

Controlo geométrico de precisão na montagem de estruturas metálicas com recurso a tecnologias digitais

JOÃO PEDRO SANTOS VENTURA
Outubro de 2024

**Controlo geométrico de precisão
na montagem de estruturas
metálicas com recurso a
tecnologias digitais**

João Pedro Santos Ventura

**Dissertação para obtenção do Grau de Mestre em
Engenharia Civil, Área de Especialização em
Estruturas**

Orientador: Prof. Diogo Ribeiro

Co-orientadores: Prof. Ricardo Santos e Prof. Maria do Rosário Oliveira

Júri:

Presidente:

Prof. Maria Rosário Oliveira

Vogais:

Prof. Luís Augusto Macedo

Prof. André Pinheiro Dias

“Tudo é ousado para quem nada se atreve.” – Fernando Pessoa

Resumo

A norma NP EN 1090-2:2020 estabelece requisitos para a execução de estruturas metálicas, ao oferecer diretrizes detalhadas para garantir uma execução correta, salvaguardando a integridade estrutural e a segurança da construção final. Com principal foco nas tolerâncias de montagem, a presente dissertação tem como principal objetivo apresentar uma metodologia automatizada para verificação de desvios geométricos em edifícios industriais metálicos utilizando tecnologias digitais e técnicas de inteligência artificial. As regras normativas são avaliadas usando dados de nuvens de pontos derivados de modelos digitais 3D de uma estrutura, como o modelo *As-Is* e o modelo *As-Design*. O modelo *As-Is* é obtido através da integração de fotogrametria e *laser scanner* terrestre, enquanto o modelo *As-Design* é adquirido a partir do modelo estrutural do projeto. O aspecto inovador desta metodologia assenta na aplicação do algoritmo YOLOv8 para identificar automaticamente a secção transversal de elementos estruturais utilizando técnicas de segmentação por instâncias e *Oriented Bounding Box (OBB)*. Os desvios geométricos entre os dois modelos são calculados e analisados para garantir o cumprimento das regras normativas estabelecidas pela NP EN 1090-2:2020. Os resultados deste estudo indicaram que a metodologia proposta é robusta o suficiente para ser aplicada em qualquer tipo de estrutura de aço, independentemente da sua complexidade.

Palavras-chave: EN 1090-2; OBB; Fotogrametria; LiDAR; TLS; YOLOv8.

Abstract

The quality requirements of metallic structures are established by EN 1090-2:2020, which provides detailed guidelines to ensure proper execution, thereby safeguarding the structural integrity and safety of the final construction. With the focus on assembly rules, the main objective of this dissertation is to present an automated methodology for verifying geometric deviations in metallic industrial buildings using digital technologies and artificial intelligence techniques. The normative rules are evaluated using point cloud data derived from 3D digital models of an asset, the “As-Is” and “As-Design” models. The “As-Is” model is obtained through the integration of photogrammetry and Terrestrial Laser Scanning, while the “As-Design” model is acquired from the project’s structural model. The innovative aspect of this methodology is based on the application of the YOLOv8 algorithm to automatically identify the cross-section of structural elements using instance segmentation and “Oriented Bounding Box” (OBB) techniques. Geometric deviations between the two models are computed and analysed to ensure that normative rules established by EN 1090-2:2020 are accomplished. The results of this study indicated that the current methodology is robust enough to be applied on any type of steel structure, even the most complex ones.

Keywords: EN 1090-2; OBB; Photogrammetry; LiDAR; TLS; YOLOv8,

Agradecimentos

A conclusão deste trabalho traz-me um profundo sentimento de realização. Finalizo esta etapa com a certeza de que, apesar dos desafios, mantive sempre o foco. Deixo aqui o meu sincero agradecimento a todas as pessoas que, de alguma forma, contribuíram para o sucesso deste percurso.

Agradeço ao Professor Diogo Ribeiro, meu orientador, pelo apoio incansável. A sua exigência, rigor e conhecimento foram fundamentais para o meu desenvolvimento e para garantir a qualidade do projeto em cada etapa.

Agradeço ao Professor Ricardo Santos e à Professora Maria do Rosário pelo acompanhamento constante ao longo de todo o projeto. A vossa disponibilidade e orientação ajudaram-me a superar desafios e a encontrar soluções para os problemas que surgiram ao longo do caminho.

Agradeço à equipa da JF Metal, incluindo o Engenheiros Marcos Lima e Luís Costa, pelo apoio técnico, pelo conhecimento partilhado e pelo tempo dedicado, que foram cruciais para a concretização de vários aspetos práticos do projeto.

Ao projeto I&D Check Metallic, expresso o meu agradecimento pela oportunidade da bolsa de investigação e por todo o suporte.

Aos Professores Rodrigo Falcão Moreira e António Pestana, o meu sincero agradecimento pela vossa disponibilidade e pelas contribuições e sugestões que realizaram ao longo deste projeto.

Aos Engenheiros Rui Gavina e Vítor Carvalho, expresso a minha gratidão pelas valiosas trocas de ideias que foram essenciais para a evolução deste projeto.

Aos investigadores do DEC-ISEP — Jorge Magalhães, Tomás Jorge, Pedro Oliveira e Francisco Andrade — agradeço pela paciência, compreensão e amizade ao longo do projeto. O vosso espírito de entreajuda foi essencial para ultrapassar os desafios e garantir o meu progresso.

Aos restantes colaboradores, Óscar Moreira e Rafael Cabral, o meu sincero obrigado.

Aos meus amigos Tiago Martins, Diogo Castro, Filipe Cardoso, Pedro Rodrigues e Rui Amaro.

À minha namorada, Amy Santos, quero expressar o meu agradecimento. Nos momentos de maior *stress* e ansiedade, foste a minha âncora, o meu porto seguro.

Por fim, aos meus pais, Delfim Ventura e Rosa Santos, e aos meus avós, Mário Ferreira e Rosa Silva, o meu mais sincero obrigado. Sem o vosso suporte, nada disto teria sido possível.

Índice de texto

1	Introdução.....	1
1.1	Considerações iniciais	1
1.2	Objetivos.....	2
1.3	Estrutura do documento.....	3
2	Estado da arte	5
2.1	Estruturas metálicas	5
2.1.1	Montagem	6
2.1.2	Desvios geométricos e controlo de qualidade	8
2.2	Tecnologias digitais aplicadas à AEC.....	10
2.2.1	Fotogrametria.....	11
2.2.1.1	Plataforma UAV.....	12
2.2.1.2	Técnicas e boas práticas.....	14
2.2.1.3	Processamento de dados	15
2.2.2	LiDAR.....	19
2.2.2.1	<i>Terrestrial Laser Scanner</i> (TLS)	20
2.2.2.2	Princípio de funcionamento e equipamentos.....	20
2.2.2.3	Técnicas e boas práticas.....	22
2.2.2.4	Processamento de dados	23
2.2.3	Técnicas de fusão e alinhamento de dados.....	25
2.3	Inteligência artificial.....	29
2.3.1	Enquadramento.....	29
2.3.2	Redes neuronais	33

2.3.3	Redes Neurais Convolucionais (CNN)	35
2.3.4	Deteção e segmentação em imagens com o YOLO	39
2.3.5	Métricas de avaliação dos modelos.....	49
3	Metodologia para identificação de desvios geométricos	51
3.1	Enquadramento	51
3.2	Aquisição e processamento de dados.....	53
3.2.1	Fotogrametria com UAV	53
3.2.2	Fotogrametria terrestre.....	55
3.2.3	<i>LiDAR</i>	55
3.2.4	Fusão de dados	57
3.3	Extração de características do modelo	58
3.4	Algoritmo de extração de secções transversais.....	61
3.5	Modelo IA YOLOv8	64
3.5.1	<i>Dataset</i>	65
3.5.2	Preparação de dados no <i>Roboflow</i>	66
3.5.3	Treino do modelo YOLOv8-SEG	67
3.5.4	Validação das métricas	69
3.6	Processamento de imagem.....	72
3.7	Validação com a norma NP EN 1090-2:2020	74
3.7.1	Inclinação de colunas de edifícios com um só andar.....	76
3.7.2	Retilinearidade de colunas de um só andar	78
3.7.3	Posicionamento em planta dos pilares.....	79
4	Caso de estudo	81
4.1	Enquadramento	81
4.2	Memória descritiva do projeto	82
4.3	Aquisição e processamento de dados.....	85
4.3.1	Fotogrametria com UAV	85

ÍNDICE DE TEXTO

4.3.2	LiDAR.....	87
4.3.3	Fusão das nuvens de pontos	90
4.3.4	Modelo As-Design.....	90
4.4	Alinhamento dos modelos <i>As-Is</i> e <i>As-Design</i>	91
4.5	Resultados obtidos.....	93
4.5.1	Inclinação de colunas de edifícios com um só andar	94
4.5.2	Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas	95
4.5.3	Retilinearidade de colunas de um só andar	96
4.5.4	Posicionamento em planta dos pilares	97
5	Considerações finais.....	99
5.1	Conclusões	99
5.2	Desenvolvimentos futuros.....	101
	Referências bibliográficas.....	103
	Anexos	109

Índice de figuras

Figura 1: Estrutura industrial metálica (retirado de www.servicesteel.org).....	6
Figura 2: Funcionamento conjunto de tecnologias digitais.	11
Figura 3: DJI Mavic 3 Enterprise Series com o módulo RTK e câmara com 20MPx (retirado de https://enterprise.dji.com).	13
Figura 4: Esquematização dos parâmetros da câmara (adaptado de Alshawabkeh et al., (2023)).	14
Figura 5: Variação dos Ground Sampling Distance (GSD) com a variação da altura do UAV (adaptado de Wingtra, (2019)).	15
Figura 6: Fluxograma de processamento de dados fotogramétricos.	15
Figura 7: Aquisição de imagens do objeto de diversas perspectivas e ângulos (adaptado Galanakis et al., (2021)).	16
Figura 8: Esquematização SfM e extração de características com SIFT. a) Posicionamento da câmara no instante da captura ((adaptado de van Riel, (2016)); b) Exemplo de nuvem esparsa criada pela técnica SfM (adaptado de Cao et al., (2023)).	17
Figura 9: Processamento fotogramétrico: a) aquisição de imagens; b) reconstrução tridimensional (SfM); c) densificação após a aplicação da metodologia MVS (disponível em: github.com).	18
Figura 10: Criação da malha com textura, recriando um modelo mais realista (disponível em: github.com).	19
Figura 11: Princípio de funcionamento de um <i>laser scanner</i> (adaptado de Zheng et al., (2019)).....	21
Figura 12: BLK 360 G1 (disponível em: leica-geosystems.com).	21
Figura 13: Faro Focus 3D X330. (disponível em: www.faro.com).	21
Figura 14: Exemplos de alvos para auxiliar o varrimento a laser (adaptado de Tang et al., (2020)).	22
Figura 15: Fluxograma a descrever as etapas de processamento de dados LiDAR.	23
Figura 16: Processo de alinhamento entre duas estações no <i>Cyclone REGISTER 360</i> . a) nuvens aleatoriamente espaçadas. b) alinhamento das duas nuvens.....	24

Figura 17: Método gráfico para localizar o centro geométrico de duas nuvens de pontos (adaptado de Cao et al., (2023)).	26
Figura 18: Resultado do alinhamento pelo algoritmo iterativo ICP (adaptado de Cao et al., (2023)).	26
Figura 19: Diagramas conceituais das técnicas C2C e M3C2. a) Técnica C2C, onde as menores distâncias $LC2C$ entre Ca e Mb são calculadas e armazenadas. b) Técnica M3C2, é estimada a normal do ponto i e um cilindro com diâmetro d é utilizado para selecionar pontos em Ca e Cb . A distância $LM3C2$ entre dois pontos é medida ao longo da sua normal e armazenada (adaptado Barnhart et al., (2013)).	27
Figura 20: a) Exemplo de teste segmentação RANSAC para dados fotogramétrico; b) Teste de segmentação para dados TLS (adaptado de Bouziani et al., (2021)).	28
Figura 21: Exemplificação da distância de <i>Hausdorff</i> entre dois conjuntos de pontos. a) Conjuntos de pontos A e B; b) Cálculo da distância euclidiana de cada ponto do conjunto A para o ponto mais próximo no conjunto B; c) Cálculo da distância euclidiana de cada ponto do conjunto B para o ponto mais próximo no conjunto A; d) Distâncias máximas entre os dois conjuntos; e) Distância de <i>Hausdorff</i> definida como a maior dessas distâncias mínimas (adaptado de Charbonnier et al., (2013)).	29
Figura 22: Inteligência Artificial, Machine Learning e Deep Learning (adaptado de Balodi, (2020)).	31
Figura 23: Exemplo da arquitetura de uma rede neuronal artificial profunda (adaptado de (Yao et al., 2021)).	33
Figura 24: Modelo não-linear de um neurónio artificial (adaptado de Haykin, (2009)).	34
Figura 25: Diagrama esquemático de uma arquitetura básica de rede neuronal convolucional (CNN) (adaptado de Phung et al., (2019)).	36
Figura 26: Pipeline da arquitetura CrackNet2 para a detecção de fissuras. a) Imagem original; b) resultados após o primeiro de dois passos de pré-classificação; c) Resultados da segmentação por blocos; d) Resultados da detecção de curvas de fissuras (adaptado de Zhang et al., (2018)).	37
Figura 27: Operação de convolução com aplicação de filtro (3x3) (adaptado de Cha et al., (2024)).	38
Figura 28: Exemplo de atuação de uma camada max pooling (adaptado de Almeida et al., (2020)).	39
Figura 29: Modelo de detecção YOLO composto por <i>backbone</i> , <i>neck</i> , <i>head</i> (adaptado de Kateb et al., (2021)).	40
Figura 30: Segmentação com o YOLOv8-CM. a) Imagem original; b) Imagem inferida com o YOLOv8-CM; c) Destaque dos resultados da máscara.	41

Figura 31: Processo de engenharia reversa de uma distribuição de densidade otimizada como uma abordagem de segmentação de instâncias (adaptado de Rochefort-Beaudoin et al., (2024)).	42
Figura 32: Exemplo de inferência para detecção de corrosão com o YOLOv8-SEG. a) imagem original; b) máscara gerado pelo modelo com grau de confiança 95%. (adaptado de Casas et al., (2024)).	43
Figura 33: Exemplo de segmentação de uma fissura com o YOLOv8-SEG. a) Imagem original; b) imagem em verdadeira grandeza; c) resultado da inferência com máscara a vermelho (adaptado de Wu et al., (2023)).	43
Figura 34: Exemplos de descontinuidade em OBBs. a) Descontinuidade de rotação; b) Descontinuidade da proporção de aspeto; c) <i>Decoding incompleteness</i> ; d) <i>Decoding ambiguity</i> (adaptado de Xiao et al., (2024)).	45
Figura 35: Esquematização do método COBB em comparação com HBB do objeto. a) Parâmetros base da OBB para um exemplo em que $w > h$; b) Quatro configurações candidatas para a OBB do objeto e respectivos <i>scores</i> IoU (adaptado de Xiao et al., (2024)).	46
Figura 36: Processo de regressão baseado no método <i>Bounding Box Vectorization</i> (adaptado de Wang et al., (2024)).	47
Figura 37: Demonstração da rotação dos mapas de características conforme os ângulos de rotação (adaptado de Zhou et al., (2024)).	48
Figura 38: Transformação de uma Oriented Bounding Box (OBB) numa Linear Gaussian Bounding Box (LGBB) com recurso a mapeamento Gaussiano (adaptado de Zhou et al., (2024)).	48
Figura 39: Fluxograma geral da metodologia para identificação de desvios geométricos.	51
Figura 40: Estrutura de estudo – Edifício J – ISEP.	52
Figura 41: Estrutura de estudo localizada na Rua da Estação – Maia.	52
Figura 42: Fluxograma com o processamento de dados fotogramétricos e <i>LiDAR</i> .	53
Figura 43: Modelo 1 fotogramétrico em nuvem de pontos.	54
Figura 44: Modelo 2 fotogramétrico em nuvem de pontos.	54
Figura 45: Levantamento fotogramétrico terrestre da estrutura metálica na Maia.	55
Figura 46: Esquema do posicionamento ideal das estações no levantamento.	56
Figura 47: Modelo <i>LiDAR</i> em nuvem de pontos.	56
Figura 48: Modelo fusão <i>LiDAR</i> e fotogrametria em nuvem de pontos (verde– nuvem <i>LiDAR</i> , azul – Fotogrametria).	57

Figura 49: Fluxograma da extração de <i>wireframe</i> do modelo <i>As-Design</i>	58
Figura 50: <i>Wireframe</i> da estrutura exportado do <i>Blender</i> , com a respetiva numeração dos elementos. 59	
Figura 51: Modelo <i>As-Is</i> LiDAR alinhado com o modelo <i>As-Design</i> (cor azul modelo LiDAR; cor cinzenta modelo <i>As-Design</i> ; cor verde e laranja na extremidade significa que um dos modelos, neste caso, o modelo <i>As-Design</i> não tem qualquer tipo de pontos correspondentes nessa região).	60
Figura 52: Fluxograma do algoritmo criado para extrair secções transversais de cada membro de uma estrutura.....	62
Figura 53: Visualização da nuvem de pontos LiDAR em conjunto com planos perpendiculares de segmentação. a) Modelo TLS; b) Modelo 2 fotogramétrico com UAV; c) Modelo fusão; d) Modelo fotogramétrico terrestre.....	64
Figura 54: Fluxograma do processo de implementação de modelos de IA com o YOLOv8.	65
Figura 55: Exemplos de <i>dataset</i> baseados no Modelo <i>As-Is</i> . a) Corte basal do pilar com detalhes da ligação aparafusada; b) Imagem real; c) Imagem processada com <i>voxel downsampling</i> igual a 0,01; d) Imagem processada com <i>voxel downsampling</i> igual a 0,02.	66
Figura 56: Imagens artificiais e exemplos de aumentações criadas. a) Imagem original; b) Ruído aleatório; c) Rotação; d) <i>Partial dropout</i>	66
Figura 57: Processo de anotação de uma imagem. a) Imagem original, perfil HEA 160. b) <i>Polygonal line</i> a contornar a secção transversal; c) <i>Mask</i>	67
Figura 58 Exemplos de inferências realizadas pelo modelo desenvolvido. a) Imagem artificial com o perfil HEA200; b) Imagem real com o perfil HEA120;c) Imagem artificial com o perfil IPE270; d) Imagem artificial com <i>data augmentation</i> do perfil IPE200.....	68
Figura 59: Matriz de confusão de teste do modelo.	70
Figura 60:Gráficos de perdas ao longo das <i>epochs</i> de treino e validação. a) Curva de perdas associada à predição das <i>bounding boxes</i> durante o treino; b) Curva de perdas de segmentação durante o treino; c) Curva de perdas das <i>bounding boxes</i> durante a validação; d) Curva de perdas de segmentação durante a validação.	71
Figura 61: Fluxograma do algoritmo de processamento da imagem.....	72
Figura 62: Processo de filtragem de imagens obtidas pelo YOLOv8. a) Imagem real; b) <i>Mask</i> de segmentação; c) Imagem filtrada.....	73

Figura 63: Exemplos de OBBs obtidas após o processamento das imagens. a) OBB de uma imagem real representando o perfil HEA160, obtido por tecnologia LiDAR; b) OBB de uma imagem artificial do perfil HEA260; c) OBB de uma imagem artificial representando o perfil IPE140.	73
Figura 64: Exemplo de extração dos desvios geométricos entre as OBB de cada modelo.	74
Figura 65: Representação comparativa para o Quadro B.17-1 da norma, modelo <i>As-Is</i> (a azul) e modelo <i>As-Design</i> (a vermelho). a) Elemento 1; b) Elemento 2; c) Elemento 3; d) Elemento 4.	77
Figura 66: Representação comparativa para o Quadro B.17-5 da norma, modelo <i>As-Is</i> (a azul) e modelo <i>As-Design</i> (a vermelho). a) Elemento 1; b) Elemento 2; c) Elemento 3; d) Elemento 4.	79
Figura 67: Representação comparativa para o Quadro B.20-1 da norma. a) Elemento 1; b) Elemento 2; c) Elemento 3; d) Elemento 4.	80
Figura 68: Edifício industrial em Travanca, Amarante, Portugal.	82
Figura 69: Modelo 3D <i>As-Design</i> (retirado de Blender).	82
Figura 70: Representação do alçado das naves do caso de estudo.	83
Figura 71: Planta do caso de estudo com a representação dos pórticos do caso de estudo. a) Disposição em planta dos pilares; b) Disposição em planta das vigas.	83
Figura 72: Nuvem esparsa com filtro de elevação, obtida após o alinhamento das imagens.	86
Figura 73: Modelo 3D fotogramétrico do caso de estudo em Amarante.	87
Figura 74: Dados obtidos após o processamento de dados no <i>software Cyclone REGISTER 360</i> . a) Posicionamento das estações BLK durante o levantamento e respetivos <i>links</i> ; b) Posicionamento dos GCP e respetivas marcações a cor roxo desde cada estação.	88
Figura 75: Métricas de erro obtidas para o <i>bundle</i>	89
Figura 76: Modelo 3D LiDAR do caso de estudo em Amarante.	89
Figura 77: Fusão das nuvens de pontos (cor verde – fotogrametria, vermelho – LiDAR).	90
Figura 78: Representação do <i>wireframe</i> do caso de estudo em Amarante.	91
Figura 79: Metodologia aplicada a quatro exemplos reais P.132 (IPE270), P.110 (HEA160), P.091 (IPE240) e P.127 (HEA200), respetivamente.	94

Lista de tabelas

Tabela 1: Métricas gerais calculadas com base nos modelos LiDAR e <i>As-Design</i> após o alinhamento ICP.	60
Tabela 2: Métricas C2C entre o modelo <i>As-Design</i> e o modelo LiDAR	61
Tabela 3: Performance do modelo para as principais métricas de validação.....	69
Tabela 4: Tolerâncias de montagem definidas pelos quadros B.17 e B.20 na NP EN 1090-2:2020.....	75
Tabela 5: Resultados obtidos para o Quadro B.17-1 da NP EN 1090-2:2020	76
Tabela 6: Resultados obtidos para o Quadro B.17-5 da NP EN 1090-2:2020	78
Tabela 7: Resultados obtidos para o Quadro B.20-1 da NP EN 1090-2:2020	79
Tabela 8: Memória descritiva da nave 3	84
Tabela 9: Memória descritiva da nave 4	84
Tabela 10: Métricas gerais calculadas com base nos modelos <i>As-Is</i> e <i>As-Design</i> após o alinhamento ICP.	92
Tabela 11: Métricas C2C entre o modelo <i>As-Is</i> e o modelo <i>As-Design</i>	92
Tabela 12: Resultados obtidos para o Quadro B.17-1 – Inclinação de colunas de edifícios com um só andar da NP EN 1090-2:2020	95
Tabela 13: Resultados obtidos para o Quadro B.17-2 – Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas da NP EN 1090-2:2020	96
Tabela 14: Resultados obtidos para o Quadro B.17-5 – Retilinearidade de colunas de um só andar da NP EN 1090-2:2020	96
Tabela 15: Resultados obtidos para o Quadro B.20-1 – Posicionamento em planta dos pilares da NP EN 1090-	97
Tabela 16: Memória descritiva da nave 3 (continuação).....	109
Tabela 17: Memória descritiva da nave 4 (continuação).....	110

Tabela 18: Resultados obtidos para o Quadro B.17-1 – Inclinação de colunas de edifícios com um só andar da NP EN 1090-2:2020 (continuação).....	112
Tabela 19: Resultados obtidos para o Quadro B.17-2 – Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas da NP EN 1090-2:2020 (continuação).	113
Tabela 20: Resultados obtidos para o Quadro B.17-5 – Retilinearidade de colunas de um só andar da NP EN 1090-2:2020 (continuação).....	114
Tabela 21: Resultados obtidos para o Quadro B.20-1 – Posicionamento em planta dos pilares da NP EN 1090-2:2020 (continuação).	115

1 Introdução

1.1 Considerações iniciais

Nos últimos anos, a Construção 4.0 tem revolucionado profundamente o setor da Arquitetura, Engenharia e Construção (AEC), impulsionando uma nova era de automatização e digitalização. A integração de tecnologias emergentes, como as ferramentas digitais e a Inteligência Artificial (IA), permitiu o desenvolvimento de metodologias capazes de otimizar processos que, até há bem pouco tempo, eram difíceis de serem resolvidos eficientemente. Com o desenvolvimento da digitalização, surgem novas oportunidades para aplicar essas tecnologias em tarefas críticas da construção, como, por exemplo, a montagem de estruturas metálicas. A existência de desvios geométricos neste tipo de estruturas, ainda que mínimos, são comuns e podem comprometer a integridade e segurança da estrutura. Nesse contexto, a norma NP EN 1090-2:2020 estabelece requisitos técnicos para a execução de projetos de estruturas de aço, incluindo as tolerâncias de montagem admissíveis para os diversos elementos estruturais. De forma a avaliar o cumprimento destes requisitos, a presente dissertação insere-se no âmbito do projeto I&D CHECK METALLIC, em parceria com a empresa JF Metal, focando-se na elaboração de uma metodologia capaz de executar automaticamente a verificação de alguns critérios exigidos pela norma referida.

A aquisição e processamento de dados é fundamental para o sucesso de qualquer metodologia, uma vez que a qualidade dos dados recolhidos e o posterior tratamento influenciam diretamente a precisão dos resultados obtidos. No presente contexto, para enfrentar a complexidade dos projetos de estruturas metálicas, torna-se imprescindível recorrer a tecnologias emergentes que permitam controlar desvios geométricos de forma eficaz e correta. A utilização de tecnologias como o LiDAR (*Light Detection and Ranging*) e a fotogrametria têm-se destacado como alternativas superiores às ferramentas manuais tradicionais, possibilitando medições precisas, assim como os modelos digitais 3D detalhados da estrutura. Para o uso da

tecnologia LiDAR, é necessário definir cuidadosamente a posição das estações de levantamento para garantir que toda a geometria do elemento seja adquirida sem problemas de sombras e oclusões. O modelo 3D obtido será tanto mais detalhado quanto maior for o número de estações utilizadas para o levantamento; no entanto, o número de estações está intrinsecamente ligado aos requisitos computacionais de processamento. Relativamente à fotogrametria, o modelo 3D resultante depende diretamente da sobreposição das imagens capturadas de diferentes ângulos, o que significa que os modelos são mais precisos e realistas quanto maior for o número de imagens capturadas e o grau de sobreposição entre elas. Além disso, fatores como o local, a hora do levantamento e as condições atmosféricas devem ser previamente planeados e inspecionados, já que condicionam a qualidade do levantamento realizado em campo. A agregação dos modelos adquiridos por cada metodologia corresponde ao modelo *As-Is*, que representa com rigor o estado real da estrutura, oferecendo a oportunidade de realizar comparações e análises precisas em relação ao modelo 3D do projeto, definido como modelo *As-Design*. A correta comparação entre estes dois modelos permite detetar e localizar desvios milimétricos que, de outra forma, seriam impossíveis de detetar.

De forma a otimizar o processo de identificação dos desvios, a metodologia proposta neste trabalho faz uso de IA, em particular do algoritmo YOLOv8, que automatiza a deteção, através de uma *bounding box*, e a segmentação, com uma *mask*, das secções transversais em imagens. O modelo YOLOv8 utiliza uma arquitetura eficiente que é capaz de extrair e combinar características das imagens. Desse modo, o modelo “aprende” e adapta-se aos detalhes específicos conforme o objetivo do utilizador. Este algoritmo de *machine learning* (ML) destaca-se pela sua capacidade de deteção em tempo real, mantendo os níveis de precisão. A rede foi treinada utilizando um vasto conjunto de imagens de diferentes secções transversais existentes em estruturas metálicas. A extração dos desvios geométricos é concluída com a criação de *Oriented Bounding Box* (OBB), provenientes da *mask* e da *bounding box* original adquirida após o treino do modelo. Esta OBB representa não apenas o contorno geométrico da secção transversal identificada, mas também a sua orientação e localização na imagem. Este método possibilita a análise dos desvios através da comparação das OBBs obtidas pelo modelo *As-Is* e *As-Design*, permitindo uma avaliação detalhada da conformidade geométrica, de acordo com os padrões da norma NP EN 1090-2:2020 .

1.2 Objetivos

Atendendo à informação anteriormente descrita, os principais objetivos desta dissertação são:

1. Compreender e aprimorar processos e boas práticas para a captura, processamento e fusão de dados em nuvens de pontos adquiridos através de tecnologias digitais como LiDAR e fotogrametria, aplicadas a estruturas metálicas.
2. Desenvolver um algoritmo de extração de secções transversais a partir de modelos 3D.
3. Implementar algoritmos de ML para a deteção e segmentação automática de secções transversais em imagens, baseados no modelo YOLOv8.
4. Avaliar os desvios geométricos de forma automática, através da comparação entre os modelos *As-is* e *As-Design*, em conformidade com a norma NP EN 1090-2:2020

1.3 Estrutura do documento

Para uma melhor compreensão do conteúdo apresentado este documento está organizado da seguinte forma:

- Capítulo 1 – Introdução - Fornece uma introdução ao tema, motivação, objetivos e estrutura da tese.
- Capítulo 2 – Estado da Arte - Apresenta-se uma revisão das principais tecnologias digitais aplicadas ao levantamento de dados e controlo de qualidade em estruturas metálicas, nomeadamente fotogrametria, LiDAR e métodos de fusão de nuvens de pontos. Aborda-se também o uso de inteligência artificial para a deteção e segmentação de imagens.
- Capítulo 3 – Metodologia para Identificação de Desvios Geométricos - Descreve-se detalhadamente a metodologia proposta para o levantamento, fusão e processamento de dados, bem como a aplicação do modelo YOLOv8 para a deteção de secções transversais. Inclui também as etapas de validação com a norma NP EN 1090-2:2020 .
- Capítulo 4 – Caso de Estudo - Apresenta-se a aplicação prática da metodologia desenvolvida num estudo de caso real, com a aquisição de dados em estruturas metálicas, a fusão das nuvens de pontos e a análise dos resultados, incluindo a identificação de desvios geométricos.

CAPÍTULO 1

- Capítulo 5 – Conclusões - São discutidos os principais resultados obtidos e as limitações encontradas no campo da aplicação de tecnologias digitais no controlo de qualidade em estruturas metálicas.

2 Estado da arte

2.1 Estruturas metálicas

Com os avanços tecnológicos impulsionados pela Primeira Revolução Industrial no século XVIII, o ferro foi adotado como um material de construção, levando à introdução das estruturas metálicas na engenharia civil. Estas estruturas destacaram-se devido às suas propriedades notáveis, como a elevada resistência, durabilidade e versatilidade na construção. Como resultado, o ferro e as estruturas metálicas tornaram-se uma alternativa altamente competitiva face aos materiais utilizados na época. A Figura 1 reforça a preponderância das estruturas metálicas, ao ilustrar um edifício industrial moderno após terminada a sua construção.

As estruturas metálicas atuais são compostas geralmente por elementos de aço estrutural que são ligados entre si através de técnicas como a soldadura e o aparafusamento, o que lhes permite suportar cargas e garantir a rigidez necessária durante a sua exploração. Graças à elevada resistência do aço, as estruturas metálicas revelam-se viáveis já que, requerem menos matéria-prima em comparação com outros tipos de estruturas, como as de betão e madeira (Simões, (2007), (Corporation, 2023)). De forma semelhante, em Portugal tem-se verificado um aumento progressivo na utilização deste tipo de estruturas em vários tipos de obras, incluindo pontes, edifícios de escritórios, edifícios industriais, estacionamento e coberturas de recintos desportivos (Simões, 2007). Ao contrário do betão, o aço distingue-se pela sua elevada resistência tanto à compressão como à tração. Estas propriedades permitem a conceção de estruturas esbeltas e leves, superiores a outras soluções. Além disso, a ductilidade do aço possibilita suportar deformações plásticas significativas antes de atingir o ponto de rotura. Simultaneamente, a pré-fabricação de elementos metálicos, associada à facilidade de distribuição e à simplicidade na montagem, contribuiu para a redução dos tempos de construção.

A execução de uma estrutura metálica é um processo que obriga a cuidados técnicos e precisos em todas as suas etapas. As fases de fabrico e montagem são partes essenciais do processo da

construção metálica, com relevância acrescida comparativamente à construção tradicional em alvenaria. Na construção em betão armado as tolerâncias dimensionais são superiores e a forma de execução dos acabamentos em obra podem facilitar eventuais correções dimensionais e outras. Na construção metálica o controlo de qualidade durante as fases de fabrico e montagem é crucial para garantir que a estrutura final atenda aos requisitos e especificações técnicas do projeto. Para isso, é utilizada a norma NP EN 1090-2:2020 que fornece os requisitos técnicos para a execução de estruturas de aço, assegurando assim, os níveis de resistência mecânica, estabilidade, utilização e durabilidade.

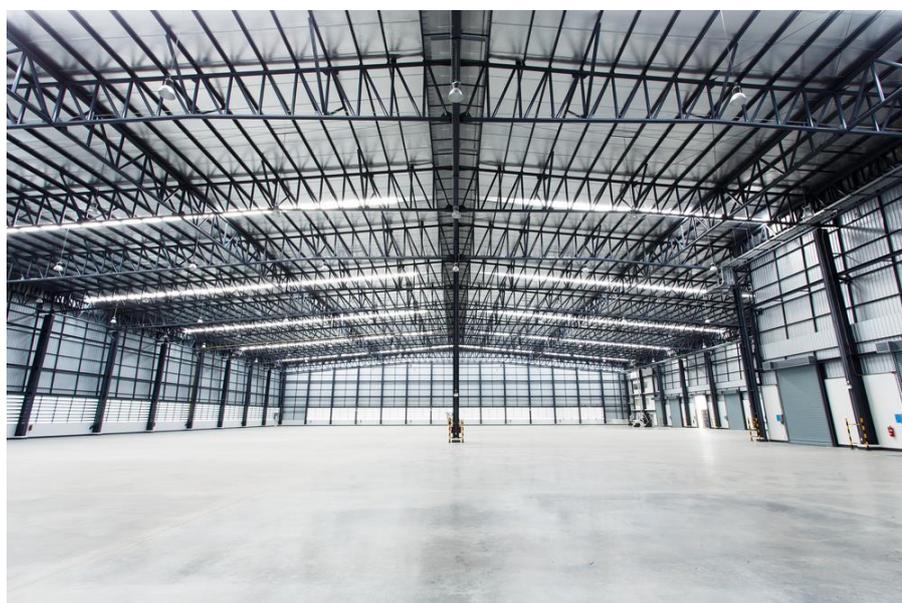


Figura 1: Estrutura industrial metálica (retirado de www.servicesteel.org).

2.1.1 Montagem

A qualidade de execução de um projeto de estruturas metálicas é fortemente influenciada pela fase de montagem, a qual, apesar da aparente simplicidade, exige um rigor elevado para evitar os erros comuns em obra. Nesse contexto, a norma NP EN 1090-2:2020 apresenta um conjunto de prescrições e indicações que devem ser seguidas desde os trabalhos preparatórios até aos acabamentos finais. A seguir, são descritas as principais etapas da fase de montagem de estruturas metálicas tendo como base a norma referida.

- **Trabalhos preparatórios**

Os trabalhos de pré-montagem são essenciais para o início do processo de montagem. Cabe ao diretor de obra realizar um planeamento detalhado das fases de execução da obra, em

conformidade com o projeto e os desenhos técnicos fornecidos pelo projetista. Após a receção dos materiais, estes devem ser inspecionados e organizados para verificar a conformidade com as especificações do projeto. Simultaneamente, devem ser elaborados planos de trabalho para os componentes, incluindo a organização dos equipamentos de montagem, como guas, plataformas elevatórias, ferramentas manuais e mão de obra, garantindo que todos os prazos estipulados para a conclusão da obra sejam cumpridos.

- **Transporte e receção do material, organização de estaleiro**

A distribuição do material na obra exige planeamentos logísticos, nos quais medidas preventivas devem ser tomadas de forma a considerar fatores como peso, dimensões e fragilidade da peça. Para isso, é essencial selecionar o equipamento de transporte e, também, as rotas do transporte, especialmente no caso de peças com complexidade ou pré-fabricadas. Todas as peças devem ser devidamente embaladas e protegidas contra danos, assegurando que cheguem ao destino em perfeitas condições e cumpram prazos para a montagem.

É responsabilidade do diretor de obra verificar a integridade e a qualidade dos componentes rececionados em obra. Cada elemento deve estar previamente identificado e inspecionado para eventuais anomalias, como deformações, esmagamentos, choques mecânicos, arranhões e problemas no tratamento superficial, antes da sua aplicação. Além disso, é importante verificar se todos os materiais estão em conformidade com o projeto e quaisquer alterações ao projeto devem ser devidamente documentadas e arquivadas. Por fim, a norma NP EN 1090-2:2020 realça a importância de organizar o estaleiro de obra de forma a garantir fluidez nos acessos dentro e fora do mesmo.

- **Montagem da estrutura**

Um dos principais fatores para o sucesso final da obra é a montagem da estrutura. A norma NP EN 1090-2:2020 realça a importância de aspetos como a definição das bases de projeto, apoios e ancoragens, já que são indispensáveis para garantir a estabilidade e segurança da estrutura no processo de montagem. Esta também inclui diretrizes quanto à seleção dos equipamentos de elevação e de manuseamento, bem como técnicas de ligação.

A correta definição das bases de projeto, considerando a sequência de montagem, a localização e o tipo das ligações, o peso e as dimensões dos componentes, e a necessidade de aplicação e posterior remoção de escoramentos temporários, é fundamental para garantir a estabilidade e segurança da estrutura durante todas as fases da construção. O responsável pela construção

terá de ter acesso a desenhos de montagem que incluem plantas, alçados com as devidas marcas de montagem dos elementos, posições de apoio e ainda requisito para tolerâncias.

