



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
MESTRADO EM ENGENHARIA DE TELEINFORMÁTICA

DANIEL ARAÚJO CHAVES SOUZA

**UMA INVESTIGAÇÃO SOBRE O USO DE DESCRITORES GEOMÉTRICOS DE
SUPERFÍCIE PARA FILTRAGEM DE REGIÕES VISANDO O AUMENTO DA
QUALIDADE DO REGISTRO DE NUVENS DE PONTOS 3D**

FORTALEZA

2023

DANIEL ARAÚJO CHAVES SOUZA

UMA INVESTIGAÇÃO SOBRE O USO DE DESCRITORES GEOMÉTRICOS DE
SUPERFÍCIE PARA FILTRAGEM DE REGIÕES VISANDO O AUMENTO DA
QUALIDADE DO REGISTRO DE NUVENS DE PONTOS 3D

Dissertação apresentada ao Curso de Mestrado em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Orientador: Prof. Dr. José Marques Soares.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

S237i Souza, Daniel Araújo Chaves.

Uma investigação sobre o uso de descritores geométricos de superfície para filtragem de regiões visando o aumento da qualidade do registro de nuvens de pontos 3D / Daniel Araújo Chaves Souza. – 2023.
95 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2023.

Orientação: Prof. Dr. José Marques Soares.

1. Nuvens de pontos 3D. 2. Métodos de registro. 3. Descritores de superfície. 4. Descritores geométricos. 5. Filtragem. I. Título.

CDD 621.38

DANIEL ARAÚJO CHAVES SOUZA

UMA INVESTIGAÇÃO SOBRE O USO DE DESCRITORES GEOMÉTRICOS DE
SUPERFÍCIE PARA FILTRAGEM DE REGIÕES VISANDO O AUMENTO DA
QUALIDADE DO REGISTRO DE NUVENS DE PONTOS 3D

Dissertação apresentada ao Curso de Mestrado em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Aprovada em: 22/09/2023.

BANCA EXAMINADORA

Prof. Dr. José Marques Soares (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. George André Pereira Thé
Universidade Federal do Ceará (UFC)

Profa. Dra. Michela Mulas
Universidade Federal do Ceará (UFC)

Prof. Dr. Luciano Rebouças de Oliveira
Universidade Federal da Bahia (UFBA)

À minha família, amigos e professores, cujo apoio e orientação moldaram meu crescimento pessoal e profissional. Sua influência é a força motriz por trás desta conquista.

AGRADECIMENTOS

Gostaria de expressar minha mais profunda gratidão a todos que tornaram possível a realização deste trabalho.

Primeiramente, aos meus queridos pais, cujo apoio incondicional e incentivo ao estudo têm sido uma força constante em minha jornada acadêmica. Mesmo nas circunstâncias mais desafiadoras, sua dedicação e encorajamento foram alicerces essenciais.

Aos amigos e colegas que compartilharam seus valiosos conselhos, ofereceram apoio inabalável e proporcionaram momentos de descontração que trouxeram alívio nos momentos difíceis. Sua amizade e presença foram um raio de luz.

Minha gratidão também se estende aos notáveis membros do Grupo de Pesquisa Interfaces, cujos conhecimentos e contribuições enriqueceram significativamente o desenvolvimento deste trabalho. A colaboração de vocês foi fundamental para a consecução dos objetivos propostos.

Ao meu orientador, o Prof. Dr. José Marques Soares, sou imensamente grato por sua orientação sábia, paciência incansável e orientação exemplar ao longo deste percurso. Seu expertise e direcionamento foram um farol orientador que me conduziu na direção certa.

Aos ilustres membros da banca examinadora, Prof. Dr. George André Pereira Thé, Profa. Dra. Michela Mulas e Prof. Dr. Luciano Rebouças de Oliveira (UFBA), meu sincero agradecimento pelo tempo dedicado à avaliação deste trabalho e pelas valiosas contribuições e sugestões que enriqueceram sua qualidade.

À coordenação, aos professores e à secretaria do Programa de Pós-Graduação em Engenharia de Teleinformática (PPGETI), meu sincero agradecimento pelo apoio constante ao longo de meu percurso acadêmico, contribuindo significativamente para o meu crescimento profissional.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro que possibilitou a manutenção da bolsa de auxílio. Sua contribuição foi fundamental para viabilizar o desenvolvimento deste trabalho.

“A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original.” (Albert Einstein)

RESUMO

Com ampla aplicação em diversos domínios, como robótica, visão computacional e reconstrução, o registro de nuvens de pontos 3D apresenta desafios quanto à eficiência computacional e à qualidade de alinhamento obtido, especialmente em nuvens com elevada quantidade de pontos e em visões parciais capturadas por sensores em diferentes perspectivas. Nesse contexto, diversas abordagens sugerem otimizar o registro por meio da seleção de subconjuntos de pontos relevantes das nuvens originais. No entanto, determinar as regiões mais apropriadas para o registro não é uma tarefa simples. Nesse sentido, propõe-se uma investigação acerca das regiões mais adequadas para o registro de nuvens de pontos, utilizando descritores geométricos derivados das matrizes de covariância da vizinhança dos pontos. O objetivo é identificar estratégias de seleção mais eficazes, visando aprimorar o alinhamento em diversos cenários. Este estudo documenta de maneira abrangente e detalhada a aplicação dos descritores de superfície na seleção de regiões relevantes para o registro, juntamente com estratégias eficazes para incorporar essas filtragens em um *pipeline* de registro. A avaliação do desempenho das estratégias investigadas foi realizada através do cálculo do erro de transformação, obtido por meio da verdade fundamental (*ground truth*), garantindo uma análise precisa da qualidade do alinhamento alcançado. Os resultados dos diversos experimentos realizados, que abrangem desde modelos de objetos até cenas internas (*indoor*) e externas (*outdoor*), mostraram que a seleção de regiões de interesse com base nos descritores de superfície proporciona um erro de transformação médio menor. Isso resulta em um maior número de amostras alinhadas satisfatoriamente, de acordo com os critérios de qualidade estabelecidos neste estudo, em comparação com as estratégias clássicas de registro avaliadas, especialmente no contexto de modelos de objetos.

Palavras-chave: Alinhamento; Nuvens de pontos; 3D; Métodos de registro; Descritores geométricos; Erro de transformação; Descritores de superfície; Filtragem.

ABSTRACT

With a broad application in various domains such as robotics, computer vision, and reconstruction, the registration of 3D point clouds presents challenges in terms of computational efficiency and the quality of alignment obtained, especially in point clouds with a high number of points and partial views captured by sensors from different perspectives. In this context, various approaches suggest optimizing registration by selecting relevant subsets of points from the original point clouds. However, determining the most suitable regions for registration is not a straightforward task. In this regard, an investigation is proposed regarding the most suitable regions for the registration of point clouds using geometric descriptors derived from the covariance matrices of point neighborhoods. The goal is to identify more effective selection strategies to enhance alignment in various scenarios. This study comprehensively and in detail documents the application of surface descriptors in the selection of relevant regions for registration, along with effective strategies for incorporating these filters into a registration pipeline. The performance evaluation of the investigated strategies was conducted by calculating the transformation error, obtained through ground truth, ensuring a precise analysis of the quality of the achieved alignment. The results of various experiments conducted, spanning from object models to indoor and outdoor scenes, showed that the selection of regions of interest based on surface descriptors results in a lower average transformation error. This leads to a greater number of samples satisfactorily aligned according to the quality criteria established in this study, compared to the evaluated classical registration strategies, especially in the context of object models.

Keywords: Alignment; Point clouds; 3D; Registration methods; Geometric descriptors; Transformation error; Surface descriptors; Filtering.

