

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**FACULDADE DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Felipe Meneguitti Dias**

**Metodologia para monitoramento de estruturas utilizando descritores visuais**

Juiz de Fora

2020

**Felipe Meneguitti Dias**

**Metodologia para monitoramento de estruturas utilizando descritores visuais**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Leonardo de Mello Honório

Coorientadora: Profa. Dra. Milena Faria Pinto

Juiz de Fora

2020

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Dias, Felipe Meneguitti.

Metodologia para monitoramento de estruturas utilizando descritores visuais / Felipe Meneguitti Dias. -- 2020.  
98 f.

Orientador: Leonardo de Mello Honório

Coorientadora: Milena Faria Pinto

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2020.

1. Monitoramento de Estruturas. 2. Visão Computacional. 3. Aprendizado Profundo. 4. Descritores Visuais. 5. Estrutura a partir do Movimento.. I. de Mello Honório, Leonardo , orient. II. Faria Pinto, Milena, coorient. III. Título.

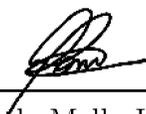
Felipe Meneguitti Dias

Metodologia para monitoramento de estruturas utilizando descritores visuais

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica

Aprovada em:

BANCA EXAMINADORA



---

Prof. Dr. Leonardo de Mello Honório - Orientador  
Universidade Federal de Juiz de Fora (UFJF)



---

Profa. Dra. Milena Faria Pinto - Coorientadora  
Centro Federal de Educação Tecnológica Celso Suckow  
da Fonseca (CEFET/RJ)



---

Prof. Dr. André G. S. Conceição  
Universidade Federal da Bahia (UFBA)



---

Prof. Dr. André L. M. Marcato  
Universidade Federal de Juiz de Fora (UFJF)

Aos meus pais, Maria Matilde Zangirolami Meneguitti  
Dias e José Carlos Dias, e à minha namorada, Rayen  
Naji.

## AGRADECIMENTOS

Agradeço aos meus pais, José Carlos Dias e Maria Matilde Zangirolami Meneguitti Dias, pelo esforço e investimento que fizeram na minha educação.

À minha namorada, Rayen Naji, que sempre esteve ao meu lado nos momentos bons e ruins durante todo o decorrer do mestrado. Este trabalho não seria possível sem o seu apoio.

Ao Professor Leonardo de Mello Honório, pela oportunidade de pesquisa no Grupo de Robótica Inteligente (GRIn) e as orientações durante a graduação e o mestrado. À Professora Milena Faria Pinto, pelas orientações, sugestões e desenvolvimento dos experimentos desse trabalho. Ao Aurélio Gouvêa de Melo, pelas sugestões, auxílio no desenvolvimento dos experimentos e as discussões para a melhoria do trabalho.

Aos amigos e colegas, que sempre contribuíram para o meu desenvolvimento pessoal e profissional.

À Universidade Federal de Juiz de Fora (UFJF), pela estrutura e apoio.

Ao Instituto de Engenharia de Sistemas e Computadores, Tecnologia e Ciência (INESC-TEC), pelo apoio.

“Quem pensa pouco, erra muito.” – Leonardo Da Vinci

## RESUMO

O monitoramento de infraestruturas de larga escala, como barragens e taludes, é essencial para garantir a integridade estrutural e a segurança de utilização. O processo de monitoramento convencional utiliza diversos sensores espalhados ao longo da estrutura. Sendo assim, isso limita a detecção e o cálculo das deformidades às áreas onde os sensores foram posicionados. Técnicas fotométricas combatem essa limitação, pois monitoram grandes áreas a baixo custo, utilizando apenas uma câmera. Nesse contexto, a técnica Comparação Multiescala de Nuvem a Nuvem (M3C2) é considerada o estado da arte para cálculo de deformações estruturais em nuvens de pontos. Entretanto, o M3C2 considera que todas as deformações ocorrem na direção normal da superfície monitorada, e isso pode gerar estimativas incorretas. Consequentemente, este trabalho propõe uma nova metodologia para cálculo de deformações em estruturas, intitulada Distância por Correspondência Visual e Reprojeção de Pontos (DCVRP). Tal método utiliza descritores visuais para encontrar pontos correspondentes entre nuvens de pontos capturadas em tempos diferentes. A validação da técnica proposta foi realizada em três experimentos controlados, utilizando deformações criadas artificialmente, e um teste conduzido em um talude de rochas. Os resultados mostraram que o método proposto é superior à técnica M3C2, especialmente quando as deformações não são normais à superfície da estrutura.

Palavras-chave: Monitoramento de Estruturas. Visão Computacional. Aprendizado Profundo. Descritores Visuais. Estrutura a partir do Movimento.

## ABSTRACT

Monitoring large-scale infrastructures, such as dams or those built on sloped foundations, is essential for ensuring their structural integrity and safe use. The conventional monitoring process utilizes several sensors spread throughout the structure. This limits the detection and calculation of deformities to areas where the sensors are positioned. Photogrammetry techniques combat this limitation by monitoring entire areas at low-cost, using only a camera. In this context, the Multiscale Model to Model Cloud Comparison (M3C2) technique is considered state-of-the-art for structural deformation calculation in point clouds. However, M3C2 incorrectly assumes that all structural deformities occur normal to the monitored surface, which can lead to inaccurate deformation estimates. Consequently, this work proposes a novel methodology for calculating deformations in infrastructure, entitled Visual Correspondence and Point Reprojection Distance. This method uses visual descriptors to find corresponding points among point clouds captured at different times. Validation of the proposed technique was performed in three controlled experiments using artificially created deformations, and one test conducted in a rock slope infrastructure. The results show that the proposed method is superior to M3C2, especially when deformations are not normal to the structure's surface.

Key-words: Structural Monitoring. Computer Vision. Deep Learning. Visual Descriptors. Structure from Motion.

## LISTA DE DIAGRAMAS

Diagrama 1 – Metodologia DCVRP para cálculo de deslocamento em estruturas tridimensionais. . . . .	48
--	----

## LISTA DE ILUSTRAÇÕES

Figura 1 – Cálculo de distância utilizando o método C2C. . . . .	24
Figura 2 – Cálculo de distância utilizando o método C2M. . . . .	24
Figura 3 – Cálculo da normal no ponto $\mathbf{p}_i^t$ utilizando a técnica M3C2. . . . .	25
Figura 4 – Cálculo da distância usando a técnica M3C2. . . . .	26
Figura 5 – Influência do parâmetro de escala $D$ na estimativa da normal. . . . .	27
Figura 6 – Configuração do experimento realizado em (JAFARI; KHALOO; LATTANZI, 2017). . . . .	29
Figura 7 – Configuração do experimento proposto em (RIEGER <i>et al.</i> , 2016). . . . .	30
Figura 8 – Ilustração do experimento realizado em (KHALOO <i>et al.</i> , 2018). . . . .	31
Figura 9 – Configuração do experimento proposto em (LEYLAND <i>et al.</i> , 2017). . . . .	32
Figura 10 – Formação da imagem de acordo com o modelo <i>pinhole</i> . . . . .	34
Figura 11 – Modelagem do processo de formação de imagem utilizando o modelo <i>pinhole</i> . . . . .	34
Figura 12 – Relações de semelhança de triângulo presentes no modelo <i>pinhole</i> . . . . .	35
Figura 13 – Detecção de <i>corners</i> em escalas diferentes. . . . .	37
Figura 14 – Detecção de <i>keypoints</i> segundo (LOWE, 2004). . . . .	38
Figura 15 – Processo de extração do descritor SIFT simplificado. . . . .	39
Figura 16 – Processo de treinamento do descritor DeepDesc. . . . .	40
Figura 17 – Configuração de treinamento do descritor UCN. . . . .	41
Figura 18 – Comparação entre descritores esparsos e densos. . . . .	41
Figura 19 – Correspondência entre descritores de diferentes imagens. . . . .	42
Figura 20 – Geometria epipolar. . . . .	43
Figura 21 – Metodologia simplificada para cálculo de deslocamento em estruturas. . . . .	46
Figura 22 – Processo de registro de nuvem de pontos utilizando pontos de controle. . . . .	49
Figura 23 – Encontrando o par da câmera 1 do conjunto $O^t$ . . . . .	50
Figura 24 – Disposição das câmeras e seus respectivos pares. . . . .	51
Figura 25 – Condição <i>backface culling</i> para projeção de pontos tridimensionais em uma imagem. . . . .	51
Figura 26 – Projeção de um ponto tridimensional em uma imagem com seus respectivos pontos vizinhos. . . . .	52
Figura 27 – Cálculo de correspondência para o $i$ -ésimo ponto tridimensional de $N^t$ utilizando a $k$ -ésima imagem de $O^t$ e seu respectivo par. . . . .	53
Figura 28 – Assinalando deslocamento para um ponto utilizando a média/mediana dos vetores deslocamentos dos pontos vizinhos. . . . .	54
Figura 29 – Utilização conjunta do método proposto e a técnica M3C2. . . . .	54

Figura 30 – Configuração do experimento 1. . . . .	56
Figura 31 – Experimento realizado no laboratório de mecânica do IFMG de Ouro Branco. . . . .	57
Figura 32 – Numeração dos círculos monitorados pela metodologia simplificada proposta. . . . .	57
Figura 33 – Plastificação da barra de alumínio nas proximidades de um dos apoios. . . . .	61
Figura 34 – Distribuição dos deslocamentos ao longo da face da barra de alumínio. . . . .	62
Figura 35 – Configuração do experimento 2. . . . .	63
Figura 36 – Experimento 2 para os tempos $t$ e $t + 1$ . . . . .	64
Figura 37 – Reconstrução tridimensional em $t$ para o experimento 2. . . . .	65
Figura 38 – Reconstrução tridimensional em $t + 1$ para o experimento 2. . . . .	65
Figura 39 – Processo de registro entre a reconstrução de $t$ com a reconstrução de $t + 1$ para o experimento 2. . . . .	66
Figura 40 – Resultado visual do algoritmo M3C2 para o experimento 2. . . . .	66
Figura 41 – Vetores de deslocamento gerados pelo método DCVRP para o experimento 2. . . . .	67
Figura 42 – Configuração do experimento 3. . . . .	68
Figura 43 – Experimento 3 para os tempos $t$ e $t + 1$ . . . . .	69
Figura 44 – Reconstrução tridimensional em $t$ para o experimento 3. . . . .	70
Figura 45 – Reconstrução tridimensional em $t + 1$ para o experimento 3. . . . .	70
Figura 46 – Processo de registro entre a reconstrução de $t$ com a reconstrução de $t + 1$ para o experimento 3. . . . .	71
Figura 47 – Comportamento esperado pela técnica M3C2 para o experimento 3. . . . .	72
Figura 48 – Resultado visual do algoritmo M3C2 para o experimento 3. . . . .	72
Figura 49 – Resultado gerado pelo método DCVRP para o experimento 3. . . . .	73
Figura 50 – Configuração do experimento 4. . . . .	73
Figura 51 – Experimento 4 para os tempos $t$ e $t + 1$ . . . . .	74
Figura 52 – Reconstrução tridimensional em $t$ para o experimento 4. . . . .	75
Figura 53 – Reconstrução tridimensional em $t + 1$ para o experimento 4. . . . .	75
Figura 54 – Processo de registro entre a reconstrução de $t$ com a reconstrução de $t + 1$ para o experimento 4. . . . .	76
Figura 55 – Resultado visual do algoritmo M3C2 para o experimento 4. . . . .	76
Figura 56 – Resultado gerado pelo método DCVRP para o experimento 4. . . . .	77
Figura 57 – Imagem utilizada para reconstrução tridimensional do talude referente a vistoria do tempo $t$ . . . . .	80
Figura 58 – Reconstrução tridimensional do talude referente a vistoria do tempo $t$ . . . . .	81
Figura 59 – Registro das nuvens $t$ e $t + 1$ para o experimento 5. . . . .	81

Figura 60 – Deslocamentos calculados pelo M3C2 codificados por uma paleta de cores. . . . .	83
Figura 61 – Vetores dos deslocamentos gerados pela técnica M3C2 ocorridos entre as nuvens de pontos $t$ e $t + 1$ . . . . .	83
Figura 62 – Deslocamentos calculados pelo método proposto no eixo X codificados por uma paleta de cores. . . . .	86
Figura 63 – Deslocamentos calculados pelo método proposto no eixo Y codificados por uma paleta de cores. . . . .	86
Figura 64 – Deslocamentos calculados pelo método proposto no eixo Z codificados por uma paleta de cores. . . . .	87
Figura 65 – Vetores dos deslocamentos gerados pela metodologia proposta ocorridos entre as nuvens de pontos $t$ e $t + 1$ . . . . .	87

## LISTA DE GRÁFICOS

Gráfico 1 – Estimativas de deformações obtidas no experimento realizado em (JAFARI; KHALOO; LATTANZI, 2017) utilizando as técnicas C2C e M3C2. . . . .	30
Gráfico 2 – Deslocamentos obtidos pela técnica C2M no experimento proposto em (RIEGER <i>et al.</i> , 2016). . . . .	31
Gráfico 3 – Deslocamento vertical do círculo 69 ao longo do tempo. . . . .	58
Gráfico 4 – Deslocamento vertical da terceira linha de círculos. . . . .	59
Gráfico 5 – Histograma dos deslocamentos calculados pelo método simplificado proposto para a barra de alumínio. . . . .	59
Gráfico 6 – Histograma dos erros entre os valores simulados e os calculados para os círculos da barra de alumínio. . . . .	60
Gráfico 7 – Histograma dos deslocamentos gerados pelo método DCVRP para o experimento 4 na direção X. . . . .	78
Gráfico 8 – Histograma dos deslocamentos gerados pelo método DCVRP para o experimento 4 na direção Y. . . . .	78
Gráfico 9 – Histograma dos deslocamentos gerados pelo método DCVRP para o experimento 4 na direção Z. . . . .	79
Gráfico 10 – Deslocamentos calculados utilizando a técnica M3C2 para o experimento 5. . . . .	82
Gráfico 11 – Deslocamentos calculados utilizando a metodologia proposta na direção X para o experimento 5. . . . .	84
Gráfico 12 – Deslocamentos calculados utilizando a metodologia proposta na direção Y para o experimento 5. . . . .	85
Gráfico 13 – Deslocamentos calculados utilizando a metodologia proposta na direção Z para o experimento 5. . . . .	85

## LISTA DE QUADROS

Quadro 1 – Resumo com as principais vantagens e desvantagens das técnicas C2C, C2M e M3C2. . . . .	28
Quadro 2 – Principais características de pontos de interesse robustos. . . . .	37

## LISTA DE ABREVIATURAS E SIGLAS

UFJF	Universidade Federal de Juiz de Fora
UFOP	Universidade Federal de Ouro Preto
SfM	Estrutura a partir do Movimento (do inglês <i>Structure from Motion</i> )
SIFT	Transformada de Descritor Invariante à Escala (do inglês <i>Scale-Invariant Feature Transform</i> )
C2C	Nuvem a Nuvem (do inglês <i>Cloud-to-Cloud</i> )
C2M	Nuvem a Malha (do inglês <i>Cloud-to-Mesh</i> )
M3C2	Comparação Multiescala de Nuvem a Nuvem (do inglês <i>Multiscale Model to Model Cloud Comparison</i> )
DCVRP	Distância por Correspondência Visual e Reprojeção de Pontos
PCA	Análise de Componentes Principais (do inglês <i>Principal Component Analysis</i> )
<i>LoD</i>	Nível de detecção (do inglês <i>Level of Detection</i> )
ICP	Iterativo de Pontos Mais Próximos (do inglês <i>Iterative Closest Point</i> )
UAV	Veículo Aéreo Não Tripulado (do inglês <i>Unmanned Aerial Vehicle</i> )
MLS	Sensor a Laser Móvel (do inglês <i>Mobile Laser Scanner</i> )
MBES	Sonar Multi-feixe (do inglês <i>Multibeam Echo Sounders</i> )
DGPS	Sistema de Posicionamento Global Diferencial (do inglês <i>Differential Global Positioning System</i> )
LMR	Aprendendo a Remover Correspondências Incorretas (do inglês <i>Learning for Mismatch Removal</i> )
LFGC	Aprendendo a Encontrar Boas Correspondências (do inglês <i>Learning to Find Good Correspondences</i> )
UCN	Rede de Correspondência Universal (do inglês <i>Universal Correspondence Network</i> )
SVM	Máquina de Vetores de Suporte (do inglês <i>Support Vector Machine</i> )

## LISTA DE SÍMBOLOS

$L$	Distância real entre duas nuvens de pontos
$L_{C2C}$	Distância entre duas nuvens de pontos calculada utilizando a técnica C2C.
$L_{C2M}$	Distância entre duas nuvens de pontos calculada utilizando a técnica C2M.
$L_{M3C2}$	Distância entre duas nuvens de pontos calculada utilizando a técnica M3C2.
$L_{\text{proposto}}$	Distância entre duas nuvens de pontos calculada utilizando o método proposto.
$L_{\text{proposto}+M3C2}$	Distância entre duas nuvens de pontos calculada utilizando o método proposto em conjunto com o M3C2.
$\mathbf{p}_i^t$	$i$ -ésimo ponto tridimensional da nuvem de pontos capturada no tempo $t$ .
$\tilde{\mathbf{p}}$	Refere-se ao ponto $\mathbf{p}$ em sua notação em coordenadas homogêneas.
$N^t$	Nuvem de pontos capturada no tempo $t$ .
$d_{p_i^t}$	Deslocamento estimado para o $i$ -ésimo ponto da nuvem de pontos capturada no tempo $t$ .
$D$	Escala para estimativa da normal local da técnica M3C2. São considerados os vizinhos locais de um determinado ponto $\mathbf{p}$ , todos os pontos que estão até uma distância $D/2$ de $\mathbf{p}$ .
$\sigma_i^t(D)$	Rugosidade da nuvem da vizinhança do $i$ -ésimo ponto da nuvem de pontos obtida no tempo $t$ usando uma escala $D$ .
$d$	É o diâmetro do cilindro de projeção para estimativa de distância na técnica M3C2.
$n_i^t(d)$	Número de pontos dentro de um cilindro de projeção com diâmetro $d$ ao redor do $i$ -ésimo ponto da nuvem de pontos obtida no tempo $t$ .
$\mu_i^t(d)$	Média dos pontos dentro de um cilindro de projeção, com diâmetro $d$ , ao redor do $i$ -ésimo ponto da nuvem $N^t$ .
$\sigma_i^t(d)$	Desvio padrão dos pontos dentro de um cilindro de projeção, com diâmetro $d$ , ao redor do $i$ -ésimo ponto da nuvem $N^t$ .
$reg$	Erro de registro de nuvens de pontos.
$O^t$	Conjunto de imagens capturado no tempo $t$ .
$I_k^t$	$k$ -ésima imagem do conjunto de imagens $O^t$ .
$L^t$	Quantidade de imagens do conjunto de imagens $O^t$ .
$\mathbf{c}_k^t$	Posição da $k$ -ésima imagem do conjunto $O^t$ .
$\mathbf{R}_k^t$	Matriz de Rotação da $k$ -ésima imagem do conjunto $O^t$ .
$e(\mathbf{I}_k^t, \mathbf{I}_{n_k}^{t+1})$	Erro conjunto de posição e rotação entre a $k$ -ésima imagem do conjunto $O^t$ e a $n_k$ -ésima imagem do conjunto $O^{t+1}$ .

$W$	Conjunto de pares de imagens. Os pares são formados de forma que a semelhança de imagens em cada par seja a máxima possível.
$\mathbf{p}_{2d_i}^{k,t}$	Projeção do $i$ -ésimo ponto tridimensional de $N^t$ na $k$ -ésima imagem de $O^t$ .
$th_1$	<i>Threshold</i> para definição dos pontos vizinhos da projeção dos pontos tridimensionais em uma imagem.
$\mathbf{vw}_k^t$	Vetor visão da $k$ -ésima imagem do conjunto $O^t$ .
$\mathbf{n}(\mathbf{p}_i^t)$	Vetor normal do $i$ -ésimo ponto tridimensional da nuvem de pontos $O^t$ .
$\mathbf{v}_u^{i,k,th,t}$	$u$ -ésimo vizinho dentro de um raio de $th$ da projeção do $i$ -ésimo ponto tridimensional na $k$ -ésima imagem do conjunto $O^t$ .
$\omega_u^{i,k,th,t+1}$	Pontos bidimensionais da $k$ -ésima imagem do conjunto $O^{t+1}$ que são correspondentes as projeções $\mathbf{v}_u^{i,k,th,t}$ .
$\mathbf{f}_g^{i,k,th_2,t}$	$g$ -ésimo ponto tridimensional da nuvem $N^t$ cuja projeção na $k$ -ésima imagem de $O^t$ esteja até uma distância $th_2$ dos pontos $\omega_u^{i,k,th_1,t}$ .
$\mathbf{d}_g^{i,k,t}$	$g$ -ésima distância tridimensional calculada para o $i$ -ésimo ponto tridimensional de $N^t$ utilizando a $k$ -ésima imagem de $O^t$ .
$\mathbf{d}_i^{k,t}$	Mediana de todas as distâncias $\mathbf{d}_g^{i,k,t}$ .
$d_i^t$	Mediana de todas as distâncias $\mathbf{d}_i^{k,t}$ . É considerado o deslocamento final para o $i$ -ésimo ponto tridimensional de $N^t$ .
R	Parâmetro de distância utilizado para determinar os vizinhos de um determinado ponto tridimensional. Esses vizinhos são utilizados para determinar o vetor deslocamento.
$\in$	Pertence

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>20</b>
1.1	OBJETIVOS . . . . .	21
1.1.1	<b>Objetivos Gerais</b> . . . . .	21
1.1.2	<b>Objetivos Específicos</b> . . . . .	22
1.2	ORGANIZAÇÃO . . . . .	22
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> . . . . .	<b>23</b>
2.1	TÉCNICAS PARA ESTIMATIVA DE DEFORMAÇÃO DE NUVENS DE PONTOS . . . . .	23
2.1.1	<b>Distância de Nuvem a Nuvem (C2C)</b> . . . . .	23
2.1.2	<b>Distância de Nuvem a Malha (C2M)</b> . . . . .	23
2.1.3	<b>Comparação Multiescala de Nuvem a Nuvem (M3C2)</b> . . . . .	24
2.1.3.1	<i>Cálculo de pontos chave (opcional)</i> . . . . .	25
2.1.3.2	<i>Cálculo das normais</i> . . . . .	25
2.1.3.3	<i>Cálculo da distância entre as nuvens de pontos</i> . . . . .	25
2.1.3.4	<i>Escolhendo a escala correta</i> . . . . .	26
2.1.3.5	<i>Intervalo de confiança</i> . . . . .	26
2.1.4	<b>Comparando as Técnicas da Literatura</b> . . . . .	27
2.2	APLICAÇÕES . . . . .	28
2.2.1	<b>Deformação de uma viga</b> . . . . .	28
2.2.2	<b>Expansão de uma Bateria</b> . . . . .	29
2.2.3	<b>Monitoramento de Barragens</b> . . . . .	29
2.2.4	<b>Monitoramento de Erosão</b> . . . . .	32
<b>3</b>	<b>FUNDAMENTOS TEÓRICOS</b> . . . . .	<b>33</b>
3.1	COORDENADAS HOMOGÊNEAS . . . . .	33
3.2	CÂMERAS . . . . .	33
3.3	PONTOS DE INTERESSE . . . . .	36
3.4	DESCRITORES . . . . .	38
3.4.1	<b>Descritores <i>handcrafted</i></b> . . . . .	39
3.4.2	<b>Descritores baseados em <i>deep learning</i></b> . . . . .	39
3.4.3	<b>Descritores densos e esparsos</b> . . . . .	40
3.5	CORRESPONDÊNCIA ENTRE DESCRITORES . . . . .	41
3.6	GEOMETRIA EPIPOLAR . . . . .	42
<b>4</b>	<b>METODOLOGIA PROPOSTA</b> . . . . .	<b>45</b>
4.1	ABORDAGEM SIMPLIFICADA . . . . .	45
4.1.1	<b>Filtragem espacial</b> . . . . .	47
4.1.2	<b>Filtragem temporal</b> . . . . .	47

4.2	DISTÂNCIA POR CORRESPONDÊNCIA VISUAL E REPROJEÇÃO DE PONTOS (DCVRP) . . . . .	47
4.2.1	Registro de nuvens . . . . .	47
4.2.2	Pareando câmeras vizinhas . . . . .	48
4.2.3	Projeção 3D → 2D . . . . .	50
4.2.4	Correspondências 2D ↔ 2D . . . . .	52
4.2.5	Correspondências 2D ↔ 3D . . . . .	52
4.2.6	Pontos sem correspondência (opcional) . . . . .	53
4.2.7	M3C2 (opcional) . . . . .	53
<b>5</b>	<b>RESULTADOS E DISCUSSÃO . . . . .</b>	<b>55</b>
5.1	EXPERIMENTO 1 - BARRA DE ALUMÍNIO . . . . .	56
5.1.1	Configuração do experimento . . . . .	56
5.1.2	Aplicação do método simplificado proposto . . . . .	57
5.2	EXPERIMENTO 2 - CAIXA . . . . .	61
5.2.1	Configuração do experimento . . . . .	62
5.2.2	Reconstrução tridimensional . . . . .	63
5.2.3	Registro de Nuvens . . . . .	63
5.2.4	Aplicação da técnica M3C2 . . . . .	65
5.2.5	Aplicação do método DCVRP . . . . .	65
5.3	EXPERIMENTO 3 - PLACA (DESLOCAMENTO NORMAL E VERTICAL) . . . . .	68
5.3.1	Configuração do experimento . . . . .	68
5.3.2	Reconstrução tridimensional . . . . .	70
5.3.3	Registro de nuvens . . . . .	71
5.3.4	Aplicação da técnica M3C2 . . . . .	71
5.3.5	Aplicação do método DCVRP . . . . .	71
5.4	EXPERIMENTO 4 - PLACA (DESLOCAMENTO VERTICAL) . . . . .	73
5.4.1	Configuração do experimento . . . . .	73
5.4.2	Reconstrução tridimensional . . . . .	74
5.4.3	Registro de nuvens . . . . .	75
5.4.4	Aplicação da técnica M3C2 . . . . .	76
5.4.5	Aplicação do método DCVRP . . . . .	77
5.5	EXPERIMENTO 5 - TALUDE REAL . . . . .	79
5.5.1	Configuração do experimento . . . . .	79
5.5.2	Reconstrução tridimensional . . . . .	80
5.5.3	Registro de nuvens . . . . .	80
5.5.4	Aplicação da técnica M3C2 . . . . .	81
5.5.5	Aplicação do método DCVRP . . . . .	84
<b>6</b>	<b>CONCLUSÕES . . . . .</b>	<b>89</b>

6.1	TRABALHOS FUTUROS . . . . .	90
	<b>REFERÊNCIAS . . . . .</b>	<b>92</b>

## 1 INTRODUÇÃO

Estruturas de larga escala, e.g., taludes e barragens, devem seguir altos padrões de segurança. Caso contrário, falhas nessas construções podem causar danos ao meio ambiente e às infraestruturas vizinhas, prejuízos econômicos e, o mais importante, grande risco de morte para as pessoas ao redor (SCAIONI *et al.*, 2018). Dessa forma, com o objetivo de garantir a segurança, inspeções regulares são necessárias.

Nas últimas décadas, a abordagem utilizada para detectar possíveis deformações em estruturas foi o monitoramento de pontos de controle, utilizando diversos sensores, e.g., piezômetros, células de carga e extensômetros. O posicionamento dos pontos de controle é definido por especialistas. Entretanto, as mudanças, nesse caso, só podem ser calculadas nas regiões onde os sensores foram posicionados (WUJANZ, 2016).

Em contrapartida, a utilização de técnicas baseadas em escaneamento por laser e fotogrametria permite o monitoramento de grandes áreas. A primeira captura as coordenadas espaciais de uma superfície através de informações de emissão e reflexão do laser (JUTZI; GROSS, 2010). Essa técnica garante erros muito pequenos nas medidas, porém o custo do equipamento é elevado (WILKINSON *et al.*, 2016; ROÇA *et al.*, 2018; O'BANION *et al.*, 2018). A segunda reconstrói uma superfície tridimensional utilizando uma sequência de imagens, baseando-se em uma técnica de visão computacional chamada Estrutura a partir do Movimento, do inglês *Structure from Motion* (SfM) (LONGUET-HIGGINS, 1981; HARTLEY; ZISSERMAN, 2003; CARRIVICK; SMITH; QUINCEY, 2016). Como essa técnica só necessita de uma câmera para ser aplicada, os custos são significativamente inferiores à primeira técnica mencionada. Além disso, as reconstruções geradas pela técnica SfM também fornecem informações sobre a textura das mesmas. Contudo, os erros nas medidas são maiores (MOON *et al.*, 2019).

Para calcular a deformação de superfícies geradas a partir de lasers ou fotogrametria, é necessário realizar uma comparação entre as nuvens de pontos capturadas em cada inspeção. Assim, dado uma nuvem de pontos capturada no tempo  $t$  e outra capturada no tempo  $t + 1$ , existem três abordagens vastamente utilizadas na literatura para calcular o deslocamento: Nuvem a Nuvem, do inglês *Cloud to Cloud* (C2C), Nuvem a Malha, do inglês *Cloud to Mesh* (C2M) e Comparação Multiescala de Nuvem a Nuvem, do inglês *Multiscale Model to Model Cloud Comparison* (M3C2) (LAGUE; BRODU; LEROUX, 2013). A primeira calcula a deformação através do cálculo da distância entre os pontos mais próximos. A segunda requer que a nuvem de pontos capturada no tempo  $t$  seja transformada em uma superfície e, em seguida, a deformação é dada pela distância dos pontos de  $t + 1$  à superfície gerada. A última calcula normais locais em cada região da nuvem de pontos capturada em  $t$ . Em seguida, a deformação é calculada na direção das normais.

Não obstante, as abordagens listadas anteriormente simplificam o processo de

associação de pontos tridimensionais, pois as deformações não ocorrem, necessariamente, na direção normal das superfícies ou na direção do ponto mais próximo. Dessa forma, essas abordagens superestimam ou subestimam a quantidade de deformação ocorrida (HAUGEN, 2016). Com o objetivo de superar essa limitação, Gojcic et al (GOJCIC; ZHOU; WIESER, 2019) propôs a utilização de descritores tridimensionais para realizar a associação dos pontos obtidos no tempo  $t$  com pontos no tempo  $t + 1$ . Nesse trabalho, também foi proposto uma técnica de filtragem de associações incorretas. Os resultados mostraram uma significativa superioridade do método proposto em relação as demais técnicas da literatura. Todavia, a técnica apresentada era focada em pontos tridimensionais capturados por laser e, portanto, não utilizava informações relacionadas à textura dos pontos.

Nesse contexto, o presente trabalho propõe uma nova metodologia para cálculo de deformações em nuvens de pontos geradas utilizando SfM, intitulada "Distância por Correspondência Visual e Reprojção de Pontos (DCVRP)". Diferentemente do que foi realizado em (GOJCIC; ZHOU; WIESER, 2019; GOJCIC; ZHOU; WIESER, ), o método proposto realiza a correspondência entre pontos utilizando as informações de textura obtidos através das imagens que geraram as nuvens de pontos. Como as estruturas de interesse (taludes e barragens) possuem uma quantidade significativa de textura e pouca variação geométrica, abordagens baseadas em descritores visuais possuem grande potencial. Além disso, a literatura disponível para extração, cálculo de correspondências e, principalmente, filtragem de correspondências de descritores visuais é mais ampla do que para os descritores tridimensionais.

## 1.1 OBJETIVOS

Nesta seção, serão apresentados os objetivos gerais e específicos dessa dissertação.

### 1.1.1 Objetivos Gerais

Propor uma nova metodologia para o cálculo de deformações em estruturas monitoradas através da técnica Estrutura a partir do Movimento. O método proposto apresenta uma novidade em relação à técnica M3C2, considerada o estado da arte para cálculo de deformações em nuvem de pontos, ao utilizar descritores visuais para realizar o cálculo das deformações ocorridas. Enquanto o M3C2 assume, de forma simplista, que as deformações ocorrem na direção normal à superfície, o método proposto utiliza da associação de pontos com texturas semelhantes para realizar o cálculo, não limitando a direção que o deslocamento deve seguir. Além disso, propor experimentos em ambientes controlados onde as deformações ocorridas são gerados de maneira artificial para realizar uma comparação entre as duas técnicas. Finalmente, aplicar e avaliar o desempenho da metodologia proposta em um talude real.

### 1.1.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Apresentar os métodos atuais para cálculo de deformações em nuvens de pontos juntamente com as vantagens, desvantagens e limitações na utilização dos mesmos;
- Propor uma nova metodologia baseada em descritores visuais para estimativa de deformação de estruturas reconstruídas através da técnica Estrutura a partir do Movimento;
- Propor experimentos em ambientes controlados para teste de metodologias para cálculo de deformação de estruturas.
- Avaliar a metodologia em um talude real.

## 1.2 ORGANIZAÇÃO

Esta dissertação possui mais cinco capítulos além desta introdução. No Capítulo 2, são apresentadas as principais técnicas para cálculo de deformação de superfícies presente na literatura. Além disso, algumas aplicações práticas que fizeram uso dessas técnicas também são expostas. O Capítulo 3 aborda o arcabouço teórico necessário para o desenvolvimento da metodologia proposta. No Capítulo 4, inicialmente, é apresentada uma versão simplificada da metodologia proposta. Nesse caso, considerou-se apenas deslocamentos em duas dimensões. Em seguida, foi apresentada a metodologia generalizada para cálculo de deformação de estruturas. O Capítulo 5 apresenta um experimento com uma barra de alumínio, onde foi aplicado a metodologia simplificada. Ademais, foram apresentados os resultados da aplicação da metodologia generalizada em três cenários controlados. A metodologia generalizada também foi aplicada em um experimento envolvendo um talude real. Finalmente, no Capítulo 6, são expostas as principais conclusões obtidas nesse trabalho e sugestões sobre trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, será apresentada uma breve revisão bibliográfica sobre as principais técnicas para cálculo de deformações em estruturas. Além disso, serão expostos diferentes tipos de aplicações que utilizaram essas técnicas.

