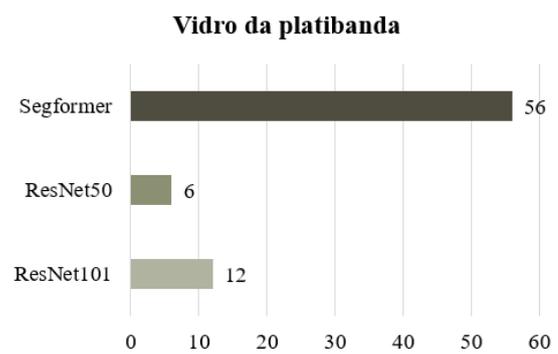
A confusão observada na segmentação do vidro da platibanda pode ser atribuída à reflexibilidade e à transparência do material, características que podem confundir os modelos de rede, especialmente em condições de iluminação variada. As Figuras 140 e 141 ilustram a ocorrência dos falsos positivos relacionados ao vidro da platibanda.

Figura 140 - Segmentação de falso positivo no vidro da platibanda – SegFormer Adam 1e-3.



Fonte: Elaborado pela autora.

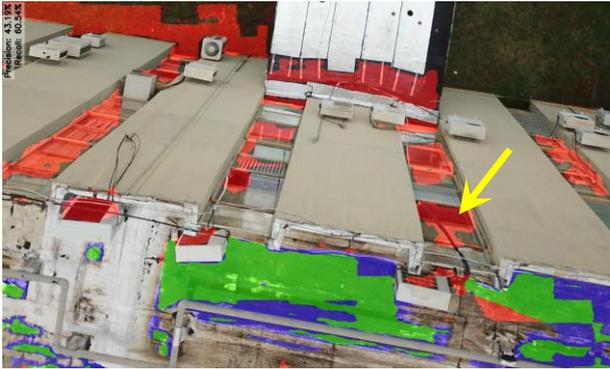
Figura 141 - Contabilização de falso positivo do vidro da platibanda para cada rede.



Fonte: Elaborado pela autora.

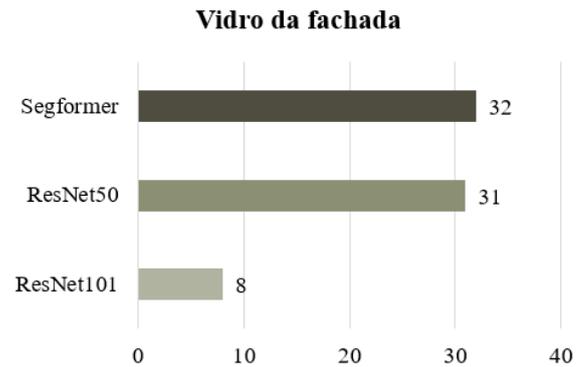
As análises dos tipos de erro evidenciaram os desafios dos algoritmos em distinguir corretamente entre vidros e manchas de umidade. As Figura 142 e Figura 143 ilustram a segmentação dos vidros dos painéis de fachada, devido às características visuais, reflexões e transparências. As imagens que continham partes das fachadas dos edifícios gerou um problema no processamento das imagens, relacionados à cor e textura que se assemelham visualmente às manchas de interesse de segmentação. Mais uma vez, alerta-se para que a imagens selecionadas para a anotação não registrem elementos externos, além da cobertura.

Figura 142 - Segmentação de falso positivo do vidro da fachada – SegFormer Adam 1e-3.



Fonte: Elaborado pela autora.

Figura 143 – Contabilização de falso positivo de vidro da fachada para cada rede.



Fonte: Elaborado pela autora.

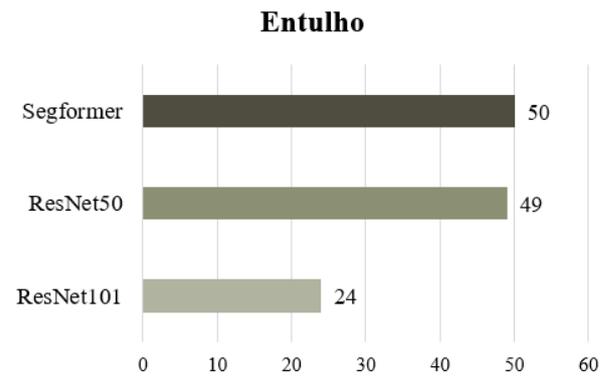
Os entulhos presentes no sistema de cobertura (Figura 14 e Figura 145) são a causa de muitos registros de falsos positivos. Os entulhos, frequentemente deixados pelas empresas terceirizadas responsáveis pela manutenção da cobertura, possuem formas e texturas variáveis, além de características visuais semelhantes às manchas.

Figura 144 - Segmentação de falso positivo de entulhos – SegFormer Adam 1e-3.



Fonte: Elaborado pela autora.

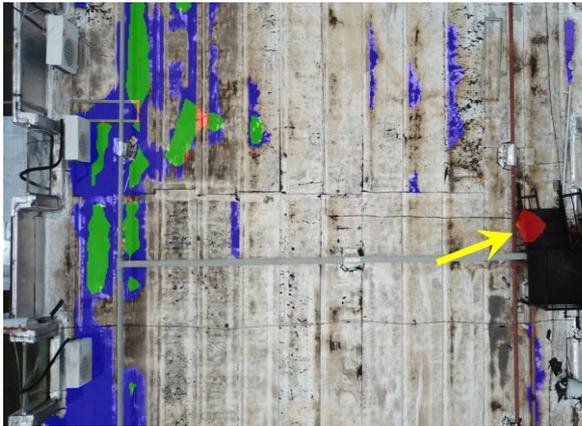
Figura 145 - Contabilização de falso positivo de entulho para cada rede.



Fonte: Elaborado pela autora.

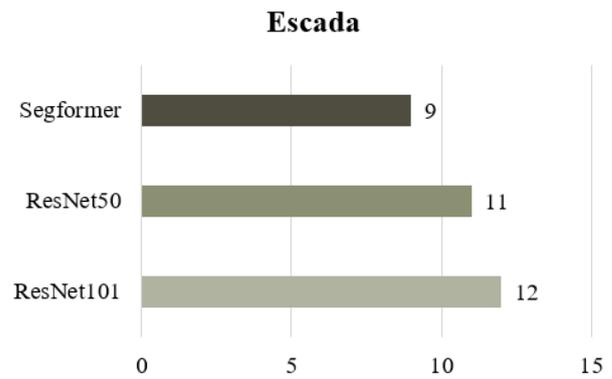
As escadas de acesso presentes nas coberturas (Figura 146 e Figura 147) levam as redes à confusão. Esse erro ocorre em menor proporção, mas está associado à diferenciação de tonalidades, devido à similaridade entre a coloração escura das escadas e a das manchas a serem segmentadas.

Figura 146 - Segmentação de falso positivo da escada – ResNet101 SGD 1e-3.



Fonte: Elaborado pela autora.

Figura 147 - Contabilização de falso positivo de escada para cada rede.



Fonte: Elaborado pela autora.

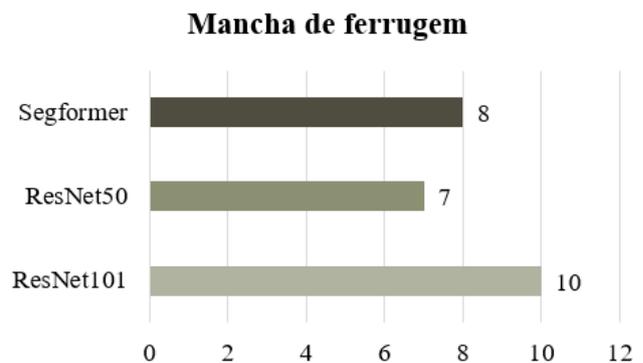
As manchas de ferrugem de coloração escura e muito próxima à tonalidade das manchas a serem segmentadas levou os modelos à confusão, resultando em falsos positivos, mostrados nas Figuras 148 e Figura 149.

Figura 148 - Segmentação de falso positivo de mancha de ferrugem – ResNet101 Adam 1e-3.



Fonte: Elaborado pela autora.

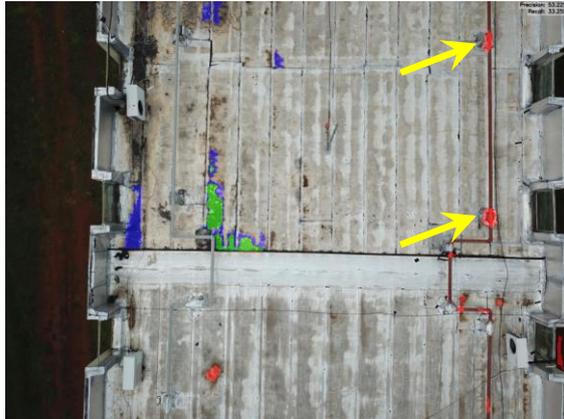
Figura 149 - Contabilização de falso positivo de mancha de ferrugem para cada rede.



Fonte: Elaborado pela autora.

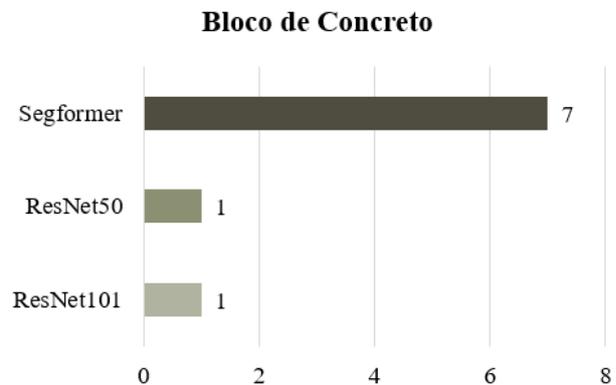
Outro tipo de erros em menor proporção está relacionado à segmentação de blocos de concreto utilizados como apoio para as tubulações (Figura 150 e Figura 151). Os blocos de concreto possuem características visuais como cores homogêneas. São elementos que se destacam do fundo e podem ser confundidos com as manchas a serem segmentadas pelos modelos.

Figura 150 - Segmentação de falso positivo do bloco de concreto – SegFormer Adam 1e-4.



Fonte: Elaborado pela autora.

Figura 151 - Contabilização de falso positivo de bloco de concreto para cada rede.



Fonte: Elaborado pela autora.

Na área externa do edifício, os containers de obras posicionados no terreno foram detectados pelas redes que segmentaram manchas de acúmulo de água e sujidades sobre o acabamento metálico (Figura 152 e Figura 153). Os algoritmos testados associaram as manchas no container com as manchas de interesse, o que pode ter contribuído para a confusão do modelo.

Figura 152 - Segmentação de falso positivo de container – SegFormer SGD 1e-2.



Fonte: Elaborado pela autora.

Figura 153 - Contabilização de falso positivo de container para cada rede.



Fonte: Elaborado pela autora.

Ao analisar a distribuição de falso positivos (FP) e falsos negativos (FN) em três faixas distintas do plano de cobertura: início da inclinação da laje, meio da laje e próximo aos ralos, foi possível identificar as regiões mais propensas a apresentar manchas.

Na faixa de laje onde inicia a inclinação da camada de regularização do sistema de cobertura, a ocorrência de falsos positivos foi menor por ser o local onde o escoamento da água é facilitado, reduzindo a formação de manchas e, portanto, erros de segmentação. A maior concentração de falsos positivos foi na parte central da laje, que pode estar relacionada à

estagnação da água nessa região, devido aos erros de inclinação da regularização ou flechas excessivas da laje estrutural, o que aumenta a probabilidade de confusão das redes.

Os erros indicados em azul (falso negativo) revelam que a rede não conseguiu segmentar os pixels anotados como mancha, interpretando-os incorretamente como fundo. Esse tipo de erro ocorre quando a rede falha em identificar padrões de textura, cor ou forma que caracterizam as manchas. Por outro lado, os erros marcados em vermelho (falsos positivos) correspondem a pixels que não foram anotados como manchas, mas sim como fundo, e que segmentou incorretamente como manchas. Esses erros refletem a confusão da rede com elementos visuais do fundo que possuem características semelhantes às manchas, como cor ou textura.

Para melhorar a precisão da segmentação e minimizar os erros de falso positivo e falso negativo, algumas soluções práticas podem ser recomendadas, incluindo o aumento do conjunto de dados e o ajuste dos hiperparâmetros, especialmente os otimizadores e taxas de aprendizagem.

O processamento automático de manifestações patológicas amplia a possibilidade de uma maior eficiência e agilidade na coleta e análise dos resultados. Por isso, os experimentos realizados com segmentação semântica neste estudo contribuem com o avanço das abordagens automatizadas aplicadas na identificação dos manchamentos em coberturas planas, utilizando tecnologias digitais em procedimentos de inspeção predial.

6 CENÁRIOS DE APLICAÇÃO

6.1 CENÁRIOS DE APLICAÇÃO DA INSPEÇÃO PREDIAL AUTOMATIZADA

Os cenários apresentados a seguir estabelecem diretrizes e estratégias aplicáveis a diferentes casos de estudo, fornecendo recomendações para a execução de inspeções prediais automatizadas. Além de orientar o planejamento das ações, essas diretrizes auxiliam na tomada de decisões, permitindo que o inspetor adote estratégias específicas na definição de protocolos e planos de voo, ajustados a diferentes tipologias arquitetônicas. Essa abordagem contribui para mitigar os riscos que possam surgir durante a operação e o processamento das imagens.

A definição do objetivo da missão e a escolha do plano de voo em uma ou mais direções são fatores determinantes para estabelecer um protocolo, pois influenciam a quantidade de imagens a serem adquiridas e as linhas de voo a serem traçadas.

Os principais desafios operacionais estão associados às dificuldades na captura de imagens. A altitude de voo deve considerar a sobreposição das imagens, a configuração arquitetônica do edifício e a presença de obstáculos identificados como alerta de barreira durante um teste piloto.

Além da altitude de sobrevoo, devem ser definidos o dia e o horário mais adequados, evitando problemas causados pelas condições climáticas, sombreamentos e reflexos em superfícies de materiais das edificações.

As bordas recomendam o posicionamento da aeronave para a aquisição de imagens, suficientes para o mapeamento. A distância entre os limites das bordas e a área de captura influencia diretamente a qualidade das ortoimagens geradas, uma vez que a presença de obstáculos, como vegetação densa, equipamentos e edificações adjacentes, pode comprometer a precisão do processamento, ocasionando falhas e lacunas na ortoimagem final.

As características do equipamento e as condições climáticas são fatores determinantes para as operações em campo. A velocidade do vento não pode causar instabilidade no equipamento no momento da captura das imagens, minimizando assim possíveis falhas no processamento.

As condicionantes para os voos influenciam diretamente a qualidade do processamento do banco de imagens e a geração da ortoimagem. Para os processos automatizados, define-se o objeto de interesse para aplicação em *deep learning* e a quantidade de imagens necessária para a construção do banco de dados.

CENÁRIO DE APLICAÇÃO 01 - Laje Plana com Diferentes Níveis



1 Sistema de Cobertura Plana

- Laje plana linear
- Laje plana linear com curvatura
- Laje plana com diferentes níveis

2 Definições

- Finalidade do levantamento (objetivos)
- Nível de precisão das imagens
 - Escolha do equipamento

3 Plano de voo

- Voo experimental para identificação dos pontos críticos
- Planejamento do voo
- Realização do checklist

4 Critérios para aquisição de imagens

- Drone com estabilidade e com mais de 3 baterias
- Plano de voo em 2 direções ou mais, variando a angulação
- Sobreposição longitudinal 80%
- Sobreposição transversal 70%
- Altitude do voo: 20 metros acima do obstáculo existente
- Mageamento: 25 metros
- Dia nublado com luz difusa

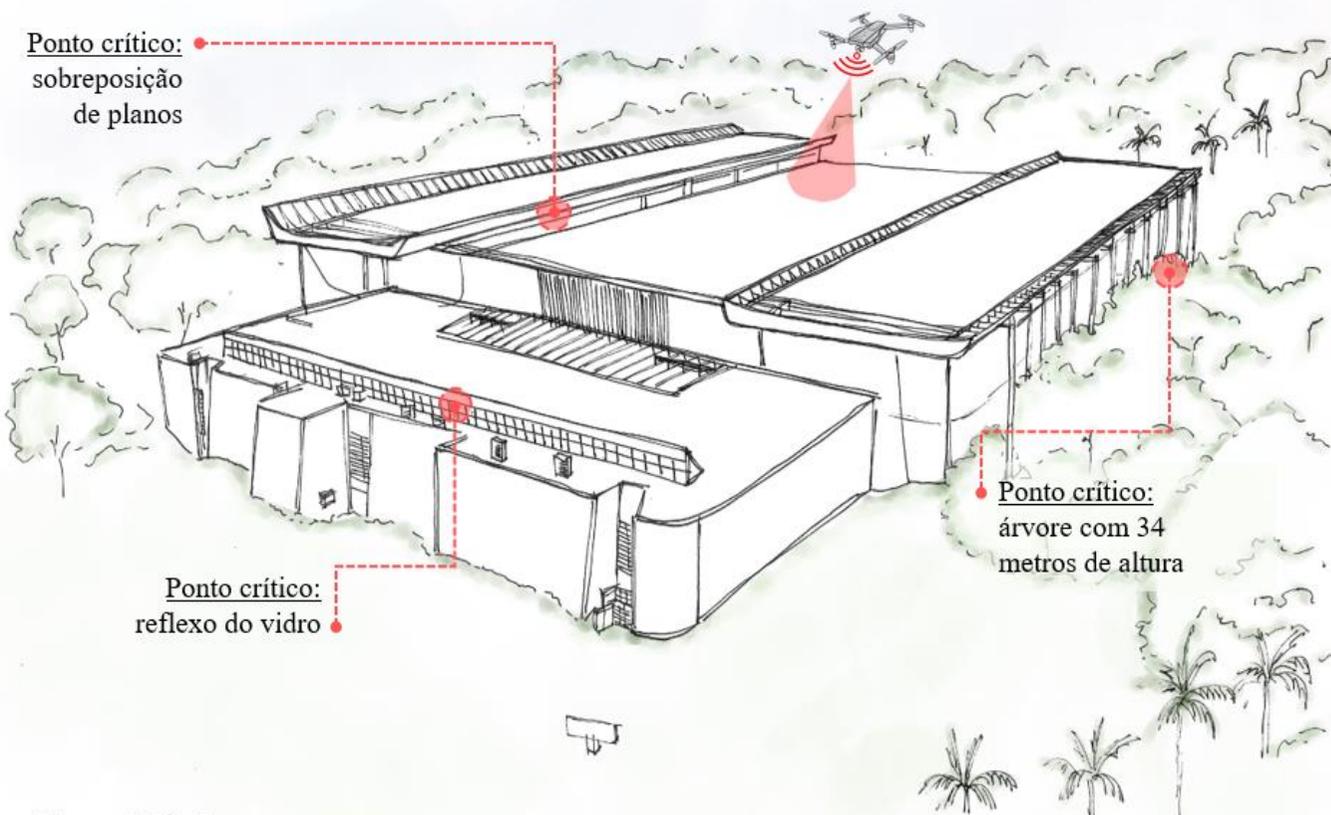
5 Processamento do banco de imagens

- Escolha do software para processamento do banco de imagens
- Definição dos parâmetros de processamento
- Computador com capacidade de processamento para diferentes configurações, simultaneamente
- Geração da ortoimagem para monitoramento futuro

6 Processos automatizados

- Definição da qualidade e quantidade de imagens do banco de imagens
- Processo de anotação das imagens
- Uso do *deep learning* e aplicação das técnicas de visão computacional
- Gestão da manutenção e o monitoramento contínuo

Ponto crítico:
sobreposição
de planos



Ponto crítico:
reflexo do vidro

Ponto crítico:
árvore com 34
metros de altura

Checklist

- | | |
|--|---|
| <input type="checkbox"/> Baterias carregadas e cartão de memória inserido no drone | <input type="checkbox"/> Avaliação das condições ambientais |
| <input type="checkbox"/> Análise da implantação e do entorno | <input type="checkbox"/> Definição da direção das linhas de voo |
| <input type="checkbox"/> Identificação de barreiras | <input type="checkbox"/> Definição do voo em uma ou mais direções |
| <input type="checkbox"/> Definição de altitude | <input type="checkbox"/> Definição da sobreposição longitudinal e transversal |
| <input type="checkbox"/> Escolha do dia e horário | <input type="checkbox"/> Definição da distância do mageamento da cobertura |

CENÁRIO DE APLICAÇÃO 02 - Laje Plana com Diferentes Níveis



1 Sistema de Cobertura Plana

- Laje plana linear
- Laje plana linear com curvatura
- Laje plana com diferentes níveis

2 Definições

- Finalidade do levantamento (objetivos)
- Nível de precisão das imagens
 - Escolha do equipamento

3 Plano de voo

- Voo experimental para identificação dos pontos críticos
- Planejamento do voo
- Realização do checklist

4 Critérios para aquisição de imagens

- Drone com estabilidade e com mais de 3 baterias
- Plano de voo em 2 direções ou mais, variando a angulação
- Sobreposição longitudinal 80%
- Sobreposição transversal 75%
- Altitude do voo: 20 metros acima do obstáculo existente
- Mageamento: 25 metros
- Dia nublado com luz difusa