LISTA DE FIGURAS

Figura 1 – Perspectivas parciais do (a) <i>Coelho de Stanford</i> : (b) 45°, (c) 90° e (d) alinhamento das visões parciais a 45° e 90°	17
Figura 2 – Taxonomia de registro de nuvem de pontos.	17
Figura 3 – Diagrama das principais etapas da metodologia aplicada.	27
Figura 4 – Mapa de calor da diferença média ponto à ponto por descritor das nuvens originais e rotacionadas.	33
Figura 5 – Mapa de calor dos valores obtidos por descritor nas nuvens originais e rotacionadas arbitrariamente ($R_x = 37^\circ, R_y = 21^\circ, R_z = 82^\circ$).	34
Figura 6 – Gráfico diferença média ponto à ponto por descritor das nuvens originais e subamostradas.	35
Figura 7 – Mapa de calor dos valores obtidos por descritor nas nuvens original e subamostradas do objeto <i>Dragon</i>	36
Figura 8 – Mapa de calor da diferença média ponto à ponto por descritor nas nuvens originais e com ruído.	38
Figura 9 – Mapa de calor dos valores obtidos por descritor nas nuvens original e com ruído do objeto <i>Buddha</i>	39
Figura 10 – Subnuvens resultantes da filtragem por meio de limiares empiricamente determinados para cada descritor.	42
Figura 11 – Mapa de calor do erro de transformação obtido no alinhamento das amostras filtradas e não filtradas.	43
Figura 12 – Regiões selecionadas pelas filtrações completa e reduzida nos objetos <i>Bunny</i> , <i>Buddha</i> e <i>Dragon</i>	44
Figura 13 – Mapa de calor do erro de transformação obtido pelo registro utilizando filtragem completa, reduzida e amostras originais.	45
Figura 14 – Segmentação das nuvens filtradas por meio das abordagens de algoritmos DBSCAN e K-médias.	47
Figura 15 – Mapa de calor do erro de transformação por estratégia de clusterização.	48
Figura 16 – Particionamento obtido utilizando KNN a partir dos pontos-chave da nuvens filtradas clusterizadas com DBSCAN.	48
Figura 17 – Mapa de calor do erro de transformação por estratégia de particionamento.	49
Figura 18 – <i>Pipeline</i> de registro para explorar todas as combinações de parâmetros avaliadas.	51

Figura 19 – Gráfico do total de configurações alinhadas satisfatoriamente por número de pares alinhados.	51
Figura 20 – <i>Pipeline</i> utilizado para o registro das amostras em ambas as configurações avaliadas.	55
Figura 21 – Gráfico do erro de transformação médio em todos os cenários (A-F, vermelho) e nos cenário com objetos (A-D, verde) agrupados por configuração	57
Figura 22 – Gráfico do erro de transformação médio do cenário A por configuração e objeto registrado.	60
Figura 23 – Comparativo entre os alinhamentos obtidos para o par de nuvens <i>Bunny45</i> (azul) e <i>Bunny90</i> (vermelho). À esquerda está o par de nuvens de entrada (a), no meio é exibido o alinhamento obtido pela configuração 9 (b) e à direita temos o alinhamento obtido pela variante centralizada do algoritmo ICP ponto-ao-plano.	62
Figura 24 – Gráfico do erro de transformação médio, por configuração, para os objetos do cenário B.	63
Figura 25 – Mapa de calor do erro de transformação médio, por configuração, para os objetos com rotações agressivas.	66
Figura 26 – Mapa de calor do erro de transformação médio obtido em cada configuração por nível de ruído.	67
Figura 27 – Gráficos comparativos do erro de transformação médio dos objeto por nível de ruído da melhor configuração proposta (esquerda) e de referência (direita).	68
Figura 28 – Níveis de ruído para o objeto <i>Bunny</i> . a) nuvem original; b) terceiro nível de ruído; c) sexto nível de ruído; d) décimo nível de ruído.	68
Figura 29 – Gráfico do erro de transformação médio, por configuração, para os objetos do cenário D.	70
Figura 30 – Gráficos do erro de transformação médio, por nível de subamostragem, das três melhores configurações propostas e de referência.	70
Figura 31 – Mapa de calor do erro de transformação médio para as cenas internas. . . .	72
Figura 32 – Gráfico do erro médio de transformação por configuração e tipo de algoritmo de registro.	73
Figura 33 – Gráfico do erro de transformação médio, por configuração, para as cenas do cenário F.	75

Figura 34 – Amostras das cenas <i>outdoor</i> alinhadas satisfatoriamente pela melhor configuração (2). a) centro da cidade de Bremen; b) vista em torno do <i>Gaussian Point</i>	76
Figura 35 – Mapa de calor do percentual de amostras que alcançaram um alinhamento aceitável por descritor e cenário.	79
Figura 36 – Subnuvens selecionadas a partir de intervalos de filtragem distintos, usando o descritor de planaridade.	83
Figura 37 – Mapa de calor do número otimizado de iterações por configuração e cenário.	85
Figura 38 – Mapa de calor do número otimizado de iterações por configuração dos cenários com objetos.	86

LISTA DE TABELAS

Tabela 1 – Erro de transformação e RMSE médios das configurações avaliadas.	53
Tabela 2 – Média dos principais indicadores de qualidade avaliados nos cenários A-F. .	59
Tabela 3 – Erro de transformação e RMSE médio para os múltiplos alinhamentos de cada objeto.	62
Tabela 4 – Média dos principais indicadores de qualidade para o cenário B.	64
Tabela 5 – Combinação mínima de descritores para os melhores resultados por configuração e cenários.	80
Tabela 6 – Combinação mínima de descritores que obtém os melhores resultados por configuração.	81
Tabela 7 – Combinação mínima de intervalos de filtragem para obtenção dos melhores resultados com as configurações 6 e 8 em cada cenário.	82
Tabela 8 – Combinação mínima de algoritmos de registro que obtém os melhores resultados por configuração e cenário.	84
Tabela 9 – Comparação entre o <i>pipeline</i> original, o <i>pipeline</i> otimizado para os cenários A-F e o <i>pipeline</i> otimizado para os cenários A, B, C* e D.	86

LISTA DE QUADROS

Quadro 1 – Objetivos gerais e específicos definidos ao longo da investigação.	19
Quadro 2 – Informações sobre os cenários de teste e os conjuntos de dados utilizados .	56

LISTA DE ABREVIATURAS E SIGLAS

ICP_{p2l}	<i>ICP ponto-à-linha</i>
ICP_{p2pl}	<i>ICP ponto-ao-plano</i>
ICP_{p2p}	<i>ICP ponto-à-ponto</i>
CP-ICP	<i>Cloud-Partitioning ICP</i>
DBSCAN	<i>Density-Based Spatial Clustering of Applications with Noise</i>
DDR5	<i>Double Data Rate 5</i>
FPFH	<i>Fast Point Feature Histograms</i>
FPS	<i>Farthest Point Sampling</i>
GICP	<i>Generalized-ICP</i>
ICP	<i>Iterative Closest Point</i>
KNN	<i>K-Nearest Neighbors</i>
LiDAR	<i>Light Detection and Ranging</i>
RANSAC	<i>Random Sample Consensus</i>
RMSE	<i>Root Mean Squared Error</i>
UPS	<i>Uniaxial Partitioning Strategy</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos gerais e específicos	18
1.2	Organização do trabalho	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Técnicas de alinhamento de nuvens de pontos 3D	21
2.2	Descritores geométricos de superfície	23
2.3	Considerações finais	26
3	METODOLOGIA	27
3.1	Cálculo dos descritores	27
3.2	Algoritmos de registro	28
3.3	Métrica de avaliação	28
3.4	Amostras	30
3.5	Ambiente de teste	31
4	AVALIAÇÃO DA ROBUSTEZ DOS DESCRITORES DE SUPERFÍCIE EM DIFERENTES CONTEXTOS	32
4.1	Mudança de rotação	32
4.2	Subamostragem	34
4.3	Ruído	37
4.4	Considerações finais	40
5	ANÁLISE DE DIFERENTES ESTRATÉGIAS DE FILTRAGEM DE REGIÕES COM BASE EM DESCRITORES DE SUPERFÍCIE	41
5.1	Filtragem empregando um único descritor	41
5.2	Filtragem completa e filtragem reduzida	43
5.3	Clusterização de nuvens filtradas	46
5.4	Seleção de regiões utilizando pontos-chave	47
5.5	Considerações finais	49
6	INVESTIGAÇÃO DE MÚLTIPLAS CONFIGURAÇÕES DE REGISTRO	50
7	AVALIAÇÃO DAS MELHORES CONFIGURAÇÕES EM DIFERENTES CENÁRIOS DE REGISTRO	54
7.1	Metodologia	54

7.1.1	<i>Critério de avaliação</i>	55
7.1.2	<i>Conjuntos de dados</i>	55
7.2	Resultados	56
7.2.1	<i>Cenário A – Registro de objetos com sobreposição parcial</i>	60
7.2.2	<i>Cenário B – Registro de objetos com sobreposição total</i>	62
7.2.3	<i>Cenário C – Registro de nuvens com ruído gaussiano</i>	65
7.2.4	<i>Cenário D – Registro de nuvens subamostradas</i>	69
7.2.5	<i>Cenário E – Registro de cenas indoor com sobreposição parcial</i>	71
7.2.6	<i>Cenário F – Registro de cenas outdoor com sobreposição parcial</i>	74
7.3	Considerações finais	75
8	OTIMIZAÇÃO DAS CONFIGURAÇÕES DE MELHOR DESEMPENHO	78
8.1	Descritor utilizado	78
8.2	Intervalo de filtragem	81
8.3	Algoritmo de registro	83
8.4	Considerações finais	84
9	CONCLUSÕES E TRABALHOS FUTUROS	87
	REFERÊNCIAS	90