Os trabalhos de terreno iniciam-se com as marcações e o posicionamento correto dos apoios da estrutura, recorrendo a ferramentas de medição e marcações topográficas para controlar possíveis desvios, desalinhamentos, desnivelamentos e garantir perpendicularidade na implantação da obra. A implementação dos apoios de suporte, geralmente fundações em betão armado, são responsáveis por fixar os pilares da estrutura metálica. Segue-se a aplicação de *grout* na área de apoios, com o objetivo de preencher lacunas entre a chapa de base dos pilares e os apoios. Após o processo de cura da argamassa, finaliza-se o processo de fixação de cada elemento com a ancoragem, utilizando chumbadouros ou parafusos, garantindo assim a estabilidade e segurança da estrutura.

As ligações entre elementos são asseguradas através de parafusos, rebites ou soldadura e são fundamentais para garantir a resistência e estabilidade da estrutura. Cada ligação deve ser executada com precisão e, no caso das soldaduras, estas devem ser realizadas por profissionais qualificados. Todas as soldas devem ser inspecionadas rigorosamente para garantir os critérios de qualidade na montagem.

Conclui-se que, a fase de montagem de uma estrutura metálica é um processo que exige o devido planeamento e atenção aos detalhes para garantir a conformidade com a norma NP EN 1090-2:2020 . Aspetos como preparação do terreno, marcações, apoios, fixações e ligações desempenham um papel crucial para a qualidade da estrutura final.

2.1.2 Desvios geométricos e controlo de qualidade

Os desvios geométricos em estruturas metálicas referem-se às discrepâncias entre as dimensões previstas em projeto comparativamente com as dimensões efetivamente obtidas após as fases de fabrico, transporte e montagem. A ocorrência destes desvios surge principalmente, devido a erros no processo de fabrico, medições não rigorosas, deformações após a fase de transporte, erros no processo de montagem ou até erros de análise estrutural. Devido ao impacto significativo dos desvios para a integridade e comportamento global da estrutura, a norma NP EN 1090-2:2020 define limites específicos para os desvios e apresenta tolerâncias que devem ser asseguradas para garantir a conformidade da estrutura e o seu desempenho. O controlo dos desvios geométricos é particularmente importante para assegurar

que a estrutura final cumpre os requisitos da norma. A não aplicação de métodos de controlo geométrico pode provocar erros graves, como incompatibilidades nas ligações onde ocorrem desalinhamentos que impedem a correta união entre elementos estruturais, sobrecargas inesperadas, excentricidades indesejáveis nos apoios de fixação, falhas estruturais por acumulação de desvios e aumento de despesas com trabalhos de reparação.

A norma NP EN 1090-2:2020 realça a importância da utilização de ferramentas de medição precisas para o controlo de desvios geométricos, bem como a integração de métodos tradicionais de medição e das tecnologias digitais. As ferramentas tradicionais como as fitas métricas, níveis, teodolitos e estações totais, apesar da sua simplicidade e baixo custo, apresentam limitações na precisão em projetos de elevada complexidade. Nesse contexto, tecnologias digitais como o LiDAR (*Light Detection and Ranging*), Fotogrametria podem ser incorporadas no projeto, permitindo assim a criação de modelos 3D precisos e posterior análise estrutural. A utilização destas tecnologias permite a deteção precoce de desvios e facilita a correção imediata, garantindo a conformidade com os requisitos de qualidade.

- **Tolerâncias geométricas**

Para compreender melhor as indicações da norma em relação aos desvios geométricos é fundamental compreender e distinguir as tolerâncias geométricas essenciais e funcionais. As tolerâncias essenciais são de cumprimento obrigatório e definem-se como os limites fundamentais que devem ser respeitados para garantir a resistência mecânica e a estabilidade do projeto estrutural, sendo que a não conformidade exige correções imediatas. Estas tolerâncias são fundamentais já que garantem que a estrutura suporte as cargas projetadas ao longo da sua vida útil. Por outro lado, as tolerâncias funcionais são mais flexíveis e referem-se aos ajustes necessários para que determinado elemento cumpra a sua função estrutural corretamente, o incumprimento destas tolerâncias causa dificuldades na montagem, problemas estéticos ou, em casos mais graves, compromete a funcionalidade global da estrutura. No que diz respeito às tolerâncias nas fases de fabrico e montagem, a norma NP EN 1090-2:2020 apresenta quadros com os desvios admissíveis para as tolerâncias essenciais e funcionais de montagem.

- **Tolerâncias de fabrico**

As tolerâncias de fabrico definem-se como os limites impostos pela norma, dentro dos quais as dimensões e formas da peça devem ser mantidas durante todo o processo de fabrico. Nesse

âmbito, apesar de a NP EN 1090-2:2020 não fornecer diretamente tolerâncias específicas para o fabrico, estabelece que estas devem ser determinadas com base nas necessidades do projeto e nas especificações do projetista. Durante o fabrico, as empresas metalomecânicas devem controlar as dimensões de elementos individuais, como vigas, pilares, chapas ou outros componentes, através de inspeções regulares e da documentação dos resultados. Isto garante que as dimensões cumprem os limites estabelecidos de acordo com as normas de produto aplicáveis, como as normas EN para produtos laminados a quente ou enformados a frio.

- **Tolerâncias de montagem**

No que respeita às tolerâncias de montagem, a norma NP EN 1090-2:2020 apresenta um conjunto de quadros com os desvios aceitáveis para as tolerâncias essenciais e funcionais para as diferentes fases de montagem. A norma aborda casos específicos quanto ao posicionamento e alinhamento dos componentes assim como aspetos como retilinearidade dos pilares. Deve-se, portanto, garantir que as tolerâncias são cumpridas para garantir a conformidade do projeto.

2.2 Tecnologias digitais aplicadas à AEC

A chegada da Indústria 4.0 transformou por completo os processos utilizados para a execução de projetos de Arquitetura, Engenharia e Construção (AEC) (Nwaogu et al., 2023). A incorporação das tecnologias digitais como LiDAR e fotogrametria, apresenta várias vantagens para a Engenharia Civil. Graças à diversificação das funcionalidades e características destas técnicas, é possível acompanhar todas as fases da obra desde a concepção e fabrico até à montagem final, e estendê-las mesmo à fase de operação.

Existem dois métodos principais utilizados para a reconstrução 3D de objetos. Os sistemas ativos, como o sistema LiDAR, utilizam radiação (ex: impulsos laser) para realizar medições remotas. Já os sistemas passivos, baseados em câmaras e na geometria da estrutura, utilizam técnicas como o SfM (*Structure from Motion*) para reconstruir um cenário. Tanto o LiDAR quanto a fotogrametria permitem a criação de modelos 3D de forma rápida e com elevada precisão, através de uma nuvem de pontos que guarda informações como, por exemplo, coordenadas geoespaciais e cor (Vieira et al., (2023); Mois, (2020); Mohammadi et al., (2022). A Figura 2 demonstra o funcionamento em conjunto destas tecnologias digitais. De acordo com Zhao et al., (2023), a análise de modelos 3D completos provenientes de tecnologias digitais

aplicadas *in situ* oferece vantagens na conservação, restauro e construção de estruturas. Este tipo de análise funciona como um ensaio de inspeção não destrutivo, capaz de recolher informação de forma económica e eficiente.

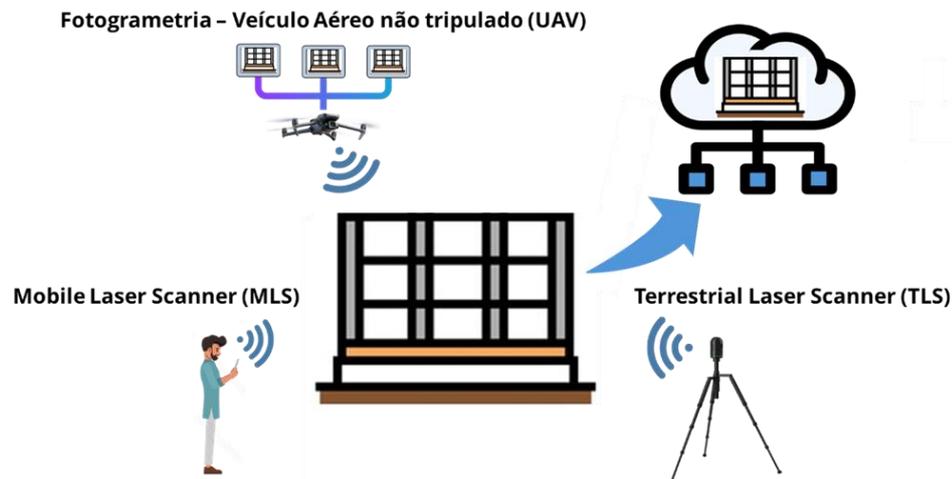


Figura 2: Funcionamento conjunto de tecnologias digitais.

2.2.1 Fotogrametria

A fotogrametria é uma técnica de medição usada em áreas como a engenharia civil, arquitetura e topografia para recolher dados geoespaciais, como coordenadas geográficas, medir distâncias, alturas, áreas e volumes, criação de mapas topográficos, bem como na criação de modelos de elevação e ortofotografias (Hu et al., 2021). Esta técnica utiliza várias imagens captadas de diferentes perspetivas para criar modelos tridimensionais a partir de imagens 2D (Deliry et al., 2021).

No que toca à fotogrametria, existem diversas abordagens possíveis para a reconstrução 3D de um objeto, nomeadamente: *close-range photogrammetry*, *Camera Array*, *wide-angle photogrammetry* e *aerial photogrammetry*. A *close-range photogrammetry* envolve a captura de imagens com distâncias mais reduzidas, podendo ser realizada de forma aérea ou terrestre. A técnica *Camera Array* recorre a câmaras fixas para capturar imagens de várias perspetivas, sendo fundamental garantir sobreposição de imagens para obter os melhores resultados na reconstrução 3D do objeto (Kovanič et al., 2023). O método *wide-angle photogrammetry* é especialmente útil em ambientes interiores, devido ao uso de lentes panorâmicas de grande abertura angular e com curta distância focal. Finalmente, a *aerial photogrammetry* é caracterizada pela captura de imagens aéreas em espaços abertos, sem obstáculos e com

espaço para movimento, com o auxílio de satélites, aviões e helicópteros (Deliry et al., 2021); (Iglhaut et al., 2019).

A reconstrução tridimensional fotogramétrica é possível através da técnica SfM e caracteriza-se pela utilização de imagens 2D captadas em movimento, associando uma posição espacial em latitude, longitude e altitude a cada pixel da imagem. Esta técnica avançada surgiu com os desenvolvimentos da visão computacional e da fotogrametria tradicional, sendo capaz de obter, simultaneamente, a estrutura tridimensional de um dado objeto, assim como as posições, os parâmetros e as orientações da câmara tendo em conta a correspondência entre imagens (Dering et al., 2019).

Entre os pontos mais fortes da fotogrametria, destaca-se o custo-eficácia, uma vez que equipamentos como UAVs e câmaras convencionais têm preços mais acessíveis em comparação com outras tecnologias mais avançadas. Além disso, a fotogrametria oferece a capacidade de criar modelos realistas e detalhados, em muitos casos superando outras soluções disponíveis. A sua versatilidade e acessibilidade permite também a captura de dados em locais de difícil acesso, ampliando assim a sua aplicação em diferentes contextos (Dering et al., (2019); Hu et al., (2021)).

Por outro lado, a fotogrametria apresenta limitações a ter em conta. Em objetos com pouca textura ou com superfícies refletoras, a precisão do processamento pode vir afetada negativamente, exigindo a aplicação de algoritmos específicos de tratamento de imagens para minimizar estes efeitos. Adicionalmente, a fotogrametria tende a gerar menos informação, o que, embora resulte em modelos mais leves e de processamento mais rápido, pode comprometer a resolução e precisão dos modelos finais. No contexto de levantamentos fotogramétricos, as condições ambientais, como chuva, luz solar intensa ou nevoeiro, podem impactar negativamente a qualidade dos dados capturados (Dering et al., (2019, Iglhaut et al., (2019, Deliry et al., (2021)).

2.2.1.1 Plataforma UAV

Os UAV têm um papel fundamental no levantamento fotogramétrico, impulsionando avanços tecnológicos significativos, principalmente através da incorporação de sensores que auxiliam na localização espacial, velocidade e aceleração durante o voo. Atualmente, os UAVs (Figura 3) integram sistemas inerciais IMU (*Inertial Measurement Unit*), sistemas de navegação por satélite (*Global Navigation Satellite System – GNSS*) e sistemas de correção de posicionamento

(*Real-Time Kinematic* – RTK). Estes sensores permitem reduzir o número de GCPs (*Ground Control Points*) necessários para o processamento de dados, acelerando o processamento sem comprometer a precisão do modelo (Alshawabkeh et al., 2023). A tecnologia RTK destaca-se pela capacidade de determinar em tempo real a posição do UAV no espaço com elevada precisão (Fabris et al., 2023). Segundo Ekaso et al., (2020), o posicionamento de uma estação fixa com RTK permite enviar sinais de correção de posição ao UAV, garantindo precisão centimétrica no espaço. Os autores também mencionam que a qualidade das imagens depende do IMU, do *gimbal*, do tipo de câmara, da nitidez e da sobreposição das imagens. O *gimbal*, um sistema estabilizador da câmara que minimiza os efeitos de vibração durante o voo, é crucial para evitar efeitos de desfoque na imagem (Chatzistamatis et al., 2018). De acordo com Meireles, (2002), a calibração da câmara é vital para garantir a correta correspondência dos pontos do espaço tridimensional e os *pixels* das imagens, ajustando os parâmetros que caracterizam o sistema, o ambiente em que está inserido e o modo como será utilizado.



Figura 3: DJI Mavic 3 Enterprise Series com o módulo RTK e câmara com 20MPx (retirado de <https://enterprise.dji.com>).

Existem dois tipos de parâmetros da câmara que devem ser considerados no processamento: os parâmetros intrínsecos e extrínsecos. Os parâmetros intrínsecos são necessários para ligar os *pixels* da imagem ao sistema de coordenadas da câmara. Além disso, estes parâmetros registam informações como a distância focal, os fatores de escala, as posições e as dimensões dos *pixels*, bem com as distorções das lentes. Por outro lado, os parâmetros extrínsecos registam os 6 graus de liberdade da câmara no espaço, compostos por três coordenadas (x, y, z) , que representam a latitude, longitude e altitude, e três ângulos diedros (w, φ, k) (Figura 4). A variação das coordenadas (x, y, z) implica uma translação da câmara no espaço real, enquanto a variação dos ângulos diedros indica rotações em torno dos eixos locais da câmara, alterando a orientação da câmara, a direção da visão e a perspetiva das imagens. Estes parâmetros são essenciais para determinar a localização e orientação de um ponto no sistema de coordenadas da câmara em relação ao mundo (Nigri, 2009). Durante o alinhamento, o

software de processamento define automaticamente estes parâmetros (Alshwabkeh et al., 2023).

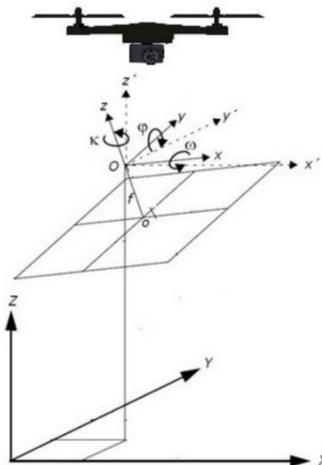


Figura 4: Esquemática dos parâmetros da câmara (adaptado de Alshwabkeh et al., (2023)).

2.2.1.2 Técnicas e boas práticas

O planejamento de um levantamento fotogramétrico é essencial para garantir que os resultados sejam precisos e fiáveis. Por isso, a escolha do UAV deve ser feita com base nas exigências de resolução dos sensores (ou câmaras) integradas, na dimensão do objeto de estudo, na área de superfície e na morfologia da envolvente. A definição do GSD (*Ground Sampling Distance*) refere-se à distância que cada pixel da imagem representa no espaço real (Dering et al., 2019). Como representado na Figura 5, um GSD menor resulta num modelo de alta resolução e vice-versa, sendo que o mesmo é definido pelas características da câmara, como distância focal, resolução e dimensões do sensor, mas também pela distância do drone ao nível do solo ou ao objeto (Tariq et al., 2017).

Atualmente, os UAVs são operados através de *software* dedicado como o *DJI Fly* e o *Litchi Flight*, suportados por *smartphones* ou *tablets*, permitindo a execução de voos programados. Para estruturas complexas, recomenda-se dividir os levantamentos e/ou aumentar a duração dos voos, de modo a garantir uma captura correta dos pontos de referência e uma adequada sobreposição de imagens (Chatzistamatis et al., 2018). As condições atmosféricas também devem ser consideradas. Fatores como a hora do dia, o vento, a temperatura e a altitude do voo influenciam diretamente os resultados obtidos. Idealmente, o levantamento deve ser realizado em dias nublados ou ao meio-dia para evitar que o sombreamento condicione a qualidade das fotografias. O vento, por sua vez, pode afetar a trajetória de voo, podendo

resultar em desvios do plano e inclinações indesejáveis na câmara, enquanto a altitude e a temperatura podem reduzir o tempo de voo e, conseqüentemente, a cobertura do levantamento (Tariq et al., 2017).

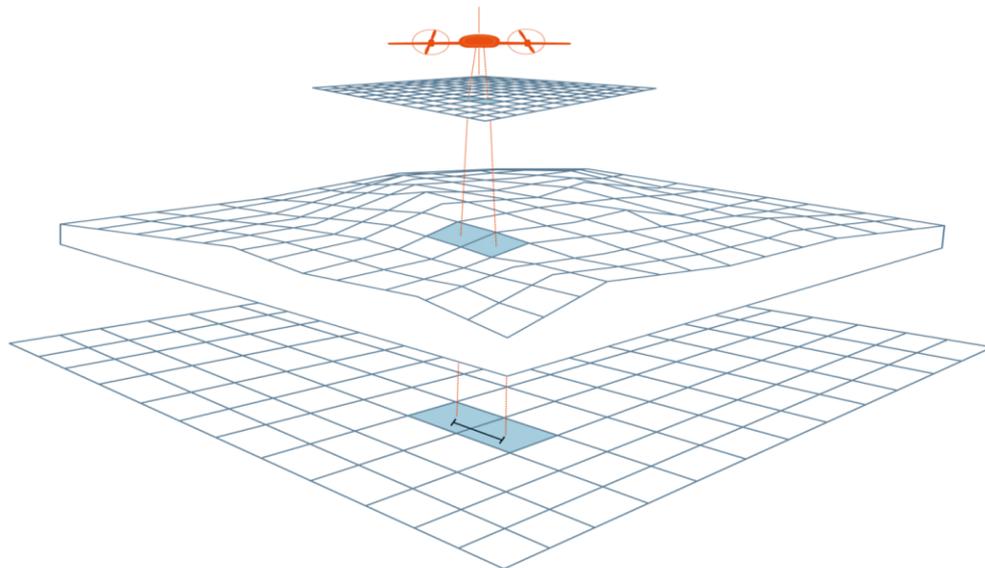


Figura 5: Variação dos Ground Sampling Distance (GSD) com a variação da altura do UAV (adaptado de Wingtra, (2019)).

2.2.1.3 Processamento de dados

Existem diversas etapas que devem ser cumpridas para o processamento fotogramétrico, de forma a obter o melhor resultado possível. Com base em pesquisa bibliográfica realizou-se um fluxograma dando uma visão macro do processamento de dados fotogramétricos (Figura 6).

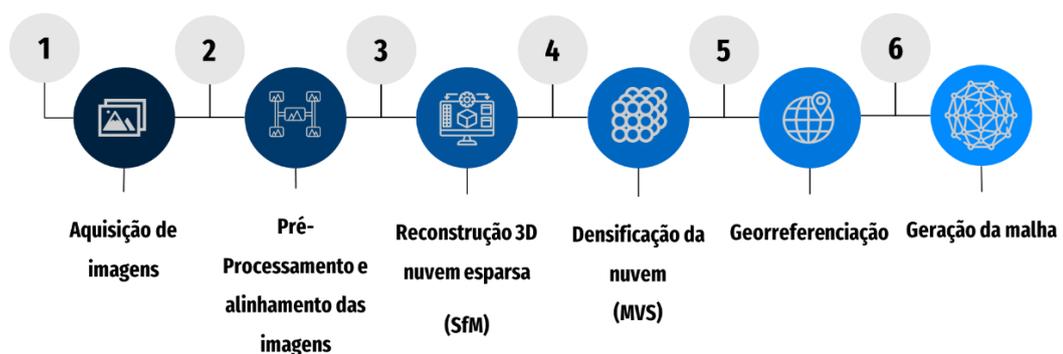


Figura 6: Fluxograma de processamento de dados fotogramétricos.

1) Aquisição de imagens

Na abordagem aérea o planeamento é crucial para garantir a qualidade dos dados. De acordo com Yadav et al., (2020), o ideal é que as capturas sejam realizadas de várias perspetivas e ângulos para garantir a melhor sobreposição e cobertura total do objeto como demonstrado na Figura 7. A definição da altura do voo, do GSD e a marcação dos GCPs é fundamental para o sucesso do levantamento. Além disso, a seleção das condições de levantamento, como a luz e o ambiente, ajuda a evitar sombras ou distorções que possam comprometer a precisão do modelo.

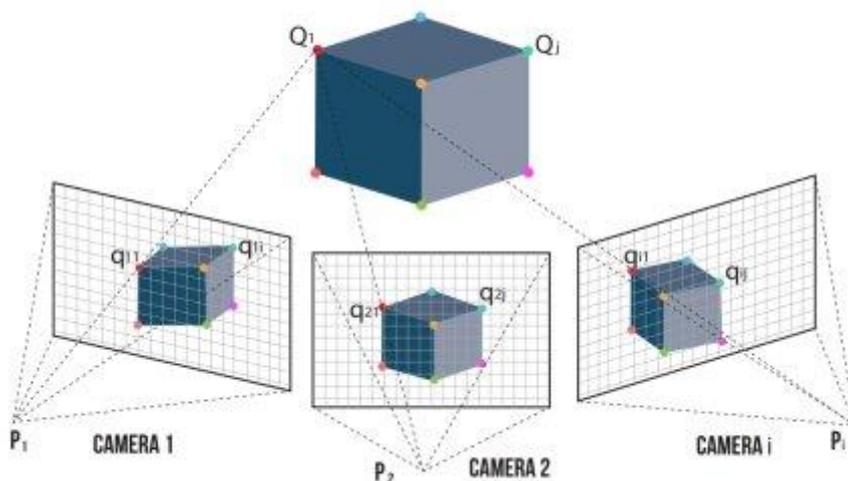


Figura 7: Aquisição de imagens do objeto de diversas perspetivas e ângulos (adaptado Galanakis et al., (2021).

2) Pré-processamento e alinhamento das imagens

Após a captura e o tratamento inicial das imagens, o próximo passo é corrigir eventuais distorções, bem como ajustar e balancear as cores de cada fotografia. Nesta fase, as imagens são pré-processadas e alinhadas num sistema de coordenadas globais, utilizando *software*, como o *iTwin Capture Modeler (Bentley Systems)* ou o *Agisoft Metashape*. A calibração da câmara é realizada utilizando parâmetros intrínsecos e parâmetros extrínsecos para corrigir distorções nas imagens (Fiorillo et al., 2023). Estes programas são capazes de criar projetos individuais para cada conjunto de imagens e localizar automaticamente cada fotografia através da leitura de informações armazenadas nos ficheiros EXIF (ficheiros de metadados das imagens), obtidos pelos sistemas GNSS e RTK integrados nos UAVs. Esses sistemas permitem armazenar informações relacionadas com o registo fotográfico, incluindo o instante da captura,

os parâmetros de configuração e a orientação da câmara. Este passo facilita o processamento dos dados e a geração da nuvem de pontos.

3) Reconstrução 3D da nuvem esparsa

Os *software* utilizados para a reconstrução de modelos 3D baseiam-se no algoritmo *SfM*. Este método permite criar o modelo tridimensional de uma estrutura a partir de fotografias 2D, capturadas de vários pontos e perspectivas (Iglhaut et al., 2019). A combinação dessas imagens permite a geração do modelo 3D da estrutura utilizando conceitos de geometria epipolar. Para auxiliar o processo, recorre-se ao algoritmo *Scale-Invariant Feature Transform* (SIFT) que é capaz de identificar e isolar pontos característicos da imagem. Esses pontos servem como referência para o alinhamento das fotos e a geração do modelo (Lowe, 2004). A Figura 8a) esquematiza o processo de reconstrução com o SfM e extração de características com o SIFT. Com o SfM é possível extrair características distintas das imagens sobrepostas resultando numa nuvem de pontos esparsa, sem escala e sem orientação, conforme demonstra o exemplo da Figura 8b).(Chatzistamatis et al., (2018).

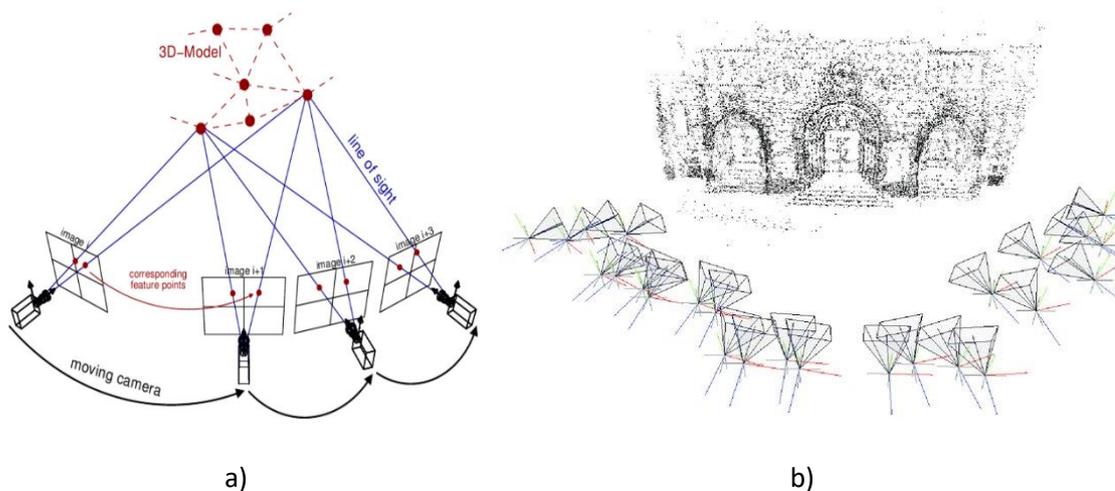


Figura 8: Esquemática SfM e extração de características com SIFT. a) Posicionamento da câmara no instante da captura ((adaptado de van Riel, (2016)); b) Exemplo de nuvem esparsa criada pela técnica SfM (adaptado de Cao et al., (2023)).

4) Densificação da nuvem

Com base nas correspondências extraídas pelo algoritmo SIFT e na nuvem esparsa obtida, é necessário densificá-la. Para isso, utiliza-se metodologia MVS (*Multi-View Stereo*), combinada com o SfM. Este processo permite ao algoritmo reconhecer características em várias imagens e gerar uma nuvem de pontos mais densa, além de criar modelos extra em malha (Figura 9)

(Deliry et al., (2021). O algoritmo SfM-MVS proporciona várias melhorias para o modelo tanto ao nível de automatização do processo, como na qualidade e precisão do modelo final. O uso do MVS permite integrar imagens de diferentes perspectivas e equipamentos, quer sejam capturadas por UAVs ou por imagens terrestres. Conforme explicam Deliry et al., (2021), as metodologias SfM e MVS são complementares, uma vez que o *Structure from Motion* não requer a determinação prévia dos parâmetros da câmara e o MVS é capaz de estimar esses parâmetros juntamente com a calibração da câmara.

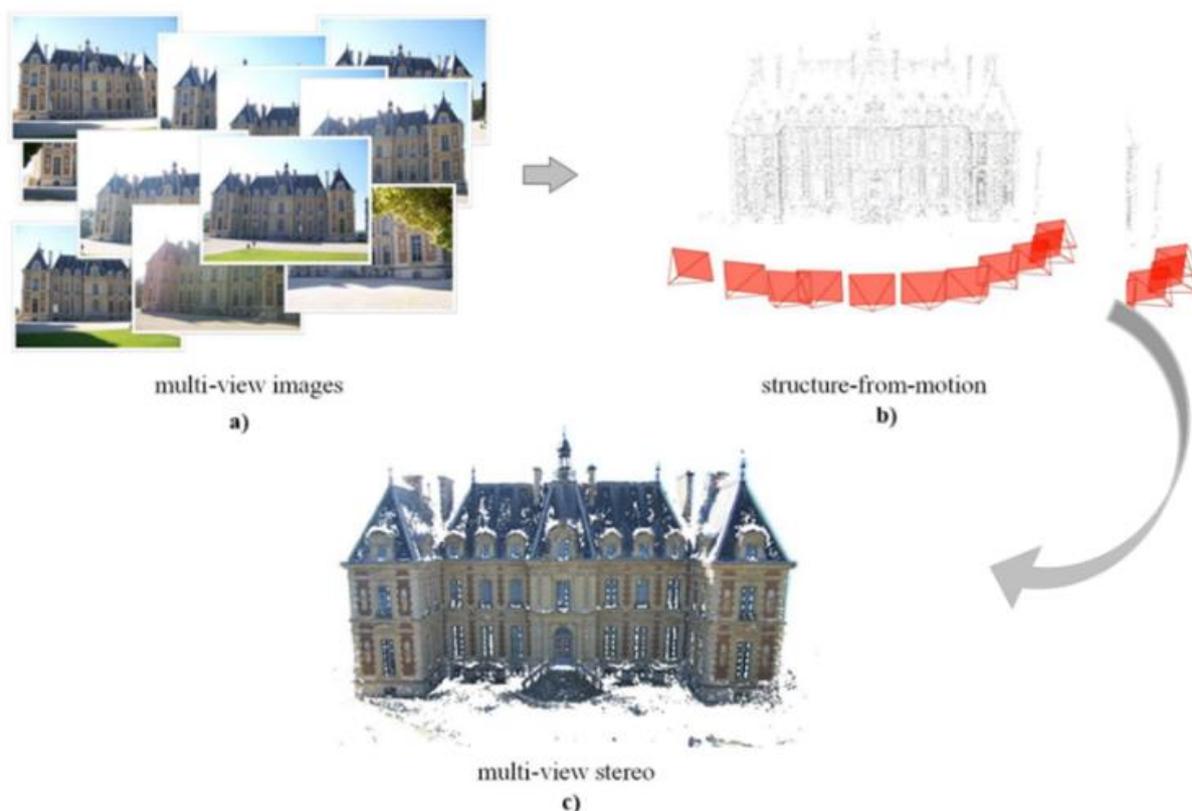


Figura 9: Processamento fotogramétrico: a) aquisição de imagens; b) reconstrução tridimensional (SfM); c) densificação após a aplicação da metodologia MVS (disponível em: github.com).

5) Georreferenciação

A georreferenciação da nuvem de pontos é essencial para orientar e escalar o modelo tridimensional. Para isso, utilizam-se *GCPs*, que são pontos de referência estratégicos com coordenadas espaciais conhecidas, obtidas de forma precisa através de métodos geodésicos (Kovanič et al., 2023). Alternativamente, os sistemas GNSS e RTK integrados nos UAVs mais recentes permitem reduzir a necessidade de *GCPs* para a georreferenciação do modelo (Deliry et al., 2021). A posição e o número de *GCPs* influenciam diretamente a qualidade dos resultados fotogramétricos obtidos (Kovanič et al., (2023). Os pontos são fornecidos pelo topógrafo e,

posteriormente, inseridos no *software* de processamento através de ficheiros de texto (em formato *.txt* ou *.csv*) contendo o *label* e as coordenadas ortométricas de cada ponto. Estes dados são atribuídos automaticamente aos pontos correspondentes, que serão usados para reconstruir o modelo.

6) Geração da malha

Após densificar a nuvem de pontos, de modo a obter uma reconstrução mais realista, é necessário gerar uma malha com textura a partir da nuvem (Figura 10). Essa malha é composta por planos triangulares aos quais é atribuída uma cor, resultante da média RGB dos três vértices que delimitam cada triângulo (Fiorillo et al., 2021). A texturização da nuvem de pontos é bastante demorada, já que o *software* vai processar inúmeros triângulos na malha, permitindo reconstruir um modelo realista da aparência do objeto de estudo, recriando as cores reais existentes. Geralmente, este processo origina ruído na malha proveniente da nuvem de pontos (pré-processada), por isso, é fundamental proceder à sua remoção manual, excluindo assim pontos que o *software* admite como fora do plano.



Figura 10: Criação da malha com textura, recriando um modelo mais realista (disponível em: github.com).

2.2.2 LiDAR

A tecnologia LiDAR, assim como a fotogrametria, transformou a forma como a indústria AEC encara os levantamentos estruturais e a análise de dados 3D. Operado através de varrimento a *laser*, o LiDAR permite realizar medições precisas e digitalizar a informação obtida, formando modelos detalhados em nuvens de pontos e registo de dados geoespaciais 3D. Esta tecnologia pode ser aplicada tanto através de *Terrestrial Laser Scanner* (TLS) como, mais recentemente, com recurso a *Mobile Laser Scanner* (MLS). O MLS emerge como um complemento ao TLS para

levantamentos de elementos de difícil acesso devido ao seu tamanho reduzido e maior mobilidade. Um marco no mercado foi o lançamento pela *Apple*, em 2020, do primeiro *smartphone* equipado com sensores LiDAR, denotando a crescente incorporação em diversos dispositivos móveis.

2.2.2.1 Terrestrial Laser Scanner (TLS)

O varrimento *Terrestrial Laser Scanner* é um método de levantamento de alta precisão que se destaca na captura das coordenadas espaciais do objeto com elevada precisão (Shen et al., 2023). Esta técnica é amplamente utilizada para a obtenção de nuvens de pontos tridimensionais de alta resolução, sendo reconhecida pela capacidade de capturar a geometria dos objetos em toda a sua envolvente através de feixes de laser emitidos em todas as direções (Oliveira et al., (2023)). Estes *scanners* são eficazes em ambientes terrestres, como obras ou edifícios, porém, dependendo da superfície, podem encontrar dificuldades na avaliação precisa de algumas formas geométricas. Geralmente, os TLS são capazes de captar imagens digitais com uma câmara incorporada, tendo a mesma capacidade de colorir a nuvem de pontos. No entanto, a posição ótima da câmara é extremamente relevante, uma vez que a qualidade dessa coloração pode ser insuficiente para visualizar superfícies, características e condições de projeto (Alshawabkeh et al., (2023)).

2.2.2.2 Princípio de funcionamento e equipamentos

O levantamento TLS utiliza a medição a *laser* por triangulação ou a rotação de um espelho refletor para cobrir diferentes ângulos enquanto o equipamento gira para captar toda a sua envolvente (Kim et al., 2020). O *laser scanner* é estacionário e capaz de emitir feixes *laser* em várias direções. Quando esses feixes atingem a superfície do objeto, são refletidos de volta ao sensor, permitindo calcular a distância entre os objetos com base no tempo e na direção do retorno (ToF – *Time of Flight*), conforme representado na Figura 11. A medição pode ser feita através da emissão de pulsos laser, com o *scanner* a medir o comprimento de onda da radiação refletida. Além disso, o *laser scanner* tem a capacidade de gravar diretamente a geometria de um objeto, resultando numa nuvem de pontos densa, viável e colorida (Alshawabkeh et al., (2023)).

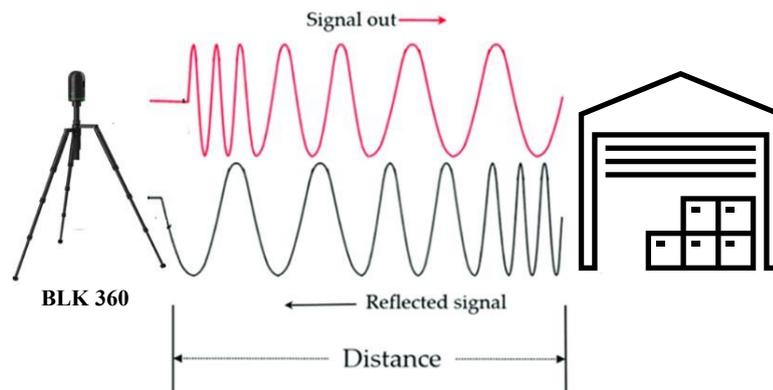


Figura 11: Princípio de funcionamento de um *laser scanner* (adaptado de Zheng et al., (2019)).

Atualmente, duas marcas dominam o mercado do *scanners a laser* terrestres: a *Leica* e a *Faro*. Além de fabricarem os equipamentos, estas empresas também desenvolveram *software* especializado para processar os dados obtidos. No caso da *Leica*, o *Leica BLK 360* (Figura 12) destaca-se pela sua facilidade de utilização e portabilidade, sem necessidade de ligações externas para realizar o varrimento. É ideal para ambientes interiores confinados ou de difícil acesso, utilizando três câmaras digitais HDR incorporadas para recolher informações por intermédio de imagens panorâmicas esféricas e ainda tem capacidade de armazenar até 64GB de dados; o seu alcance varia entre 60 cm e 60 m. Todas estas características levaram a que o mesmo fosse escolhido para as explicações das subsecções subsequentes. Relativamente à *Faro*, o *Faro Focus 3D X330* (Figura 13) destaca-se pela sua capacidade de longo alcance, de forma detalhada e robusta, sendo adequado para ambientes exteriores com condições adversas, onde a luz solar não é incidente.



Figura 12: BLK 360 G1 (disponível em: leica-geosystems.com).



Figura 13: Faro Focus 3D X330. (disponível em: www.faro.com).

2.2.2.3 Técnicas e boas práticas

Previamente ao levantamento, é importante realizar uma visita ao local e avaliar as dimensões e condições de acesso do caso de estudo, de modo a facilitar o planeamento da execução dos trabalhos. Durante esta fase, deve-se estimar a quantidade de varrimentos e estações necessárias, a localização das estações, dos pontos GCP e o modo de densidade do varrimento. A qualidade da nuvem, assim como o tempo de processamento são diretamente influenciados pelo bom planeamento prévio do levantamento. Isto é, quanto maior for a distância entre o *scanner* e o objeto a levantar, menor será a resolução e precisão dos resultados obtidos. Com base no equipamento escolhido, é importante compreender os seus limites, de forma a obter a melhor qualidade possível.