### 2.1 TÉCNICAS PARA ESTIMATIVA DE DEFORMAÇÃO DE NUVENS DE PONTOS

Nesta seção, as principais técnicas utilizadas para cálculo de deformação serão apresentadas. Para tal, define-se  $\mathbf{p}_i^t$  como o  $i$ -ésimo ponto tridimensional da nuvem de pontos  $N^t$ , capturada em  $t$ . Além disso, os termos deslocamento, deformação e distância do ponto  $\mathbf{p}_i^t$  serão utilizados de forma intercambiável, sendo esses denotados por  $\mathbf{d}_{\mathbf{p}_i^t}$ .

#### 2.1.1 Distância de Nuvem a Nuvem (C2C)

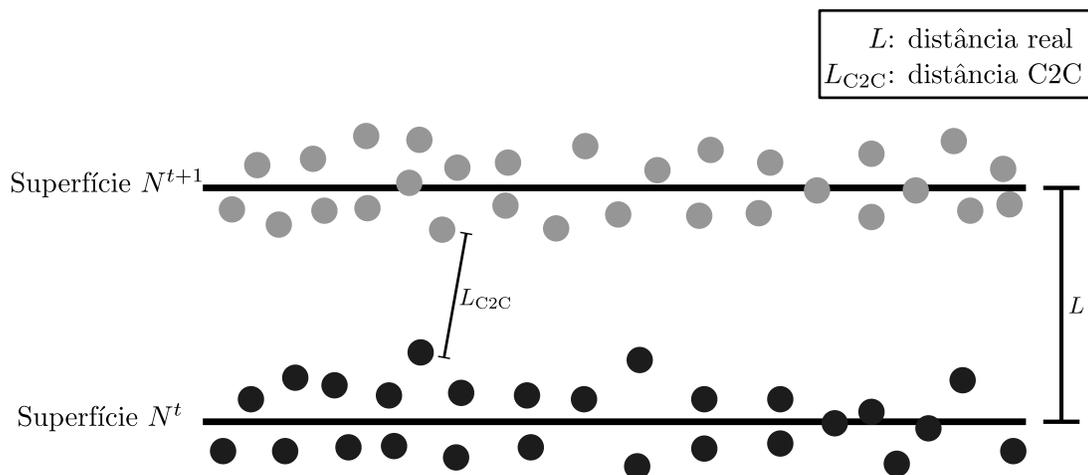
A técnica Nuvem a Nuvem, do inglês *Cloud to Cloud* (C2C), é uma abordagem simples e rápida para estimar deslocamentos ocorridos em uma nuvem de pontos, pois ela não requer reconstrução de superfícies ou estimativa de normais (LAGUE; BRODU; LEROUX, 2013). Entretanto, as medidas obtidas não são muito precisas. Dessa forma, o C2C é, em geral, utilizado para detecção de mudanças de superfícies e não para medidas (GIRARDEAU-MONTAUT *et al.*, 2005).

O C2C estima os deslocamentos dos pontos da seguinte maneira: dado o ponto  $\mathbf{p}_i^t$  da nuvem de pontos  $N^t$ , procura-se, na nuvem de pontos  $N^{t+1}$ , por um ponto  $\mathbf{p}_j^{t+1}$  com a menor distância para  $\mathbf{p}_i^t$  (vizinho mais próximo). Dessa forma, o deslocamento do ponto  $\mathbf{p}_i^t$  é definido por  $\mathbf{d}_{\mathbf{p}_i^t} = \mathbf{p}_j^{t+1} - \mathbf{p}_i^t$ . A Figura 1 ilustra o processo de cálculo de deslocamento utilizando a técnica C2C.

#### 2.1.2 Distância de Nuvem a Malha (C2M)

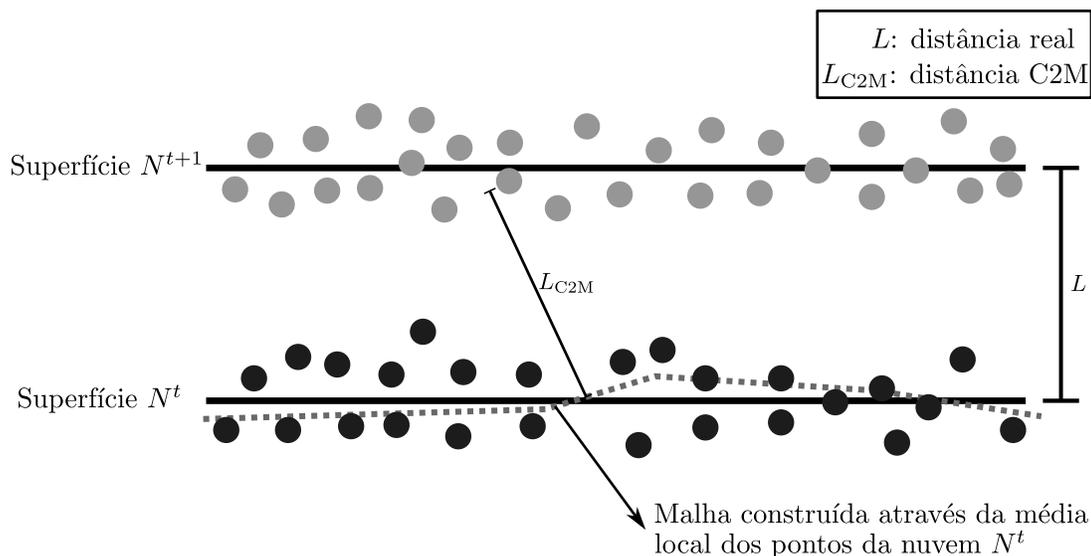
A técnica Nuvem a Malha, do inglês *Cloud to Mesh* ou *Cloud to Model* (C2M), gera uma malha de referência para a nuvem de pontos adquirida no tempo  $t$ . Em seguida, para cada ponto de  $t + 1$ , calcula-se a distância para a superfície gerada para  $t$ . Como, em geral, a malha é construída fazendo uma média local dos pontos (KAZHDAN; BOLITHO; HOPPE, 2006), gerar malhas para regiões com mais ruído ou com oclusão é um processo mais complexo e pode necessitar de intervenção humana. Dessa forma, essa abordagem possui maior complexidade em relação a técnica C2C. A Figura 2 mostra o cálculo de deslocamento utilizando a técnica C2M.

Figura 1 – Cálculo de distância utilizando o método C2C.



Fonte – Elaborada pelo autor (2020).

Figura 2 – Cálculo de distância utilizando o método C2M.



Fonte – Elaborada pelo autor (2020).

### 2.1.3 Comparação Multiescala de Nuvem a Nuvem (M3C2)

A técnica Comparação Multiescala de Nuvem a Nuvem, do inglês *Multiscale Model to Model Cloud Comparison* (M3C2), foi proposta em (LAGUE; BRODU; LEROUX, 2013) com o objetivo de superar algumas limitações do C2C e do C2M. O primeiro, apesar de sua simplicidade computacional, fornece estimativas de deslocamentos subestimados. O segundo necessita gerar uma malha para estimativa dos deslocamentos e, dessa forma, aumenta a complexidade computacional. Além disso, ambas as técnicas não fornecem uma maneira de quantificar as incertezas na estimativa dos deslocamentos.

Os passos utilizados pela técnica M3C2 são descritos a seguir.

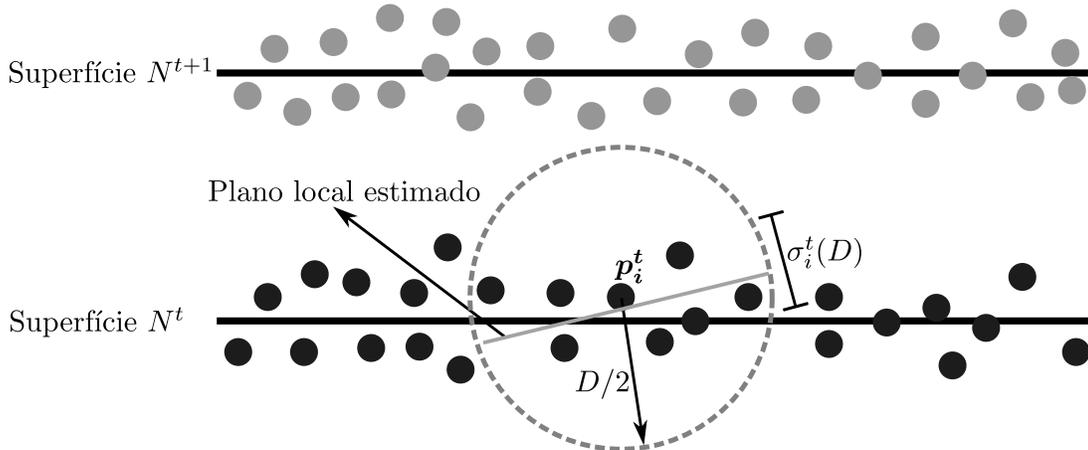
### 2.1.3.1 Cálculo de pontos chave (opcional)

As nuvens de pontos, em geral, possuem uma distribuição irregular de pontos. Dessa forma, há regiões com maior densidade de pontos que outras. Com o objetivo de diminuir a quantidade de cálculos a serem feitos, o M3C2, assim como foi feito em (BRODU; LAGUE, 2012), realiza uma subamostragem dos pontos de forma que eles estejam uniformemente espaçados. Os pontos selecionados são chamados de pontos chave. Vale ressaltar que esse passo é opcional.

### 2.1.3.2 Cálculo das normais

Dado um ponto chave  $\mathbf{p}_i^t$  que pertence a nuvem de pontos  $N^t$ , a normal é definida por um plano que melhor aproxima os vizinhos de  $\mathbf{p}_i^t$ . Os vizinhos são definidos por todos os pontos que estão à uma distância de  $D/2$  de  $\mathbf{p}_i^t$ . Além disso, a rugosidade da nuvem na vizinhança de  $\mathbf{p}_i^t$  na escala  $D$ ,  $\sigma_i^t(D)$ , é definida como o desvio padrão das distância dos vizinhos de  $\mathbf{p}_i^t$  ao plano. A Figura 3 mostra o processo da estimativa da normal pela técnica M3C2.

Figura 3 – Cálculo da normal no ponto  $\mathbf{p}_i^t$  utilizando a técnica M3C2.



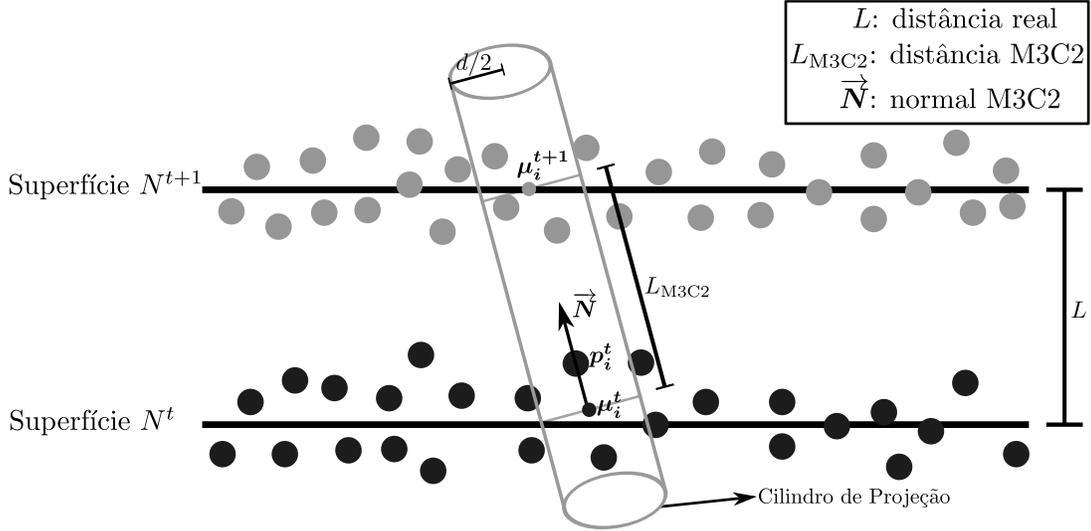
Fonte – Elaborada pelo autor (2020).

### 2.1.3.3 Cálculo da distância entre as nuvens de pontos

Após o cálculo das normais, define-se um cilindro de projeção com raio  $d/2$  cujo eixo passa pelo ponto  $\mathbf{p}_i^t$  e com mesma direção da normal calculada anteriormente. A interseção desse cilindro nas nuvens de pontos  $N^t$  e  $N^{t+1}$  define duas distribuições de pontos com número de pontos  $n_i^t(d)$  e  $n_i^{t+1}(d)$ , respectivamente. Posteriormente, a média ( $\boldsymbol{\mu}_i^t(d)$  e  $\boldsymbol{\mu}_i^{t+1}(d)$ ) e o desvio padrão ( $\sigma_i^t(d)$  e  $\sigma_i^{t+1}(d)$ ) de cada uma dessas distribuições

são calculadas. Dessa forma, o deslocamento do ponto  $\mathbf{p}_i^t$  é definido como a distância euclidiana entre  $\mu_i^t(d)$  e  $\mu_i^{t+1}(d)$ . A Figura 4 ilustra o processo de cálculo de distância proposto pelo M3C2.

Figura 4 – Cálculo da distância usando a técnica M3C2.



Fonte – Elaborada pelo autor (2020).

#### 2.1.3.4 Escolhendo a escala correta

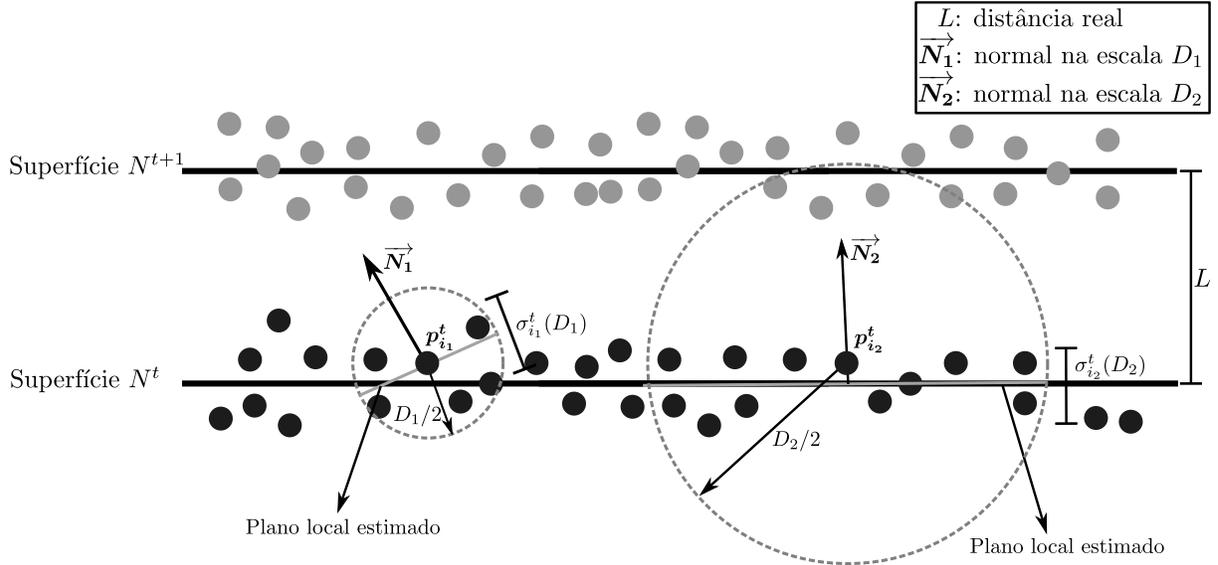
Um dos parâmetros mais importantes para o M3C2 é o da escala  $D$ . Uma escolha inadequada desse parâmetro pode resultar em uma estimativa incorreta da normal e, portanto, a distância medida pode ser errada. A importância da boa escolha desse parâmetro pode ser vista na Figura 5. Nessa figura, é possível observar que utilizando a escala  $D_1$ , a normal estimada resultará em uma distância superestimada. Enquanto isso, a escala  $D_2$  proporciona uma melhor estimativa da normal da superfície e, dessa forma, a distância calculada é mais próxima da distância real.

A escolha do parâmetro é empírica e depende do tipo de estrutura a ser analisada. Nesse contexto, o M3C2 propõe que o usuário forneça como entrada uma variedade de valores para  $D$ . Assim, o algoritmo proposto aplica uma Análise de Componentes Principais (WOLD; ESBENSEN; GELADI, 1987), do inglês *Principal Component Analysis* (PCA), na vizinhança do ponto  $\mathbf{p}_i^t$  e escolhe um fator de escala  $D_{\text{ótimo}}$  que proporcione uma superfície mais plana possível, i.e., uma superfície cuja terceira componente da PCA seja mínima.

#### 2.1.3.5 Intervalo de confiança

O M3C2 também propõe um nível de detecção, do inglês *Level of Detection* (LoD). Esse parâmetro avalia a quantidade mínima de deslocamento necessário para que o mesmo

Figura 5 – Influência do parâmetro de escala  $D$  na estimativa da normal.



Fonte – Elaborada pelo autor (2020).

seja significativo com  $x\%$  de confiança ( $LoD_{x\%}$ ). Para calcular esse valor, o M3C2 utiliza os erros nos registros das nuvens de pontos  $N^t$  e  $N^{t+1}$ :  $reg$ , os desvios padrões  $\sigma_i^t(d)$  e  $\sigma_i^{t+1}(d)$ , e os números de pontos  $n_i^t(d)$  e  $n_i^{t+1}(d)$ . Para um intervalo de confiança de 95%, o  $LoD$  é definido pela equação (2.1).

$$LoD_{95\%}(d) = \pm 1.96 \left( \sqrt{\frac{\sigma_i^t(d)^2}{n_i^t} + \frac{\sigma_i^{t+1}(d)^2}{n_i^{t+1}} + reg} \right) \quad (2.1)$$

#### 2.1.4 Comparando as Técnicas da Literatura

O Quadro 1 resume as principais vantagens e desvantagens das técnicas C2C, C2M e M3C2. Uma abordagem mais detalhada pode ser vista em (HUTCHINSON, 2018).

Quadro 1 – Resumo com as principais vantagens e desvantagens das técnicas C2C, C2M e M3C2.

<b>Técnica</b>	<b>Vantagens</b>	<b>Desvantagens</b>
C2C	<ul style="list-style-type: none"> <li>• Comparação rápida.</li> <li>• Não requer geração de malhas.</li> <li>• Adequada para quando é necessário apenas verificar se houve ou não uma deformação em uma determinada região.</li> </ul>	<ul style="list-style-type: none"> <li>• Cálculo de deformações incorreto.</li> <li>• Sensível à ruído na superfície.</li> </ul>
C2M	<ul style="list-style-type: none"> <li>• Efetiva em superfícies simples com pouco ruído e/ou oclusões.</li> </ul>	<ul style="list-style-type: none"> <li>• Requer geração de malhas.</li> <li>• Pode depender de intervenção humana em superfícies com muito ruído e/ou oclusão.</li> </ul>
M3C2	<ul style="list-style-type: none"> <li>• Não requer geração de malhas.</li> <li>• Gera um valor de significância para os deslocamentos calculados.</li> </ul>	<ul style="list-style-type: none"> <li>• Sensível aos parâmetros utilizados na técnica, principalmente ao parâmetro <math>D</math>.</li> <li>• Simplifica o sentido da deformação ao assumir que esse ocorre na direção normal à superfície.</li> </ul>

## 2.2 APLICAÇÕES

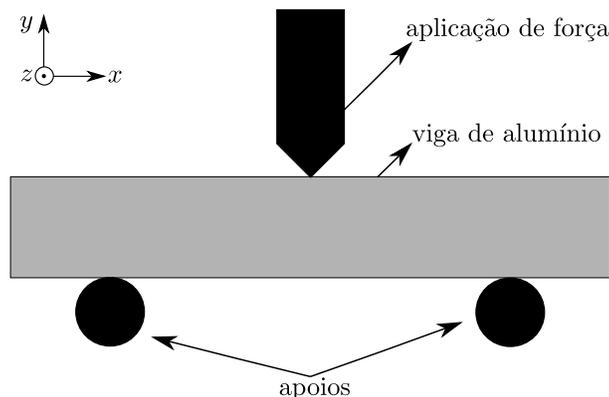
Nesta seção, serão apresentados diferentes tipos de ambiente de aplicação que utilizaram as técnicas apresentadas na seção anterior.

### 2.2.1 Deformação de uma viga

Em (JAFARI; KHALOO; LATTANZI, 2017), os autores propuseram um experimento onde uma viga retangular foi deformada através da aplicação de uma força conhecida. A Figura 6 mostra como foi a configuração do experimento proposto.

Para medir a deformação, inicialmente, a viga foi reconstruída tridimensionalmente antes e depois da aplicação da força. A reconstrução, nesse caso, foi feita utilizando a técnica SfM. Em seguida, as nuvens de pontos geradas antes e depois da aplicação da força foram registradas com uma combinação de intervenção manual e do algoritmo Iterativo de Pontos Mais Próximos, do inglês *Iterative Closest Point* (ICP) (BESL; MCKAY, 1992).

Figura 6 – Configuração do experimento realizado em (JAFARI; KHALOO; LATTANZI, 2017).



Fonte – Elaborada pelo autor (2020).

Posteriormente, os autores utilizaram as técnicas C2C e M3C2 para mensurar a deformação da viga.

O Gráfico 1 mostra os resultados obtidos em (JAFARI; KHALOO; LATTANZI, 2017), quando a deformação central esperada era de 6.3 mm. Os autores concluíram que a técnica M3C2 forneceria resultados melhores em comparação com a C2C.

### 2.2.2 Expansão de uma Bateria

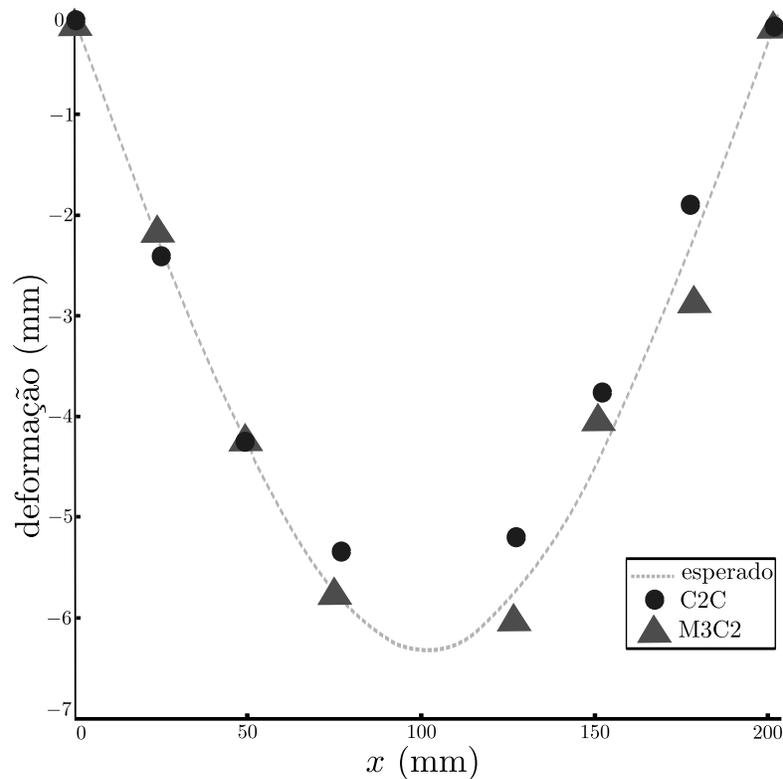
Em (RIEGER *et al.*, 2016), a variação da grossura de uma bateria foi medida durante o seu carregamento. Inicialmente, foi utilizado um scanner de luz estruturada para realizar a captura tridimensional da geometria da bateria. Em seguida, foi aplicada a técnica C2M para medir as deformações ocorridas. Para validar as medidas, também foi utilizado um par de sensores de deslocamento. A Figura 7 mostra a configuração do experimento, utilizando tanto a luz estruturada quanto os sensores de deslocamento.

Como os sensores de deslocamento apenas realizam a medida em um ponto específico e o scanner de luz estruturada realiza medidas ao longo de toda superfície, foram calculados a média e a mediana dos deslocamentos medidos pelo scanner para comparar os dois sensores. O Gráfico 2 mostra os resultados para os deslocamentos ocorridos ao longo do tempo. Os autores concluíram que o scanner de luz estruturada em combinação com a técnica C2M proporciona medidas acuradas sem necessitar contato físico entre o sensor de medida e o objeto de interesse.

### 2.2.3 Monitoramento de Barragens

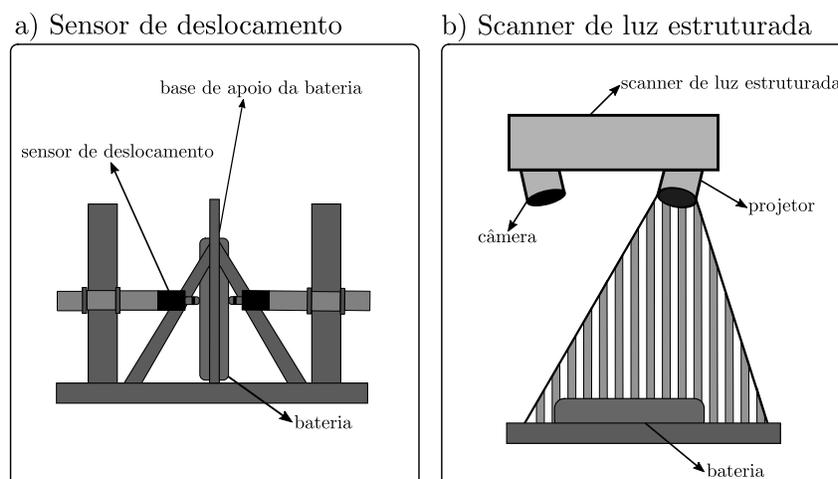
Em (KHALOO *et al.*, 2018), os autores propuseram a utilização de um Veículo Aéreo Não Tripulado, do inglês *Unmanned Aerial Vehicle* (UAV), equipado com uma câmera para realizar o monitoramento de uma barragem. Para simular situações de

Gráfico 1 – Estimativas de deformações obtidas no experimento realizado em (JAFARI; KHALOO; LATTANZI, 2017) utilizando as técnicas C2C e M3C2.



Fonte – Adaptado de (JAFARI; KHALOO; LATTANZI, 2017).

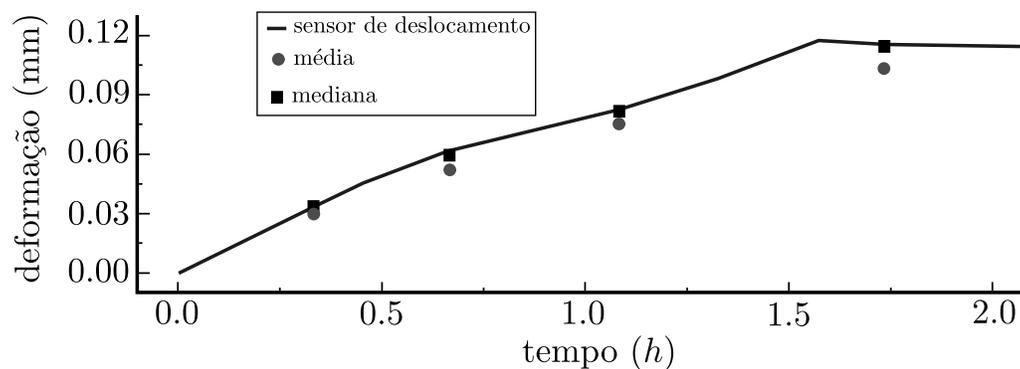
Figura 7 – Configuração do experimento proposto em (RIEGER *et al.*, 2016).



Fonte – Adaptado de (RIEGER *et al.*, 2016).

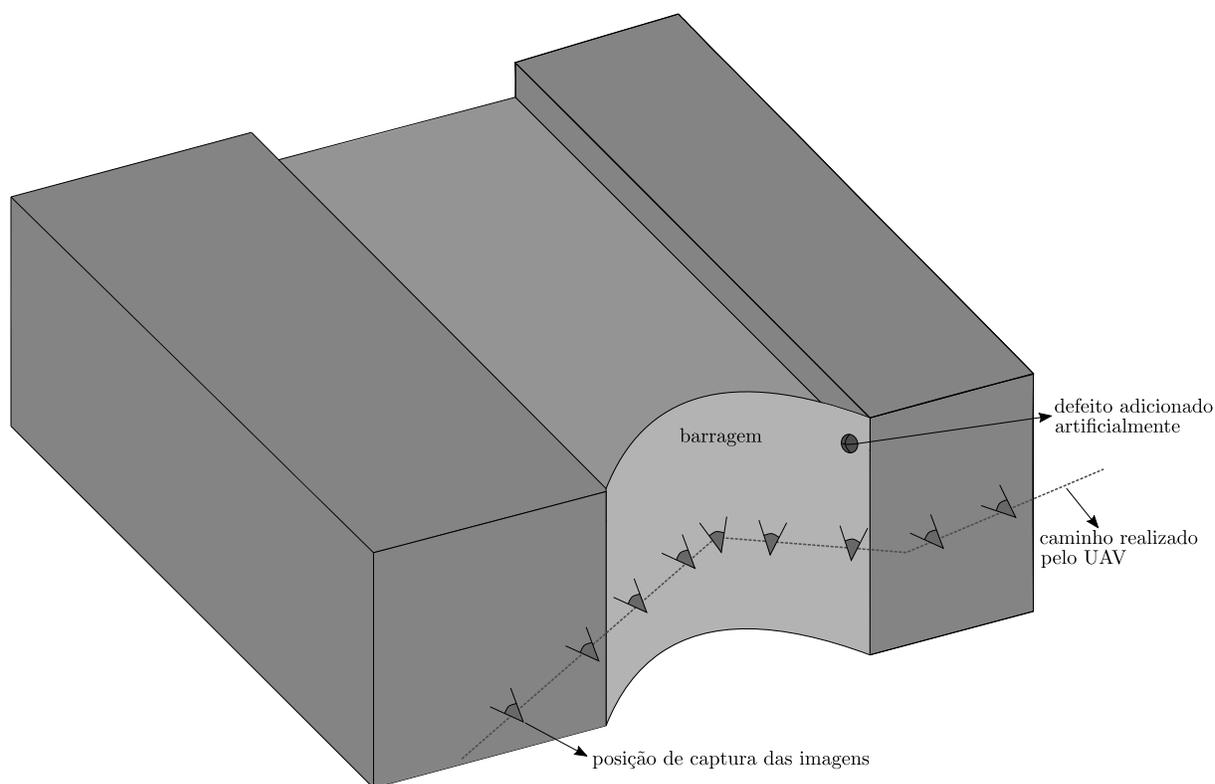
possíveis deformações nas barragens, objetos de diferentes tamanhos foram colocados junto a estrutura. Para medir as deformações, a técnica C2C foi aplicada. A Figura 8 mostra a configuração do experimento.

Gráfico 2 – Deslocamentos obtidos pela técnica C2M no experimento proposto em (RIEGER *et al.*, 2016).



Fonte – Adaptado de (RIEGER *et al.*, 2016).

Figura 8 – Ilustração do experimento realizado em (KHALOO *et al.*, 2018).



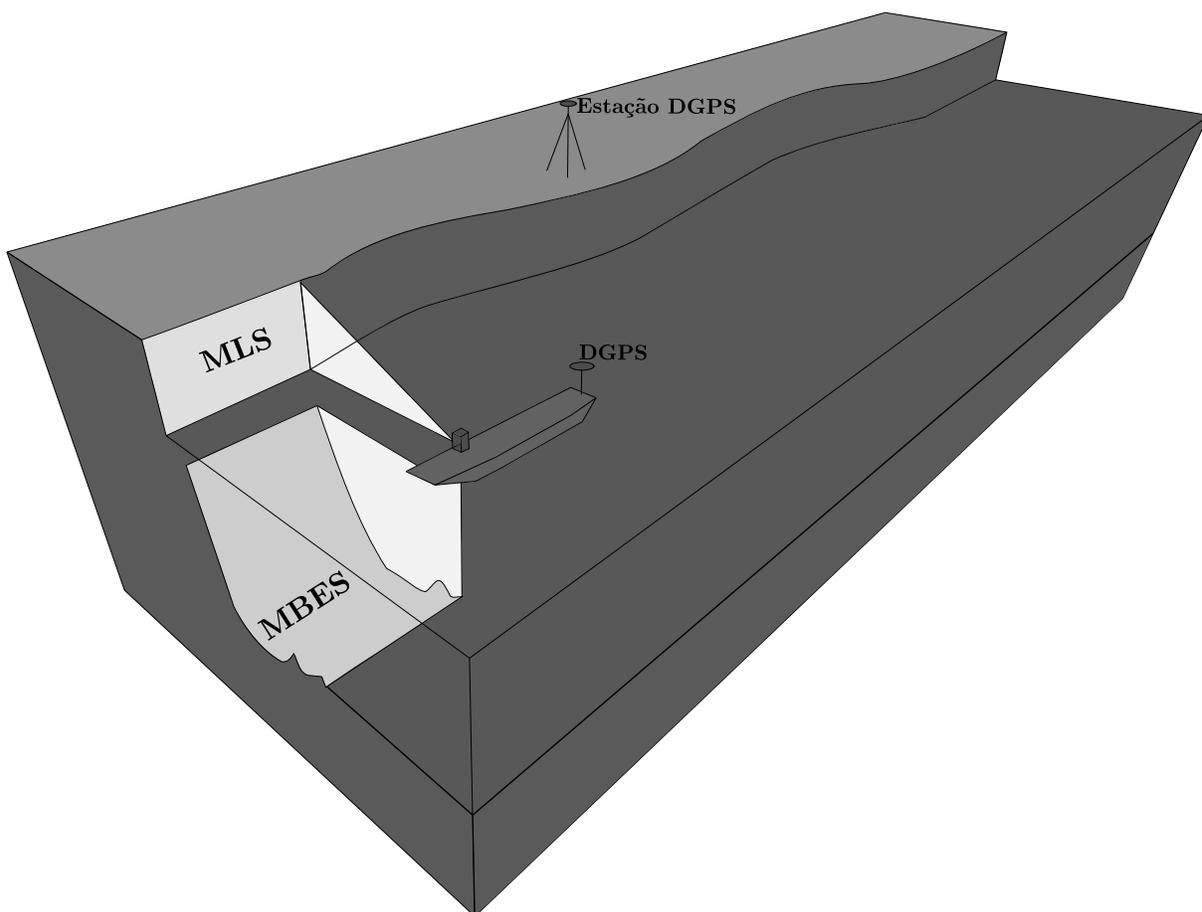
Fonte – Elaborada pelo autor (2020).