1 INTRODUÇÃO

Os sensores de profundidade têm desempenhado um papel crucial em várias tarefas, como navegação autônoma (PAK; SON, 2022; PFRUNDER *et al.*, 2017), realidade aumentada (LIU *et al.*, 2020; KOHLISCH *et al.*, 2023), reconhecimento facial (YP; ZELE, 2022), visão computacional (LIN *et al.*, 2021; BÖRCS *et al.*, 2017), entre outras. Entre esses sensores, destaca-se o *Light Detection and Ranging* (LiDAR), que passou por um desenvolvimento significativo nas últimas décadas e está se tornando um equipamento padrão na comunidade de robótica (YIN *et al.*, 2023). Os sensores LiDAR são dispositivos que executam a aquisição de medidas de distância de forma direta, utilizando o princípio de emissão e recepção de pulsos de luz (laser). Por conta dessa abordagem, eles se apresentam como uma alternativa mais robusta diante de mudanças nas condições de iluminação e aparência, quando comparados com as imagens capturadas por câmeras 2D. Esses sensores permitem a amostragem espacial da superfície de um objeto ou cena em um conjunto de pontos tridimensionais (x, y, z), conhecido como nuvem de pontos 3D.

Devido às limitações inerentes ao campo de visão restrito dos sensores, bem como à possibilidade de oclusão por outros objetos ou auto-occlusão, quando a perspectiva de captura impede a detecção de áreas encobertas, é necessário realizar múltiplas capturas de um objeto ou cena em diferentes posições para abranger toda a superfície de interesse. No entanto, devido às variações na posição do sensor e do objeto, cada captura possui seu próprio sistema de referência espacial. Para obter um modelo completo e consistente do objeto ou ambiente a partir dessas capturas parciais, é necessário alinhá-las em um único sistema de referência usando técnicas de registro ou fusão de imagens tridimensionais, como ilustrado na Figura 1. O processo de registro envolve o cálculo da transformação geométrica que melhor alinha as capturas parciais, resultando em uma representação unificada e coerente do objeto ou cena.

Diversas técnicas têm sido propostas para abordar o problema do registro nos mais variados cenários. Em sua pesquisa, Huang *et al.* (2021) apresentaram uma taxonomia abrangente, ilustrada na Figura 2, com o objetivo de organizar as diversas estratégias existentes. O registro de mesma fonte (*same-source*) refere-se à combinação de várias nuvens de pontos provenientes da mesma fonte ou sensor. Por outro lado, o registro de fontes cruzadas (*cross-source*) é ainda mais complexo e envolve o alinhamento de nuvens de pontos provenientes de diferentes tipos de sensores ou tecnologias, como nuvens de pontos obtidas por uma câmera RGB-D e um escâner a laser.

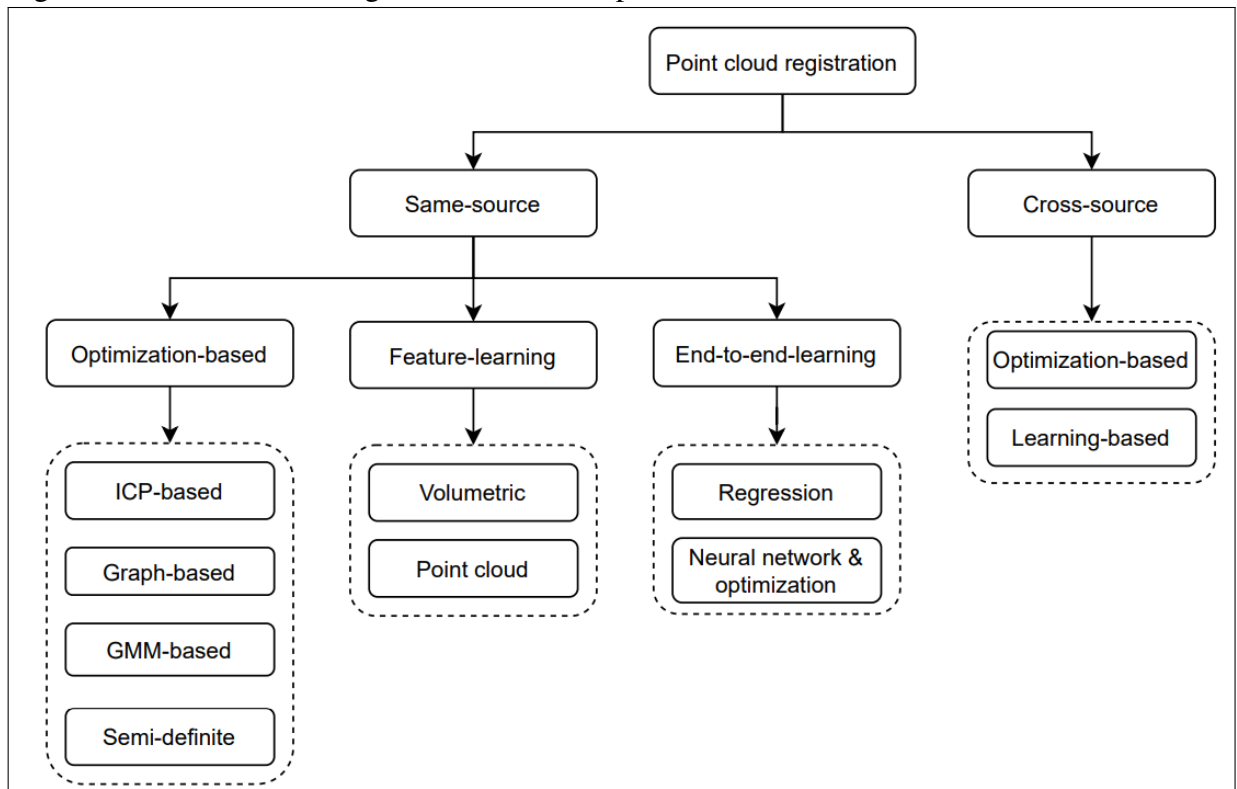
Figura 1 – Perspectivas parciais do (a) *Coelho de Stanford*: (b) 45°, (c) 90° e (d) alinhamento das visões parciais a 45° e 90°.



Fonte: elaborada pelo autor.

Nota: o fundo cinza nas imagens (b) e (c) representa as regiões oclusas não capturadas pelo sensor.

Figura 2 – Taxonomia de registro de nuvem de pontos.



Fonte: Huang *et al.* (2021).

Os métodos de registro baseados em otimização empregam estratégias de otimização para estimar a matriz de transformação entre duas nuvens de pontos, utilizando técnicas de busca de correspondências e estimação da transformação. Por outro lado, os métodos de aprendizado de características se baseiam em redes neurais profundas para aprender características robustas e identificar correspondências confiáveis entre as nuvens de pontos. Por fim, os métodos de registro baseados em aprendizado de ponta a ponta resolvem o problema de registro por meio do uso direto de redes neurais que realizam a transformação. Os métodos baseados em otimização possuem uma base matemática sólida, enquanto os métodos de aprendizado de características

exploram o poder do aprendizado profundo. Os métodos de aprendizado de ponta a ponta combinam as vantagens das teorias matemáticas e das redes neurais. No entanto, também apresentam limitações, como sensibilidade ao ruído e a necessidade de uma métrica de distância adequada para garantir uma estimativa precisa da transformação (HUANG *et al.*, 2021).

Muitas estratégias de registro não utilizam o conjunto de pontos completo para realizar o alinhamento dos modelos 3D, por duas razões fundamentais. Primeiramente, a utilização do conjunto de pontos completo resultaria em uma carga computacional excessiva, tornando o processo demorado e ineficiente. Em segundo lugar, essa abordagem não seria benéfica para o registro, uma vez que existem muitas áreas na nuvem de pontos que possuem semelhanças entre si. Conseqüentemente, haveria um processamento desnecessário, aumentando a probabilidade de correspondências incorretas e dificultando o alinhamento adequado (SI *et al.*, 2022).