Com o planeamento concluído, é necessário calibrar o equipamento para garantir a precisão dos resultados. Após a calibração do *laser*, inicia-se o processo de varrimento a laser terrestre. Este processo deve ser acompanhado em tempo real através da aplicação *Leica Cyclone FIELD 360*, suportado por um *iPad*. Para facilitar o processamento da nuvem de pontos no *software*, recomenda-se o uso de alvos axadrezados (Figura 14), que são detetados automaticamente pelo software de registo (Luhmann et al., (2020)).



Figura 14: Exemplos de alvos para auxiliar o varrimento a laser (adaptado de Tang et al., (2020)).

Durante o levantamento, é essencial garantir sobreposição adequada entre nuvens de pontos, permitindo estabelecer associações robustas entre as estações, o que é necessário para a criação de *bundles*. Essa sobreposição é crucial para assegurar a qualidade dos dados e facilitar o alinhamento e integração dos modelos obtidos com o sistema de coordenadas geodésicas. Para tal, é necessário utilizar os pontos de controlo (GCP) com coordenadas conhecidas, obtidas através de métodos topográficos, para posteriormente proceder ao alinhamento e integração dos modelos gerados.

A aplicação do *iPad (Cyclone Field 360)* permite que, sempre que o equipamento seja movido para a realização de um novo *scan*, esse *scan* permaneça ligado, através de um *link*, ao último *scan* realizado, facilitando o posterior processamento. Caso este *link* não seja efetuado no local, ao importar a nuvem para o *software Cyclone Register*, os *scans* estarão incorretamente sobrepostos e/ou aleatoriamente espaçadas, o que dificulta o estabelecimento dos *links* (Oliveira et al., (2023).

A qualidade da nuvem de pontos depende diretamente da localização e do número de estações LiDAR, para garantir uma elevada sobreposição de *scans* e cobertura total do caso de estudo. Embora aumentar o número de estações seja vantajoso para obter resultados precisos, isso também aumenta o tempo de processamento de dados. Por outro lado, em locais com geometria complexa ou na presença de obstáculos, como por exemplo, paredes, pilares e máquinas industriais, o posicionamento do *scanner* é fundamental para obter a cobertura total do objeto. Consequentemente, torna-se relevante elaborar processos de otimização desses fatores, de modo a obter a melhor precisão após o varrimento e, ao mesmo tempo, limitar o tempo de processamento da informação.

2.2.2.4 Processamento de dados

Com base na pesquisa bibliográfica sobre o processamento de dados de nuvem de pontos TLS, a Figura 15 ilustra as etapas sistemáticas, destacando as fases críticas e os procedimentos técnicos necessários para a análise eficaz destes dados.

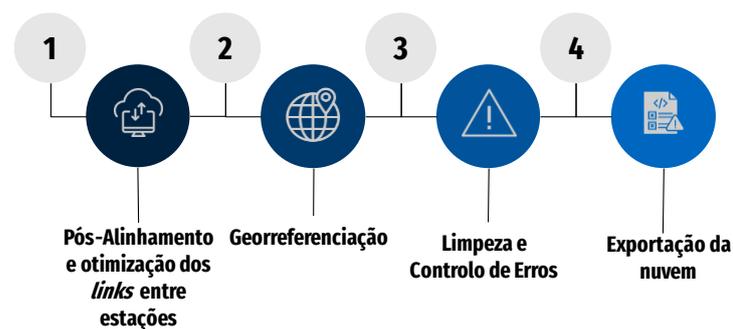


Figura 15: Fluxograma a descrever as etapas de processamento de dados LiDAR.

1) Pós-alinhamento e otimização dos *links* entre estações

Após o levantamento LiDAR, os dados são importados para o *Cyclone REGISTER 360*. Numa primeira fase, o utilizador deve verificar o alinhamento virtual entre nuvens e proceder aos seus ajustes, se necessário, como demonstrado na Figura 16. Para assegurar a melhor resolução

possível da nuvem de pontos, é essencial estabelecer *links* entre os diversos *scans* realizados. Este processo envolve a união entre as nuvens capturadas por diferentes *scans*, unindo todos aqueles que estejam na proximidade imediata dos restantes. Idealmente, o conjunto de *links* deve formar uma triangulação, sendo que, os *links* devem ser apresentados a cor verde, de modo a minimizar o erro (Bastonero et al., (2014)). A cor verde dos *links* indica que a ligação é forte e, por sua vez, o erro está minimizado. Quando esse mesmo *link* é amarelo, significa que a ligação entre os *scans* é fraca e, por isso, irá contribuir para o aumento do erro na nuvem de pontos.

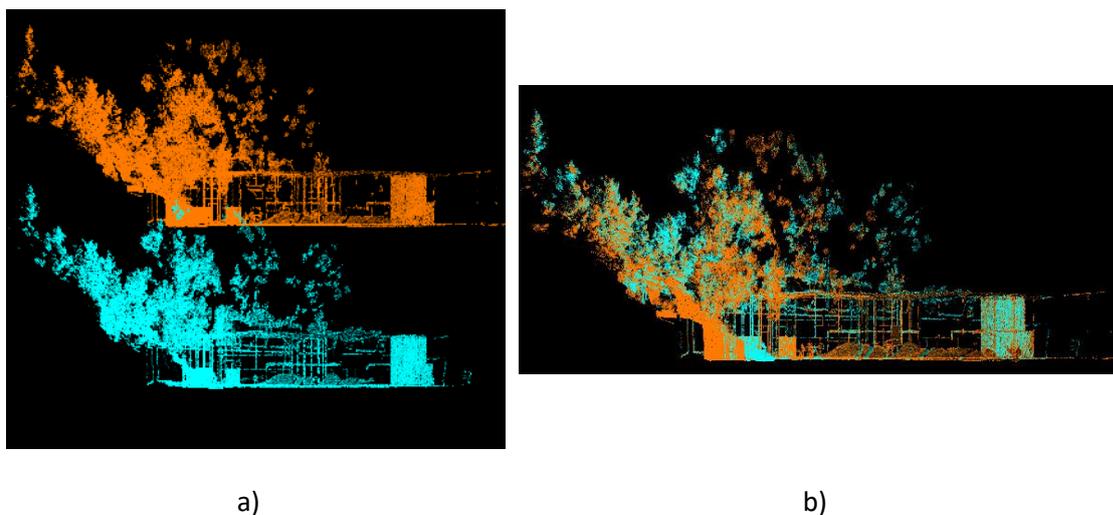


Figura 16: Processo de alinhamento entre duas estações no *Cyclone REGISTER 360*. a) nuvens aleatoriamente espaçadas. b) alinhamento das duas nuvens.

- 2) **Georreferenciação:** Como parte integral do levantamento, o topógrafo é responsável por levantar as coordenadas topográficas dos alvos colocados no terreno. Subsequentemente, no *software Cyclone Register*, esses pontos são devidamente identificados e marcados no *bundle*, garantindo que correspondam aos alvos com coordenadas conhecidas. O topógrafo deve registar num bloco de notas (ficheiro *.txt*) os GCP, com as respetivas coordenadas (x, y, z) que através da importação desse mesmo ficheiro para o *software* são automaticamente assumidas (Schneider, (2006, González-Collazo et al., (2024)).
- 3) **Limpeza e controlo de erros:** O *Cyclone Register* oferece a funcionalidade de selecionar e isolar regiões específicas da nuvem de pontos que sejam relevantes para o utilizador, removendo os pontos das restantes zonas. É imperativo consultar o relatório de erros gerado pelo *software*, assim como, a verificação do modelo gerado, através de diversos cortes e plantas (Bouziani et al., (2021)).

- 4) **Exportação da nuvem de pontos:** Por fim, surge a fase da exportação, em que tem de ser escolhido qual o formato pretendido para a nuvem de pontos (ex., *.las*, *.e57*, *.rcp*, entre outros). Além do ficheiro exportado, é gerado um relatório de erros que especifica os erros *link a link*.

2.2.3 Técnicas de fusão e alinhamento de dados

A fusão de nuvem de pontos provenientes de diferentes tecnologias é amplamente utilizada para maximizar as vantagens de cada método de reconstrução 3D. Enquanto o TLS é particularmente eficaz na captação de objetos terrestres de difícil acesso, sendo complementado pelo MLS para a captura de detalhes ao nível do solo, a fotogrametria proporciona maior detalhe visual ao modelo, sendo essencial pela sua captação de perspetivas superiores do objeto de estudo. A técnica de fusão envolve o alinhamento das nuvens com base em pontos de referência (coordenadas dos pixels) e a combinação dos pontos resultantes após a filtragem, onde são removidos os *outliers* (Liu et al., 2023). Um dos métodos mais utilizados para a fusão é o ICP (*Iterative Closest Point*) desenvolvido por Besl et al., (1992), que estabelece uma correspondência entre pontos de diferentes nuvens com base na minimização das suas distâncias. A Figura 17 demonstra como são estimados os pontos de correspondência e o centro geométrico das nuvens de pontos. De acordo com Bouziani et al., (2021), o processo pode ser sintetizado da seguinte forma: i) Pré-seleção dos pontos mais próximos entre as nuvens de pontos, recorrendo a uma subamostra para otimizar o tempo de processamento; ii) Utilização do algoritmo estrutural *kd-tree*, que organiza os pontos num espaço *k*-dimensional, facilitando a identificação de pontos comuns entre as nuvens para o alinhamento; iii) Exclusão de pares de pontos que vão introduzir erros e imprecisão na fusão, com base em critérios como pontos afastados com um *threshold*; iv) Definição de funções métricas que minimizam erros de alinhamento, visando melhorar a precisão do modelo final. Após o alinhamento, as nuvens de pontos são ajustadas de forma a coincidir com base na minimização das distâncias entre pontos, como se mostra na Figura 18.

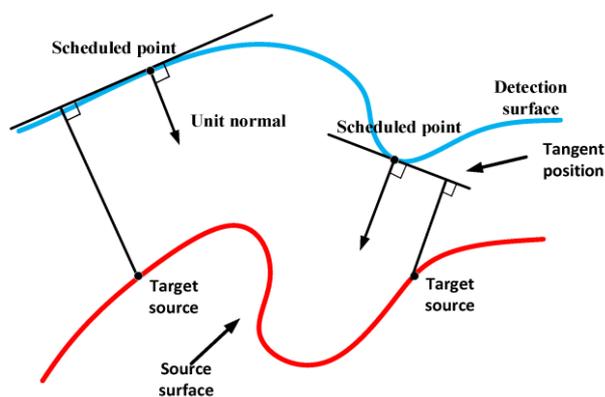


Figura 17: Método gráfico para localizar o centro geométrico de duas nuvens de pontos (adaptado de Cao et al., (2023).

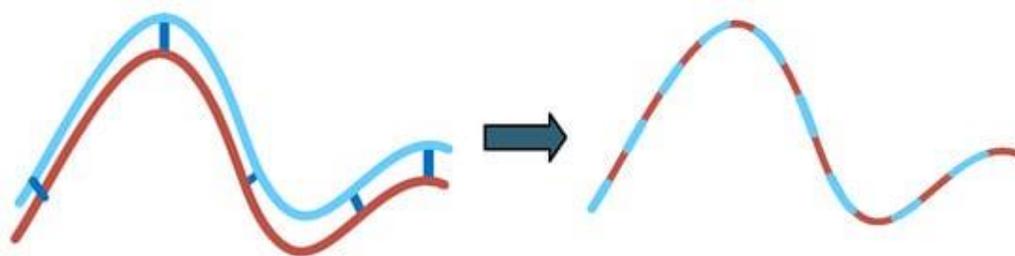


Figura 18: Resultado do alinhamento pelo algoritmo iterativo ICP (adaptado de Cao et al., (2023).

Diversos *software* de processamento utilizam o ICP para a fusão de nuvens de pontos. Bruno et al., (2022) e Alshwabkeh et al., (2023) utilizaram o *Agisoft Metashape* para integrar nuvens de pontos num sistema de coordenadas arbitrário, onde os dados de *laser scanner* são convertidos em imagens equiretangulares em formato .tif, com cada pixel correspondendo a um ponto da nuvem, contendo valores RGB e profundidade. As nuvens são então alinhadas com o ICP, sem a necessidade de georreferenciação através de GCPs. Alternativamente, Chatzistamatis et al., (2018), utilizam o *iTwin Capture Modeler*, que, à semelhança do *Agisoft Metashape*, também suporta a integração de nuvens com o método ICP. Já Luhmann et al., (2020) utilizaram o *software RealityCapture*, que se destaca pela capacidade de processar simultaneamente dados de fotogrametria e TLS, garantindo processamentos mais rápidos comparativamente a outros.

O processo de fusão exige a aplicação de técnicas de pós-processamento das nuvens de pontos para assegurar a qualidade de resultados. Nesse sentido, diversos autores propõem os seguintes métodos de validação:

- **Cloud-to-Cloud (C2C)**

Bouziani et al., (2021) utilizaram este método para comparar nuvens ao usar valores indicativos obtidos durante a aquisição. A técnica C2C é caracterizada por avaliar a distribuição dos pontos, desvios de superfície e a precisão geométrica dos pontos com recurso ao algoritmo Hausdorff. Este algoritmo mede a distância máxima entre dois conjuntos de pontos, permitindo a identificação de *outliers* na fusão. Na Figura 19a) está representado um esquema ilustrativo do funcionamento do C2C.

- **Multiscale Model to Model Cloud Comparison (M3C2)**

Fabris et al., (2023) descrevem o *plugin* M3C2, que permite o cálculo da distância entre duas nuvens de pontos já alinhadas, ao definir uma subamostra de pontos principais como referência. Esta ferramenta compara duas nuvens ao estimar a normal de cada ponto e calcular as distâncias entre pontos inscritos num raio definido, projetadas na direção da normal estimada (Son et al., 2020). Na Figura 19b) apresenta-se o processo gráfico da técnica M3C2.

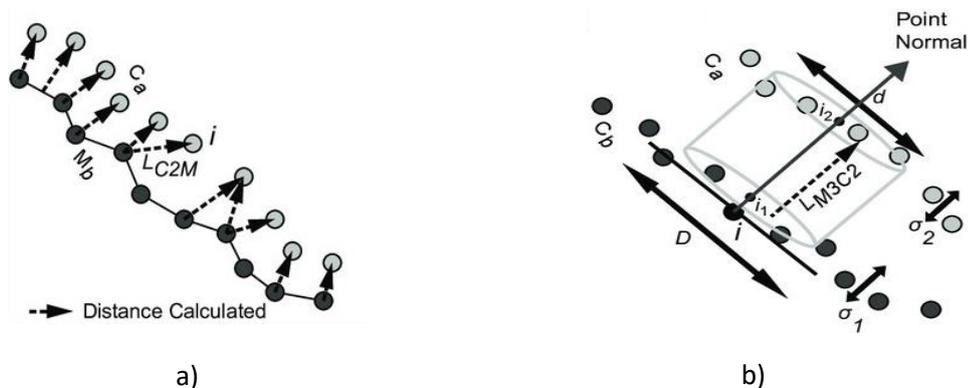


Figura 19: Diagramas conceituais das técnicas C2C e M3C2. a) Técnica C2C, onde as menores distâncias L_{C2C} entre C_a e M_b são calculadas e armazenadas. b) Técnica M3C2, é estimada a normal do ponto i e um cilindro com diâmetro d é utilizado para selecionar pontos em C_a e C_b . A distância L_{M3C2} entre dois pontos é medida ao longo da sua normal e armazenada (adaptado Barnhart et al., (2013)).

- **Cloud-to-Mesh Distance (C2M)**

Jiang et al., (2022) sugerem a função *Cloud-to-Mesh Distance*, disponível no *software* *CloudCompare*, que compara as nuvens de pontos com modelos 3D em malha. Este processo

mede a distância média entre as nuvens e o desvio padrão, permitindo uma avaliação detalhada da precisão da fusão.

- **Teste de Segmentação (RANSAC – *Random Sample Consensus*)**

Bouziani et al., (2021) e Chatzistamatis et al., (2018) aplicam o algoritmo RANSAC para segmentar as nuvens de pontos e identificar formas geométricas presentes nas nuvens de pontos, como ilustrado na Figura 20. Esta técnica iterativa auxilia a identificar e remover *outliers* focando-se nos pontos *inliers* que seguem o padrão geométrico do modelo (Li et al., 2024).

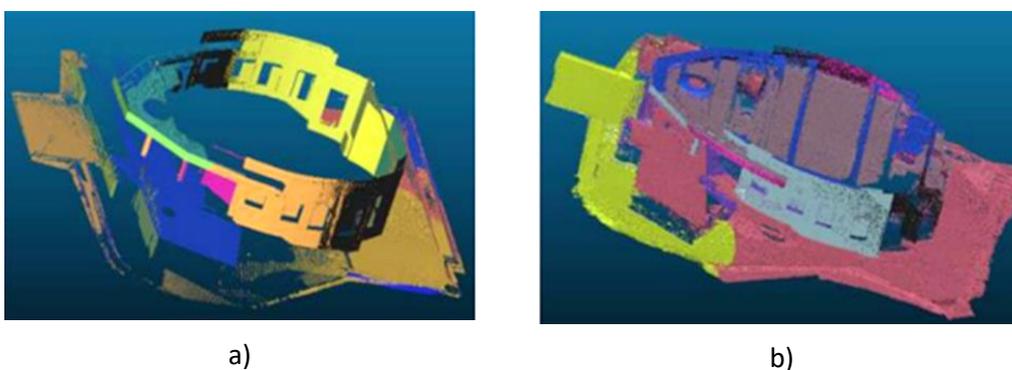


Figura 20: a) Exemplo de teste segmentação RANSAC para dados fotogramétrico; b) Teste de segmentação para dados TLS (adaptado de Bouziani et al., (2021)).

- **Distância de *Hausdorff***

A distância de *Hausdorff* é uma métrica que mede a maior das distância mínimas entre duas nuvens de pontos. Para cada ponto de uma nuvem, calcula-se a menor distância até o ponto mais próximo no segundo conjunto, sendo o valor final de *Hausdorff* o maior entre as distâncias mínimas. Esta técnica é bastante sensível à presença de *outliers* nas nuvens comparadas (Charbonnier et al., 2013). A Figura 21 apresenta um exemplo ilustrativo da métrica, demonstrando de que forma a menor distância entre pontos é calculada.

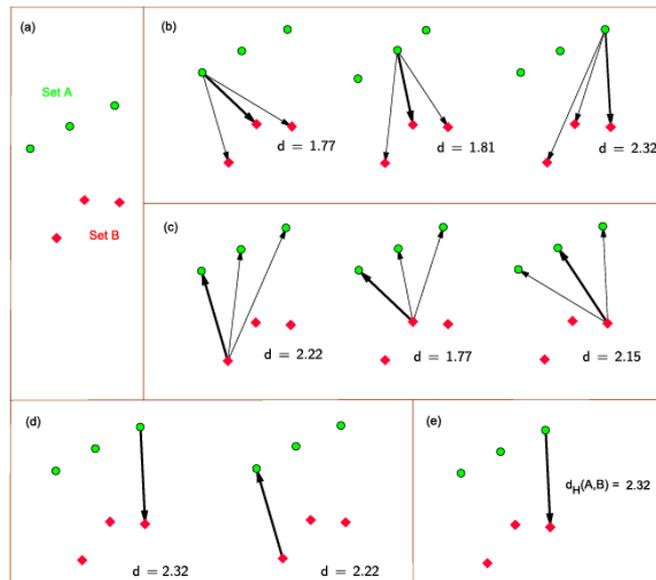


Figura 21: Exemplificação da distância de *Hausdorff* entre dois conjuntos de pontos. a) Conjuntos de pontos A e B; b) Cálculo da distância euclidiana de cada ponto do conjunto A para o ponto mais próximo no conjunto B; c) Cálculo da distância euclidiana de cada ponto do conjunto B para o ponto mais próximo no conjunto A; d) Distâncias máximas entre os dois conjuntos; e) Distância de *Hausdorff* definida como a maior dessas distâncias mínimas (adaptado de Charbonnier et al., (2013)).

2.3 Inteligência artificial

2.3.1 Enquadramento

A Inteligência Artificial (IA) é uma ferramenta revolucionária que tem vindo a ser integrada em diversas áreas. O conceito de máquinas inteligentes foi inicialmente proposto na década de 1950, através do trabalho pioneiro de Alan Turing na sua obra "*Computing Machinery and Intelligence*", onde ele levantou a questão: "Podem as máquinas replicar o comportamento humano de maneira convincente?". Passadas mais de sete décadas desde este pensamento, a IA evoluiu significativamente, e a sensação que prevalece é a de que estamos cada vez mais próximos de poder responder afirmativamente à questão proposta por Turing.

A inteligência artificial tem sido alvo de inúmeros estudos que impulsionaram significativamente a tecnologia. Contudo, foi apenas na década de 1980 que surgiram os primeiros desenvolvimentos relevantes em rede neuronais artificiais, ou em inglês *Artificial Neural Networks* (RNA). Estas redes definem-se como modelos computacionais inspirados no

funcionamento do cérebro humano e, são estruturalmente caracterizadas por conjuntos de camadas de «neurónios artificiais» interligados. Os neurónios são capazes de processar informação, permitindo assim, que as máquinas aprendam a partir dos dados fornecidos (Lu et al., 2012). Um dos principais avanços em tarefas de visão computacional surgiu na década de 1990 pelo cientista Yann LeCun que introduziu os primeiros conceitos de Redes Neurais Convolucionais (CNN – *Convolutional Neural Networks*). Essas redes são essenciais e eficazes para tarefas de reconhecimento de imagens e objetos (Huang et al., 2019). Apesar do seu potencial, a elevada exigência computacional desta tecnologia e a escassez de dados limitaram a evolução da IA durante várias décadas. Desde 2010, os avanços tecnológicos no processamento de dados computacionais têm sido fundamentais para alcançar o verdadeiro potencial da IA. A integração de grandes volumes de dados e o poder computacional permitiu o desenvolvimento de modelos artificiais em escalas nunca vistas (Marzouk et al., 2024).

Atualmente, IA define-se como a área da ciência da computação que se dedica ao desenvolvimento de sistemas capazes de realizar tarefas que normalmente requerem inteligência humana para a resolução de problemas complexos. Entre os domínios da IA encontra-se o *Machine Learning* (ML), ou Aprendizagem da Máquina. Como ilustrado na Figura 22 o ML permite que a máquina aprenda a partir de dados e melhore o seu desempenho a partir de experiências, sem necessidade de intervenção humana ou programação específicas. Recentemente, algoritmos de Aprendizagem Profunda (AP), ou em inglês *Deep Learning* (DL) têm desempenhado um papel crucial para estimular o desenvolvimento da IA (Huang et al., 2019); Kumar et al., (2021).

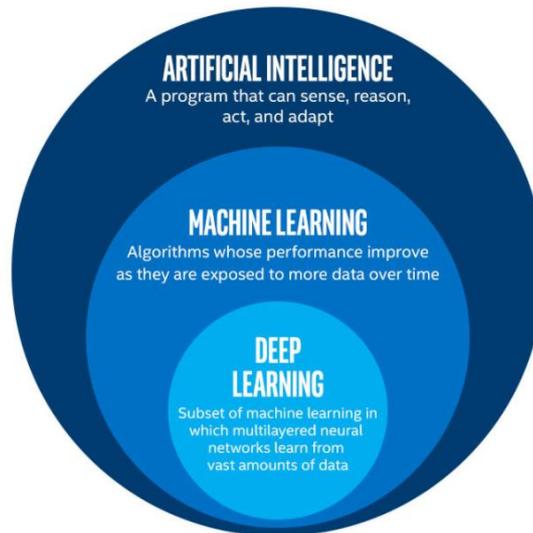


Figura 22: Inteligência Artificial, Machine Learning e Deep Learning (adaptado de Balodi, (2020).

Em engenharia civil, especialmente nos últimos anos, a integração da IA resultou no desenvolvimento de metodologias mais precisas e eficientes, sendo o *Structure Health Monitoring* (Monitorização da Saúde Estrutural) (SHM) uma das áreas que mais beneficia dessas inovações, com o uso de algoritmos de *Deep Learning* que permitem a detecção de danos e avaliação contínua da segurança de infraestruturas (Cha et al., 2024). Outras áreas que beneficiaram com a integração de IA foram a análise estrutural, otimização de projetos de construção, previsão de falhas em materiais, gestão de obra e, mais recentemente, desenvolvimento de cidades inteligentes (Marzouk et al., 2024);(Kumar et al., 2021). A incorporação da IA na AEC, transformará as abordagens e práticas de projetos e gestão de infraestruturas, estabelecendo novos padrões de segurança e eficiência, e moldando um futuro inovador e sustentável.

Os algoritmos de ML dividem-se em três categorias: aprendizagem supervisionada, não supervisionada e por reforço. Como o nome indica, os modelos de aprendizagem supervisionada são treinados com dados anotados, onde a saída de previsão é conhecida. Esta abordagem é amplamente utilizada para a resolução de problemas de previsão e classificação. Uncuoglu et al., (2022) desenvolveram um modelo de aprendizagem supervisionado com o intuito de estimar os custos de construção de um projeto, utilizando grandes conjuntos de dados históricos para auxiliar o modelo a realizar previsões precisas. No caso da aprendizagem não supervisionada, o modelo adapta-se e agrupa os dados com base em padrões e similaridades entre os objetos. Estes algoritmos são particularmente úteis em situações onde

as categorias ou padrões nos dados não são previamente conhecidos. Por fim, a aprendizagem por reforço envolve um algoritmo ou programa capaz de interagir com um ambiente de forma a aprender a tomar decisões. Esta técnica pode ser descrita como um “jogo de recompensas”, onde o algoritmo é recompensado ou penalizado com base em ações corretas ou incorretas, tendo sempre como objetivo a maximização das recompensas. Esta abordagem é potencialmente aplicável para o desenvolvimento de estratégias de otimização de redes urbanas de distribuição de água (Wang et al., 2024).

A otimização dos resultados e a performance dos modelos de ML é aprimorada pela incorporação de algoritmos estatísticos, tais como: o algoritmo Máquinas de Vetores de Suporte (SVM), que se caracteriza pela capacidade de gerar dados de alta dimensão – definidos como conjuntos de dados com um grande número de características ou atributos em relação ao número de observações – sendo particularmente eficaz em problemas de classificação. O principal objetivo deste algoritmo é encontrar um hiperplano que divide o espaço de características entre duas classes, maximizando a margem entre elas. Este hiperplano é definido por uma equação linear que permite a transformação de dados não linearmente separáveis num espaço de dimensão superior. Os algoritmos de Árvores de Decisão também são muito utilizados e têm o objetivo de gerar “caminhos” que levam a decisões, permitindo a previsão de categorias discretas ou valores contínuos. A estrutura hierárquica estabelece nós de decisão que se relacionam entre si. Cada nó da árvore representa uma decisão baseada numa característica específica.

O processo de desenvolvimento de um algoritmo de ML supervisionado geralmente envolve três etapas principais: i) **treino** onde o modelo é alimentado por um conjunto de dados (entradas) em formato de imagem, texto ou até dados numéricos sendo previamente anotados com as suas respectivas classificações. Após a receção aleatória das entradas, o modelo ajusta os seus parâmetros por meio de processos iterativos (épocas), de forma que, este último consiga produzir previsões (saídas) que correspondem às anotações reais; ii) a **validação** é responsável por ajustar os hiperparâmetros do modelo, como a taxa de aprendizagem e o número de camadas, assim como, evitar fenómenos de *overfitting*, que se refere ao ajuste excessivo do modelo aos dados de treino, resultando na perda de capacidade de generalizar para novos dados. O subconjunto de dados de validação não é utilizado no treino do modelo, mas sim para monitorizar o seu desempenho; iii) **teste**, cujo objetivo é avaliar a performance final do modelo, garantindo que o modelo não só ajustou corretamente os dados de treino, mas também é capaz de realizar previsões precisas em dados nunca vistos.

2.3.2 Redes neurais

O *Deep Learning* (DL) é uma subcategoria do *Machine Learning* que se distingue pelo uso de *Deep Neuronal Networks* (DNN), ou redes neurais profundas. O termo “*deep*” refere-se ao acréscimo de camadas ocultas entre as camadas de entrada e de saída de uma rede neuronal (Figura 23). Ao contrário do ML, que abrange grande diversidade de algoritmos e técnicas que permitem que as máquinas aprendam a partir de dados e equações predefinidas, a Aprendizagem Profunda foca-se especificamente nas DNNs para determinar padrões básicos dessa informação e, posteriormente, ensina os computadores a desenvolverem-se através da identificação de padrões em camadas de processamento (Chagas, 2019). As DNN têm capacidade de reconhecer e aprender automaticamente características importantes a partir dos dados não-estruturados. Uma das principais vantagens das DNN é a capacidade de aprender representações complexas dispensando a necessidade de criar manualmente essas características (Kumar et al., (2021) ; Wang et al., (2022).

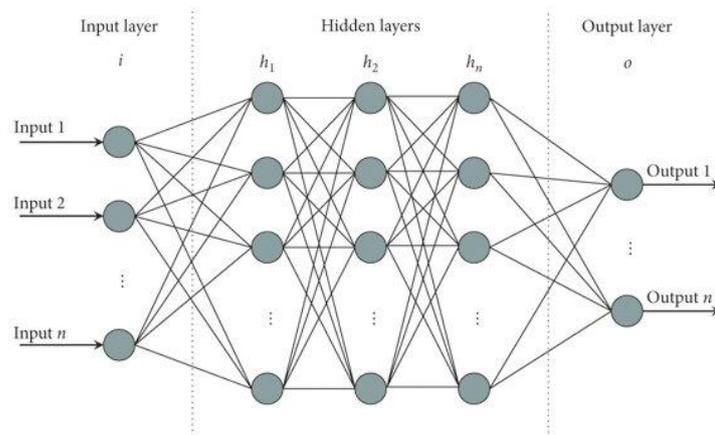


Figura 23: Exemplo da arquitetura de uma rede neuronal artificial profunda (adaptado de (Yao et al., 2021).

As redes neurais não são todas iguais, pelo que diferentes arquiteturas têm sido desenvolvidas para atender a necessidades específicas. A compreensão plena das arquiteturas, assim como o funcionamento das redes, requer o conhecimento prévio do conceito de neurónio artificial e da sua composição interna. A Figura 24 apresenta a esquematização simplificada de um neurónio artificial (k), destacando: i) **dados de entrada (inputs)** (x_1, x_2, \dots, x_n) para alimentar o neurónio; ii) **pesos sinápticos** – (w_{ki}) que são aplicados a cada entrada, ajustando-a de acordo com a importância relativa de cada entrada, representada pelo peso sináptico correspondente (w_{ki}); iii) a **função soma** – (Σ) é aplicada após a ponderação de cada entrada

pelos seus respetivos pesos sinápticos. A soma ponderada (u_k) é o resultado da combinação linear de todas as entradas com seus pesos correspondentes; iv) **viés** – (b_k) parâmetro externo adicional à soma ponderada que permite ajustar a saída do neurónio. Os viés ajudam a melhorar a convergência e, por isso, a capacidade de aprendizagem de uma rede neuronal; v) a **função de ativação** – ($\varphi(\cdot)$) é responsável por introduzir a não-linearidade ao modelo, permitindo assim que a rede aprenda padrões complexos de dados. Esta decide se o neurónio deve produzir saída ou não; vi) **saída** (output) – (y_k) é resultado da função de ativação que pode, ou não ser transmitido aos neurónios subsequentes interligados. (Haykin, (2009), Pamuncak et al., (2023)).

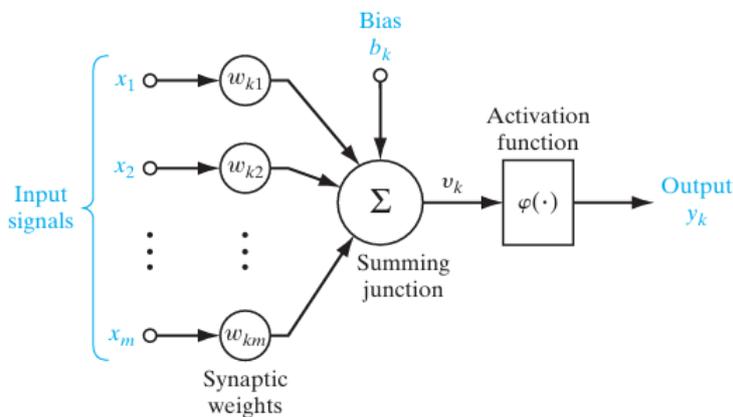


Figura 24: Modelo não-linear de um neurónio artificial (adaptado de Haykin, (2009)).

Em termos matemáticos pode-se descrever então:

Soma ponderada das entradas com os pesos sinápticos atribuídos.

$$u_k = \sum_{i=1}^m w_{ki} x_i \tag{1}$$

Aplicação do viés.

$$v_k = u_k + b_k \tag{2}$$

Output após a aplicação de função ativação.

$$y_k = \varphi(u_k + b_k) \tag{3}$$

Em redes de aprendizagem supervisionada, é comum o uso de algoritmos de *backpropagation* que ajustam os pesos das conexões da rede ao calcular a diferença entre a saída prevista e a real, com o objetivo de minimizar a função de custo (Marzouk et al., 2024). Dessa forma, a rede consegue aprender padrões complexos a partir dos resultados, melhorando a capacidade de acertar as suas previsões. Estes algoritmos *backpropagation* são tipicamente utilizados em redes *feedforward*, onde a informação é propagada numa única direção, da camada de entrada até a camada de saída, sem que ocorra qualquer retroalimentação (Haykin, 2009). A incorporação deste algoritmo pode resultar no desvanecimento gradual do gradiente, onde os gradientes calculados se tornam pequenos à medida que avançam pelas camadas iniciais que praticamente durante o treino, não causam atualização nos pesos dessas camadas.

2.3.3 Redes Neurais Convolucionais (CNN)

As Redes Neurais Convolucionais (CNN) têm-se revelado altamente eficazes no processamento hierárquico de dados estruturados em matrizes, como é o caso das imagens. Estas redes são bastante utilizadas em tarefas de visão computacional, uma vez que conseguem processar imagens como entradas, armazenando os valores dos pixel na forma de matriz. As redes CNN através de operações de convolução, permitem a extração de características locais de uma imagem, como formas e texturas que depois de combinadas, auxiliam a tarefas de detecção e segmentação de objetos em imagens (Wang et al., 2024).

De modo geral, uma CNN consiste em diversas camadas convolucionais, seguidas por camadas *pooling*, pela camada de *flatten* e, finalmente, pelas camadas *fully connected*, como mostra a Figura 25. A camada convolucional é responsável por extrair características relevantes de uma imagem por meio de filtros (*kernels*). Esses filtros percorrem a imagem, e em cada posição, os valores dos *pixels* na imagem são multiplicados, elemento a elemento, pelos valores do *kernel* numa operação de produto escalar, cujo resultado é um único valor que destaca uma característica específica da imagem. Este processo é repetido para cada posição possível da imagem, e os resultados são organizados num mapa de características. Em seguida, as camadas de *pooling* são acionadas com o objetivo de reduzir a dimensionalidade dos dados dos mapas de características, melhorando a eficiência da rede e reduzindo as regiões de interesse. Após essas camadas, as imagens são transformadas de um volume, em que a sua altura e largura correspondem às dimensões da imagem, e a sua profundidade corresponde ao número de canais de cor, para um vetor unidimensional por meio da camada de *flatten*, preparando assim os

dados para serem processados pelas camadas *fully connected*. Por fim, as camadas *fully connected* recebem as características extraídas e processadas pelas camadas anteriores. Nessas camadas, cada neurónio está conectado a todos os neurónios da camada anterior, permitindo que a rede combine as informações locais e globais para realizar a classificação ou outra tarefa específica desejada, como a identificação de objetos em uma imagem (Radu et al., 2020); Shao et al., (2024).

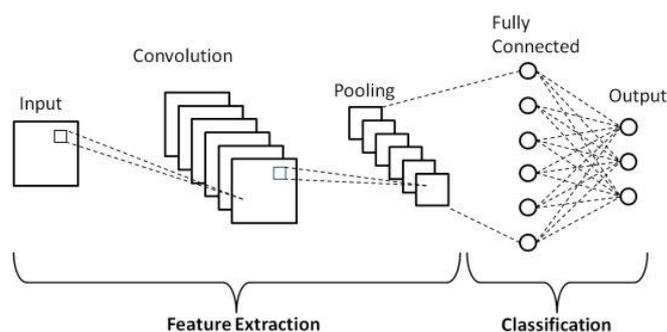


Figura 25: Diagrama esquemático de uma arquitetura básica de rede neuronal convolucional (CNN) (adaptado de Phung et al., (2019).

Um exemplo pioneiro da utilização das CNN é o trabalho de Krizhevsky et al. (2012). Neste trabalho os autores desenvolveram a AlexNet, caracterizada por uma rede composta por várias camadas convolucionais e totalmente conectadas. Esta rede foi utilizada no ImageNet Challenge para classificar imagens em 1.000 categorias distintas, obtendo resultados de elevada precisão. A AlexNet destacou-se pela sua capacidade de extrair automaticamente características relevantes das imagens revolucionando assim o mundo da visão computacional. Já na área da engenharia civil, as CNN têm sido amplamente exploradas, especialmente em tarefas de análise de imagens, inspeção de estruturas, deteção de anomalias e monitorização de estruturas. Zhang et al., (2018) desenvolveram a arquitetura *CrackNet2*, baseada em CNN que assegura precisão ao nível do pixel na deteção automática de fissuras em pavimentos de asfalto 3D. A Figura 26 apresenta as diversas etapas da metodologia. Noutro estudo, Huang et al., (2018), aplicaram uma CNN para a deteção de fissuras em pontes de betão. A rede, treinada com um extenso conjunto de imagens de pontes, conseguiu distinguir entre superfícies intactas e fissuradas. Paralelamente, Cha et al., (2017) apresentam uma abordagem baseada em variantes CNN como a *Region-Based CNN*, ou R-CNN, para a deteção múltipla de diversos tipos de danos estruturais. Sendo o modelo capaz de identificar danos, como fissuras, corrosão e deformações.