Nesse trabalho, os autores concluíram que para que a metodologia proposta fosse suficiente para detecção de defeitos milimétricos, era necessário que resolução da câmera utilizada fosse no mínimo 8MP.

### 2.2.4 Monitoramento de Erosão

Em (LEYLAND *et al.*, 2017), os autores utilizaram a técnica M3C2 para quantificar a erosão que ocorria às margens de um rio. Para realizar as medidas, foram utilizados dois sensores: Sensor a Laser Móvel, do inglês *Mobile Laser Scanner* (MLS), e um Sonar Multi-feixe, do inglês *Multibeam Echo Sounders* (MBES). Para tornar as localizações das medidas mais precisas, também foi utilizado um Sistema de Posicionamento Global Diferencial, do inglês *Differential Global Positioning System* (DGPS). O sistema de medida foi acoplado a um barco que realizava as medidas conforme se movimentava próximo da região de interesse. A Figura 9 mostra a configuração do experimento proposto para medir a erosão.

Figura 9 – Configuração do experimento proposto em (LEYLAND *et al.*, 2017).



Fonte – Adaptada de (LEYLAND *et al.*, 2017).

### 3 FUNDAMENTOS TEÓRICOS

Neste capítulo, serão apresentados os principais conceitos teóricos que foram utilizados para o desenvolvimento desse trabalho.

#### 3.1 COORDENADAS HOMOGÊNEAS

Coordenadas homogêneas são uma maneira de representar pontos tridimensionais de forma que eles possam ser manipulados mais facilmente na forma matricial.

Dado um ponto  $\mathbf{p} = (x, y)^T$  no sistema de coordenadas euclidiano, o mapeamento para o sistema de coordenadas homogêneas é dado pela equação (3.1).

$$\tilde{\mathbf{p}} = \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} = \begin{pmatrix} \alpha x \\ \alpha y \\ \alpha \end{pmatrix} \quad (3.1)$$

Onde  $\tilde{\mathbf{p}}$  é notação do ponto  $\mathbf{p} = (x, y)^T$  em coordenadas homogêneas e  $\alpha \in \mathbb{R}^*$ .

#### 3.2 CÂMERAS

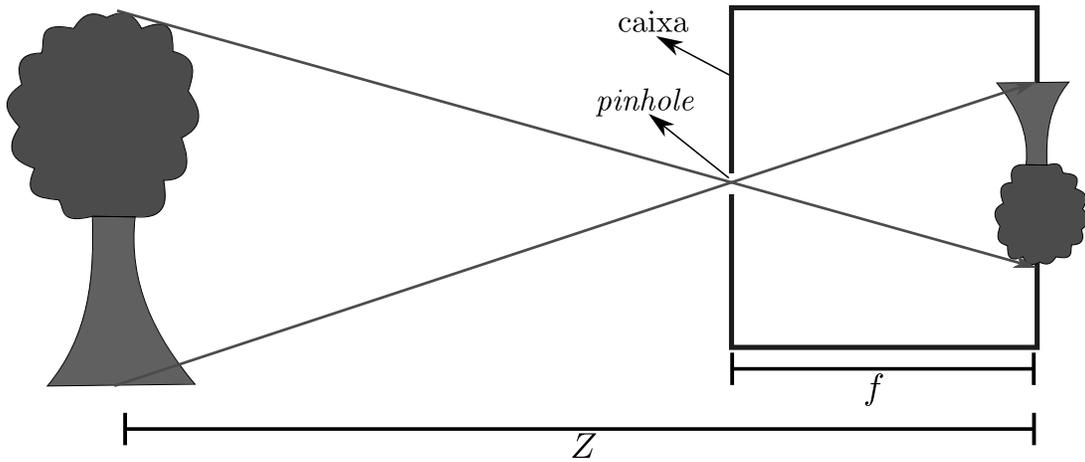
As câmeras realizam o processo de projeção de objetos do mundo tridimensional para um plano bidimensional, chamado de imagem (GONZALEZ; WOODS, 2017; GONZALEZ; WOODS; EDDINS, 2004). Um dos modelos mais simples para caracterizar esse processo é o modelo *pinhole* (TRUCCO; VERRI, 1998). Nesse modelo, a luz emitida ou refletida por um objeto no espaço tridimensional passa por um pequeno orifício de uma caixa fechada. Dessa forma, a imagem é formada de forma invertida dentro da caixa. A Figura 10 ilustra o processo de formação de imagem segundo o modelo *pinhole*.

Matematicamente, o processo de formação de imagem pode ser descrito considerando o orifício de entrada de luz como a origem do sistema de coordenadas,  $\mathbf{c}$ , o ponto no espaço tridimensional  $\mathbf{p} = (X, Y, Z)^T$  e sua projeção bidimensional  $\mathbf{p}_{2D} = (x, y)^T$ . Além disso, para evitar a inversão da imagem, o plano bidimensional para a formação da imagem será considerado à frente do orifício por uma distância  $f$ , conhecida como distância focal. A Figura 11 mostra o processo de projeção utilizando a notação descrita.

Através da Figura 11, é possível verificar duas relações de semelhança de triângulo. A Figura 12 mostra essas duas relações de semelhança. A partir dessa figura, é possível obter (3.2) e (3.3).

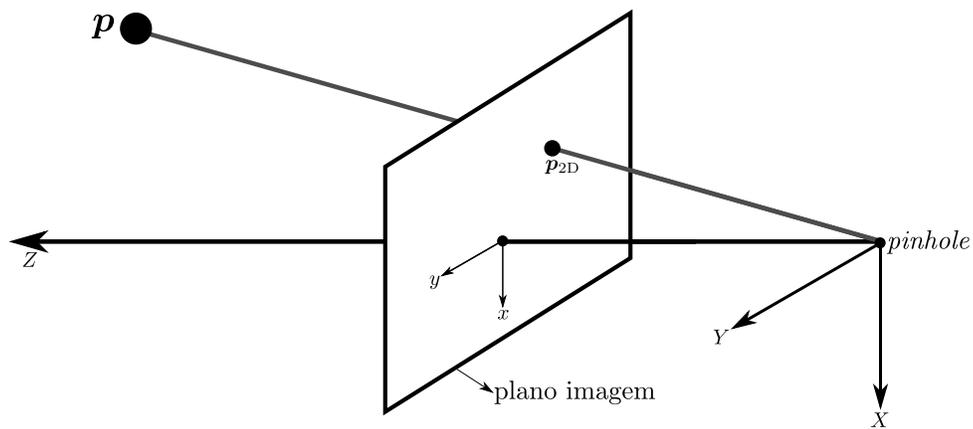
$$x = \frac{fX}{Z} \quad (3.2)$$

Figura 10 – Formação da imagem de acordo com o modelo *pinhole*.



Fonte – Elaborada pelo autor (2020).

Figura 11 – Modelagem do processo de formação de imagem utilizando o modelo *pinhole*.



Fonte – Elaborada pelo autor (2020).

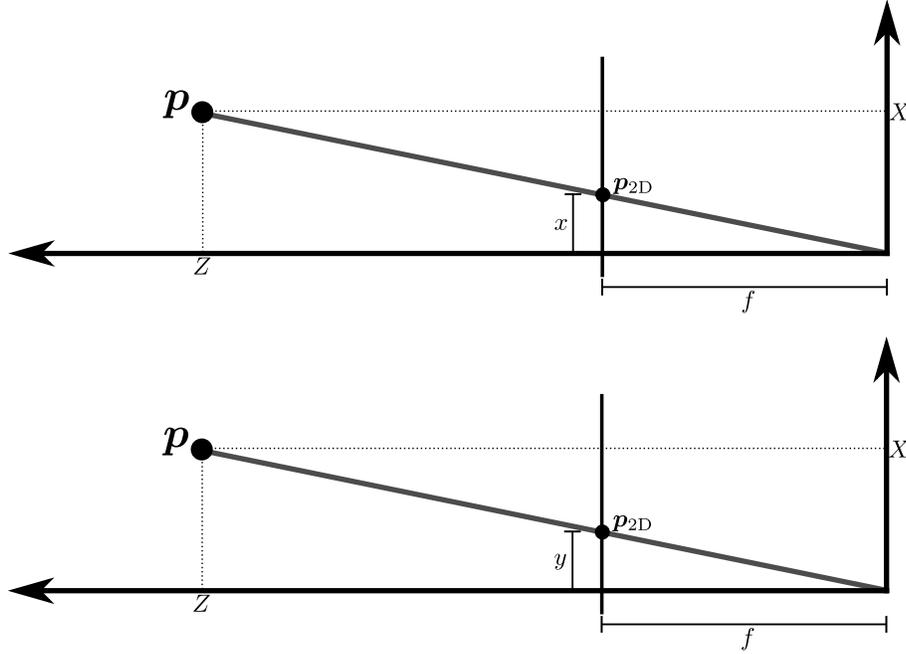
$$y = \frac{fY}{Z} \quad (3.3)$$

Dessa forma, o ponto tridimensional  $\mathbf{p} = (X, Y, Z)^T$  será projetado para  $(\frac{fX}{Z}, \frac{fY}{Z})$ . Utilizando coordenadas homogêneas, i.e.,  $\tilde{\mathbf{p}} = (X, Y, Z, 1)^T$  e  $\tilde{\mathbf{p}}_{2D} = (x, y, 1)^T$ , é possível escrever essa projeção de forma matricial usando a equação (3.4).

$$\begin{pmatrix} x \\ y \\ Z \end{pmatrix} = \begin{pmatrix} f & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \quad (3.4)$$

A equação (3.4) considera o centro da imagem como origem do sistema de referência

Figura 12 – Relações de semelhança de triângulo presentes no modelo *pinhole*.



Fonte – Elaborada pelo autor (2020).

do plano bidimensional. Entretanto, em geral, utiliza-se o canto superior esquerdo da imagem como origem. Considerando que o centro da imagem esteja na posição  $(x_0, y_0)$  em relação ao canto superior esquerdo, é possível reescrever a equação (3.4) utilizando essa nova referência. A equação (3.5) mostra a projeção utilizando o canto superior esquerdo da imagem como referência.

$$\begin{pmatrix} x \\ y \\ Z \end{pmatrix} = \begin{pmatrix} f & 0 & x_0 & 0 \\ 0 & f & y_0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \quad (3.5)$$

Em imagens digitais, também é necessário levar em consideração a discretização do plano imagem. Assim, considera-se uma câmera que possua  $m_x$  *pixels* por unidade de distância na direção  $x$  e  $m_y$  *pixels* por unidade de distância na direção  $y$ . Para transformar o valor projetado de distâncias reais para distâncias em *pixels*, a equação (3.5) deve ser escrita conforme mostrado na equação (3.6).

$$\begin{pmatrix} x \\ y \\ Z \end{pmatrix} = \begin{pmatrix} fm_x & 0 & x_0m_x & 0 \\ 0 & fm_y & y_0m_y & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \quad (3.6)$$

Considerando  $f_x = fm_x$ ,  $f_y = fm_y$ ,  $p_x = m_x x_0$  e  $p_y = m_y y_0$ , a equação (3.7) simplifica a equação (3.6).

$$\begin{pmatrix} x \\ y \\ Z \end{pmatrix} = \begin{pmatrix} f_x & 0 & p_x & 0 \\ 0 & f_y & p_y & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \quad (3.7)$$

Caso o ponto tridimensional  $\mathbf{p}$  não esteja referenciado no mesmo sistema de coordenadas da câmera, também é necessário a utilização das matrizes de rotação,  $\mathbf{R}$ , e translação da câmera,  $\mathbf{t}$ , para realizar a projeção. A equação (3.8) mostra a equação final de projeção de um ponto tridimensional para uma câmera.

$$\begin{pmatrix} x \\ y \\ Z \end{pmatrix} = \begin{pmatrix} f_x & 0 & p_x & 0 \\ 0 & f_y & p_y & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{R} & \mathbf{t} \\ 0_{1 \times 3} & 1 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \quad (3.8)$$

Dá-se o nome de calibração da câmera, o processo de encontrar os parâmetros  $f_x$ ,  $p_x$ ,  $f_y$ ,  $p_y$ . Mais informações sobre o processo de calibração de câmeras podem ser encontradas em (WENG; COHEN; HERNIOU, 1992; ZHANG, 2000; SALVI; ARMANGUÉ; BATLLE, 2002).

### 3.3 PONTOS DE INTERESSE

Os pontos de interesse, do inglês *keypoints*, são regiões de uma imagem que possuem características que as distingue dos seus vizinhos locais (TUYTELAARS; MIKOLAJCZYK *et al.*, 2008). Existem, na literatura, diferentes tipos de algoritmos para detecção de pontos de interesse (KRIG, 2016).

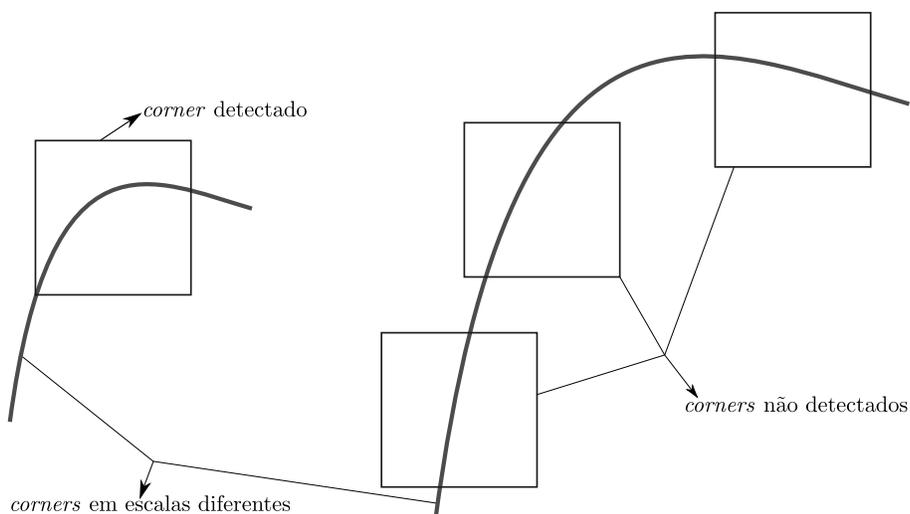
Porém, segundo (TUYTELAARS; MIKOLAJCZYK *et al.*, 2008), para se obter pontos de interesse robustos, esses algoritmos devem possuir um conjunto de características, como: repetibilidade, distintividade, localidade, precisão, quantidade, eficiência. A descrição de cada uma dessas características está disposta no Quadro 2.

Regiões de canto, do inglês *corner*, são um dos pontos de interesse utilizados em visão computacional, sendo o algoritmo *Harris Corner* (HARRIS; STEPHENS *et al.*, 1988) um dos detectores de regiões de canto mais conhecidos. Entretanto, como pode ser visto na Figura 13, regiões de canto não possuem invariância à escala. Dessa forma, caso ocorra uma mudança significativa de escala entre duas imagens, esses pontos de interesse não serão repetidos.

Uma solução para tornar pontos de interesse invariantes à escala foi proposta em (LOWE, 2004). Nesse artigo, são aplicados filtros gaussianos de diferentes amplitudes

Quadro 2 – Principais características de pontos de interesse robustos.

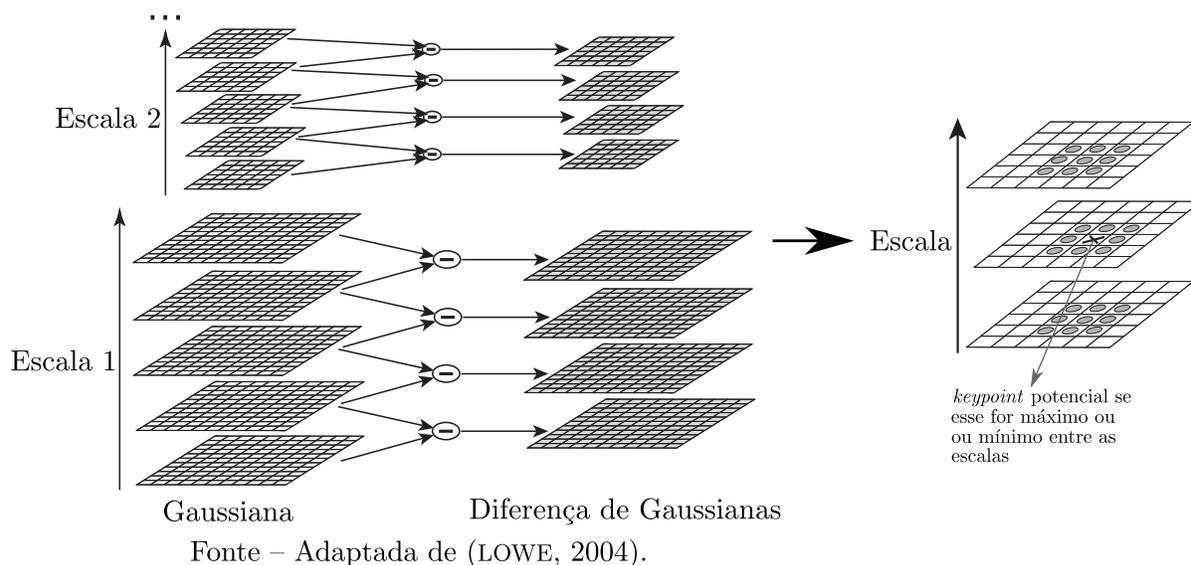
Característica	Descrição
Repetibilidade	Dadas duas imagens de um mesmo objeto ou cena, capturas de dois pontos de vista diferentes, uma grande porcentagem dos pontos de interesse detectados na cena devem ser encontrados nas duas imagens.
Distintividade	O padrão de intensidade dos pontos de interesse detectados deve mostrar grande variação de tal forma que os pontos de interesse possam ser distinguidos e correlacionados.
Localidade	Os pontos de interesse devem ser locais para reduzir as chances de oclusão e permitir um aproximação de um modelo simples das deformações geométricas e fotométricas entre as duas imagens capturas de pontos de vista distintos.
Quantidade	O número de pontos de interesse deve ser suficientemente grande de tal forma que um número razoável de pontos de interesse sejam detectados inclusive em objetos pequenos.
Acurácia	Os pontos de interesse detectados devem possuir posição e escala bem definidos.
Eficiência	Os algoritmos devem ser computacionalmente eficientes.

Figura 13 – Detecção de *corners* em escalas diferentes.

Fonte – Elaborada pelo autor (2020).

em diferentes escalas de imagem. Em seguida, escolhe-se os pontos que são máximos ou mínimos em sua escala e suas escalas vizinhas como pontos de interesse em potencial. Esse processo, conhecido como o detector de *keypoints* SIFT, é ilustrado na Figura 14.

Mais detalhes sobre esse detector de pontos de interesse podem ser encontrados em (LOWE, 2004; GONZALEZ; WOODS, 2017).

Figura 14 – Detecção de *keypoints* segundo (LOWE, 2004).

### 3.4 DESCRITORES

A extração de descritores possui grande importância para diversas aplicações de visão computacional, e.g., *Structure from Motion* (ZHU *et al.*, 2018), reconhecimento de objetos (BLUM *et al.*, 2012; YAO *et al.*, 2015; RASHID *et al.*, 2019), reconhecimento facial (ALBIOL *et al.*, 2008), rastreamento de movimento (LU; LITTLE, 2006), geração de mosaicos panorâmicos (SZELISKI; SHUM, 1997) e navegação robótica (SCHMIDT; KRAFT; KASIŃSKI, 2010; ZHANG, 2011).

Nesse contexto, diversos tipos de descritores já foram propostos na literatura, e.g., SIFT (LOWE, 2004), SURF (BAY *et al.*, 2008), DAISY (TOLA; LEPETIT; FUA, 2009), ORB (RUBLEE *et al.*, 2011), KAZE (ALCANTARILLA; BARTOLI; DAVISON, 2012) e AKAZE (ALCANTARILLA; SOLUTIONS, 2013). Esses descritores são chamados de *handcrafted*, i.e., são descritores onde os tipos de parâmetros a serem extraídos seguem um algoritmo projetado por um humano.

Nos últimos anos, métodos baseados em *deep learning* vêm ganhando importância significativa em visão computacional. Dessa forma, diferentes descritores baseados em aprendizado de máquina foram propostos, e.g., DeepDesc (SIMO-SERRA *et al.*, 2015), LIFT (YI *et al.*, 2016), UCN (CHOY *et al.*, 2016) e DeepCD (YANG *et al.*, 2017). Essas abordagens utilizam grandes base de dados de imagens para treinar mecanismos de geração de descritores.

Nesta seção, será apresentada uma breve descrição sobre descritores *handcrafted*. Em seguida, será mostrado como atuam os descritores baseados em *deep learning*. Finalmente, será feita uma comparação entre descritores densos e esparsos.

### 3.4.1 Descritores *handcrafted*

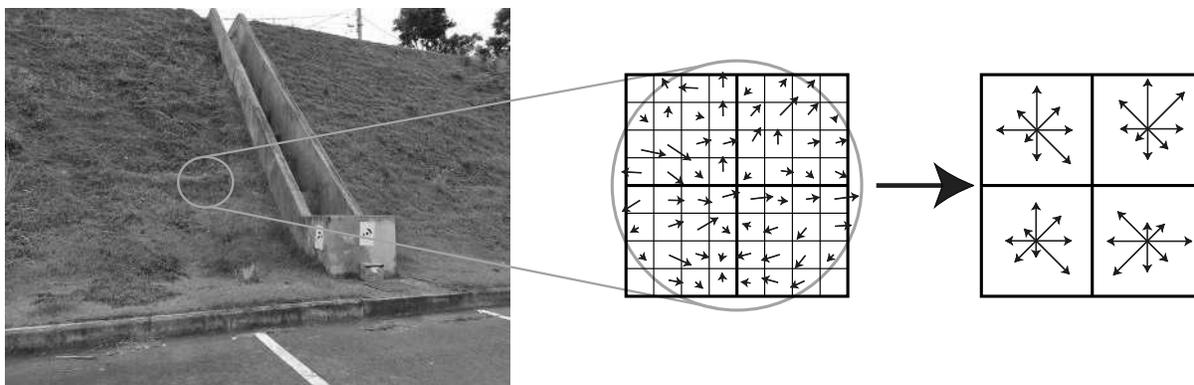
Os descritores *handcrafted* são algoritmos que realizam a extração de informações de um segmento de imagem. Esses são muito importantes, pois permitem a identificação de regiões iguais que foram capturadas por câmeras em posições diferentes ou em condições de iluminação diferentes.

Ao desenvolver os algoritmos, deve-se levar em consideração que o descritor gerado deve ser robusto à possíveis variações fotométricas e variações do ponto de vista. Para atingir esse objetivo, esses algoritmos, em geral, se baseiam no cálculo de histogramas de gradientes. O SIFT (LOWE, 2004), por exemplo, descreve um ponto de interesse da imagem da seguinte forma:

- Em uma vizinhança  $16 \times 16$  pixels ao redor do ponto de interesse, calcula-se os gradientes de cada pixel;
- Divide-se o bloco  $16 \times 16$  em 16 sub-blocos  $4 \times 4$ , chamados de células;
- Para cada célula, calcula-se um histograma com 8 *bins*;
- O vetor descritor SIFT final será a concatenação dos histogramas de cada célula, i.e., será um vetor de  $4 * 4 * 8 = 128$  posições.

A Figura 15 mostra o processo de extração do SIFT simplificado. Nesse caso, foram utilizados sub-blocos  $2 \times 2$  calculados em uma vizinhança de  $8 \times 8$  pixels ao redor do ponto de interesse.

Figura 15 – Processo de extração do descritor SIFT simplificado.



Fonte – Elaborada pelo autor (2020).

### 3.4.2 Descritores baseados em *deep learning*

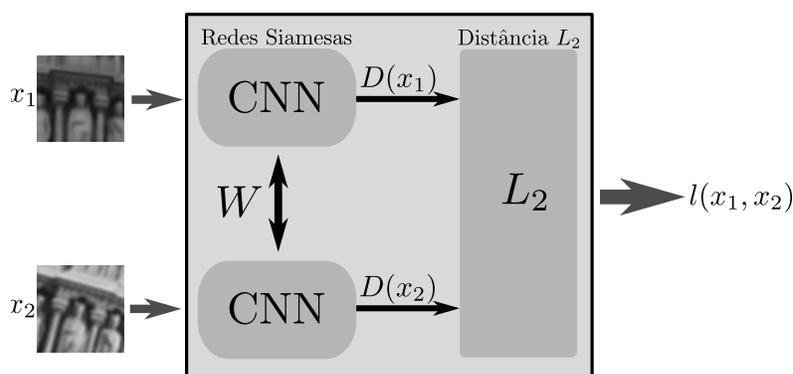
Diferentemente dos descritores *handcrafted*, os descritores baseados em *deep learning* não seguem um algoritmo pré-determinado. O processo de extração de informação é

treinado com uma grande base de dados que contém pontos que são correspondentes em diferentes imagens. Dessa forma, a extração de descritores é aprendida a partir dos dados.

O descritor DeepDesc, por exemplo, utiliza redes neurais convolucionais (CNN) (LECUN *et al.*, 1998) para a extração dos descritores. Esse descritor utiliza uma topologia com duas CNNs siamesas, i.e., os pesos das camadas internas são compartilhadas. Para o treinamento, utiliza-se uma base de dados com pedaços de imagens que são correspondentes. Os pesos das CNNs são ajustados com o objetivo de minimizar a distância  $L_2$  entre descritores de pedaços de imagens que são correspondentes.

A Figura 16 mostra o funcionamento do treinamento do DeepDesc.

Figura 16 – Processo de treinamento do descritor DeepDesc.



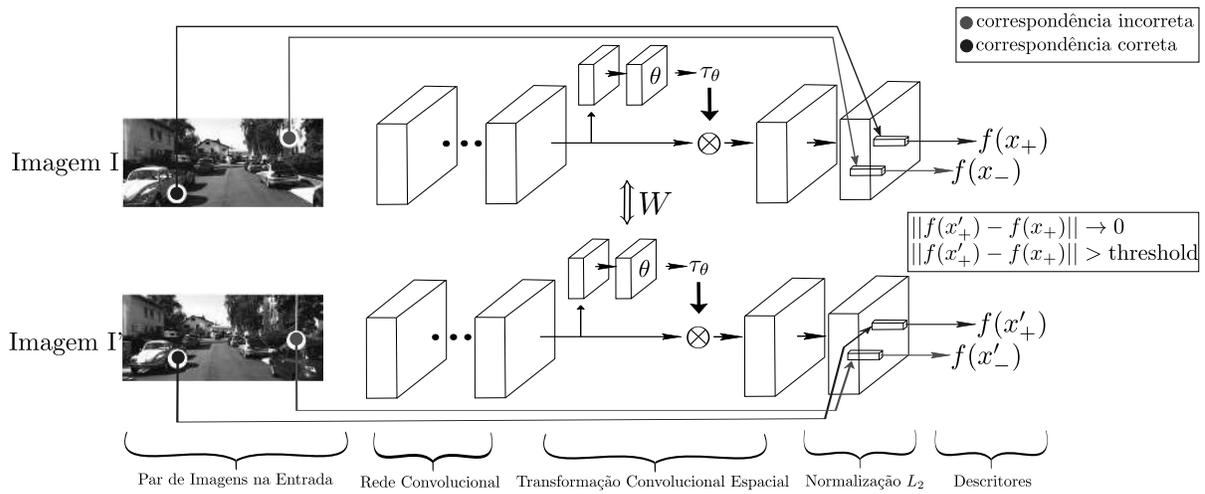
Fonte – Adaptada de (SIMO-SERRA *et al.*, 2015).

Por outro lado, o descritor Rede de Correspondência Universal (CHOY *et al.*, 2016), do inglês *Universal Correspondence Network* (UCN), realiza o aprendizado através de um par de imagens e uma lista contendo pontos correspondentes e não correspondentes entre as imagens utilizadas. Além disso, o UCN também utiliza redes neurais convolucionais para realizar a extração dos parâmetros. Contudo, o UCN adiciona uma etapa de transformação espacial de forma a tornar os descritores gerados invariantes à escala e rotação. Ademais, esse descritor, a partir dos dados de treinamento, otimiza seus pesos internos de forma a minimizar a distância euclidiana entre pontos semelhantes e tornar a distância entre pontos distintos maior que um certo valor limiar. A grande vantagem do UCN é a sua capacidade de gerar descritores densos, i.e., há um descritor para cada pixel da imagem. A Figura 17 ilustra a configuração do descritor UCN.

### 3.4.3 Descritores densos e esparsos

Em geral, a etapa que precede a extração de descritores é a localização de pontos de interesse. Esses são pontos que possuem alta capacidade de ser distinguidos de outros, e.g., regiões de canto e borda. Dessa forma, os descritores costumam ser calculados apenas nesses pontos de interesse para evitar falsos positivos no *match* de descritores. Entretanto, como apenas uma pequena porcentagem dos pontos são considerados de

Figura 17 – Configuração de treinamento do descritor UCN.

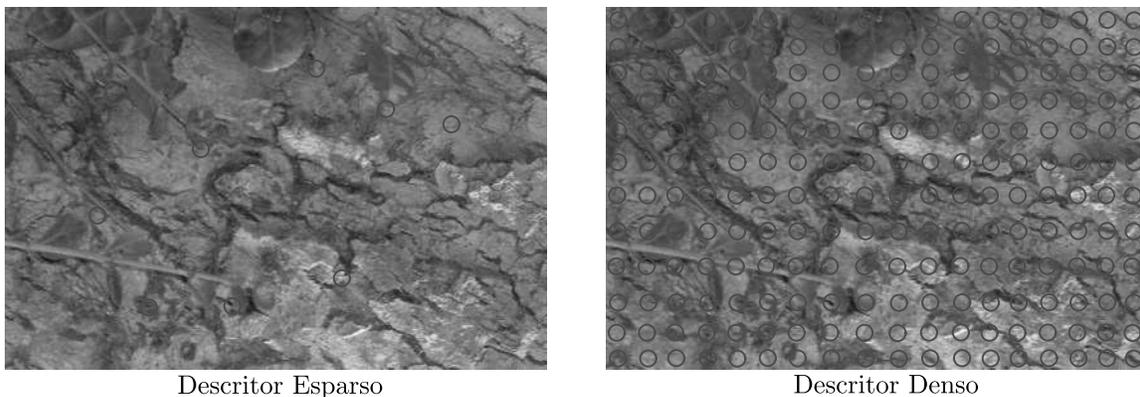


Fonte – Adaptada de (CHOY *et al.*, 2016).

interesse, a distribuição de descritores ao longo de imagem se torna esparsa. Os descritores SIFT e SURF são exemplos de descritores esparsos. Uma outra alternativa é o cálculo de descritores para todos os pixels da imagem. Esses são chamados de descritores densos. Como exemplos de descritores densos, pode-se citar os descritores DAISY e UCN.

A Figura 18 mostra a diferença entre o descritores esparsos e densos.

Figura 18 – Comparação entre descritores esparsos e densos.



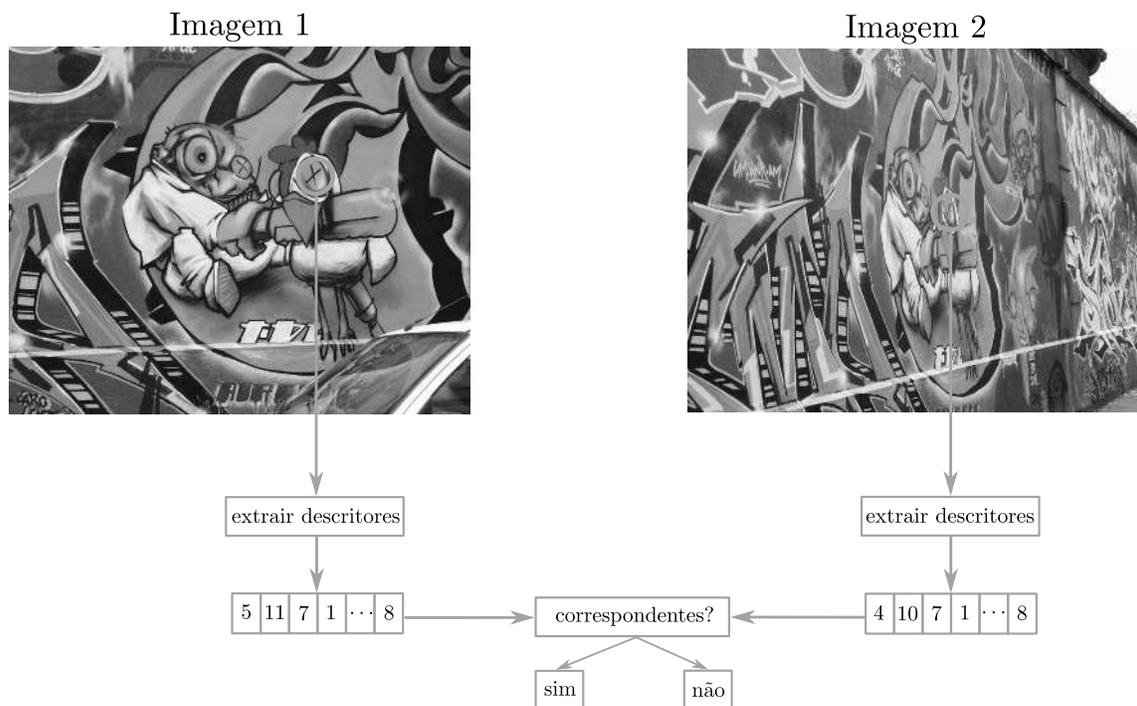
Fonte – Elaborada pelo autor (2020).

### 3.5 CORRESPONDÊNCIA ENTRE DESCRITORES

Para encontrar pontos que são correspondentes entre duas imagens, é necessário aplicar um processo de correspondência entre os descritores da primeira imagem com os descritores da segunda. O processo mais simples para encontrar correspondências é a utilização da menor diferença quadrada. Nesse processo, considera-se que dois descritores são correspondentes, caso eles possuam a menor diferença quadrada em relação aos demais

correspondentes. A Figura 19 ilustra o processo de correspondência entre descritores de diferentes imagens.