1.1 Objetivos gerais e específicos

Considerando a segmentação das nuvens de pontos um método promissor para a redução da complexidade do registro, o presente estudo tem como principal objetivo a investigação de estratégias de seleção de pontos ou regiões nas nuvens de pontos, utilizando descritores geométricos de superfície extraídos da matriz de covariância (WEINMANN, 2013), em uma vizinhança ao redor dos pontos. Essas estratégias têm como objetivo identificar os pontos mais adequados para o processo de registro, visando aprimorar a qualidade do alinhamento em diferentes cenários. A expectativa é que, por meio dessas abordagens de seleção de pontos, seja possível obter resultados melhores, garantindo alinhamentos mais precisos e robustos em cenários diversos.

Além disso, a pesquisa busca avaliar a robustez das regiões selecionadas em relação a fatores como mudança de rotação, subamostragem e presença de ruído. Serão analisados quais descritores ou combinações de descritores são mais apropriados para a seleção de regiões nas nuvens de pontos, buscando identificar aqueles que melhor contribuem para o processo de registro. Também será investigado se as regiões com maior mudança de curvatura são as mais adequadas para obter alinhamentos de maior qualidade.

Outro ponto relevante é a avaliação de estratégias de alinhamento que permitam maior flexibilidade na seleção de pontos e/ou ajuste de parâmetros de filtragem. Pretende-se analisar como essas abordagens mais flexíveis impactam o processo de registro e se elas podem

melhorar a eficiência e a precisão dos resultados.

Por fim, serão conduzidos testes avançados com objetos, cenas *indoor* e *outdoor* para avaliar o desempenho das melhores estratégias de alinhamento investigadas. Esses testes em cenários mais complexos permitirão verificar a aplicabilidade prática das abordagens propostas e a sua efetividade em casos de uso mais realistas.

Ressalta-se que, devido à natureza investigativa do presente estudo, alguns objetivos foram aprimorados e/ou delineados ao longo do processo investigativo, com base nos resultados obtidos em etapas anteriores. Como resultado, o Quadro 1 sintetiza os aspectos da investigação que se converteram em objetivos específicos ao longo do curso do estudo:

Quadro 1 – Objetivos gerais e específicos definidos ao longo da investigação.

Objetivos Gerais

Investigar formas de segmentar nuvens de pontos em regiões que favoreçam um alinhamento de maior qualidade com base em descritores de superfície derivados da matriz de covariância.

Objetivos Específicos

Analisar a robustez dos descritores em relação à presença de ruído, invariância à rotação e subamostragem.

Avaliar se subnuvens resultantes de um único processo de filtragem alcançam alinhamentos superiores em comparação às abordagens clássicas analisadas.

Analisar se a clusterização de subnuvens filtradas resulta em alinhamentos mais eficazes em comparação com as abordagens clássicas examinadas.

Investigar se a diminuição das descontinuidades nas regiões filtradas contribui para a obtenção de alinhamentos melhores em comparação às abordagens clássicas avaliadas.

Avaliar se o ajuste iterativo dos parâmetros de filtragem e registro pode resultar em alinhamentos de maior precisão.

Analisar as estratégias de registro que se baseiam em nuvens filtradas, empregando diversos limiares para os atributos geométricos, a fim de identificar as abordagens de registro mais eficazes em um conjunto abrangente e variado de amostras.

Explorar a possibilidade de otimização das estratégias mais bem avaliadas nos cenários de testes.

Fonte: elaborado pelo autor.

O presente estudo visa contribuir para a área de processamento de nuvens de pontos, oferecendo *insights* sobre a seleção e o alinhamento de pontos em diferentes cenários, utilizando os descritores geométricos de superfície da matriz de covariância. Espera-se que os resultados obtidos possam beneficiar aplicações em áreas como visão computacional, realidade virtual, mapeamento 3D, entre outras. O aprimoramento do registro de nuvens de pontos pode abrir novas

possibilidades em diversas indústrias, além de facilitar a obtenção de modelos tridimensionais mais precisos e confiáveis.

1.2 Organização do trabalho

O restante deste trabalho segue a seguinte estrutura. No Capítulo 2, são apresentadas técnicas de registro presentes na literatura e são abordados fundamentos e conceitos utilizados neste trabalho. No Capítulo 4, é realizada uma investigação do comportamento dos descritores de superfície em diferentes condições, como mudança de rotação, subamostragem e presença de ruído. No Capítulo 5, são avaliados os alinhamentos obtidos por meio de filtragens simples baseadas nos descritores de superfície. Além disso, são empregadas estratégias de filtragens mais sofisticadas, combinando características dos descritores de superfície e técnicas de clusterização. No Capítulo 6, são investigadas várias combinações de filtragem para comprovar a eficácia da filtragem com base nos descritores de superfície. Além disso, é proposta uma abordagem iterativa para obter resultados ainda melhores e mais robustos, utilizando diferentes configurações de parâmetros no processo de registro. No Capítulo 7, é realizada uma investigação detalhada, utilizando uma maior quantidade de amostras, nas melhores configurações em cenários diversos, como registro com sobreposição parcial e total, registro de nuvens com diferentes intensidades de ruído e subamostragem, e registro de modelos de cenários *indoor* e *outdoor*. No Capítulo 8, são investigadas formas de otimização das configurações de registro apresentadas. Por fim, no Capítulo 9, são apresentadas as conclusões do estudo e possibilidades para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentadas diversas abordagens utilizadas para realizar o alinhamento de nuvens de pontos 3D provenientes de diferentes fontes, incluindo métodos baseados em otimização, aprendizado de características e aprendizado de ponta a ponta. Além disso, são exploradas as principais características dos descritores geométricos de superfície e suas aplicações no processo de seleção de pontos ou regiões adequadas para o registro. Ademais, são apresentadas as métricas de avaliação utilizadas para mensurar a qualidade dos alinhamentos obtidos por meio das técnicas investigadas, fornecendo critérios objetivos para a seleção e comparação dos resultados. A compreensão desses conceitos é essencial para o desenvolvimento das estratégias de registro abordadas nos capítulos subsequentes e para o aprimoramento geral das técnicas de alinhamento de nuvens de pontos 3D.

2.1 Técnicas de alinhamento de nuvens de pontos 3D

Diversas abordagens têm sido propostas na literatura especializada para resolver o desafiador problema do alinhamento de nuvens de pontos 3D. Devido à complexidade envolvida na tarefa de alinhar com precisão modelos com características diversas, é comum que cada solução se concentre em abordar o problema de alinhamento para conjuntos específicos de nuvens de pontos. A maioria desses métodos de registro é desenvolvida com base na minimização do erro de projeção geométrica por meio de dois processos principais: busca de correspondências e estimativa de transformação (HUANG *et al.*, 2021).

O algoritmo de registro *Iterative Closest Point* (ICP), proposto por Besl e McKay (1992), tem sido amplamente utilizado como referência no alinhamento de nuvens de pontos 3D, tanto na área de pesquisa quanto na indústria (PARK *et al.*, 2017). O ICP possui um grande número de variantes, incluindo o *ICP ponto-à-ponto* (ICP_{p2p}), *ICP ponto-ao-plano* (ICP_{p2pl}) (CHEN; MEDIONI, 1992) e *Generalized-ICP* (GICP) (SEGAL *et al.*, 2009). O ICP_{p2p} é a versão mais simples do algoritmo, onde os pontos correspondentes entre os pares de nuvens de pontos são encontrados com base na distância euclidiana mínima. O ICP_{p2pl} estende o ICP_{p2p} ao considerar não apenas os pontos correspondentes, mas também os planos associados a esses pontos. Em vez de minimizar apenas a distância euclidiana entre os pontos, o ICP_{p2pl} minimiza a distância entre o ponto da nuvem de pontos de origem e o plano correspondente na nuvem de pontos de destino. O GICP é um algoritmo que combina o ICP_{p2p} e o ICP_{p2pl} .

linha (ICP_{p2l}) (SEGAL *et al.*, 2009) em um *framework* probabilístico unificado. Ele ajusta os pesos das distâncias ponto-à-ponto e ponto-à-linha para otimizar a correspondência, levando em consideração as informações das nuvens de pontos (SI *et al.*, 2022).

Os métodos baseados em redes neurais para o registro de nuvens de pontos 3D representam uma abordagem alternativa aos métodos clássicos de otimização, como o ICP. Esses métodos exploram o uso de redes neurais profundas para aprender características robustas e realizar a correspondência de pontos entre os conjuntos de pontos a serem alinhados. Ao aprender a correspondência de características, a etapa de registro pode ser simplificada. Normalmente, um método simples, como o *Random Sample Consensus* (RANSAC), é utilizado para finalizar a estimativa da matriz de transformação, levando em consideração as correspondências encontradas pela rede neural (HUANG *et al.*, 2021).