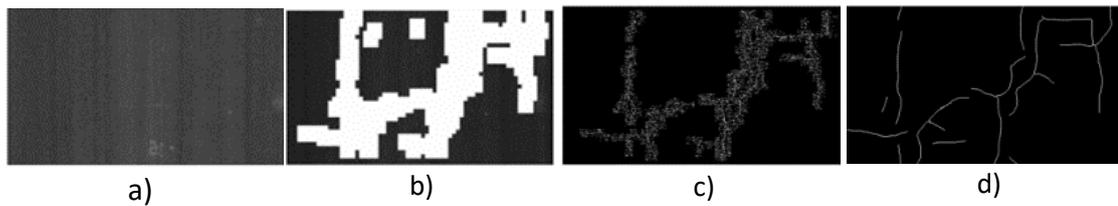


Figura 26: Pipeline da arquitetura CrackNet2 para a detecção de fissuras. a) Imagem original; b) resultados após o primeiro de dois passos de pré-classificação; c) Resultados da segmentação por blocos; d) Resultados da detecção de curvas de fissuras (adaptado de Zhang et al., (2018).

As redes neurais não são criadas apenas para desempenhar tarefas de monitorização ou inspeção de estruturas. Ding et al., (2018) desenvolveram um modelo híbrido de *deep learning* que integra redes neurais convolucionais (CNN) e redes de memória de curto longo prazo (LSTM) para identificar automaticamente comportamentos inseguros dos funcionários nos estaleiros de obra. O modelo de CNN foi treinado para reconhecer comportamentos que pudessem representar riscos à segurança, como a ausência de equipamento de proteção ou a prática de ações inseguras. Compreender a estrutura e o funcionamento das redes CNN é essencial para acompanhar os desenvolvimentos recentes inerentes a esta tecnologia. Na seguinte enumeração, explorar-se-á em maior profundidade cada um desses componentes, analisando como funcionam e como podem ser ajustados para melhorar o desempenho das CNN em diferentes aplicações de visão computacional.

- **Camadas convolucionais**

Como já referido, as camadas convolucionais são usadas para extrair características relevantes das imagens de entrada através da aplicação de filtros. Os *kernels* são submatrizes de números que se deslocam pela imagem, multiplicando os valores dos pixels pelos valores do filtro e somando os resultados. A Figura 27 demonstra o processo esquematicamente. Em termos práticos, é através destas camadas que a rede aprende a “ver” e interpretar padrões visuais. Uma única camada convolucional pode conter vários filtros, e ao adicionar mais camadas à rede, esta torna-se mais profunda e complexa.

No processo inicial de uma rede CNN, os valores dos filtros são configurados de forma aleatória, sendo que o objetivo da rede é aprender os valores ideais dos filtros através do treino. O número de filtros e o tamanho do filtro são parâmetros que podem ser ajustados para influenciar o desempenho e a eficiência da rede (Marzouk et al., 2024). O tamanho do *kernel* define o tamanho da *subarray* que será aplicada à matriz de entrada e a profundidade do filtro

é igual à profundidade da entrada ou do mapa de características, enquanto a largura e altura do filtro são sempre iguais ou menores que as matrizes de entrada. Um dos hiperparâmetros que deve ser equacionado na formação de uma rede CNN é o *stride*, que define o modo como o *kernel* percorre a matriz de entrada nas direções de largura e altura. Com um *stride* maior, os recursos computacionais são reduzidos, uma vez que o filtro é aplicado menos vezes; porém, isso implica a perda de capacidade de processar características mais complexas. Para evitar perda de informação devido ao *stride*, bem como manter o tamanho da saída equivalente ao da imagem de entrada, é comum aplicar o *padding*. O método mais utilizado é o *zero-padding*, que consiste no acréscimo de *pixels* de valor 0 (preto) nos bordos da imagem. Isto implica a expansão da matriz de entrada, permitindo que o *kernel* tenha mais posições de aplicação, preservando assim mais detalhes na saída (Cha et al., 2024).

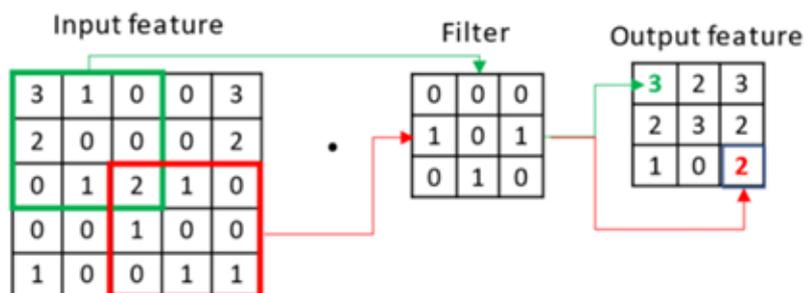


Figura 27: Operação de convolução com aplicação de filtro (3x3) (adaptado de Cha et al., (2024).

- **Camadas *pooling***

Após a extração de características por meio das camadas convolucionais, normalmente aplicam-se as camadas de *pooling*. A principal função dessas camadas é de reduzir a dimensionalidade dos mapas de características. Este processo envolve o resumo da informação de várias unidades adjacentes num único valor o que torna a representação mais otimizada computacionalmente e menos sensível à localização exata das características dentro da imagem, ou por outras palavras, a rede deixa de se concentrar nas posições exatas das características e passa a captar a presença dessas características numa região mais ampla (Radu et al., 2020). Existem diferentes tipos de *pooling* que podem ser utilizados, cada um com as suas próprias características e aplicações, sendo as estratégias mais comuns: o *max pooling*, que seleciona o valor máximo de uma região predefinida (ver Figura 28); o *average pooling*, que consistem em calcular a média de valores na região de interesse; e o *min pooling*, que seleciona o valor mínimo numa região e define-o como saída (Pamuncak et al., 2023).



Figura 28: Exemplo de atuação de uma camada max pooling (adaptado de Almeida et al., (2020)).

- **Camadas fully connected**

As camadas *fully connected* são aquelas em que cada neurónio está conectado a todos os neurónios da camada anterior. Pode-se descrever o processo como uma imagem de entrada que passa pela rede e retorna como um conjunto de matrizes de características, que são comprimidas num único vetor (Radu et al., 2020). Este vetor é então passado para as camadas *fully connected* com o objetivo de combinar as características locais identificadas ao longo da rede, culminando numa decisão final, como a classificação de uma imagem e deteção de objetos. Devido à sua capacidade de processar e extrair características significativas das imagens, as redes CNN são especificamente adequadas para tarefas de visão computacional. A deteção de objetos em imagens representa uma das ferramentas emergentes nesse campo, e a utilização de arquiteturas como o YOLO (*You Only Look Once*) revolucionou a forma como as máquinas percebem as imagens. Ao combinar a precisão e a profundidade das CNNs com a velocidade e eficiência, o YOLO possibilita a deteção de objetos em tempo real.

2.3.4 Deteção e segmentação em imagens com o YOLO

A deteção de objetos e segmentação de imagens são ferramentas essenciais em diversas áreas da visão computacional. Entre os métodos mais utilizados para essas tarefas está a arquitetura YOLO (*You Only Look Once*), reconhecida pela sua rapidez e precisão sendo um modelo de aprendizagem supervisionada. Ao contrário de outras redes, o YOLO identifica objetos em imagens com uma única passagem na rede, o que otimiza o tempo de processamento.

A arquitetura do YOLO combina operações avançadas de convolução e processamento de dados, permitindo identificar e segmentar múltiplos objetos com precisão (Wang et al., 2024), Zhang et al., (2024). O YOLO utiliza redes CNN como arquitetura base da rede para a deteção

de objetos. Tal como as CNN, o funcionamento do YOLO consiste na divisão da imagem de entrada numa grade, sendo que, para cada célula, o modelo identifica e classifica o objeto ao mesmo tempo que, desenha uma caixa delimitadora (*bounding box*) (BB) que delimita o objeto. Essa abordagem permite que o modelo faça previsões simultâneas para várias classes, otimizando o tempo de processamento (Zhang et al., 2024). Tal como representado na Figura 29, a arquitetura do YOLO é composta por três componentes principais: i) o *backbone*, que é responsável pela extração de características da imagem; ii) o *neck*, que combina essas características em diferentes escalas e pesos; iii) o *head*, que prevê as inferências finais. O módulo *head* tem como objetivo definir na imagem as *bounding boxes*, a localização, o tamanho, classificação e a confiança da previsão.

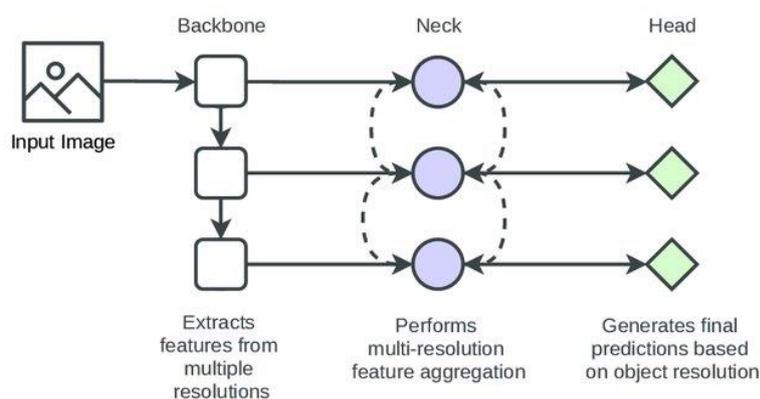


Figura 29: Modelo de detecção YOLO composto por *backbone*, *neck*, *head* (adaptado de Kateb et al., (2021).

As versões mais recentes, como o YOLOv8, introduzem melhorias significativas, especialmente com atualizações no *backbone*. É exemplo, a incorporação do CSPDarknet53, utilizando a *Cross Stage Partial Network* (CSPNet) que se foca em otimizar o fluxo de gradiente para melhorar o desempenho sem duplicar informações (Wang et al., (2020). Esta arquitetura divide as características de entrada em duas partes, permitindo que um bloco de características seja direcionado para a saída da rede, enquanto o restante é processado em camadas mais profundas (Casas et al., 2024). Essa estratégia reduz os recursos computacionais necessários sem comprometer a capacidade de aprendizagem profunda das características visuais. Outra novidade do YOLOv8 é o desenvolvimento do componente *anchor-free head* que se refere ao método de previsão final. Noutras versões, *anchor boxes* predefinidas eram usadas para prever a localização e o tamanho do objeto, porém, no YOLOv8 a rede calcula diretamente as coordenadas das caixas durante a inferência (Ultralytics, 2024). Recentemente, Zhang et al., (2024) desenvolveram o modelo YOLOv8-CM com a integração de mecanismos de atenção,

como *Convolutional Block Attention Module* (CBAM) para melhorar a precisão na detecção e segmentação de defeitos em túneis. Este módulo permite que a rede concentre a sua atenção em características relevantes, auxiliando o modelo a prever em ambientes com elevado ruído e sobreposições. A Figura 30 representa a aplicação prática da metodologia pelos autores com um exemplo de inferência com a detecção múltipla de anomalias num túnel.

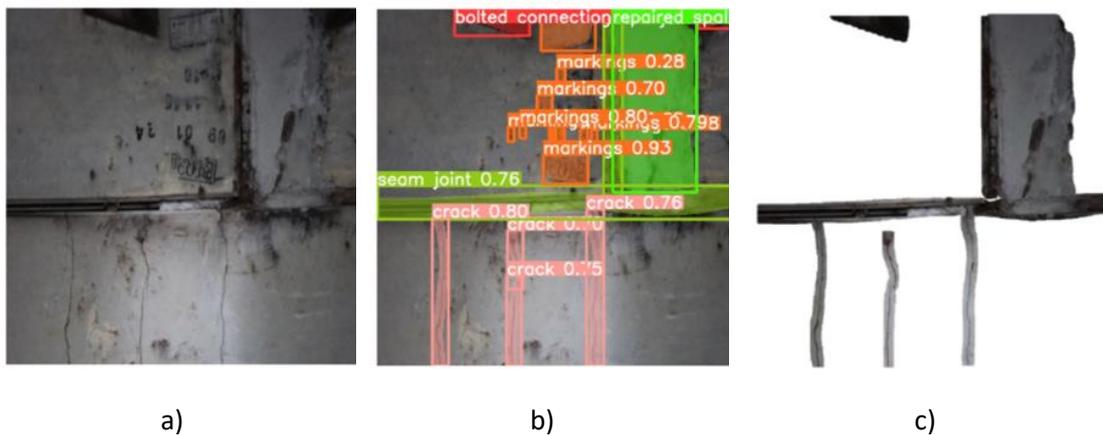


Figura 30: Segmentação com o YOLOv8-CM. a) Imagem original; b) Imagem inferida com o YOLOv8-CM; c) Destaque dos resultados da máscara.

- **Segmentação de instâncias (YOLOv8-SEG)**

A variante YOLOv8-SEG, projetada para segmentação de instâncias, além de detetar objetos e prever a BB também cria uma máscara de segmentação (*mask*) (M) para cada objeto detetado. Segundo Qi et al., (2024), as máscaras de segmentação no YOLOv8-SEG são geradas pela arquitetura *Proto module*, que combina coeficientes de máscara e módulos de deteção para criar máscaras correspondentes aos objetos identificados. Esta arquitetura divide a tarefa de segmentação em duas partes. Por um lado, a ramificação protótipo, onde o modelo prevê máscaras genéricas com a resolução da imagem de entrada, sendo o processamento realizado por camadas de convolução 2D seguidas de *upsampling* (aumento da resolução de uma imagem). Ao mesmo tempo, a ramificação de coeficientes de máscara que trabalha em paralelo com o anterior e gera coeficientes numéricos cada vez que o modelo deteta uma instância de forma a ajustar a *mask* protótipo. Juntas geram as máscaras finais de cada instância detetada.

Diversos autores têm desenvolvido trabalhos com a aplicação da variante YOLOv8-SEG no âmbito da AEC. Por exemplo, Rochefort-Beaudoin et al., (2024) desenvolveram o inovador YOLOv8-TO para reconstruir geometrias complexas de forma visual e precisa. Esta metodologia

é particularmente eficaz para interpretar distribuições de densidade ótima e convertê-las em representações paramétricas que podem ser exploradas em ferramentas CAD para design e fabrico. A Figura 31 apresenta a reconstrução de geometrias com o modelo YOLOv8-TO.

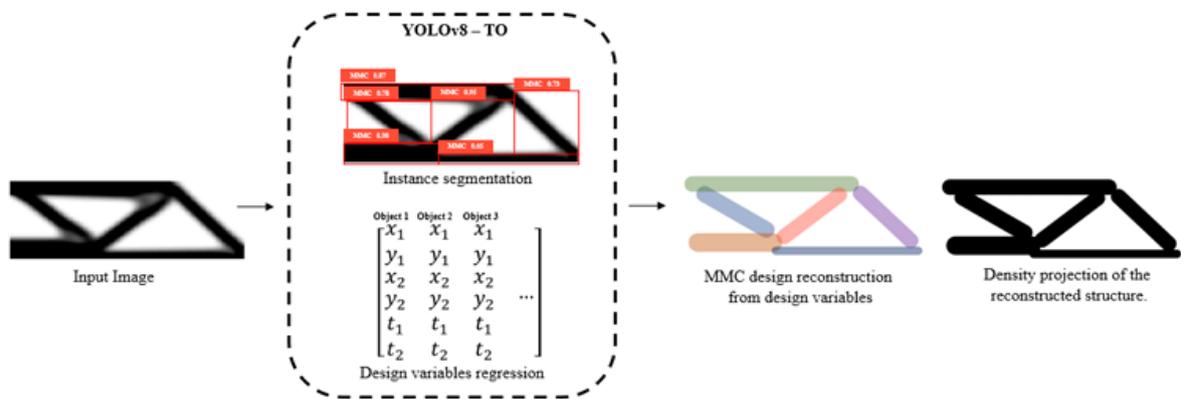


Figura 31: Processo de engenharia reversa de uma distribuição de densidade otimizada como uma abordagem de segmentação de instâncias (adaptado de Rochefort-Beaudoin et al., (2024).

Noutra abordagem Casas et al., (2024), desenvolveram um estudo comparativo para tarefas de segmentação de danos de corrosão em estruturas metálicas utilizando diferentes versões do YOLO, no caso YOLOv5 e YOLOv8 como demonstrado na Figura 32. Os autores verificaram que o YOLOv8 é superior em diversas métricas de precisão, realçando cenários de elevada complexidade, como sobreposições e aumentações. Computacionalmente, o YOLOv8 também apresenta uma melhor performance e tempo de inferência menor.

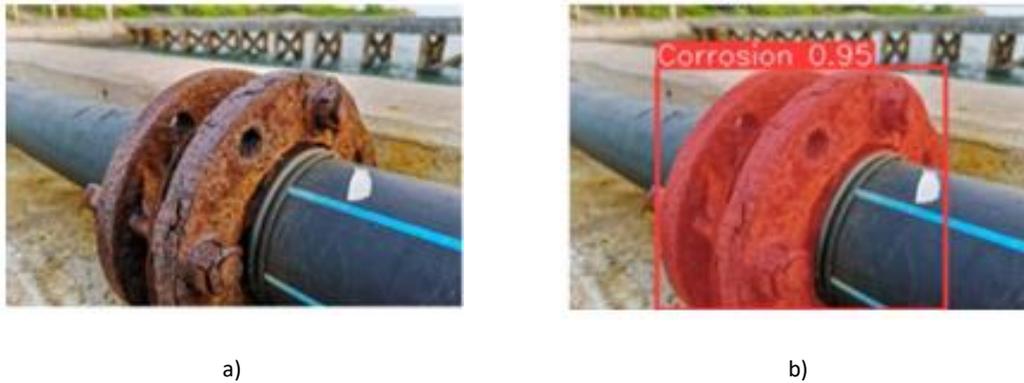


Figura 32: Exemplo de inferência para detecção de corrosão com o YOLOv8-SEG. a) imagem original; b) máscara gerado pelo modelo com grau de confiança 95%. (adaptado de Casas et al., (2024)).

Noutro exemplo, Wu et al., (2023) desenvolveram um modelo LCA-YOLOv8-seg (*Lightweight Channel Attention YOLOv8-SEG*) a partir de imagens submersas de alta resolução, capturadas por veículos operados remotamente (ROVs) durante a inspeção de fissuras em barragens. Este método utiliza uma arquitetura inovadora de *backbone*, denominada LCANet, projetada especificamente para a detecção de fissuras em pontes e barragens (Figura 33). Quando combinada com um novo ramo de máscara de protótipo, denominado ProtoC1, permite gerar máscaras de segmentação de danos de forma precisa.

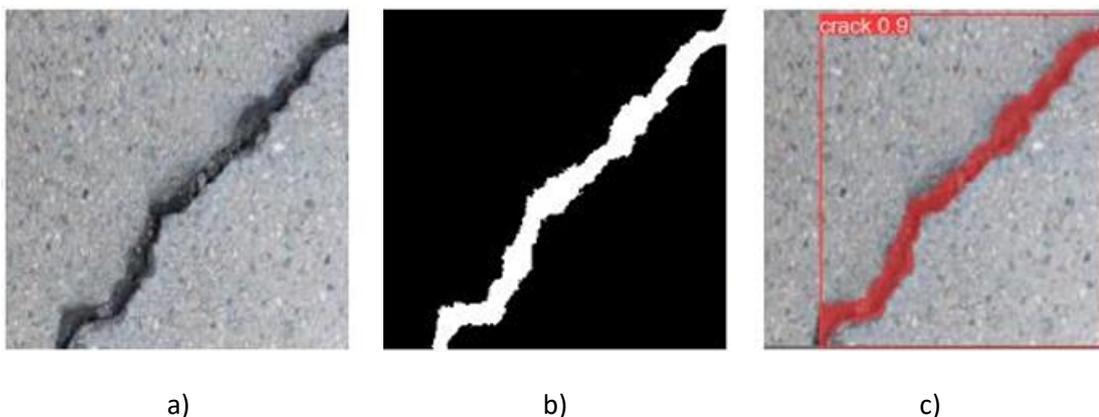


Figura 33: Exemplo de segmentação de uma fissura com o YOLOv8-SEG. a) Imagem original; b) imagem em verdadeira grandeza; c) resultado da inferência com máscara a vermelho (adaptado de Wu et al., (2023)).

- **Oriented Bounding Box**

As caixas delimitadoras orientadas (*Oriented Bounding Boxes* - OBB) são uma variação das tradicionais caixas delimitadoras alinhadas aos eixos (*Axis-Aligned Bounding Boxes* - AABB) são especialmente concebidas para a detecção de objetos orientados. Estas são particularmente úteis em casos onde os objetos não estão alinhados horizontalmente ou têm formas irregulares. As OBBs oferecem um ajuste mais preciso ao objeto, reduzindo a quantidade de espaço não ocupado que uma AABB normalmente oferece, permitindo uma detecção mais precisa e reduzindo a sobreposição desnecessária (Sabino et al., 2023); Wang et al., (2019).

Apesar dos recentes desenvolvimentos sobre a implantação de OBBs em modelos de detecção, o seu cálculo é mais complexo em comparação com AABBs devido à necessidade de considerar a rotação do objeto. Isso obriga à utilização de técnicas avançadas de otimização para determinar a orientação ótima de cada OBB (Zhou et al., 2024). Além disso, o fenómeno de ambiguidade de orientação é frequente em objetos com forma simétrica ou irregulares, já que, múltiplas orientações podem parecer igualmente válidas. Por fim, as descontinuidades são uma componente importante que deve ser considerada no desenvolvimento de um modelo. O problema surge principalmente durante a rotação contínua de um objeto para além de um ângulo crítico. Se um modelo for treinado com imagens de um objeto que é submetido a rotações, as mudanças abruptas na orientação da OBB podem resultar em erros ou inconsistências na detecção (Xiao et al., 2024).

A Figura 34 representa as descontinuidades comuns na representação de OBBs, esquematizando os quatro tipos principais de problemas que podem surgir durante a detecção de objetos orientados: a) Descontinuidade de rotação, a representação de ângulo agudo limita o ângulo de rotação das OBBs dentro de um intervalo de $\frac{\pi}{2}$, neste exemplo: $\left[-\frac{\pi}{4}, \frac{\pi}{4}\right]$. A OBB1 vermelha e a OBB2 azul são semelhantes, porém as suas representações são significativamente diferentes; b) Descontinuidade da proporção de aspeto, a representação de borda longa determina o ângulo de rotação θ pelo lado mais longo e pelo eixo XX. Uma pequena perturbação na proporção do aspeto das OBBs quadradas causará erros de representação; c) *Decoding incompleteness* ou Incompletude de Decodificação, onde as OBBs não podem ser representadas de forma precisa e completa devido à limitação imposta pelas categorias fixas do método CSL (*Classification-based Segmentation Learning*); d) *Decoding ambiguity*, como os quadrados com diferentes ângulos de rotação podem corresponder à mesma distribuição gaussiana, a orientação dos quadrados decodificados será ambígua.

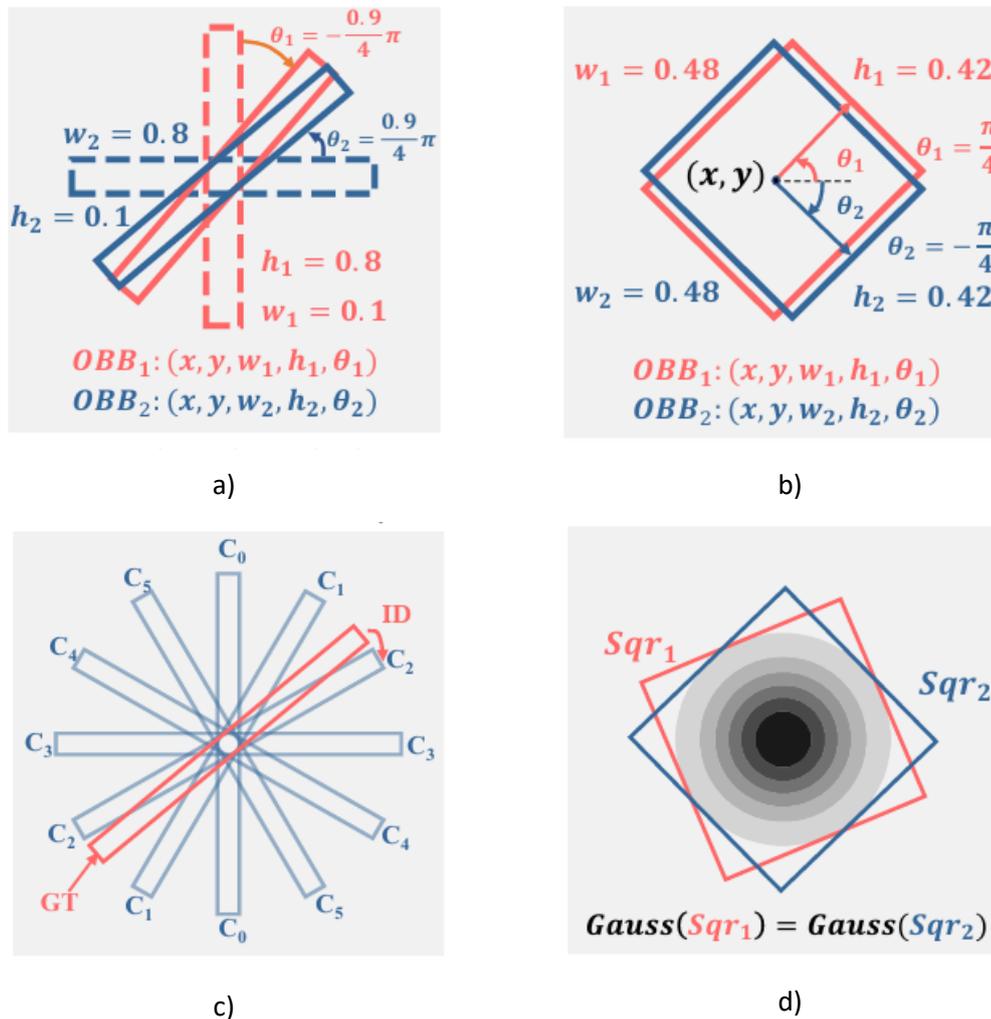


Figura 34: Exemplos de descontinuidade em OBBs. a) Descontinuidade de rotação; b) Descontinuidade da proporção de aspecto; c) *Decoding incompleteness*; d) *Decoding ambiguity* (adaptado de Xiao et al., (2024)).

Diversos autores apresentam metodologias para mitigar as inconsistências inerentes às OBBs. Zhu et al., (2024) apresentam a técnica de Análise de Componentes Principais (PCA) para determinar a orientação principal de um objeto. Esta técnica estatística é utilizada para reduzir a dimensionalidade dos dados, preservando as características essenciais dos mesmos. Ao aplicar a PCA, a orientação dos dados de um objeto é identificada de modo que a OBB seja alinhada com as principais direções de variação. Este método permite que a OBB seja corretamente ajustada à forma do objeto. Noutra abordagem, Xiao et al., (2024) introduzem as *Continuous Oriented Bounding Boxes (COBB)* para mitigar as descontinuidades frequentes nas OBBs, sendo um método muito eficaz porque funciona como um *plugin* externo que é aplicado

após os resultados do treino. Este método utiliza nove parâmetros derivados de funções contínuas que incluem o centro (x_c, y_c) e as dimensões (w, h) da *bounding box*, uma razão de deslizamento (r_s) e quatro parâmetros referentes aos scores de IoU (Interseção sobre União) (s_0, s_1, s_2, s_3) . A partir do princípio de semelhança de triângulos são definidas quatro configurações distintas para a OBB de um objeto, com a variação da razão de deslizamento e transformações geométricas, conforme representado na Figura 35. Para cada candidato determina-se um score de IoU que mede a precisão da sobreposição entre a OBB candidata e a OBB *ground truth* (anotações em ambiente de treino). A OBB com maior *score* IoU é selecionada como a representação mais precisa do objeto.

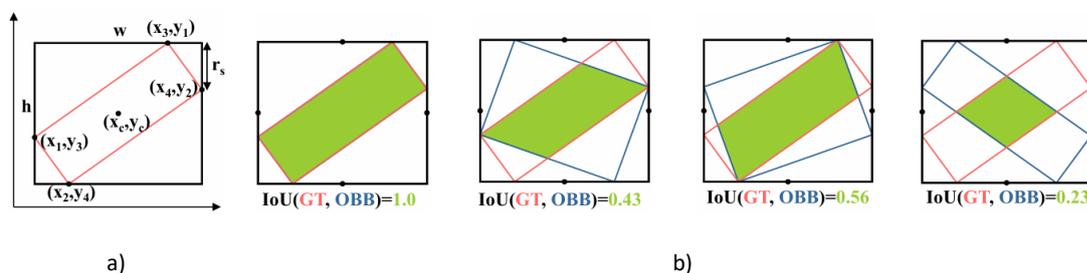


Figura 35: Esquematização do método COBB em comparação com HBB do objeto. a) Parâmetros base da OBB para um exemplo em que $(w > h)$; b) Quatro configurações candidatas para a OBB do objeto e respectivos *scores* IoU (adaptado de Xiao et al., (2024)).

Ao invés de se basear apenas em parâmetros geométricos das caixas delimitadoras para a representação de rotações, Wang et al., (2024) introduzem o método alternativo *Bounding Box Vectorization*. Este método representa cada BB como um conjunto de vetores ortogonais, que definem características do objeto importantes, como arestas e orientações. Para avaliar a precisão das *bounding boxes*, os autores propõem uma regressão baseada no coeficiente de Tanimoto, métrica de similaridade da *bounding box* prevista e a *ground truth*. Além disso, é incluída uma função de perda *Box2Vector* (B2V), aplicada durante o treino da rede, com o objetivo de minimizar o erro entre a predição do modelo e os valores reais. O processo é esquematizado na Figura 36.

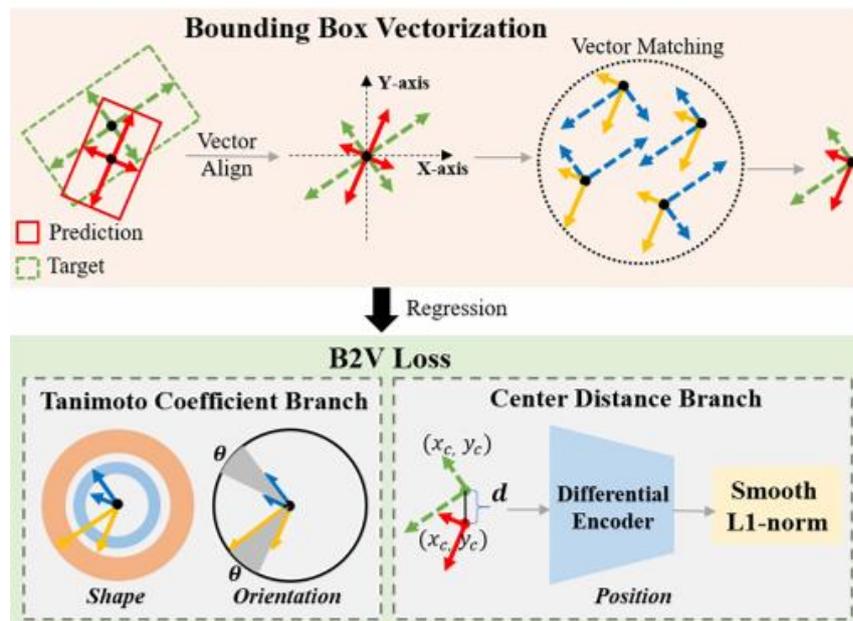


Figura 36: Processo de regressão baseado no método *Bounding Box Vectorization* (adaptado de Wang et al., (2024)).

Alternativamente, Zhou et al., (2024) sugerem a adição da camada de convolução *Ring-Shape Rotated Convolution* (RRC) ao *backbone* da rede. Esta atualização permite que os mapas característicos sejam orientados e ajustados dinamicamente para alinhar ao objeto detetado. Ao contrário das camadas de convoluções normais, que aplicam filtros em orientações fixas, a RRC adapta a saída em forma de anel, dando a capacidade de girar em torno do centro do objeto. A Figura 37 representa esquematicamente como os mapas de características se adaptam rotativamente para alinhar com a orientação do objeto. Esse ajuste permite uma captação mais eficiente das características ao apreender informações relevantes de todos os ângulos. No *neck* da rede, os autores aplicam uma atualização por intermédio de matrizes de covariância gaussiana para modelar as *bounding boxes* orientadas, denominadas *Linear Gaussian Bounding Box* (LGBB). Esta matriz permite definir a forma e a orientação do objeto com maior precisão, já que converte as variáveis contínuas de forma e posição em parâmetros que são quantificáveis. Na Figura 38 a transformação Gaussiana é aplicada de acordo com a dispersão dos pontos em torno do centro, refletindo a orientação do objeto e as variações de forma.

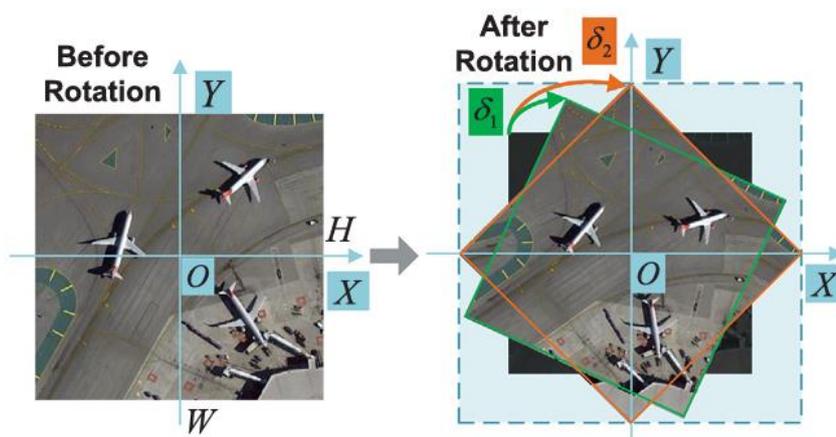


Figura 37: Demonstração da rotação dos mapas de características conforme os ângulos de rotação (adaptado de Zhou et al., (2024)).

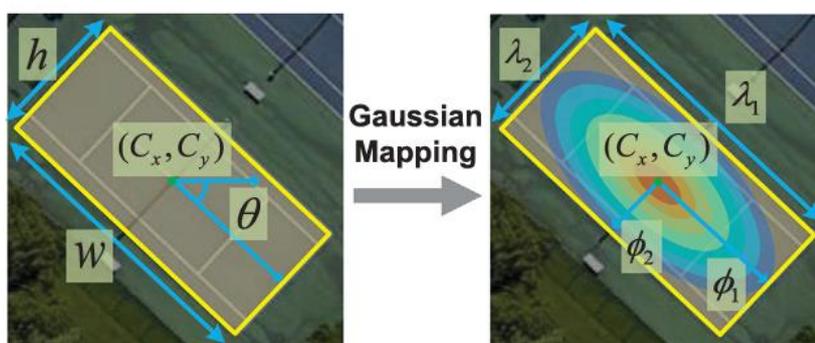


Figura 38: Transformação de uma Oriented Bounding Box (OBB) numa Linear Gaussian Bounding Box (LGBB) com recurso a mapeamento Gaussiano (adaptado de Zhou et al., (2024)).

Zhou et al., (2024) introduzem a variante do YOLOv8-OBB, em conjunto com o YOLO-MLD (*Detector Multi-label*), de forma a detetar múltiplas oriented bounding boxes em imagens de colheitas alimentares. Para suportar a precisão do modelo, os autores implementam o *software OBBLabel*, para anotar o *dataset* de imagens. Esta ferramenta é especialmente desenvolvida para refinar as anotações de objetos com rotações. O YOLOv8-OBB também utilizado por Soni et al., (2024), porém, o *dataset* neste caso é processado pela plataforma *Roboflow*.

A inteligência artificial afirma-se diariamente como um fator revolucionário na AEC. A incorporação das redes CNN com arquiteturas específicas, como o YOLO, eleva as expectativas quanto às futuras aplicações em diversos setores, desde a deteção de anomalias até à otimização de projetos. O IA não só aumenta a eficácia e precisão dos processos, mas também introduz uma nova era de construção inteligente.

2.3.5 Métricas de avaliação dos modelos

As métricas de avaliação são fundamentais para avaliar o desempenho do modelo durante o treino, ao medir a precisão, exatidão e capacidade de generalização para imagens não vistas. Métricas comuns, como o *F1-Score*, *precision* e *recall*, devem ser cuidadosamente inspecionadas para garantir que o modelo está a aprender de forma equilibrada e eficiente. Os gráficos de avaliação, gerados após a conclusão de um treino, demonstram o comportamento e a performance do modelo ao longo das épocas (*epochs*) do treino (Zhang et al., (2024); Qi et al., (2024); Wang et al., (2023); Casas et al., (2024)). De seguida, apresenta-se uma visão geral das principais métricas utilizadas para avaliar o modelo.

- **Precisão**

A precisão (*precision*) do modelo quantifica a percentagem de previsões positivas corretas (*true positives – TP*) em relação ao total de previsões positivas, incluindo falsos positivos (*false positives – FP*). Um valor elevado de precisão indica que, na maioria dos casos, o modelo faz um previsão correta. A equação (4) indica como calcular a precisão de um modelo.

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

- **Recall**

Com a métrica *recall* mede-se a proporção de positivos reais que o modelo consegue identificar de forma correta. Um valor elevado de *recall* indica que o modelo está a conseguir detetar a maioria dos objetos, mesmo que identifique, em alguns casos, falsos positivos. Isso auxilia a evitar falsos negativos (*false negatives – FN*), que ocorrem quando o modelo não deteta um objeto presente na imagem. A equação (5) permite calcular o valor de *recall* do modelo.

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

- **Mean Average Precision (mAP)**

A métrica mAP (*Mean Average Precision*) é calculada a partir da média da *Average Precision* (AP), que combina a precisão e o *recall* de um modelo ao longo de diferentes *thresholds* de

confiança, representados numa curva precisão-*recall*. A AP é determinada para cada classe individualmente, e a mAP advém da média das APs de todas as classes existentes no modelo.

Existem duas variantes comuns da mAP:

- **mAP50**: Refere-se à mAP ser calculada com um limite IoU de 0,5. Isso implica que a deteção é considerada correta se a sobreposição entre a *bounding box* prevista e a *ground truth* for superior a 50%.