Figura 19 – Correspondência entre descritores de diferentes imagens.



Fonte – Elaborada pelo autor (2020).

Entretanto, essa abordagem pode gerar muitas falsas correspondências. De forma a mitigar esse problema, alguns processos de filtragem de correspondências podem ser empregados. Uma regra simples de filtragem, proposta em (LOWE, 2004), é a realização de um teste entre o descritor com menor e segunda menor diferença quadrada. Caso a razão entre a distância entre esses dois descritores seja maior que 0,8, a correspondência é considerada falsa. Segundo (LOWE, 2004), a aplicação desse processo de filtragem proporciona uma filtragem de 90% das correspondências falsas e menos de 5% das correspondências verdadeiras.

Além disso, existem diferentes soluções na literatura baseadas em aprendizagem de máquina para filtragem de correspondências incorretas. A técnica Aprendendo a Remover Correspondências Incorretas, do inglês *Learning for Mismatch Removal* (LMR), por exemplo, extrai um conjunto de características para classificar uma correspondência em correta ou incorreta, utilizando diferentes algoritmos de classificação, como por exemplo, a Máquina de Vetores de Suporte, do inglês *Support Vector Machine* (SVM).

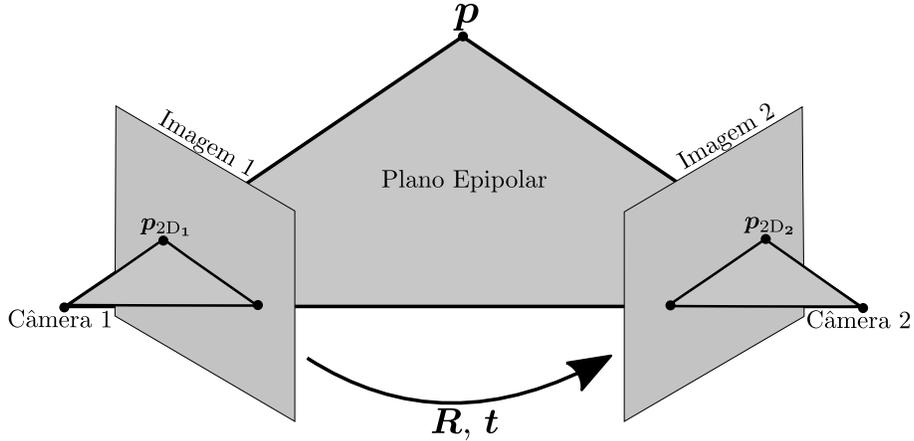
### 3.6 GEOMETRIA EPIPOLAR

A técnica SfM possui como base teórica a geometria epipolar que é o tipo de relação que ocorre quando duas câmeras observam uma cena tridimensional de posições diferentes.

Nessa geometria, as câmeras são aproximadas através do modelo *pinhole*.

Assim, considera-se um ponto tridimensional  $\mathbf{p}$  com projeções nas câmeras 1 e 2, definidas por  $\mathbf{p}_{2D_1}$  e  $\mathbf{p}_{2D_2}$ , respectivamente. Além disso, considera-se também que as câmeras 1 e 2 estejam relacionadas pela matriz de rotação,  $\mathbf{R}$ , e o vetor de translação,  $\mathbf{t}$ . A Figura 20 ilustra a configuração da geometria epipolar.

Figura 20 – Geometria epipolar.



Fonte – Elaborada pelo autor (2020).

Denotando por  $\mathbf{p}^1$  e  $\mathbf{p}^2$  as descrições do ponto  $\mathbf{p}$  em relação aos sistemas de coordenadas da câmera 1 e 2, respectivamente, é possível relacioná-las através da equação (3.9).

$$\mathbf{p}^2 = \mathbf{R}\mathbf{p}^1 + \mathbf{t} \quad (3.9)$$

Sendo  $\mathbf{t} = (t_x, t_y, t_z)$ , define-se por  $[\mathbf{t}]_x$  a matriz antisimétrica do vetor  $\mathbf{t}$ , descrita na equação (3.10).

$$[\mathbf{t}]_x = \begin{bmatrix} 0 & -t_z & t_y \\ t_z & 0 & -t_x \\ t_y & t_x & 0 \end{bmatrix} \quad (3.10)$$

Pré-multiplicando a equação (3.9) por  $[\mathbf{t}]_x$ , obtém-se a equação (3.11).

$$[\mathbf{t}]_x \mathbf{p}^2 = [\mathbf{t}]_x \mathbf{R}\mathbf{p}^1 + \underbrace{[\mathbf{t}]_x \mathbf{t}}_0 \quad (3.11)$$

A equação (3.12) pode ser obtida pré-multiplicando a equação (3.11) por  $(\mathbf{p}^2)^T$ .

$$\underbrace{(\mathbf{p}^2)^T [\mathbf{t}]_x \mathbf{p}^2}_0 = (\mathbf{p}^2)^T [\mathbf{t}]_x \mathbf{R}\mathbf{p}^1 \quad (3.12)$$

O termo  $\mathbf{E} = [\mathbf{t}]_x \mathbf{R}$  é chamado de matriz essencial. Dessa forma, a geometria epipolar pode ser compactada através da equação (3.13).

$$(\mathbf{p}^2)^T \mathbf{E} \mathbf{p}^1 = 0. \quad (3.13)$$

A equação (3.13) pode ser reescrita utilizando os pontos projetados  $\mathbf{p}_{2D_1}$  e  $\mathbf{p}_{2D_2}$ . Para isso, considera-se  $\mathbf{K}$  a matriz de calibração das câmeras,  $\mathbf{p}_{2D_1} = \mathbf{K} \mathbf{p}^1$  e  $\mathbf{p}_{2D_2} = \mathbf{K} \mathbf{p}^2$ . Assim, obtém-se a equação (3.14).

$$(\mathbf{K}^{-1} \mathbf{p}^2)^T \mathbf{E} (\mathbf{K}^{-1} \mathbf{p}^1) = 0. \quad (3.14)$$

Desenvolvendo a equação (3.14), obtém-se a equação (3.15).

$$(\mathbf{p}^2)^T (\mathbf{K}^{-1} \mathbf{E} \mathbf{K}^{-1}) \mathbf{p}^1 = 0. \quad (3.15)$$

O termo  $\mathbf{F} = \mathbf{K}^{-1} \mathbf{E} \mathbf{K}^{-1}$  é chamado de matriz fundamental. Assim, a equação (3.16) é outra forma compacta de se representar a geometria epipolar.

$$(\mathbf{p}^2)^T \mathbf{F} \mathbf{p}^1 = 0. \quad (3.16)$$

Os termos da matriz fundamental  $\mathbf{F}$  podem ser encontrados utilizando o Algoritmo de 8 pontos (MA *et al.*, 2012).

## 4 METODOLOGIA PROPOSTA

Neste capítulo, será apresentada a metodologia proposta para cálculo de deslocamentos de pontos de uma superfície. Porém, inicialmente, será mostrada uma abordagem simplificada para monitoramento de deformações. Nessa abordagem, apenas deslocamentos em duas dimensões serão considerados. Em seguida, essa abordagem simplificada foi generalizada de forma a englobar deformações em qualquer direção. Essa última foi intitulada de Distância por Correspondência Visual e Reprojecção de Pontos (DCVRP).

### 4.1 ABORDAGEM SIMPLIFICADA

Com o objetivo de verificar a capacidade da utilização de descritores para o monitoramento de deformações, foi feita uma simplificação do problema de deslocamento tridimensional. Dessa forma, inicialmente, apenas deslocamentos bidimensionais foram considerados. Nesse sentido, para essa abordagem, uma estrutura plana com dimensões conhecidas foi considerada como objeto de interesse para monitoramento de deslocamentos. Nessa estrutura, são pintados círculos com tamanhos e posições conhecidas. Além disso, uma força externa,  $\mathbf{F}$ , deformará a estrutura ao longo do tempo, e as deformações ocorridas serão calculadas a partir da detecção dos círculos pintados nas imagens capturadas. Assim, considera-se  $t = 0$  o instante anterior a aplicação da força e  $t > 0$  quando a força já está atuante.

Considerando que o um sistema de coordenadas globais tenha origem no círculo localizado no canto superior esquerdo, a posição do círculo localizado na  $i$ -ésima linha e  $j$ -ésima coluna é dado por  $\mathbf{P}(i, j, t = 0) = (\delta j, \delta i, 0)^T$ . Onde  $\delta$  é a distância dos círculos adjacentes em milímetros. Como a estrutura é plana, a posição da coordenada  $Z$  foi considerada como zero para todos os círculos.

Além disso, nas imagens capturadas, é possível detectar a posição dos círculos utilizando a transformada de Hough circular. Nesse caso, os círculos atuam como os descritores nessa abordagem simplificada.

Como a posição dos círculos em coordenadas globais é conhecida, é possível fazer um mapeamento das coordenadas dos círculos detectados pela transformada de Hough para o sistema de coordenada global proposto através de uma relação de homografia. Essa relação é mostrada na equação (4.1).

$$\lambda \begin{bmatrix} x_{i,j} \\ y_{i,j} \\ 1 \end{bmatrix} = H \begin{bmatrix} \delta j \\ \delta i \\ 1 \end{bmatrix} \quad (4.1)$$

Onde, na imagem,  $x_{i,j}$  e  $y_{i,j}$  são as coordenadas  $x$  e  $y$  do círculo localizado na  $i$ -ésima linha e  $j$ -ésima coluna, e  $\lambda$  é um fator de escala. Para encontrar a matriz  $H$ ,

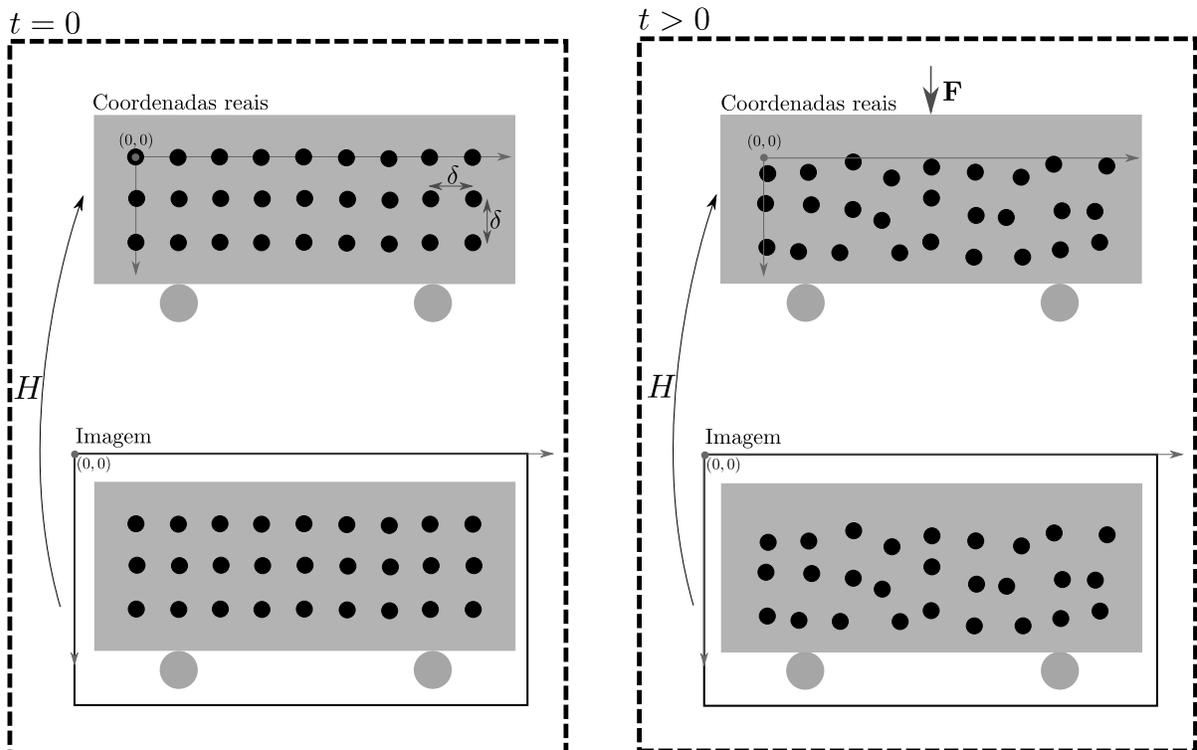
utiliza-se a Transformação Linear Direta, do inglês *Direct Linear Transform* (DLT). Nesse caso, são necessários no mínimo 4 pontos para aplicar a DLT.

A matriz  $H$  é calculada em  $t = 0$ , i.e., antes da barra sofrer qualquer deformação causada pela força externa. Para  $t > 0$ , ainda é possível detectar os círculos na imagem utilizando a transformada de Hough, porém não é possível saber, *a priori*, a disposição dos círculos nas coordenadas globais. Dessa forma, não é possível calcular a matriz  $H$  durante o experimento. Contudo, a matriz calculada em  $t = 0$ , continua válida caso a câmera se mantenha fixa durante todo o experimento. Assim, a nova posição dos círculos, em coordenadas globais, pode ser encontrada apenas multiplicando a matriz  $H$  por  $\mathbf{p}(i, j, t) = (x_{i,j,t}, x_{i,j,t}, 1)^T$ . Portanto, o deslocamento do círculo localizado na  $i$ -ésima linha e  $j$ -ésima coluna no tempo  $t > 0$  é dado pela equação (4.2).

$$\mathbf{d}(i, j, t) = H \begin{bmatrix} x_{i,j,t}/\lambda \\ y_{i,j,t}/\lambda \\ 1/\lambda \end{bmatrix} - \mathbf{P}(i, j) \quad (4.2)$$

Dessa forma, os deslocamentos podem ser calculados para cada novo quadro capturado durante o experimento. A Figura 21 ilustra a metodologia simplificada para cálculo de deslocamentos em duas dimensões.

Figura 21 – Metodologia simplificada para cálculo de deslocamento em estruturas.



Fonte – Elaborada pelo autor (2020).

Com o objetivo de melhorar os resultados obtidos, é possível aplicar dois tipos de filtros nos deslocamentos obtidos: espacial e temporal.

#### 4.1.1 Filtragem espacial

A filtragem espacial consiste em suavizar o deslocamento capturado para o círculo em  $(i, j)$  utilizando os deslocamentos dos círculos vizinhos. Isso pode ser feito através de um *kernel* que é aplicado sobre a matriz de deslocamentos  $d(i, j, t)$ . A aplicação do *kernel* de suavização  $G$  de tamanho  $n_v \times n_v$  pode ser verificada na equação (4.3).

$$d_{esp}(i, j, t) = \frac{\sum_{u=-n_v}^{n_v} \sum_{k=-n_v}^{n_v} G(u, k) d(i+u, j+k, t)}{\sum_{u=-n_v}^{n_v} \sum_{k=-n_v}^{n_v} G(u, k)} \quad (4.3)$$

#### 4.1.2 Filtragem temporal

Durante a captura das imagens no experimento, pequenas alterações de iluminação no ambiente podem modificar a capacidade de detecção de círculos da transformada de Hough. Dessa forma, ao longo do tempo, pequenas variações de deslocamento podem ser verificadas. Uma das formas de mitigar esse efeito é a aplicação de um filtro média móvel nos deslocamentos encontrados. A equação (4.4) mostra a aplicação do filtro média móvel para o círculo da  $i$ -ésima linha e  $j$ -ésima coluna.

$$d_{temp}(i, j, t) = \frac{1}{M} \sum_{k=0}^{M-1} d(i, j, t+k) \quad (4.4)$$

Onde  $M$  é a largura do filtro média móvel.

## 4.2 DISTÂNCIA POR CORRESPONDÊNCIA VISUAL E REPROJEÇÃO DE PONTOS (DCVRP)

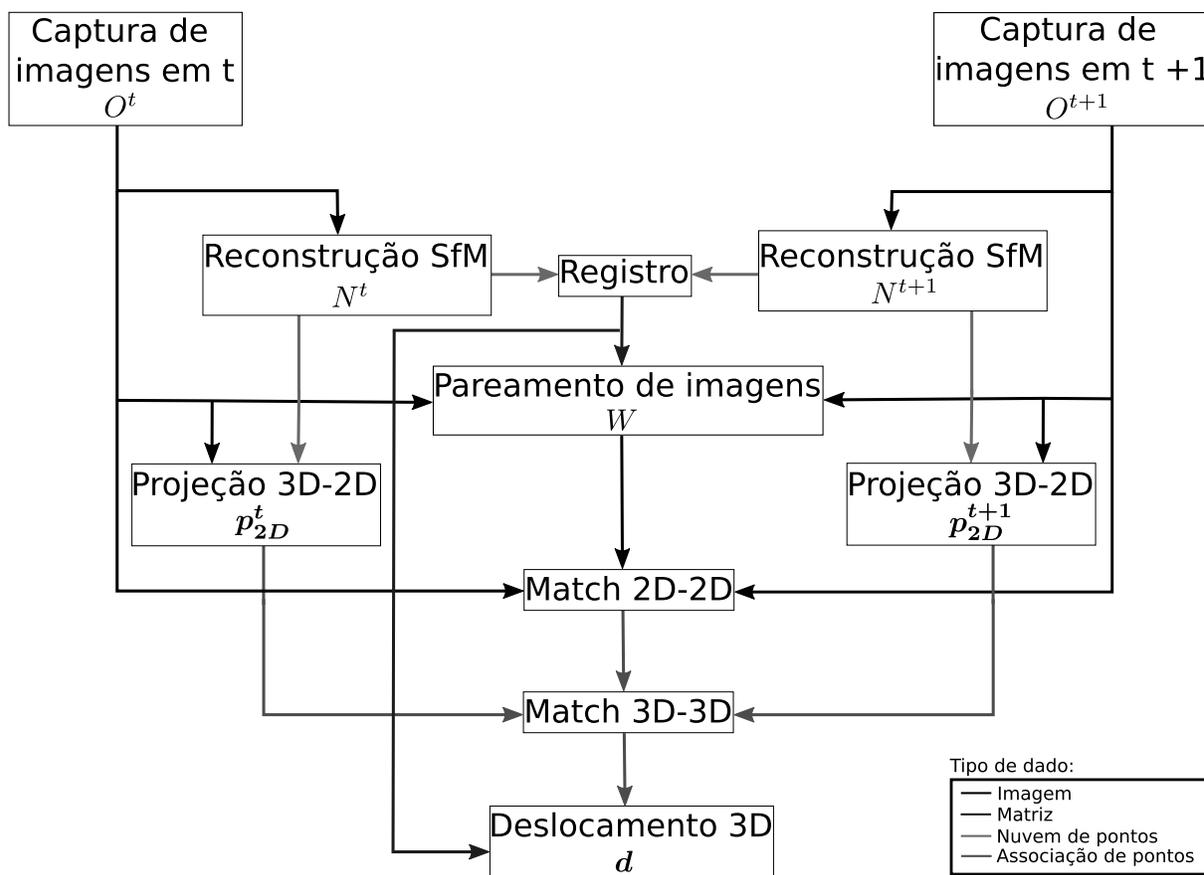
Dadas duas nuvens de pontos,  $N^t$  e  $N^{t+1}$ , geradas utilizando a técnica SfM pelos conjuntos de imagens  $O^t = \{\mathbf{I}_1^t, \mathbf{I}_2^t, \dots, \mathbf{I}_k^t, \dots, \mathbf{I}_{L^t}^t\}$  e  $O^{t+1} = \{\mathbf{I}_1^{t+1}, \mathbf{I}_2^{t+1}, \dots, \mathbf{I}_k^{t+1}, \dots, \mathbf{I}_{L^{t+1}}^{t+1}\}$  nos tempos  $t$  e  $t+1$ , respectivamente. Sendo  $L^t$  e  $L^{t+1}$  a quantidade de imagens dos conjuntos  $O^t$  e  $O^{t+1}$ , respectivamente. O deslocamento do  $i$ -ésimo ponto tridimensional de  $N^t$ ,  $\mathbf{p}_i^t$ , é calculado através dos passos desenvolvidos nas subseções a seguir.

O Diagrama 1 resume os principais passos da metodologia DCVRP para o cálculo de deslocamento em estruturas.

#### 4.2.1 Registro de nuvens

Para comparar nuvens de pontos, é necessário, inicialmente, que ambas estejam no mesmo referencial. Para realizar essa tarefa, existem diversas técnicas disponíveis na

Diagrama 1 – Metodologia DCVRP para cálculo de deslocamento em estruturas tridimensionais.



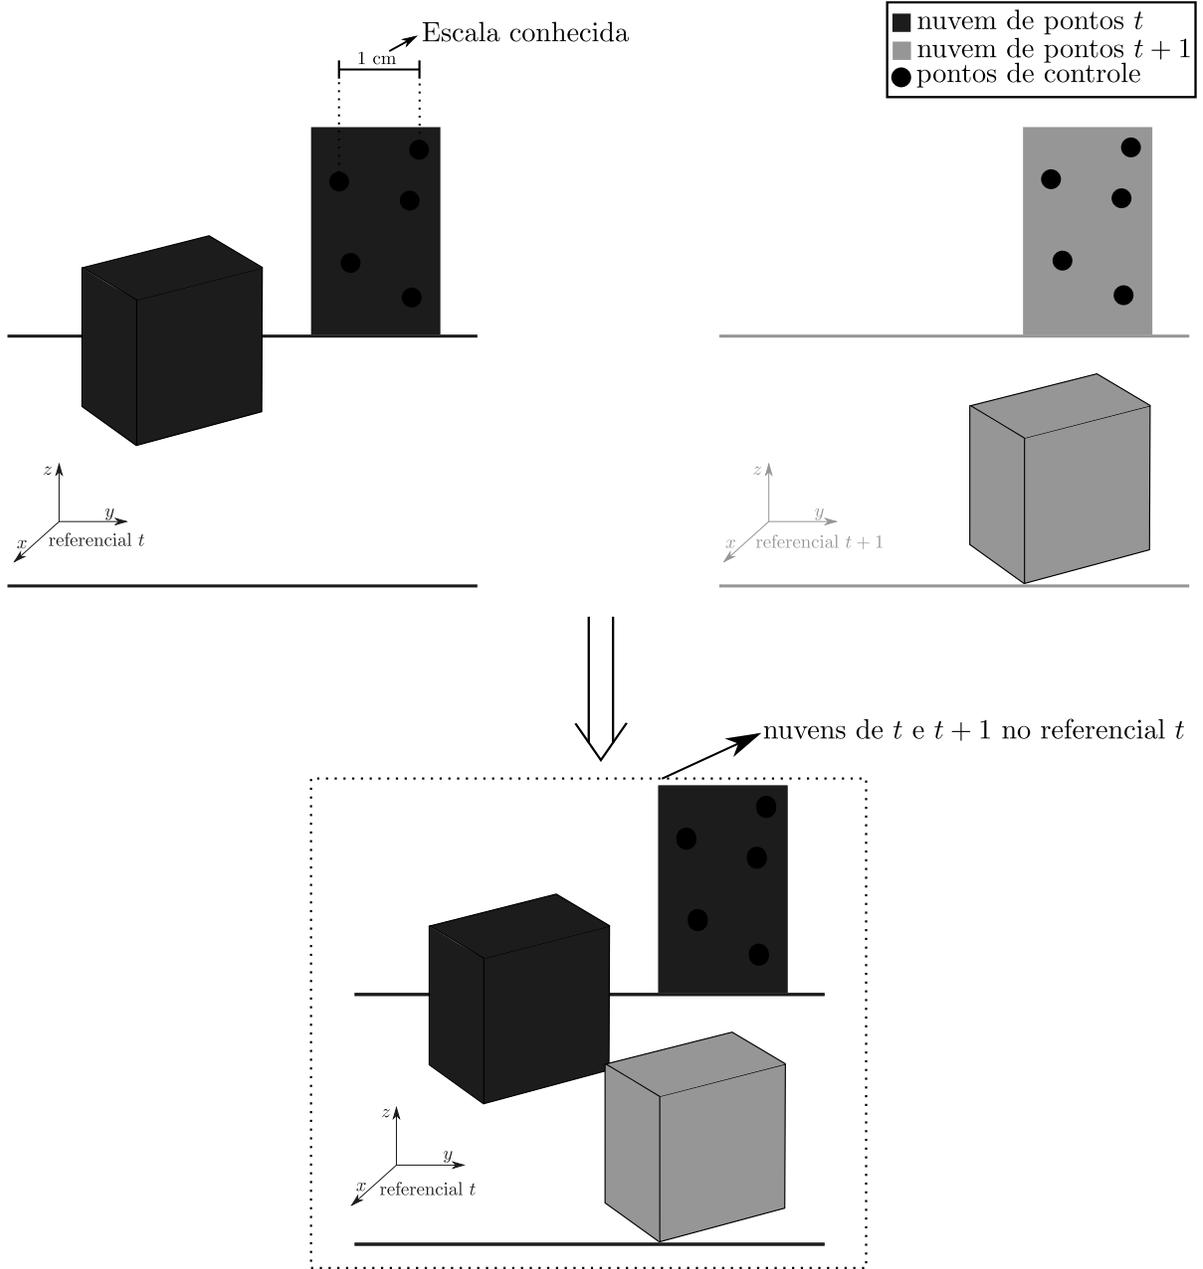
literatura, como por exemplo: ICP (BESL; MCKAY, 1992), HGMR (ECKART; KIM; KAUTZ, 2018), DUGMA (PU *et al.*, 2018) e GOGMA (CAMPBELL; PETERSSON, 2016).

Entretanto, uma maneira simples e eficaz para realizar o registro é a utilização de pontos de controle. Esses pontos são regiões que existem nas duas nuvens capturadas, com posições conhecidas ou georreferenciadas. Dessa forma, é possível tanto registrar as nuvens quanto colocá-las na escala correta. A Figura 22 ilustra o processo de registro utilizando pontos de controle.

#### 4.2.2 Pareando câmeras vizinhas

Cada imagem dos conjuntos  $O^t$  e  $O^{t+1}$  possui uma posição,  $\mathbf{c}$ , e rotação de câmera,  $\mathbf{R}$ . O objetivo dessa etapa é encontrar para a imagem  $\mathbf{I}_k^t \in O^t$  uma imagem  $\mathbf{I}_{h_k}^{t+1} \in O^{t+1}$  que possui o ângulo de visão mais próximo de  $\mathbf{I}_k^t$ . Para realizar essa tarefa, procuram-se três imagens de  $O^{t+1}$  que possuam a menor distância de câmera e menor diferença de rotação, i.e, procuram-se três imagens com o menor erro conjunto, definido na equação 4.5

Figura 22 – Processo de registro de nuvem de pontos utilizando pontos de controle.



Fonte – Elaborada pelo autor (2020).

(LIN, 2013).

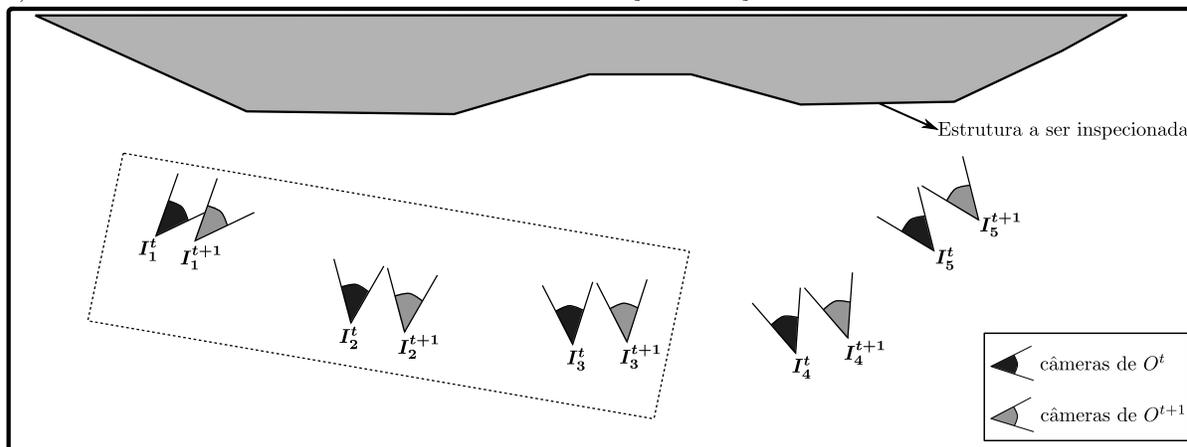
$$e(\mathbf{I}_k^t, \mathbf{I}_{h_k}^{t+1}) = \frac{\|\mathbf{c}_k^{t+1} - \mathbf{c}_k^t\|}{\|\mathbf{c}_k^t\|} + \cos^{-1} \left( \frac{\text{traço}(\mathbf{R}_k^t \mathbf{R}_{h_k}^{t+1}) - 1}{2} \right) \quad (4.5)$$

Em seguida, são calculados os pontos de interesse e os descritores da imagem  $\mathbf{I}_k^t$  e das três imagens candidatas. Finalmente, escolhe-se como par de  $\mathbf{I}_k^t$ , a imagem que possuir a maior quantidade de correspondência de descritores com ela. Dessa forma, o conjunto de pares de imagens  $W = \{(\mathbf{I}_1^t, \mathbf{I}_{h_1}^{t+1}), (\mathbf{I}_2^t, \mathbf{I}_{h_2}^{t+1}), \dots, (\mathbf{I}_l^t, \mathbf{I}_{h_l}^t), \dots, (\mathbf{I}_l^t, \mathbf{I}_{h_{l+1}}^t)\}$  é formado.

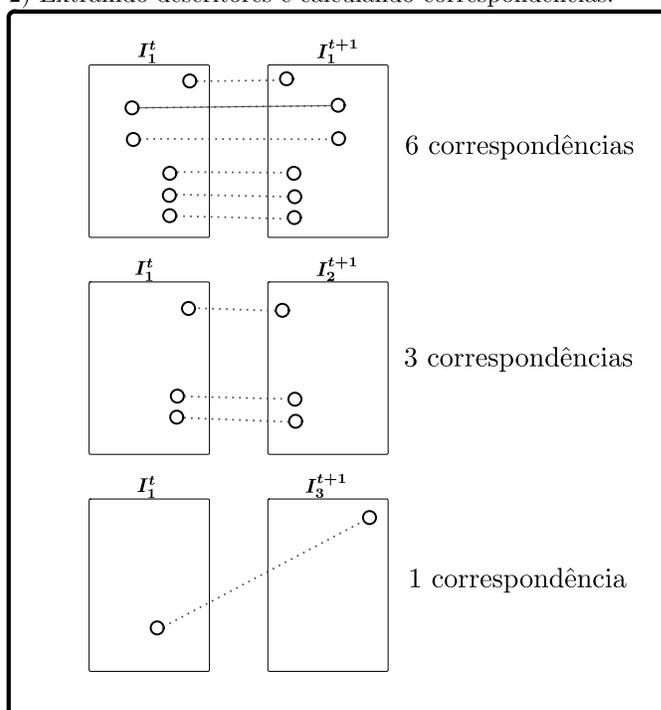
A Figura 23 mostra o processo de pareamento de câmeras.

Figura 23 – Encontrando o par da câmera 1 do conjunto  $O^t$ .

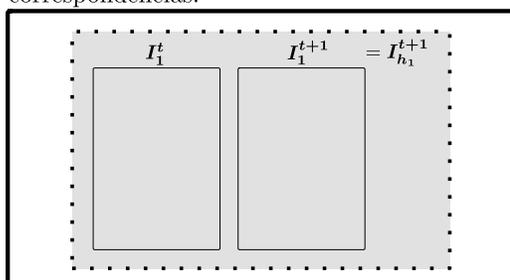
1) Escolher três câmeras com os menores erros de translação e rotação.



2) Extraindo descritores e calculando correspondências.



3) Escolhendo par com o maior número de correspondências.



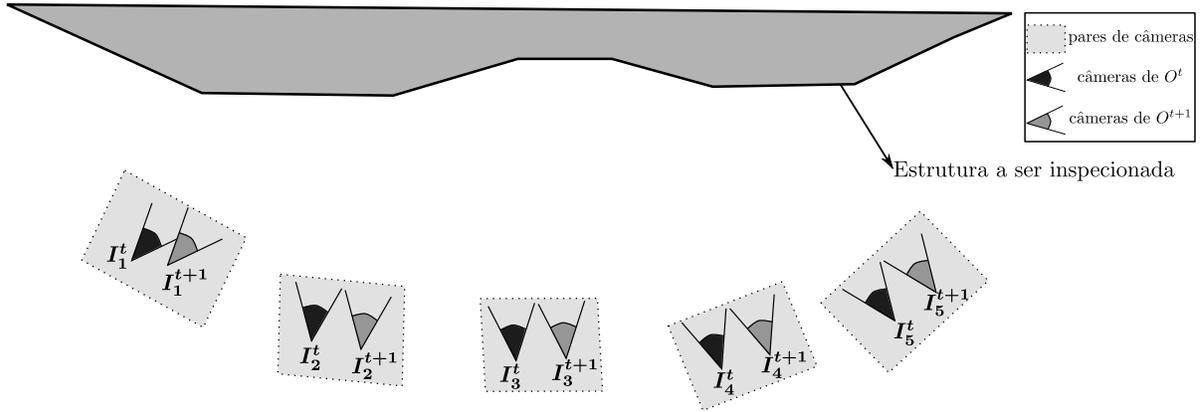
Fonte – Elaborada pelo autor (2020).

O pareamento é realizado para todas as imagens do conjunto  $O^t$ . A Figura 24 ilustra a disposição dos pares de câmeras após o processo de pareamento ter finalizado.

#### 4.2.3 Projeção 3D $\rightarrow$ 2D

O ponto  $p_i^t$  é projetado em todas as imagens de  $O^t$  utilizando a equação (3.8). Entretanto, a condição *backface culling* também deve ser respeitada. Essa condição

Figura 24 – Disposição das câmeras e seus respectivos pares.