O PointNet, introduzido por Qi *et al.* (2017a), propôs o uso de redes neurais profundas para processar nuvens de pontos brutas. Desde então, houve um crescente interesse na aplicação do aprendizado profundo nesse contexto. O PointNet obteve resultados de ponta em tarefas de classificação e segmentação, mesmo com uma arquitetura simples (BELLO *et al.*, 2020). Sua relevância é destacada pelo grande número de trabalhos acadêmicos que a citam (11389¹) e é considerado um dos pilares do aprendizado profundo para o processamento de nuvens de pontos brutas.

Além do PointNet, várias outras arquiteturas foram propostas com base em seus conceitos, abrindo caminho para uma variedade de aplicações. O PointNet++ (QI *et al.*, 2017b) expande os conceitos da sua predecessora, permitindo a computação de regiões locais de forma hierárquica. Já o PointNetLK (AOKI *et al.*, 2019) foi projetada exclusivamente para lidar com o desafio do registro de nuvens de pontos 3D. O RPM-Net (YEW; LEE, 2020), por sua vez, é uma variante adaptada do PointNet que aborda o problema de registro parcial de nuvens de pontos, incorporando recursos adicionais para enfrentar os desafios específicos desse cenário. O PointCNN (LI *et al.*, 2018) é uma variação do PointNet que introduz uma camada de convolução especializada para operar diretamente em nuvens de pontos. Já o PointConv (WU *et al.*, 2019) estende e aprimora o PointNet, acrescentando uma camada de convolução adaptativa que possibilita uma representação mais rica e flexível dos dados de nuvens de pontos. Além disso, o DGCNN (WANG *et al.*, 2019) expande as capacidades do PointNet ao incorporar convoluções em grafos dinâmicos, aprimorando o processamento de nuvens de pontos.

¹ Fonte: Google Acadêmico (<https://scholar.google.com/>). Acesso em: 12 de junho de 2023.

Embora os métodos sofisticados de aprendizado profundo sejam uma tendência promissora, eles apresentam algumas limitações significativas. Esses métodos dependem de um grande conjunto de dados de treinamento e seu desempenho pode cair drasticamente em cenas desconhecidas (HUANG *et al.*, 2021). Diante disso, outras abordagens de pesquisa buscam melhorar a qualidade dos conjuntos de pontos utilizados nos algoritmos de registro por meio de *pipelines* de registro que combinam estratégias de pré-processamento capazes de aprimorar o alinhamento dos pontos com os algoritmos de registro. Estratégias baseadas em particionamento, como o *Cloud-Partitioning ICP* (CP-ICP) (PEREIRA *et al.*, 2015) e *Uniaxial Partitioning Strategy* (UPS) (NETO *et al.*, 2022), visam dividir o par de nuvens de pontos (*source* e *target*) em subnuvens ou partições e, em seguida, realizar o alinhamento iterativo dessas partições, submetendo-as ao algoritmo de registro. Outras técnicas buscam agregar informações contextuais aos pontos por meio da extração de características, como o *Fast Point Feature Histograms* (FPFH) (SUN *et al.*, 2023; RUSU *et al.*, 2009), SHOT (TOMBARI *et al.*, 2010) e descritores de superfície (WEINMANN, 2013). Essas abordagens têm como objetivo enriquecer a representação dos pontos, levando em consideração informações adicionais que podem auxiliar no processo de registro.

Para uma compreensão mais abrangente e detalhada das estratégias e conceitos discutidos nesta seção, é recomendado que os leitores consultem os seguintes estudos secundários: Si *et al.* (2022), Huang *et al.* (2021), Bello *et al.* (2020), Guo *et al.* (2020), Pomerleau *et al.* (2015), Tam *et al.* (2012). Além desses estudos, em um trabalho anterior (SOUZA *et al.*, 2022), investigamos outras abordagens de particionamento e seleção de regiões relevantes para o registro de nuvens de pontos 3D. Esses trabalhos fornecem uma revisão abrangente do assunto, abordando diversas técnicas e perspectivas relevantes.

2.2 Descritores geométricos de superfície

As nuvens de pontos 3D adquiridas por sensores de profundidade, como o LiDAR (GIONGO *et al.*, 2010), geralmente contêm apenas informações das coordenadas X, Y e Z dos pontos. Embora essas coordenadas sejam suficientes para representar a superfície do objeto ou cena capturada, elas não são adequadas para identificar a correspondência entre regiões similares em diferentes capturas do mesmo objeto ou cena, onde as coordenadas de um mesmo ponto podem ser diferentes.

No contexto do registro de nuvens de pontos, é comum utilizar estratégias como o K -

Nearest Neighbors (KNN) para encontrar correspondências entre pontos das nuvens de origem (*source*) e destino (*target*), levando em consideração apenas as coordenadas 3D. No entanto, essa abordagem enfrenta desafios devido à falta de informações que caracterizem os pontos em relação à sua localização na superfície do objeto. Para superar essa limitação, é comum empregar estratégias que avaliam a geometria local dos pontos, a fim de descrever de forma adequada cada ponto em termos da região em que está localizado (DAI; CHEN, 2022; WANG; YUAN, 2010; GUMHOLD *et al.*, 2001). Essas estratégias buscam extrair características adicionais dos pontos além das coordenadas 3D, proporcionando uma representação mais completa e discriminativa dos pontos para o processo de registro.

Inspirados por Weinmann (2013), utilizamos os descritores geométricos do tensor de estrutura 3D (JUTZI; GROSS, 2009) para obter informações sobre a forma, orientação e curvatura local dos pontos. Esses descritores são calculados a partir dos autovalores $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ e autovetores $e_1, e_2, e_3 \in R^3$ da matriz de covariância da vizinhança em torno dos pontos. Existem várias abordagens para a seleção dessa vizinhança, como o uso de um raio fixo (LEE; SCHENK, 2002), um número fixo de vizinhos mais próximos (LALONDE *et al.*, 2006) ou um tamanho ótimo de vizinhança (DEMANTKÉ *et al.*, 2012; GRESSIN, 2012).

Os descritores considerados neste trabalho são:

- **Onivariância (omni)** - mede a isotropia ou a invariância a rotação da superfície e representa a dispersão dos pontos em todas as direções. Um valor alto de onivariância indica uma distribuição isotrópica dos pontos, ou seja, a ausência de uma orientação preferencial na superfície;

$$O_\lambda = \sqrt[3]{\lambda_1 \lambda_2 \lambda_3} \quad (2.1)$$

- **Autoentropia (eige)** - mede a complexidade ou a irregularidade da superfície. Quanto maior for o valor da autoentropia, maior será a variação da superfície em diferentes direções, indicando uma superfície mais complexa ou mais rugosa;

$$E_\lambda = - \sum_{i=1}^3 \lambda_i \ln(\lambda_i) \quad (2.2)$$

- **Anisotropia (anis)** - descreve o grau de desigualdade ou assimetria na distribuição dos pontos em uma superfície e indica a variação preferencial dos pontos em direções específicas. Um valor alto de anisotropia indica uma distribuição assimétrica dos pontos, enquanto um valor baixo indica uma distribuição mais

uniforme;

$$A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1} \quad (2.3)$$

- **Planaridade (plan)** - representa a proporção da curvatura que pode ser atribuída a uma superfície plana em relação à curvatura total da região. Um valor alto de planaridade indica uma região mais plana, enquanto um valor baixo indica uma região mais curva;

$$P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (2.4)$$

- **Linearidade (line)** - indica a proporção da curvatura que pode ser atribuída a uma superfície linear em relação à curvatura total da região. Um valor alto de linearidade indica uma região mais linear, enquanto um valor baixo indica uma região mais curva;

$$L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (2.5)$$

- **Variação de superfície (svar)** - quantifica a variação local da superfície em diferentes escalas e indica a diversidade dos pontos vizinhos em relação a um ponto de referência. A variação de superfície é útil para detectar características distintas ou detalhes finos em uma superfície;

$$C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (2.6)$$

- **Esfericidade (sphe)** - mede o quão esférica é uma região de superfície e representa a proporção da curvatura que pode ser atribuída a uma superfície esférica em relação à curvatura total da região. Um valor alto de esfericidade indica uma região mais esférica, enquanto um valor baixo indica uma região mais alongada ou achatada;

$$C_\lambda = \frac{\lambda_3}{\lambda_1} \quad (2.7)$$

- **Verticalidade (vert)** - indica o quão vertical é uma superfície em relação à direção vertical do sistema de coordenadas e fornece uma medida da inclinação ou orientação vertical da superfície em relação à gravidade ou a um plano de referência específico.

$$V = 1 - |\langle [0, 0, 1], e_3 \rangle| \quad (2.8)$$

2.3 Considerações finais

Neste capítulo, foram abordadas diversas técnicas de registro fundamentadas em abordagens de otimização e aprendizado de características, além de terem sido apresentadas algumas estratégias de extração de características da superfície dos modelos. Os experimentos de registro realizados no âmbito deste trabalho empregam, de forma exclusiva ou em conjunto com outras estratégias de pré-processamento, as variantes do algoritmo ICP discutidas: ICP_{p2p} , ICP_{p2pl} e GICP. Dentre os descritores apresentados, os obtidos do tensor de estrutura 3D serão utilizados em conjunto com esses algoritmos de registro, com o objetivo de atingir um alinhamento de maior qualidade.