- **mAP50-95**: Refere-se à média das APs calculadas em diferentes *thresholds* de IoU que variam entre 0,5 e 0,95. Esta métrica avalia o desempenho do modelo de forma mais rigorosa, já que mede a precisão em níveis de precisão superiores.

- **F1-Score**

O *F1-Score* é uma métrica que combina a precisão e o *recall* do modelo, oferecendo um único valor para avaliar a capacidade de o modelo detetar objetos. Esta métrica é particularmente útil em cenários onde é necessário equilibrar *false positives* e *false negatives*, proporcionando uma avaliação mais equilibrada do desempenho global.

- **Matriz de confusão**

A matriz de confusão apresenta a distribuição detalhada dos *true positives*, *false positives*, *true negatives*, e *false negatives* para cada classe. Desta forma, é possível visualizar eventuais erros de previsão que o modelo cometeu para cada classe e identificar onde são necessárias melhorias, ou seja, quais as classes que requerem ajustes.

3 Metodologia para identificação de desvios geométricos

3.1 Enquadramento

A presente secção apresenta uma descrição detalhada e objetiva da metodologia desenvolvida, composta pelas seis etapas apresentadas na Figura 39. Esta metodologia é composta por uma componente manual, envolvendo o uso de tecnologias digitais e respetivo processamento, para a aquisição do modelo *As-Is*, e uma componente automática, em linguagem *Python*, com a aplicação de algoritmos de inteligência artificial para a avaliação dos critérios estabelecidos pela norma NP EN 1090-2:2020.

A primeira etapa consiste na aquisição e processamento do modelo *As-Is*, em nuvem de pontos. Na segunda etapa, procede-se à extração do *wireframe* do modelo *As-Design*. Os dados resultantes destas duas primeiras etapas servem de *input* para a terceira etapa, que se centra na extração das secções transversais de todos os elementos estruturais de ambos os modelos. A quarta etapa, de carácter inovador, envolve a aplicação do algoritmo YOLOv8, com o objetivo de identificar automaticamente a secção transversal de cada elemento estrutural. Após esta identificação, na quinta etapa, os resultados são processados de forma a adquirir métricas de comparação entre os dois modelos. Finalmente, na sexta etapa, essas métricas são utilizadas para validar os requisitos normativos dispostos na NP EN 1090-2:2020 .

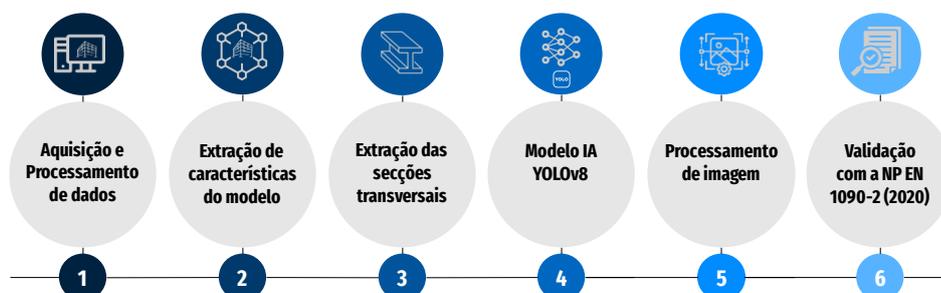


Figura 39: Fluxograma geral da metodologia para identificação de desvios geométricos.

A aquisição de dados experimentais é fundamental para a validação de qualquer metodologia. Nesse contexto, foram realizados dois ensaios em campo, com o objetivo de obter a geometria de elementos de estruturas metálicas e validar a precisão da metodologia proposta.

O primeiro ensaio realizou-se no campus do Instituto Superior de Engenharia do Porto (ISEP), no corredor exterior que conecta o edifício J e F (Figura 40). Este levantamento focou-se na captura da geometria existente composta por dois pórticos metálicos, formado por pilares HEA160. A seleção deste teste piloto deveu-se à particularidade de um dos pórticos apresentar perfis com inclinação, o que representou um desafio para o algoritmo criado para a extração de secções transversais. Este levantamento foi efetuado com recurso a tecnologias digitais, nomeadamente o *Laser Scanning* e a fotogrametria aérea com UAV.



Figura 40: Estrutura de estudo – Edifício J – ISEP.

Adicionalmente, foi realizado um levantamento com a técnica fotogrametria terrestre, numa estrutura situada num parque urbano na Maia (Figura 41). Este ensaio visou aprimorar e testar técnicas e boas práticas de fotogrametria quanto à aquisição e processamento de dados.



Figura 41: Estrutura de estudo localizada na Rua da Estação – Maia.

3.2 Aquisição e processamento de dados

A fase de aquisição e processamento de dados, conforme ilustrada na Figura 42, envolve a aplicação das tecnologias digitais, como a fotogrametria, o TLS, e o MLS. Estes métodos são utilizados para capturar as nuvens de pontos. Após a captura, os dados são georreferenciados e alinhados, culminando na fusão das nuvens. Esta fase apresenta um elevado grau de importância dado que a nuvem de pontos obtida com estas tecnologias será avaliada ao longo de toda a metodologia.

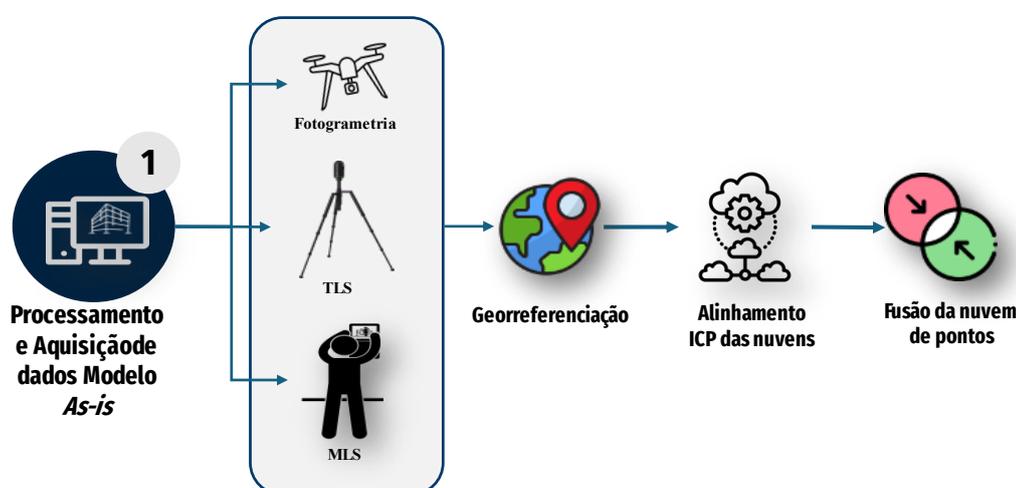


Figura 42: Fluxograma com o processamento de dados fotogramétricos e LiDAR.

3.2.1 Fotogrametria com UAV

Para o levantamento fotogramétrico dos pórticos do edifício J do ISEP, foram capturadas 832 imagens iniciais (Modelo 1) com o UAV *DJI Mavic 3 Enterprise Series*. O voo foi controlado manualmente com o auxílio da aplicação *DJI Pilot*, permitindo captar imagens de diversas perspetivas e alturas de cada elemento. O processo envolveu o contorno individual de cada pilar, focando-se na obtenção de imagens detalhadas de um pilar de cada vez, assegurando que todas as áreas críticas fossem cobertas.

O software *iTwin Capture Modeler* foi utilizado para processar as imagens, recorrendo à aerotriangulação para garantir o primeiro alinhamento das fotografias. A orientação e ajuste do modelo foram asseguradas pelo posicionamento georreferenciado incorporado nos metadados de cada imagem. Após o alinhamento inicial, os GCPs obtidos no local foram marcados em todas as imagens, garantindo um posicionamento realista do modelo.

Posteriormente, foi extraída uma nuvem de pontos densa no formato *.ply* e o modelo em malha 3D realista no formato *.obj*. Embora o levantamento geral tenha sido bem-sucedido, houve um problema na reconstrução das imagens do pórtico inclinado. Durante o voo, a distância focal da câmara do UAV foi alterada inadvertidamente devido à aplicação involuntária de *zoom*, comprometendo a qualidade do modelo gerado nessa região, conforme ilustrado na Figura 43. Adicionalmente, devido ao voo manual e à presença de um taipal de proteção no local, o sinal do RTK foi interrompido em várias ocasiões. A perda de sinal obrigou a pausas momentâneas do UAV durante o levantamento, comprometendo temporariamente a continuidade da captura de imagens. Estes detalhes foram importantes para identificar e prevenir possíveis erros em levantamentos futuros.



Figura 43: Modelo 1 fotogramétrico em nuvem de pontos.

Tendo presente os erros referidos na obtenção do Modelo 1, foi realizado um segundo levantamento (Modelo 2) com o mesmo equipamento (UAV DJI Mavic 3 *Enterprise Series*) para capturar os pórticos do Edifício J do ISEP. Este levantamento foi conduzido num dia chuvoso e ventoso, o que dificultou o controlo do *drone* durante o processo. Apesar das condições adversas, foram capturadas 1856 fotografias da região de interesse, utilizando um voo manual em torno dos perfis metálicos. O processamento foi novamente realizado no *software iTwin Capturer Modeler* (Bentley Systems), e os resultados apresentaram uma precisão geométrica superior, como demonstrado na Figura 44.



Figura 44: Modelo 2 fotogramétrico em nuvem de pontos.

3.2.2 Fotogrametria terrestre

O levantamento com fotogrametria terrestre do parque urbano da Maia foi efetuado com uma câmara digital *Cannon EOS 1100D*, resultando no total de 110 imagens obtidas em diversas perspetivas circundantes ao objeto. O processamento das imagens foi também realizado com o software *iTwin Capture Modeler*, resultando no modelo estrutural *As-Is* apresentado na Figura 45. Após o processamento de dados foi possível verificar a coerência e qualidade do modelo *As-Is*. No entanto, devido à utilização exclusiva de fotogrametria terrestre, alguns detalhes na parte superior da estrutura não foram capturados com a precisão ideal. Apesar disso, o modelo resultante mantém-se fiel à realidade.



Figura 45: Levantamento fotogramétrico terrestre da estrutura metálica na Maia.

3.2.3 LiDAR

Na aquisição de dados LiDAR, utilizou-se o *Laser Scanner Leica BLK 360 G1* para o varrimento terrestre (TLS), em conjunto com um iPad para aplicação da tecnologia MLS, captando pormenores adicionais. Este ensaio de campo foi realizado no campus do ISEP, em simultâneo com o levantamento fotogramétrico Modelo 1, já descrito na secção 3.2.1 do presente relatório. Durante o levantamento, definiram-se nove estações e quatro alvos físicos. Para a obtenção dos dados, foi escolhida a densidade média considerada adequada para esse propósito. O posicionamento do *Laser Scanner* foi cuidadosamente planeado para garantir a cobertura completa do perfil, minimizando fenómenos de oclusão e sombras, que podem afetar a qualidade do levantamento. A Figura 46 demonstra o esquema com a disposição das estações, bem como o raio de ação dos *lasers* emitidos pelo BLK 360.

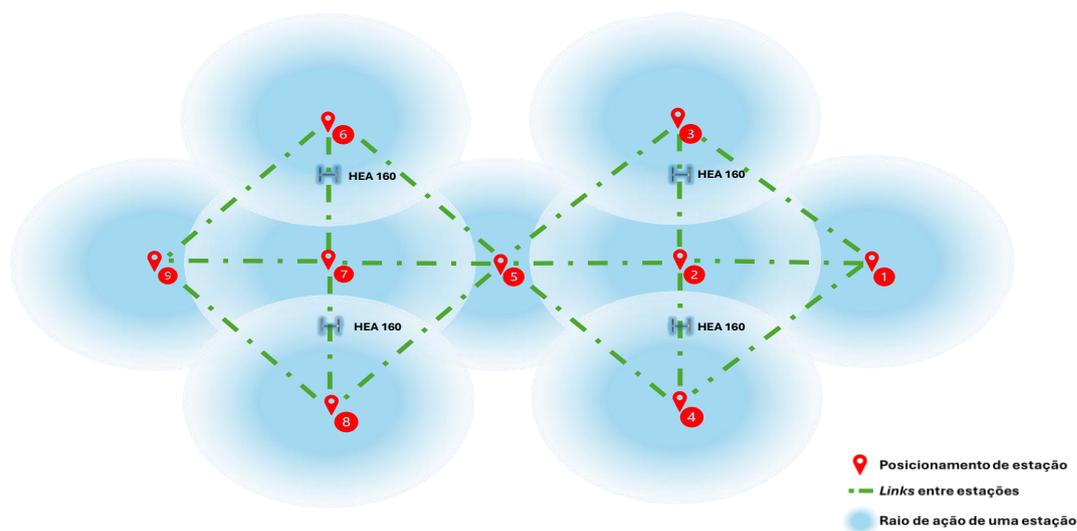


Figura 46: Esquema do posicionamento ideal das estações no levantamento.

Após a aquisição de cada estação, realizou-se o levantamento MLS para captar detalhes como a base dos pilares, ligações e alma do perfil. O pré-alinhamento e otimização dos *links* realizou-se em tempo real através do iPad, utilizando o *software Cyclone Fied 360*. Esta abordagem facilitou a integração das nuvens no processamento final.

O processamento dos dados concretizou-se no *software Cyclone REGISTER 360*. Os dados foram importados para o *software* onde foi realizado um novo alinhamento virtual de todas as estações, garantindo a minimização de erros entre *links*. De seguida, o modelo foi georreferenciado através da importação e marcação manual dos GCPs obtidos no local. A nuvem foi então submetida a um processo de limpeza para a remoção de elementos irrelevantes, mantendo apenas a região de interesse, ou seja, elementos estruturais metálicos. Por fim, a nuvem foi exportada em formato *.e57*. Na Figura 47 está representado o modelo final obtido após o processamento.

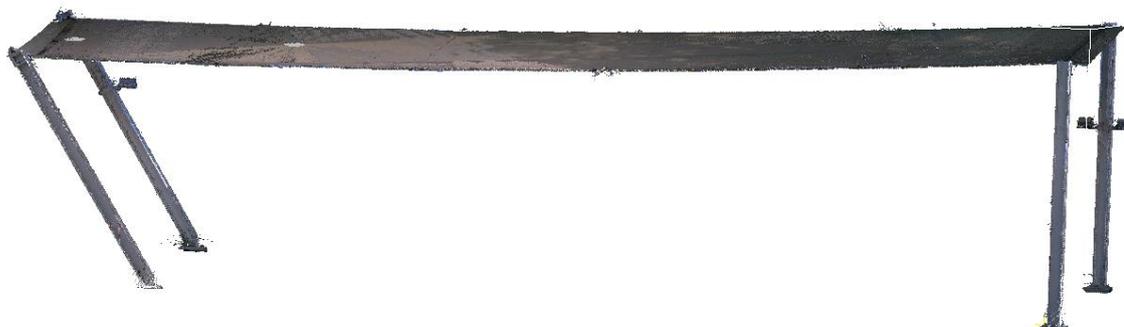


Figura 47: Modelo LiDAR em nuvem de pontos.

3.2.4 Fusão de dados

A fusão de nuvens de pontos, surge com o intuito de combinar as melhores características de cada tecnologia. O processo pode ser realizado com ou sem georreferenciação, sendo que os resultados tendem a ser mais precisos quando a georreferenciação é utilizada. No caso de nuvens georreferenciadas, o processo torna-se significativamente mais simples, uma vez que os *software* de processamento de dados, como o *Metashape* e o *iTwin Capture Modeler*, integram algoritmos de ICP otimizados para a fusão automática. A georreferenciação baseia-se no alinhamento das nuvens dentro de um sistema de coordenadas comum, o que permite a fusão direta e precisa.

Por outro lado, a inexistência de georreferenciação nos modelos torna o processo de fusão mais trabalhoso e minucioso. Inicialmente, o processo envolve a definição de uma nuvem de referência, geralmente a nuvem de pontos LiDAR, devido à sua elevada densidade e precisão. Posteriormente, é necessário recorrer ao alinhamento manual inicial das nuvens através do *software CloudCompare*. De seguida, a nuvem fotogramétrica é ajustada com base na nuvem LiDAR, utilizando a distância mínima entre pontos correspondentes através do algoritmo ICP. A cada iteração, o ICP tenta minimizar a soma das distâncias entre os pontos correspondentes. O ajuste é feito de forma iterativa até a convergência ser atingida, ou seja, o algoritmo termina quando a variação entre iterações é suficientemente reduzida. O algoritmo ICP pode ser otimizado através da definição de um número máximo de iterações, que limita o número de tentativas de alinhamento, assim como, da tolerância ao erro, estabelecendo um *threshold* para o erro aceitável, garantindo uma convergência eficaz. O resultado da fusão dos modelos está representado na Figura 48.



Figura 48: Modelo fusão LiDAR e fotogrametria em nuvem de pontos (verde– nuvem LiDAR, azul – Fotogrametria).

A etapa seguinte consiste em utilizar estes modelos obtidos pelas tecnologias digitais para criar o modelo *As-Design*, a partir do qual serão extraídas as características geométricas relevantes para a análise de desvios.

3.3 Extração de características do modelo

O modelo *As-Design* identifica-se como a base comparativa do modelo *As-Is*, sendo por isso necessário adquirir características que possibilitem efetuar essas comparações. As principais características a extrair deste modelo são as coordenadas nodais, permitindo obter o *wireframe* da estrutura, assim como toda a informação relativa ao tipo de elementos estruturais existentes. A Figura 49 representa esquematicamente o procedimento desta etapa.

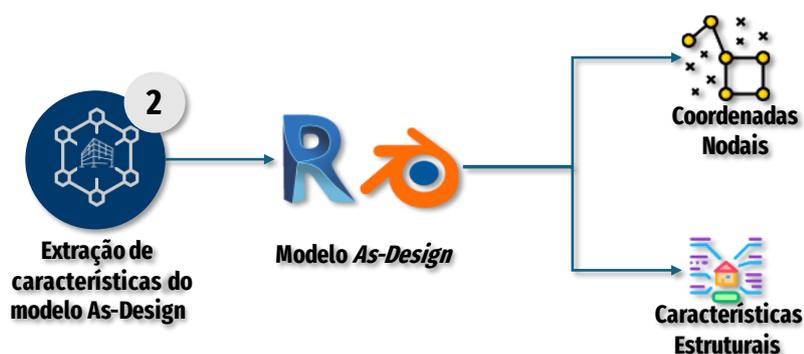


Figura 49: Fluxograma da extração de *wireframe* do modelo *As-Design*.

Para o desenvolvimento do modelo *As-Design* da estrutura, recorreu-se a dois *software* de modelação: *Revit Autodesk* e *Blender 4.2*. Numa primeira fase, foi necessário fazer medições no local, utilizando uma fita métrica e um nível *laser*. Estes dados, assim como um esboço auxiliar, foram registados e serviram como base para a modelação da estrutura no *Revit*. Durante a modelação, assegurou-se que todas as características dos elementos foram corretamente representadas, bem como os comprimentos, e distâncias entre elementos. O modelo foi exportado em formato IFC (*Industry Foundation Classes*), utilizado para garantir a interoperabilidade entre diferentes *softwares* de modelação, mantendo toda a informação inserida pelo utilizador. De seguida, o ficheiro IFC foi importado para o *Blender 4.2*, através do *add-on Bonsai*, anteriormente conhecido como *BlenderBIM*. Esta ferramenta permite não só importar ficheiros IFC como também editar as suas características.

De forma a automatizar a extração de informação estrutural do modelo, foi desenvolvido um algoritmo em *Python* integrado no *Blender*. Este algoritmo apresenta uma elevada relevância para a metodologia, devido à sua capacidade de extrair características da estrutura, como coordenadas nodais, associar cada nó aos respetivos elementos, identificar a secção transversal e calcular o comprimento de cada elemento, resultando num modelo *wireframe* da estrutura, conforme demonstra a Figura 50. Através de uma Análise de Componentes Principais (PCA), onde o centroide e os vértices de cada elemento são determinados num referencial local. Cada vértice do elemento é tratado como um nó. O código utiliza a matriz de covariância das coordenadas dos vértices, identificando assim o eixo principal de cada elemento. Posteriormente, recolhe-se as coordenadas dos vértices dos objetos no espaço 3D, convertendo-as para o sistema de coordenadas globais. O comprimento de cada elemento é determinado com a distância entre as coordenadas das extremidades.



Figura 50: *Wireframe* da estrutura exportado do *Blender*, com a respetiva numeração dos elementos.

O *wireframe* da estrutura é um componente imprescindível na metodologia proposta. No entanto, a aplicação eficaz desta metodologia depende da georreferenciação dos modelos 3D envolvidos. Devido à ausência de georreferenciação durante o levantamento, foi necessário proceder ao alinhamento do modelo *As-Is* (obtido pelo LiDAR) com o modelo *As-Design* (modelo teórico). Neste caso, observou-se que o modelo 3D fotogramétrico e, por consequência, a fusão das nuvens apresentaram limitações significativas que comprometeram sua utilidade na análise de desvios geométricos. Assim sendo, o modelo LiDAR foi definido como referência para a restante aplicação da metodologia. O processo de alinhamento foi executado com recurso ao algoritmo ICP entre os modelos *As-Is* e *As-Design*, de forma a simplificar o alinhamento na estrutura de elementos não essenciais, como o taipal de proteção e as vigas presentes no modelo prático, mantendo apenas os pilares em ambos os modelos, conforme demonstrado na Figura 51.



Figura 51: Modelo *As-Is* LiDAR alinhado com o modelo *As-Design* (cor azul modelo LiDAR; cor cinzenta modelo *As-Design*; cor verde e laranja na extremidade significa que um dos modelos, neste caso, o modelo *As-Design* não tem qualquer tipo de pontos correspondentes nessa região).

Para avaliar as métricas de alinhamento tanto aos níveis de precisão e correspondência entre as nuvens de pontos, foram calculadas diversas métricas que auxiliam a comparação entre os modelos LiDAR e *As-Design*, apresentadas nas Tabela 1 e Tabela 2.

Tabela 1: Métricas gerais calculadas com base nos modelos LiDAR e *As-Design* após o alinhamento ICP.

Métrica	Valor (m)
Distância média	0,008004
Desvio Padrão	0,010602
Erro Absoluto Médio (MAE)	0,007347
Erro Quadrático Médio (RMSE)	0,009307
Distância de <i>Hausdorff</i>	0,197173
M3C2	0,012584

Ao observar os resultados obtidos na Tabela 1 é possível perceber que os modelos, de uma forma geral, foram alinhados corretamente. Os baixos valores de MAE e RMSE indicam que, em média, os pontos das duas nuvens estão muito próximos entre si, sugerindo um alinhamento preciso na escala milimétrica. A distância de *Hausdorff* mais elevada sinaliza a presença de *outliers* locais, devido a ruído nos dados, que, porém, não comprometem o alinhamento global.

Também a métrica M3C2, que considera a orientação das superfícies para detetar diferenças entre duas nuvens, sugere que o alinhamento apresenta diferenças relativamente pequenas.

Tabela 2: Métricas C2C entre o modelo *As-Design* e o modelo LiDAR

Métrica	<i>As-Design</i> para LiDAR	LiDAR para <i>As-Design</i>
Distância Mínima	0,000040	0,000040
Distância Máxima	0,055909	0,197173
Distância Média	0,007347	0,008771
Mediana	0,005781	0,004445

A análise das métricas C2C da Tabela 2 é um complemento fundamental para avaliar o alinhamento global dos modelos. Os baixos valores da distância média e da mediana em ambos os casos confirmam que a maioria dos pontos entre as duas nuvens está alinhada corretamente, apresentando erros inferiores a um centímetro. Os valores obtidos para as distâncias máximas podem ser atribuídos à presença de detalhes no modelo LiDAR que não existem no modelo *As-Design*, como, por exemplo, as ligações físicas dos pilares, assim como ruído extra que não foi removido.

3.4 Algoritmo de extração de secções transversais

Os resultados adquiridos na etapa anterior permitem aceder à secção transversal de todos os elementos estruturais. Para isso, utiliza-se o eixo principal de cada elemento, determinado pelas suas coordenadas nodais, e são simulados sucessivos planos de corte perpendiculares a esse eixo. Através desta simulação, os pontos compreendidos entre dois planos são projetados para o plano inferior, resultando na secção transversal do elemento em formato *.jpeg*. Este processo é realizado simultaneamente nos dois modelos 3D, *As-Is* e *As-Design*, assegurando que as secções transversais sejam comparadas na mesma localização do elemento. A Figura 52 representa esquematicamente este processo.

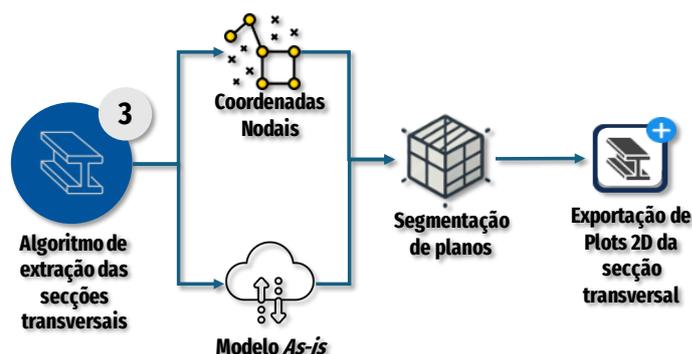
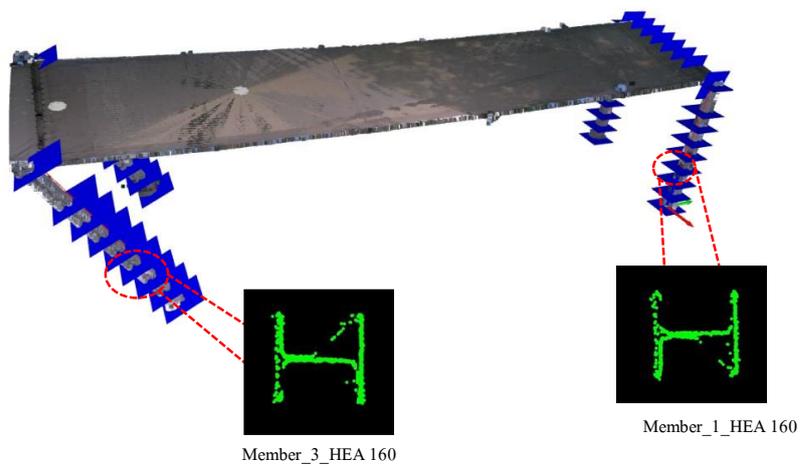
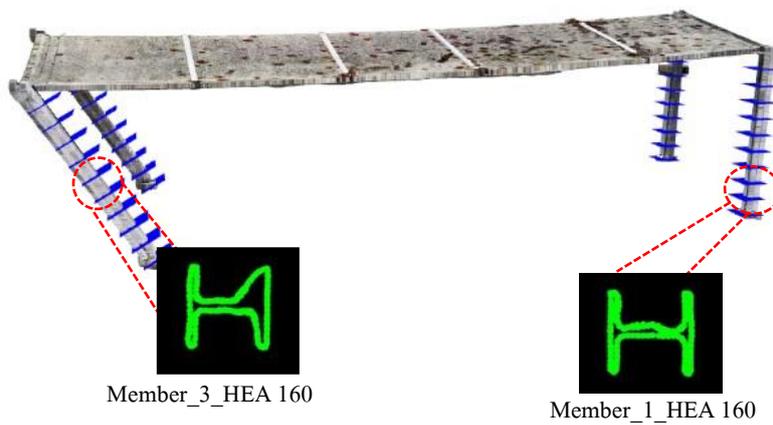


Figura 52: Fluxograma do algoritmo criado para extrair secções transversais de cada membro de uma estrutura.

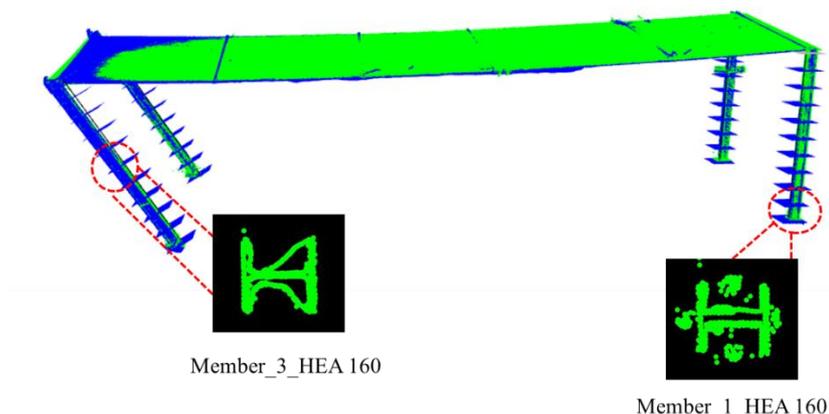
A partir das coordenadas nodais da estrutura, bem como do modelo *As-is* alinhado, o algoritmo segmenta os membros ao longo de planos perpendiculares ao eixo de cada elemento. A Figura 53 apresenta as nuvens de pontos descritas na secção 3.2 do presente relatório, com a representação dos planos de corte a azul, definidos a partir de vetores perpendiculares à normal do eixo do membro. Os planos são espaçados ao longo do comprimento do elemento, gerando conjuntos de cortes em intervalos regulares. O número de planos e a sua distância podem ser ajustados, sendo que, quanto maior a distância entre os planos, mais densa será a secção captada na imagem 2D, enquanto uma menor distância produz imagens menos densas e mais refinadas. Cada segmento é projetado, originando imagens 2D das secções transversais correspondentes a cada corte, que são posteriormente armazenadas para análise.



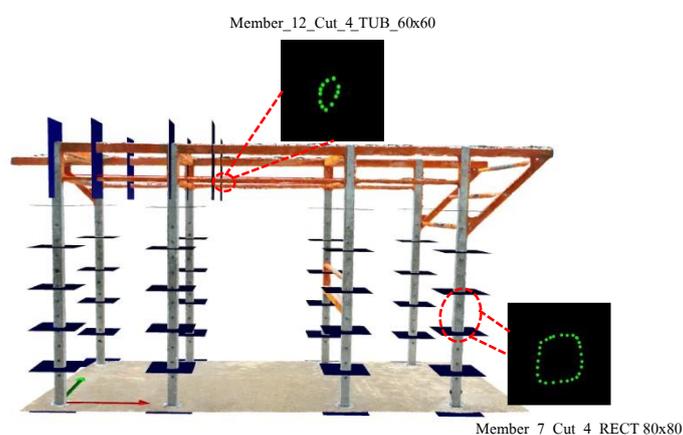
a)



b)



c)



d)

Figura 53: Visualização da nuvem de pontos LiDAR em conjunto com planos perpendiculares de segmentação. a) Modelo TLS; b) Modelo 2 fotogramétrico com UAV; c) Modelo fusão; d) Modelo fotogramétrico terrestre.

3.5 Modelo IA YOLOv8

Esta secção destaca-se pela aplicação de um modelo de inteligência artificial, o YOLOv8, para a deteção automática de perfis metálicos. O YOLOv8 é uma rede neuronal que combina operações avançadas de convolução e processamento de dados capazes de identificar e segmentar um objeto através de uma *mask* de segmentação e uma *bounding box*. A aplicação deste algoritmo requer a elaboração de um processo de treino prévio. Numa primeira fase, é necessário adquirir um conjunto de dados robusto (*dataset*), definido pelas imagens da secção transversal de vários perfis metálicos existentes, com diferentes posicionamentos e

orientações, com ou sem aumentação. Com base nestas imagens, é realizado um processo de anotação que consiste no desenho da geometria do perfil e posterior atribuição da classe. Por fim, o algoritmo é treinado e validado para que seja possível identificar e segmentar qualquer secção geométrica, designado como teste de inferência. A Figura 54 ilustra de forma sucinta todo o processo descrito anteriormente.

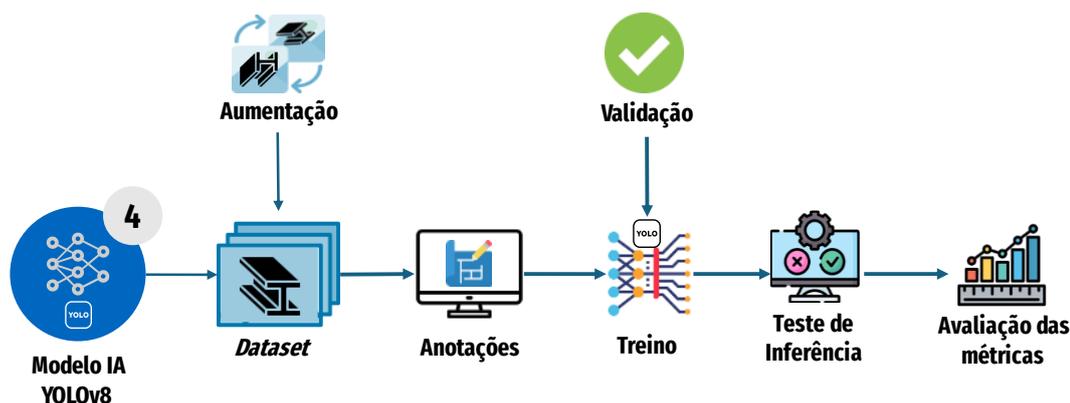


Figura 54: Fluxograma do processo de implementação de modelos de IA com o YOLOv8.

3.5.1 Dataset

Com o objetivo de criar o *dataset* para o desenvolvimento do modelo, foi aplicado o algoritmo de extração de secções transversais, que permitiu extrair dados artificiais provenientes de modelos *As-Design*, bem como dados reais obtidos a partir dos modelos *As-Is*. Para garantir consistência nas imagens processadas, todas as imagens extraídas pelo algoritmo apresentam uma dimensão uniforme de 1280x1280 *pixels* e uma resolução de 500 DPI (*Dots Per Inch*), o que significa 500 *pixels* por polegada linear. Quanto maior é o valor de DPI, maior será a densidade de detalhes por polegada linear da imagem, resultando numa imagem de maior qualidade.

Para prevenir fenómenos de *overfitting* e, ao mesmo tempo, aumentar a robustez do modelo, foram utilizadas várias técnicas, incluindo *data augmentation*, *voxel downsampling* e remoção de *outliers*, de modo a produzir diferentes variantes da mesma imagem, conforme apresenta a Figura 55. Noutra abordagem, desenvolveu-se um algoritmo de aumentação, onde foi possível adicionar ruído, rotações, oclusões parciais do objeto (*partial dropout*) tanto em imagens artificiais quanto reais (Figura 56). Estas técnicas enriquecem o *dataset*, melhorando a

capacidade do modelo na tarefa de detecção de secções transversais, mesmo em imagens com ruído e sobreposições.

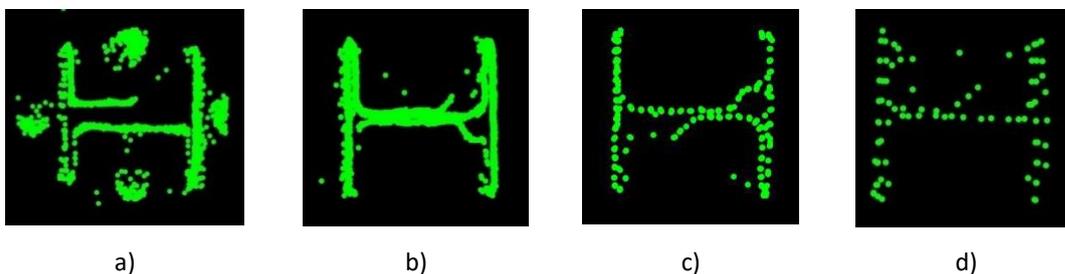


Figura 55: Exemplos de *dataset* baseados no Modelo *As-Is*. a) Corte basal do pilar com detalhes da ligação aparafusada; b) Imagem real; c) Imagem processada com *voxel downsampling* igual a 0,01; d) Imagem processada com *voxel downsampling* igual a 0,02.

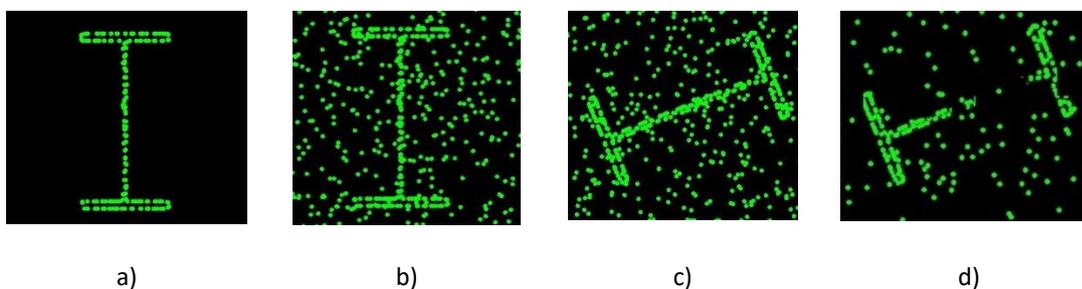


Figura 56: Imagens artificiais e exemplos de aumentações criadas. a) Imagem original; b) Ruído aleatório; c) Rotação; d) *Partial dropout*.

3.5.2 Preparação de dados no *Roboflow*

O processo de preparação do *dataset* foi desenvolvido na plataforma *Roboflow*, escolhida pela sua facilidade de utilização e capacidade de integração com modelos de *Machine Learning*, especialmente em tarefas de segmentação e detecção de objetos. O *Roboflow* proporciona uma interface intuitiva que permite organizar e armazenar o *dataset*, além de disponibilizar ferramentas de desenho que tornam o processo de anotação mais eficiente e rápido.