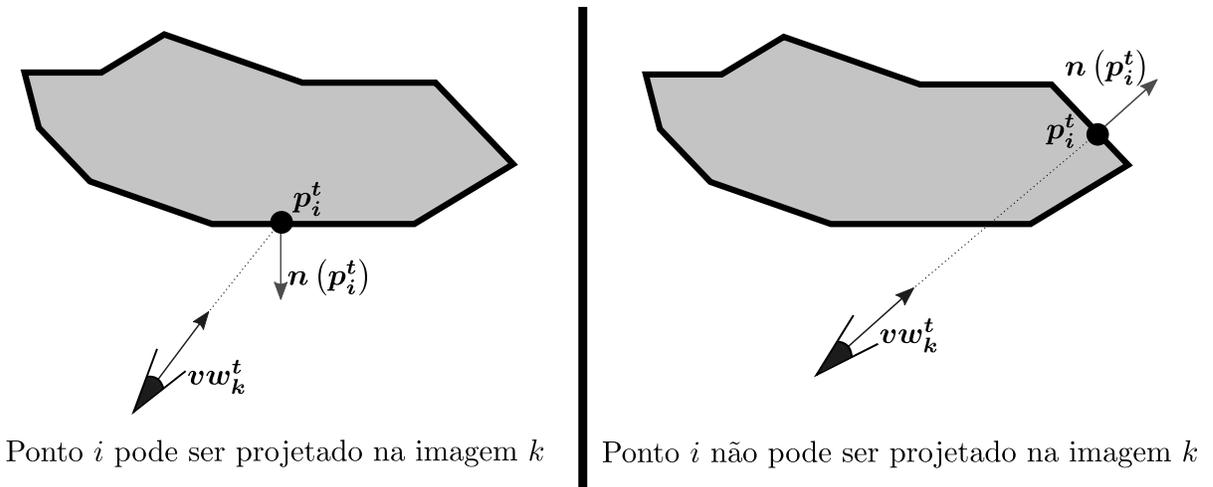
Fonte – Elaborada pelo autor (2020).

estabelece um ângulo máximo entre o vetor visão de uma câmera ( $\mathbf{vw}$ ) e o vetor normal de um ponto tridimensional ( $\mathbf{n}(\mathbf{p})$ ). Assim, para que o  $i$ -ésimo ponto tridimensional da nuvem de pontos  $N^t$  possa ser projetado na  $k$ -ésima imagem de  $O^t$ , a condição descrita na (4.6) deve ser respeitada.

$$\mathbf{n}(\mathbf{p}_i^t) \cdot (-\mathbf{vw}_k^t) < \cos(\theta) \quad (4.6)$$

A Figura 25 ilustra a importância da utilização da condição *backface culling* para evitar projeções 3D  $\rightarrow$  2D incorretas.

Figura 25 – Condição *backface culling* para projeção de pontos tridimensionais em uma imagem.



Ponto  $i$  pode ser projetado na imagem  $k$

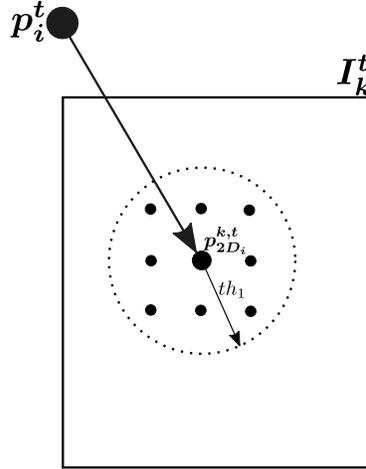
Ponto  $i$  não pode ser projetado na imagem  $k$

Fonte – Elaborada pelo autor (2020).

Assim, denota-se por  $\mathbf{p}_{2d_i}^{k,t}$  a projeção do  $i$ -ésimo ponto tridimensional de  $N^t$  na

$k$ -ésima imagem de  $O^t$ . Em seguida, armazena-se todos os pontos bidimensionais que estejam a um raio de  $th_1$  do ponto  $\mathbf{p}_{2d_i}^{k,t}$ . Denota-se por  $\mathbf{v}_u^{i,k,t}$  o  $u$ -ésimo vizinho de  $\mathbf{p}_{2d_i}^{k,t}$  a um distância de até  $th_1$ . A Figura 26 mostra o processo de projeção e seleção dos pontos vizinhos.

Figura 26 – Projeção de um ponto tridimensional em uma imagem com seus respectivos pontos vizinhos.



Fonte – Elaborada pelo autor (2020).

#### 4.2.4 Correspondências 2D $\leftrightarrow$ 2D

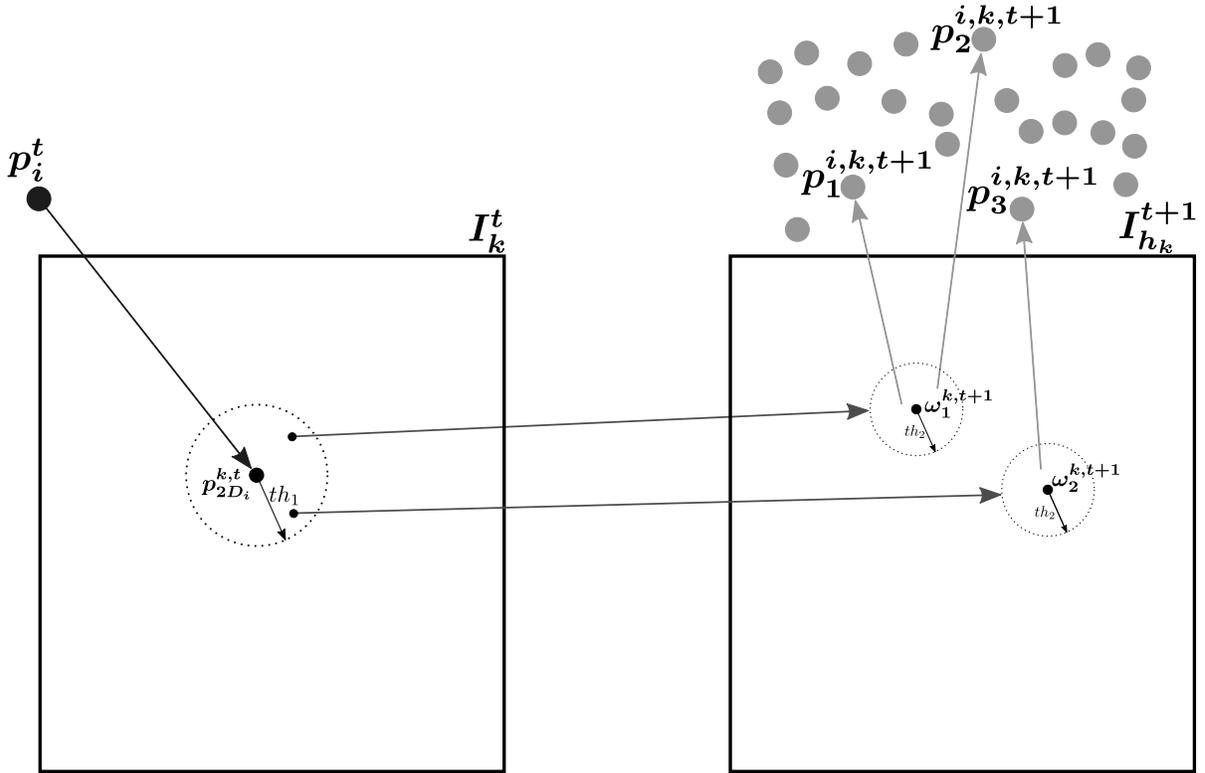
Após projetar o ponto  $\mathbf{p}_i^t$  na  $k$ -ésima imagem de  $O^t$ , a imagem par de  $\mathbf{I}_k^t, \mathbf{I}_{h_k}^{t+1}$ , do conjunto  $W$  é selecionada. Em seguida, é realizada a extração de descritores para o par  $(\mathbf{I}_k^t, \mathbf{I}_{h_k}^{t+1})$ . Nessa etapa, é recomendado a utilização de descritores densos, e.g., DAISY (TOLA; LEPETIT; FUA, 2009) e UCN (CHOY *et al.*, 2016), para obter um maior número de correspondências entre imagens. Posteriormente, é realizado a correspondência entre os descritores do par de imagem selecionado. Seguidamente, é recomendado a utilização de alguma técnica para filtragem de falsas correspondências, e.g., LMR (MA *et al.*, 2019) e LFGC (YI *et al.*, 2018). Finalmente, na imagem  $\mathbf{I}_{h_k}^{t+1}$ , procuram-se correspondências dos pontos  $\mathbf{v}_u^{i,k,t}$ . Esses são denominados por  $\omega_u^{i,h_k,th_1,t+1}$ .

#### 4.2.5 Correspondências 2D $\leftrightarrow$ 3D

Em seguida, seleciona-se pontos tridimensionais  $\mathbf{p}_j^{t+1}$  da nuvem  $N^{t+1}$  cujas projeções na imagem  $\mathbf{I}_{h_k}^{t+1}$  estejam dentro de um raio de  $th_2$  em torno dos pontos  $\omega_u^{i,h_k,th_1,t+1}$ . Denota-se por  $\mathbf{f}_g^{i,h_k,th_2,t+1}$  o  $g$ -ésimo ponto tridimensional de  $N^{t+1}$  cuja projeção na imagem  $h_k$  de  $O^{t+1}$  está até uma distância  $th_2$  dos pontos  $\omega_u^{i,h_k,th_1,t+1}$ . O vetor  $\mathbf{d}_g^{i,k,t} = \mathbf{f}_g^{i,h_k,th_2,t+1} - \mathbf{p}_i^t$  é calculado para todo  $g$ . A mediana desses vetores, denominada por  $\mathbf{d}_i^{k,t}$ , será o vetor deslocamento de  $\mathbf{p}_i^t$  calculada pela  $k$ -ésima imagem de  $O^t$ . A mediana dos

vetores  $\{\mathbf{d}_i^1, \mathbf{d}_i^2, \dots, \mathbf{d}_i^{L^t}\}$ , denominada por  $\mathbf{d}_i^t$ , é o vetor deslocamento do ponto  $\mathbf{p}_i^t$ . Para diminuir o espaço de procura dos pontos  $\mathbf{p}_j^{t+1}$ , com objetivo de reduzir a complexidade computacional, é possível limitar o raio de procura para pontos que estejam até uma distância máxima  $d_{max}$  do ponto  $\mathbf{p}_i^t$ . A Figura 27 mostra o processo de cálculo de correspondência para o ponto  $\mathbf{p}_i^t$  a partir da  $k$ -ésima imagem de  $O^t$ .

Figura 27 – Cálculo de correspondência para o  $i$ -ésimo ponto tridimensional de  $N^t$  utilizando a  $k$ -ésima imagem de  $O^t$  e seu respectivo par.



Fonte – Elaborada pelo autor (2020).

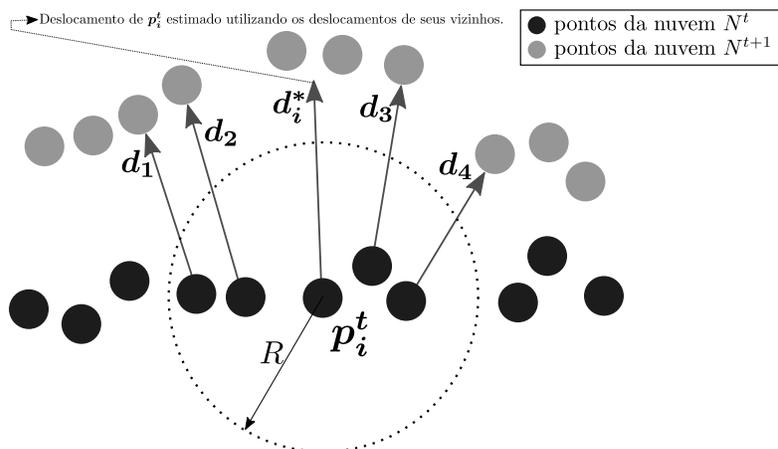
#### 4.2.6 Pontos sem correspondência (opcional)

É possível que a projeção do ponto  $\mathbf{p}_i^t$  nas imagens de  $O^t$  não possua correspondências nas imagens obtidas em  $t + 1$ . Nesse caso, o ponto  $\mathbf{p}_i^t$  não possuirá um vetor deslocamento  $\mathbf{d}_i$ . Para designar um deslocamento para  $\mathbf{p}_i^t$ , pode-se utilizar a mediana ou média dos vetores deslocamentos dos pontos vizinhos à uma distância  $R$  de  $\mathbf{p}_i^t$ . Essa etapa é opcional, sendo desnecessária quando a quantidade de correspondências tridimensionais for alta. A Figura 28 ilustra esse processo.

#### 4.2.7 M3C2 (opcional)

Os vetores deslocamentos  $\mathbf{d}_i$  podem ser utilizados como vetores normais dos pontos da nuvem  $N^t$ . Dessa forma, é possível utilizar essas normais no lugar das normais estimadas

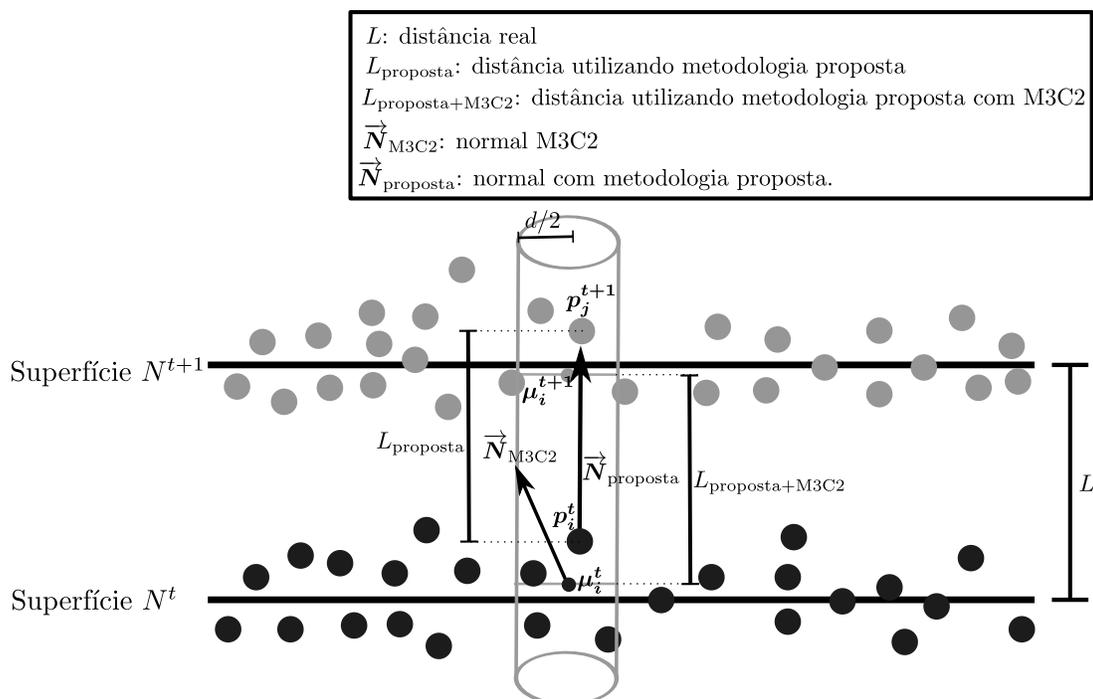
Figura 28 – Assinalando deslocamento para um ponto utilizando a média/mediana dos vetores deslocamentos dos pontos vizinhos.



Fonte – Elaborada pelo autor (2020).

pelo método M3C3 e, em seguida, utiliza-se o restante da metodologia do M3C2. Essa combinação de técnicas adiciona ao método proposto a capacidade do M3C2 de dar significância estatística às suas medidas. Entretanto, esse passo é facultativo. A Figura 29 ilustra a utilização conjunta da metodologia proposta e do M3C2.

Figura 29 – Utilização conjunta do método proposto e a técnica M3C2.



Fonte – Elaborada pelo autor (2020).

## 5 RESULTADOS E DISCUSSÃO

Neste capítulo, será apresentado um experimento utilizando a metodologia simplificada para cálculo de deformações e quatro experimentos utilizando a metodologia generalizada. Além disso, a metodologia generalizada será comparada com a técnica M3C2, considerada, atualmente, o estado da arte na estimativa de deformações em nuvens de pontos.

O método simplificado foi implementado em MATLAB. O método generalizado, por outro lado, teve parte da sua implementação feita em Python e outra parte em MATLAB. Na primeira, foram realizados os processos de pareamento de imagens, extração de características, correspondência de descritores visuais e correspondência de pontos tridimensionais. Na segunda, foram geradas as figuras dos vetores e histogramas de deslocamento. Para aplicar a técnica M3C2, foi utilizado o *software* CloudCompare (GIRARDEAU-MONTAUT, 2016). Ademais, as reconstruções tridimensionais das estruturas de interesse foram realizadas no *softwares* VisualSFM (WU *et al.*, 2011) e COLMAP (SCHÖNBERGER; FRAHM, 2016; SCHÖNBERGER *et al.*, 2016).

Para a aplicação da técnica DCVRP, foi necessário a escolha dos parâmetros  $th_1$  e  $th_2$ . Essa escolha foi empírica e baseou-se na maximização de correspondências tridimensionais. Dessa forma, escolheu-se  $th_1 = th_2 = 1$  px. Além disso, também foi escolhido o parâmetro  $\theta = 60$  da condição *backface culling*, assim como foi feito em (LIN, 2013).

Ademais, para o método DCVRP, os descritores UCN foram escolhidos para esse trabalho devido ao seu alto nível de acurácia (CHOY *et al.*, 2016). É importante mencionar que não foi feito um re-treinamento da rede UCN, foram utilizados os pesos pré-treinados, conforme descrito em (CHOY *et al.*, 2016). Outra vantagem da UCN é a possibilidade da geração de descritores densos. Esses permitem uma maior quantidade de correspondências entre imagens e, dessa forma, mais correspondências entre pontos tridimensionais. Portanto, esse descritor foi utilizado para tornar o método proposto mais robusto e com maior quantidade de pontos com deslocamentos conhecidos. Contudo, vale ressaltar que qualquer outro descritor visual poderia ser utilizado.

Como os descritores densos demandam um grande esforço computacional, especialmente para imagens de altas resoluções, as imagens utilizadas nas reconstruções foram reduzidas para o tamanho 640 x 480 px para a realização da extração dos descritores. Entretanto, a mudança na resolução da imagem modifica os parâmetros  $f_x$  e  $f_y$  da matriz de calibração. Se, por exemplo, a largura e a altura da imagem ficassem  $V_x$  e  $V_y$  menores, os novos valores de  $f_x$  e  $f_y$  seriam  $f_x/V_x$  e  $f_y/V_y$ .

Além disso, como a quantidade de correspondência entre pontos tridimensionais da nuvem capturada em  $t$  com pontos da nuvem de  $t+1$  foi alta, o passo 4.6 do método proposto

não foi implementado. Esse passo é recomendado para situações onde a quantidade de correspondências é pequena e/ou esparsa.

## 5.1 EXPERIMENTO 1 - BARRA DE ALUMÍNIO

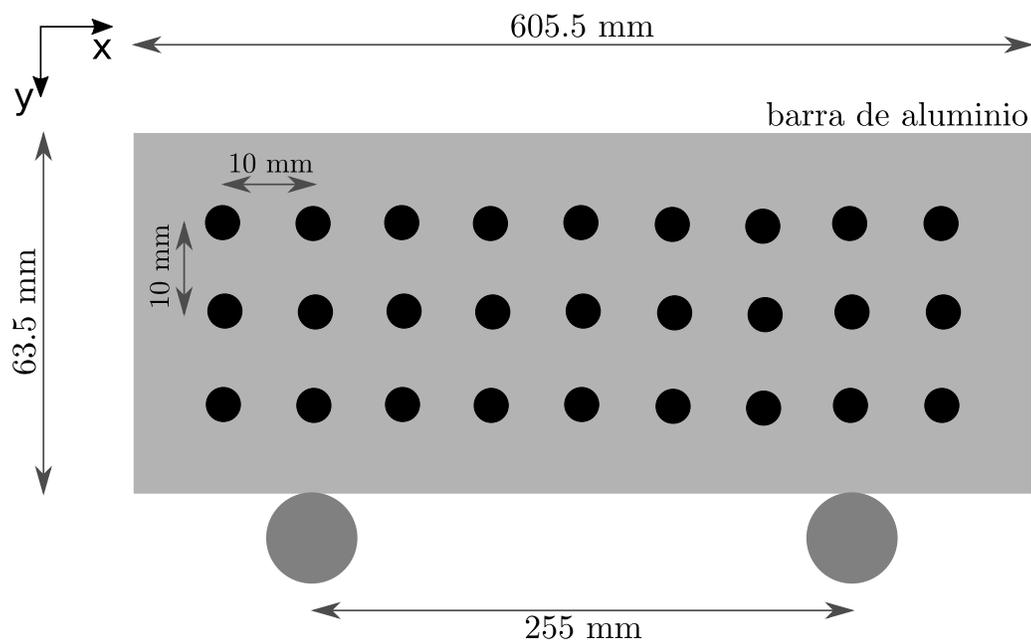
Neste experimento, a metodologia simplificada foi aplicada em uma barra de alumínio com tamanho e características conhecidas.

### 5.1.1 Configuração do experimento

Uma barra de alumínio de 605.5 mm de comprimento, 18.9 mm de largura e 63.5 mm de altura foi submetida a uma força externa nesse experimento. A barra foi colocada entre dois apoios espaçados em 255 mm. Além disso, foi pintado um *grid* de círculos pretos, onde a distância de círculos adjacentes é de 10 mm. Para monitorar o deslocamento dos círculos, uma câmera foi posicionada em frente a barra. A captura das imagens foi feita por vídeo com aquisição de 30 quadros por segundo com resolução de 1920 x 1080 px. Para a configuração desse experimento, os deslocamentos horizontais esperados para a barra são muito pequenos e a resolução da câmera utilizada é limitada. Assim, apenas os deslocamentos verticais puderam ser capturados através da metodologia simplificada.

A Figura 30 mostra a configuração do experimento proposto.

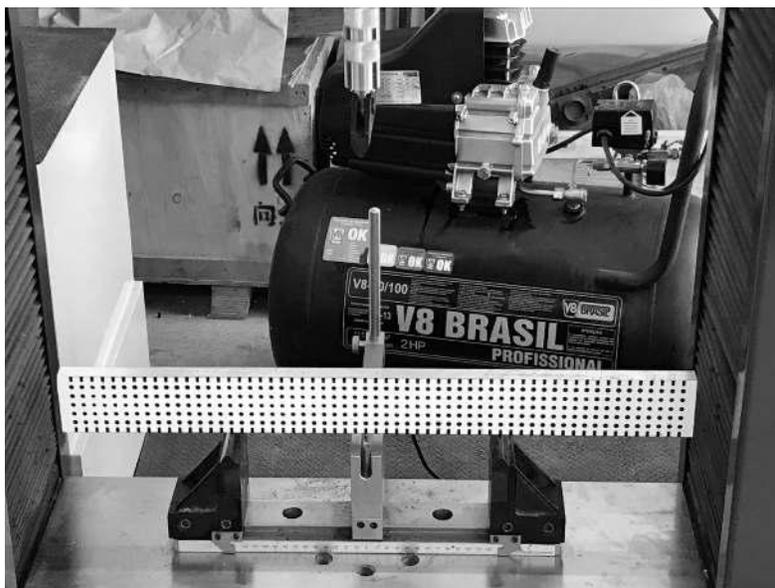
Figura 30 – Configuração do experimento 1.



Fonte – Elaborada pelo autor (2020).

O experimento foi realizado no laboratório de mecânica do Instituto Federal de Minas Gerais (IFMG) em Ouro Branco, Minas Gerais. A Figura 31 mostra uma imagem do experimento realizado.

Figura 31 – Experimento realizado no laboratório de mecânica do IFMG de Ouro Branco.

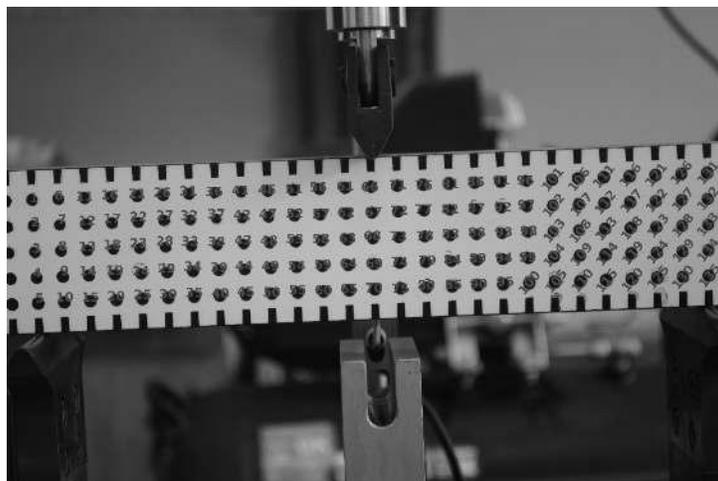


Fonte – Elaborada pelo autor (2020).

### 5.1.2 Aplicação do método simplificado proposto

Para monitorar os deslocamentos dos círculos pretos, uma câmera foi colocada em frente a barra do experimento. Além disso, para referência, os círculos foram numerados de 1 a 135, conforme mostrado na Figura 32.

Figura 32 – Numeração dos círculos monitorados pela metodologia simplificada proposta.

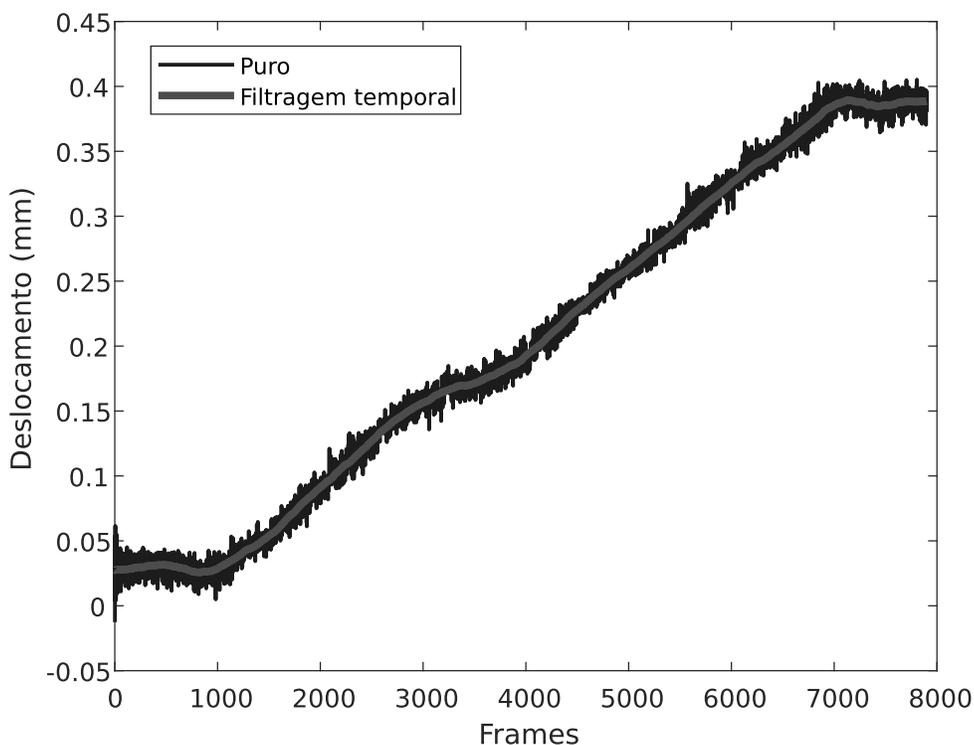


Fonte – Elaborada pelo autor (2020).

Para obter um *ground truth*, uma equipe de pesquisa de engenharia civil da Universidade Federal de Ouro Preto (UFOP) simulou quais as deformações esperadas para uma barra de alumínio com as mesmas especificações da barra utilizada e sob as mesmas condições do experimento. Os resultados obtidos pela metodologia simplificada proposta foram comparados com as simulações.

Como foi mencionado anteriormente, pequenas variações de iluminação podem prejudicar o cálculo das posições dos círculos ao longo do tempo. Para mitigar esse problema, os filtros espaciais e temporais foram implementados conjuntamente. No Gráfico 3, é possível observar os deslocamentos verticais calculados para o círculo 69 ao longo do tempo. Além disso, também é possível verificar o ruído presente nesse deslocamento e como a aplicação do filtro temporal ameniza esse efeito. Nesse experimento, foi utilizado um filtro média móvel com janela de 300 quadros.

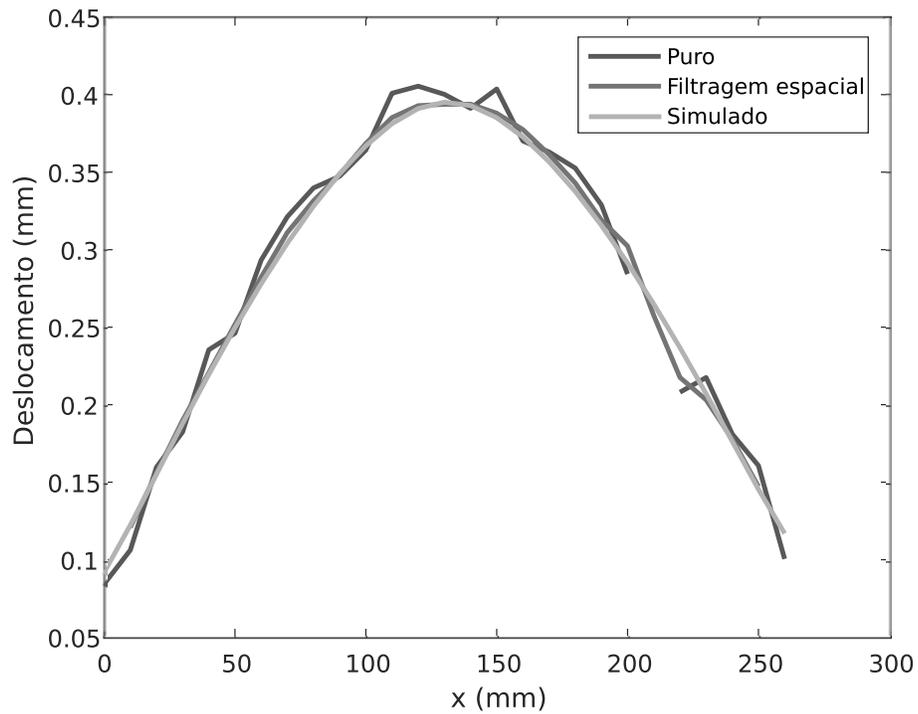
Gráfico 3 – Deslocamento vertical do círculo 69 ao longo do tempo.



Fonte – Elaborado pelo autor (2020).

O Gráfico 4 mostra o deslocamentos verticais da terceira linha de círculos da barra de alumínio no fim do experimento, quando a força aplicada era máxima. Além disso, também é mostrado esse deslocamento após a aplicação da filtragem espacial. É possível observar que a filtragem suaviza os deslocamentos ocorridos ao longo da linha. O filtro espacial utilizado aplicou um *kernel* uniforme com  $n_v = 1$ .

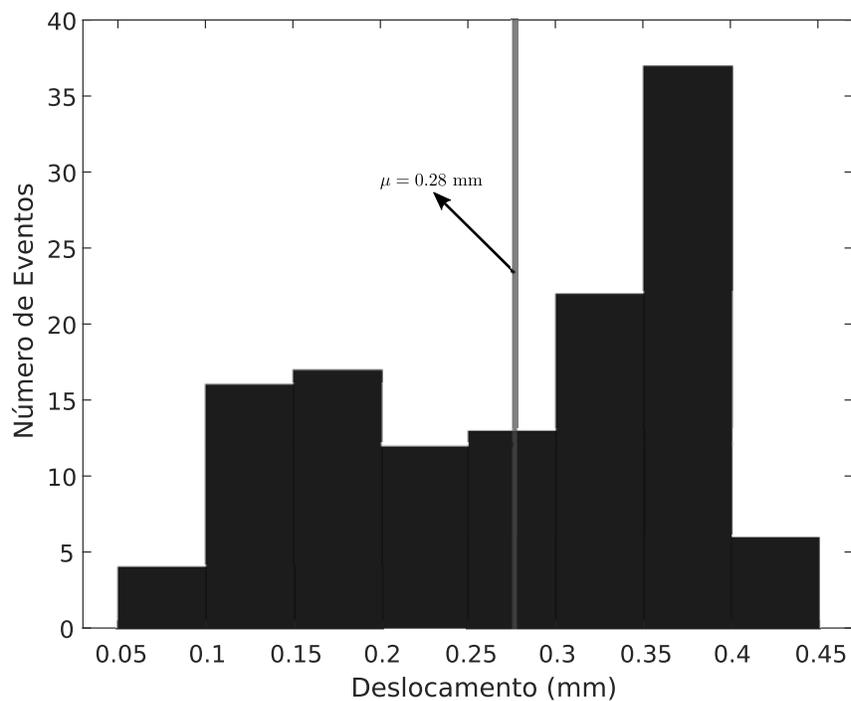
Gráfico 4 – Deslocamento vertical da terceira linha de círculos.



Fonte – Elaborado pelo autor (2020).

O Gráfico 5 mostra o histograma dos deslocamentos encontrados para a barra de alumínio nesse experimento.