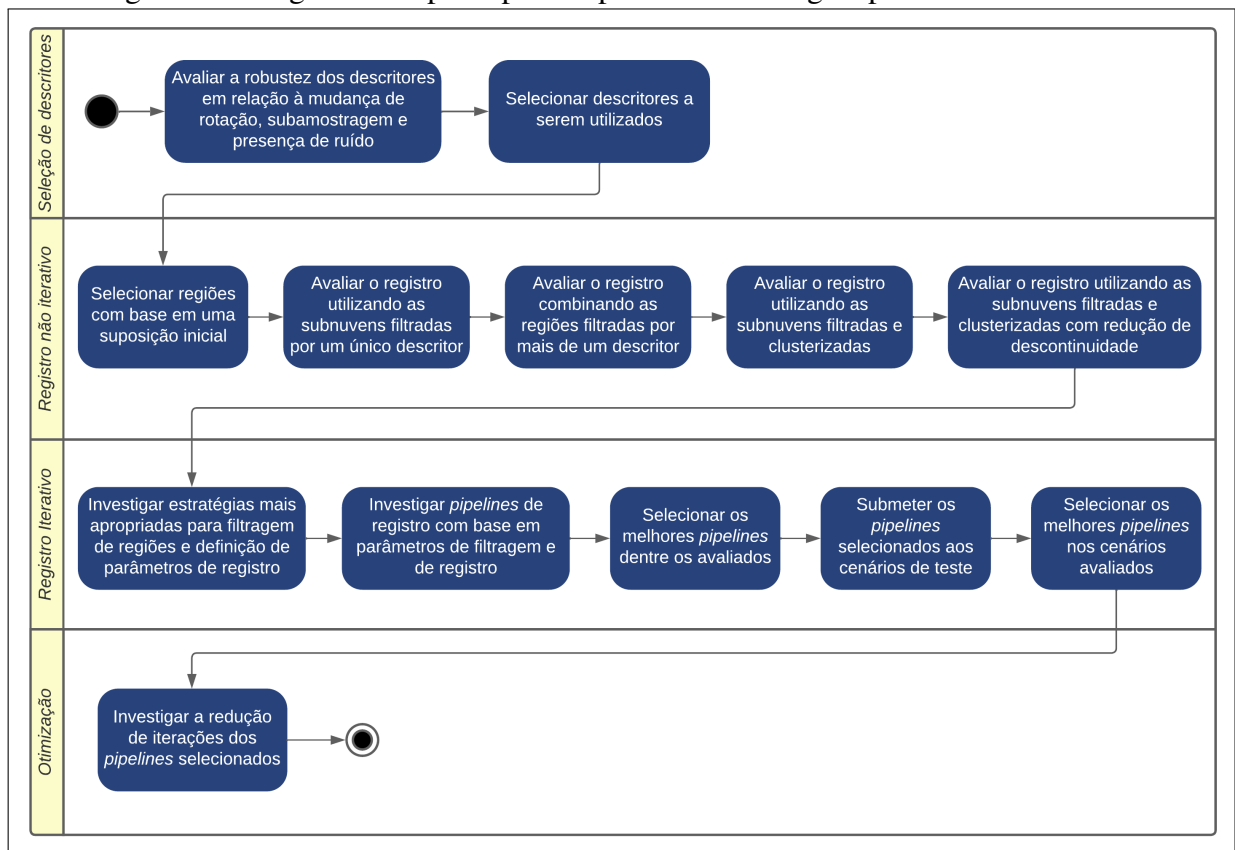
No próximo capítulo, será apresentada em detalhes a metodologia fundamental adotada para a realização das investigações abordadas no contexto deste estudo.

3 METODOLOGIA

Neste capítulo é fornecida uma descrição geral dos métodos que foram empregados na realização dos estudos experimentais apresentados nos próximos capítulos subsequentes. Além disso, abordamos os conjuntos de amostras que foram utilizados e a estratégia de avaliação que foi aplicada.

A Figura 3 exibe um diagrama de alto nível que ilustra as principais etapas da metodologia empregada neste estudo.

Figura 3 – Diagrama das principais etapas da metodologia aplicada.



Fonte: elaborada pelo autor.

3.1 Cálculo dos descritores

Ao longo de todos os experimentos conduzidos neste estudo, uma abordagem uniforme foi adotada para o cálculo dos descritores de superfície apresentados na Seção 2.2. Para essa finalidade, foi estabelecida uma vizinhança fixa correspondente a 5% do tamanho total do conjunto de pontos, com base em uma avaliação empírica que demonstrou ser esta proporção suficiente para capturar informações locais relevantes nos modelos analisados. No cálculo dos

descritores de superfície, utilizamos os autovalores normalizados pela soma (WEINMANN *et al.*, 2015), conforme apresentado na Equação 3.1, onde os valores de cada característica pontual são ajustados para o intervalo entre 0 e 1. Essa normalização é interessante, visto que as formas das superfícies podem ser alteradas por diversos fatores, como rotações, translações ou mudanças de escala (HACKEL *et al.*, 2016; WEINMANN, 2013). Além disso, ao normalizar os autovalores, torna-se viável a comparação direta dos descritores de superfície entre diferentes objetos, mesmo que esses objetos apresentem tamanhos ou geometrias distintas.

$$\hat{\lambda}_i = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \lambda_3}, i \in \{1, 2, 3\}. \quad (3.1)$$

3.2 Algoritmos de registro

Para avaliar o alinhamento em ambos os experimentos realizadas, após a obtenção das subnuvens filtradas, é necessário submetê-las à algoritmos de registro. Nesse contexto, foram empregados três algoritmos clássicos de registro: o ICP_{p2p} , o ICP_{p2pl} e o GICP. Nos experimentos conduzidos nos Capítulos 4 e 5, foi adotada a variante sem centralização dos centroides das subnuvens, que corresponde à implementação padrão desses algoritmos. Nos demais experimentos, que representam os *pipelines* de registro mais complexos (Capítulos 6 e 7), foram adotadas variantes com centralização desses mesmos algoritmos. Esses algoritmos, tanto com centralização quanto sem centralização, também foram empregados para obter o alinhamento de referência utilizando as amostras originais, a fim de possibilitar a comparação com as estratégias investigadas.

3.3 Métrica de avaliação

Embora o *Root Mean Squared Error* (RMSE) seja a métrica comumente utilizada para avaliar o desalinhamento entre nuvens de pontos, ela pode não refletir com exatidão a qualidade do alinhamento encontrado. Isso ocorre porque ela exige que os pontos sobrepostos sejam pareados corretamente e que as eventuais regiões não sobrepostas sejam desconsideradas, de forma a não influenciar negativamente o valor resultante. Para superar esse problema, o RMSE considera um valor limiar de distância, acima do qual os pares de pontos são descartados. Em um cenário ideal, esse limiar deveria garantir que os pares de pontos correspondessem apenas a regiões sobrepostas. No entanto, na prática, um valor de limiar que se aproxime do valor ideal é difícil de determinar, especialmente quando não se tem nenhum conhecimento prévio sobre as

características das nuvens de entrada (XU *et al.*, 2021; BUENO *et al.*, 2017).