No âmbito da metodologia, optou-se por um projeto de segmentação de instâncias, uma vez que este permite uma segmentação rigorosa da área do objeto. O projeto é composto por 2584 imagens, importadas e armazenadas no *Roboflow*, consistindo em imagens reais e artificiais, com e sem *data augmentation*, e com elevada diversidade de classes. No total, foram definidas 55 classes de secções transversais, incluindo perfis HEA, HEB, IPE, UPE, bem como algumas classes de perfis RHS e tubulares. No processo de anotações, utilizou-se a ferramenta de *polygonal lines*, que permite a marcação precisa do contorno das secções transversais. A

marcação foi realizada de forma sistemática, começando sempre no vértice superior esquerdo do objeto e avançando no sentido horário, marcando um ponto em cada vértice característico da secção transversal do perfil. Este método assegura consistência durante a marcação, evitando erros que podem ocorrer com uma marcação aleatória. Após o desenho do contorno do objeto, a secção transversal é etiquetada com a classe correta do perfil. A Figura 57 apresenta um exemplo do processo de anotação da *dataset* para uma secção HEA160.

Após o processo de anotações, o *dataset* foi dividido em 70%, 20%, 10% para treino, validação e teste, respetivamente, garantindo distribuição dos dados para um treino mais robusto. Por fim, o *Roboflow* permite a exportação direta do *dataset* em formato compatível com o YOLOv8. Definiu-se um pré-processamento às imagens no *Roboflow* com um *resize* de 640x640, com as coordenadas das *Bounding Boxes* normalizadas em relação às dimensões da imagem, assim como as respetivas classes atribuídas.

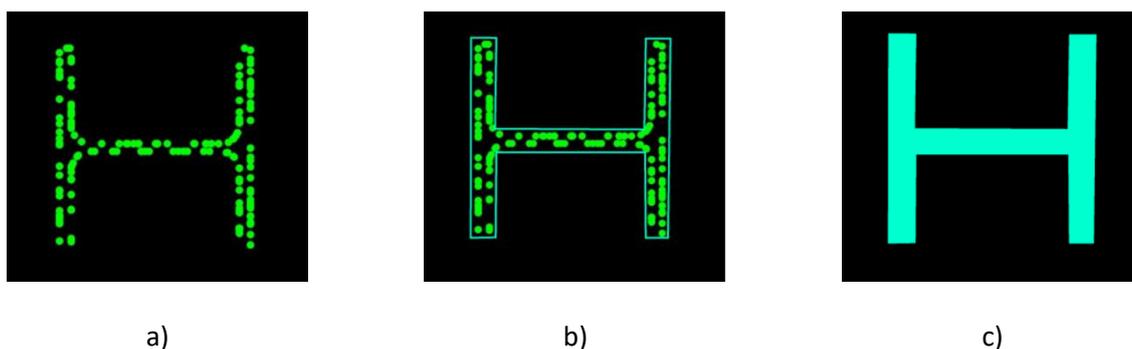


Figura 57: Processo de anotação de uma imagem. a) Imagem original, perfil HEA 160. b) *Polygonal line* a contornar a secção transversal; c) *Mask*.

3.5.3 Treino do modelo YOLOv8-SEG

Para treinar o modelo utilizou-se o computador das instalações da sala J303 do ISEP, equipado com um processador 13th Gen Intel® Core™ I9-13900KF de 3.00 GHZ, 64.0 GB de memória RAM, e uma GPU NVIDIA GeForce RTX 4090 que permitiu concluir o treino em 1 hora e 6 minutos. O modelo foi configurado para a tarefa de segmentação de instâncias, com o modelo mais complexo do YOLOv8, o YOLOv8x-SEG, com 401 camadas e aproximadamente 71.7 milhões de parâmetros. A revisão bibliográfica (Ultralytics, 2024), permitiu definir os seguintes parâmetros para o treino:

- **Epochs = 100:** Refere-se ao número total de vezes que o modelo realiza uma passagem completa por todos os dados de treino. Neste caso, 100 *epochs* garante que o modelo tenha oportunidades suficientes para aprender padrões dos dados.
- **Patience = 25:** Define o número de *epochs* consecutivos sem melhorias nas métricas de validação após o qual o treino será interrompido para evitar *overfitting*, ou seja, se o modelo não melhorar em 25 *epochs*, o treino será parado.
- **Imgz = 640:** Indica o tamanho das imagens de entrada em *pixels*, imagens com resolução de 640x640 são usadas para equilibrar a precisão do modelo.
- **Device = 0:** Refere-se à utilização da GPU (placa gráfica) para realizar o treino. O valor 0 indica que o primeiro dispositivo GPU disponível será utilizado para acelerar o processo de treino, garantindo maior eficiência.
- **Batch = 8:** Refere-se ao número de amostras processadas antes de atualizar os pesos do modelo. Um tamanho de *batch* de 8 ajuda a otimizar o uso da memória da GPU.

Após a conclusão do treino, foi realizado um teste de inferência para verificar a capacidade preditiva do modelo em detetar, segmentar e classificar corretamente as secções transversais em novas imagens. Para isso, foi utilizado o conjunto de imagens previamente reservadas para teste (10% no total), contendo imagens reais e artificiais com diversidade nas classes. Os resultados obtidos neste processo demonstraram que o modelo é capaz de segmentar corretamente a geometria do perfil, e ainda atribuir as classes correspondentes aos rótulos da imagem. Na Figura 58, apresentam-se alguns exemplos de inferências realizadas pelo modelo desenvolvido:

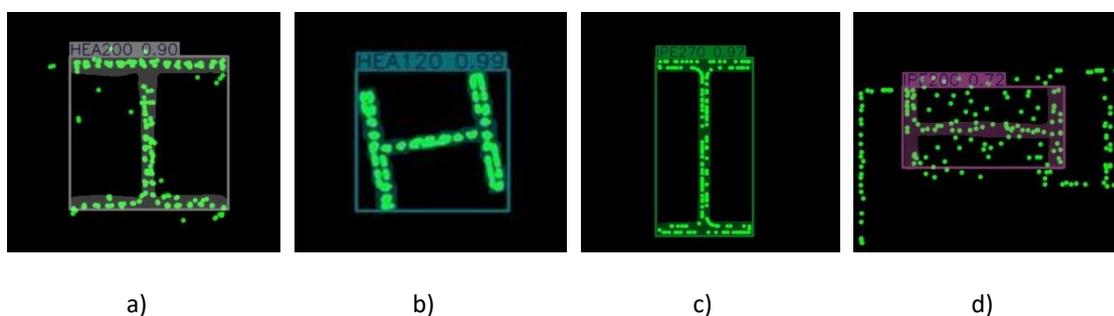


Figura 58 Exemplos de inferências realizadas pelo modelo desenvolvido. a) Imagem artificial com o perfil HEA200; b) Imagem real com o perfil HEA120;c) Imagem artificial com o perfil IPE270; d) Imagem artificial com *data augmentation* do perfil IPE200.

Os resultados do teste de inferência do modelo traduzem, de forma geral, desempenhos positivos, tanto para a segmentação do perfil pela *mask* como na classificação das secções transversais. No entanto, como pode ser observado na Figura 58b), as *bounding boxes* não seguem a orientação do perfil, tornando necessário um processamento adicional para corrigir essa limitação. Contudo, o modelo ainda apresenta margem para melhorias, tanto no que se refere à precisão preditiva como à precisão de segmentação do objeto. Nesse intuito, será necessário aumentar o número de imagens do *dataset* para cada classe do perfil, e ainda aplicar mais técnicas de aumento.

3.5.4 Validação das métricas

Durante o treino, várias métricas foram calculadas para avaliar a eficácia e performance do modelo nas tarefas atribuídas. Os gráficos com os resultados são cruciais para a compreensão do seu desempenho em várias métricas essenciais, tais como a *F1-Score*, precisão, *recall* e mAP. Estas métricas foram analisadas tanto para as *bounding boxes* (B) quanto para as *masks* de segmentação (M). De forma geral, o modelo, após 100 *epochs*, apresentou resultados promissores para a metodologia em ambas as tarefas, conforme apresentado na Tabela 3. Através dos resultados apresentados, verifica-se que o modelo possui um desempenho eficaz para as tarefas de delimitação das *bounding boxes*, assim como para as *masks* de segmentação. Com uma precisão (P) de 88,9% e um *recall* (R) de 98,2% para ambas as tarefas, o modelo demonstra ser capaz de identificar, localizar e segmentar corretamente a maioria dos objetos presentes no conjunto de dados. Além disso, o valor elevado de 98,6% de mAP50, para ambas as tarefas, indica que o modelo é altamente preciso. No entanto, ao analisar o mAP50-95, verifica-se uma discrepância nos resultados entre as *bounding boxes* e as *masks*, no caso 90,6% e 70,5%, respectivamente, o que é algo habitual, já que a tarefa de segmentação é computacionalmente mais exigente.

Tabela 3: Performance do modelo para as principais métricas de validação.

Métricas	<i>Bounding Box</i> (B)	<i>Masks</i> (M)
Precisão (P)	0,9447	0,9447
<i>Recall</i> (R)	0,9584	0,9584
mAP50	0,9845	0,9845
mAP50-95	0,9625	0,8400

Ao analisar a matriz de confusão após o teste representado na Figura 59, verifica-se um bom desempenho geral na classificação, onde se percebe pela diagonal principal as previsões corretas do modelo para as diferentes classes. A classe *background*, definida pelas imagens sem qualquer objeto ou com casos *false negatives*, também apresenta incongruências, indicando que o modelo pode melhorar na distinção entre os objetos de interesse e o fundo. Estes resultados apontam para a necessidade de ajustes do modelo e aprimoramentos no conjunto de dados, adicionando mais exemplos das classes.

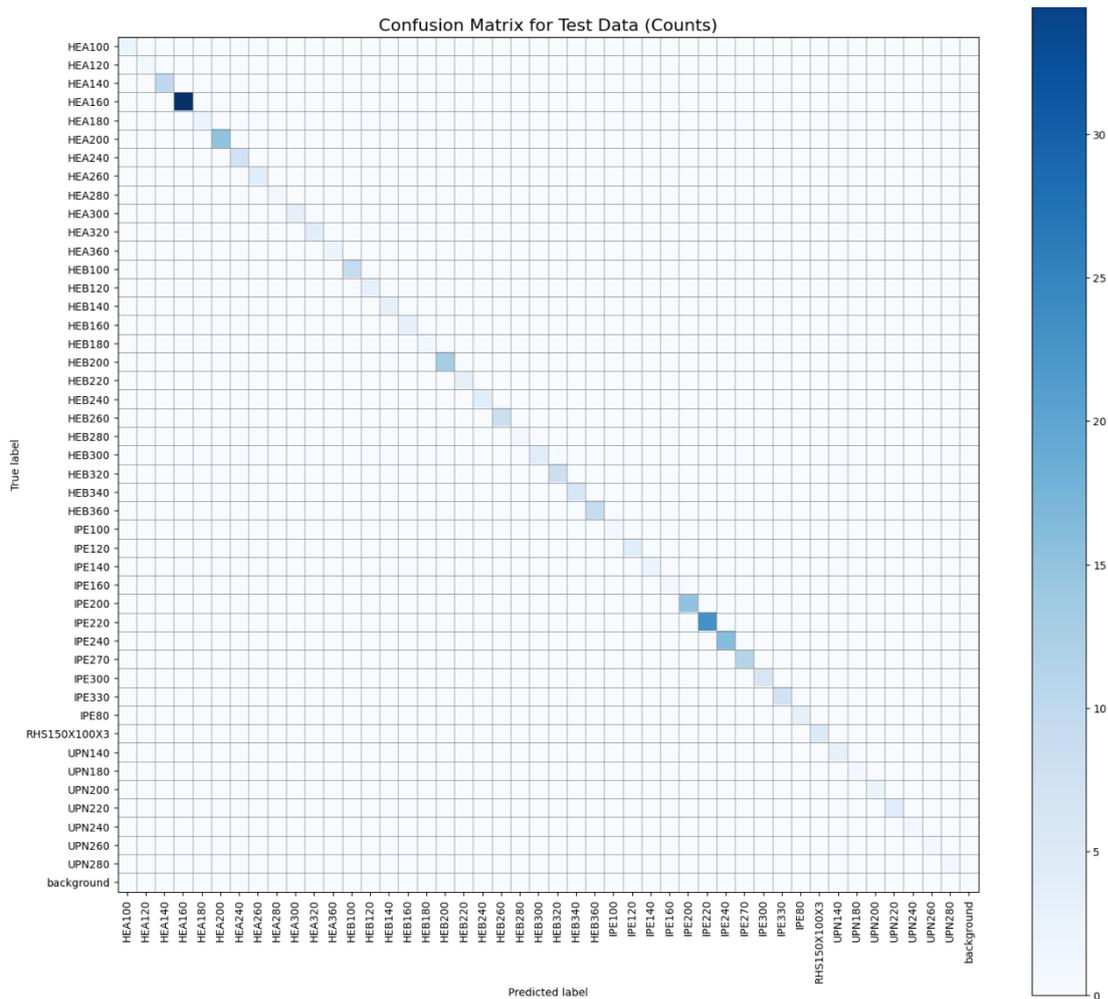


Figura 59: Matriz de confusão de teste do modelo.

O gráficos traduzindo as curva de perda apresentados na Figura 60 ajudam a avaliar se o modelo está a aprender de forma eficiente durante o treino e a validação. Graficamente, o eixo horizontal corresponde ao número de *epochs*, enquanto o eixo vertical representa o valor da perda (loss) correspondente para cada tarefa (*bounding boxes* e *masks* de segmentação).

No caso das *bounding boxes*, a perda de treino, conforme demonstrado na Figura 60a), estabiliza ao fim de aproximadamente 80 *epochs*, o que sinaliza que o modelo está a convergir corretamente ao longo do tempo. Ainda no caso das *bounding boxes*, a perda por validação, ilustrada na Figura 60c), diminui muito rapidamente nas primeiras *epochs* do treino, estabilizando em torno de 0,25, sugerindo que o modelo generaliza corretamente e não sofre de fenómenos de *overfitting*. Em relação às *masks* de segmentação, a perda de treino Figura 60b) demonstra uma diminuição progressiva até cerca de 0,20, o que indica que o modelo está a melhorar na segmentação dos objetos. Por outro lado, a perda de validação na Figura 60d) apresenta uma diminuição rápida, estabilizando em torno de 0,50. Nesta fase, nota-se uma ligeira tendência de aumento a partir de 70-80 épocas, o que pode indicar sinais iniciais de *overfitting* nesta tarefa. A diminuição contínua das perdas nos quatro gráficos apresentados, tanto no treino quanto na validação, sugere que o modelo está a aprender efetivamente e a convergir para as tarefas selecionadas. A proximidade entre as perdas de treino e validação indica uma boa generalização do modelo aos dados não vistos. Estes resultados positivos denotam que o modelo está a ajustar corretamente para ambas as tarefas e pode ser confiável para aplicações práticas.

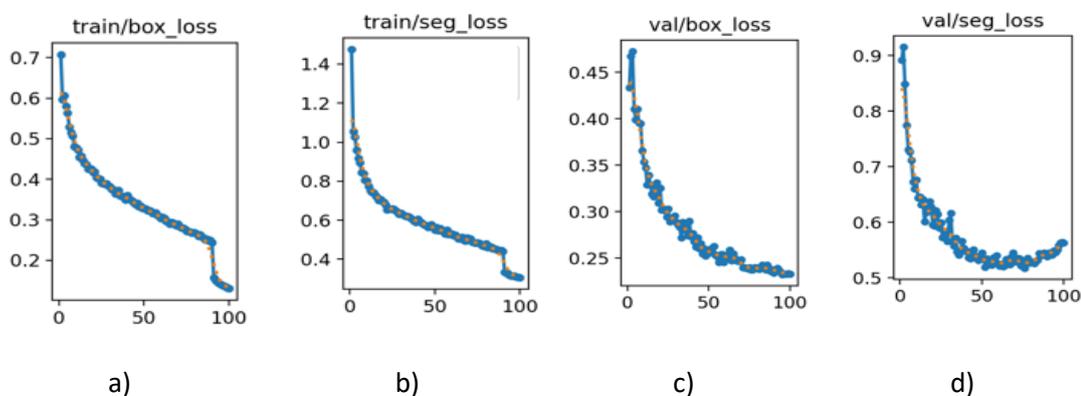


Figura 60: Gráficos de perdas ao longo das *epochs* de treino e validação. a) Curva de perdas associada à predição das *bounding boxes* durante o treino; b) Curva de perdas de segmentação durante o treino; c) Curva de perdas das *bounding boxes* durante a validação; d) Curva de perdas de segmentação durante a validação.

3.6 Processamento de imagem

A etapa descrita nesta secção, processamento de imagens, visa determinar a melhor representação geométrica das secções transversais analisadas, identificando as principais áreas de interesse com a remoção de ruídos externos e *outliers*. Atendendo ao último passo da etapa anterior, teste de inferência do modelo YOLOv8, as novas imagens adquiridas são previstas no modelo treinado para que seja determinada a *mask* e a *bounding box* associada a cada uma. Através destes resultados, é realizada uma filtragem de *pixels* e calculada a *box* final, designada de *oriented bounding box (OBB)*, capaz de identificar objetos rodados. A Figura 61 apresenta uma visão detalhada do fluxo correspondente ao processamento adequado da imagem.

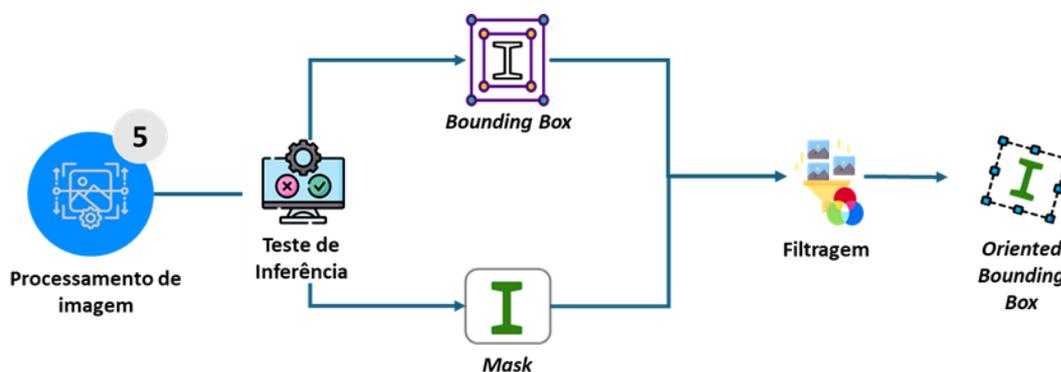


Figura 61: Fluxograma do algoritmo de processamento da imagem

O processamento inicia-se com o uso do *dataset* original e das *masks* e *bounding boxes* obtidas pelo modelo YOLOv8. O refinamento das imagens é necessário para ser possível identificar desvios geométricos. A *bounding box* é utilizada como uma área de interesse inicial para a análise. Esta delimita a região onde a secção transversal deve estar localizada, facilitando o foco do processamento nos *pixels* relevantes. Adicionalmente, no caso de secções rodadas, a *bounding box* original é convertida numa OBB que siga a orientação real do objeto, assegurando uma representação precisa do perfil geométrico na imagem. De seguida, a *mask* de segmentação é aplicada para filtrar os *pixels* da imagem. Para o efeito, todos os *pixels* localizados fora da área da *mask* são removidos, resultando numa imagem limpa, sem ruídos externos. Nesse contexto, os *pixels* dentro da *mask* são mantidos (verde fluorescente) para facilitar a identificação e processamento subsequente. O processo é muito semelhante a um problema binário, onde os *pixels* são classificados como pertencentes ao objeto (1) ou não (0), o que permite simplificar a manipulação e análise das imagens. A Figura 62 apresenta o

processo de filtragem ao utilizar a *mask* de segmentação de uma imagem real obtida do levantamento no edifício J do ISEP. É possível verificar que a imagem beneficia da filtragem para a obtenção de secções mais precisas.

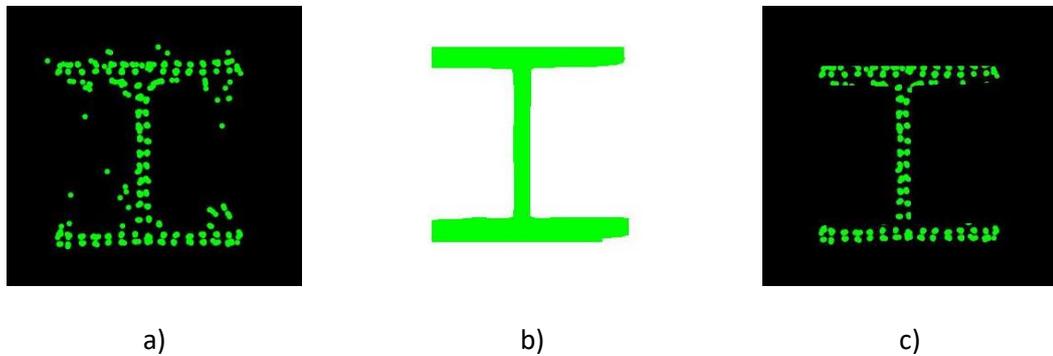


Figura 62: Processo de filtragem de imagens obtidas pelo YOLOv8. a) Imagem real; b) *Mask* de segmentação; c) Imagem filtrada.

Com as imagens filtradas, é possível proceder à extração dos contornos das secções recorrendo a funções disponíveis na biblioteca *OpenCV*, como *cv2.findContours*. Esta função permite detetar contornos, ao longo da fronteira do objeto, em imagens binárias. A imagem é analisada *pixel a pixel* para identificar alterações na intensidade de RGB e indicar a presença de um bordo. A função *cv2.minAreaRect* é aplicada aos contornos obtidos para determinar a menor área retangular que envolve a secção, levando em consideração a sua orientação, o que permite chegar à OBB, conforme se demonstra na Figura 63 com a cor vermelha.

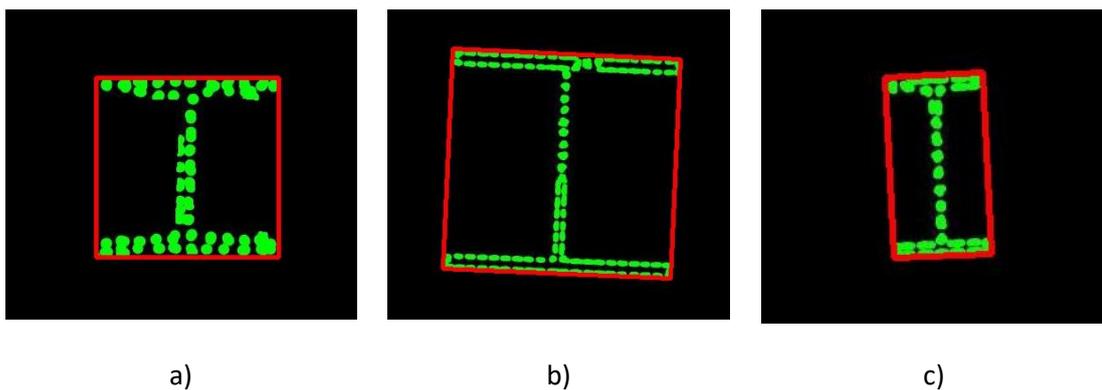


Figura 63: Exemplos de OBBs obtidas após o processamento das imagens. a) OBB de uma imagem real representando o perfil HEA160, obtido por tecnologia LiDAR; b) OBB de uma imagem artificial do perfil HEA260; c) OBB de uma imagem artificial representando o perfil IPE140.

A metodologia é finalizada com um processo comparativo das OBBs obtidas para cada corte aplicado na estrutura, entre o modelo *As-Design* e o modelo *As-Is*. Esta comparação permite calcular desvios geométricos ao longo de cada elemento, incluindo rotações e translações nos eixos XX e YY. A translação é calculada com base na comparação dos centros geométricos das duas OBBs, o que permite determinar com precisão os deslocamentos em ambas as direções Δx e Δy , conforme ilustra a Figura 64. A distância entre os centros das OBBs teórica e prática é medida, proporcionando uma avaliação direta do deslocamento geométrico. Já no caso da rotação, esta é determinada, com base nos vetores extraídos das coordenadas dos pontos das OBBs. O ângulo é definido através de uma função que determina a diferença de orientações entre as *bounding boxes* no plano 2D.

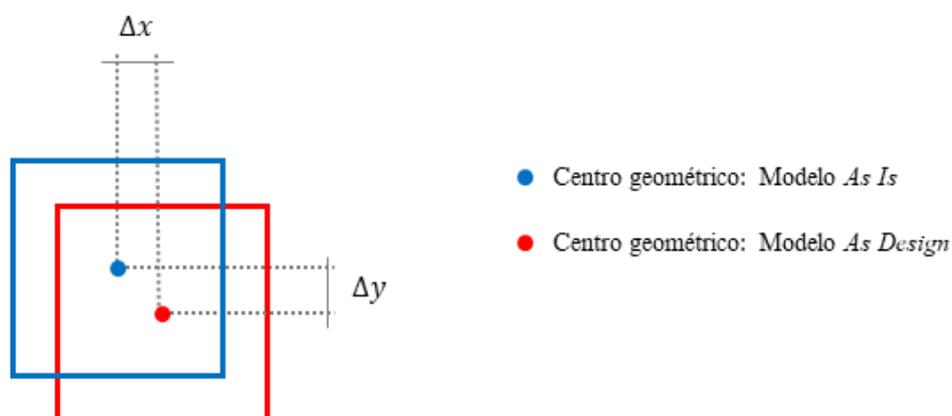


Figura 64: Exemplo de extração dos desvios geométricos entre as OBB de cada modelo.

3.7 Validação com a norma NP EN 1090-2:2020

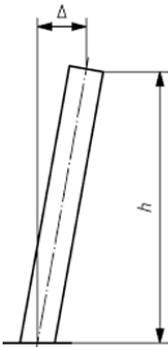
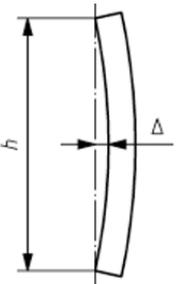
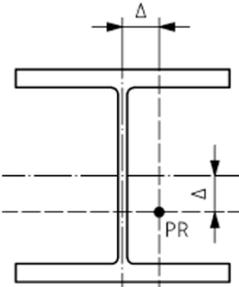
Nesta secção, são apresentados os resultados do levantamento realizado no edifício J do ISEP. Para a avaliação dos desvios geométricos da estrutura, foram consideradas três tolerâncias de montagem definidas pela norma NP EN 1090-2:2020. Os critérios avaliados baseiam-se nos Quadros B.17 e B.20 que estabelecem limites específicos como:

- Inclinação de pilares – Inclinação total na altura do andar h.

- Retilinearidade de pilares de um só andar – Posição da coluna no plano, em relação a uma linha reta entre os pontos de referência na base e no topo.
- Posicionamento de pilares – Posição em planta dos eixos dos pilares ao nível da sua base, em relação a um ponto de referência (PR).

Na Tabela 4, estão especificados os limites máximos de desvios estabelecidos para os casos avaliados.

Tabela 4: Tolerâncias de montagem definidas pelos quadros B.17 e B.20 na NP EN 1090-2:2020

Quadro	Nº	Critérios	Tolerâncias funcionais		Tolerâncias essenciais
			Classe 1	Classe 2	Classe 1 ou 2
B.17	1		$\Delta = \pm h/300$	$\Delta = \pm h/300$	$\Delta = \pm h/500$
	5		Nenhuma Exigência	Nenhuma Exigência	$\Delta = \pm h/1000$
B.20	1		$\Delta = \pm 10 \text{ mm}$	$\Delta = \pm 5 \text{ mm}$	Nenhuma Exigência

3.7.1 Inclinação de colunas de edifícios com um só andar

Ao analisar os resultados obtidos para a inclinação no topo dos pilares, verifica-se que todos os elementos analisados cumprem os critérios impostos. A Tabela 5 apresenta os resultados dos desvios geométricos obtidos quanto à inclinação do pilar, comparando-os com as tolerâncias essenciais e funcionais definidas pelo Quadro B.17-1 da norma. Para a avaliação utilizaram-se os dados obtidos do topo de cada elemento com uma comparação entre modelos.

Tabela 5: Resultados obtidos para o Quadro B.17-1 da NP EN 1090-2:2020 .

Elemento	Tolerâncias essenciais	Tolerâncias funcionais (mm)		Desvios obtidos (mm)
	(mm)	Classe 1	Classe 2	
1	$\Delta = \pm 11,7$ mm	$\Delta = \pm 11,7$ mm	$\Delta = \pm 7,00$ mm	$\Delta x = 1,10$ mm $\Delta y = 5,20$ mm
2	$\Delta = \pm 11,7$ mm	$\Delta = \pm 11,7$ mm	$\Delta = \pm 7,00$ mm	$\Delta x = 3,30$ mm $\Delta y = 4,10$ mm
3	$\Delta = \pm 11,5$ mm	$\Delta = \pm 11,5$ mm	$\Delta = \pm 6,90$ mm	$\Delta x = 8,80$ mm $\Delta y = 6,00$ mm
4	$\Delta = \pm 11,9$ mm	$\Delta = \pm 11,9$ mm	$\Delta = \pm 7,2$ mm	$\Delta x = 11,80$ mm $\Delta y = -3,80$ mm

- **Tolerâncias essenciais**

As tolerância essenciais, neste caso, são atendidas, embora os resultados obtidos para o elemento 4 sejam alarmantes.

- Elemento 1 e 2: Desvios na direção XX e YY cumprem os limites da tolerância essenciais.
- Elemento 3: Desvios na direção XX e YY ainda permanecem dentro dos limites, porém estão mais próximos do limite superior.

- Elemento 4: O desvio na direção XX alcança o limite máximo imposto pela norma, sinalizando a existência de problemas de alinhamento ou montagem deste elemento. No caso da direção YY, os valores obtidos estão abaixo da tolerância, apresentando um desvio negativo, contrariamente aos demais.

- **Tolerâncias funcionais:**

As tolerâncias funcionais (Classe 1 e Classe 2) são mais rigorosas e visam prevenir problemas estéticos ou facilidade de instalação.

- Elemento 1 e Elemento 2: Os desvios obtidos tanto para a direção XX quanto para a direção YY estão dentro das tolerâncias de Classe 1 e Classe 2.
- Elemento 3: O desvio na direção XX excede a tolerância de Classe 2, mas está dentro da tolerância para a Classe 1.
- Elemento 4: O desvio na direção XX excede as tolerâncias de Classe 2, enquanto na direção YY está dentro de ambas as classes.

Pode-se concluir que os desvios geométricos analisados estão, na sua maioria, dentro das tolerâncias essenciais, garantindo a segurança estrutural dos pilares. Contudo, os resultados obtidos para o elemento 4, principalmente na direção XX, sugerem a necessidade de aplicação de medidas de prevenção como por exemplo inspeção periódica e o rastreamento do estado do desvio. A Figura 65 oferece uma representação comparativa das diferenças entre o modelo *As-Is* e o modelo *As-Design* para cada elemento. O ensaio foi realizado para cortes semelhantes na estrutura, onde se pode verificar desvios mais acentuados nos elementos 3 e 4.

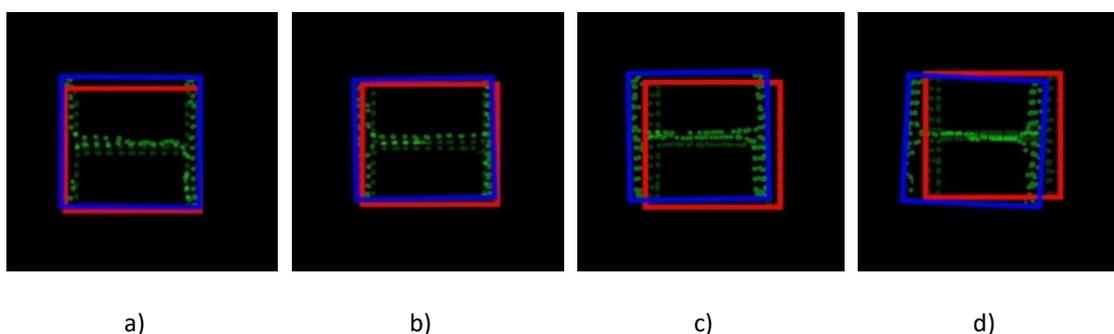


Figura 65: Representação comparativa para o Quadro B.17-1 da norma, modelo *As-Is* (a azul) e modelo *As-Design* (a vermelho). a) Elemento 1; b) Elemento 2; c) Elemento 3; d) Elemento 4.

3.7.2 Retilinearidade de colunas de um só andar

Para avaliar a retilinearidade dos pilares analisaram-se os dados obtidos a partir da secção a meio vão de cada pilar. A Tabela 6 apresenta os resultados dos desvios geométricos obtidos para os elementos analisados, comparando-os com as tolerâncias essenciais definidas pelo Quadro B.17-5 da norma.

Tabela 6: Resultados obtidos para o Quadro B.17-5 da NP EN 1090-2:2020 .

Elemento	Tolerâncias essenciais	
	Classes 1 ou 2	Desvios obtidos
1	$\Delta = \pm 3,50 \text{ mm}$	$\Delta x = 2,60 \text{ mm}$
		$\Delta y = 0,70 \text{ mm}$
2	$\Delta = \pm 3,50 \text{ mm}$	$\Delta x = 4,60 \text{ mm}$
		$\Delta y = -0,40 \text{ mm}$
3	$\Delta = \pm 3,45 \text{ mm}$	$\Delta x = -2,10 \text{ mm}$
		$\Delta y = 3,40 \text{ mm}$
4	$\Delta = \pm 3,58 \text{ mm}$	$\Delta x = -0,20 \text{ mm}$
		$\Delta y = -2,40 \text{ mm}$

- **Tolerâncias essenciais**

- Elemento 1 e 3: Os desvios determinados para o Elemento 1, em ambas as direções, estão dentro dos limites impostos pelas tolerâncias essenciais.
- Elemento 2: O desvios na direção XX excede ligeiramente a tolerância essencial, sinalizando a necessidade de ajustes para garantir a integridade estrutural. Na direção YY, o desvio encontrado é insignificante e está bem dentro dos limites.
- Elemento 4: Apesar do resultados obtido anteriormente, o Elemento 4 apresenta desvios abaixo dos limites permitidos a meio vão do pilar, em ambas as direções.

A Tabela 6 permite concluir que a maioria dos elementos avaliados estão dentro das tolerâncias essenciais definidas pela norma. Contudo, o Elemento 2 apresentou um desvio acima do limite permitido, novamente na direção XX, o que indica a necessidade de ajustes nessa direção. A Figura 66 oferece uma representação gráfica dos desvios encontrados a meio vão de cada elemento.

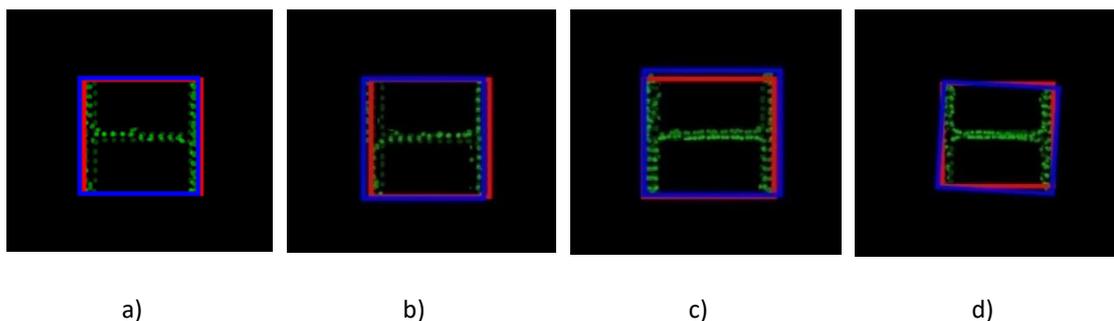


Figura 66: Representação comparativa para o Quadro B.17-5 da norma, modelo *As-Is* (a azul) e modelo *As-Design* (a vermelho). a) Elemento 1; b) Elemento 2; c) Elemento 3; d) Elemento 4.

3.7.3 Posicionamento em planta dos pilares

Para avaliar as tolerâncias quanto ao posicionamento de pilares, aplicou-se a metodologia na base dos pilares em ambos os modelos. A Tabela 7 apresenta os resultados dos desvios geométricos obtidos para os elementos analisados, comparando-os com as tolerâncias funcionais definidas pelo Quadro B.20-1 da norma.

Tabela 7: Resultados obtidos para o Quadro B.20-1 da NP EN 1090-2:2020 .

Elemento	Tolerâncias funcionais		Desvios obtidos
	Classe 1	Classe 2	
1	$\Delta = \pm 10,0 \text{ mm}$	$\Delta = \pm 5,0 \text{ mm}$	$\Delta x = 2,60 \text{ mm}$ $\Delta y = -6,00 \text{ mm}$
2	$\Delta = \pm 10,0 \text{ mm}$	$\Delta = \pm 5,0 \text{ mm}$	$\Delta x = 7,00 \text{ mm}$ $\Delta y = -6,20 \text{ mm}$
3	$\Delta = \pm 10,0 \text{ mm}$	$\Delta = \pm 5,0 \text{ mm}$	$\Delta x = -10,80 \text{ mm}$ $\Delta y = -0,40 \text{ mm}$
	$\Delta = \pm 10,0 \text{ mm}$	$\Delta = \pm 5,0 \text{ mm}$	$\Delta x = -12,80 \text{ mm}$

- **Tolerâncias funcionais**

- Elemento 1: Este elemento apresenta desvios dentro dos limites das tolerâncias funcionais, apenas para a Classe 1, em ambas as direções. No entanto, o desvio na direção YY está ligeiramente acima do limite da Classe 2.
- Elemento 2: Os desvios em ambas as direções estão dentro da tolerância da Classe 1, mas ultrapassam o limite da Classe 2.
- Elemento 3: O desvio na direção XX ultrapassa o limite permitido para ambas as classes. Contudo, na direção YY, os desvios encontrados estão bem dentro dos limites.
- Elemento 4: O desvio na direção XX é crítico, ultrapassando tanto o limite da Classe 1 quanto da Classe 2. No entanto, o desvio na direção YY está dentro dos limites para ambas as classes.

Ao analisar a Figura 67, observa-se que os elementos 3 e 4 apresentam desvios consideráveis, especialmente na direção XX, quando comparados aos elementos 1 e 2, que exibem desvios menores.