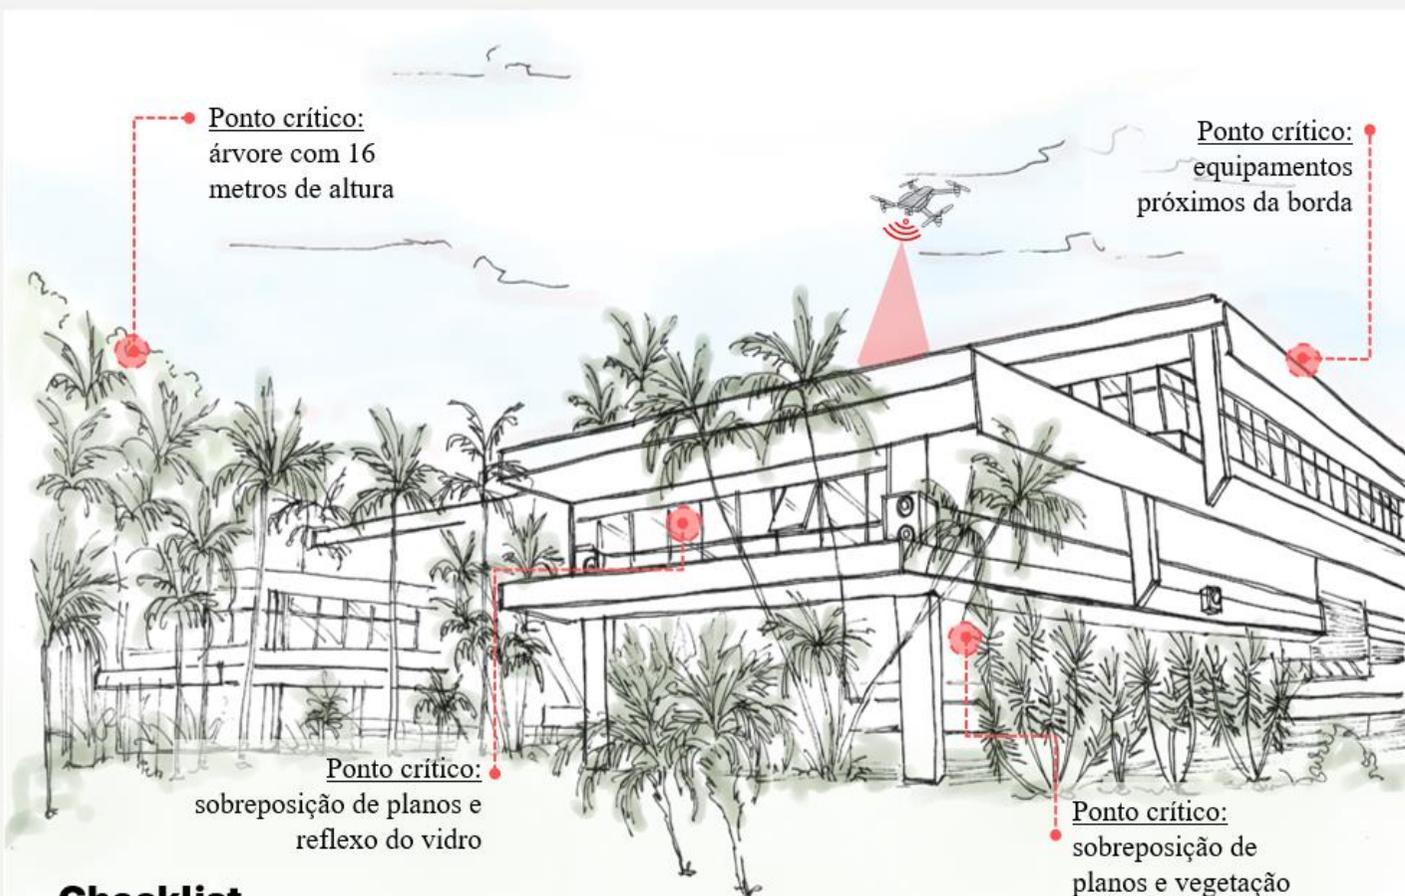
5 Processamento do banco de imagens

- Escolha do software para processamento do banco de imagens
- Definição dos parâmetros de processamento
- Computador com capacidade de processamento para diferentes configurações, simultaneamente
- Geração da ortoimagem para monitoramento futuro

6 Processos automatizados

- Definição da qualidade e quantidade de imagens do banco de imagens
- Processo de anotação das imagens
- Uso do *deep learning* e aplicação das técnicas de visão computacional
- Gestão da manutenção e o monitoramento continuado

Inspeção predial automatizada



Checklist

- | | |
|--|---|
| <input type="checkbox"/> Baterias carregadas e cartão de memória inserido no drone | <input type="checkbox"/> Avaliação das condições ambientais |
| <input type="checkbox"/> Análise da implantação e do entorno | <input type="checkbox"/> Definição da direção das linhas de voo |
| <input type="checkbox"/> Identificação de barreiras | <input type="checkbox"/> Definição do voo em uma ou mais direções |
| <input type="checkbox"/> Definição de altitude | <input type="checkbox"/> Definição da sobreposição longitudinal e transversal |
| <input type="checkbox"/> Escolha do dia e horário | <input type="checkbox"/> Definição da distância do mageamento da cobertura |

CENÁRIO DE APLICAÇÃO 03 - Laje Plana com Diferentes Níveis



1 Sistema de Cobertura Plana

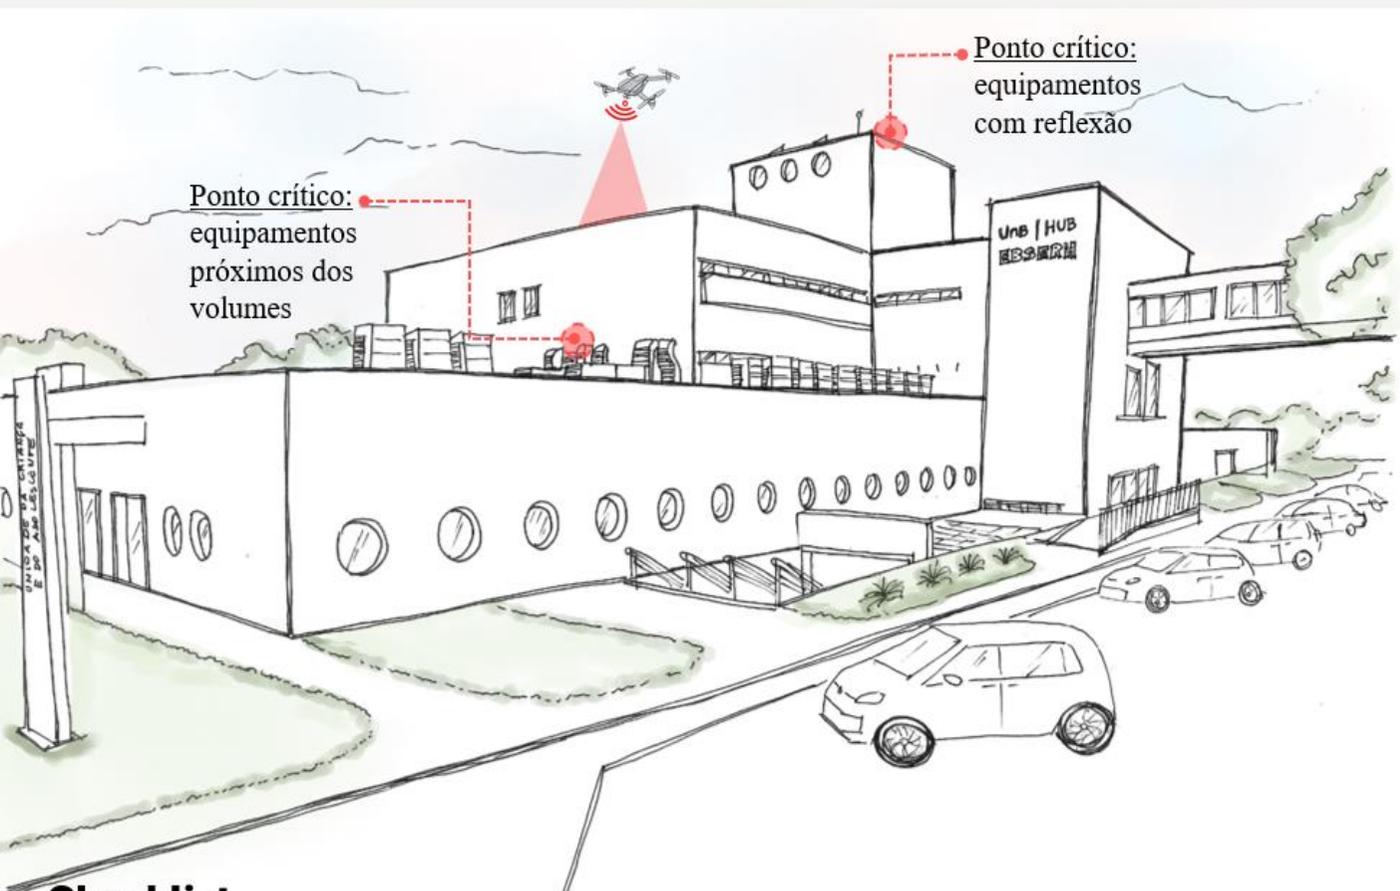
- Laje plana linear
- Laje plana linear com curvatura
- Laje plana com diferentes níveis

2 Definições

- Finalidade do levantamento (objetivos)
- Nível de precisão das imagens
 - Escolha do equipamento

3 Plano de voo

- Voo experimental para identificação dos pontos críticos
- Planejamento do voo
- Realização do checklist



4 Critérios para aquisição de imagens

- Drone com estabilidade e com mais de 3 baterias
- Plano de voo em 2 direções ou mais, variando a angulação
- Sobreposição longitudinal 80%
- Sobreposição transversal 75%
- Altitude do voo: 20 metros
- Mageamento: 20 metros
- Dia nublado com luz difusa

5 Processamento do banco de imagens

- Escolha do software para processamento do banco de imagens
- Definição dos parâmetros de processamento
- Computador com capacidade de processamento para diferentes configurações, simultaneamente
- Geração da ortoimagem para monitoramento futuro

6 Processos automatizados

- Definição da qualidade e quantidade de imagens do banco de imagens
- Processo de anotação das imagens
- Uso do *deep learning* e aplicação das técnicas de visão computacional
- Gestão da manutenção e o monitoramento continuado

Checklist

- | | |
|--|---|
| <input type="checkbox"/> Baterias carregadas e cartão de memória inserido no drone | <input type="checkbox"/> Avaliação das condições ambientais |
| <input type="checkbox"/> Análise da implantação e do entorno | <input type="checkbox"/> Definição da direção das linhas de voo |
| <input type="checkbox"/> Identificação de barreiras | <input type="checkbox"/> Definição do voo em uma ou mais direções |
| <input type="checkbox"/> Definição de altitude | <input type="checkbox"/> Definição da sobreposição longitudinal e transversal |
| <input type="checkbox"/> Escolha do dia e horário | <input type="checkbox"/> Definição da distância do mageamento da cobertura |

CENÁRIO DE APLICAÇÃO 04 - Laje Plana Linear com Curvatura



1 Sistema de Cobertura Plana

- Laje plana linear
- Laje plana linear com curvatura
- Laje plana com diferentes níveis

4 Critérios para aquisição de imagens

- Drone com estabilidade e com mais de 3 baterias 
- Plano de voo em 1 direção
- Linhas de direção de voo acompanhando os raios de curvatura
- Sobreposição longitudinal 80%
- Sobreposição transversal 75%
- Altitude do voo: 14 metros
- Mageamento: até 15 metros
- Dia nublado com luz difusa

5 Processamento do banco de imagens

- Escolha do software para processamento do banco de imagens
- Definição dos parâmetros de processamento
- Computador com capacidade de processamento para diferentes configurações, simultaneamente
- Geração da ortoimagem para monitoramento futuro

6 Processos automatizados

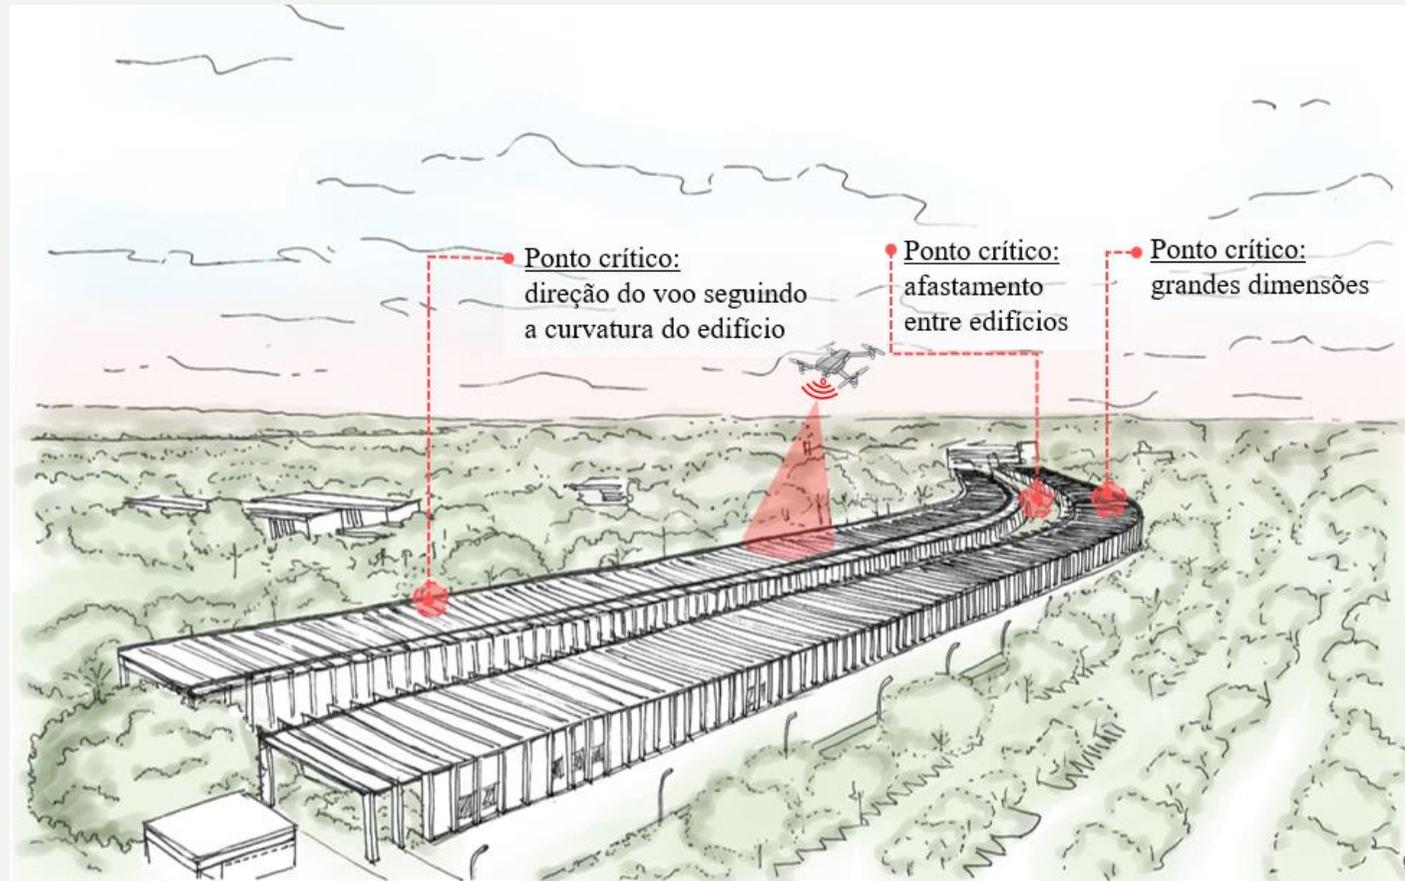
- Definição da qualidade e quantidade de imagens do banco de imagens
- Processo de anotação das imagens
- Uso do *deep learning* e aplicação das técnicas de visão computacional
- Gestão da manutenção e o monitoramento continuado

2 Definições

- Finalidade do levantamento (objetivos)
- Nível de precisão das imagens
 - Escolha do equipamento

3 Plano de voo

- Voo experimental para identificação dos pontos críticos
- Planejamento do voo
- Realização do checklist



Checklist

- | | |
|--|---|
| <input type="checkbox"/> Baterias carregadas e cartão de memória inserido no drone | <input type="checkbox"/> Avaliação das condições ambientais |
| <input type="checkbox"/> Análise da implantação e do entorno | <input type="checkbox"/> Definição da direção das linhas de voo |
| <input type="checkbox"/> Identificação de barreiras | <input type="checkbox"/> Definição do voo em uma ou mais direções |
| <input type="checkbox"/> Definição de altitude | <input type="checkbox"/> Definição da sobreposição longitudinal e transversal |
| <input type="checkbox"/> Escolha do dia e horário | <input type="checkbox"/> Definição da distância do mageamento da cobertura |

CENÁRIO DE APLICAÇÃO 05 - Laje Plana Linear



1 Sistema de Cobertura Plana

- Laje plana linear
- Laje plana linear com curvatura
- Laje plana com diferentes níveis

2 Definições

- Finalidade do levantamento (objetivos)
- Nível de precisão das imagens
 - Escolha do equipamento

3 Plano de voo

- Voo experimental para identificação dos pontos críticos
- Planejamento do voo
- Realização do checklist

4 Critérios para aquisição de imagens

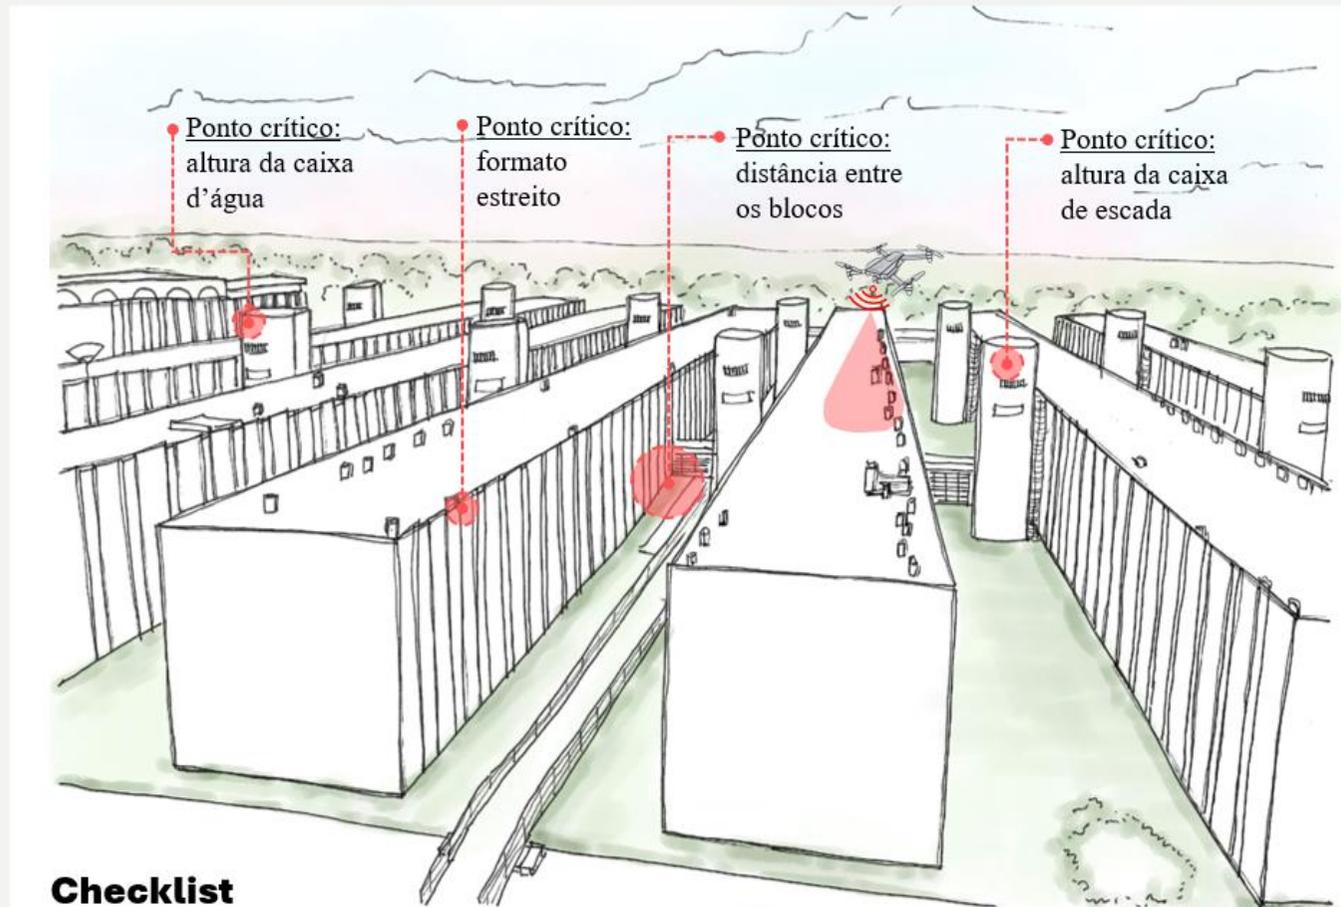
- Drone com estabilidade e com mais de 3 baterias
- Plano de voo em 2 direções ou mais, variando a angulação
- Linhas de voo com menor afastamento
- Sobreposição longitudinal 80%
- Sobreposição transversal 75%
- Altitude do voo: 20 metros acima do obstáculo existente
- Mageamento: no mínimo, metade da sobreposição lateral
- Dia nublado com luz difusa

5 Processamento do banco de imagens

- Escolha do software para processamento do banco de imagens
- Definição dos parâmetros de processamento
- Definição da qualidade e quantidade de imagens do banco de imagens
- Geração da ortomagem para monitoramento futuro

6 Processos automatizados

- Computador com capacidade de processamento para diferentes configurações, simultaneamente
- Processo de anotação das imagens
- Uso do *deep learning* e aplicação das técnicas de visão computacional
- Gestão da manutenção e o monitoramento continuado



Checklist

- | | |
|--|---|
| <input type="checkbox"/> Baterias carregadas e cartão de memória inserido no drone | <input type="checkbox"/> Avaliação das condições ambientais |
| <input type="checkbox"/> Análise da implantação e do entorno | <input type="checkbox"/> Definição da direção das linhas de voo |
| <input type="checkbox"/> Identificação de barreiras | <input type="checkbox"/> Definição do voo em uma ou mais direções |
| <input type="checkbox"/> Definição de altitude | <input type="checkbox"/> Definição da sobreposição longitudinal e transversal |
| <input type="checkbox"/> Escolha do dia e horário | <input type="checkbox"/> Definição da distância do mageamento da cobertura |

7 CONCLUSÃO DA TESE

7.1 CONSIDERAÇÕES FINAIS

A implementação de tecnologias digitais e processos automatizados, como o uso de drones para captura de imagens, o processamento de ortoimagens e modelos digitais de elevação, além da aplicação de técnicas de visão computacional e *deep learning*, contribuiu significativamente para a melhoria dos procedimentos de inspeção predial e da gestão da manutenção em sistemas de cobertura plana com lajes impermeabilizadas.