Neste trabalho, as investigações foram conduzidas com base em transformações conhecidas, visando assegurar uma análise mais precisa dos alinhamentos avaliados. Para alcançar esse objetivo, optou-se por empregar a verdade fundamental (*ground truth*), que fornece informações precisas sobre o desalinhamento entre as nuvens de pontos registradas. Com a verdade fundamental, é possível obter o erro de rotação (E_{rot}) e translação (E_{trl}) do alinhamento resultante do *pipeline* de registro, que retrata com exatidão o desalinhamento, ao contrário do RMSE. No entanto, como essas duas medidas possuem ordens de grandeza diferentes, não é adequado, por exemplo, resumir o erro de transformação com uma média simples. Nesse sentido, é necessário adotar uma estratégia para torná-las comparáveis, a fim de quantificar a qualidade do alinhamento resultante. Para sintetizar o erro de rotação e translação em um valor que represente o erro de transformação (E_{trf}), foi utilizada a seguinte estratégia para manter as duas medidas em escalas compatíveis:

$$E_{trf} = \frac{E_{rot} + W_{trl}E_{trl}}{2}. \quad (3.2)$$

O fator de ajuste de escala atribuído ao erro de translação (W_{trl}) é obtido por meio de uma estratégia de desalinhamento da nuvem *target*. Essa estratégia consiste em aplicar uma rotação arbitrária pequena (dois graus) à nuvem *target* e, em seguida:

- medir o ângulo de rotação equivalente (θ_{ref}) entre a nuvem rotacionada e a original;
- calcular a distância euclidiana média (d_{ref}) entre pontos da nuvem rotacionada (Q) e da nuvem original (P), conforme a Equação 3.3:

$$d_{ref} = \frac{1}{N} \sum_{i=1}^N \| p_i - q_i \|, \quad (3.3)$$

onde N é o tamanho da nuvem *target*, $p_i \in P$ e $q_i \in Q$;

- obter o fator de ajuste de escala para o erro de translação, conforme a Equação 3.4:

$$W_{trl} = \frac{\theta_{ref}}{d_{ref}} \quad (3.4)$$

Embora o erro de transformação possa ser utilizado para comparação e classificação de amostras, é difícil determinar a qualidade do alinhamento resultante somente através desse valor. Por esse motivo, neste trabalho, adotou-se como critério de aceitabilidade um erro de

transformação igual ou inferior ao erro obtido por um ângulo de rotação de três graus (ou 0.0261799). Para os propósitos deste trabalho, esse critério é considerado adequado para garantir um alinhamento satisfatório das nuvens de pontos.

Além do erro de transformação, algumas tabelas também apresentam o valor de RMSE para o alinhamento final. A distância máxima entre os pontos correspondentes utilizada no cálculo do RMSE foi definida como a distância média (d_{ref}) apresentada na Equação 3.3. Em alguns casos, essa distância não é suficiente para encontrar pares de pontos muito distantes resultantes de alinhamentos ruins. Nesses casos, o valor do RMSE é apresentado como “*inf*”, indicando uma baixa qualidade de alinhamento.

3.4 Amostras

No contexto das investigações conduzidas nos Capítulos 5 e 6, que representam explorações iniciais, foi empregado um conjunto restrito de modelos de objetos disponíveis no Repositório de Digitalização 3D da Universidade de Stanford (STANFORD, 2014). Embora esses conjuntos de dados envolvam modelos de objetos simples, eles apresentam características de interesse, como capturas parciais exibindo variações em níveis de detalhe e diversas intensidades de auto-occlusões. Nos experimentos avançados relatados no Capítulo 7, além dos modelos previamente utilizados, também incorporamos conjuntos variados de nuvens de pontos 3D (ALEOTTI *et al.*, 2014; MIAN *et al.*, 2006; EPFL, 2014; NÜCHTER; LINGEMANN, 2016), possibilitando uma ampla diversidade de modelos para avaliação.

Além das representações originais, foram geradas imagens adicionais a partir das nuvens de pontos originais, com o intuito de introduzir características específicas de interesse. Esses detalhes estão devidamente documentados nos testes correspondentes. Ademais, visando viabilizar a execução dos experimentos em nosso ambiente de testes, todas as nuvens de pontos contendo mais de 300 mil pontos foram subamostradas utilizando um filtro de voxelização, de modo a ajustar o tamanho das nuvens filtradas próximo a esse limite.

Em certos casos, a sobreposição entre pares de cenas no conjunto de dados original mostrou-se insignificante. Como resultado, para cada sequência de três capturas subsequentes (P , Q , R), optamos por realizar a união dois-a-dois dos conjuntos de pontos (PQ , QR), resultando em um par de amostras a ser registrado onde a nuvem intermediária (Q) desempenha o papel de região de sobreposição entre os pares de nuvens mescladas.

3.5 Ambiente de teste

A configuração de hardware utilizada para executar todos os testes consistiu de um processador AMD^R RyzenTM 7600X de seis núcleos com duas *threads* cada, totalizando doze *threads*, com uma velocidade máxima de *clock* de 5.3GHz, duas memória *Double Data Rate 5* (DDR5) de 16 GB com uma frequência de 5600MHz e uma placa de vídeo Nvidia^R GeForce RTXTM 3060 Ti.

Para a implementação dos cenários de teste, a versão 3.9.16 da linguagem de programação *Python* foi escolhida devido à sua simplicidade, agilidade como ferramenta de prototipação e compatibilidade com as bibliotecas de processamento de nuvens de pontos utilizadas. A distribuição *Anaconda^R* para o sistema operacional *Windows 11* foi utilizada em conjunto com a biblioteca de processamento de dados 3D de código aberto, *Open3D*. Esta biblioteca disponibiliza diversas rotinas e algoritmos de processamento de imagens 3D, permitindo concentrar os esforços no desenvolvimento da camada de software necessária para os testes.

4 AVALIAÇÃO DA ROBUSTEZ DOS DESCRITORES DE SUPERFÍCIE EM DIFERENTES CONTEXTOS

A análise do comportamento dos descritores de superfície em diversas condições é importância para compreender sua robustez e capacidade de capturar informações relevantes e similares entre pares de nuvens de pontos. O registro preciso de nuvens de pontos requer que os descritores sejam capazes de manter valores consistentes mesmo diante de desafios como mudanças de rotação, subamostragem e presença de ruído.

Transformações geométricas, como a rotação, têm o potencial de afetar a forma e a orientação dos pontos, o que torna crucial avaliar a capacidade dos descritores em preservar as características das regiões correspondentes mesmo diante dessas transformações. A subamostragem do conjunto de pontos pode resultar em uma diminuição na densidade de pontos, acarretando a perda de informações relevantes. Além disso, a presença de ruído nos dados pode interferir na precisão dos descritores, uma vez que pontos ruidosos podem introduzir informações indesejadas que alteram a superfície do objeto.

No âmbito deste estudo, o objetivo principal é empregar os descritores de superfície para selecionar regiões mais adequadas ao processo de registro. Portanto, a avaliação desses descritores em diferentes condições proporcionará uma compreensão mais aprofundada de sua eficácia e confiabilidade nesse contexto específico. Essa análise desempenha um papel fundamental na identificação das limitações de uso dos descritores geométricos de superfície, além de estabelecer diretrizes para o uso adequado dessas técnicas no registro de nuvens de pontos.

Para os experimentos descritos nas subseções a seguir, foram utilizadas os modelos dos objetos *Bunny*, *Buddha* e *Dragon* do Repositório de Digitalização 3D da Universidade de Stanford (STANFORD, 2014), na pose inicial (0°).

4.1 Mudança de rotação

Para analisar o efeito da mudança de rotação sobre os valores dos descritores, realizamos experimentos com amostras adicionais em cinco diferentes rotações para cada objeto. Foram utilizados quatro conjuntos de rotações com ângulos fixos (30° , 60° , 90° e 120°) aplicados nos três eixos ($R_x = R_y = R_z$), e uma amostra com rotações arbitrárias em cada eixo ($R_x = 37^\circ$, $R_y = 21^\circ$, $R_z = 82^\circ$). Todas as rotações foram realizadas utilizando ângulos de Euler na ordem *XYZ*. A fim de avaliar a diferença entre as amostras rotacionadas e a nuvem original, calculamos as diferenças médias ponto à ponto entre elas e apresentamos os resultados no mapa

de calor exibido na Figura 4.

Figura 4 – Mapa de calor da diferença média ponto à ponto por descritor das nuvens originais e rotacionadas.