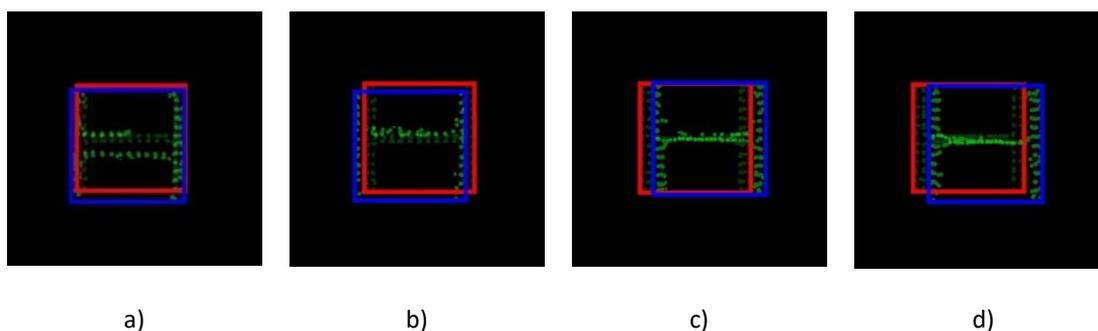


Figura 67: Representação comparativa para o Quadro B.20-1 da norma. a) Elemento 1; b) Elemento 2; c) Elemento 3; d) Elemento 4.

4 Caso de estudo

4.1 Enquadramento

O presente capítulo apresenta a aplicação da metodologia desenvolvida, descrita no capítulo 3, a um edifício industrial, localizado em Travanca, Amarante, Portugal (coordenadas GPS: 41,264592° N, -8,210002° W), conforme ilustra a Figura 68. O ensaio consistiu no levantamento geométrico do modelo 3D *As-Is* da estrutura metálica em fase de construção, com recurso às tecnologias digitais. A estrutura é composta por quatro naves industriais geometricamente idênticas, sendo que o presente relatório se foca na análise dos desvios das naves 3 e 4, uma vez que, à época do levantamento, se encontravam numa fase de construção menos avançada, facilitando a observação dos elementos estruturais.

O levantamento geométrico da estrutura teve uma duração aproximada de quatro horas, realizada entre as 9h e as 13h do dia 28 de maio de 2024. As condições meteorológicas do dia apresentaram céu limpo e alta luminosidade, sem qualquer presença de nuvens, embora essas condições não fossem ideais para a captura dos dados, especialmente para a fotogrametria, devido ao elevado contraste causado pela cor branca da estrutura. Para a aquisição dos modelos tridimensionais, foram utilizados dois métodos de captura da realidade por meio de nuvens de pontos: a fotogrametria aérea e o LiDAR. A equipa de levantamento dividiu-se e a aquisição dos dados foi realizada em paralelo.

No dia do levantamento, a estrutura já possuía diversos elementos estruturais executados, incluindo pilares, vigas, contraventamentos e algumas paredes pré-fabricadas. No entanto, ainda havia elementos estruturais por executar. A presença das paredes pré-fabricadas entre os pilares representou um desafio para a metodologia, uma vez que impediu a captação completa da geometria e da secção dos pilares nessas regiões.



Figura 68: Edifício industrial em Travanca, Amarante, Portugal.

4.2 Memória descritiva do projeto

O modelo 3D do projeto, representado na Figura 69, foi exportado diretamente do *software* de modelação *Tekla Structures*. Para suportar a metodologia, o modelo foi disponibilizado em formato IFC, destacando-se as naves 3 e 4, que são o foco de análise deste relatório. Este modelo permitiu a extração das coordenadas nodais e das características dos elementos estruturais, facilitando a sua análise posterior. A Figura 70 proporciona uma visão clara da disposição das naves industriais do caso de estudo. Por fim, a Figura 71, apresenta a esquematização e identificação dos elementos estruturais, como pilares e vigas, bem como a organização dos pórticos em cada nave.



Figura 69: Modelo 3D *As-Design* (retirado de Blender).



Figura 70: Representação do alçado das naves do caso de estudo.

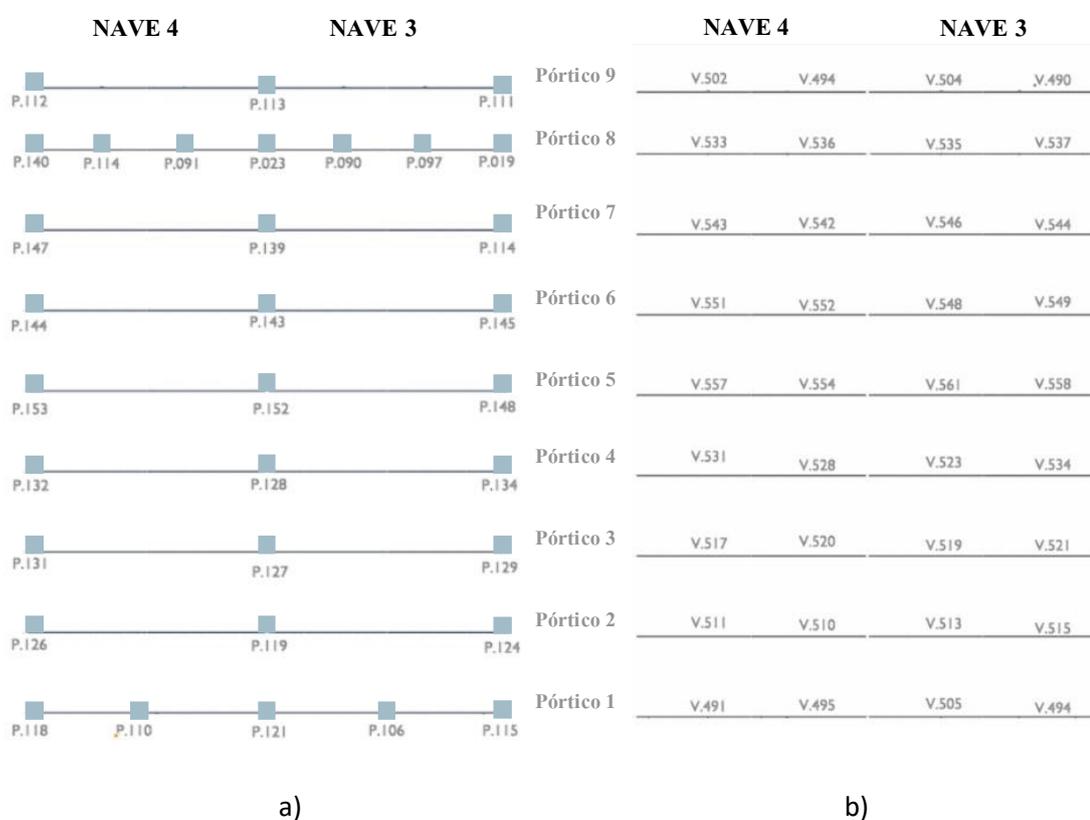


Figura 71: Planta do caso de estudo com a representação dos pórticos do caso de estudo. a) Disposição em planta dos pilares; b) Disposição em planta das vigas.

As Tabela 8 e Tabela 9 apresentam uma síntese dos principais componentes estruturais da nave 3 e da nave 4, respetivamente. Os dados foram extraídos diretamente do *Blender* e, para a organização das tabelas, foram categorizados por pórticos estruturais, facilitando a visualização da disposição da estrutura em pórticos. A organização das tabelas inclui os elementos estruturais que constituem cada pórtico, as secções transversais e comprimentos. As tabelas

completas contendo os elementos estruturais de ambas as naves podem ser consultadas em anexo deste relatório.

Tabela 8: Memória descritiva da nave 3

Pórtico	Elemento	Secção Transversal	Comprimento [m]
1A	P.115	HEA200	7,24
	V.494	IPE200	7,34
	P.106	HEA160	7,51
	V.505	IPE200	7,34
	P.121	HEA200	7,24
(...)	(...)	(...)	(...)
9A	P.111	HEA200	7,24
	V.490	IPE220	7,34
	V.504	IPE220	7,34
	P.113	HEA200	7,24

Tabela 9: Memória descritiva da nave 4

Pórtico	Elemento	Secção Transversal	Comprimento [m]
1B	P.121	HEA200	7,24
	V.495	IPE200	7,34
	P.110	HEA160	7,52
	V.491	IPE200	7,34
	P.118	IPE270	7,24
(...)	(...)	(...)	(...)
9B	P.113	HEA200	7,24
	V.499	IPE220	7,34

V.502	IPE220	7,34
P.112	IPE270	7,24

4.3 Aquisição e processamento de dados

4.3.1 Fotogrametria com UAV

No caso da fotogrametria aérea, foi utilizado o drone *DJI Mavic 3 (M3M)*, controlado através do *software DJI Pilot*, para capturar imagens de alta resolução do local. Inicialmente, realizaram-se dois voos nadir, a uma altitude de 35 metros, em modo orto-coleção. Cada voo teve a duração aproximada de 1 minuto de 50 segundos, com o GSD igual a 0,95 cm/pixel. Estes voos permitiram a aquisição de dados globais, como o reconhecimento e localização da área de estudo. De seguida, foram realizados quatro voos manuais com recurso à técnica *close-range* para captar 1200 imagens de diferentes perspetivas da envolvente dos elementos estruturais de interesse. Para assegurar a precisão e georreferenciação dos modelos 3D, foram utilizados 10 GCPs, de modo a facilitar o alinhamento e integração dos dados.

O processamento dos dados fotogramétricos foi realizado no *software Agisoft Metashape*. O fluxo do processamento de dados consistiu nos seguintes passos:

1. **Estimativa de qualidade das imagens:** Após a importação das imagens obtidas no levantamento, foi realizada uma estimativa de qualidade das imagens, resultando na remoção de 28 imagens com incongruências na qualidade.
2. **Alinhamento das imagens:** O alinhamento das imagens foi feito com a configuração *High Quality*, utilizando os metadados obtidos do UAV para assegurar a precisão no ajuste das imagens capturadas, recriando uma nuvem esparsa, conforme representado na Figura 72.

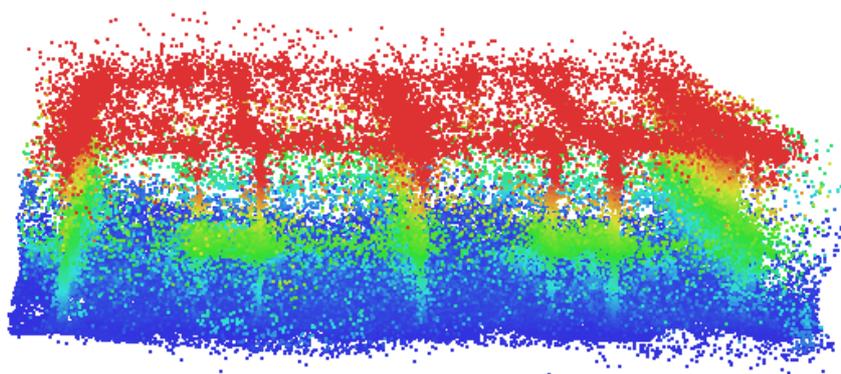


Figura 72: Nuvem esparsa com filtro de elevação, obtida após o alinhamento das imagens.

3. **Alteração do sistema referencial:** Foi necessário ajustar o sistema referencial do modelo, aplicando o geóide GeodPT08 – EGM89, que é o mais adequado para Portugal. Esse geóide foi obtido no *website* da *Agisoft*.
4. **Importação dos GCPs:** Os GCPs foram importados para o *Metashape*, onde os alvos foram marcados nas imagens. Em seguida, aplica-se uma otimização dos parâmetros da câmara, melhorando a precisão do modelo 3D.
5. **Aplicação de filtros de qualidade:** Após o alinhamento das imagens e georreferenciação do modelo, a nuvem esparsa foi submetida a uma série de filtros para garantir a qualidade da reconstrução 3D: i) Erro de projeção < 0.4 onde, pontos com erros de projeção superiores a 0.4 foram removidos; ii) Incerteza de reconstrução < 200 , que permitiu aumentar a confiança da nuvem, ao eliminar pontos com incerteza de reconstrução elevada, superiores a 200; iii) Precisão de projeção < 20 , que excluiu pontos com desvios superiores ao limite estabelecido.
6. **Divisão em *tiles*:** Para otimizar o processamento e reduzir os custos computacionais, o modelo foi dividido em três zonas (*tiles*), facilitando a reconstrução da nuvem de pontos.
7. **Reconstrução da nuvem de pontos:** A nuvem de pontos foi gerada com a configuração *High Quality*, obtendo um alto nível de detalhe.
8. **Fusão dos *tiles*:** Após a criação dos *tiles*, foi realizado um processo de *merge* de forma a integrar todas as zonas e gerar um modelo único final fotogramétrico.

O modelo 3D fotogramétrico da estrutura está representado na Figura 73.

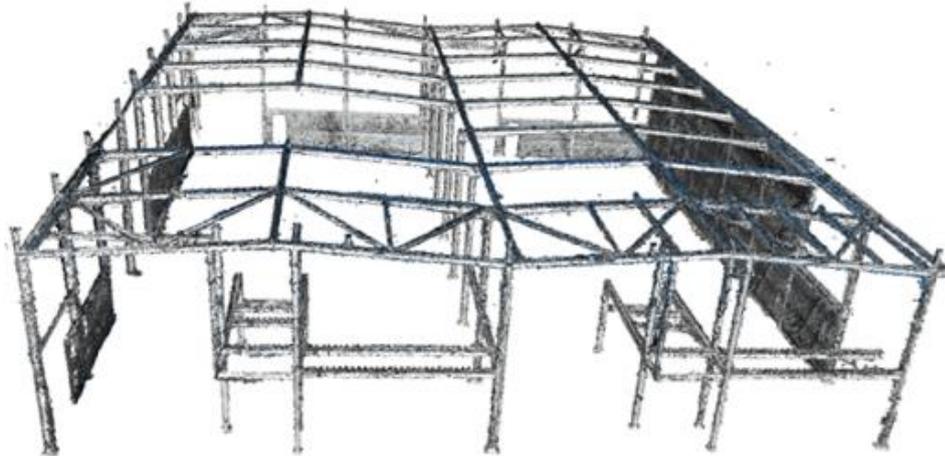


Figura 73: Modelo 3D fotogramétrico do caso de estudo em Amarante.

4.3.2 LiDAR

Para complementar as características da fotogrametria aérea, foi realizado um levantamento terrestre com o *laser scanner* BLK360 G1, em conjunto com a tecnologia MLS, através de um iPad, para captar detalhes na base dos elementos. O levantamento consistiu em 32 estações, garantindo a cobertura integral da estrutura. O BLK360 foi configurado para captar os pontos com uma densidade média, sendo que cada estação teve a duração aproximada de 2 minutos e 50 segundos. A otimização dos *links* foi realizada em tempo real, após cada estação no *software* Cyclone Field. O processamento dos dados LiDAR seguiu a metodologia descrita no Capítulo 3. Numa primeira fase, os dados foram importados para o *software* Cyclone REGISTER 360, onde foram criados e otimizados os *links* entre estações, totalizando 81 *links* entre as 32 estações (ver Figura 74a)). Após esta etapa, o modelo foi georreferenciado com a marcação manual dos GCPs obtidos no local, conforme demonstra a Figura 74b).

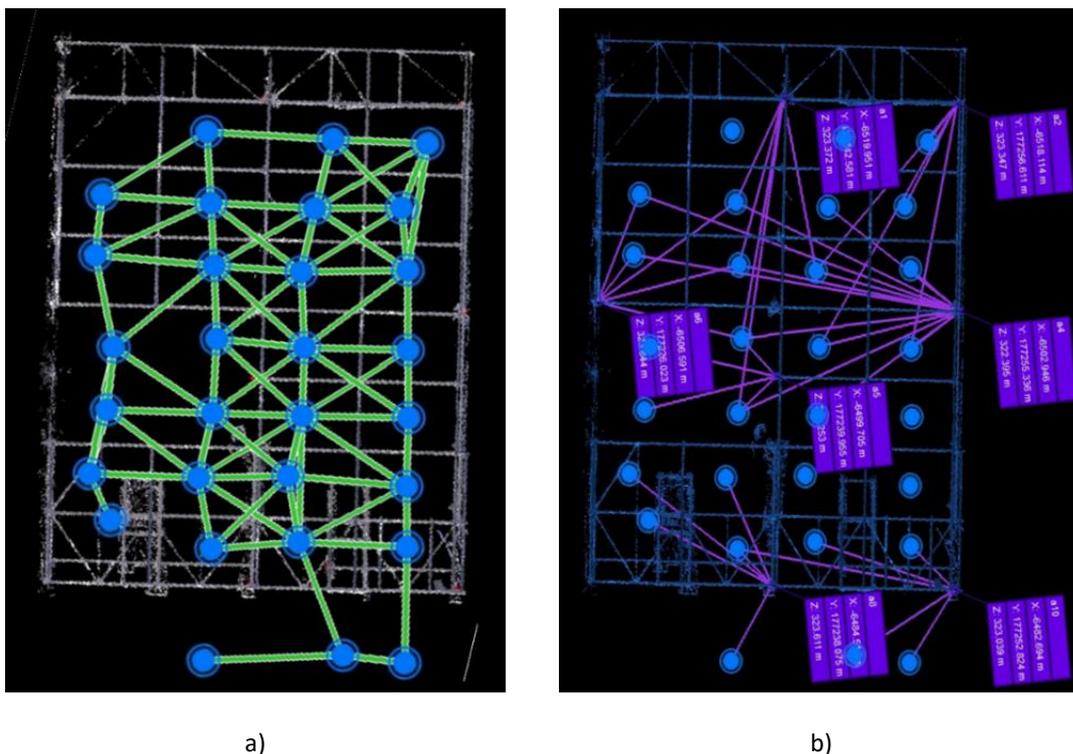


Figura 74: Dados obtidos após o processamento de dados no *software Cyclone REGISTER 360*. a) Posicionamento das estações BLK durante o levantamento e respetivos *links*; b) Posicionamento dos GCP e respetivas marcações a cor roxo desde cada estação.

De seguida, procedeu-se à otimização final do *bundle*, com o resultado das métricas de erro representadas na Figura 75. O *bundle error* foi calculado em torno de 3 mm, sendo que o *overlap* entre *nuvens* atingiu 68% e a *strength* chegou aos 71%. O modelo final foi exportado, após a sua limpeza, em formato .e57 e está representado na Figura 76.

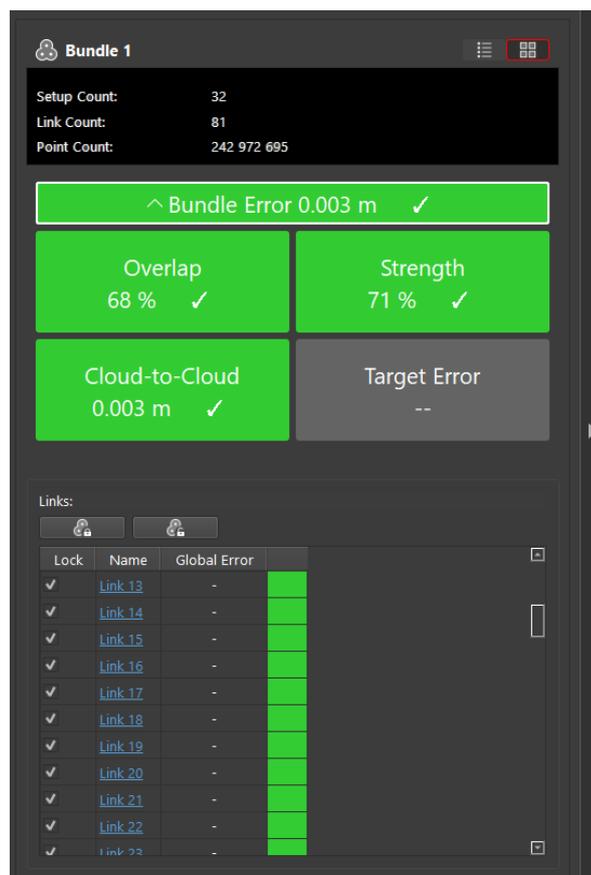


Figura 75: Métricas de erro obtidas para o bundle.

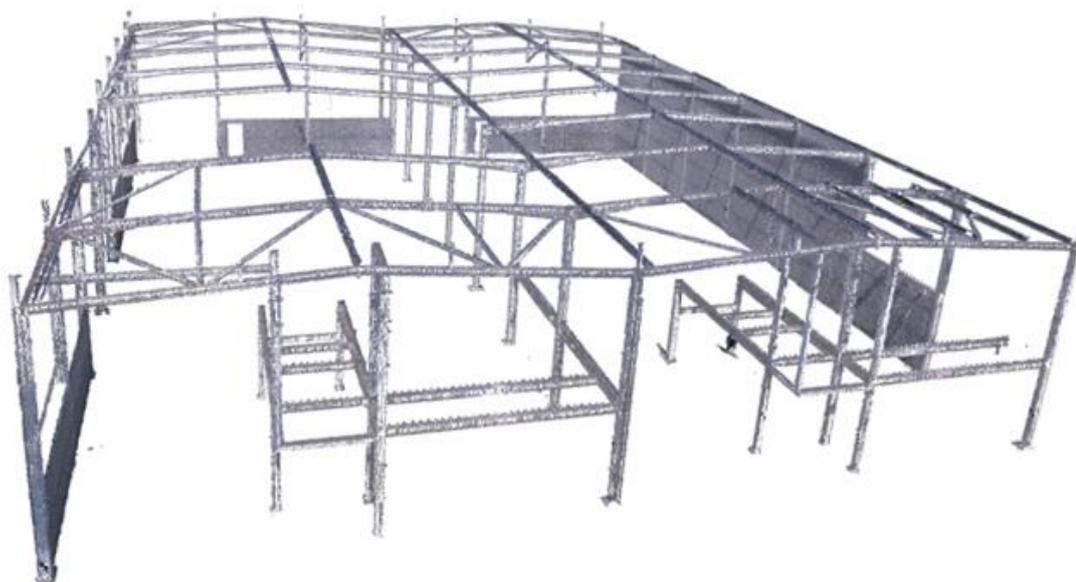


Figura 76: Modelo 3D LiDAR do caso de estudo em Amarante.

4.3.3 Fusão das nuvens de pontos

Com ambos os modelos prontos, foi importada a nuvem de pontos LiDAR para o *Metashape*. Face ao processo de georreferenciação de ambos os modelos no mesmo sistema de coordenadas, o processo de fusão de dados foi direto e automático. O *software* reconheceu a correspondência entre as duas nuvens, o que permitiu o *merge* da informação sem necessidade de ajustes manuais. A fusão dos dados resultou num único modelo combinado, conforme apresenta a Figura 77.

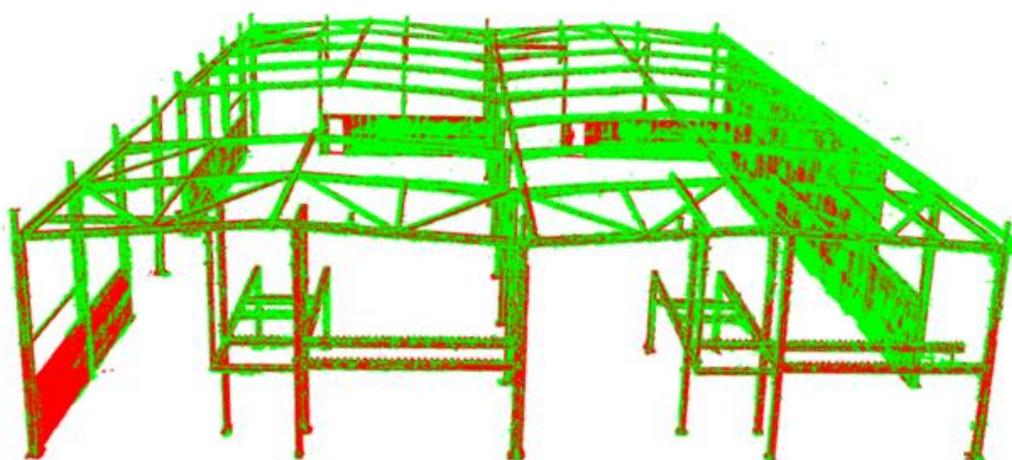


Figura 77: Fusão das nuvens de pontos (cor verde – fotogrametria, vermelho – LiDAR).

4.3.4 Modelo As-Design

Conforme descrito anteriormente, o ficheiro foi importado para o *Blender 4.2*, onde se procedeu à remoção dos elementos que não estavam implementados no dia do levantamento. Após a limpeza, foi possível extrair as coordenadas nodais de cada elemento, que serviram de base para a criação do *wireframe* do modelo, conforme representa a Figura 78. O *wireframe* criado permite a visualização da estrutura completa em forma de “esqueleto”, onde cada linha (de cor preta) representa o eixo central de cada elemento. Através desta abordagem, é possível comparar a localização dos elementos estruturais com precisão milimétrica, uma vez que o *wireframe* oferece uma visão clara das posições teóricas dos pilares, vigas e outros componentes principais.

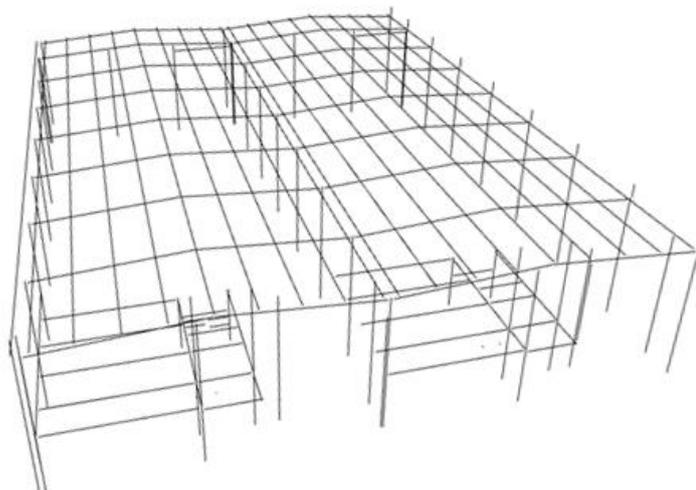


Figura 78: Representação do *wireframe* do caso de estudo em Amarante.

Além disso, a extração das características de cada elemento, como, por exemplo a classe do perfil, desempenhou um papel crucial para a metodologia. Esta etapa permitiu identificar as classes dos perfis estruturais, e associá-las diretamente às secções transversais obtidas pelo algoritmo de extração das secções. A partir deste algoritmo, é possível determinar o tipo de perfil correspondente nas imagens geradas, o que facilita a análise de cada componente estrutural ao longo do processo.

4.4 Alinhamento dos modelos *As-Is* e *As-Design*

A metodologia criada requer a comparação dos modelos obtidos com o modelo teórico de projeto. Nesse contexto, a georreferenciação do modelo *As-Design* é uma componente essencial para a validação dos resultados. No entanto, a ausência de georreferenciação do modelo *As-Design* representou um desafio significativo para o processo de análise dos desvios geométricos. Este fator impediu a correspondência direta das coordenadas espaciais entre o modelo teórico e os dados georreferenciados obtidos durante o levantamento. Deste modo não foi possível, neste caso, realizar a verificação do posicionamento em planta dos elementos conforme a norma. Como solução, foi necessário recorrer ao algoritmo ICP para realizar o alinhamento entre o modelo *As-Is* e o modelo *As-Design*. O ICP permitiu ajustar os dois modelos, minimizando as distâncias entre os pontos correspondentes. Os resultados das métricas obtidas encontram-se na Tabela 10.

Tabela 10: Métricas gerais calculadas com base nos modelos *As-Is* e *As-Design* após o alinhamento ICP.

Métrica	Valor [m]
Distância média	0,020427
Desvio Padrão	0,070415
Erro Absoluto Médio (MAE)	0,020603
Erro Quadrático Médio (RMSE)	0,073368
Distância de <i>Hausdorff</i>	1.593688
M3C2	0,012584

Conforme demonstram as métricas apresentadas, a distância média à escala centimétrica e o baixo MAE indicam um bom ajuste global entre os dois modelos. No entanto, o desvio padrão relativamente elevado sugere que existem desvios indesejáveis, o que é ainda mais evidente pela elevada distância de Hausdorff, que sinaliza a existência de *outliers*, possivelmente devido a dados insuficientes do modelo *As-Is* ou até de deformações estruturais existentes.

Por outro lado, as métricas C2C descritas na Tabela 11 fornecem uma visão mais detalhada, mostrando que a maior diferença ocorre na direção do modelo *As-Is* para o *As-Design*. Isso reforça a hipótese que o modelo *As-Is* apresenta dados insuficientes comparativamente ao modelo *As-Design*, resultando em discrepâncias elevadas nos valores máximos, apesar dos valores mínimos e a média (C2C) serem relativamente baixos.

Tabela 11: Métricas C2C entre o modelo *As-Is* e o modelo *As-Design*

Métrica	<i>As-Design</i> para <i>As-Is</i> [m]	<i>As-Is</i> para <i>As-Design</i> [m]
Distância Mínima	0,000074	0,000077
Distância Máxima	0,339629	1,593688
Distância Média	0,027711	0,020603
Mediana	0,012211	0,013487

Pode-se concluir que o alinhamento global dos modelos é satisfatório, porém, os resultados sugerem que ainda há espaço para melhorias. Para isso, será necessário aplicar novas técnicas

de processamento inicial das nuvens, aprimorar a filtragem de *outliers* no modelo *As-Is*, ou, idealmente, georreferenciar o modelo teórico, prevenindo a necessidade de alinhamentos subsequentes e aumentando significativamente a precisão da metodologia.

4.5 Resultados obtidos

Nesta secção, são apresentados os resultados do levantamento geométrico realizado para o caso de estudo apresentado. Para avaliar os desvios geométricos da estrutura, foram utilizadas as tolerâncias de montagem estabelecidas pela norma NP EN 1090-2:2020. Para o caso específico deste estudo, foram consideradas quatro categorias de tolerâncias para os pilares da estrutura, conforme os Quadros B.17 e B.20 da norma:

- Quadro B.17-1: Inclinação de colunas de edifícios com um só andar
- Quadro B.17-2: Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas
- Quadro B.17-5: Retilinearidade de colunas de um só andar.
- Quadro B.20-1: Posicionamento em planta dos pilares

Os resultados apresentados seguem os critérios estabelecidos nos quadros mencionados acima, comparando os desvios medidos com as tolerâncias permitidas. As tabelas apresentadas neste capítulo são uma síntese dos resultados obtidos, sendo que os resultados são descritos em anexo. Os desvios apresentados nas tabelas abaixo foram obtidos de forma automática a partir da comparação das *oriented bounding boxes*, conforme descrito no Capítulo 3 do presente relatório. Esta comparação foi realizada através de cortes aplicados nas regiões em estudo, seja no topo, na base ou a meio vão dos elementos. Em alguns casos apresentados, os desvios geométricos apresentam valores não definidos (ND), marcados com (-). Estes resultados devem-se à presença de elementos não estruturais, como paredes divisórias, que impediram a captação completa das secções transversais dos elementos, algo que deve ser tido em conta em trabalhos de campo futuros. A Figura 79 demonstra o processo aplicado a quatro exemplos de imagens reais. Cada caso inclui quatro fases: a) imagem original, b) imagem inferida pelo modelo, c) imagem filtrada e d) comparação com o modelo teórico, representando as OBBs do modelo teórico e prático sobrepostos.

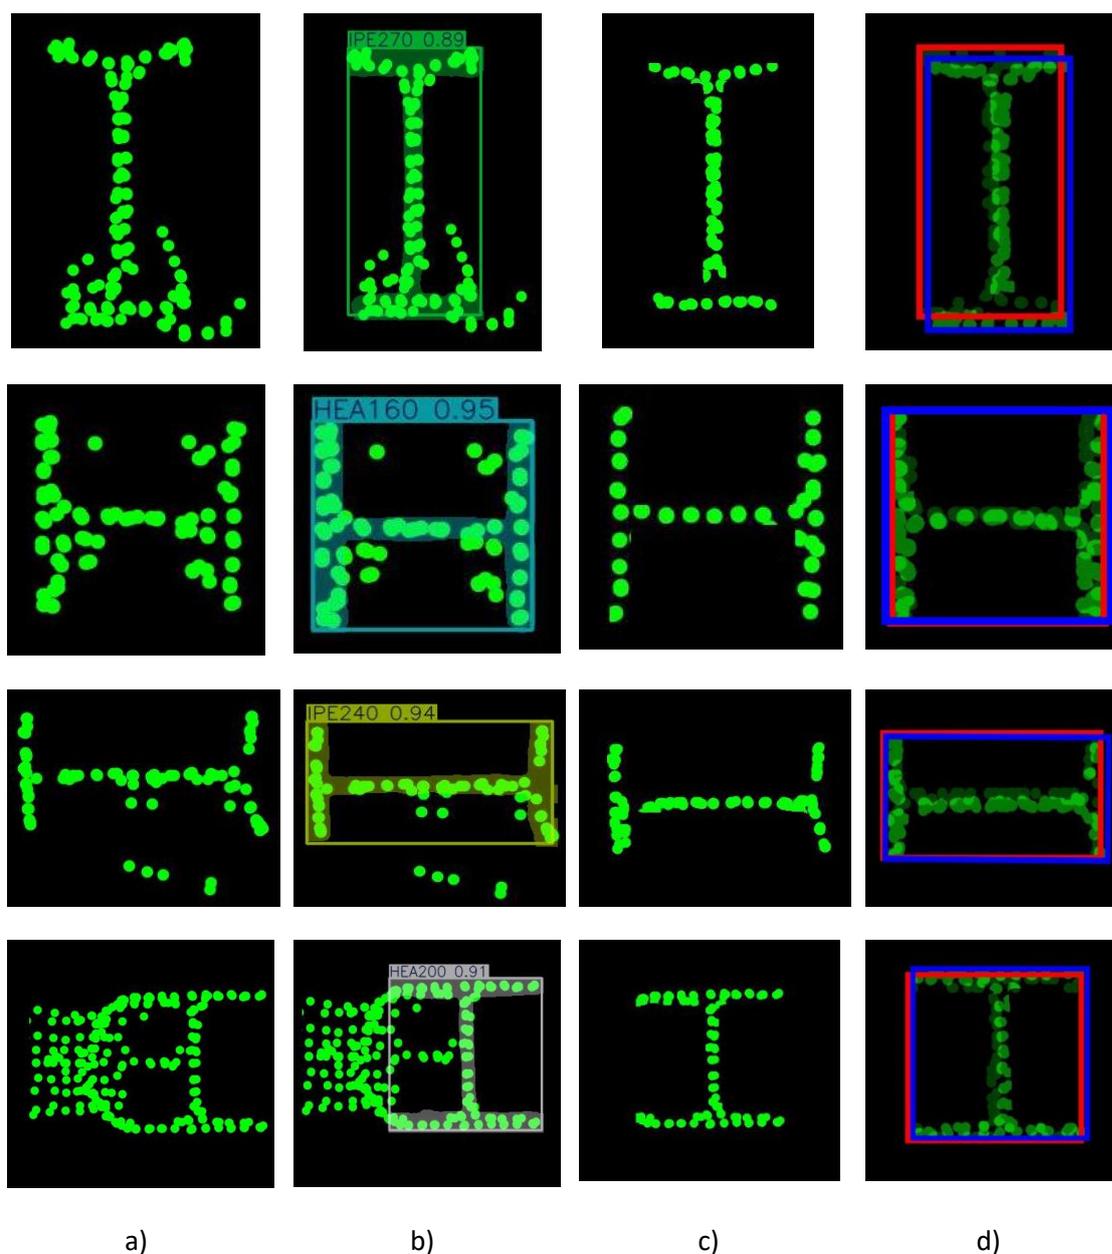


Figura 79: Metodologia aplicada a quatro exemplos reais P.132 (IPE270), P.110 (HEA160), P.091 (IPE240) e P.127 (HEA200), respetivamente.

4.5.1 Inclinação de colunas de edifícios com um só andar

A Tabela 12 apresenta um excerto dos desvios obtidos para os pilares do caso de estudo, em conformidade com o Quadro B.17-1 da NP EN 1090-2:2020. Este quadro estabelece as tolerâncias de inclinação das colunas em edifícios de um andar. Foram determinadas as tolerâncias essenciais e funcionais, e, em seguida, comparadas com os desvios geométricos reais medidos no topo de cada pilar, nas direções Δx e Δy , respetivamente.

De forma geral, os resultados para este critério encontram-se dentro das tolerâncias impostas pela norma. No entanto, em alguns casos, como o do P.132, o desvio na direção YY ultrapassa claramente o valor estipulado. Este valor era esperado, uma vez que, durante o levantamento, verificou-se a ausência da ligação asna/pilar neste pórtico, o que evidenciou a inclinação do pilar. Os resultados completos, com os desvios medidos para todos os pilares avaliados, encontram-se disponíveis em anexo a este relatório, onde são detalhadas as comparações para cada pilar individualmente.

Tabela 12: Resultados obtidos para o Quadro B.17-1 – Inclinação de colunas de edifícios com um só andar da NP EN 1090-2:2020 .

Elemento	Tolerâncias		Tolerâncias		Desvio no topo		Validação
	Essenciais [cm]	Funcionais [cm]		obtido [cm]			
		Classes 1 e 2	Classe 1	Classe 2	Δx	Δy	
P.115	2,413	2,413	1,448	0,397	-0,556	OK	
		(...)					
P.132	2,413	2,413	1,448	0,317	-5,583	KO	
		(...)					
P.091	2,453	2,453	1,472	-0,168	-0,066	OK	

4.5.2 Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas

A Tabela 13 apresenta os resultados parciais obtidos para as tolerâncias definidas pelo critério 2 do Quadro B.17-2 da norma NP EN 1090-2:2020. Este critério especifica as tolerâncias funcionais para a inclinação de colunas individuais em edifícios em pórtico com travessas inclinadas. Para a obtenção dos resultados para este critério, os desvios foram determinados a partir de cortes realizados na base e no topo de cada pilar, permitindo analisar individualmente os desvios em cada pilar do pórtico. De modo geral, os desvios calculados encontram-se enquadrados com as tolerâncias estabelecidos, tanto para a Classe 1 quanto para a Classe 2. Porém, alguns casos destacam-se por apresentarem desvios significativos que devem ser considerados para possível intervenção. Os resultados completos da Tabela 13 encontram-se

apresentados em anexo a este relatório, onde os desvios são detalhados para cada pórtico e para cada nave do caso de estudo. Destaca-se que os pórticos 1 e 8 de cada nave não foram considerados para esta avaliação, pois não se enquadram nos critérios definidos pela norma. Esses pórticos, em particular, devem ser compostos por dois pilares e duas vigas inclinadas, conforme os requisitos de configuração estrutural para este tipo de construção.