A hipótese foi testada e demonstrada por meio da seleção de cinco casos de estudo, que permitiram explorar, na prática, a utilização do drones em protocolos específicos para inspeção predial em diferentes coberturas planas, possibilitando a análise comparativa dos resultados obtidos.

A definição das variáveis para a estruturação dos planos de voo em diferentes cenários serviu de base para a formulação de diretrizes e estratégias recomendadas aos profissionais, orientando os procedimentos de inspeção para a identificação de possíveis ações de manutenção, monitoramento ou avaliação do estado de conservação dos sistemas de cobertura.

A pesquisa realizada neste estudo mostrou que os procedimentos adotados nos processos de aquisição de imagens para a geração de ortoimagem, modelo de elevação e construção de banco de imagens para aplicação em *deep learning* trazem contribuições significativas para o aprimoramento da inspeção predial automatizada. Em especial, a quantificação e a qualificação dos parâmetros foram decisivos para a formação do banco de imagens.

A alta resolução das ortoimagens facilita a visualização, no ambiente de escritório, das condições do sistema de cobertura, propiciando uma evolução no processo de inspeção e monitoramento das edificações. Os experimentos em processos automatizados para detecção de equipamentos e segmentação semântica de manchas de umidade obtiveram sucesso e evidenciaram a importância da qualidade na construção de um banco de imagens.

Além disso, esta tese representa um avanço fundamental no planejamento das práticas de inspeção predial e monitoramento em sistemas de cobertura plana, contribuindo para a implementação de abordagens integradas na gestão da manutenção em grandes lajes impermeabilizadas, garantindo uma conservação mais eficiente, maior segurança e o prolongamento da vida útil.

7.2 OBJETIVOS ALCANÇADOS E CONTRIBUIÇÕES DA TESE

→ **Uso de drones e processamento digital para aquisição de imagens, geração de ortoimagens e modelos digitais de elevação para a gestão da manutenção e monitoramento do estado de conservação da edificação**

Os cinco estudos exploratórios em edifícios permitiram aferir diferentes processamentos de ortoimagens e modelos digitais de elevação, identificando as variáveis e os parâmetros mais relevantes para a obtenção de resultados com melhor qualidade em menor tempo e com menor custo operacional. Os experimentos foram conduzidos com planos de voo em diferentes direções, sendo cada voo submetido a um ou dois processamentos, conforme a necessidade de verificação dos parâmetros estabelecidos e as devidas comparações.

Na etapa de aquisição de imagens, verificou-se que fatores como o sentido e direção das linhas do voo, além da sobreposição, influenciaram a qualidade do processamento. Outras variáveis, como a identificação de barreiras, a definição da altitude e a escolha do dia e horário para o levantamento, também impactaram significativamente os resultados.

A altitude do voo, em particular, foi um fator determinante na quantidade de imagens adquiridas. Altitudes mais elevadas reduziram a resolução, comprometendo o nível de detalhamento das ortoimagens. Além disso, diminuíram a quantidade de imagens capturadas, resultando em um tempo menor de processamento. Por outro lado, a distância do mapeamento da cobertura influenciou a captura de informações detalhadas, uma vez que distâncias maiores favoreceram a obtenção de dados mais abrangentes sobre os diferentes planos do sistema de cobertura.

Na etapa de processamento, diferentes configurações foram testadas para avaliar o seu impacto na qualidade das ortoimagens. Os resultados demonstraram que a escolha adequada dos parâmetros influencia diretamente na qualidade final. O processamento das ortoimagens demandou softwares de alta capacidade computacional, devido ao tempo prolongado de processamento em determinadas etapas. Por vezes, foi necessário o uso de padrões de qualidade reduzidos. No entanto, em alguns casos, essa abordagem gerou resultados satisfatórios, dependendo do contexto do estudo de caso. Isso evidencia a importância de experimentações em diferentes cenários de aplicação.

Dentre as limitações observadas, destaca-se a presença de vegetação densa nas imediações dos edifícios, que obstruiu partes das coberturas, impossibilitando a correta modelagem no DEM e resultando em falhas (buracos brancos) nas ortoimagens geradas. A construção de um modelo DEM permite identificar os locais com acúmulo de sujeira nas

calhas, equipamentos obsoletos e ações inadequadas de manutenção realizadas por empresas terceirizadas.

A vegetação e os elementos envidraçados apresentaram desafios adicionais, uma vez que o movimento provocado pelo vento dificulta o reconhecimento dos pixels durante o processamento, e os reflexos dos vidros geram inconsistências na modelagem digital. Outros obstáculos, como a presença de antenas e caixas de escadas, restringiram a altitude do voo, reduzindo a qualidade de imagens capturadas e, conseqüentemente, o nível de detalhamento das ortoimagens geradas. A altitude influencia a aquisição de imagens e a quantidade de informações capturadas para a geração da ortoimagem.

Em cobertura linear com curvatura, constatou-se que os voos realizados não apresentaram perda de qualidade dos resultados nem dificuldades adicionais. Verificou-se que a operação em apenas uma direção foi suficiente, uma vez que a baixa altitude do drone em relação ao sistema permitiu a obtenção de imagens detalhadas.

As edificações com diferentes níveis apresentaram desafios adicionais no processamento. Além da vegetação densa, regiões abaixo de pórticos, marquises ou elementos acoplados às coberturas também se mostraram pontos críticos, especialmente quando o nível mais elevado contém telhamentos, painéis ou equipamentos envidraçados ou metálicos, que provocam reflexos no momento da aquisição das imagens. Mesmo com a execução de voos em várias direções e diferentes ângulos, não foi possível capturar imagens abaixo dos pórticos devido às diferenças de níveis e aos avanços que se sobrepõem. Essas diferenças interferem na coleta de informações, impactando a definição dos alinhamentos e a quantidade de direções a serem empregadas no plano de voo.

Dificuldades operacionais foram registradas em edificações situadas em espaços restritos, onde a proximidade entre edifícios compromete a captura de imagens suficientes para a modelagem do DEM e a geração da ortoimagem. A baixa sobreposição de imagens adquiridas nesse contexto pode limitar a qualidade do processamento.

Os parâmetros testados nos diferentes edifícios analisados contribuíram para o aprimoramento de inspeções prediais aplicáveis a sistemas de coberturas planas em diferentes configurações – lineares e com diferentes níveis. Os resultados dos processamentos digitais, com o uso dos parâmetros adequados para a geração de ortoimagens das edificações, demonstraram que a utilização do drone como ferramenta de captura de imagens representa uma contribuição significativa para a gestão da manutenção e os processos automatizados na fase de monitoramento.

→ **Aplicação de métodos e técnicas de visão computacional e redes neurais em *deep learning* para a segmentação semântica de manchas e a detecção de equipamentos como estratégias para o aprimoramento da inspeção predial**

A utilização de drones possibilitou a criação de um banco de imagens para análises com técnicas de visão computacional e processos automatizados em *deep learning*. Pela sua originalidade, estes estudos apresentaram significativas contribuições ao explorar a detecção de equipamentos e a segmentação semântica de manchas de umidade em coberturas planas.

Os processos automatizados, utilizando redes neurais convolucionais para segmentação de manchas e detecção de equipamentos, demonstraram a viabilidade da inspeção predial e da gestão da manutenção com essas metodologias. Os resultados evidenciaram que as redes neurais identificaram manchas de umidade – indicativas de degradação – com precisão. Devido às características visuais complexas das coberturas planas, especialmente em imagens capturadas por drones, foi essencial analisar os erros cometidos pelas arquiteturas de rede.

Os modelos testados apresentaram erros principalmente em regiões próximas a tubulações de drenagem, platibandas e equipamentos, áreas críticas sujeitas à estagnação de água devido à falta de limpeza dos ralos, bloqueios em tubos de drenagem e instalações inadequadas de equipamentos. A recorrência de manchas nesses locais sugere que as decisões das redes neurais foram influenciadas por informações espaciais, geométricas, de coloração e luminosidade. As redes neurais demonstraram bom desempenho na identificação de manchas escuras, sem confusão significativa entre os diferentes tipos de superfície.

O principal desafio foi segmentar objetos com tamanhos, formas e cores variados em imagens de ambientes complexos, devido às condições naturais de exposição e à presença de múltiplos equipamentos na superfície analisada. A similaridade cromática dos pixels entre manchas claras, escuras e resíduos, como lixo, restos de manutenção e unidades condensadoras desativadas, pode ter resultado em falsos positivos.

Nos experimentos de detecção dos equipamentos, as redes apresentaram erros ao detectar objetos de aparência semelhante, como antenas circulares, chaminés de exaustão, subestações de antenas de comunicação, equipamentos desativados, condensadoras localizadas nas fachadas dos edifícios, além de resíduos de construção, placas fotovoltaicas, telhas e tubos de ventilação. A maioria dos objetos detectados incorretamente possuía formato retangular ou circular, com características visuais semelhantes às condensadoras.

As imagens de alta resolução capturadas pelos drones evidenciaram como a instalação inadequada de equipamentos acelera a degradação da membrana impermeabilizante, devido à presença de umidade e sujeidade, comprometendo o desempenho do sistema construtivo. A

análise dos resultados revelou áreas com acúmulo de água próximo aos ralos, causado por falhas na execução da camada de regularização e pela disposição inadequada de equipamentos.

As técnicas de detecção e segmentação semântica em *deep learning* possibilitaram a identificação de regiões críticas para monitoramento contínuo da manutenção. A metodologia pode ser adaptada a diferentes objetos de interesse, conforme a necessidade do inspetor, bastando a construção de um banco de imagens qualificado para os experimentos automatizados. Os resultados indicaram que o conjunto de dados era adequado para processamento em *deep learning*, contribuindo para o avanço dos processos automatizados em tempo real e a tomada de decisões estratégicas no planejamento de manutenção.

A qualidade do conjunto de dados influenciou positivamente o desempenho das redes, embora tenham sido observados desafios devido à semelhança geométrica e cromática entre condensadoras e outros elementos presentes na cobertura. Os experimentos mostraram-se relevante não apenas para a identificação dos equipamentos em uso, mas também para a detecção de unidades desativadas, carcaças abandonadas e resíduos de manutenção, que comprometem a integridade do sistema de cobertura e aceleram a degradação.

A segmentação semântica aplicada às manchas em coberturas planas apresentou resultados satisfatórios e promissores. Mesmo diante da variabilidade de forma, tamanho, cor, brilho e interferência de equipamentos no mesmo plano, as redes neurais demonstraram a capacidade de diferenciar manchas escuras e claras. Como indicadores de degradação, a segmentação de manchas escuras permitiu a identificação de danos decorrentes da umidade e do acúmulo de sujeira, possibilitando ações preventivas antes do surgimento de falhas estruturais.

Em suma, os processos automatizados permitem prever manifestações patológicas, analisar a degradação de componentes e aprimorar o planejamento da manutenção com base em dados coletados durante as inspeções prediais com drones em coberturas planas.

→ **Cenários para aplicação de inspeções prediais automatizadas no monitoramento de sistemas de cobertura plana.**

Os cenários propostos basearam-se na análise dos cinco casos de estudo e contribuem na orientação dos inspetores na elaboração de seus próprios protocolos de inspeção predial, considerando as especificidades de cada tipologia arquitetônica.

Os resultados mostraram que a configuração arquitetônica e a geometria das edificações influenciam diretamente as decisões sobre os planos de voo e os resultados do processamento digital. Dessa forma, destaca-se a importância de uma definição clara dos objetivos da inspeção

predial automatizada, garantindo a escolha adequada dos procedimentos e técnicas para a construção de um banco de imagens e a implementação de um monitoramento contínuo.

7.3 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestões para os trabalhos futuros, recomenda-se:

- Empregar tecnologias embarcadas em drones, como sensores multiespectrais, ampliando a abrangência da captura e formação de um banco de imagens, especialmente em sistemas de cobertura plana que apresentam dificuldades na captura de imagens;
- Integrar as inspeções prediais automatizadas ao uso do BIM;
- Expandir o banco de imagens de sistemas de coberturas planas, incluindo a anotação de outras classes de equipamentos, manifestações patológicas e componentes do sistema de drenagem (ralos e calhas) para ampliar a aplicação de métodos e técnicas de reconhecimento, detecção, classificação e segmentação semântica;
- Avançar nas metodologias de inspeção com processos automatizados, aprimorando os procedimentos e a precisão.

Essas sugestões visam consolidar e expandir a utilização de tecnologias digitais e processos automatizados na inspeção e monitoramento de sistemas de cobertura, contribuindo para a modernização das práticas de manutenção predial.

REFERÊNCIAS

- AGISOFT. **Agisoft Metashape User Manual: Professional Edition, Version 2.1.** 2024. Disponível em: https://www.agisoft.com/pdf/metashape-pro_2_1_en.pdf. Acesso em: 13 jan 2025.
- AGRAFIOTIS, P.; TALAVEROS, G.; GEORGOPOULOS, A. Orthoimage-o-2d t Drawing With Conditional Adversarial Networks. **Isprs Annals Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, [S.L.], v. --1-2023, p. 11-18, 23 jun. 2023. Copernicus GmbH. <http://dx.doi.org/10.5194/isprs-annals-x-m-1-2023-11-2023>.
- AMERICAN SOCIETY FOR TESTING AND MATERIALS - ASTM. **Standard Practice for Developing Accelerated Tests to a Prediction of the Service Life of Building Components and Materials.** Philadelphia: ASTM E 632-81, 1996.6 p.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 9575:** Impermeabilização - Seleção e projeto. Rio de Janeiro: ABNT, 2010.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 9574:** Execução de impermeabilização. Rio de Janeiro: ABNT, 2008.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 5674:** Manutenção de edificações - Requisitos para o Sistema de gestão de manutenção. Rio de Janeiro: ABNT, 2012.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15575-1:** Edificações Habitacionais - Desempenho: Parte 1- Requisitos Gerais. Rio de Janeiro: ABNT, 2021a.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 15575-5:** Edificações Habitacionais - Desempenho: Parte 5 - Requisitos para sistemas de coberturas. Rio de Janeiro: ABNT, 2021b.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, ABNT. **NBR 16747:** Inspeção Predial - Diretrizes, conceitos, terminologia e procedimento. Rio de Janeiro: ABNT, 2020.
- BANASZEK, A; BANASZEK, S.; CELLMER, A. Possibilities of Use of UAVS for Technical Inspection of Buildings and Constructions. **Iop Conference Series: Earth and Environmental Science**, [S.l.], v. 95, p. 032001, Dec. 2017.
- BAUER, E.; SOUZA, J. S.; MOTA, L. M. G. Degradação de fachadas revestidas em argamassas nos edifícios de Brasília, Brasil. **Ambiente Construído**, Porto Alegre, v.21, n.4, p.23-43, 2021.
- BOWN, M.; MILLER, K. The use of unmanned aerial vehicles for sloped roof inspections - considerations and constraints. **Journal Of Facility Management Education and Research**, [S.L.], v. 2, n. 1, p. 12-18, Jan. 2018.
- BRAR, K. K.; GOYAL, B.; DOGRA, A.; MUSTAFA, M. A.; MAJUMDAR, R.; ALKHAYYAT, A.; KUKREJA, V. Image segmentation review: theoretical background and

recent advances. **Information Fusion**, [S.L.], v. 114, p. 102608, fev. 2025. Elsevier BV. <http://dx.doi.org/10.1016/j.inffus.2024.102608>.

CAMPOS, B. P. A. **Palácio do Exército: Conjunto Arquitetônico de Oscar Niemeyer para o Quartel General do Exército de Brasília - 1968-73**. 2020. 213 p. Dissertação (Mestrado) - Faculdade de Arquitetura e Urbanismo, Programa de Pós-Graduação em Arquitetura e Urbanismo, Universidade de Brasília. Brasília, Brasil.

CARRETERO-AYUSO, M. J.; BRITO, J. Analysis of the Execution Deficiencies of Flat Roofs with Bituminous Membranes. **Journal of Performance of Constructed Facilities**, [S.l.], v. 30, n. 6, p. 1-8, dez. 2021.

CARRETERO-AYUSO, M. J.; MORENO-CANSADO, A.; BRITO, J. Failure and damage determination of building roofs. **Revista de La Construcción**, Pontificia Universidad Católica de Chile, v. 16, n. 1, p. 145-157, maio 2017.

CHA, Y.-J.; ALI, R.; LEWIS, J.; BÜYÜKHJZTÜRK, O. Deep learning-based structural health monitoring. **Automation In Construction**, [S.L.], v. 161, p. 105328, maio 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.autcon.2024.105328>.

CHEN, L. C.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H. Rethinking atrous convolution for semantic image segmentation. **Computer Vision and Pattern Recognition**. 2017. ArXiv. <https://doi.org/10.48550/arXiv.1706.05587>.

CÓIAS, V. **Inspeções e ensaios na reabilitação de edifícios**. 2 ed. IST Press: Lisboa. 2009. 437 p.

COSTA, R. P.; FERNANDES, L. L. A.; MUTA, L. F.; ISATTO, E. L.; COSTA, D. B. Modelagem 3D de edificação gerada por fotogrametria com uso de Veículos Aéreos Não Tripulados (VANT). **Ambiente Construído**, [S.L.], v. 24, p. 1-15, dez. 2024. Fap UNIFESP (SciELO). <http://dx.doi.org/10.1590/s1678-86212024000100737>.

CUNHA, A. G.; NEUMANN, W. **Manual de Impermeabilização e Isolamento Térmico: como projetar e executar**. Quarta edição. Rio de Janeiro: Texsa Brasileira Ltda, 1979. 227 p.

CRUZ, J. H. P. **Manifestações Patológicas de Impermeabilizações com Uso de Sistemas Não Aderido de Mantas Asfálticas: avaliação e análise com auxílio de sistemas multimídia**. 2003. 168 p. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul. Porto Alegre, Rio Grande do Sul.

DÀ-JIĀNG INNOVATIONS SCIENCE AND TECHNOLOGY - DJI. **DJI Fly**. Available at: <https://www.dji.com/br/downloads/djiapp/dji-fly>. Accessed on: Dezembro 8, 2023.

DAIS, D.; BAL, Í. E.; SMYROU, E.; SARHOSIS, V. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning. **Automation In Construction**, [S.L.], v. 125, p. 103606, maio 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.autcon.2021.103606>.

DJI. **Mavic Pro**. Disponível em: <https://www.dji.com/br/mavic>. Acesso em: 14 fev. 2023.

DOSOVITSKIY, A.; BEYER, L.; KOLESNIKOV, A.; WEISSENBORN, D.; ZHAI, X.; UNTERTHINER, T.; DEHGhani, M.; MINDERER, M.; HEIGOLD, G.; GELLY, S. An Image is Worth 16x16 Words: transformers for image recognition at scale. **Computer Vision And Pattern Recognition**, [S.L.], v. 2, p. 1-22, 2020. ArXiv. <http://dx.doi.org/10.48550/ARXIV.2010.11929>.

EFFISUS. **Selagem de Perfurações em Coberturas Planas**. 2020. Disponível em: <https://effisus.com/wp-content/uploads/2020/10/Selagem-de-perfura%C3%A7%C3%B5es-em-coberturas-planas_PT.pdf>. Acesso em: 30 jan. 2023.

ESCHMANN, C.; KUO, C.; KUO, C.; BOLLER, C. (2013). Unmanned Aircraft Systems for Remote Building Inspection and Monitoring. 6th European Workshop on Structural Health Monitoring (EWSHM 2012), July 3 -6, 2012 in Dresden, Germany. <https://www.ndt.net/?id=14139>.

FERRAZ, G. T.; BRITO, J. de; FREITAS, V. P. de; SILVESTRE, J. D. State-of-the-Art Review of Building Inspection Systems. **Journal of Performance of Constructed Facilities**, [S.L.], v. 30, n. 5, p. 04016018-04010188, Oct. 2016.

FERREIRA, J. A. S.; CARRILHO, F. R. L.; ALCANTARA, J. A. O.; GONÇALVES, C.; STOLZ, C. M.; AMARIO, M.; HADDAD, A. N. Assessment of Staining Patterns in Facades Using an Unmanned Aerial Vehicle (UAV) and Infrared Thermography. **Drones**, [S.L.], v. 8, n. 10, p. 542, 1 out. 2024. MDPI AG. <http://dx.doi.org/10.3390/drones8100542>.

FIORILLO, F.; PERFETTI, L.; CARDANI, G. Automated Mapping of the roof damage in historic buildings in seismic areas with UAV photogrammetry. **Procedia Structural Integrity**, [S.L.], v. 44, p. 1672-1679, 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.prostr.2023.01.214>.

FIORINI, L.; CONTI, A.; PELLIS, E.; BONORA, V.; MASIERO, A.; TUCCI, G. Machine Learning-Based Monitoring for Planning Climate-Resilient Conservation of Built Heritage. **Drones**, [S.L.], v. 8, n. 6, p. 249, 6 jun. 2024. MDPI AG. <http://dx.doi.org/10.3390/drones8060249>.

FREITAS, V.P. **Transferência de humidade em paredes de edifícios- análise do fenómeno de interface**. Tese (Doutorado). Faculdade de Engenharia da Universidade do Porto, 1992.

GAJJAR, Dr. D.; BURGETT, Dr. J. Evaluating the Use of Unmanned Aerial Systems (UAS) to Perform Low-Slope Roof Inspections. **Epic Series In Built Environment**, [S.L.], v. 1, p. 214-204, 2020. EasyChair. <http://dx.doi.org/10.29007/jknh>.

GILI, G. (ed.) **Ministere de L'equipement**, Direction de la Construction, Rehabilitación de la Vivienda. Guia Práctica. Barcelona, Ed. 1980.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. **International Conference on Artificial Intelligence and Statistics**. 13th AISTATS. Proceedings, v. 9 of JMLR: W&CP 9. Italy, 2010. Disponível em: <<https://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf>>. Acessado em: May 15, 2024.

GONÇALVES, M.; SILVESTRE, J. D.; BRITO, J.; GOMES, R. Environmental and economic comparison of the life cycle of waterproofing solutions for flat roofs. **Journal of Building Engineering**, [S.L.], v. 24, p. 100710, Jul. 2019.