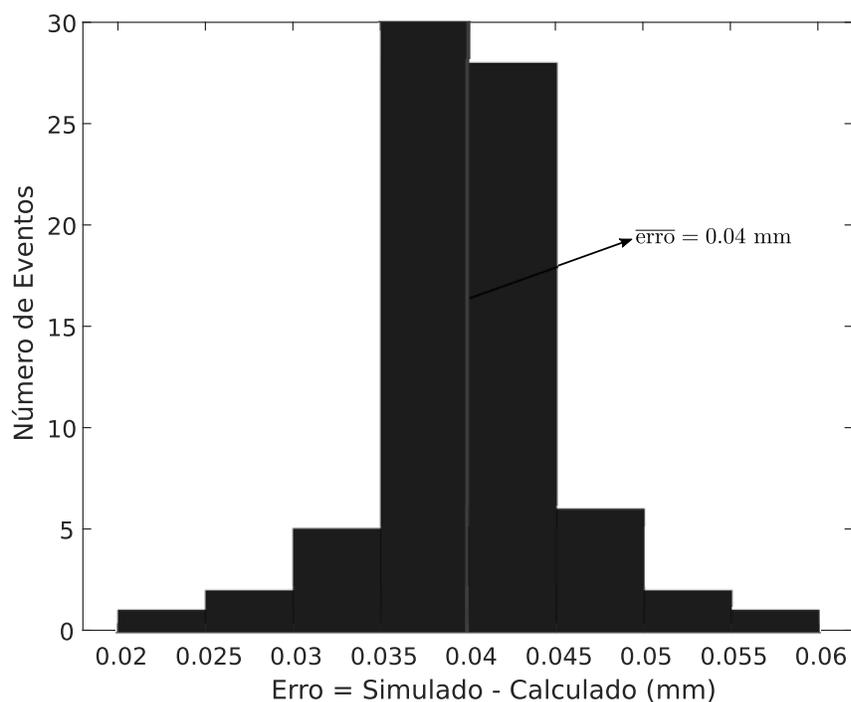
Gráfico 5 – Histograma dos deslocamentos calculados pelo método simplificado proposto para a barra de alumínio.



Fonte – Elaborado pelo autor (2020).

Para avaliar a capacidade do método, também foi construído um histograma das diferenças entre os deslocamentos simulados e os deslocamentos calculados pelo método simplificado proposto. Esse histograma está disposto no Gráfico 6. É importante notar que alguns círculos não foram detectados pela metodologia proposta. Isso é devido, principalmente, à falta de qualidade na pintura desses círculos. Dessa forma, eles não foram considerados no cálculo dos erros.

Gráfico 6 – Histograma dos erros entre os valores simulados e os calculados para os círculos da barra de alumínio.



Fonte – Elaborado pelo autor (2020).

É possível observar que o erro médio dos deslocamentos verticais obtidos foi de 0.04 mm. Esse erro pode ser explicado pela plastificação que ocorreu na região dos apoios da barra durante o experimento. Esse efeito não foi considerado nas simulações. A Figura 33 mostra o efeito de plastificação que ocorreu na barra em um dos apoios.

Figura 33 – Plastificação da barra de alumínio nas proximidades de um dos apoios.



Fonte – Elaborada pelo autor (2020).

Através dos valores deslocamentos encontrados nesse experimento, a equipe da UFOP também conseguiu simular a distribuição dos deslocamentos ao longo de toda face da barra de alumínio. As Figuras 34a e 34b mostram a distribuição dos deslocamentos em milímetros utilizando os deslocamentos simulados e os deslocamentos encontrados pela metodologia simplificada, respectivamente. Nessa figura, é possível verificar uma grande semelhança entre essas duas distribuições de deslocamento. Dessa forma, a técnica proposta, além de fornecer medidas com erro médio pequeno, também proporciona uma distribuição de deslocamento concordante com o resultado teórico simulado.

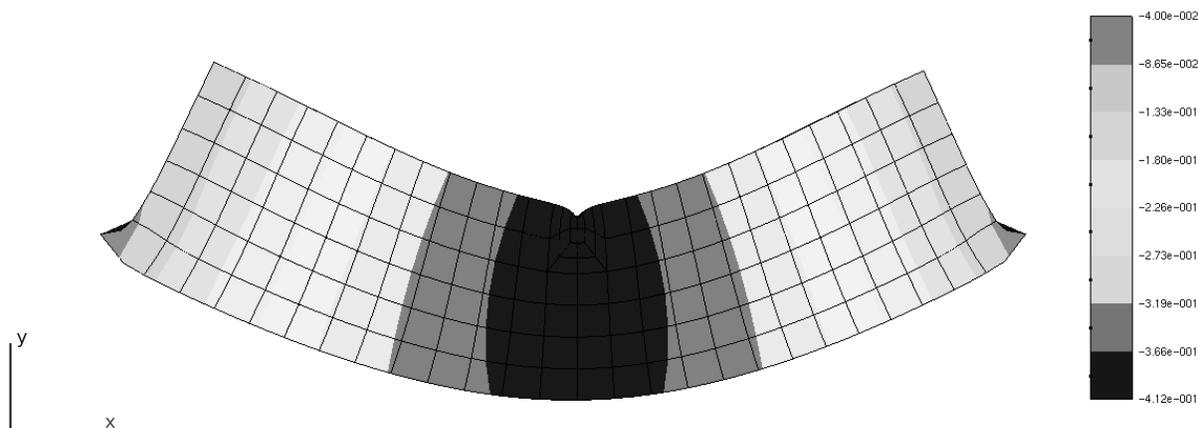
Os resultados obtidos nesse experimento foram a motivação para tornar a metodologia simplificada mais genérica, ou seja, para englobar deformações em todas as direções.

## 5.2 EXPERIMENTO 2 - CAIXA

Este experimento tem como objetivo comparar a metodologia DCVRP e a técnica M3C2 com relação a avaliação da direção correta de um deslocamento. Para tal, movimentou-se uma caixa para uma direção diferente da direção da sua normal.

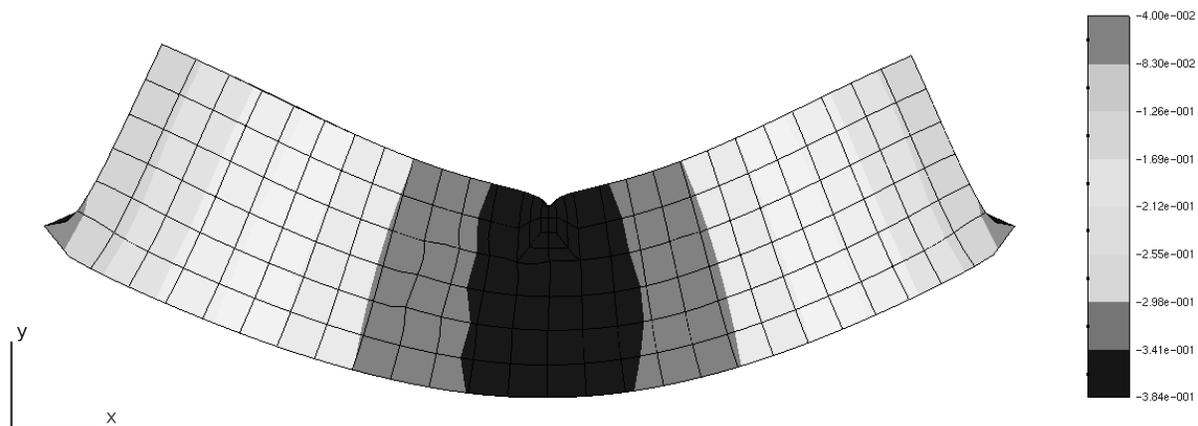
Figura 34 – Distribuição dos deslocamentos ao longo da face da barra de alumínio.

(a) Distribuição utilizando os deslocamentos simulados.



Fonte Elaborada pelo autor (2020).

(b) Distribuição utilizando os deslocamentos calculados pela metodologia simplificada.



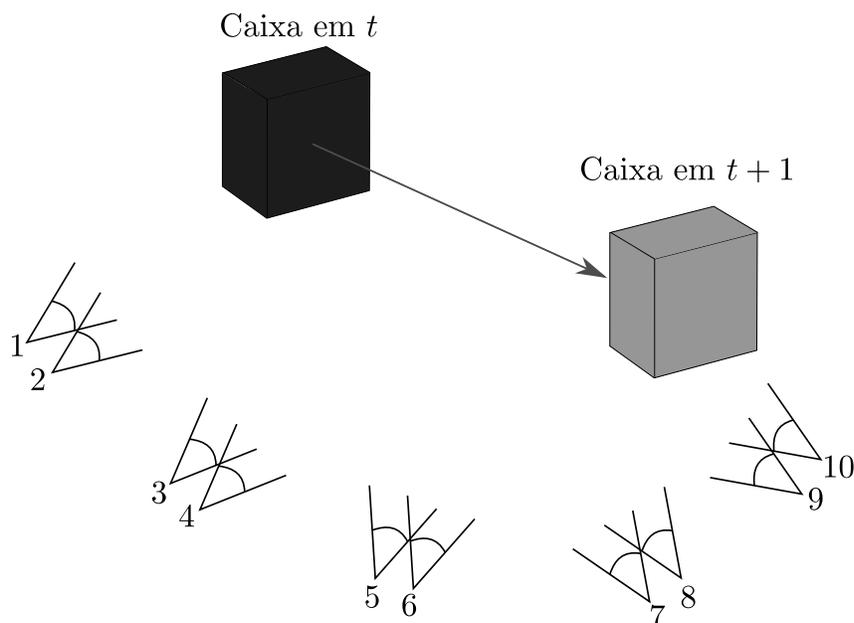
Fonte Elaborada pelo autor (2020).

### 5.2.1 Configuração do experimento

Nesse experimento, colocou-se uma caixa encostada em uma parede no tempo  $t$ . Em seguida, um conjunto de imagens foi capturado em posições predeterminadas. Posteriormente, no tempo  $t + 1$ , a caixa foi movida em uma direção que não fosse a mesma da sua normal. Finalmente, um outro conjunto de imagens foi capturado utilizando aproximadamente as mesmas posições usadas anteriormente. A Figura 35 ilustra a configuração do experimento proposto. Nessa figura, é possível verificar que o movimento executado pela caixa foi realizado em uma direção diferente de sua normal. Além disso, nesse experimento, foram utilizadas 10 imagens tanto no tempo  $t$  quanto no tempo  $t + 1$ .

A Figura 36 exibe as imagens reais do experimento realizado. Na Figura 36(a), mostra-se a posição da caixa no tempo  $t$  e a Figura 36(b) expõe o posicionamento da caixa no tempo  $t + 1$ .

Figura 35 – Configuração do experimento 2.



Fonte – Elaborada pelo autor (2020).

### 5.2.2 Reconstrução tridimensional

Os conjuntos de imagens capturadas foram utilizadas para realizar a reconstrução tridimensional das cenas usando o *software* VisualSFM. Foram utilizadas 10 imagens com resolução de 3648 x 2736 px para a reconstrução da cena no tempo  $t$ . Para o tempo  $t + 1$ , também foram utilizadas 10 imagens, capturadas nas mesmas posições, porém a resolução das imagens era de 7296 x 5472 px.

As Figuras 37 e 38 mostram as reconstruções obtidas para os tempos  $t$  e  $t + 1$ , respectivamente. Nessas figuras, é possível observar que a reconstrução de  $t + 1$  possui uma densidade de pontos muito superior à reconstrução de  $t$ . Isso se deveu a maior resolução das imagens utilizadas para gerar a reconstrução de  $t + 1$ .

### 5.2.3 Registro de Nuvens

Para realizar o registro das nuvens obtidas em  $t$  e  $t + 1$ , i.e., colocar as nuvens no mesmo referencial, quatro pontos que eram comuns as duas nuvens foram manualmente escolhidos. Em seguida, com auxílio do *software* CloudCompare e sua função de registro de nuvens, as duas nuvens de pontos foram registradas. Foram escolhidos pontos comuns que, a priori, sabia-se que não sofreriam deformações entre o tempo  $t$  e  $t + 1$ . Entretanto, é importante notar que como o registro foi feito de forma manual, dessa forma, erros de registro podem ter sido gerados.

A Figura 39 ilustra o processo de escolha dos pontos em comum. Os pontos em

Figura 36 – Experimento 2 para os tempos  $t$  e  $t + 1$ .

(a) Experimento 1 em  $t$ .



Fonte Elaborada pelo autor (2020).

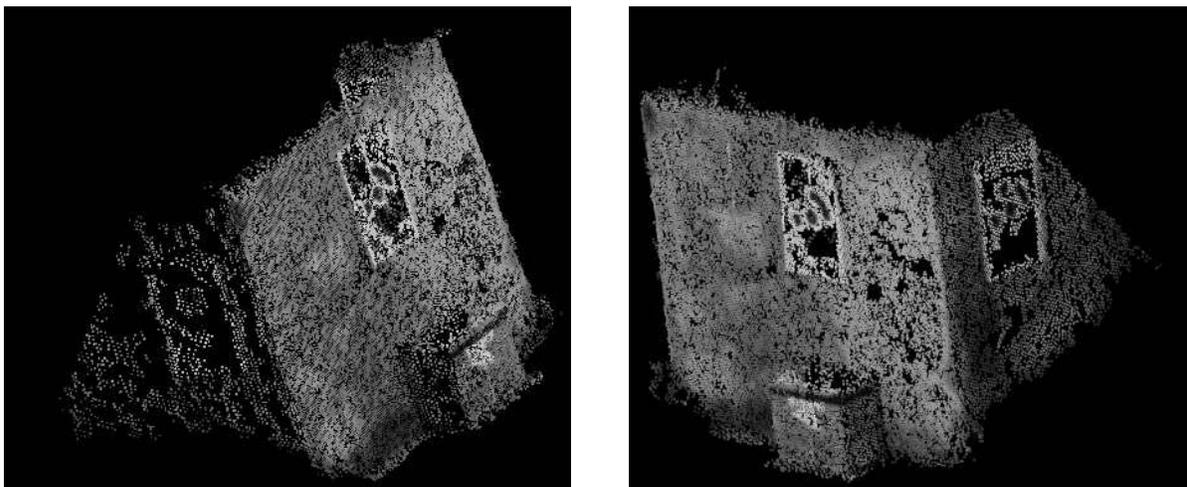
(b) Experimento 2 em  $t + 1$ .



Fonte Elaborada pelo autor (2020).

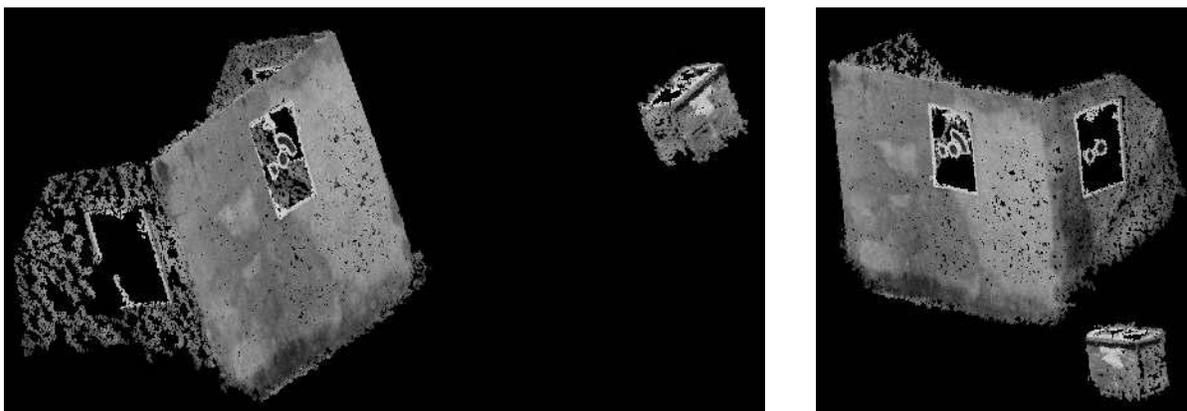
vermelho e verde são referentes as nuvens dos tempos  $t$  e  $t + 1$ , respectivamente.

Figura 37 – Reconstrução tridimensional em  $t$  para o experimento 2.



Fonte – Elaborada pelo autor (2020).

Figura 38 – Reconstrução tridimensional em  $t + 1$  para o experimento 2.



Fonte – Elaborada pelo autor (2020).

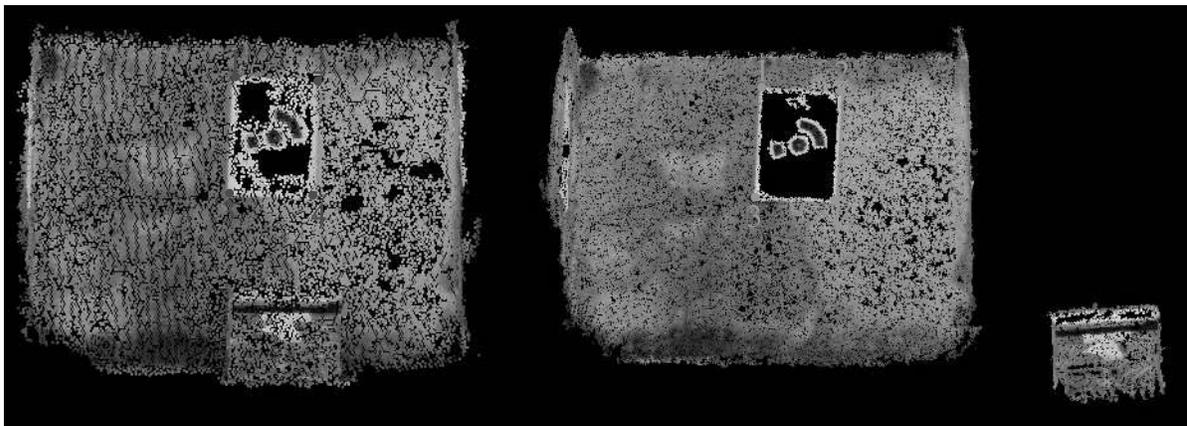
#### 5.2.4 Aplicação da técnica M3C2

A Figura 40 ilustra a aplicação da técnica M3C2. Os pontos brancos na região próxima da caixa indicam que nenhum deslocamento foi estimado para essa região. Isso ocorreu pois o deslocamento efetuado não foi normal à superfície. Dessa forma, o algoritmo do M3C2, ao verificar que não existem pontos na direção normal à superfície, indica uma indeterminação de deslocamento para aquela região.

#### 5.2.5 Aplicação do método DCVRP

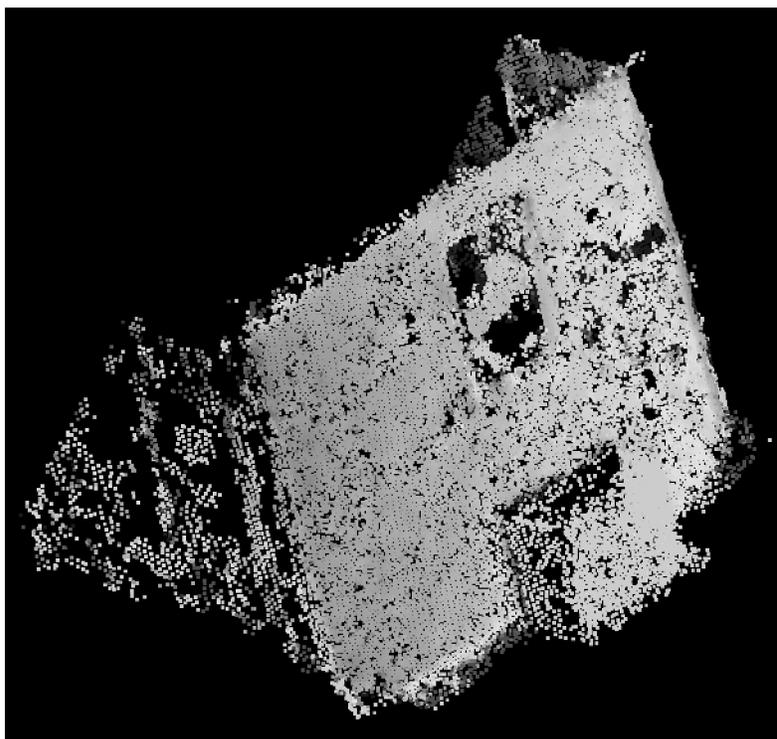
A Figura 41 mostra os vetores de deslocamento gerados após a aplicação do método DCVRP. Para facilitar a visualização, apenas alguns vetores de deslocamento foram utilizados. Nessa figura, é possível verificar que os vetores de deslocamento seguem corretamente

Figura 39 – Processo de registro entre a reconstrução de  $t$  com a reconstrução de  $t + 1$  para o experimento 2.



Fonte – Elaborada pelo autor (2020).

Figura 40 – Resultado visual do algoritmo M3C2 para o experimento 2.

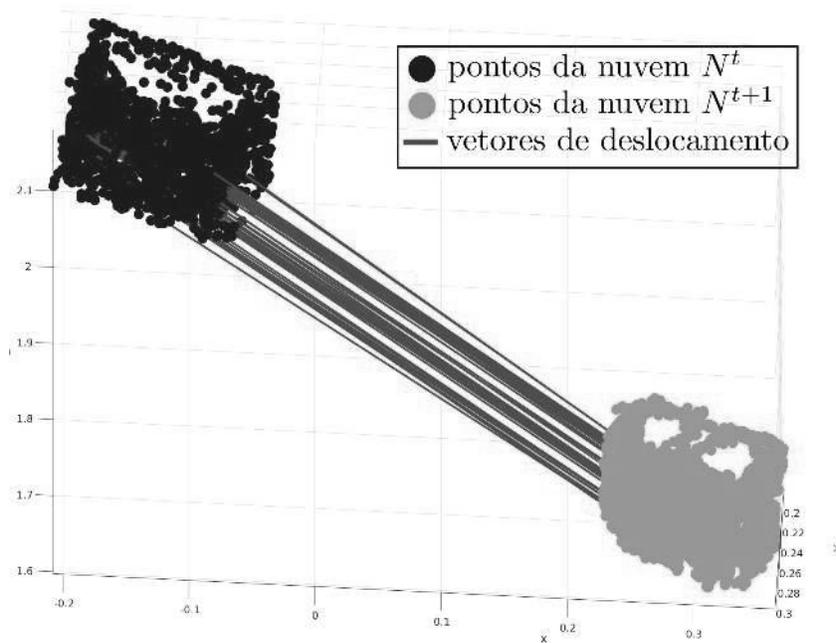


Fonte – Elaborada pelo autor (2020).

o sentido de movimentação realizado pela caixa, mostrando, dessa forma, a eficiência do método proposto em um caso que o M3C2 não é capaz de atuar satisfatoriamente.

Assim, esse experimento demonstrou a incapacidade do M3C2 ao lidar com deslocamentos que não sejam normais à superfície. Ao mesmo tempo, o método proposto é capaz de gerar vetores de deslocamento condizentes com o deslocamento real. Entretanto, nesse

Figura 41 – Vetores de deslocamento gerados pelo método DCVRP para o experimento 2.



Fonte – Elaborada pelo autor (2020).

experimento, a movimentação foi realizada de forma exagerada. O próximo experimento, por outro lado, se propõe a simular deslocamentos mais próximos da realidade.

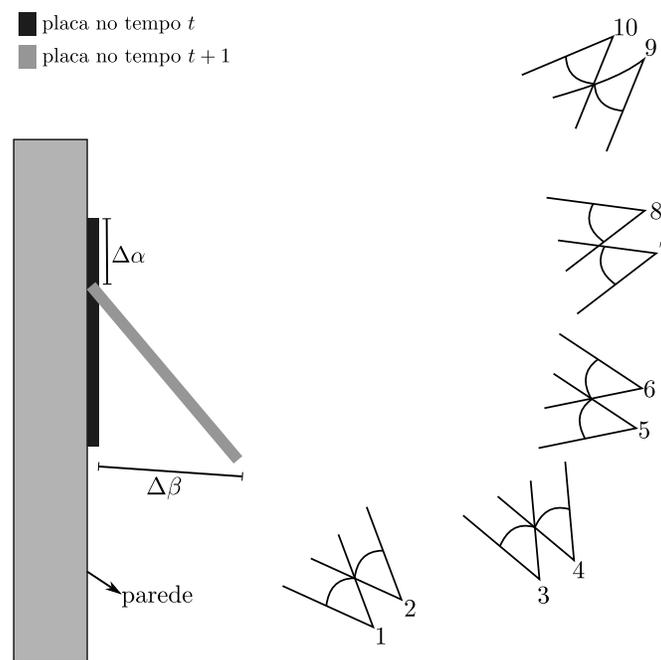
### 5.3 EXPERIMENTO 3 - PLACA (DESLOCAMENTO NORMAL E VERTICAL)

Este experimento, assim como o experimento anterior, tem como objetivo verificar a capacidade das técnicas M3C2 e DCVRP para a detecção da direção correta de deslocamentos efetuados. Entretanto, diferentemente do experimento anterior, o deslocamento foi em uma escala menor (alguns milímetros) e projetado para ser uma composição de um movimento vertical com um movimento normal à superfície do objetivo deslocado.

#### 5.3.1 Configuração do experimento

Nesse experimento, uma placa foi disposta em uma parede no tempo  $t$ . Um conjunto de imagens foi obtido para essa posição. Em seguida, três apoios de 9 mm cada um foram colocados na base na placa para simular um deslocamento normal à superfície da parede. Porém, com a adição dos apoios, a placa sofreu um pequeno deslocamento vertical. Ademais, um novo conjunto de imagens foi capturado para essa nova posição. A Figura 42 mostra a configuração do experimento proposto.

Figura 42 – Configuração do experimento 3.



Fonte – Elaborada pelo autor (2020).

A Figura 43 mostra duas imagens obtidas na mesma posição. A imagem à esquerda foi obtida no tempo  $t$  e a imagem à direita foi obtida no tempo  $t + 1$ .

Figura 43 – Experimento 3 para os tempos  $t$  e  $t + 1$ .

(a) Experimento 3 em  $t$ .



(b) Experimento 3 em  $t + 1$ .

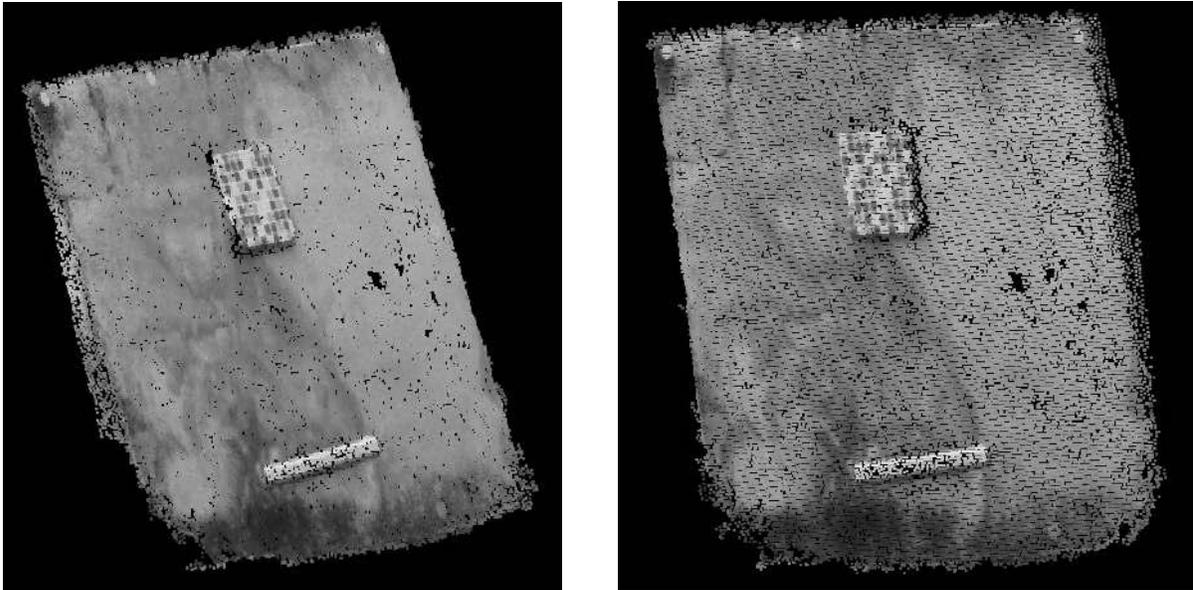


Fonte – Elaborada pelo autor (2020).

### 5.3.2 Reconstrução tridimensional

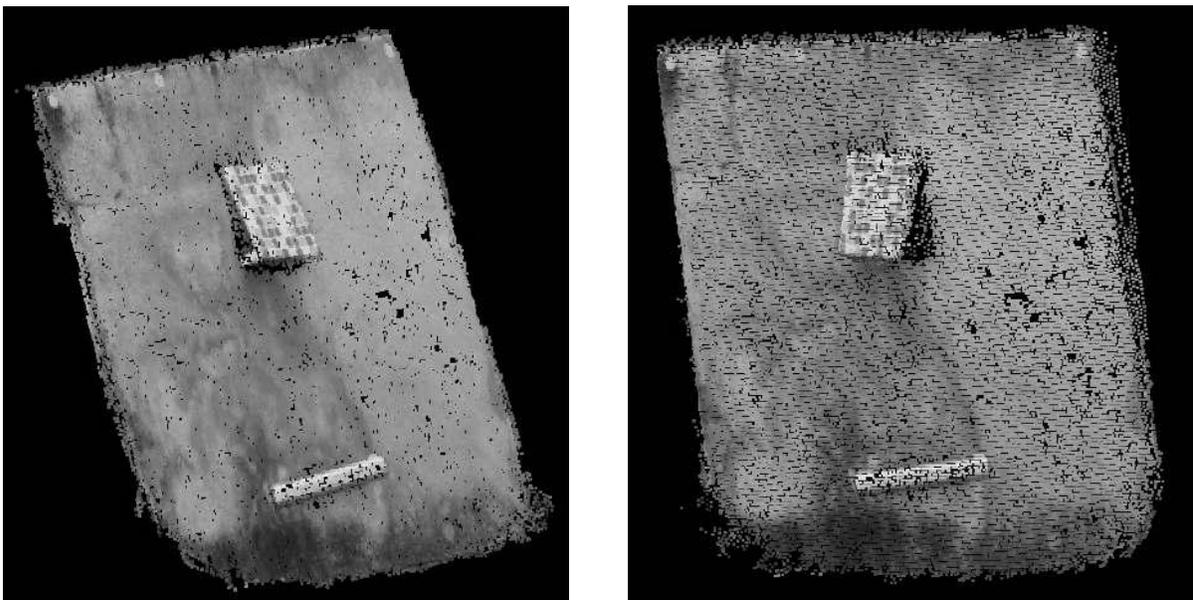
As reconstruções obtidas para os tempos  $t$  e  $t + 1$  estão dispostas nas Figuras 44 e 45, respectivamente. Para essas reconstruções, foram utilizadas 10 imagens com resolução de 4864 x 3648 px.

Figura 44 – Reconstrução tridimensional em  $t$  para o experimento 3.



Fonte – Elaborada pelo autor (2020).

Figura 45 – Reconstrução tridimensional em  $t + 1$  para o experimento 3.

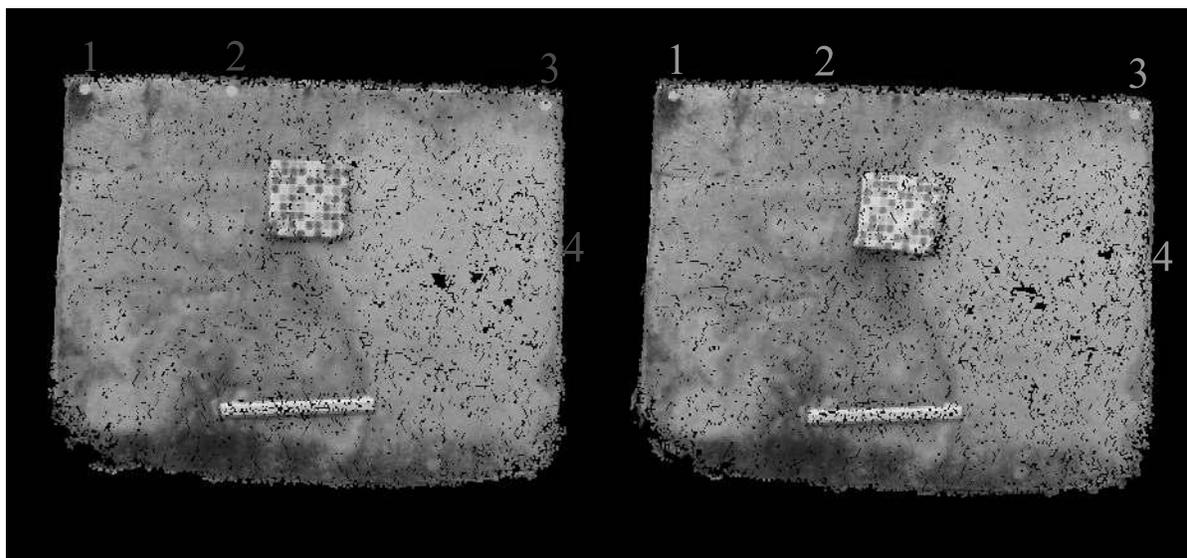


Fonte – Elaborada pelo autor (2020).

### 5.3.3 Registro de nuvens

Para registrar as nuvens obtidas nos tempos  $t$  e  $t + 1$ , foi utilizada a ferramenta de registro do CloudCompare que requer que quatro pontos correspondentes entre as duas nuvens sejam selecionados. A Figura 46 mostra os quatro pontos escolhidos para a reconstrução realizada no tempo  $t$  (vermelho) e para a reconstrução referente ao tempo  $t + 1$  (verde).

Figura 46 – Processo de registro entre a reconstrução de  $t$  com a reconstrução de  $t + 1$  para o experimento 3.



Fonte – Elaborada pelo autor (2020).

### 5.3.4 Aplicação da técnica M3C2

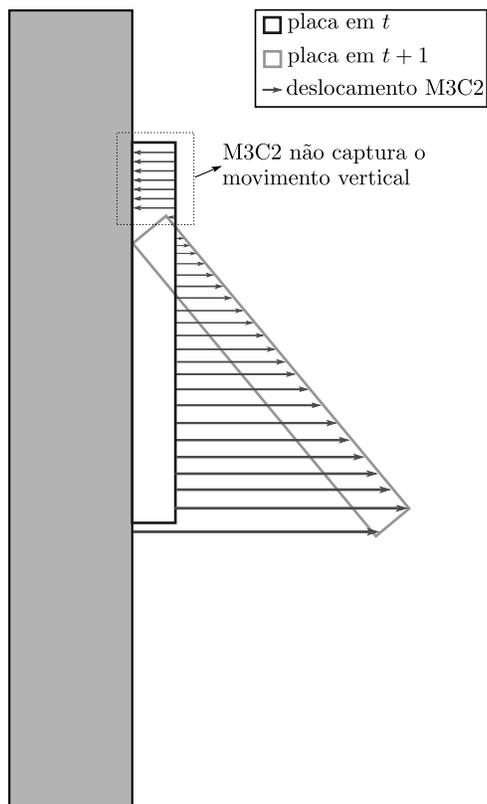
Nesse experimento, a placa realiza um movimento normal à superfície e um pequeno movimento vertical. Porém, como a técnica M3C2 detecta apenas movimentos na direção normal, o movimento vertical não é detectado. A Figura 47 mostra o comportamento esperado pela técnica M3C2. Nessa figura, é possível observar que o M3C2 não é capaz de verificar o deslocamento vertical. Além disso, ele atribui erroneamente um movimento normal na região onde a placa se deslocou verticalmente.