Tabela 13: Resultados obtidos para o Quadro B.17-2 – Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas da NP EN 1090-2:2020 .

Nave	Pórtico	Elemento	Tolerâncias Funcionais [cm]		Desvio obtido [cm]	Validação	
			Classe 1	Classe 2			
Nave 3	2A	P.124	4,827	2,413	$\Delta 1$	-	ND
		P.119	4,827	2,413	$\Delta 2$	0,132	OK
(...)							
Nave 4	2B	P.119	4,827	2,413	$\Delta 1$	0,132	OK
		P.126	4,827	2,413	$\Delta 2$	0,662	OK

4.5.3 Retilinearidade de colunas de um só andar

O critério 5 do Quadro B.17 da norma, estabelece os limites de retilinearidade dos pilares, avaliando os desvios em relação ao eixo central ideal de cada elemento. A retilinearidade refere-se à capacidade do pilar de manter-se alinhado com esse eixo central ao longo de toda a sua altura. Para avaliar este critério, os desvios geométricos foram medidos nas direções Δx e Δy a partir de cortes aplicados a meio vão de cada elemento. Ao analisar os resultados parciais da Tabela 14, verifica-se que a maioria dos pilares estão dentro dos limites impostos pela norma. No entanto, alguns pilares, como o P.128, P.126 e P.139, ultrapassaram ligeiramente as tolerâncias numa direção, sinalizando a necessidade de uma possível correção.

Tabela 14: Resultados obtidos para o Quadro B.17-5 – Retilinearidade de colunas de um só andar da NP EN 1090-2:2020 .

Elemento	Tolerâncias Essenciais [cm]		Desvio obtido [cm]	Validação

	Classes 1 e 2	Δx	Δy	
P.128	0,724	-0,816	0,436	KO
P.139	0,724	-0,397	0,767	KO
P.126	0,724	0,026	0,794	KO
	(...)			
P.091	0,736	-0,238	-0,079	OK

4.5.4 Posicionamento em planta dos pilares

Na Tabela 15 estão representados os resultados obtidos referentes ao posicionamento em planta dos pilares para o critério 1 do Quadro B.20 da norma NP EN 1090-2:2020 . Este critério estabelece as tolerâncias para a localização dos pilares no plano horizontal, comparando a posição teórica com a posição real. Os desvios foram medidos em ambas direções, a partir de cortes aplicados na base de cada pilar. De modo abrangente, a maioria dos pilares encontra-se dentro dos limites de tolerância da norma. Porém, alguns pilares, como o P.090 apresenta desvios superiores aos limites em ambas as direções e para ambas as classes. Os resultados completos são representados em anexo do presente relatório.

Tabela 15: Resultados obtidos para o Quadro B.20-1 – Posicionamento em planta dos pilares da NP EN 1090-

Elemento	Tolerâncias Funcionais [cm]		Desvios obtidos [cm]		Validação
	Classes 1	Classe 2	Δx	Δy	
		(...)			
P.090	1,000	0,500	-0,751	-1,270	KO
		(...)			
P.091	1,000	0,500	-0,423	0,079	OK

5 Considerações finais

5.1 Conclusões

Esta dissertação inseriu-se no âmbito do projeto I&D CHECK METALLIC, com o objetivo de desenvolver uma metodologia automática para o controlo de precisão geométrica em estruturas metálicas, em conformidade com a NP EN 1090 – 2 (2020). O trabalho desenvolvido combina técnicas avançadas de digitalização e a inteligência artificial (IA) para comparar modelos *As-Is* com modelos *As-Design*, permitindo a identificação automática de desvios geométricos na estrutura.

No Capítulo 2, Estado da arte, foi realizada uma análise das tecnologias emergentes aplicadas ao setor da AEC, focando-se na fotogrametria e LiDAR e nos seus princípios de funcionamento, bem como na importância de seguir as boas práticas de aquisição e processamento de dados. Ainda neste capítulo, foi abordada a aplicação de técnicas de fusão de nuvens de pontos, integrando os pontos fortes de cada tecnologia para o desenvolvimento de um modelo 3D robusto. Por fim, o capítulo realça a integração de IA, aplicada à engenharia civil, em particular os algoritmos de ML. Identificou-se a carência de aplicações semelhantes à metodologia proposta, confirmando o seu carácter inovador na identificação de desvios em estruturas metálicas.

No Capítulo 3 foi descrita a metodologia desenvolvida para a identificação de desvios geométricos. Para auxiliar na explicação da metodologia o capítulo foi subdividido em diversas etapas que sintetizam o funcionamento da metodologia.

- i. Aquisição e processamento de dados: Muito provavelmente a etapa mais importante da metodologia, uma vez que influencia diretamente a qualidade dos resultados. De forma geral, os resultados fotogramétricos apresentaram menor precisão comparativamente ao LiDAR. Atendendo aos resultados obtidos, verificou-se que o *Laser Scanner* é a ferramenta mais eficiente para aplicação da metodologia proposta.

Contudo, o processo de fusão de dados pode ser uma alternativa eficaz para contrariar a falta de precisão da fotogrametria e a incapacidade do LiDAR captar informação aérea.

- ii. Extração de características do modelo: A extração das características e do *wireframe* da estrutura a partir do modelo *As-Design* envolve dois pontos críticos. Em primeiro lugar, a georreferenciação precisa do modelo é um requisito fundamental da metodologia proposta, permitindo a comparação direta entre modelos sem a necessidade de alinhamento manuais ou iterativos. Em segundo lugar, é crucial manter a nomenclatura adequada das características dos elementos do projeto, ou seja, pilares devem ser identificados como tais, seguindo uma definição uniforme ao longo de todo o projeto.
- iii. Extração das secções transversais: O desenvolvimento deste algoritmo envolveu várias atualizações para garantir a correta adaptação a qualquer tipo estrutura. Além disso, a escolha apropriada das dimensões e do parâmetro DPI das imagens de saída foi fundamental para preservar a resolução e, ao mesmo tempo, manter detalhes importantes da secção transversal de cada perfil captado.
- iv. Modelo IA YOLOv8: A escolha do modelo revelou ser uma das maiores dificuldades, uma vez que foi necessário enquadrar as capacidades dos modelos YOLOv8 com as necessidades da metodologia. A uniformização das anotações e a criação de um *dataset* equilibrado, constituído por imagens reais capturadas em campo e imagens artificiais aumentadas, foram fatores decisivos para o sucesso e precisão do modelo. Apesar das dificuldades, o modelo mostrou-se capaz de detetar e segmentar secções transversais em imagens, confirmando o seu potencial.
- v. Processamento de imagem: A etapa de processamento de imagens utilizou as *masks* provenientes do modelo YOLOv8 para filtrar as imagens, removendo ruído e preservando apenas as características relevantes das secções transversais. Além disso, foi possível reconstruir as OBBs de cada objeto. No entanto, nesta etapa, surgiram fenómenos de descontinuidades nas OBBs, o que representou um obstáculo para a obtenção da orientação correta do objeto/perfil.
- vi. Validação com a NP EN 1090-2:2020: A validação da metodologia é realizada através da comparação entre as OBBs geradas para o modelo *As-Is* e o modelo *As-Design*. Nesse sentido, o algoritmo está preparado para comparar cortes semelhantes

aplicados aos dois modelos em simultâneo, permitindo identificar desvios geométricos conforme os estabelecidos pela norma NP EN 1090-2:2020 .

No Capítulo 4 foi apresentado o caso de estudo onde a metodologia foi testada em ambiente real. Inicialmente, são apresentados os dados obtidos através das tecnologias digitais, que, de forma geral, se revelaram de alta qualidade. O planeamento prévio e a aplicação de técnicas de boas práticas demonstraram-se fundamentais para o bom desempenho do modelo. No entanto, a presença de elementos não estruturais, como paredes divisórias entre pilares, evidenciou ser um obstáculo para a metodologia, já que impede a captação total dos elementos a avaliar. Referente à ausência da georreferenciação do modelo As-Design, esta impediu a correspondência direta das coordenadas espaciais entre modelos, tendo sido necessário adotar uma solução alternativa. Nesse contexto, realizou-se um alinhamento através do algoritmo ICP, aplicando uma transformação rígida para ajustar o modelo As-Is ao modelo As-Design. Dessa forma, foi possível utilizar as características extraídas do projeto para o algoritmo de extração de secções transversais. As métricas resultantes deste alinhamento indicaram algumas discrepâncias que afetam a precisão e fiabilidade do modelo. Ainda assim, a comparação das OBBs dos modelos demonstraram resultados positivos, permitindo a identificação automática de desvios com base nos critérios definidos pela norma. A avaliação inclui critérios como a inclinação e retilinearidade dos pilares e pórticos, bem como o posicionamento em planta dos pilares. Um dos principais destaques são os resultados obtidos para o pilar P.132, uma vez que durante o levantamento era visível um desvio acentuado neste elemento, confirmado pela aplicação da metodologia.

De uma forma geral, a metodologia desenvolvida apresentou bons resultados em todas as etapas que a compõem. Uma das principais características deste algoritmo, até à etapa de validação de desvios com a NP EN 1090-2:2020, é a sua capacidade de adaptação a qualquer projeto estrutural, não sendo exclusivo para estruturas metálicas. No entanto, seria necessário atualizar o modelo de treino do YOLOv8, enriquecendo-o com imagens apropriadas das diferentes secções transversais que poderão existir.

5.2 Desenvolvimentos futuros

De forma geral, o presente trabalho atingiu os objetivos inicialmente propostos, porém, há diversas áreas que podem ser exploradas e aprimoradas para aumentar a aplicabilidade e a

precisão da metodologia desenvolvida. Para os desenvolvimentos futuros, propõem-se as seguintes melhorias e expansões, com o objetivo de continuar a evoluir o trabalho realizado:

1. Utilização de novas tecnologias para levantamentos futuros: Como discutido, a tecnologia LiDAR apresentou resultados muito satisfatórios, sendo recomendada para aplicação da metodologia. Sugere-se a utilização de LiDAR em UAVs para o varrimento aéreo. Esta abordagem permitirá a captura de dados de forma mais precisa e eficiente, especialmente em áreas de difícil acesso.
2. Integração de um *pipeline* para a georreferenciação do modelo *As-Design*: A georreferenciação é fundamental para a metodologia, por isso, sugere-se a criação de um *pipeline* automático para a georreferenciação do modelo teórico, assegurando a precisão da comparação entre modelos.
3. Expansão do *dataset* utilizado no treino do modelo YOLOv8: O modelo de treino já apresenta resultados positivos para algumas classes. No entanto, recomenda-se a inclusão de novas imagens com um maior número de classes de perfis, o que permitirá melhorar a capacidade de deteção e segmentação do modelo.
4. Aplicação de técnicas mais refinadas para o desenvolvimento de *Oriented Bounding Boxes* (OBB): As descontinuidades e incongruências nas OBBs ainda são uma limitação. Assim, sugere-se a incorporação de novas técnicas de refinamento das OBBs.
5. Desenvolvimento da metodologia para o controlo de mais critérios em conformidade com a norma NP EN 1090: A metodologia, atualmente, avalia critérios limitados da norma. Portanto, recomenda-se o seu aprimoramento para ampliar o número de critérios verificados automaticamente, garantindo uma avaliação mais completa em conformidade com a norma.
6. Desenvolvimento de interfaces gráficas: Após os testes realizados à metodologia, sugere-se a criação de uma interface gráfica para facilitar a sua utilização, tornando o processo de deteção de desvios geométricos mais acessível a utilizadores com menor conhecimento técnico.

Referências bibliográficas

- Almeida, I. and P. Barros (2020). "Denoising Autoencoder - Deep Learning."
- Alshwabkeh, Y. and A. Baik (2023). "Integration of Photogrammetry and Laser Scanning for Enhancing Scan-to-Hbim Modeling of Al Ula Heritage Site." Heritage Science **11**(1): 147.
- Balodi, A. (2020). Application of Introduction Artificial Intelligence Machine Learning in Real Life.
- Barnhart, T. and B. Crosby (2013). "Comparing Two Methods of Surface Change Detection on an Evolving Thermokarst Using High-Temporal-Frequency Terrestrial Laser Scanning, Selawik River, Alaska." Remote Sensing, vol. 5, issue 6, pp. 2813-2837 **5**: 2813-2837.
- Bastonero, P., et al. (2014). "Fusion of 3d Models Derived from TIs and Image-Based Techniques for Ch Enhanced Documentation." ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci. **II-5**: 73-80.
- Besl, P. J. and N. D. McKay (1992). "A Method for Registration of 3-D Shapes." IEEE Transactions on Pattern Analysis and Machine Intelligence **14**(2): 239-256.
- Bouziani, M., et al. (2021). "Evaluation of 3d Building Model Using Terrestrial Laser Scanning and Drone Photogrammetry." The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences **XLVI-4/W4-2021**: 39-42.
- Bruno, N., et al. (2022). "Integrated Processing of Photogrammetric and Laser Scanning Data for Frescoes Restoration." Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. **XLVI-2/W1-2022**: 105-112.
- Cao, L., et al. (2023). "A Global Structure and Adaptive Weight Aware Icp Algorithm for Image Registration." **15**(12): 3185.
- Casas, E., et al. (2024). "A Comparative Study of Yolov5 and Yolov8 for Corrosion Segmentation Tasks in Metal Surfaces." Array **22**: 100351.
- Cha, Y.-J., et al. (2024). "Deep Learning-Based Structural Health Monitoring." Automation in Construction **161**: 105328.
- Cha, Y.-J., et al. (2017). "Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks." **32**(5): 361-378.
- Chagas, E. (2019). "Deep Learning E Suas Aplicações Na Atualidade." Revista Científica Multidisciplinar Núcleo do Conhecimento **04**: 05-26.
- Charbonnier, P., et al. (2013). "Accuracy Assessment of a Canal-Tunnel 3d Model by Comparing Photogrammetry and Laserscanning Recording Techniques." ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences **XL-5/W2**: 171-176.

Chatzistamatis, S., et al. (2018). "Fusion of Tls and Uav Photogrammetry Data for Post-Earthquake 3d Modeling of a Cultural Heritage Church." Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. **XLII-3/W4**: 143-150.

Corporation, A. S. S. (2023). "Steel Structure – the Future of Structure." from <https://atad.vn/steel-structure-introduction/>.

Deliry, S. I. and U. Avdan (2021). "Accuracy of Unmanned Aerial Systems Photogrammetry and Structure from Motion in Surveying and Mapping: A Review." Journal of the Indian Society of Remote Sensing **49**(8): 1997-2017.

Dering, G. M., et al. (2019). "Review of Drones, Photogrammetry and Emerging Sensor Technology for the Study of Dykes: Best Practises and Future Potential." Journal of Volcanology and Geothermal Research **373**: 148-166.

Ding, L., et al. (2018). "A Deep Hybrid Learning Model to Detect Unsafe Behavior: Integrating Convolution Neural Networks and Long Short-Term Memory." Automation in Construction **86**: 124.

Ekaso, D., et al. (2020). "Accuracy Assessment of Real-Time Kinematics (Rtk) Measurements on Unmanned Aerial Vehicles (Uav) for Direct Geo-Referencing." Geo-spatial Information Science **23**(2): 165-181.

Fabris, M., et al. (2023). "Expeditious Low-Cost Sfm Photogrammetry and a Tls Survey for the Structural Analysis of Illasi Castle (Italy)." **7**(2): 101.

Fiorillo, F., et al. (2021). Image-Based and Range-Based Dataset Integration for an Efficient 3d Representation.

Fiorillo, F., et al. (2023). "Automated Mapping of the Roof Damage in Historic Buildings in Seismic Areas with Uav Photogrammetry." Procedia Structural Integrity **44**: 1672-1679.

Galanakis, G., et al. (2021). "A Study of 3d Digitisation Modalities for Crime Scene Investigation." Forensic Sciences **1**: 56-85.

González-Collazo, S. M., et al. (2024). "Santiago Urban Dataset Sud: Combination of Handheld and Mobile Laser Scanning Point Clouds." Expert Systems with Applications **238**: 121842.

Haykin, S. S. (2009). Neural Networks and Learning Machines, Pearson.

Hu, J., et al. (2021). "Application of Structural Deformation Monitoring Based on Close-Range Photogrammetry Technology." **2021**(1): 6621440.

Huang, H.-w., et al. (2018). "Deep Learning Based Image Recognition for Crack and Leakage Defects of Metro Shield Tunnel." Tunnelling and Underground Space Technology **77**: 166-176.

Huang, Y., et al. (2019). "Review on Application of Artificial Intelligence in Civil Engineering." **121**(3): 845--875.

Iglhaut, J., et al. (2019). "Structure from Motion Photogrammetry in Forestry: A Review." Current Forestry Reports **5**(3): 155-168.

Jiang, N., et al. (2022). "A Fusion Method Using Terrestrial Laser Scanning and Unmanned Aerial Vehicle Photogrammetry for Landslide Deformation Monitoring under Complex Terrain Conditions." IEEE Transactions on Geoscience and Remote Sensing **60**: 1-1.

Kateb, F., et al. (2021). "Fruitdet: Attentive Feature Aggregation for Real-Time Fruit Detection in Orchards." Agronomy **11**: 2440.

- Kim, S., et al. (2020). "Sustainable Application of Hybrid Point Cloud and Bim Method for Tracking Construction Progress." **12**(10): 4106.
- Kovanič, L., et al. (2023). "Combined Ground-Based and Uas Sfm-Mvs Approach for Determination of Geometric Parameters of the Large-Scale Industrial Facility – Case Study." Measurement **216**: 112994.
- Kumar, A. and N. Mor (2021). An Approach-Driven: Use of Artificial Intelligence and Its Applications in Civil Engineering: 201-221.
- Li, Z., et al. (2024). "Adaptive Fusion of Different Platform Point Cloud with Improved Particle Swarm Optimization and Supervoxels." International Journal of Applied Earth Observation and Geoinformation **130**: 103934.
- Liu, J., et al. (2023). "Deep Learning Based Multi-View Stereo Matching and 3d Scene Reconstruction from Oblique Aerial Images." ISPRS Journal of Photogrammetry and Remote Sensing **204**: 42-60.
- Lowe, D. G. J. I. j. o. c. v. (2004). "Distinctive Image Features from Scale-Invariant Keypoints." **60**: 91-110.
- Lu, P., et al. (2012). "Artificial Intelligence in Civil Engineering." Mathematical Problems in Engineering **2012**.
- Luhmann, T., et al. (2020). "Fusion of Uav and Terrestrial Photogrammetry with Laser Scanning for 3d Reconstruction of Historic Churches in Georgia." **4**(3): 53.
- Marzouk, M., et al. (2024). "Artificial Neural Networks Applications in Construction and Building Engineering (1991–2021): Science Mapping and Visualization." Applied Soft Computing **152**: 111174.
- Meireles, R. (2002). Interface Com Computador Por Controlo Visual De Cursores.
- Mohammadi, M., et al. (2022). "Application of Tls Method in Digitization of Bridge Infrastructures: A Path to Brim Development." Remote Sensing **14**: 1148.
- Mois, J. G. R. (2020). Modelação De Estruturas Mistas De Aço E Betão Em Edifícios, Universidade de Coimbra.
- Nigri, I. (2009). Comparação Entre Controlos Look-and-Move E Servo-Visual Utilizando Transformadas Sift Em Manipuladores Do Tipo Eye-in-Hand, Pontifícia Universidade Católica do Rio de Janeiro
- Nwaogu, J. M., et al. (2023). "Application of Drones in the Architecture, Engineering, and Construction (Aec) Industry." Automation in Construction **150**: 104827.
- Oliveira, M., et al. (2023). "Laser Scanner in Construction Quality Control of Steel Industrial Buildings." Practice Periodical on Structural Design and Construction **28**.
- Pamuncak, A., et al. (2023). "Correlation-Based Damage Detection Method Using Convolutional Neural Network for Civil Infrastructure." Computers & Structures **282**: 107034.
- Phung and Rhee (2019). "A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets." Applied Sciences **9**: 4500.
- Qi, Z., et al. (2024). "A Novel Method for Tomato Stem Diameter Measurement Based on Improved Yolov8-Seg and Rgb-D Data." Computers and Electronics in Agriculture **226**: 109387.

- Radu, M., et al. (2020). Automatic Traffic Sign Recognition Artificial Intelligence - Deep Learning Algorithm.
- Rocheftort-Beaudoin, T., et al. (2024). From Density to Geometry: Yolov8 Instance Segmentation for Reverse Engineering of Optimized Structures.
- Sabino, R., et al. (2023). "Building Oriented Bounding Boxes by the Intermediate Use of Odops." Computers & Graphics **116**: 251-261.
- Schneider, D. (2006). "Terrestrial Laser Scanning for Area-Based Deformation Analysis of Towers and Water Damns."
- Shao, Y., et al. (2024). "3d Displacement Measurement Using a Single-Camera and Mesh Deformation Neural Network." Engineering Structures **318**: 118767.
- Shen, N., et al. (2023). "A Review of Terrestrial Laser Scanning (Tls)-Based Technologies for Deformation Monitoring in Engineering." Measurement **223**: 113684.
- Simões, R. A. D. (2007). Manual De Dimensionamento De Estruturas Metálicas.
- Son, S. W., et al. (2020). "Integrating Uav and Tls Approaches for Environmental Management: A Case Study of a Waste Stockpile Area." **12**(10): 1615.
- Soni, V., et al. (2024). "Introducing Aod 4: A Dataset for Air Borne Object Detection." Data in Brief **56**: 110801.
- Tang, P., et al. (2020). Chapter 2 - Surveying, Geomatics, and 3d Reconstruction. Infrastructure Computer Vision. I. Brilakis and C. Haas, Butterworth-Heinemann: 13-64.
- Tariq, A., et al. (2017). Heritage Preservation Using Aerial Imagery from Light Weight Low Cost Unmanned Aerial Vehicle (Uav). 2017 International Conference on Communication Technologies (ComTech).
- Ultralytics (2024). "Yolov8." from <https://docs.ultralytics.com/pt/models/yolov8/>.
- Uncuoglu, E., et al. (2022). "Comparison of Neural Network, Gaussian Regression, Support Vector Machine, Long Short-Term Memory, Multi-Gene Genetic Programming, and M5 Trees Methods for Solving Civil Engineering Problems." Applied Soft Computing **129**: 109623.
- van Riel, S. (2016). Exploring the Use of 3d Gis as an Analytical Tool in Archaeological Excavation Practice.
- Vieira, M. M., et al. (2023). "Strategy for Hbim Implementation Using High-Resolution 3d Architectural Documentation Based on Laser Scanning and Photogrammetry of the José De Alencar Theatre." Digital Applications in Archaeology and Cultural Heritage **30**: e00287.
- Wang, C.-Y., et al. (2020). Cspnet: A New Backbone That Can Enhance Learning Capability of Cnn.
- Wang, C., et al. (2022). "End-to-End Structural Analysis in Civil Engineering Based on Deep Learning." Automation in Construction **138**: 104255.
- Wang, G., et al. (2023). "Uav-Yolov8: A Small-Object-Detection Model Based on Improved Yolov8 for Uav Aerial Photography Scenarios." **23**(16): 7190.
- Wang, J., et al. (2019). "Mask Obb: A Semantic Attention-Based Mask Oriented Bounding Box Representation for Multi-Category Object Detection in Aerial Images." **11**(24): 2930.
- Wang, L., et al. (2024). "Bounding Box Vectorization for Oriented Object Detection with Tanimoto Coefficient Regression." IEEE Transactions on Multimedia **26**: 5181-5193.

- Wang, S., et al. (2024). "Automated Detection of Pavement Distress Based on Enhanced Yolov8 and Synthetic Data with Textured Background Modeling." Transportation Geotechnics **48**: 101304.
- Wang, X., et al. (2024). "Artificial Intelligence Is Transforming the Research Paradigm of Environmental Science and Engineering." Environmental Science and Ecotechnology **19**: 100346.
- Wingtra (2019). How Ground Sample Distance (Gsd) Relates to Accuracy and Drone Ro.
- Wu, Y., et al. (2023). "Lca-Yolov8-Seg: An Improved Lightweight Yolov8-Seg for Real-Time Pixel-Level Crack Detection of Dams and Bridges." **13**(19): 10583.
- Xiao, Z., et al. (2024). Theoretically Achieving Continuous Representation of Oriented Bounding Boxes. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
- Yadav, Y., et al. (2020). Role of Ground Control Points (Gcps) in Integration of Terrestrial Laser Scanner (Tls) and Close-Range Photogrammetry (Crp): 531-537.
- Yao, K.-c., et al. (2021). "Establishing an Ai Model on Data Sensing and Prediction for Smart Home Environment Control Based on Labview." Mathematical Problems in Engineering **2021**.
- Zhang, A., et al. (2018). "Automated Pixel-Level Pavement Crack Detection on 3d Asphalt Surfaces with a Recurrent Neural Network: Automated Pixel-Level Pavement Crack Detection on 3d Asphalt Surfaces Using Cracknet-R." Computer-Aided Civil and Infrastructure Engineering **34**.
- Zhang, C., et al. (2024). "Automated Detection and Segmentation of Tunnel Defects and Objects Using Yolov8-Cm." Tunnelling and Underground Space Technology **150**: 105857.
- Zhang, K., et al. (2018). "Unified Approach to Pavement Crack and Sealed Crack Detection Using Preclassification Based on Transfer Learning." Journal of Computing in Civil Engineering **32**.
- Zhao, Q., et al. (2023). "A 3d Modeling Method for Buildings Based on Lidar Point Cloud and Dlg." Computers, Environment and Urban Systems **102**: 101974.
- Zheng, L., et al. (2019). "Lane-Level Road Network Generation Techniques for Lane-Level Maps of Autonomous Vehicles: A Survey." Sustainability **11**: 4511.
- Zhou, S., et al. (2024). "Framework of Rod-Like Crops Sorting Based on Multi-Object Oriented Detection and Analysis." Computers and Electronics in Agriculture **216**: 108516.
- Zhou, Z., et al. (2024). "Linear Gaussian Bounding Box Representation and Ring-Shaped Rotated Convolution for Oriented Object Detection." Pattern Recognition **155**: 110677.
- Zhu, H.-R., et al. (2024). Oriented Bounding Box for Contact Detection.

Anexos

Tabela 16: Memória descritiva da nave 3 (continuação).

Pórtico	Elemento	Secção Transversal	Comprimento [m]
1A	P.115	HEA200	7,24
	V.494	IPE200	7,34
	V.505	IPE200	7,34
	P.121	HEA200	7,24
2A	P.124	HEA200	7,24
	V.515	IPE220	7,34
	V.513	IPE220	7,34
	P.119	HEA200	7,24
3A	P.129	HEA200	7,24
	V.521	IPE220	7,34
	V.519	IPE220	7,34
	P.127	HEA200	7,24
4A	P.134	HEA200	7,24
	V.534	IPE220	7,34
	V.523	IPE220	7,34
	P.128	HEA200	7,24
5A	P.148	HEA200	7,24
	V.558	IPE220	7,34
	V.561	IPE220	7,34
	P.152	HEA200	7,24
6A	P.145	HEA200	7,24
	V.549	IPE220	7,34
	V.548	IPE220	7,34
	P.143	HEA200	7,24

7A	P.141	HEA200	7,24
	V.544	IPE220	7,34
	V.546	IPE220	7,34
8A	P.139	HEA200	7,24
	P.019	IPE270	7,24
	V.537	IPE200	7,34
	P.114	IPE240	7,40
	P.091	IPE240	7,40
	V.535	IPE200	7,26
9A	P.023	IPE270	7,25
	P.111	HEA200	7,24
	V.490	IPE220	7,34
	V.504	IPE220	7,34
	P.113	HEA200	7,24

Tabela 17: Memória descritiva da nave 4 (continuação).

Pórtico	Elemento	Secção Transversal	Comprimento [m]
1B	P.121	HEA200	7,24
	V.495	IPE200	7,34
	P.110	HEA160	7,52
	V.491	IPE200	7,34
	P.118	IPE270	7,24
2B	P.119	HEA200	7,24
	V.510	IPE220	7,34
	V.511	IPE220	7,34
	P.126	IPE270	7,24
3B	P.127	HEA200	7,24
	V.520	IPE220	7,34
	V.517	IPE220	7,34
	P.131	IPE270	7,24
4B	P.128	HEA200	7,24
	V.528	IPE220	7,34
	V.531	IPE220	7,34

ANEXOS

	P.132	IPE270	7,24
5B	P.152	HEA200	7,24
	V.554	IPE220	7,34
	V.557	IPE220	7,34
	P.153	IPE270	7,24
	P.143	HEA200	7,24
6B	V.552	IPE220	7,34
	V.551	IPE220	7,34
	P.144	IPE270	7,24
7B	P.139	HEA200	7,24
	V.542	IPE220	7,34
	V.543	IPE220	7,34
	P.147	IPE270	7,24
8B	P.023	IPE270	7,25
	V.536	IPE200	7,34
	P.097	IPE240	7.40
	P.090	IPE240	7.37
	V.533	IPE200	7,34
	P.140	IPE270	7,24
9B	P.113	HEA200	7,24
	V.499	IPE220	7,34
	V.502	IPE220	7,34
	P.112	IPE270	7,24

Tabela 18: Resultados obtidos para o Quadro B.17-1 – Inclinação de colunas de edifícios com um só andar da NP EN 1090-2:2020 (continuação).

Elemento	Tolerâncias Essenciais [cm]	Tolerâncias Funcionais [cm]		Desvio no topo obtido [cm]		Validação
	Classes 1 e 2	Classes 1	Classe 2	Δx	Δy	
P.115	2,413	2,413	1,448	0,397	-0,556	OK
P.106	2,503	2,503	1,502	-0,040	-0,392	OK
P.121	2,413	2,413	1,448	-0,026	-0,265	OK
P.124	2,413	2,413	1,448	-0,291	-0,026	OK
P.119	2,413	2,413	1,448	-0,873	-0,635	OK
P.129	2,413	2,413	1,448	-	-	ND
P.127	2,413	2,413	1,448	-0,348	-0,040	OK
P.134	2,413	2,413	1,448	-	-	ND
P.128	2,413	2,413	1,448	-0,348	0,939	OK
P.148	2,413	2,413	1,448	-	-	ND
P.152	2,413	2,413	1,448	-0,714	0,238	OK
P.145	2,413	2,413	1,448	-	-	ND
P.143	2,413	2,413	1,448	0,234	0,013	OK
P.141	2,413	2,413	1,448	-	-	ND
P.139	2,413	2,413	1,448	-0,397	0,767	OK
P.019	2,413	2,413	1,448	-	-	ND
P.097	2,417	2,417	1,450	-0,146	-0,611	OK
P.090	2,467	2,467	1,480	-0,278	-0,214	OK
P.023	2,453	2,453	1,472	-0,344	-0,238	OK
P.111	2,413	2,413	1,448	-	-	ND
P.113	2,413	2,413	1,448	0,022	0,304	OK
P.110	2,503	2,503	1,502	-0,317	-0,370	OK
P.118	2,413	2,413	1,448	0,556	-0,344	OK
P.126	2,413	2,413	1,448	0,582	0,159	OK
P.131	2,413	2,413	1,448	0,317	0,556	OK
P.132	2,413	2,413	1,448	0,317	-5,583	KO
P.153	2,413	2,413	1,448	-0,476	0,238	OK
P.144	2,413	2,413	1,448	-0,741	0,317	OK

P.147	2,413	2,413	1,448	0,212	0,900	OK
P.140	2,413	2,413	1,448	-	-	ND
P.114	2,467	2,467	1,480	0,053	0,238	OK
P.091	2,453	2,453	1,472	-0,168	-0,066	OK

Tabela 19: Resultados obtidos para o Quadro B.17-2 – Inclinação de colunas individuais de um só andar em edifícios em pórtico com travessas inclinadas da NP EN 1090-2:2020 (continuação).

Nave	Pórtico	Elemento	Tolerâncias Funcionais [cm]		Desvio obtido [cm]	Validação		
			Classe 1	Classe 2				
Nave 3	2A	P.124	4,827	2,413	$\Delta 1$	-	ND	
		P.119	4,827	2,413	$\Delta 2$	0,132	OK	
	3A	P.129	4,827	2,413	$\Delta 1$	-	ND	
		P.127	4,827	2,413	$\Delta 2$	-0,080	OK	
	4A	P.134	4,827	2,413	$\Delta 1$	-	ND	
		P.128	4,827	2,413	$\Delta 2$	0,145	OK	
	5A	P.148	4,827	2,413	$\Delta 1$	-	ND	
		P.152	4,827	2,413	$\Delta 2$	0,595	OK	
	6A	P.145	4,827	2,413	$\Delta 1$	-	ND	
		P.143	4,827	2,413	$\Delta 2$	0,476	OK	
	7A	P.141	4,827	2,413	$\Delta 1$	-	ND	
		P.139	4,827	2,413	$\Delta 2$	1,230	OK	
	9A	P.111	4,827	2,413	$\Delta 1$	-	ND	
		P.113	4,827	2,413	$\Delta 2$	-	ND	
	Nave 4	2B	P.119	4,827	2,413	$\Delta 1$	0,132	OK
			P.126	4,827	2,413	$\Delta 2$	0,662	OK
3B		P.127	4,827	2,413	$\Delta 1$	-0,080	OK	
		P.131	4,827	2,413	$\Delta 2$	1,059	OK	
4B		P.128	4,827	2,413	$\Delta 1$	0,145	OK	
		P.132	4,827	2,413	$\Delta 2$	-5,914	KO	
5B		P.152	4,827	2,413	$\Delta 1$	0,595	OK	
		P.153	4,827	2,413	$\Delta 2$	0,807	OK	
6B		P.143	4,827	2,413	$\Delta 1$	0,476	OK	

	P.144	4,827	2,413	$\Delta 2$	0,608	OK
7B	P.139	4,827	2,413	$\Delta 1$	1,230	OK
	P.147	4,827	2,413	$\Delta 2$	-4,603	KO
9B	P.113	4,827	2,413	$\Delta 1$	-	ND
	P.112	4,827	2,413	$\Delta 2$	-	ND

Tabela 20: Resultados obtidos para o Quadro B.17-5 – Retilinearidade de colunas de um só andar da NP EN 1090-2:2020 (continuação).

Elemento	Tolerâncias Essenciais [cm]		Desvio obtido [cm]		Validação
	Classes 1 e 2		Δx	Δy	
P.115	0,724		-0,582	-0,265	OK
P.106	0,751		-0,013	0,190	OK
P.121	0,724		0,026	-0,053	OK
P.124	0,724		-0,445	0,145	OK
P.119	0,724		-0,366	0,013	OK
P.129	0,724		-	-	ND
P.127	0,724		-0,207	-0,489	OK
P.134	0,724		-	-	ND
P.128	0,724		-0,816	0,436	KO
P.148	0,724		-	-	ND
P.152	0,724		-0,238	0,582	OK
P.145	0,724		-	-	ND
P.143	0,724		-0,287	0,622	OK
P.141	0,724		-	-	ND
P.139	0,724		-0,397	0,767	OK
P.019	0,724		-	-	ND

ANEXOS

P.097	0,725	-0,291	0,000	OK
P.090	0,740	-0,124	0,013	OK
P.023	0,736	0,145	0,089	OK
P.111	0,724	-	-	ND
P.113	0,724	0,476	-0,370	OK
P.110	0,751	0,185	0,185	OK
P.118	0,724	0,291	-0,106	OK
P.126	0,724	0,026	0,794	KO
P.131	0,724	-0,529	0,661	OK
P.132	0,724	-0,505	-3,717	KO
P.153	0,724	-0,609	0,238	OK
P.144	0,724	-0,606	0,225	OK
P.147	0,724	-0,267	0,542	OK
P.140	0,724	-	-	ND
P.114	0,740	0,053	0,238	OK
P.091	0,736	-0,238	-0,079	OK

Tabela 21: Resultados obtidos para o Quadro B.20-1 – Posicionamento em planta dos pilares da NP EN 1090-2:2020 (continuação).

Elemento	Tolerâncias Funcionais [cm]		Desvios obtidos [cm]		Validação
	Classes 1	Classe 2	Δx	Δy	
P.115	1,000	0,500	-0,525	0,172	OK
P.106	1,000	0,500	0,000	-0,238	OK
P.121	1,000	0,500	-0,106	-0,317	OK
P.124	1,000	0,500	-1,270	-0,132	KO
P.119	1,000	0,500	-1,164	-0,503	KO
P.129	1,000	0,500	-	-	ND
P.127	1,000	0,500	-0,207	-0,489	OK

P.134	1,000	0,500	-	-	ND
P.128	1,000	0,500	-0,450	-0,794	KO
P.148	1,000	0,500	-	-	ND
P.152	1,000	0,500	-0,234	0,357	OK
P.145	1,000	0,500	-	-	ND
P.143	1,000	0,500	-0,322	0,463	OK
P.141	1,000	0,500	-	-	ND
P.139	1,000	0,500	0,340	0,463	OK
P.019	1,000	0,500	-	-	ND
P.097	1,000	0,500	-	-	ND
P.090	1,000	0,500	-0,751	-1,270	KO
P.023	1,000	0,500	-0,265	0,053	OK
P.111	1,000	0,500	-	-	ND
P.113	1,000	0,500	-	-	ND
P.110	1,000	0,500	-0,119	-0,348	OK
P.118	1,000	0,500	0,000	-0,079	OK
P.126	1,000	0,500	-0,847	0,503	KO
P.131	1,000	0,500	-0,529	0,661	KO
P.132	1,000	0,500	-0,320	-0,331	OK
P.153	1,000	0,500	-	-	ND
P.144	1,000	0,500	-	-	ND
P.147	1,000	0,500	-	-	ND
P.140	1,000	0,500	-	-	ND
P.114	1,000	0,500	0,079	0,212	OK
P.091	1,000	0,500	-0,423	0,079	OK