HAO, S.; ZHOU, Y.; GUO, Y. A Brief Survey on Semantic Segmentation with Deep Learning. **Neurocomputing**, [S.L.], v. 406, p. 302-321, set. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2019.11.118>.

HEZAVEH, M. M.; KANAN, C.; SALVAGGIO, C. Roof Damage Assessment using Deep learning. **2017 IEEE Applied Imagery Pattern Recognition Workshop (Aipr)**, [S.l.], v. 1, n. 1, p. 1-6, Oct. 2017.

HODGES, C. Effective roof management - Understanding the life cycle of your roof systems, p. 1213-1222. In: 8DBMC International Conference on Durability of Building Materials and Components. **Anais...**, Vancouver, Canadá, 1999.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION - ISO. **ISO 6241**: Performance standards in building - Principles for their preparation and factors to be considered. London: [s.n.], 1984.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION - ISO. **ISO 15686-1**: Buildings and constructed assets - Service life planning. Part 1: General principles and framework. London: [s.n.], 2011.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION - ISO. **ISO 15686-2**: Buildings and constructed assets - Service life planning. Part 2: Service life prediction procedures. London: [s.n.], 2012.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION - ISO. **ISO 15686-7**: Buildings and constructed assets - Service life planning. Part 7: Performance evaluation for feedback of service life data from practice. London: [s.n.], 2006.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION - ISO. **ISO 15686-9**: Buildings and constructed assets - Service life planning. Part 7: Guidance on assessment of service-life data. London: [s.n.], 2008.

KIM, H.; LEE, J.; AHN, E.; CHO, S.; SHIN, M.; SIM, S. Concrete crack identification using a UAV incorporating hybrid image processing, **Sensors**. v. 17, n. 9, p. 2052, 2017. <https://doi.org/10.3390/s17092052>.

KO, P.; PRIETO, S. A.; SOTO, B. G. ABECIS: an automated building exterior crack inspection system using uavs, open-source deep learning and photogrammetry. **Proceedings of the 38th International Symposium on Automation and Robotics in Construction (Isarc)**, [S.l.], p. 1-8, Nov. 2021.

KONG, T.; SUN, F.; LIU, H.; JIANG, Y.; LI, L.; SHI, J. FoveaBox: beyond anchor-based object detection. **Ieee Transactions On Image Processing**, [S.L.], v. 29, p. 7389-7398, 2020. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tip.2020.3002345>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, [S.l.], v. 521, n. 7553, p. 436-444, May, 2015.

LEMOS, R.; CABRAL, R.; RIBEIRO, D.; SANTOS, R.; ALVES, V.; DIAS, A. Automatic Detection of Corrosion in Large-Scale Industrial Buildings Based on Artificial Intelligence and

Unmanned Aerial Vehicles. **Applied Sciences**, [S.L.], v. 13, n. 3, p. 1386, 20 jan. 2023. MDPI AG. <http://dx.doi.org/10.3390/app13031386>.

LIN, T-Y.; GOYAL, P.; GIRSHICK, R.; HE, K.; DOLLÁR, P. Focal Loss for Dense Object Detection. **Computer Vision And Pattern Recognition**, [S.L.], v. 2, p. 1-10, 2017. ArXiv. <http://dx.doi.org/10.48550/ARXIV.1708.02002>.

LLAMAS, J.; LERONES, P.; MEDINA, R.; ZALAMA, E.; GÓMEZ-GARCÍA-BERMEJO, J. Classification of Architectural Heritage Images Using Deep Learning Techniques. **Applied Sciences**, [S.L.], v.7, n.10, p. 992, 26 set. 2017. MDPI AG. <http://dx.doi.org/10.3390/app7100992>.

LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. **2015 IEEE Conference On Computer Vision And Pattern Recognition (Cvpr)**, [S.L.], p. 3431-3440, jun. 2015. IEEE. <http://dx.doi.org/10.1109/cvpr.2015.7298965>.

LOPES, M. L. F., SOUZA, A. L. R., SOUZA, M. D., SILVA, L. S., BAUER, E. Estudo da Degradação de Fachadas Revestidas de Argamassa Utilizando Aeronave Remotamente Pilotada (RPA). **Simpósio Brasileiro de Tecnologia das Argamassas**, 14(00), nov. 2023. <https://doi.org/10.46421/sbta.v14.4762>.

MALCHE, T.; THAREWAL, S.; DHANARAJ, R. K. Automated Damage Detection on Concrete Structures Using Computer Vision and Drone Imagery. **Ecsa 2023**, [S.L.], p. 60, 15 nov. 2023. MDPI. <http://dx.doi.org/10.3390/ecsa-10-16059>.

MELO JÚNIOR, C. M.; EVANGELISTA JUNIOR, F.; SILVA, L. S.; NEPOMUCENO, A. A. Geração de mapas de danos de fachadas de edifícios por processamento digital de imagens capturadas por Vant e uso de fotogrametria digital. **Ambiente Construído**, [S.L.], v. 18, n. 3, p. 211-226, set. 2018. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1678-86212018000300277>.

MENDES, M. V. A. S.; LAFÉ, E. P.; MELO, M. B.; MELO JÚNIOR, C. M. Damages mapping of façade using Aerophotogrammetry and Thermography Inspection: zoroastro artiaga museum ∴ art deco in brazil. **Matéria (Rio de Janeiro)**, [S.L.], v. 27, n. 3, p. 1-18, 2022. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1517-7076-rmat-2022-0031>.

MIDWINTER, M.; AL-SABBAG, Z. A.; YEUM, C. M. Unsupervised defect segmentation with pose priors. **Computer-Aided Civil And Infrastructure Engineering**, [S.L.], v. 38, n. 17, p. 2455-2471, 3 abr. 2023. Wiley. <http://dx.doi.org/10.1111/mice.13001>.

MISHRA, M.; LOURENÇO, P. B. Artificial intelligence-assisted visual inspection for cultural heritage: state-of-the-art review. **Journal Of Cultural Heritage**, [S.L.], v. 66, p. 536-550, mar. 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.culher.2024.01.005>.

MO, Y.; WU, Y.; YANG, X. LIU, F.; LIAO, Y. Review the state-of-the-art technologies of semantic segmentation based on deep learning. **Neurocomputing**, [S.L.], v. 493, p. 626-646, jul. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2022.01.005>.

MOORE, J.; TADINADA, H.; KIRSCHE, K.; PERRY, J.; REMEN, F.; TSE, Z. T. H. Facility inspection using UAVs: a case study in the university of georgia campus. **International Journal of Remote Sensing**, [S.L.], v. 39, n. 21, p. 7189-7200, Oct. 2018.

MORGADO, J. N. P. L. V. **Plano de inspeção e manutenção de coberturas de edifícios correntes**. 2012. 267 p. Dissertação (Mestrado) - Universidade Técnica de Lisboa, Lisboa, 2012.

MOTA, L. M. G. **Estudo da iniciação e da propagação da degradação de fachadas com revestimento em argamassa**. 2021. 179 p. Dissertação (Mestrado em Estruturas e Construção Civil) - Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2021.

NEX, F.; REMONDINO, F. Preface: latest developments, methodologies, and applications based on uav platforms. **Drones**, [S.l.], v. 3, n. 1, p. 26, Mar. 2019.

OTTONI, A. L. C.; NOVO, M. S.; COSTA, D. B. Hyperparameter tuning of convolutional neural networks for building construction image classification. **The Visual Computer**, [S.l.], p. 1-15, jan. 2022.

PAZOS, V. (2024). Relatório Técnico-Científico de Pesquisa de Desenvolvimento de Tecnologia Assistida no Campus Darcy Ribeiro. Coordenação do Laboratório de Prototipagem - Lapis, da Faculdade de Arquitetura e Urbanismo – FAU. Projeto financiado pela Diretoria de Acessibilidade - DACES/UnB.

PEREIRA, A. C. T. **Metodologia de diagnóstico de anomalias em edifícios residenciais com o envolvimento dos seus utilizadores**. 2017. 112 p. Dissertação (Mestrado Integrado em Engenharia Civil) - Curso de Engenharia Civil, Instituto Superior Técnico da Universidade de Lisboa, Portugal, 2017.

PICCHI, F. A. **Impermeabilização de coberturas**. São Paulo: Pini, 1986. 220 p.

PIERDICCA, R.; GORGOGLIONE, L.; MARTUSCELLI, M.; USMANOV, S. CHALLENGING ARCHITECTURES: an integrated and multipurpose survey for the complete mapping of the emir palace in kogon (uzbekistan). **The International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, [S.L.], v. --2-2023, p. 1225-1232, 26 jun. 2023. Copernicus GmbH. <http://dx.doi.org/10.5194/isprs-archives-xxlviii-m-2-2023-1225-2023>.

PORTUGAL. Presidência do Conselho de Ministros e Ministérios das Finanças e da Administração Pública, do Ambiente, do Ordenamento do Território e do Desenvolvimento Regional e das Obras Públicas, Transportes e Comunicações. Portugal: **Diário da República**, v. 1, Seção 212, p. 9-15. 2006.

QIU, H.; ZHANG, J.; ZHUO, L.; XIAO, Q.; CHEN, Z.; TIAN, H. Research on intelligent monitoring technology for roof damage of traditional Chinese residential buildings based on improved YOLOv8: taking ancient villages in southern fujian as an example. **Heritage Science**, [S.L.], v. 12, n. 1, p. 1-17, 4 jul. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1186/s40494-024-01345-8>.

RAINIO, O.; TEUHO, J.; KLÉN, R. Author Correction: evaluation metrics and statistical tests for machine learning. **Scientific Reports**, [S.L.], v. 1, p. 1-14, 8 jul. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-024-66611-y>.

RAKHA, T.; GORODETSKY, A. Review of Unmanned Aerial System (UAS) applications in the built environment: towards automated building inspection procedures using drones. **Automation in Construction**, [S.l.], v. 93, p. 252-264, Sep. 2018.

RAKHA, T.; LIBERTY, A.; GORODETSKY, A.; KAKILLIOGLU, B.; VELIPASALAR, S. Heat Mapping Drones: an autonomous computer-vision-based procedure for building envelope inspection using unmanned aerial systems (uas). **Technology|Architecture + Design**, [S.l.], v. 2, n. 1, p. 30-44, Jan. 2018.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: towards real-time object detection with region proposal networks. **Computer Vision And Pattern Recognition**, [S.L.], v. 3, p. 1-14, 2015. ArXiv. <http://dx.doi.org/10.48550/ARXIV.1506.01497>.

RESENDE, M. **Cobertura e Impermeabilização**: aula 21. São Paulo: Visual, 81 slides, 2017. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5075800/mod_resource/content/3/Impermeabiliza%C3%A7%C3%A3o%20e%20Cobertura.pdf. Acesso em: 30 jan. 2023.

REVISTA ACRÓPOLE. São Paulo: Fauusp, v. 369, 1970. Disponível em: <http://www.acropole.fau.usp.br/edicao/369>. Acesso em: 10 jun. 2021.

ROBOFLOW. Give your software the sense of sight. 2022. Disponível em: <https://roboflow.com/> Acesso em: 8 jan. 2023.

ROBOFLOW. Give your software the sense of sight. 2024. Disponível em: <https://roboflow.com/> Acesso em: 10 mai. 2024.

ROCA, D.; LAGÜELA, S.; DÍAZ-VILARIÑO, L.; ARMESTO, J.; ARIAS, P. Low-cost aerial unit for outdoor inspection of building façades. **Automation In Construction**, [S.L.], v. 36, p. 128-135, dez. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.autcon.2013.08.020>.

SANTOS, D. G. **Estudo da vida útil e degradação de fachadas em argamassa a partir da inspeção de edifícios**. 2018. 136 p. Dissertação (Mestrado em Estruturas e Construção Civil) - Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2018.

SANTOS JUNIOR, G.; FERREIRA, J.; MILLÁN-ARIAS, C.; DANIEL, R.; CASADO JUNIOR, A.; FERNANDES, B. J. T. Ceramic Cracks Segmentation with Deep Learning. **Applied Sciences**, [S.l.], v. 11, n. 13, p. 6017, jun. 2021.

SANTOS, L. M. A.; KAMINSKI, M. G.; GUIMARÃES, B. M.; ZANONI, V. A. G. O impacto dos sistemas de instalações prediais e equipamentos na cobertura plana do ICC.ENTAC2024. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 20., 2024, Maceió. **Anais...** Maceió: ANTAC, 2024.

SANTOS, L. M. A.; LESCANO, L. R.; HIGA, G. T. H.; ZANONI, V. A. G.; SILVA, L. S.; ALVAREZ, C. I.; PISTORI, H. Mapping stains on flat roofs using semantic segmentation based on deep learning. **Case Studies In Construction Materials**, [S.L.], v. 22, p. 04106, jul. 2025. Elsevier BV. <http://dx.doi.org/10.1016/j.cscm.2024.e04106>.

SANTOS, L. M. A.; ZANONI, V. A. G.; BEDIN, E.; PISTORI, H. Deep learning applied to equipment detection on flat roofs in images captured by UAV. **Case Studies In Construction**

Materials, [S.L.], v. 18, p. 1-18, jul. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.cscm.2023.e01917>.

SANTOS, L. M. A.; ZANONI, V. A. G.; ALMEIDA, J. G. **Guia orientativo para edificações com sistema de coberturas em bambu: estudo de caso Brasília – DF**. Brasília, DF: UnB. 2021.

SCHLEE, A. R.; GARCIA, C. G.; SOARES, E. O.; TENORIO, G. S.; NASCIMENTO, M. L. C.; VULCÃO, M. G. V.; CHOAS, M. L. L. S. **Registro Arquitetônico da Universidade de Brasília**. Brasília: Universidade de Brasília, 2014. 152 p.

SENA, G. O.; NASCIMENTO, M. L. M.; NETO, A. C. N.; LIMA, N. M. **Patologia das Construções**. Primeira Edição. Salvador: Editora 2B. 2020.

SHOAB, M.; SINGH, V. K.; RAVIBABU, M. V. High-Precise True Digital Orthoimage Generation and Accuracy Assessment based on UAV Images. **Journal Of The Indian Society Of Remote Sensing**, [S.L.], v. 50, n. 4, p. 613-622, 11 abr. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12524-021-01364-z>.

SILVA, É.; VASCONCELLOS, J.; SÁNCHEZ, J. M. **Instituto Central de Ciências: A complexidade da síntese**. In: Congresso Internacional de História da Construção Luso-Brasileira - 3ºCIHCLB. Salvador: Universidade Federal da Bahia, 2019.

SILVA, L. S.; ZANONI, V. A. G.; PAZOS, V. C.; SANTOS, L. M. A. S.; JUCÁ, T. R. P. Fotogrametria com imagens adquiridas com drones: do plano de voo ao modelo 3D. Brasília, DF: LaSUS FAU: Editora Universidade de Brasília, 2022. 78 p. DOI: <https://doi.org/10.29327/563260>. Disponível em: <https://livros.unb.br/index.php/portal/catalog/book/202>.

SILVEIRA, B.; MELO, R.; COSTA, D. B. Using UAS for Roofs Structure Inspections at Post-occupational Residential Buildings. **Lecture Notes in Civil Engineering**, [S.l.], p. 1055-1068, jul. 2020.

SOUZA, J. S. **Impacto dos fatores de degradação sobre a vida útil de fachadas de edifícios**. 2019. 160 p. Tese (Doutorado em Estruturas e Construção Civil) - Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2019.

STAFFA JUNIOR, L. B.; COSTA, D.; NOGUEIRA, J. T.; SILVA, A. S. Web platform for building roof maintenance inspection using UAS and artificial intelligence. **International Journal Of Building Pathology And Adaptation**, v. 1, p. 1, 2023. <https://doi.org/10.1108/IJBPA-12-2022-0186>.

STAFFA, L. B.; SÁ, L. S.; 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, p.1-8. In: Encontro Nacional de Tecnologia do Ambiente Construído, **Anais...** Porto Alegre: UFRGS, 2020.

TAOUFIQ, S.; NAGY, B.; BENEDEK, C. HierarchyNet: hierarchical cnn-based urban building classification. **Remote Sensing**, [S.l.], v. 12, n. 22, p. 3794, Nov. 2020.

THISANKE, H.; DESHAN, C.; CHAMITH, K.; SENEVIRATNE, S.; VIDANAARACHCHI, R.; HERATH, D. Semantic segmentation using Vision Transformers: A survey. **Engineering Applications of Artificial Intelligence**, v. 126, p. 106669, 2023. <https://doi.org/10.1016/j.engappai.2023.106669>.

TORRES-GONZÁLES, M.; VALENÇA, J.; SANTOS, B. O.; SILVA, A.; MENDES, M. P. StainView: a fast and reliable method for mapping stains in facades using image classification in hsv and cielab colour space. **Remote Sensing**, [S.L.], v. 15, n. 11, p. 2895, 1 jun. 2023. MDPI AG. <http://dx.doi.org/10.3390/rs15112895>.

VIANA, B. **Universidade de Brasília é a oitava melhor Universidade do Brasil**. 2019. Disponível em: <<https://obrasilianista.com.br/2019/09/12/universidade-de-brasilia-e-a-oitava-melhor-universidade-do-brasil/>>. Acesso em: 30 jan. 2023.

STUDIES, Centre For Science And Technology. **VOSviewer**: visualizing scientific landscapes. Visualizing scientific landscapes. 2025. Disponível em: <https://www.vosviewer.com/>. Acesso em: 10 dez. 2024.

WALTER, A.; LOPES, J.; DE BRITO, J. Flat-roof waterproofing to prevent anomalies on its surface, p.519-528. In: International Symposium on Building Pathology, Durability and Rehabilitation. **Anais...** CBPDR: Lisboa, 2003.

WALTER, A.; BRITO, J.; LOPES, G. Current flat roof bituminous membranes waterproofing systems - Inspection, diagnosis and pathology classification. **Construction and building materials**, [S.l.], v. 19, n. 3, p. 233-242, 2005.

WANG, J.; ZHANG, W.; CAO, Y.; CHEN, K.; PANG, J.; GONG, T.; SHI, J.; LOY, C. C.; LIN, D. Side-Aware Boundary Localization for More Precise Object Detection. **Computer Vision And Pattern Recognition**, [S.L.], v. 2, p. 1-21, 2019. ArXiv. <http://dx.doi.org/10.48550/ARXIV.1912.04260>.

XIE; E., WANG, W.; YU, Z.; ANANDKUMAR, A.; ALVAREZ, J. M.; LUO, P. SegFormer: Simple and efficient design for semantic segmentation with transformers. **Advances in neural information processing systems**. p. 12077, 2021.

YUDIN, D; NAUMOV, A.; DOLZHENKO, A.; PATRAKOVA, E. Software for roof defects recognition on aerial photographs. **Journal of Physics: Conference Series**, [S.l.], v. 1015, p. 032152, May 2018.

YIN, Y.; ANTONIO, J. Application of 3D laser scanning technology for image data processing in the protection of ancient building sites through deep learning. **Image and Vision Computing**, [S.L.], v. 102, p. 103969, out. 2020. Elsevier BV. <https://doi.org/10.1016/j.imavis.2020.103969>.

ZANONI, V. A. G. **Influência dos agentes climáticos de degradação no comportamento higrotérmico de fachadas em Brasília**. 2015. 293 p. Tese (Doutorado) - Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2015.

ZANONI, V. A. G. (org.); LIRA, F. B.; FERREIRA, O. L.; FRAZAO, K. N.T.; GEHLEN, J.; JUCÁ, T.R.P.; MEDEIROS, A. E. de A.; MELO, C. E. L. de; MISHINA, L. N. C.; PEREIRA,

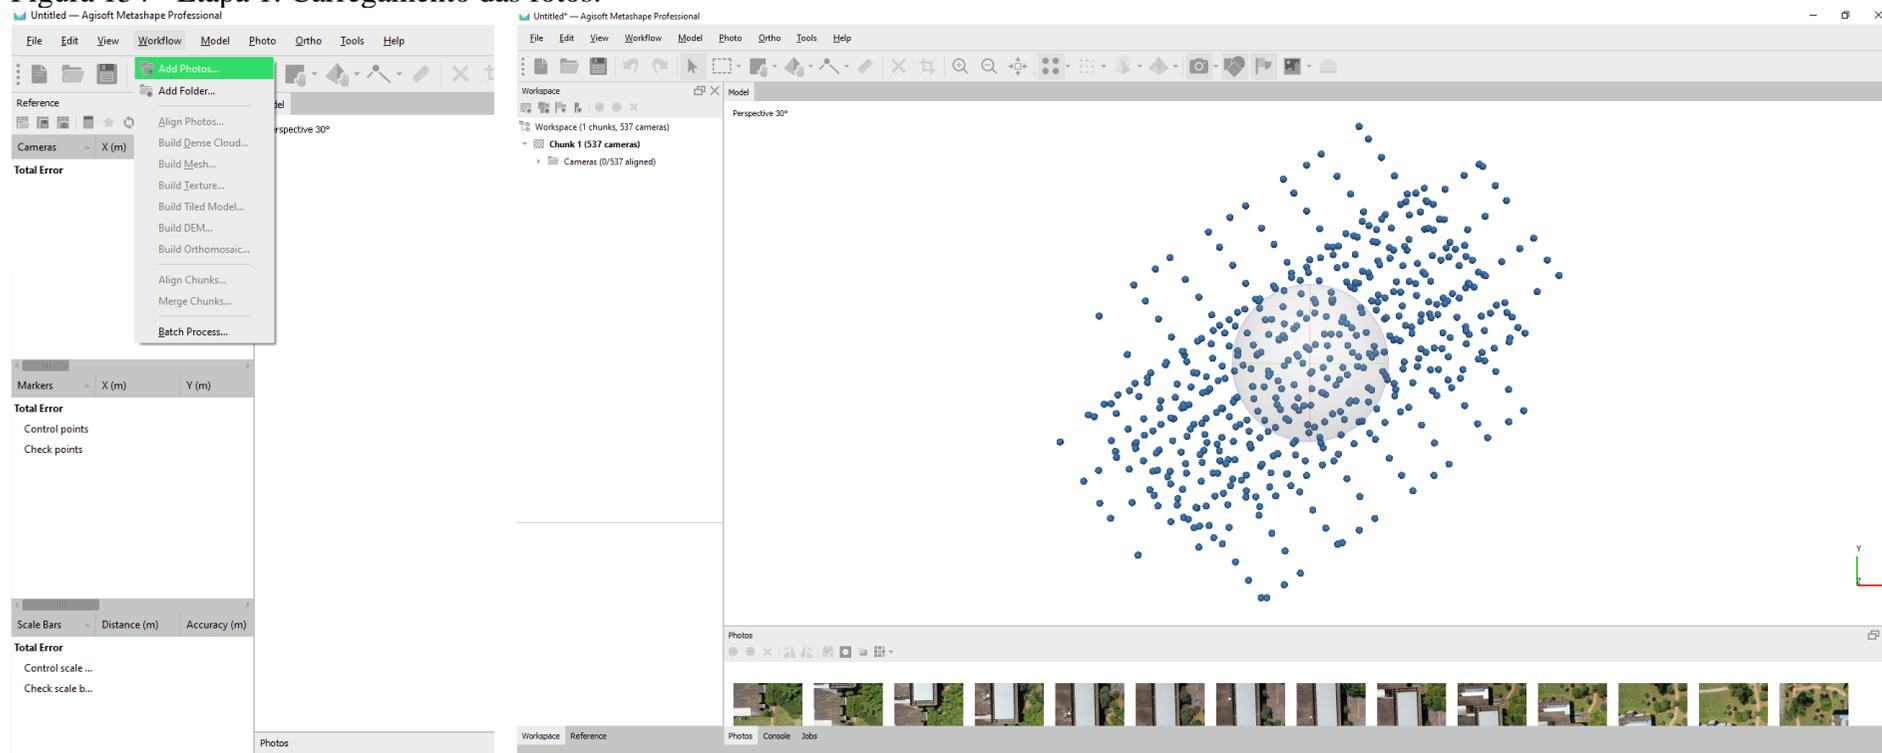
C. H. de A. F.; RIOS, R. B.; SANTOS, A.V. Programa de Conservação e Manutenção Continuada para as Edificações da Universidade de Brasília: Da Concepção ao Delineamento de Programas e Planos. Relatório Geral – Módulo I | Módulo II | Módulo III. Projeto Institucional de Pesquisa e Extensão da Universidade de Brasília (UnB) e Faculdade de Arquitetura e Urbanismo (FAU). Brasília: UnB, mar. 2023. Formato A3, 269 p.