Na Figura 48, é mostrado o resultado encontrado ao aplicar a técnica M3C2. Os resultados encontrados confirmam o comportamento esperado do M3C2.

### 5.3.5 Aplicação do método DCVRP

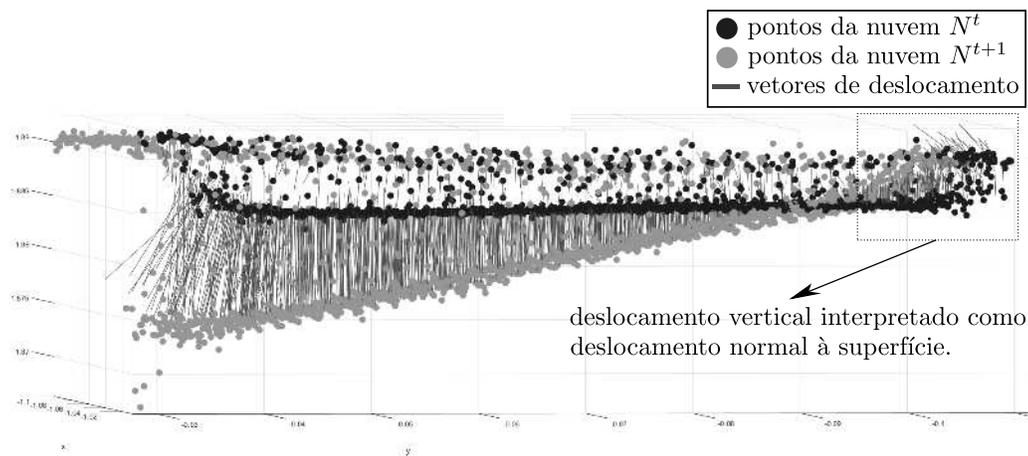
A Figura 49 mostra os vetores deslocamento obtidos utilizando o método DCVRP. Nessa figura, é possível observar que, diferentemente do M3C2, o método proposto gera

Figura 47 – Comportamento esperado pela técnica M3C2 para o experimento 3.



Fonte – Elaborada pelo autor (2020).

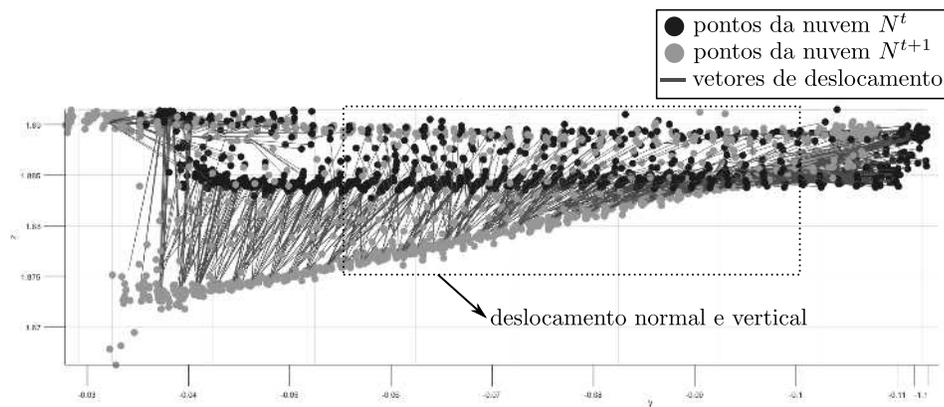
Figura 48 – Resultado visual do algoritmo M3C2 para o experimento 3.



Fonte – Elaborada pelo autor (2020).

vetores que representam tanto o deslocamento vertical quanto o deslocamento normal à superfície.

Figura 49 – Resultado gerado pelo método DCVRP para o experimento 3.



Fonte – Elaborada pelo autor (2020).

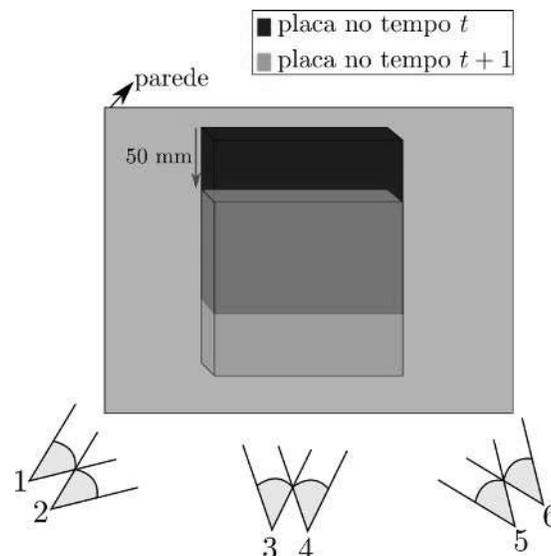
#### 5.4 EXPERIMENTO 4 - PLACA (DESLOCAMENTO VERTICAL)

Este experimento tem como objetivo comparar a capacidade de mensurar os deslocamentos ocorridos pelas técnicas M3C2 e DCVRP. Para tal, um objeto foi submetido a um deslocamento de valor conhecido.

##### 5.4.1 Configuração do experimento

Nesse experimento, uma placa foi colocada em uma parede, e uma sequência de imagens foi capturada nessa configuração (tempo  $t$ ). Em seguida, a placa foi submetida à um deslocamento vertical de 50 mm. Posteriormente, um outro conjunto de imagens foi capturado da nova posição da placa (tempo  $t + 1$ ). A Figura 50 mostra a configuração do experimento proposto.

Figura 50 – Configuração do experimento 4.



Fonte – Elaborada pelo autor (2020).

A Figura 51 mostra imagens reais do experimento proposto. Dessa forma, as Figuras 51(a) e 51(b) mostram as configurações antes e depois da placa sofrer um movimento vertical de 50 mm, respectivamente.

Figura 51 – Experimento 4 para os tempos  $t$  e  $t + 1$ .

(a) Experimento 4 em  $t$ .



(b) Experimento 4 em  $t + 1$ .

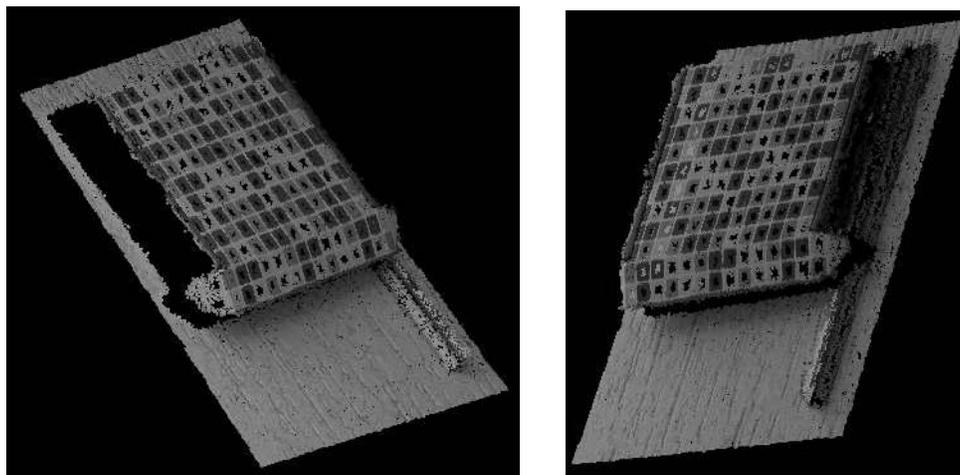


Fonte – Elaborada pelo autor (2020).

#### 5.4.2 Reconstrução tridimensional

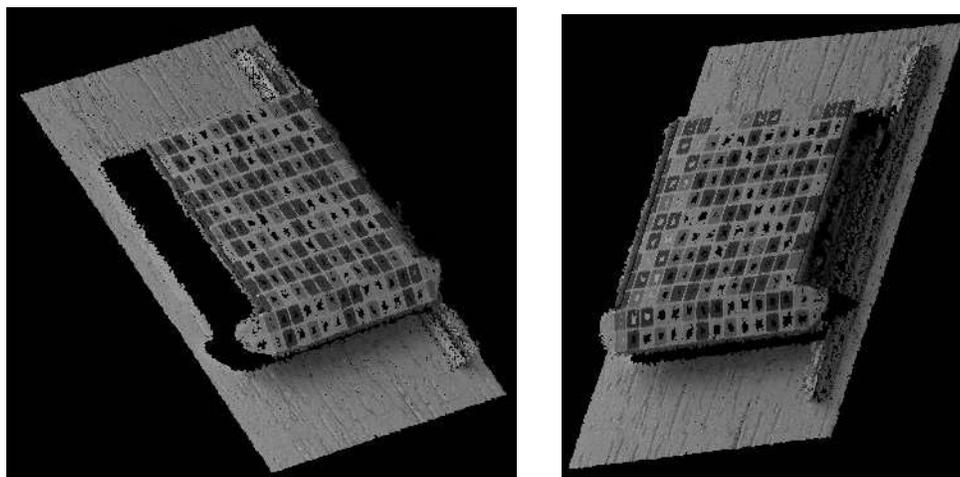
Para realizar as reconstruções das cenas dos tempos  $t$  e  $t + 1$ , foram utilizadas 6 imagens com resolução de 4864 x 3648 px. As Figuras 52 e 53 mostram as reconstruções para as cenas dos tempos  $t$  e  $t + 1$ , respectivamente.

Figura 52 – Reconstrução tridimensional em  $t$  para o experimento 4.



Fonte – Elaborada pelo autor (2020).

Figura 53 – Reconstrução tridimensional em  $t + 1$  para o experimento 4.



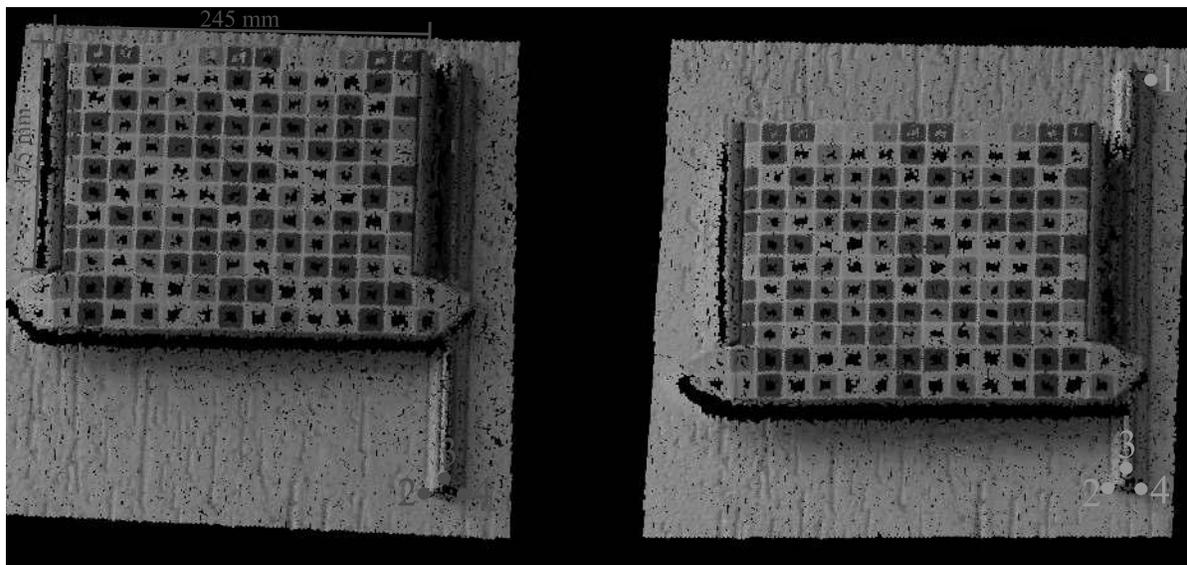
Fonte – Elaborada pelo autor (2020).

### 5.4.3 Registro de nuvens

Para o registro das nuvens, foram selecionados quatro pontos comuns entre as nuvens. Em seguida, foi utilizada a ferramenta de registro do CloudCompare em conjunto com o algoritmo ICP.

Além disso, como as dimensões da placa eram conhecidas (245 mm x 175 mm), essas medidas foram utilizadas para que as reconstruções estivessem na escala real, i.e., em milímetros. A Figura 54 ilustra o processo de registro nesse experimento.

Figura 54 – Processo de registro entre a reconstrução de  $t$  com a reconstrução de  $t + 1$  para o experimento 4.

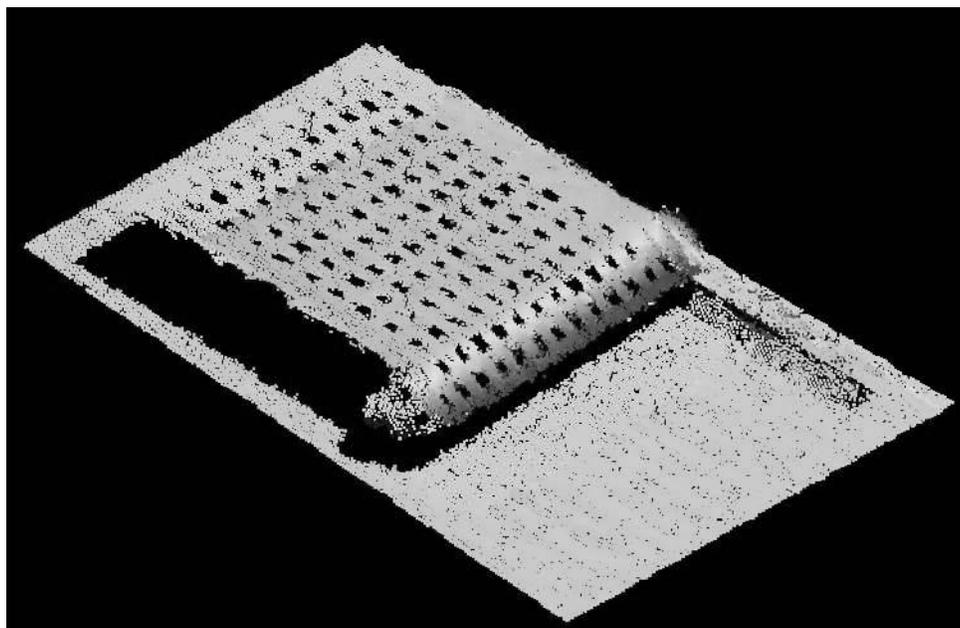


Fonte – Elaborada pelo autor (2020).

#### 5.4.4 Aplicação da técnica M3C2

Como o deslocamento efetuado pela placa não foi na sua direção normal, o M3C2 não foi capaz de estimar esse deslocamento. Isso pode ser visto na Figura 55, onde os pontos brancos indicam as regiões com deslocamento indeterminado.

Figura 55 – Resultado visual do algoritmo M3C2 para o experimento 4.

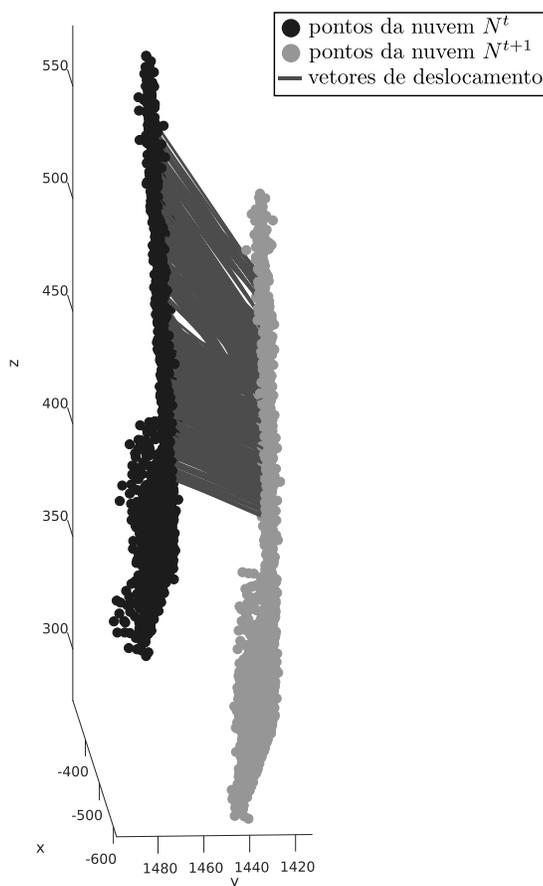


Fonte – Elaborada pelo autor (2020).

### 5.4.5 Aplicação do método DCVRP

A Figura 56 ilustra a aplicação do DCVRP no experimento proposto. Nessa figura, as nuvens de pontos foram espaçadas apenas com o objetivo de melhorar a visualização dos vetores deslocamento. Dessa forma, é possível verificar que o método proposto é capaz de gerar vetores deslocamento condizentes com o deslocamento efetuado.

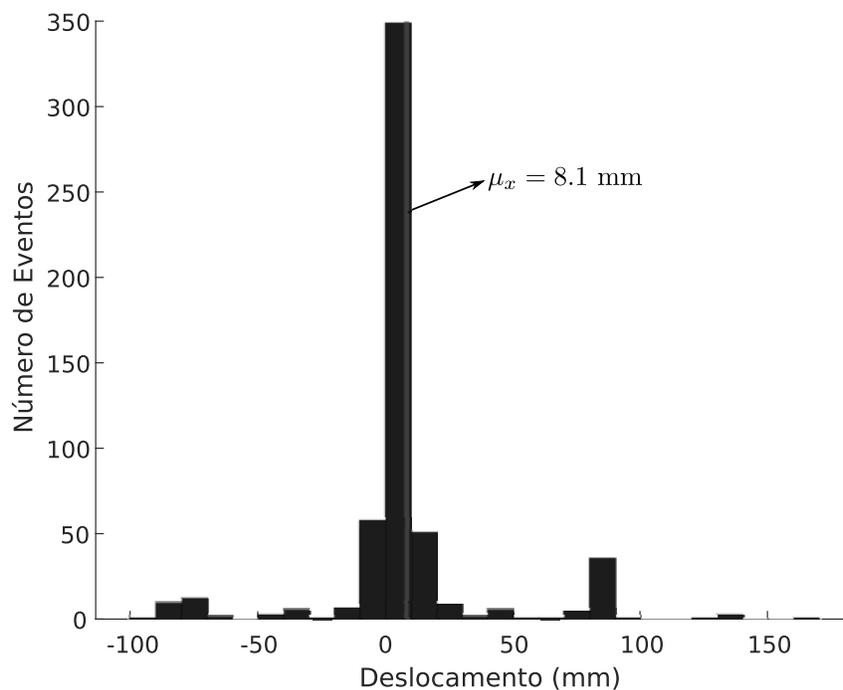
Figura 56 – Resultado gerado pelo método DCVRP para o experimento 4.



Fonte – Elaborada pelo autor (2020).

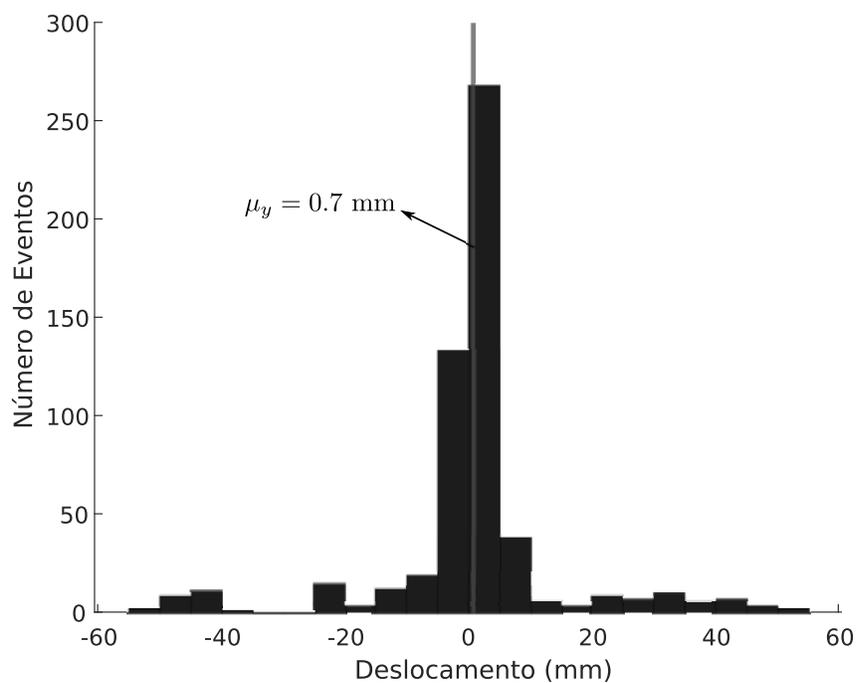
Para avaliar quantitativamente os deslocamentos obtidos, foram calculados os histogramas dos deslocamentos obtidos para as direções X, Y, Z. Esses histogramas podem ser vistos nos Gráficos 7, 8 e 9, respectivamente. A média dos deslocamentos em cada direção forma um vetor deslocamento final e o módulo desse vetor caracteriza a quantidade de deslocamento ocorrido na região considerada. Nesse experimento, a média dos deslocamentos em X, Y e Z foram  $\mu_x = 8.1$  mm,  $\mu_y = 0.7$  mm e  $\mu_z = -54$  mm, respectivamente. Dessa forma, o método proposto estima que a caixa moveu  $\sqrt{\mu_x^2 + \mu_y^2 + \mu_z^2} = 54.6$  mm, sendo que o deslocamento aplicado foi de 50 mm. É importante notar que o erro no deslocamento medido advém de uma combinação de fatores, como erro de registro, de escala e associação incorreta entre os pontos tridimensionais.

Gráfico 7 – Histograma dos deslocamentos gerados pelo método DCVRP para o experimento 4 na direção X.



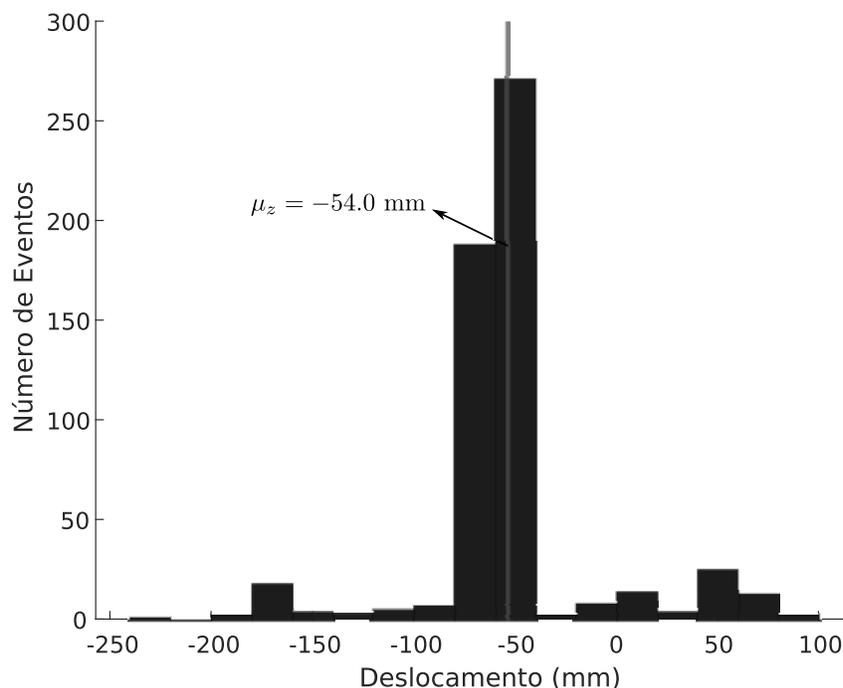
Fonte – Elaborado pelo autor (2020).

Gráfico 8 – Histograma dos deslocamentos gerados pelo método DCVRP para o experimento 4 na direção Y.



Fonte – Elaborado pelo autor (2020).

Gráfico 9 – Histograma dos deslocamentos gerados pelo método DCVRP para o experimento 4 na direção Z.



Fonte – Elaborado pelo autor (2020).

## 5.5 EXPERIMENTO 5 - TALUDE REAL

Este experimento foi desenvolvido de forma a submeter as técnicas M3C2 e DCVRP a um ambiente de monitoramento de uma estrutura de grande escala, nesse caso, um talude de rochas.

### 5.5.1 Configuração do experimento

Nesse experimento, foram feitas duas vistorias em um talude real localizado no estado de Santa Catarina. As vistorias foram feitas em um intervalo de dois meses. A primeira será denotada por vistoria do tempo  $t$  e a segunda como vistoria do tempo  $t + 1$ . A Figura 57 mostra umas das imagens utilizadas para a reconstrução do talude em uma das vistorias.

Diferentemente do que foi feito nos experimentos anteriores, não foram colocados pontos fixos nos taludes de forma a melhorar o registro entre as nuvens. Além disso, não existe um *ground truth* em relação ao deslocamento ocorrido no intervalo entre as vistorias. Dessa forma, devido a essas limitações, uma região do talude foi considerada estável e foram selecionados pontos nessa área para realizar o registro. Ademais, devido ao curto intervalo entre as vistorias, o deslocamento ocorrido foi considerado nulo. Além disso, por

Figura 57 – Imagem utilizada para reconstrução tridimensional do talude referente a vistoria do tempo  $t$ .



Fonte – Elaborada pelo autor.

questões de limitações computacionais, apenas uma pequena região do talude, com área de aproximadamente  $80 \text{ m}^2$ , foi analisada pela metodologia proposta e pela técnica M3C2.

### 5.5.2 Reconstrução tridimensional

Para reconstruir o talude nas duas vistorias, foram utilizadas 199 imagens com resolução de  $4864 \times 3648$  que foram capturadas por um veículo aéreo não tripulado. A Figura 58 mostra a reconstrução do talude em uma das vistorias efetuadas. Essa reconstrução foi realizada no *software* COLMAP que foi integrado ao *software* SM.A.R.T.3D. Esse último também foi capaz de recuperar a escala real das reconstruções tridimensionais usando as posições de GPS das imagens. A Figura 58 mostra a reconstrução tridimensional feita para a vistoria  $t$ .

### 5.5.3 Registro de nuvens

Como foi mencionado anteriormente, o talude utilizado nesse experimento não possui pontos com posições que sejam fixas entre vistorias para realizar o registro da nuvem de pontos obtida em  $t$  com a nuvem obtida em  $t + 1$ . Dessa forma, uma plataforma contida no talude foi considerada estável e foi utilizada para o registro das nuvens. A

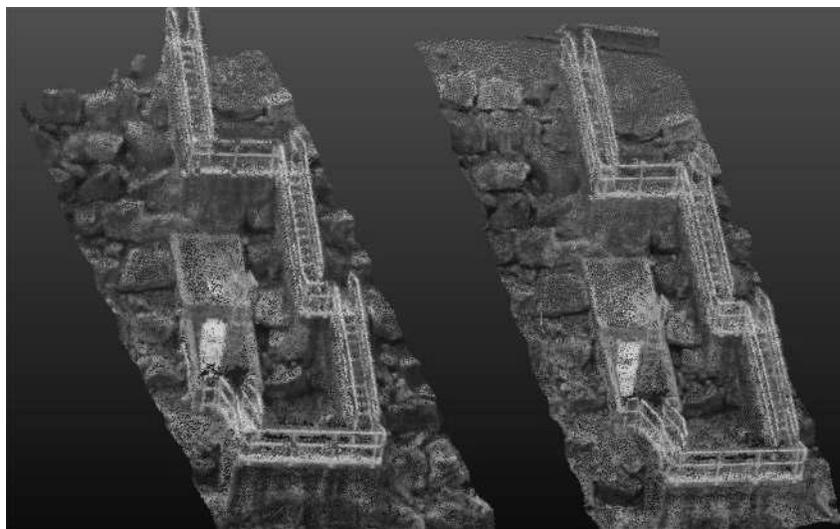
Figura 58 – Reconstrução tridimensional do talude referente a vistoria do tempo  $t$ .



Fonte – Elaborada pelo autor (2020).

Figura 59 ilustra o processo de escolha de pontos em comum entre as nuvens  $t$  e  $t + 1$ , onde os pontos vermelhos e verdes são referentes às nuvens  $t$  e  $t + 1$ , respectivamente. Ato contínuo, foi aplicado o algoritmo ICP para aperfeiçoar o registro.

Figura 59 – Registro das nuvens  $t$  e  $t + 1$  para o experimento 5.



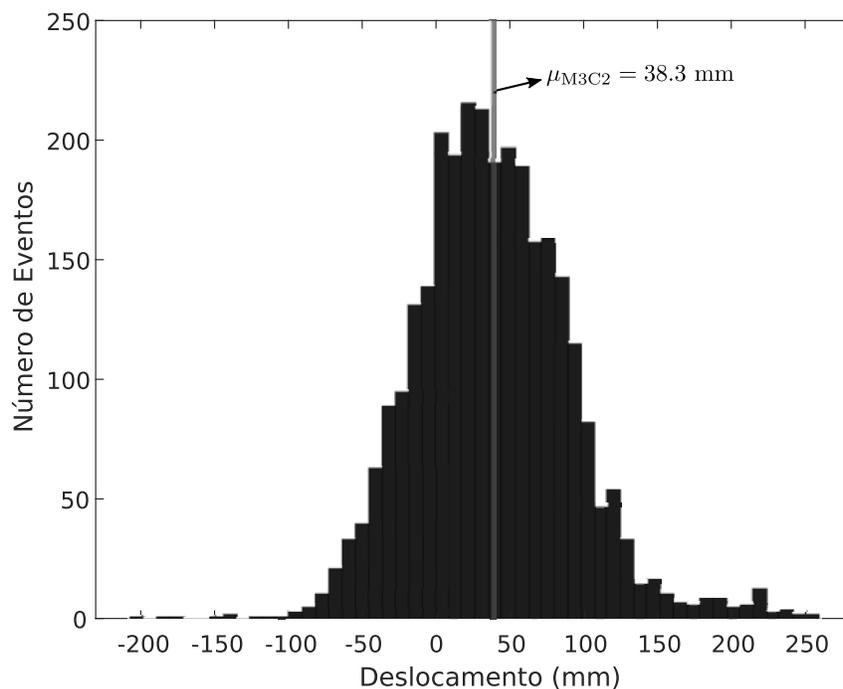
Fonte – Elaborada pelo autor (2020).

#### 5.5.4 Aplicação da técnica M3C2

Diferentemente do caso anterior, onde o M3C2 não foi capaz de estimar o deslocamento ocorrido, nesse caso, onde o deslocamento esperado é nulo, o M3C2 foi capaz

fazer uma estimativa do deslocamento ocorrido. O Gráfico 10 mostra um histograma dos deslocamentos calculados pelo M3C2 para a região escolhida. É possível notar que a média desses deslocamentos foi  $\mu_{M3C2} = 25.609$  mm. Além disso, vale ressaltar que, diferentemente do método proposto que pode estimar vetores de deslocamentos para qualquer direção, o M3C2 estima os deslocamentos na direção normal. Dessa forma, não é necessário decompor os deslocamentos nas direções x, y, z, como é feito na metodologia proposta.

Gráfico 10 – Deslocamentos calculados utilizando a técnica M3C2 para o experimento 5.

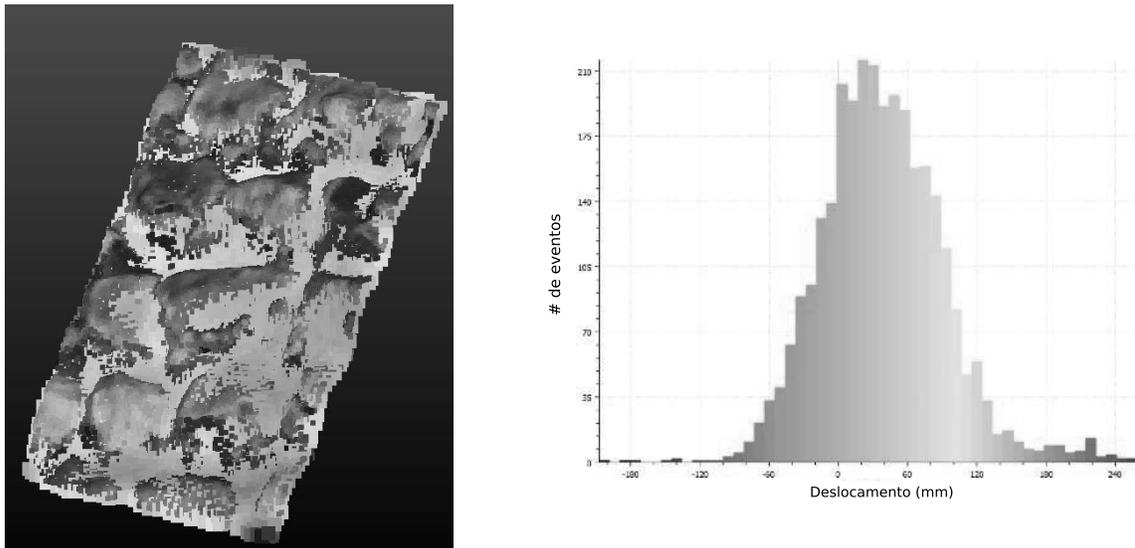


Fonte – Elaborado pelo autor (2020).

Também é possível verificar como esses deslocamentos estão distribuídos ao longo do segmento de talude utilizado para essa análise. A Figura 60 mostra esses deslocamentos codificados por uma paleta de cores.