ZHANG, S.; CHI, C.; YAO, Y.; LEI, Z.; LI, S. Z. Bridging the Gap Between Anchor-based and Anchor-free Detection via Adaptive Training Sample Selection. **Computer Vision And Pattern Recognition**, [S.L.], v. 4, p. 1-10, 2019. ArXiv. <http://dx.doi.org/10.48550/ARXIV.1912.02424>.

ZHANG, S.; SONG, X.; LIU, S.; SUN, F.; LIU, G.; TAN, Z. Template-assisted synthesized MoS₂/polyaniline hollow microsphere electrode for high performance supercapacitors. **Electrochimica Acta**, [S.L.], v. 312, p. 1-10, jul. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.electacta.2019.04.177>.

ZHANG, J.; XU, S.; ZHAO, Y.; SUN, J.; XU, S.; ZHANG, X. Aerial orthoimage generation for UAV remote sensing: review. **Information Fusion**, [S.L.], v. 89, p. 91-120, jan. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.inffus.2022.08.007>.

Figura 154 - Etapa 1: Carregamento das fotos.

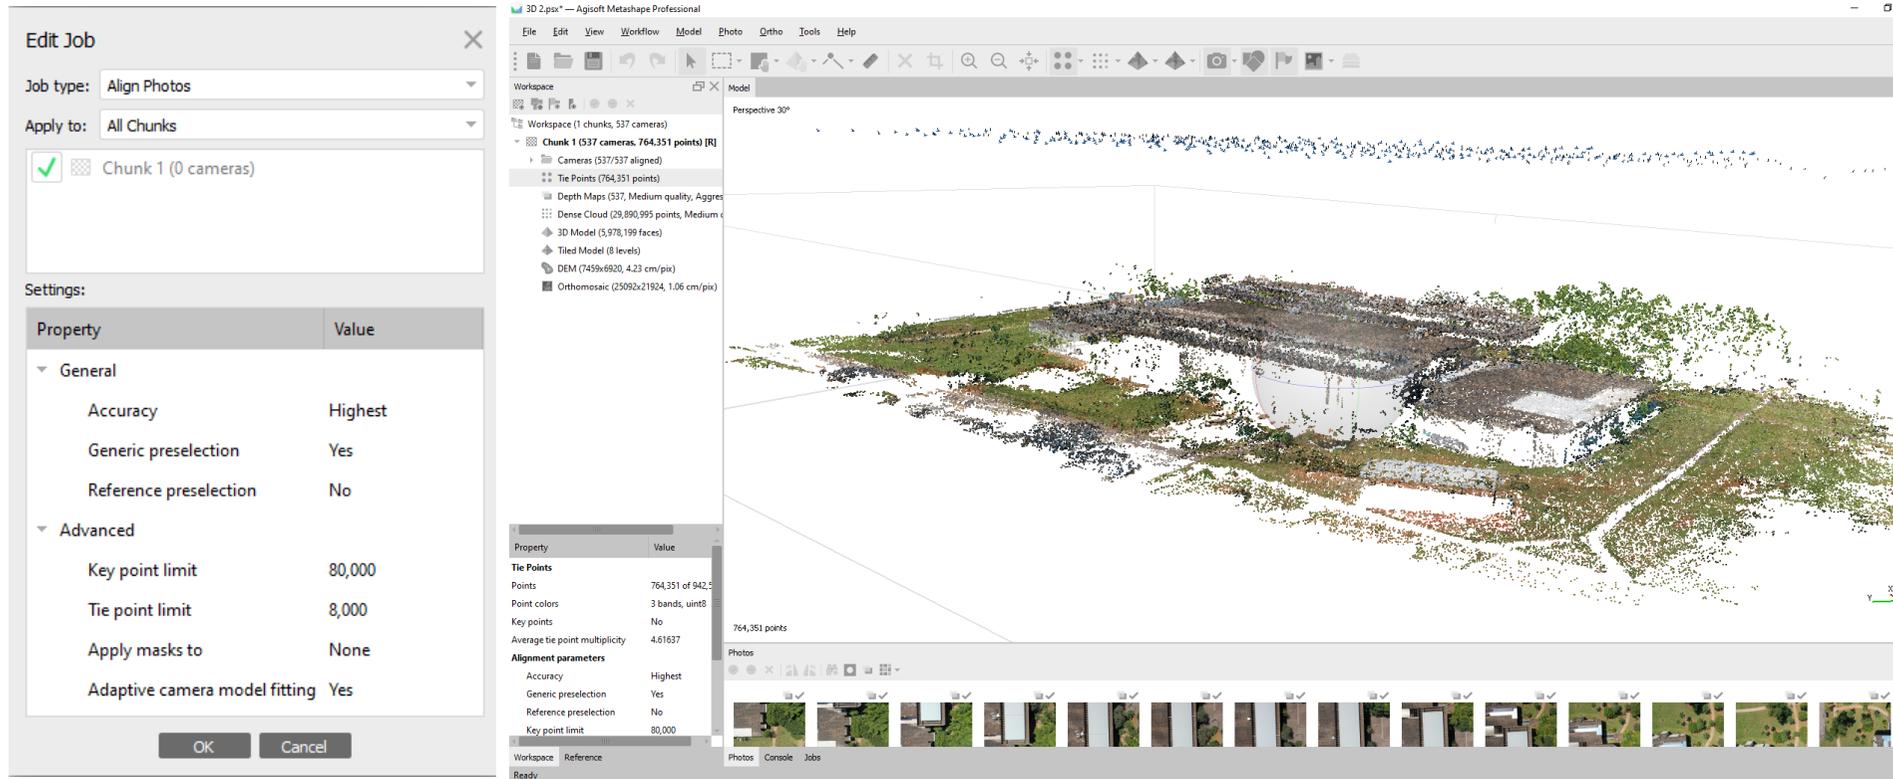


(a)

(b)

Fonte: Elaborado pela autora.

Figura 155 - Etapa 2: Alinhamento das fotos (Processamento BCE – 5D).

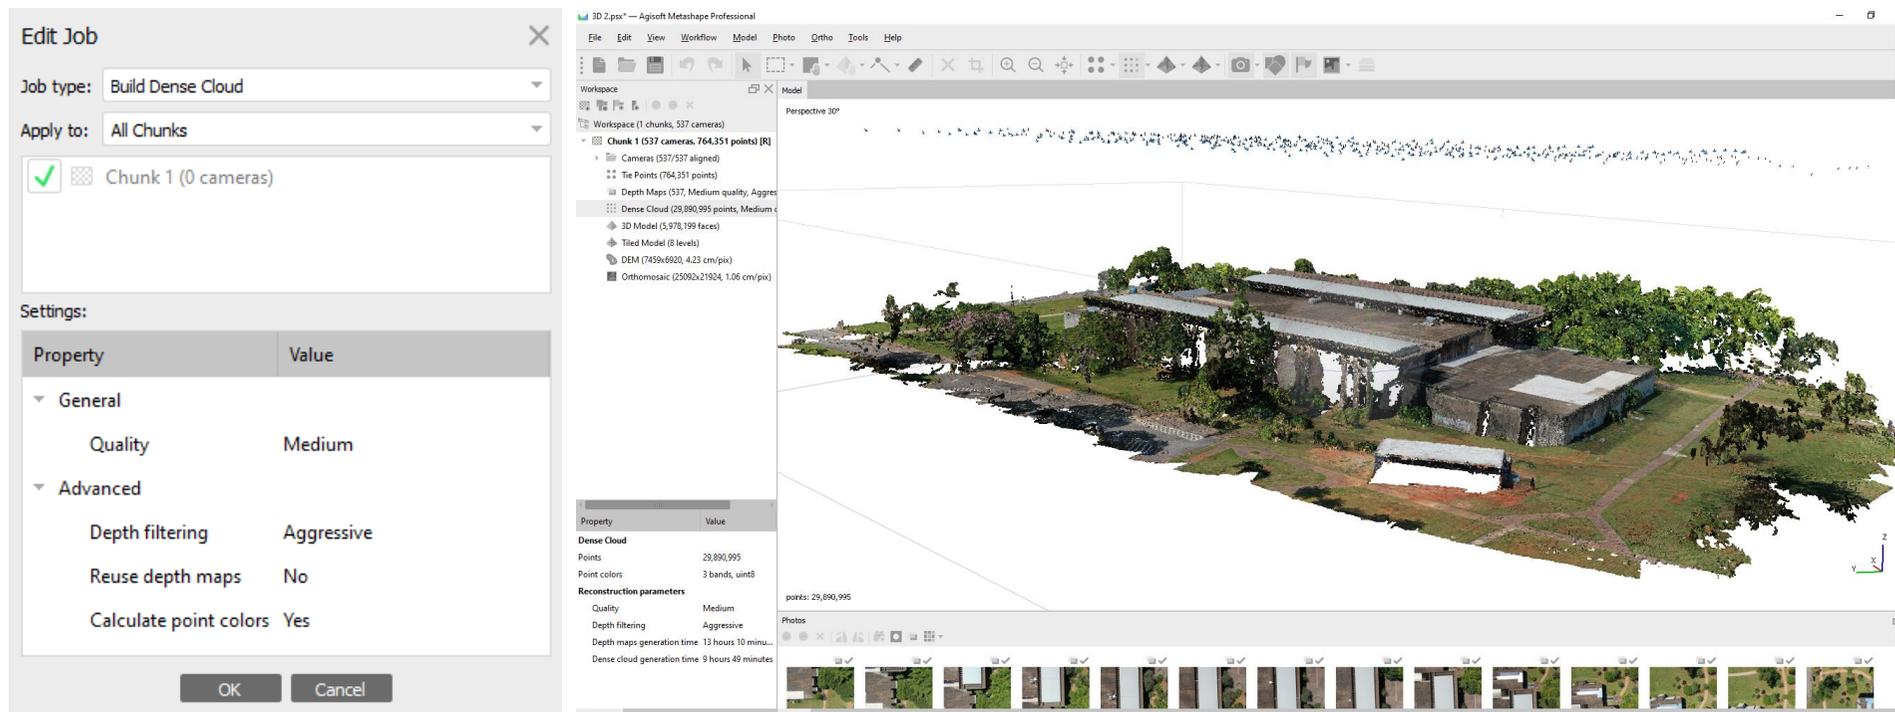


(a)

(b)

Fonte: Elaborado pela autora.

Figura 156 - Etapa 3: Dense Cloud (Processamento BCE – 5D).

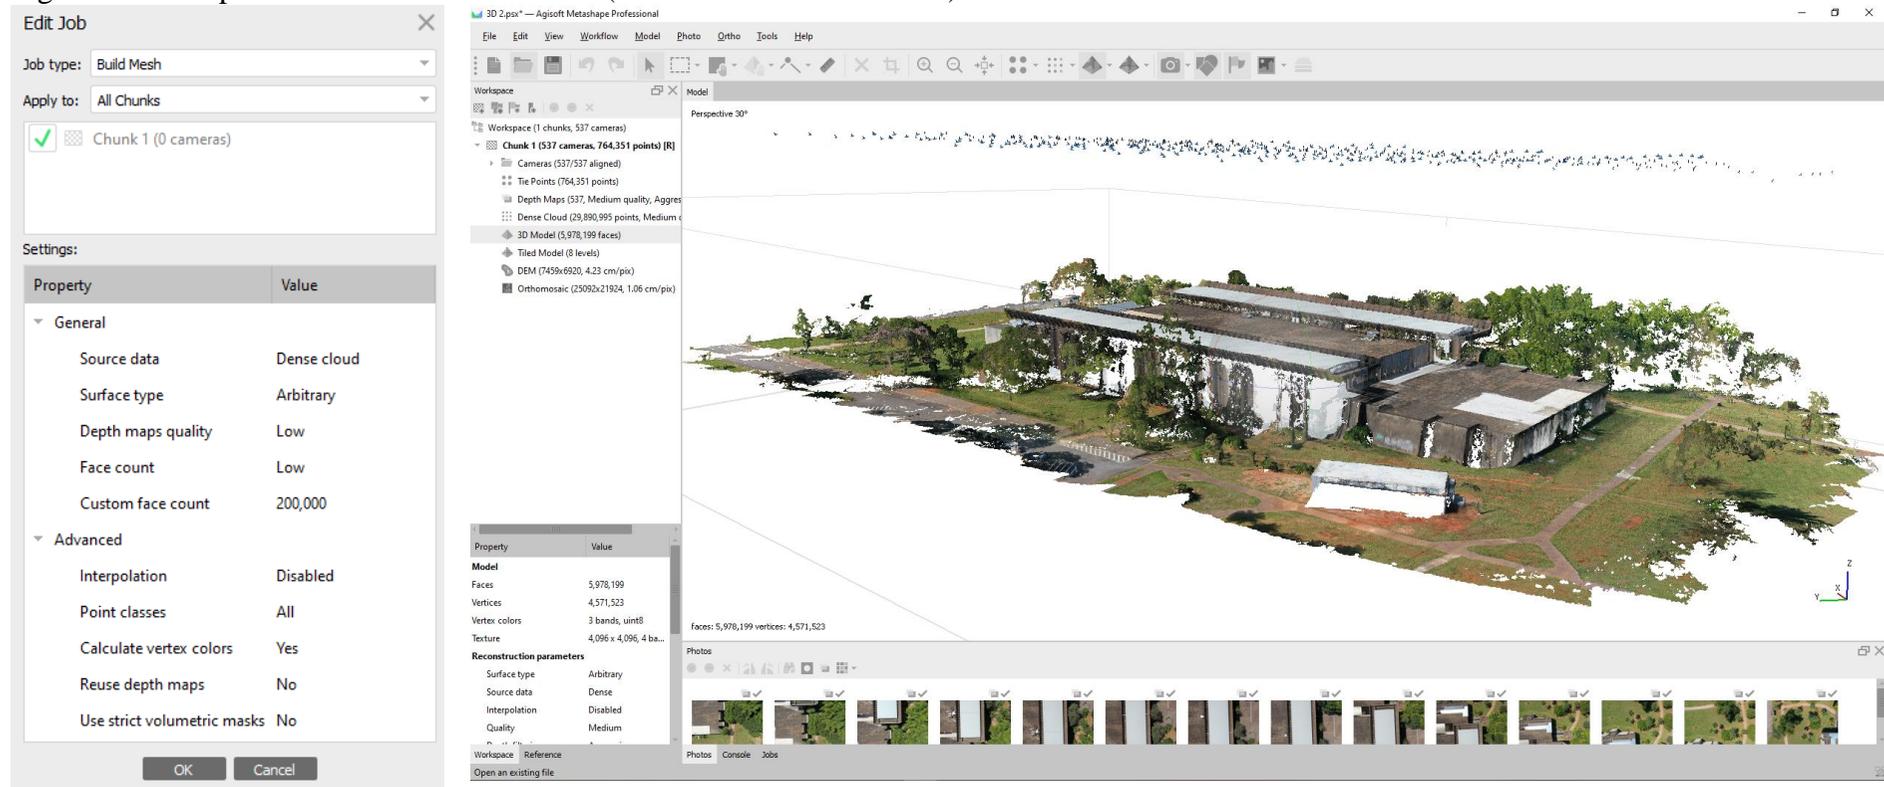


(a)

(b)

Fonte: Elaborado pela autora.

Figura 157 - Etapa 3: Build Mesh - 3D Model (Processamento BCE – 5D).

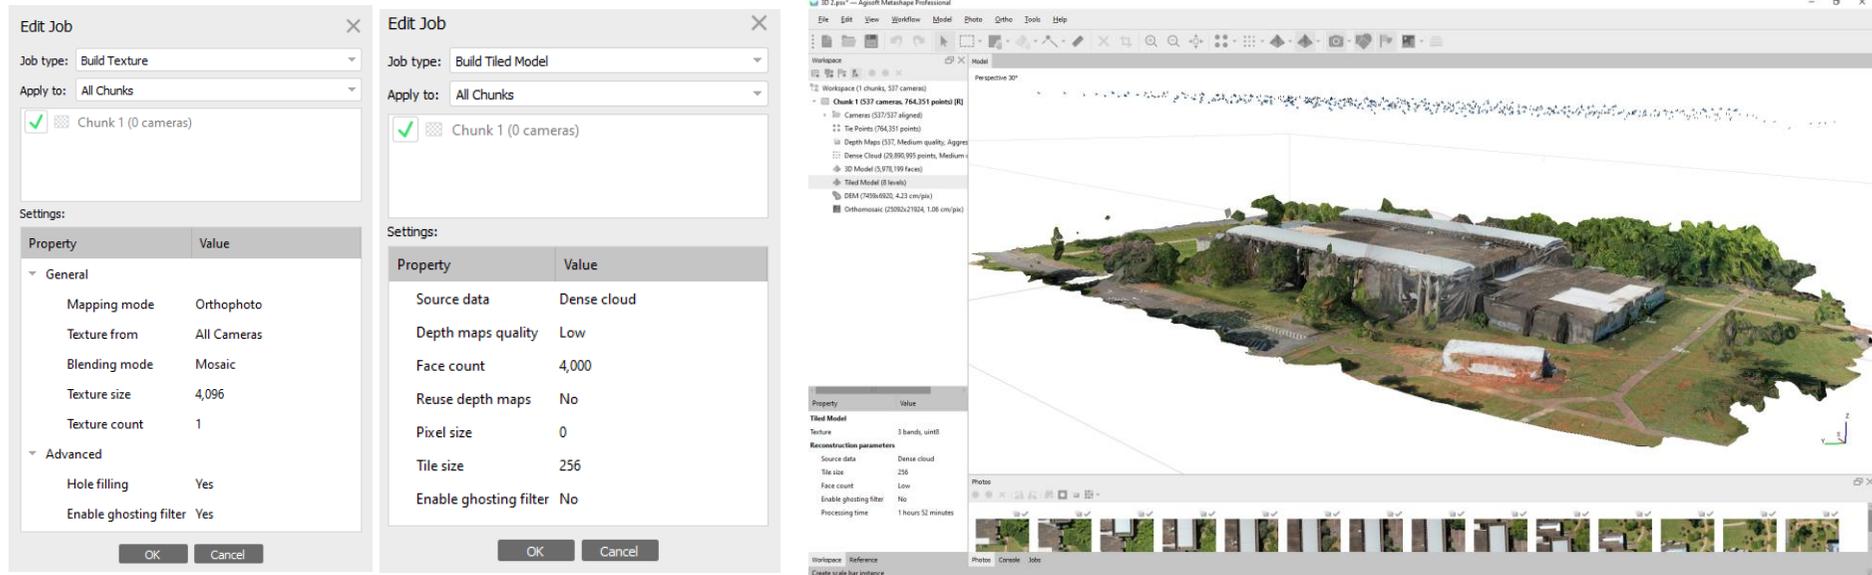


(a)

(b)

Fonte: Elaborado pela autora.

Figura 158 - Etapa 4: Tiled Model (Processamento BCE – 5D).

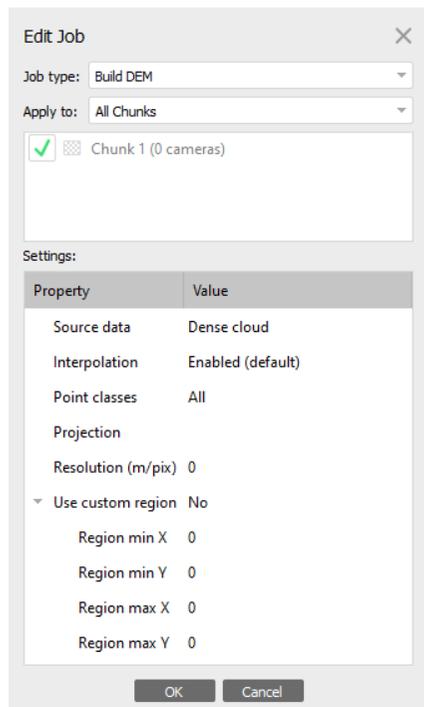


(a)

(b)

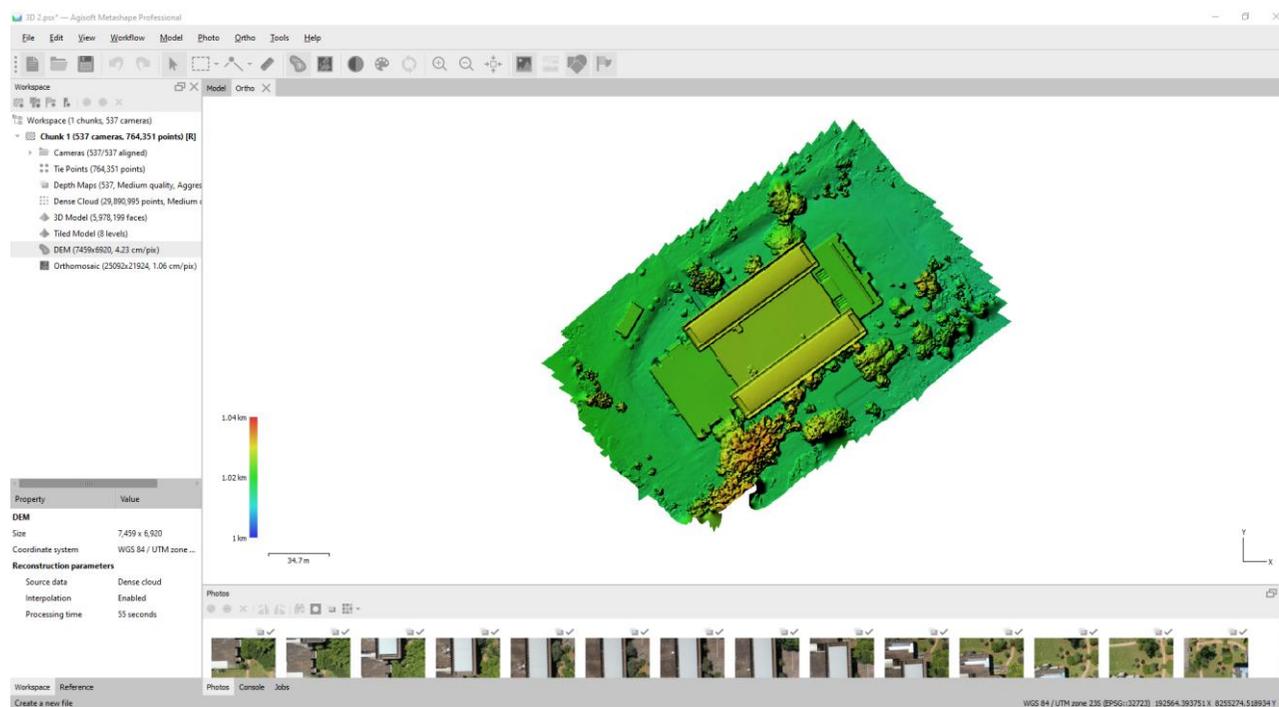
Fonte: Elaborado pela autora.

Figura 159 - Etapa 5: DEM (Processamento BCE – 5D).



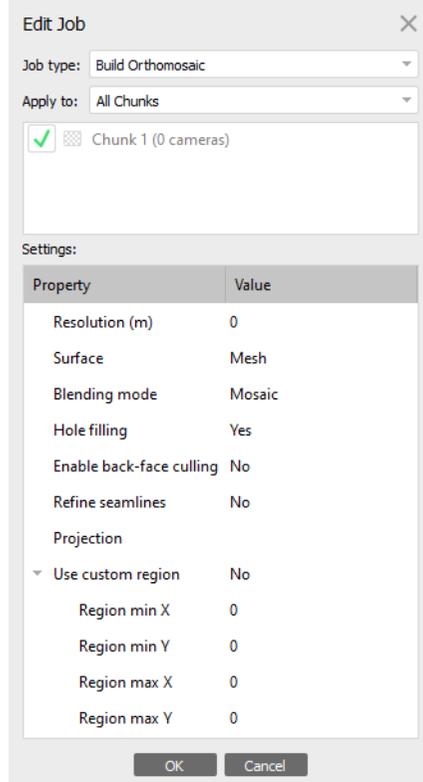
(a)

Fonte: Elaborado pela autora.

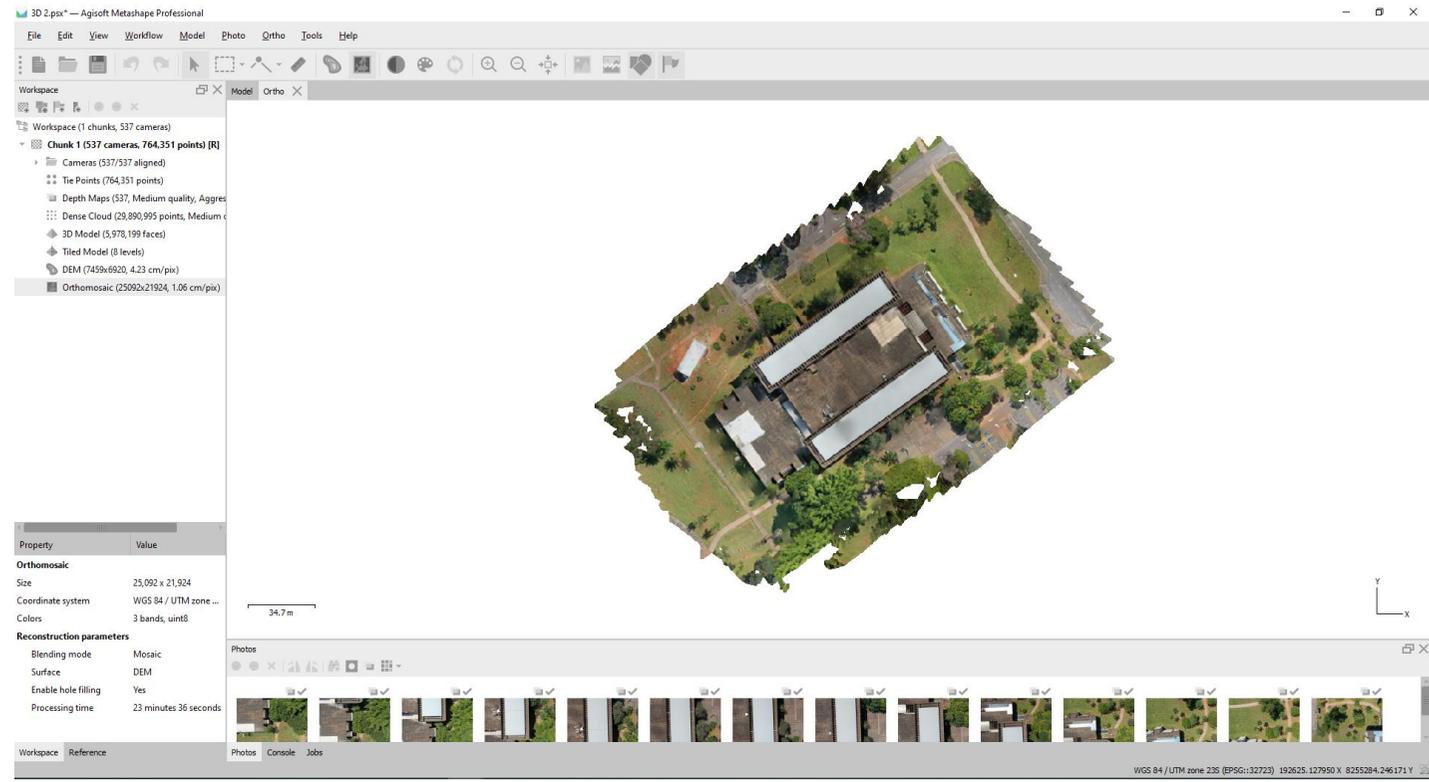


(b)

Figura 160 - Etapa 6: Ortoimagem (Processamento BCE – 5D).



(a)



(b)

Fonte: Elaborado pela autora.

APÊNDICE B

Tabela 33 - Dados dos parâmetros da etapa de processamento.

Parâmetros/Amostras	QGEx 1	QGEx 2	QGEx 3	ICC 1	ICC 2	ICC 3
Align Photos						
<i>Accuracy</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>High</i>	<i>High</i>
<i>Generic preselection</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
<i>Key point limit</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>
<i>Tie point limit</i>	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>
<i>Tempo de processamento</i>	<i>1h 29m</i>	<i>1h 5m</i>	<i>13m 2s</i>	<i>11m 12s</i>	<i>9m 7s</i>	<i>8m 46s</i>
Build Dense Cloud						
<i>Quality</i>	<i>Medium</i>	<i>High</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
<i>Depth filtering</i>	<i>Aggressive</i>	<i>Aggressive</i>	<i>Moderate</i>	<i>Aggressive</i>	<i>Moderate</i>	<i>Moderate</i>
<i>Tempo de processamento</i>	<i>11m 58s</i>	<i>11m 24s</i>	<i>9m 33s</i>	<i>22m 48s</i>	<i>35m 30s</i>	<i>57m 22s</i>
Build Mesh						
<i>Source data</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>
<i>Surface type</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>
<i>Interpolation</i>	<i>Disabled</i>	<i>Enabled</i>	<i>Disabled</i>	<i>Disabled</i>	<i>Enabled</i>	<i>Disable</i>
<i>Quality</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
<i>Tempo de processamento</i>	<i>1h 36m</i>	<i>1h 32m</i>	<i>58m 40s</i>	<i>51m 53s</i>	<i>38m 48s</i>	<i>1h 5m</i>
Build Texture						
<i>Mapping mode</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>
<i>Blending mode</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Tempo de processamento</i>	<i>42m 5s</i>	<i>36m 17s</i>	<i>17m 57s</i>	<i>28m 48s</i>	<i>36m 15s</i>	<i>58m 23s</i>
Build Tiled Model						
<i>Source data</i>	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>-</i>	<i>Dense cloud</i>	<i>-</i>	<i>Dense cloud</i>
<i>Face count</i>	<i>Low</i>	<i>Low</i>		<i>Low</i>		<i>Low</i>
<i>Tempo de processamento</i>	<i>5h 51m</i>	<i>5h 33m</i>		<i>16h 14m</i>		<i>3h 59s</i>
Build DEM						
<i>Source data</i>	<i>Dense cloud</i>					
<i>Interpolation</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>
<i>Tempo de processamento</i>	<i>2m 22s</i>	<i>3m 5s</i>	<i>1m 14s</i>	<i>3m 11s</i>	<i>41s</i>	<i>1m 42s</i>
Build Orthomosaic						
<i>Surface</i>	<i>Mesh</i>	<i>DEM</i>	<i>DEM</i>	<i>Mesh</i>	<i>Mesh</i>	<i>DEM</i>
<i>Blending mode</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Hole filling</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
<i>Tempo de processamento</i>	<i>25m 32s</i>	<i>23h 40m</i>	<i>13m 48s</i>	<i>30m 4s</i>	<i>13m 13s</i>	<i>35m 29s</i>

Fonte: Elaborado pela autora.

Tabela 34 - Dados dos parâmetros da etapa de processamento.

Parâmetros/Amostras	ICC 4	ICC 5	ICC 6	ICC 7	ICC 8
Align Photos					
<i>Accuracy</i>	<i>High</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>
<i>Generic preselection</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
<i>Key point limit</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>
<i>Tie point limit</i>	<i>8,000</i>	<i>8,000</i>	<i>80,000</i>	<i>8,000</i>	<i>8,000</i>
<i>Tempo de processamento</i>	<i>11m 1s</i>	<i>8m 2s</i>	<i>12m 51s</i>	<i>6m 16s</i>	<i>1h 15m</i>
Build Dense Cloud					
<i>Quality</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
<i>Depth filtering</i>	<i>Moderate</i>	<i>Aggressive</i>	<i>Aggressive</i>	<i>Aggressive</i>	<i>Aggressive</i>
<i>Tempo de processamento</i>	<i>30m 36s</i>	<i>38m 21s</i>	<i>30m 49s</i>	<i>13m 25s</i>	<i>2h 44m</i>
Build Mesh					
<i>Source data</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>
<i>Surface type</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>
<i>Interpolation</i>	<i>Disabled</i>	<i>Disabled</i>	<i>Disabled</i>	<i>Disabled</i>	<i>Disabled</i>
<i>Quality</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
<i>Tempo de processamento</i>	<i>1h 35m</i>	<i>1h 24m</i>	<i>1h 47s</i>	<i>1h 20m</i>	<i>15h 27m</i>
Build Texture					
<i>Mapping mode</i>	<i>-</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>
<i>Blending mode</i>		<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Tempo de processamento</i>		<i>35m 34s</i>	<i>57m 32s</i>	<i>33m 13s</i>	<i>4h 26m</i>
Build Tiled Model					
<i>Source data</i>	<i>Dense cloud</i>				
<i>Face count</i>	<i>Low</i>	<i>Low</i>	<i>Low</i>	<i>Low</i>	<i>Low</i>
<i>Tempo de processamento</i>	<i>4h 14m</i>	<i>19h 8m</i>	<i>14h 59m</i>	<i>5h 35m</i>	<i>1 dia 4h</i>
Build DEM					
<i>Source data</i>	<i>Dense cloud</i>				
<i>Interpolation</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>
<i>Tempo de processamento</i>	<i>2m 50s</i>	<i>5m 21s</i>	<i>6m 12s</i>	<i>3m 37s</i>	<i>35m 22s</i>
Build Orthomosaic					
<i>Surface</i>	<i>DEM</i>	<i>Mesh</i>	<i>Mesh</i>	<i>Mesh</i>	<i>Mesh</i>
<i>Blending mode</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Hole filling</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
<i>Tempo de processamento</i>	<i>38m 29s</i>	<i>59m 6s</i>	<i>1h 15m</i>	<i>16h 35m</i>	<i>4h 54m</i>

Fonte: Elaborado pela autora.

Tabela 35 - Dados dos parâmetros da etapa de processamento.

Parâmetros / Amostras	BCE 1	BCE 2	BCE 3	Reitoria 1	UCA 1	UCA 2	UCA 3
Align Photos							
<i>Accuracy</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>	<i>Highest</i>
<i>Generic preselection</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Enable</i>	<i>Enable</i>	<i>Enable</i>	<i>Enable</i>
<i>Key point limit</i>	<i>40,000</i>	<i>40,000</i>	<i>40,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>	<i>80,000</i>
<i>Tie point limit</i>	<i>10,000</i>	<i>10,000</i>	<i>10,000</i>	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>	<i>8,000</i>
<i>Tempo de processamento</i>	<i>9m 13s</i>	<i>2m 9s</i>	<i>9m 22s</i>	<i>30m 2s</i>	<i>9m 13s</i>	<i>2m 20s</i>	<i>1m 6s</i>
Build Dense Cloud							
<i>Quality</i>	<i>Highest</i>	<i>Ultra-high</i>	<i>Highest</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
<i>Depth filtering</i>	<i>Moderate</i>	<i>Moderate</i>	<i>Mild</i>	<i>Aggressive</i>	<i>Aggressive</i>	<i>Aggressive</i>	<i>Aggressive</i>
<i>Tempo de processamento</i>	<i>1h 5m</i>	<i>3h 48m</i>	<i>18h 49m</i>	<i>2h 18m</i>	<i>3h 7m</i>	<i>18m 32s</i>	<i>4m 15s</i>
Build Mesh							
<i>Source data</i>				<i>Dense</i>	<i>Dense</i>	<i>Dense</i>	<i>Dense</i>
<i>Surface type</i>	-	-	-	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>	<i>Arbitrary</i>
<i>Interpolation</i>				<i>Disabled</i>	<i>Disabled</i>	<i>Disabled</i>	<i>Disabled</i>
<i>Quality</i>				<i>Medium</i>	<i>Medium</i>	<i>Medium</i>	<i>Medium</i>
<i>Tempo de processamento</i>				<i>1h 30m</i>	<i>22m 38s</i>	<i>11m 4s</i>	<i>5m 24s</i>
Build Texture							
<i>Mapping mode</i>	-	-	-	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>	<i>Orthophoto</i>
<i>Blending mode</i>				<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Tempo de processamento</i>				<i>1h 18m</i>	<i>48m 24s</i>	<i>14m 43s</i>	<i>7m 38s</i>
Build Tiled Model							
<i>Source data</i>	-	-	-	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>
<i>Face count</i>				<i>Low</i>	<i>Low</i>	<i>Low</i>	<i>Low</i>
<i>Tempo de processamento</i>				<i>7h 10m</i>	<i>2h 25m</i>	<i>53m 37s</i>	<i>38m 53s</i>
Build DEM							
<i>Source data</i>	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Sparse cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>	<i>Dense cloud</i>
<i>Interpolation</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>	<i>Enabled</i>
<i>Tempo de processamento</i>	<i>3m 33s</i>	<i>3m 55s</i>	<i>13s</i>	<i>2m 33s</i>	<i>1m 8s</i>	<i>34s</i>	<i>16s</i>
Build Orthomosaic							
<i>Surface</i>	<i>DEM</i>	<i>DEM</i>	<i>DEM</i>	<i>Mesh</i>	<i>Mesh</i>	<i>Mesh</i>	<i>Mesh</i>
<i>Blending mode</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>	<i>Mosaic</i>
<i>Hole filling</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>	<i>Yes</i>
<i>Tempo de processamento</i>	<i>21m 17s</i>	<i>9m 12s</i>	<i>15m 4s</i>	<i>1h 8m</i>	<i>27m 18s</i>	<i>9m 41s</i>	<i>4m 11s</i>

Fonte: Elaborado pela autora.

APÊNDICE C

Tabela 36 - Descrição dos métodos de detecção de objetos.

Símbolo usado	Descrição
Faster R-CNN	O Faster R-CNN consiste em um detector de objetos de aprendizagem profunda de dois estágios que usa a Rede de Proposta de Região (RPN) como um algoritmo de proposta de região e o Fast R-CNN como uma rede de detecção. Em primeiro lugar, essas redes identificam regiões de interesse e usam o algoritmo de proposta de região para gerar caixas delimitadoras ou locais de possíveis objetos na imagem. Em seguida, essas regiões são transferidas para uma rede neural convolucional que é usada para obter recursos desses objetos, seguida por uma camada de classificação para prever a qual classe esses objetos pertencem e, por fim, uma camada de regressão para tornar as coordenadas da caixa delimitadora do objeto mais precisas (REN <i>et al.</i> , 2015).
Retina-Net	O Retina-Net usa uma rede de backbone e duas sub-redes para realizar tarefas específicas. A primeira rede, a rede de backbone, é responsável pelo cálculo de um mapa de recursos convolucional da imagem de entrada inteira. A primeira sub-rede executa a classificação convolucional de objetos na saída do backbone, e a segunda sub-rede executa a regressão convolucional da caixa delimitadora. Detectores de objetos de dois estágios, o desequilíbrio de classe é tratado por uma cascata de dois estágios e heurística de amostragem. O estágio de proposta reduz rapidamente o número de locais de objetos candidatos a um pequeno número, filtrando as amostras de fundo. No estágio de classificação, a heurística de amostragem, como uma proporção fixa de primeiro plano para segundo plano, é realizada para manter um equilíbrio gerenciável entre primeiro plano e segundo plano (LIN <i>et al.</i> , 2017).
Atss	Adaptive Training Sample Selection (Atss) método que seleciona automaticamente amostras positivas e negativas de acordo com características estáticas do objeto. Ele preenche a lacuna entre amostras baseadas em âncora e amostras sem âncora (ZHANG <i>et al.</i> , 2019).
VFNet	O VarifocalNet (VFNet) é um detector de objetos densos com reconhecimento de IoU, destinado a classificar com precisão um grande número de detecções candidatas. Ele consiste em uma nova função de perda denominada Varifocal Loss, para treinar um detector de objetos densos para prever o IACS (IoU-Aware Classification Score) e uma nova representação eficiente de recurso de caixa delimitadora em forma de estrela para estimar o IACS e refinar as caixas delimitadoras grosseiras (ZHANG <i>et al.</i> , 2019).
Sabl	O SABL (<i>Side-Aware Boundary Localization</i>) consiste em usar um ramo de rede dedicado em cada lado da caixa delimitadora para detectar objetos (WANG <i>et al.</i> , 2019).
Fovea	FoveaBox (Fovea) é uma estrutura precisa, flexível e livre de âncoras para detecção de objetos. Esta arquitetura de rede aprende diretamente as características do objeto e as coordenadas da caixa delimitadora sem referência de âncora (KONG <i>et al.</i> , 2020).

Fonte: Elaborado pela autora.

Tabela 37 - Descrição dos hiperparâmetros usados no experimento.

Hiperparâmetros	Descrição
Epochs	As épocas para um sistema de inteligência artificial, referem-se ao número de vezes que o algoritmo irá realizar o treinamento, testes e validações com todo o dataset disponível, ajustando os pesos das iterações com base nos resultados de cada época executada.
Classifier threshold	Define o limiar que determina se o objeto detectado é ou não o objeto a ser detectado.
Intersection Over Union (IoU)	Determina a porcentagem que a anotação realizada pelo algoritmo deve interseccionar com a anotação manual para ser considerado uma detecção.
Learn Rate	Determina o tamanho do passo que cada iteração de aprendizagem deve ter em relação ao todo, enquanto essa etapa se move para o mínimo de uma função de perda.

Fonte: Elaborado pela autora.

Tabela 38 - Descrição das métricas de desempenho usadas na avaliação.