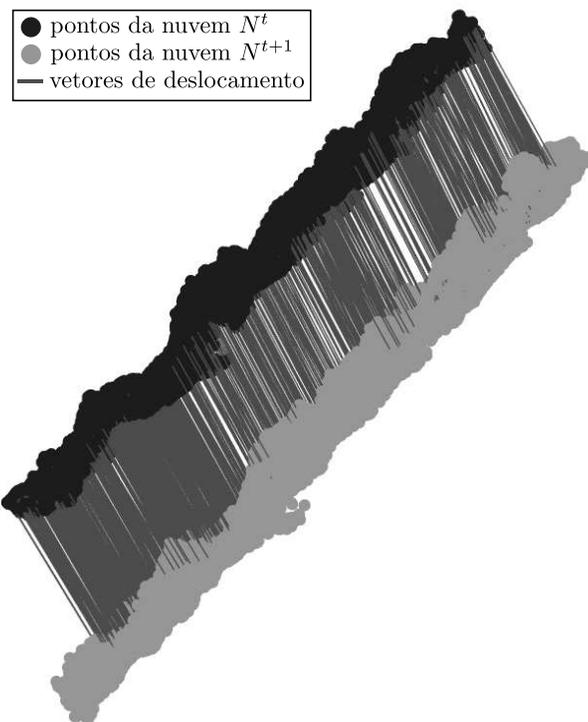
Adicionalmente, também é possível fazer a visualização dos vetores de deslocamento gerados pela técnica M3C2. Essa visualização é disposta na Figura 61. Em azul, está a nuvem de pontos no tempo  $t$ . Em verde, estão dispostos os pontos da nuvem do tempo  $t + 1$ . Os vetores de deslocamento gerados estão em vermelho. É importante notar que as nuvens  $t$  e  $t + 1$  foram manualmente separadas de forma a melhorar a visualização dos vetores de deslocamento. Essa separação foi realizada na direção normal da nuvem de pontos  $t$ . Nesse sentido, é possível notar que os deslocamentos obtidos estão condizentes com o separação aplicada manualmente.

Figura 60 – Deslocamentos calculados pelo M3C2 codificados por uma paleta de cores.



Fonte – Elaborada pelo autor (2020).

Figura 61 – Vetores dos deslocamentos gerados pela técnica M3C2 ocorridos entre as nuvens de pontos  $t$  e  $t + 1$ .

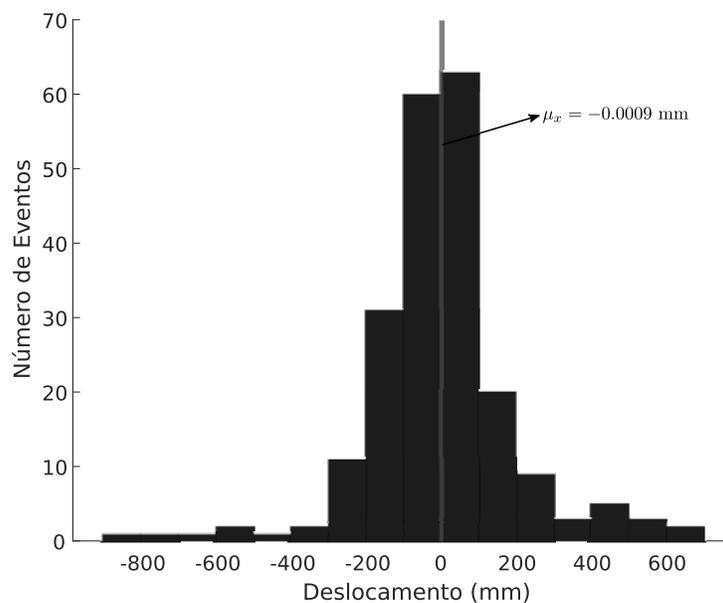


Fonte – Elaborada pelo autor (2020).

### 5.5.5 Aplicação do método DCVRP

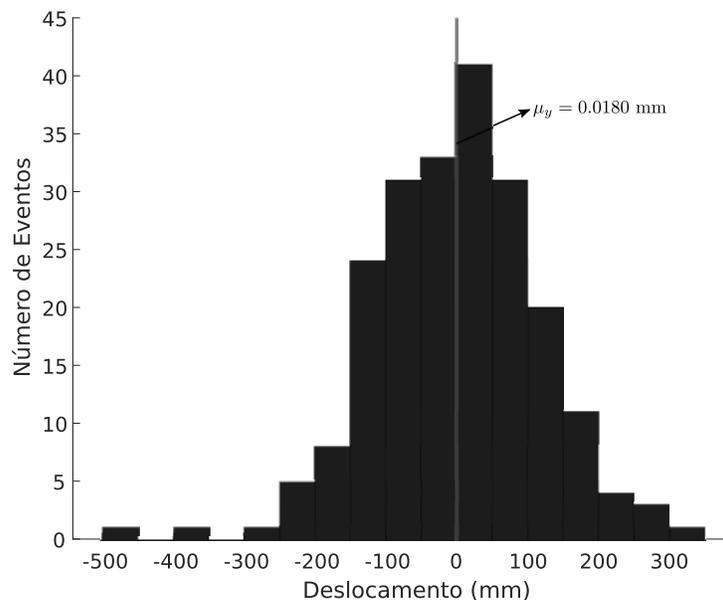
Assim como foi feito no experimento anterior, para mostrar a eficácia da metodologia proposta, foram calculados os histogramas dos deslocamentos ocorridos nas direções X, Y, Z. Esses histogramas estão dispostos nos Gráficos 11, 12 e 13, respectivamente. Como é possível observar nessas figuras, a média dos deslocamentos nas direções X, Y e Z foram  $\mu_x = -0.0009$ ,  $\mu_y = 0.0180$  e  $\mu_z = 1.0038$ , respectivamente. Portanto, a metodologia proposta estima que o talude moveu  $d = \sqrt{\mu_x^2 + \mu_y^2 + \mu_z^2} = 1.0039$  mm. O deslocamento esperado era de 0 mm. Porém, esse pequeno erro ocorrido pode ser explicado pelo erro de registro das nuvens de pontos, que foi feito de maneira não ideal, como foi mencionado anteriormente.

Gráfico 11 – Deslocamentos calculados utilizando a metodologia proposta na direção X para o experimento 5.



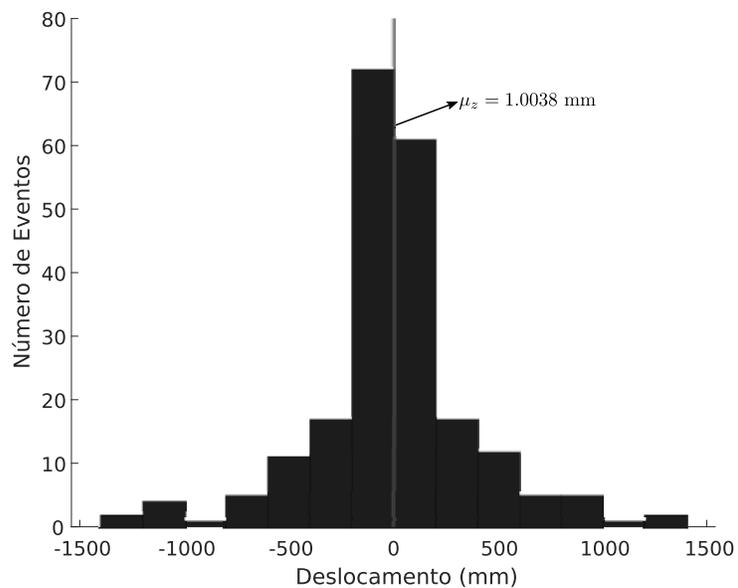
Fonte – Elaborado pelo autor (2020).

Gráfico 12 – Deslocamentos calculados utilizando a metodologia proposta na direção Y para o experimento 5.



Fonte – Elaborado pelo autor (2020).

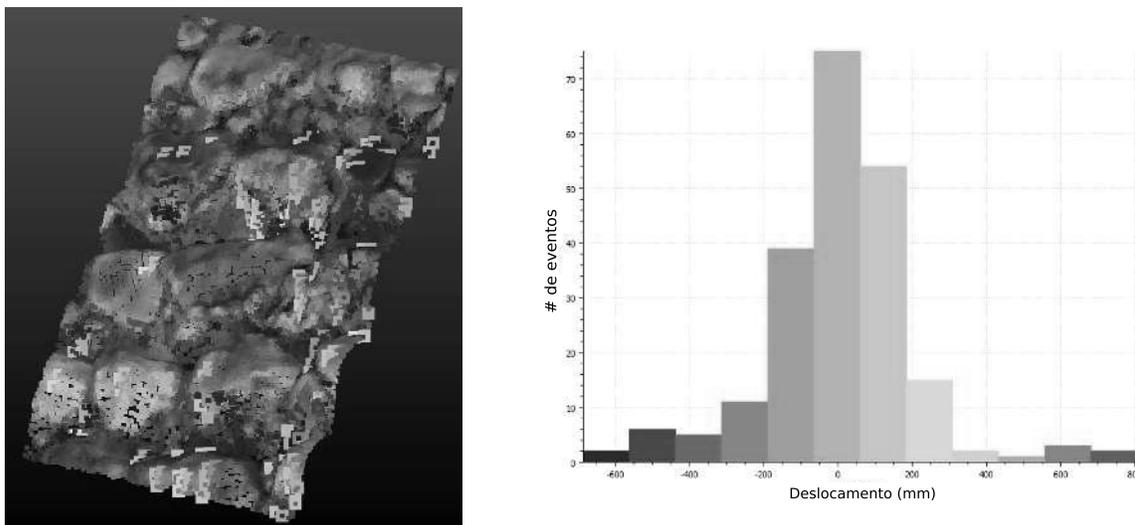
Gráfico 13 – Deslocamentos calculados utilizando a metodologia proposta na direção Z para o experimento 5.



Fonte – Elaborado pelo autor (2020).

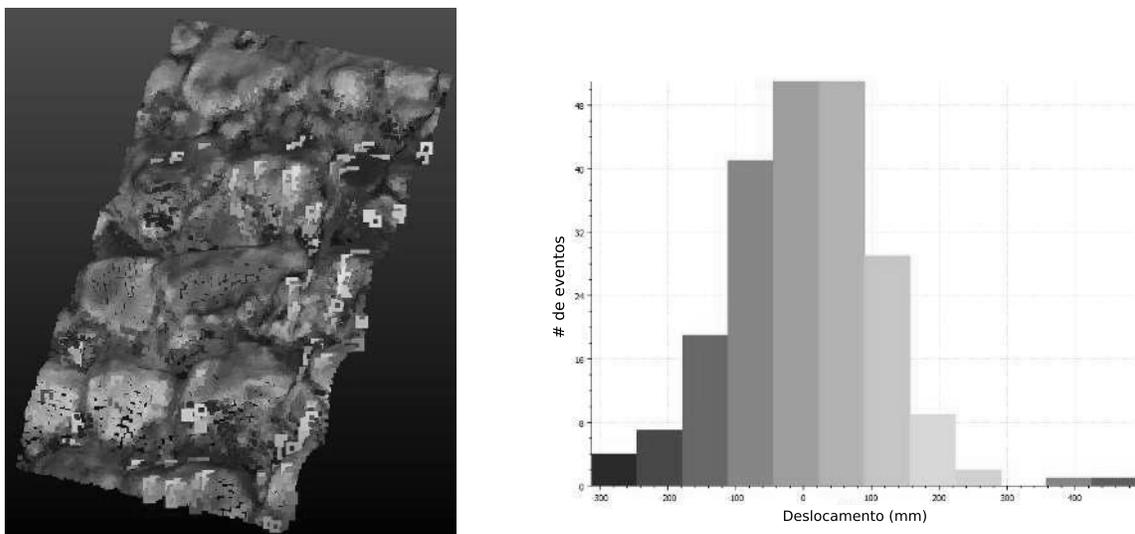
Também é possível verificar visualmente os deslocamentos ocorridos em cada coordenada. Nas Figuras 62, 63 e 64, estão dispostas os deslocamentos ocorridos na estrutura codificados por uma paleta de cores nas direções X, Y e Z, respectivamente.

Figura 62 – Deslocamentos calculados pelo método proposto no eixo X codificados por uma paleta de cores.



Fonte – Elaborada pelo autor (2020).

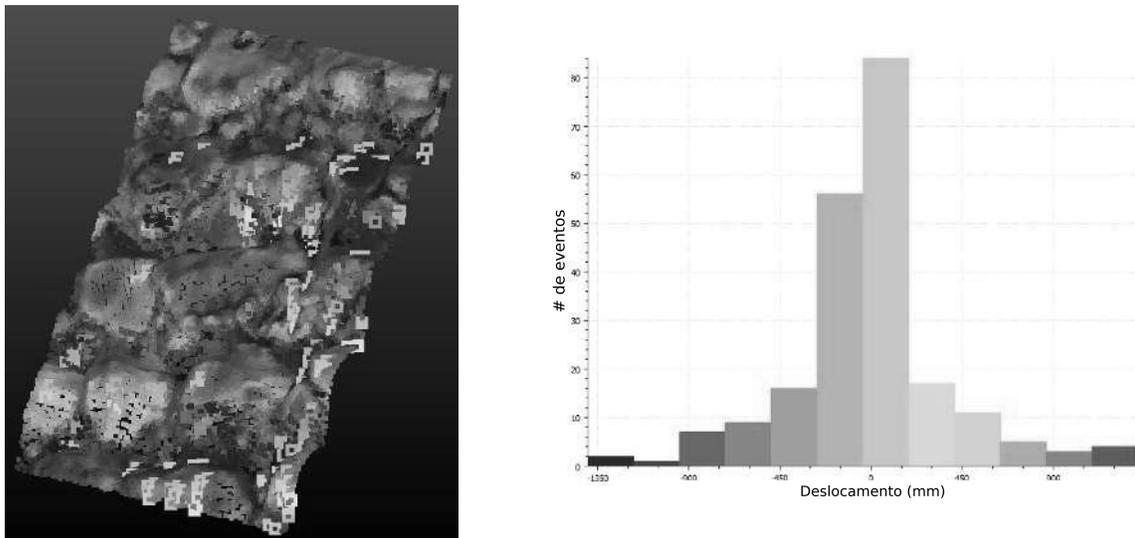
Figura 63 – Deslocamentos calculados pelo método proposto no eixo Y codificados por uma paleta de cores.



Fonte – Elaborada pelo autor (2020).

Outra forma de visualizar os deslocamentos ocorridos, é dispondo os vetores de deslocamento ocorridos. Na Figura 65, são dispostas as nuvens de ponto dos tempos  $t$  e  $t + 1$  nas cores azul e verde, respectivamente. As nuvens de pontos foram manualmente afastadas na direção perpendicular da nuvem de  $t$  para facilitar a visualização dos vetores de deslocamentos. Esses, por sua vez, estão dispostos na cor vermelha. A partir dessa figura, é possível observar que os vetores de deslocamento apresentam características

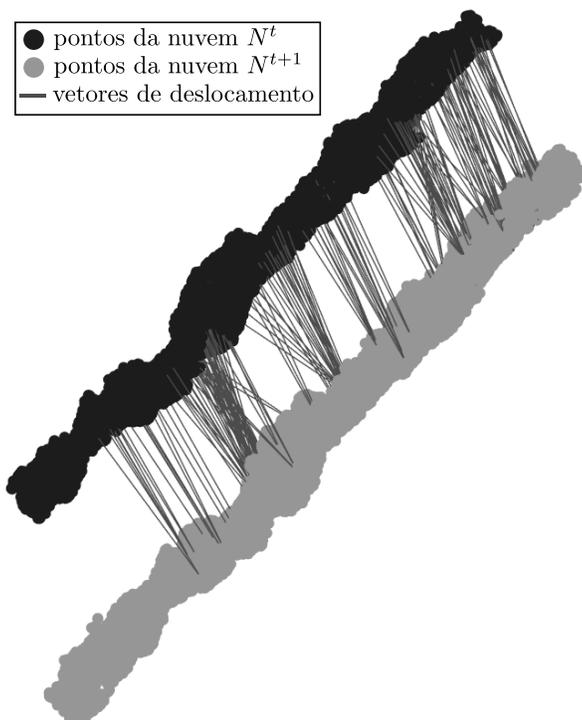
Figura 64 – Deslocamentos calculados pelo método proposto no eixo Z codificados por uma paleta de cores.



Fonte – Elaborada pelo autor (2020).

semelhantes ao deslocamento imposto manualmente.

Figura 65 – Vetores dos deslocamentos gerados pela metodologia proposta ocorridos entre as nuvens de pontos  $t$  e  $t + 1$ .



Fonte – Elaborada pelo autor (2020).

Como não havia pontos de controle no talude e o *ground truth* da deformação

ocorrida não era conhecido, apesar do erro obtido pela metodologia proposta ser menor do que o erro da técnica M3C2, ainda não é possível afirmar que o método proposto obteve melhor performance nesse experimento. Dessa forma, em experimentos futuros envolvendo taludes, é necessário acoplar pontos de controle na estrutura e obter, através das técnicas tradicionais, um *ground truth* do deslocamento de uma região do talude para realizar comparações mais justas entre técnicas de detecção de deformação.

## 6 CONCLUSÕES

Neste capítulo, serão apresentadas as principais conclusões acerca do trabalho desenvolvido. Além disso, também serão expostas algumas sugestões de trabalhos futuros que possam melhorar os resultados obtidos.

O desenvolvimento de técnicas baseadas em fotogrametria para o monitoramento de grandes estruturas é muito importante para diminuir o custo de vistoriamento dessas construções. Dessa forma, por consequência, a quantidade de inspeções pode ser aumentada, tornando essas estruturas cada vez mais seguras.

Nesse trabalho, foi realizada uma revisão sobre os métodos mais conhecidos para o cálculo de deformação em nuvens de pontos. Assim, foi possível verificar que as atuais técnicas na literatura realizam aproximações sobre a direção de deformação das estruturas e, dessa maneira, comprometem o cálculo da deformação ocorrida.

Com o objetivo de superar as limitações das técnicas atuais, uma nova metodologia para cálculo de deformações foi proposta nessa dissertação. Inicialmente, uma metodologia simplificada foi apresentada. Nesse caso, apenas deslocamentos bidimensionais eram considerados e todos os cálculos eram realizados diretamente nas imagens, ou seja, nenhuma reconstrução tridimensional foi aplicada. Os resultados dessa abordagem mostraram que é possível detectar deslocamentos em estruturas através do monitoramento de características nas imagens.

Em seguida, a metodologia simplificada foi generalizada para estruturas tridimensionais. A técnica proposta, chamada de Distância por Correspondência Visual e Reprojção de Pontos (DCVRP), foi desenvolvida para ser utilizada em nuvens de pontos que foram geradas através de imagens, utilizando SfM. Diferentemente da metodologia simplificada, as características monitoradas não foram manualmente colocadas na estrutura monitorada. Nessa técnica, o cálculo das deformações se dá pela utilização das informações de textura de cada ponto tridimensional. Pontos tridimensionais cujas projeções possuem informações de textura semelhantes são considerados correspondentes. Para extrair a textura dos pontos, foi utilizado um descritor denso baseado em *deep learning*: UCN. Esse tipo de descritor tem a capacidade de gerar uma grande quantidade de correspondências bidimensionais e, dessa forma, aumenta-se a quantidade de correspondências tridimensionais. Entretanto, a complexidade computacional aumenta consideravelmente. Portanto, as imagens utilizadas passaram por um processo de redução de resolução devido às limitações computacionais.

Apesar disso, os resultados dos experimentos realizados mostraram que o método proposto é capaz de superar a técnica M3C2, considerada, atualmente, o estado da arte no cálculo de deformações em nuvens de pontos. No segundo e terceiro experimento, deslocamentos com direção diferente da normal foram simulados. Assim, foi possível verificar

que o M3C2, ao contrário do método proposto, não foi capaz de calcular os deslocamentos ocorridos. No quarto experimento, uma placa foi submetida à um deslocamento vertical de 50 mm. Nesse experimento, o M3C2 novamente não foi capaz de calcular a movimentação ocorrida. Por outro lado, o método proposto estimou um deslocamento de 54.6 mm. O erro obtido de 4.6 mm não pode ser totalmente atribuído à técnica proposta, pois erros de registro e escala também contribuem para o erro final. Dessa forma, para quantificar melhor o erro de cálculo de deslocamento do método proposto, é necessário desenvolver um experimento que minimize ao máximo os erros de registro e escala. No quinto experimento, a metodologia proposta foi aplicada em um talude real, onde nenhuma movimentação era esperada. Nesse cenário, a técnica proposta e o M3C2 estimaram deslocamentos de 1.0039 mm e 25.609 mm, respectivamente. Como esse experimento foi realizado em condições não ideais, i.e., não havia pontos de controle para fazer o registro adequado das nuvens e não havia um *ground truth* do deslocamento ocorrido, não é possível fazer uma comparação justa entre o método proposto e a técnica M3C2.

Baseado nos resultados obtidos nos experimentos controlados, foi possível demonstrar que a metodologia proposta, diferentemente do M3C2, pode ser aplicada em qualquer cenário sem necessitar restringir o deslocamento para apenas uma direção.

## 6.1 TRABALHOS FUTUROS

Apesar dos excelentes resultados obtidos em cenários que as técnicas atuais não são capazes de atuar, algumas melhorias podem ser importantes em trabalhos futuros. Em primeiro lugar, é necessário montar experimentos de forma que os erros de registro e escala sejam submilimétricos. Para isso, é necessário utilizar mais pontos de controle que estejam posicionados de forma mais precisa.

Além disso, validar a combinação do método proposto com a técnica M3C2 pode proporcionar deslocamentos com um valor de significância associado. Assim, apesar dessa combinação ser proposta no passo 4.7 do método proposto, é necessário realizar a validação em experimentos futuros.

Outrossim, foram utilizados pesos pré-treinados da rede UCN para a extração dos descritores das imagens utilizadas nesse trabalho. Com o objetivo de melhorar a qualidade das correspondências entre descritores, uma possibilidade futura seria fazer o treinamento da rede UCN utilizando imagens de taludes ou outra estrutura real para obter descritores que atuem melhor nesses ambientes.

Ademais, a combinação dos descritores visuais utilizados nesse trabalho com descritores tridimensionais ofereceria maior robustez no cálculo do deslocamento. Em regiões onde há pouca textura e/ou houve alguma alteração de textura devido a efeitos de intemperismo, os descritores tridimensionais poderiam gerar os vetores de deslocamento com maior precisão. Por outro lado, em regiões com pouca variação geométrica ou quando

a deformação ocorrida for grande o suficiente para modificar o descritor tridimensional, o emprego de descritores visuais poderia fornecer vetores de deslocamento melhores.

Por fim, esse trabalho foi desenvolvido com severas limitações computacionais, sendo necessário, inclusive, utilizar computação em nuvem (Google Colab) para atingir os objetivos propostos. Entretanto, a plataforma utilizada possui diversas limitações, e.g, tempo de execução e memória da GPU, que dificultaram a aplicação do método proposto em situações de maior escala. Portanto, em trabalhos futuros, é necessário implementar o método proposto em um ambiente com maiores recursos computacionais.

## REFERÊNCIAS

- ALBIOL, A. *et al.* Face recognition using hog+ebgm. **Pattern Recognition Letters**, Elsevier, v. 29, n. 10, p. 1537–1543, 2008.
- ALCANTARILLA, P. F.; BARTOLI, A.; DAVISON, A. J. Kaze features. In: SPRINGER. **European Conference on Computer Vision**. [S.l.], 2012. p. 214–227.
- ALCANTARILLA, P. F.; SOLUTIONS, T. Fast explicit diffusion for accelerated features in nonlinear scale spaces. **IEEE Trans. Patt. Anal. Mach. Intell**, TrueVision Solutions, v. 34, n. 7, p. 1281–1298, 2013.
- BAY, H. *et al.* Speeded-up robust features (surf). **Computer vision and image understanding**, Elsevier, v. 110, n. 3, p. 346–359, 2008.
- BESL, P. J.; MCKAY, N. D. Method for registration of 3-d shapes. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Sensor fusion IV: control paradigms and data structures**. [S.l.], 1992. v. 1611, p. 586–606.
- BLUM, M. *et al.* A learned feature descriptor for object recognition in rgb-d data. In: IEEE. **2012 IEEE International Conference on Robotics and Automation**. [S.l.], 2012. p. 1298–1303.
- BRODU, N.; LAGUE, D. 3d terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 68, p. 121–134, 2012.
- CAMPBELL, D.; PETERSSON, L. Gogma: Globally-optimal gaussian mixture alignment. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2016. p. 5685–5694.
- CARRIVICK, J. L.; SMITH, M. W.; QUINCEY, D. J. **Structure from Motion in the Geosciences**. [S.l.]: John Wiley & Sons, 2016.
- CHOY, C. B. *et al.* Universal correspondence network. In: **Advances in Neural Information Processing Systems**. [S.l.: s.n.], 2016. p. 2414–2422.
- ECKART, B.; KIM, K.; KAUTZ, J. Hgmr: Hierarchical gaussian mixtures for adaptive 3d registration. In: **Proceedings of the European Conference on Computer Vision (ECCV)**. [S.l.: s.n.], 2018. p. 705–721.
- GIRARDEAU-MONTAUT, D. **CloudCompare**. [S.l.]: EDF R&D Telecom ParisTech, 2016.
- GIRARDEAU-MONTAUT, D. *et al.* Change detection on points cloud data acquired with a ground laser scanner. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. part 3, p. W19, 2005.
- GOJCIC, Z.; ZHOU, C.; WIESER, A. F2s3: Robustified determination of 3d displacement vector fields using deep learning. **Journal of Applied Geodesy**, De Gruyter.

GOJCIC, Z.; ZHOU, C.; WIESER, A. Robust pointwise correspondences for point cloud based deformation monitoring of natural scenes. In: **JISDM. 4th Joint International Symposium on Deformation Monitoring: JISDM**. [S.l.], 2019.

GONZALEZ, R.; WOODS, R. **Digital image processing, 4th edn. ISBN: 9780133356724**. [S.l.]: Pearson, 2017.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital image processing using MATLAB**. [S.l.]: Pearson Education India, 2004.

HARRIS, C. G.; STEPHENS, M. *et al.* A combined corner and edge detector. In: **CITeseer. Alvey vision conference**. [S.l.], 1988. v. 15, n. 50, p. 10–5244.

HARTLEY, R.; ZISSERMAN, A. **Multiple view geometry in computer vision**. [S.l.]: Cambridge university press, 2003.

HAUGEN, B. D. **Qualitative and quantitative comparative analyses of 3D lidar landslide displacement field measurements**. Tese (Doutorado) — Colorado School of Mines. Arthur Lakes Library, 2016.

HUTCHINSON, L. **Characterization of landform evolution and slope response to the 2015 earthquake sequence and annual monsoon in Central Nepal**. Tese (Doutorado) — Science: Department of Earth Sciences, 2018.

JAFARI, B.; KHALOO, A.; LATTANZI, D. Deformation tracking in 3d point clouds via statistical sampling of direct cloud-to-cloud distances. **Journal of Nondestructive Evaluation**, Springer, v. 36, n. 4, p. 65, 2017.

JUTZI, B.; GROSS, H. Investigations on surface reflection models for intensity normalization in airborne laser scanning (als) data. **Photogrammetric Engineering & Remote Sensing**, American Society for Photogrammetry and Remote Sensing, v. 76, n. 9, p. 1051–1060, 2010.

KAZHDAN, M.; BOLITHO, M.; HOPPE, H. Poisson surface reconstruction. In: **Proceedings of the fourth Eurographics symposium on Geometry processing**. [S.l.: s.n.], 2006. v. 7.

KHALOO, A. *et al.* Utilizing uav and 3d computer vision for visual inspection of a large gravity dam. **Frontiers in Built Environment**, Frontiers, v. 4, p. 31, 2018.

KRIG, S. Interest point detector and feature descriptor survey. In: **Computer vision metrics**. [S.l.]: Springer, 2016. p. 187–246.

LAGUE, D.; BRODU, N.; LEROUX, J. Accurate 3d comparison of complex topography with terrestrial laser scanner: Application to the rangitikei canyon (nz). **ISPRS journal of photogrammetry and remote sensing**, Elsevier, v. 82, p. 10–26, 2013.

LECUN, Y. *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, Ieee, v. 86, n. 11, p. 2278–2324, 1998.

LEYLAND, J. *et al.* Extreme flood-driven fluvial bank erosion and sediment loads: direct process measurements using integrated mobile laser scanning (mls) and hydro-acoustic techniques. **Earth Surface Processes and Landforms**, Wiley Online Library, v. 42, n. 2, p. 334–346, 2017.

- LIN, B. **Change Detection of 3D Scene with 3D and 2D Information for Environment Checking**. Tese (Doutorado) — (Hiroshima University), 2013.
- LONGUET-HIGGINS, H. C. A computer algorithm for reconstructing a scene from two projections. **Nature**, Springer, v. 293, n. 5828, p. 133–135, 1981.
- LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International journal of computer vision**, Springer, v. 60, n. 2, p. 91–110, 2004.
- LU, W.-L.; LITTLE, J. J. Simultaneous tracking and action recognition using the pca-hog descriptor. In: IEEE. **The 3rd Canadian Conference on Computer and Robot Vision (CRV'06)**. [S.l.], 2006. p. 6–6.
- MA, J. *et al.* Lmr: Learning a two-class classifier for mismatch removal. **IEEE Transactions on Image Processing**, IEEE, v. 28, n. 8, p. 4045–4059, 2019.
- MA, Y. *et al.* **An invitation to 3-d vision: from images to geometric models**. [S.l.]: Springer Science & Business Media, 2012. v. 26.
- MOON, D. *et al.* Comparison and utilization of point cloud generated from photogrammetry and laser scanning: 3d world model for smart heavy equipment planning. **Automation in Construction**, Elsevier, v. 98, p. 322–331, 2019.
- O'BANION, M. S. *et al.* Suitability of structure from motion for rock-slope assessment. **The Photogrammetric Record**, Wiley Online Library, v. 33, n. 162, p. 217–242, 2018.
- PU, C. *et al.* Dugma: Dynamic uncertainty-based gaussian mixture alignment. In: IEEE. **2018 International Conference on 3D Vision (3DV)**. [S.l.], 2018. p. 766–774.
- RASHID, M. *et al.* Object detection and classification: a joint selection and fusion strategy of deep convolutional neural network and sift point features. **Multimedia Tools and Applications**, Springer, v. 78, n. 12, p. 15751–15777, 2019.
- RIEGER, B. *et al.* Multi-scale investigation of thickness changes in a commercial pouch type lithium-ion battery. **Journal of Energy Storage**, Elsevier, v. 6, p. 213–221, 2016.
- ROȘCA, S. *et al.* Comparing terrestrial laser scanning and unmanned aerial vehicle structure from motion to assess top of canopy structure in tropical forests. **Interface focus**, The Royal Society, v. 8, n. 2, p. 20170038, 2018.
- RUBLEE, E. *et al.* Orb: An efficient alternative to sift or surf. In: CITESEER. **ICCV**. [S.l.], 2011. v. 11, n. 1, p. 2.
- SALVI, J.; ARMANGUÉ, X.; BATLLE, J. A comparative review of camera calibrating methods with accuracy evaluation. **Pattern recognition**, Elsevier, v. 35, n. 7, p. 1617–1635, 2002.
- SCAIONI, M. *et al.* Geodetic and remote-sensing sensors for dam deformation monitoring. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 11, p. 3682, 2018.
- SCHMIDT, A.; KRAFT, M.; KASIŃSKI, A. An evaluation of image feature detectors and descriptors for robot navigation. In: SPRINGER. **International Conference on Computer Vision and Graphics**. [S.l.], 2010. p. 251–259.

- SCHÖNBERGER, J. L.; FRAHM, J.-M. Structure-from-motion revisited. In: **Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016.
- SCHÖNBERGER, J. L. *et al.* Pixelwise view selection for unstructured multi-view stereo. In: **European Conference on Computer Vision (ECCV)**. [S.l.: s.n.], 2016.
- SIMO-SERRA, E. *et al.* Discriminative learning of deep convolutional feature point descriptors. In: **Proceedings of the IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2015. p. 118–126.
- SZELISKI, R.; SHUM, H.-Y. Creating full view panoramic image mosaics and environment maps. In: **Proceedings of the 24th annual conference on Computer graphics and interactive techniques**. [S.l.: s.n.], 1997. p. 251–258.
- TOLA, E.; LEPETIT, V.; FUA, P. Daisy: An efficient dense descriptor applied to wide-baseline stereo. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 32, n. 5, p. 815–830, 2009.
- TRUCCO, E.; VERRI, A. **Introductory techniques for 3-D computer vision**. [S.l.]: Prentice Hall Englewood Cliffs, 1998. v. 201.
- TUYTELAARS, T.; MIKOLAJCZYK, K. *et al.* Local invariant feature detectors: a survey. **Foundations and trends® in computer graphics and vision**, Now Publishers, Inc., v. 3, n. 3, p. 177–280, 2008.
- WENG, J.; COHEN, P.; HERNIOU, M. Camera calibration with distortion models and accuracy evaluation. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, IEEE, n. 10, p. 965–980, 1992.
- WILKINSON, M. *et al.* A comparison of terrestrial laser scanning and structure-from-motion photogrammetry as methods for digital outcrop acquisition. **Geosphere**, Geological Society of America, v. 12, n. 6, p. 1865–1880, 2016.
- WOLD, S.; ESBENSEN, K.; GELADI, P. Principal component analysis. **Chemometrics and intelligent laboratory systems**, Elsevier, v. 2, n. 1-3, p. 37–52, 1987.
- WU, C. *et al.* Visualsfm: A visual structure from motion system. 2011.
- WUJANZ, D. Terrestrial laser scanning for geodetic deformation monitoring. 2016.
- YANG, T.-Y. *et al.* Deepcd: Learning deep complementary descriptors for patch representations. In: **Proceedings of the IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2017. p. 3314–3322.
- YAO, S. *et al.* A new pedestrian detection method based on combined hog and lss features. **Neurocomputing**, Elsevier, v. 151, p. 1006–1014, 2015.
- YI, K. M. *et al.* Lift: Learned invariant feature transform. In: SPRINGER. **European Conference on Computer Vision**. [S.l.], 2016. p. 467–483.
- YI, K. M. *et al.* Learning to find good correspondences. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2018. p. 2666–2674.

ZHANG, H. Borf: Loop-closure detection with scale invariant visual features. In: **IEEE. 2011 IEEE International conference on robotics and automation**. [S.l.], 2011. p. 3125–3130.

ZHANG, Z. A flexible new technique for camera calibration. **IEEE Transactions on pattern analysis and machine intelligence**, IEEE, v. 22, n. 11, p. 1330–1334, 2000.

ZHU, S. *et al.* Very large-scale global sfm by distributed motion averaging. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2018. p. 4568–4577.