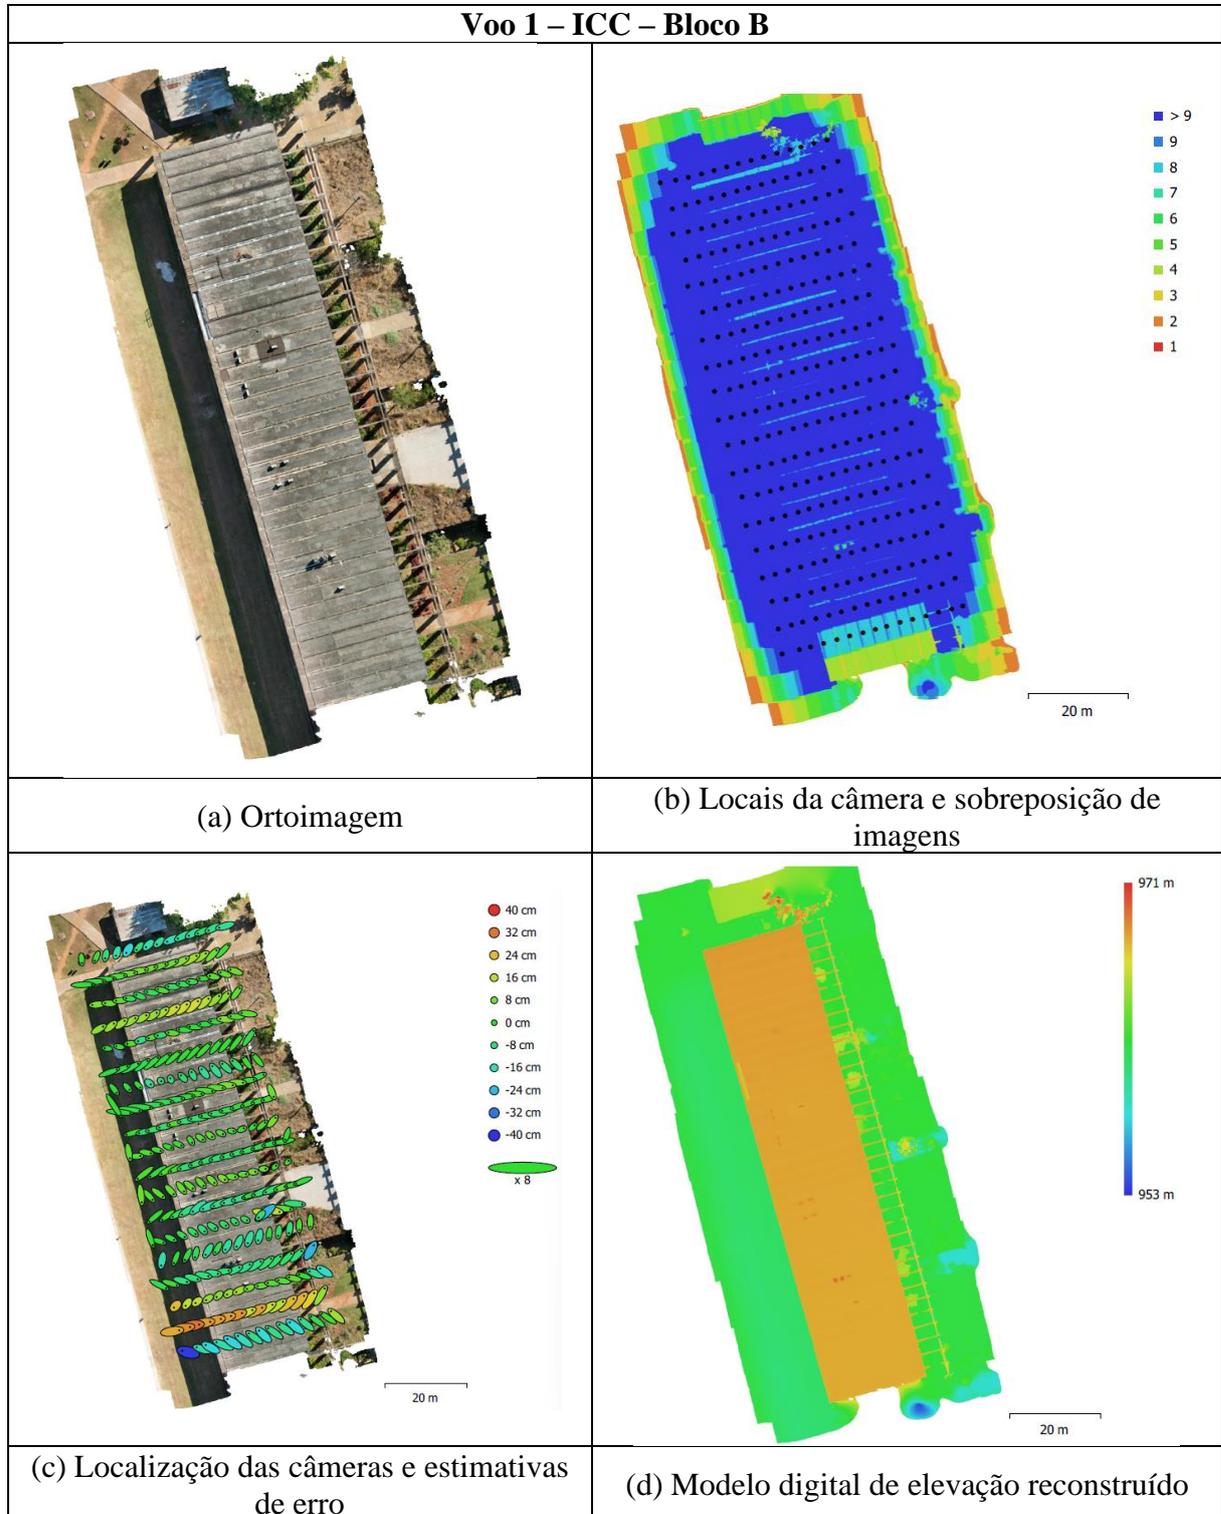
Métrica	Símbolo utilizado	Descrição
Precision	P	É considerada a fração dos verdadeiros positivos, a previsão correta da quantidade total de resultados relevantes, ou seja, a soma de TP e FP. $P = TP / (TP + FP)$
Recall	R	Ela é definida como a fração de casos positivos reais que estão relacionados corretamente, ou seja, a quantidade de TP da quantidade total de TP e FN. $R = TP / (TP + FN)$
F1score	F1	É a média harmônica da precision e recall. $F1 = 2 \times (TP \times FP) / (TP + FP)$
Mean Average Precision	mAP mAP50 mAP75	O valor de mAP representa a área sob a curva Precision-Recall, que conecta os pares (Px; Ry) em um intervalo de 0 a 1. AP50 e AP75 referem-se ao valor fixado para o limiar <i>Intersection Over Union</i> – IoU, respectivamente, em 50% ou 75%. Nesse caso, mAP50 e mAP75 representam a média dos valores obtidos para cada dobra.
Mean Absolute Error	MAE	É a magnitude da diferença entre um valor esperado e um valor previsto. Como esse resultado pode ser positivo ou negativo, sugere-se usar a função matemática MAE para a média dos valores de erro absoluto sempre retorna valores positivos.
Root Mean Square Error	RMSE	É o desvio padrão das diferenças entre os valores previstos e os valores observados.
Correlação de Pearson	r	O coeficiente mostra a relação entre duas variáveis. Quando r é igual a zero, neste caso, não há correlação entre as variáveis. Quanto mais próximo o coeficiente estiver de 1 ou -1, mais forte será a relação. Se a correlação for negativa, a variável está influenciando a outra na direção oposta. Se for positiva, ambas as variáveis estão aumentando ou diminuindo na mesma direção.

* Verdadeiro positivo -TP; Falso positivo - FP; Verdadeiro negativo -TN; Falso positivo - FN.

Fonte: Elaborado pela autora.

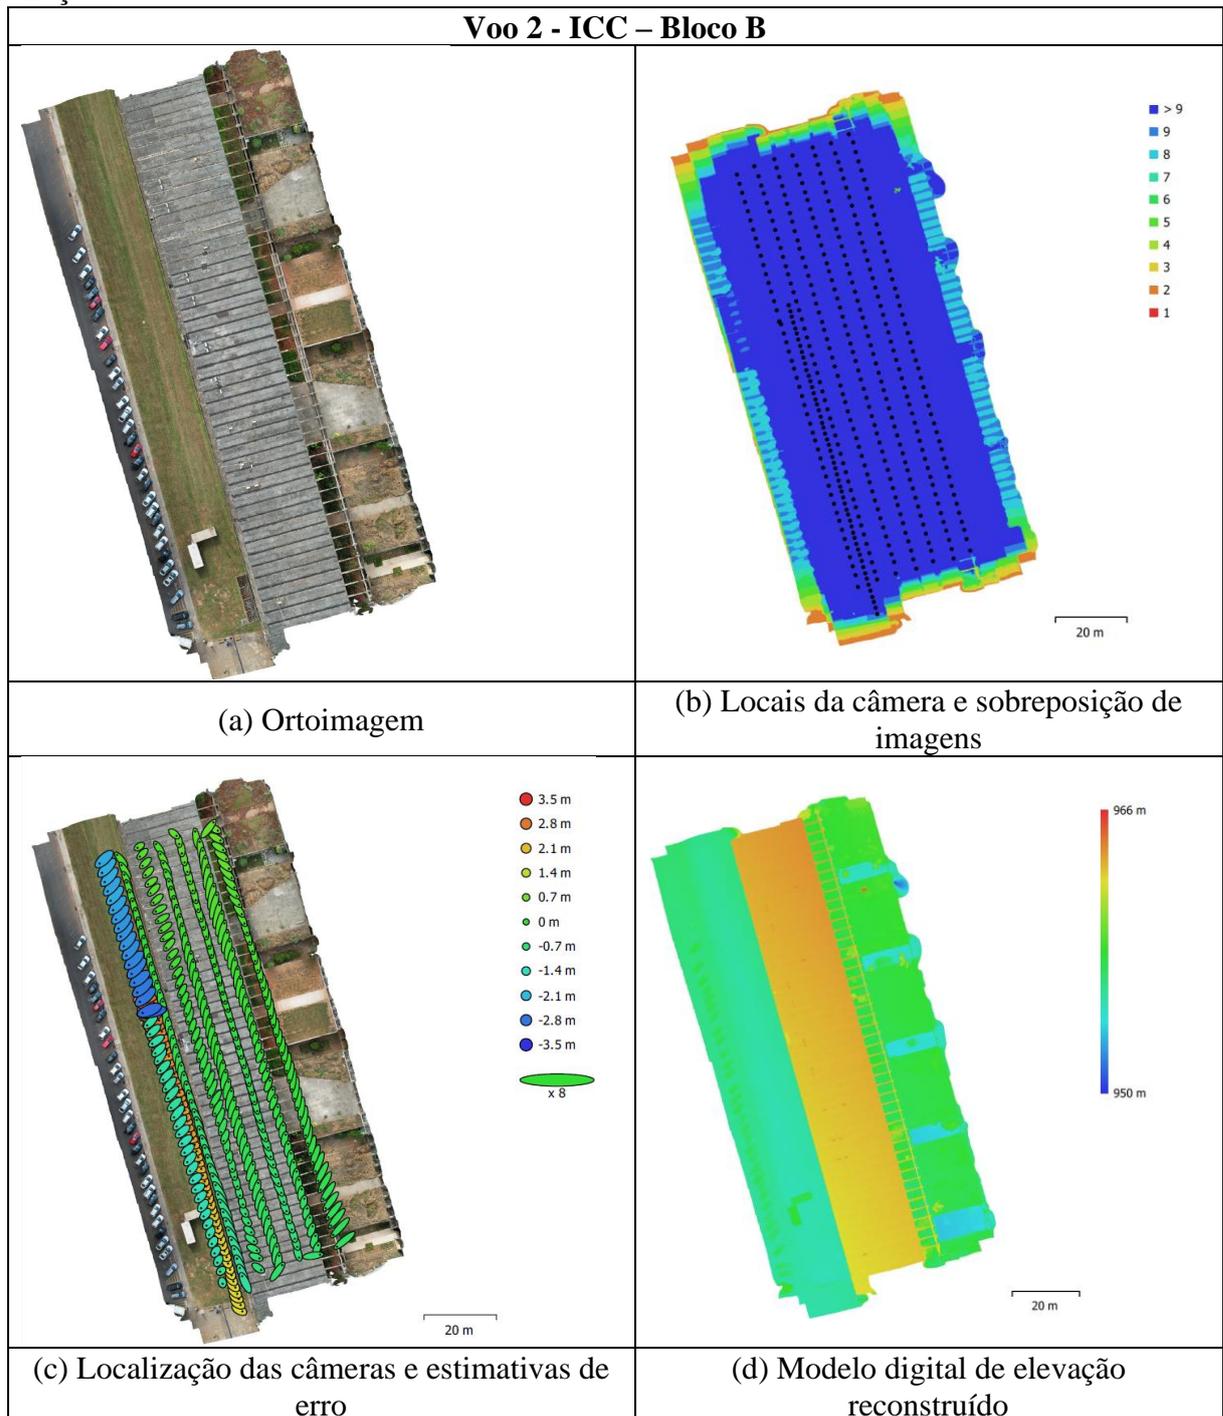
APÊNDICE D

Quadro 36 - Resultado do processamento do plano de voo 1 realizado no ICC – 14 metros – 1 direção.



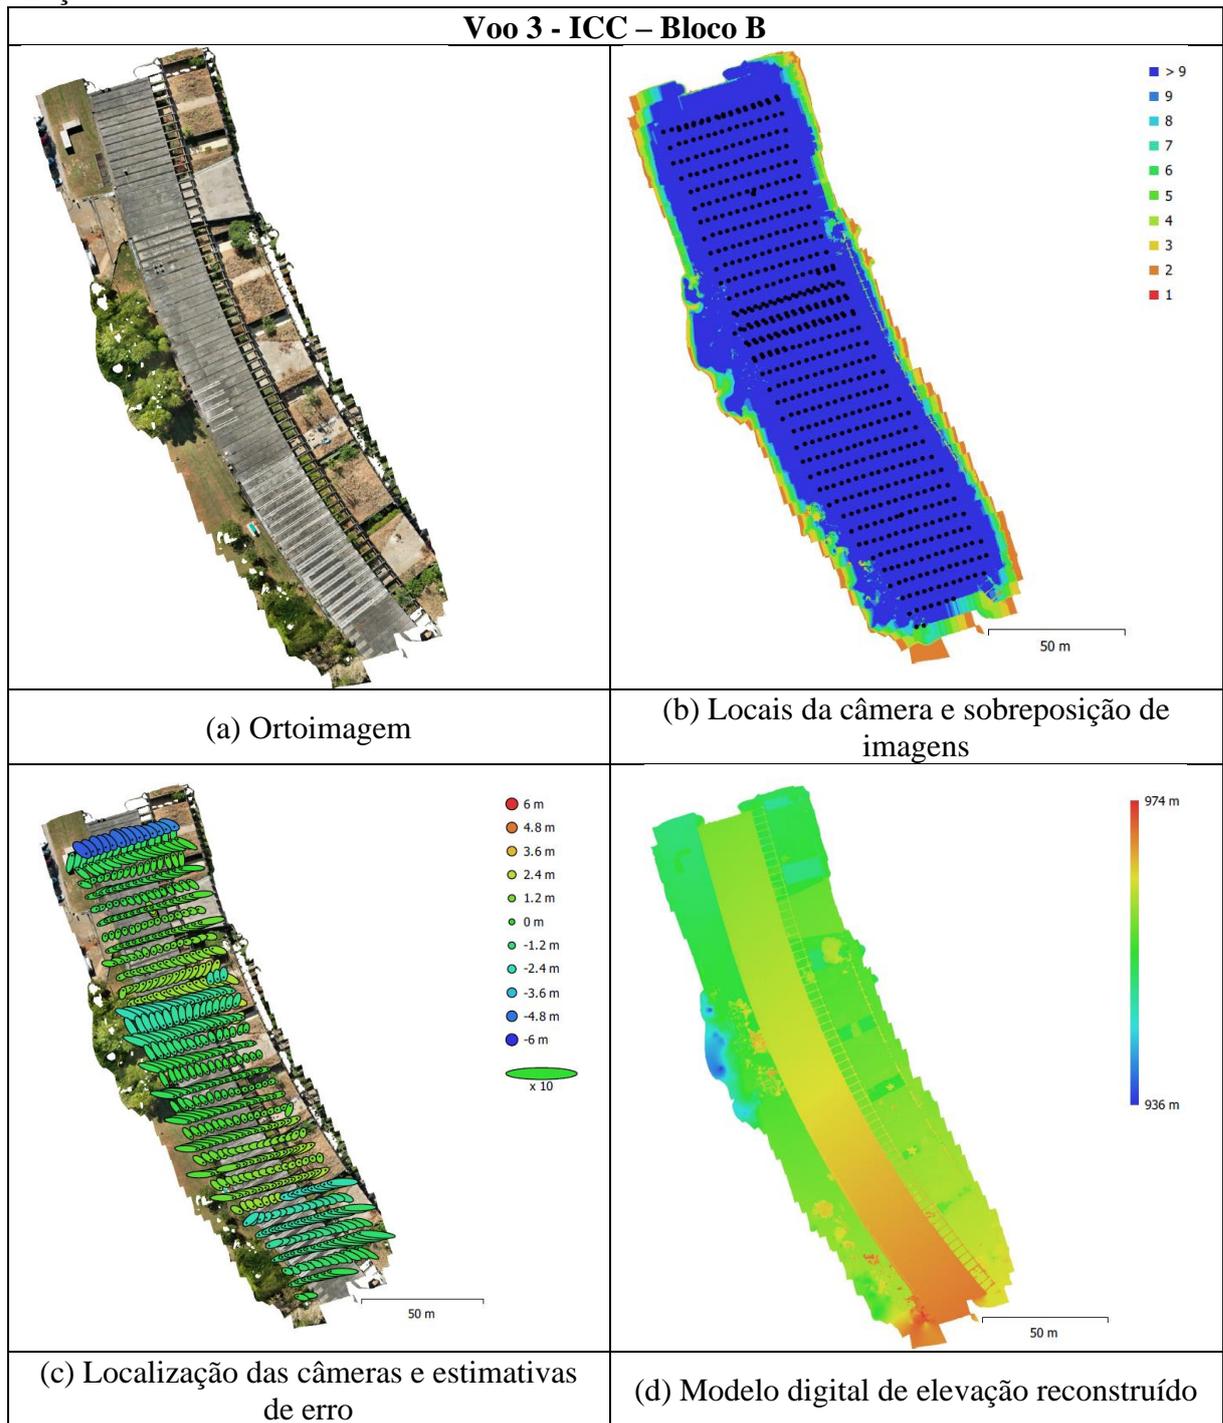
Fonte: Elaborado pela autora.

Quadro 37 - Resultado do processamento do plano de voo 2 realizado no ICC – 14 metros – 1 direção.



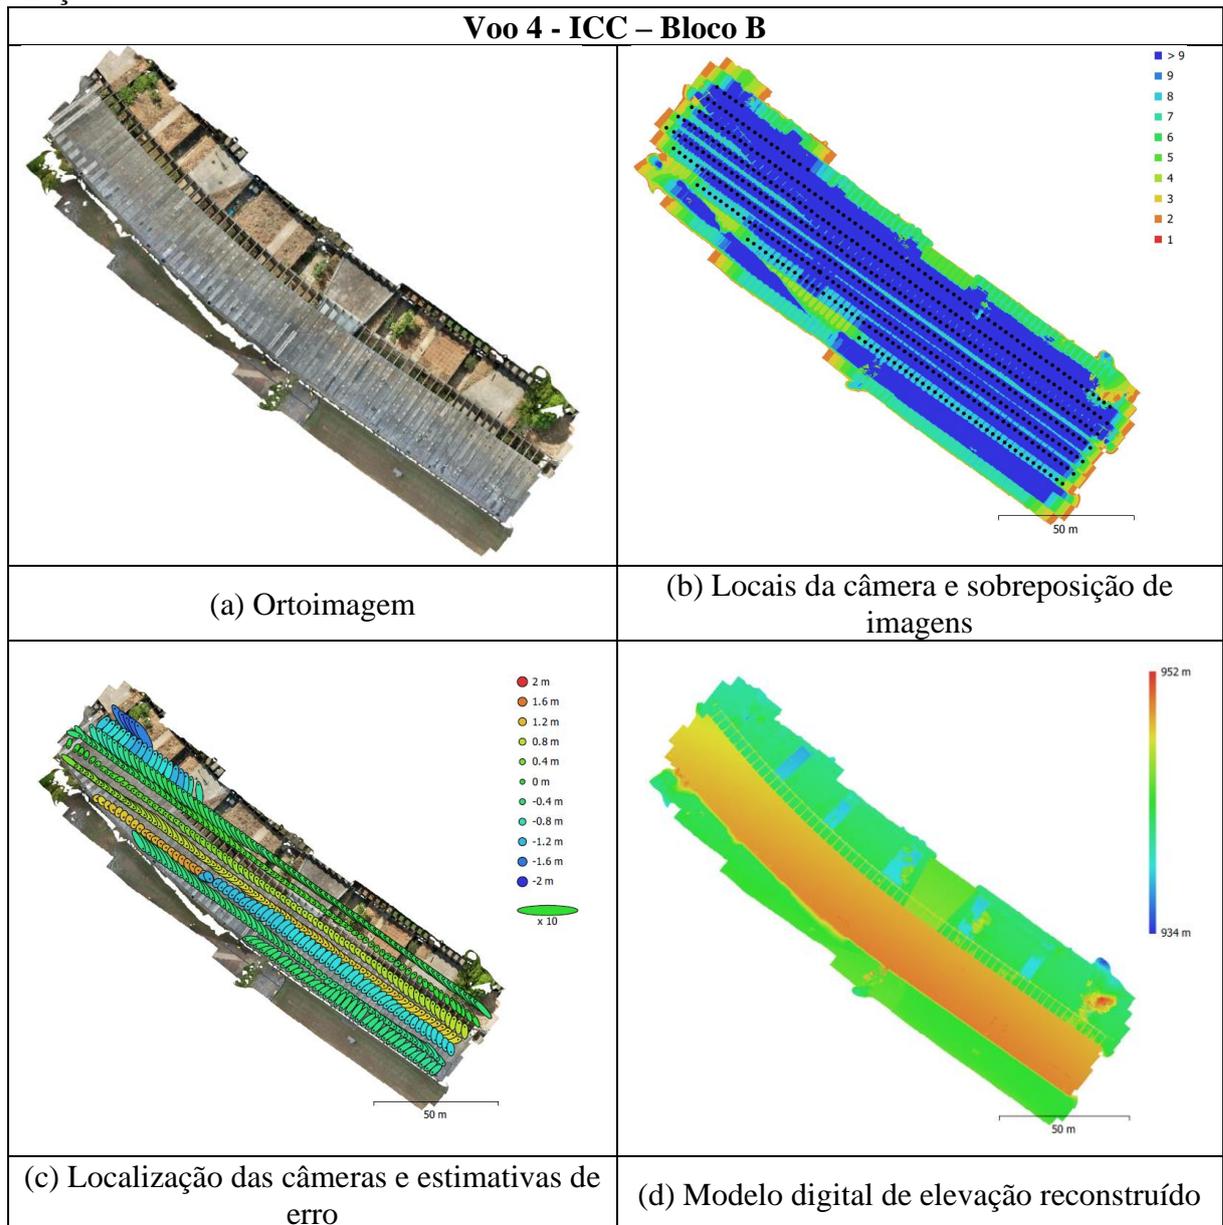
Fonte: Elaborado pela autora.

Quadro 38 - Resultado do processamento do plano de voo 3 realizado no ICC – 14 metros – 1 direção.



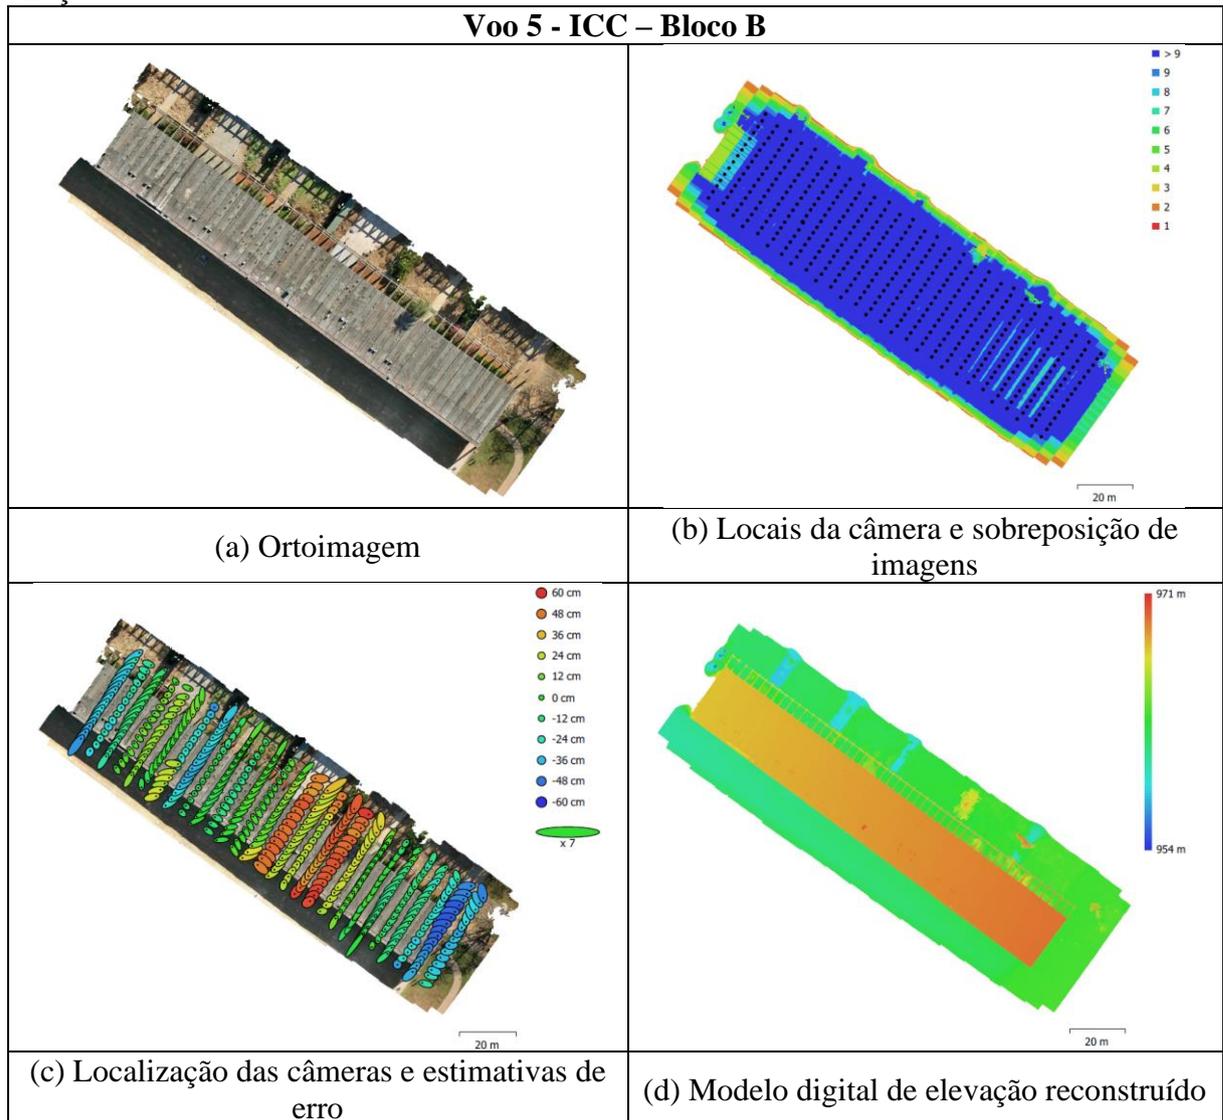
Fonte: Elaborado pela autora.

Quadro 39 - Resultado do processamento do plano de voo 4 realizado no ICC – 14 metros – 1 direção.



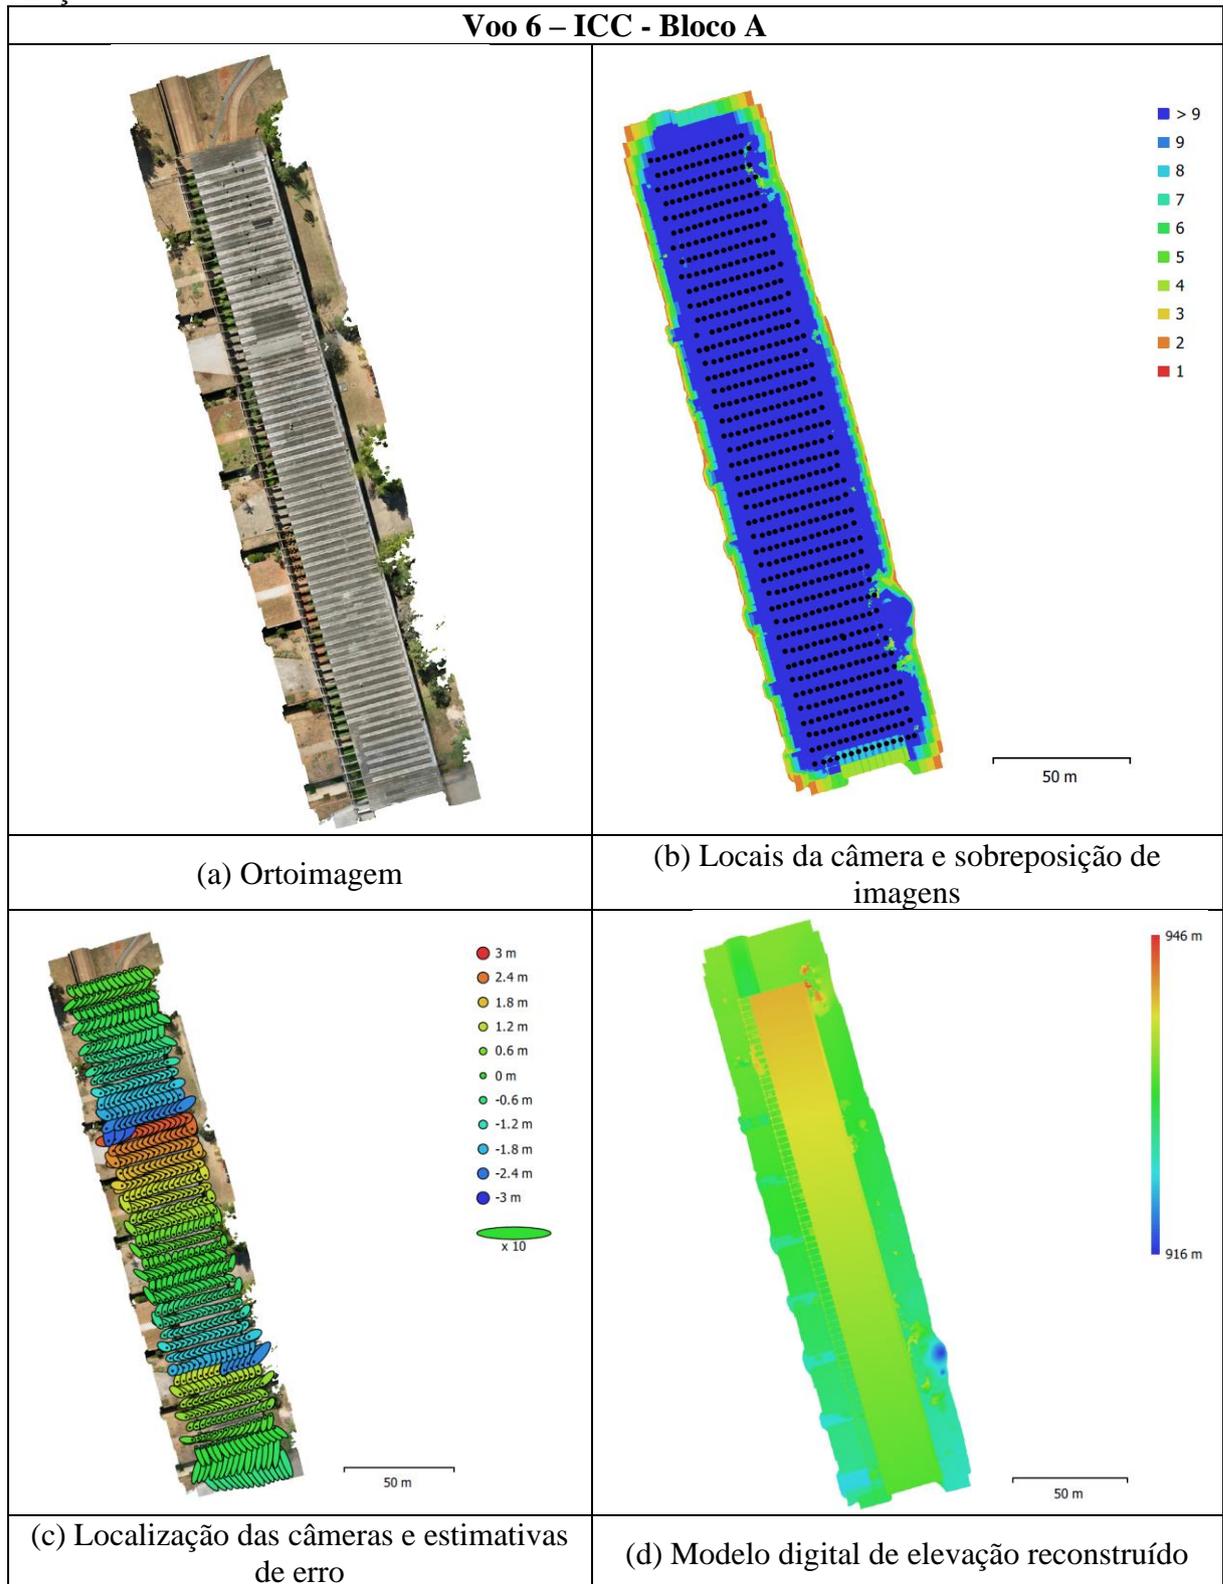
Fonte: Elaborado pela autora.

Quadro 40 - Resultado do processamento do plano de voo 5 realizado no ICC – 14 metros – 1 direção.



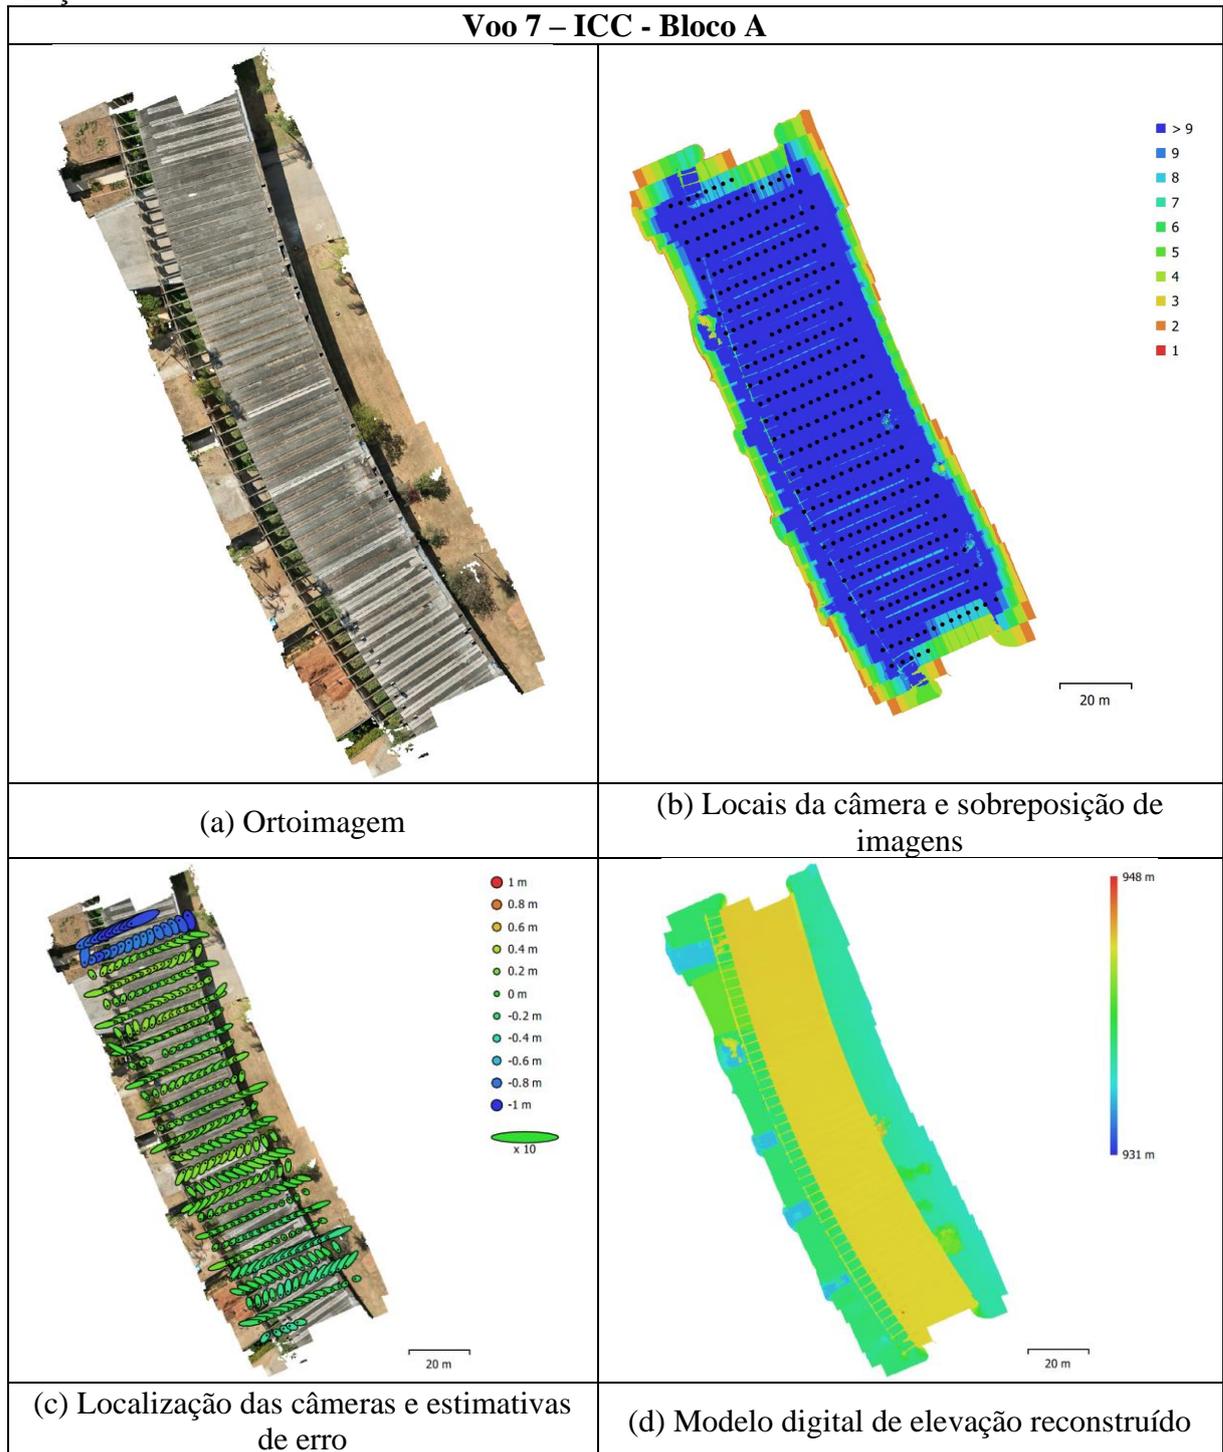
Fonte: Elaborado pela autora.

Quadro 41 - Resultado do processamento do plano de voo 6 realizado no ICC – 14 metros – 1 direção.



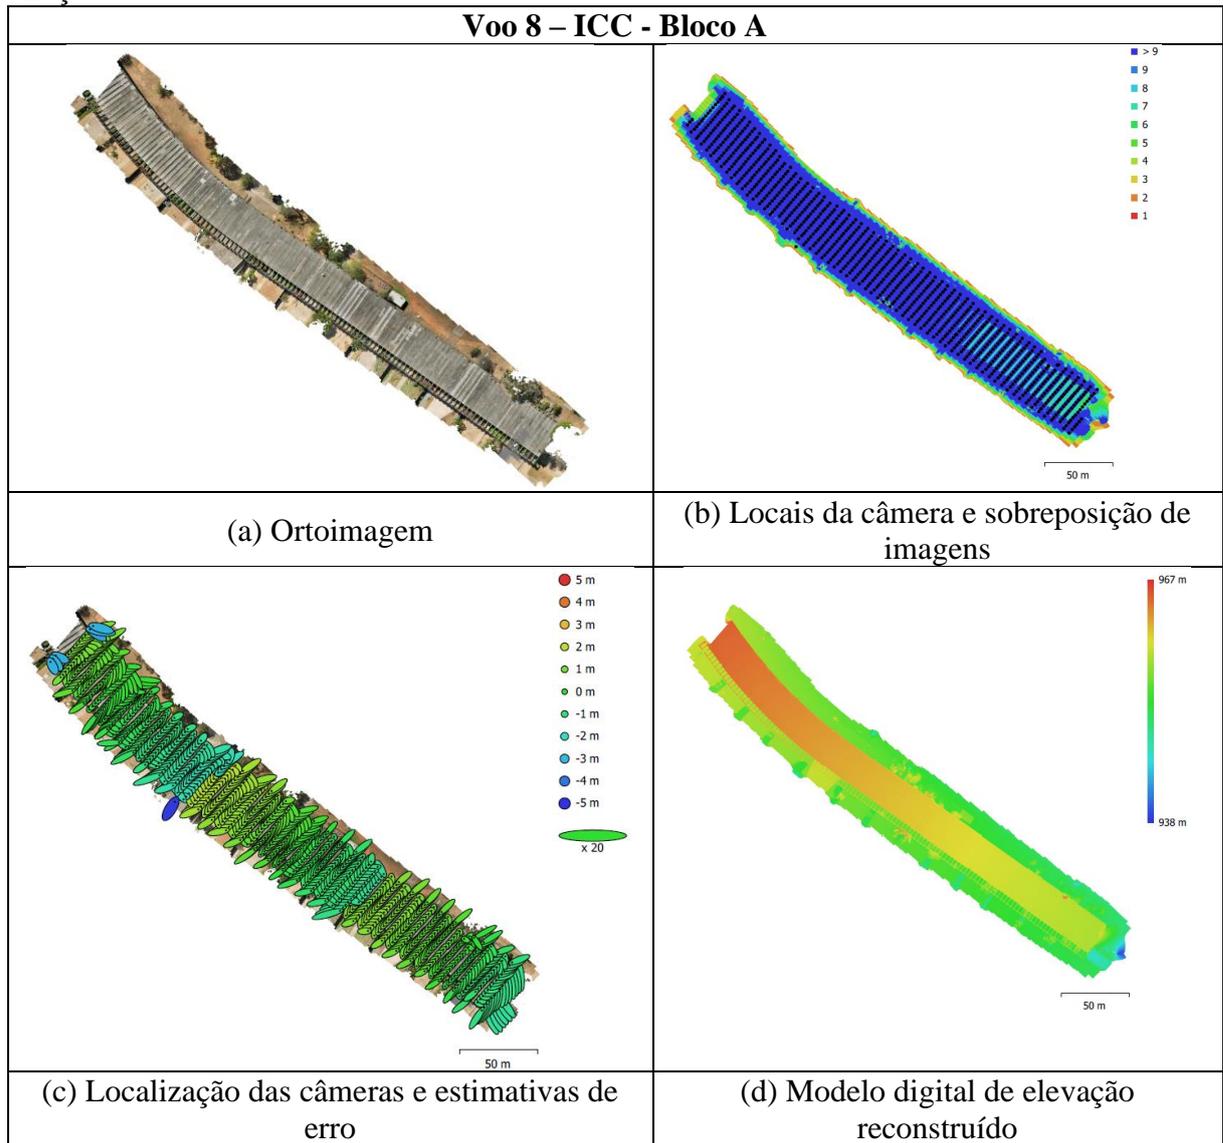
Fonte: Elaborado pela autora.

Quadro 42 - Resultado do processamento do plano de voo 7 realizado no ICC – 14 metros – 1 direção.



Fonte: Elaborado pela autora.

Quadro 43 - Resultado do processamento do plano de voo 8 realizado no ICC – 14 metros – 1 direção.



Fonte: Elaborado pela autora.