Buddha	R _{xyz} 30°	6.8e-17	1.6e-16	9.8e-17	5.7e-16	6.0e-16	4.4e-17	9.2e-17	3.2e-01
	R _{xyz} 60°	7.2e-17	1.7e-16	1.0e-16	5.8e-16	6.0e-16	4.6e-17	9.6e-17	4.5e-01
	R _{xyz} 90°	7.5e-17	1.8e-16	1.1e-16	6.6e-16	6.9e-16	5.0e-17	1.1e-16	4.6e-01
	R _{xyz} 120°	7.2e-17	1.7e-16	1.0e-16	5.7e-16	6.0e-16	4.7e-17	9.7e-17	4.7e-01
	R _{xyz} Arbit.	6.9e-17	1.6e-16	1.0e-16	5.7e-16	6.0e-16	4.5e-17	9.4e-17	3.0e-01
Bunny	R _{xyz} 30°	6.6e-08	1.3e-07	7.5e-08	1.3e-06	1.4e-06	2.5e-08	7.5e-08	2.5e-01
	R _{xyz} 60°	7.8e-08	1.4e-07	8.3e-08	1.6e-06	1.6e-06	3.0e-08	8.3e-08	4.8e-01
	R _{xyz} 90°	6.4e-08	1.2e-07	7.8e-08	1.4e-06	1.5e-06	2.6e-08	7.8e-08	5.0e-01
	R _{xyz} 120°	7.4e-08	1.5e-07	9.8e-08	1.5e-06	1.6e-06	2.8e-08	9.8e-08	5.2e-01
	R _{xyz} Arbit.	8.1e-08	1.4e-07	8.7e-08	1.7e-06	1.7e-06	3.3e-08	8.7e-08	2.4e-01
Dragon	R _{xyz} 30°	6.9e-17	1.7e-16	1.0e-16	5.6e-16	5.8e-16	4.7e-17	9.6e-17	2.7e-01
	R _{xyz} 60°	7.2e-17	1.7e-16	1.1e-16	5.4e-16	5.7e-16	4.8e-17	9.8e-17	6.0e-01
	R _{xyz} 90°	7.5e-17	1.8e-16	1.1e-16	6.0e-16	6.3e-16	5.0e-17	1.0e-16	5.7e-01
	R _{xyz} 120°	7.1e-17	1.7e-16	1.1e-16	5.4e-16	5.7e-16	4.8e-17	9.8e-17	6.4e-01
	R _{xyz} Arbit.	6.5e-17	1.6e-16	9.9e-17	5.3e-16	5.6e-16	4.5e-17	9.2e-17	2.4e-01
		omni	eige	anis	plan	line	svar	sphe	vert
		Descritor							

Fonte: elaborada pelo autor.

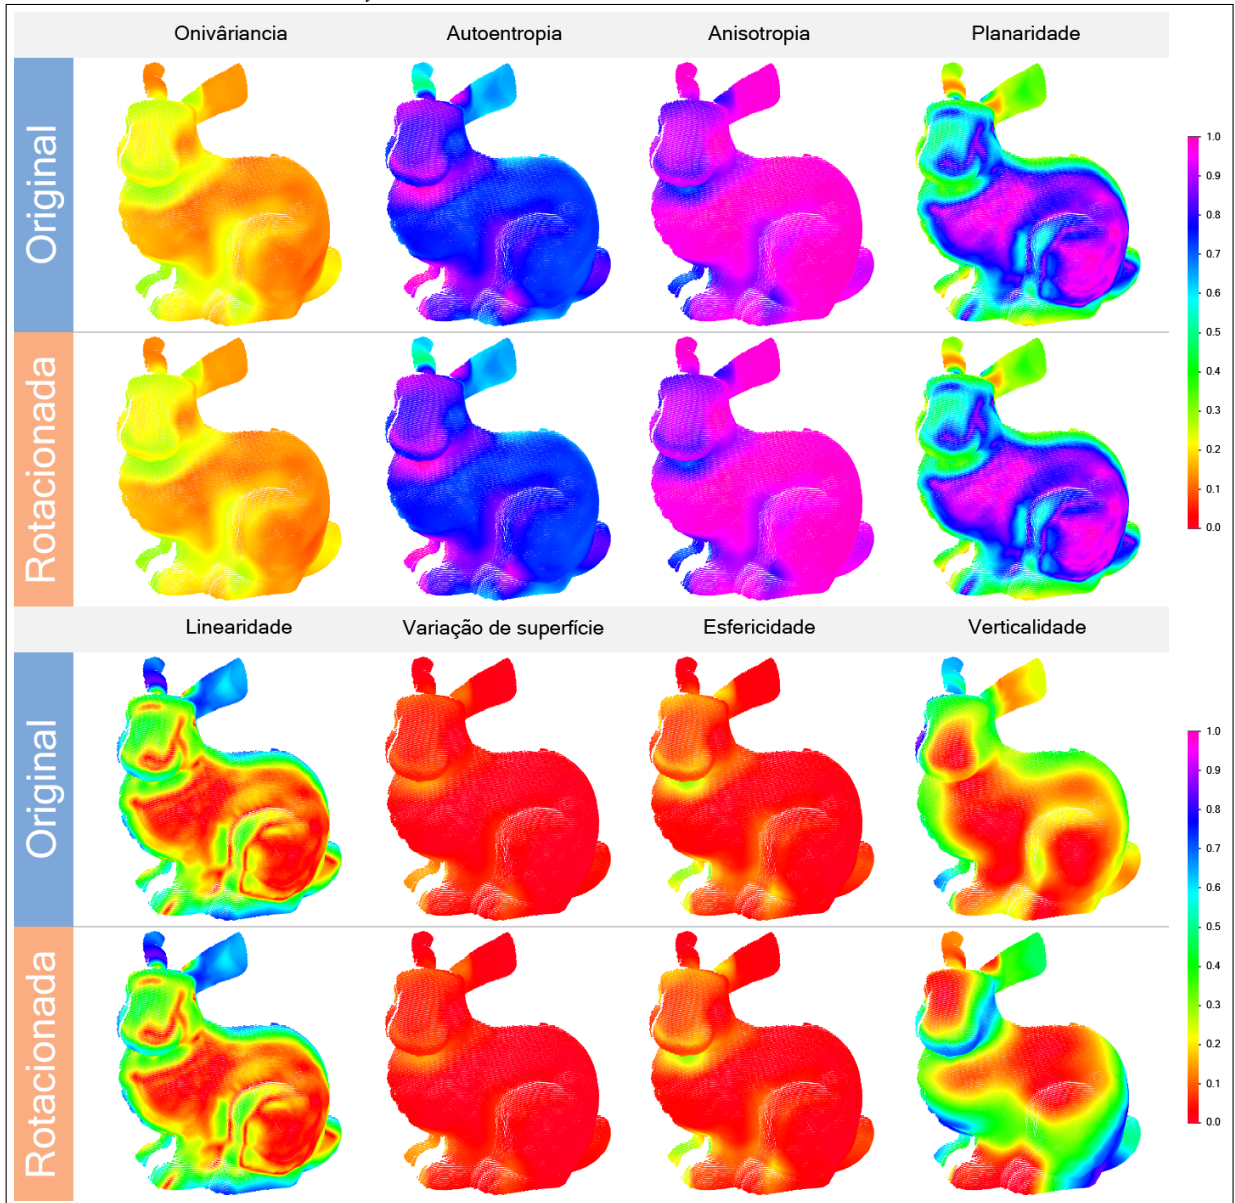
Nota: valores em negrito indicam as menores diferenças por descritor, considerando uma margem de erro de 1%.

Ao analisar os resultados, podemos observar que a diferença média entre os valores obtidos utilizando as nuvens originais e a nuvens rotacionadas são insignificantes para a maioria dos descritores, com exceção da verticalidade. Independentemente da rotação aplicada, os descritores apresentam pouca variação nos valores. Os objetos *Dragon* e *Buddha* mostraram diferenças médias de várias ordens de magnitude menores em comparação ao objeto *Bunny*. No entanto, mesmo para o objeto *Bunny*, a diferença média na ordem de 10^{-6} obtida pelo descritor de linearidade ainda resulta em uma seleção de regiões muito semelhantes (ver Figura 5).

Os valores obtidos utilizando a verticalidade nas amostras apresentam uma grande discrepância em relação aos demais descritores, indicando uma sensibilidade à rotação, como evidenciado na Figura 5. Essa discrepância é esperada, uma vez que a verticalidade é diretamente influenciada pela magnitude da componente Z do vetor de coordenadas. Portanto, a verticalidade não é um bom descritor para selecionar regiões similares em nuvens de pontos rotacionadas, e, conseqüentemente, não é adequada para o processo de registro, onde a correção de rotação é uma das principais tarefas a serem realizadas.

Nas Subseções 7.2.1 e 7.2.2, investigaremos detalhadamente o registro de nuvens de pontos com rotações, abrangendo amostras com sobreposição parcial.

Figura 5 – Mapa de calor dos valores obtidos por descritor nas nuvens originais e rotacionadas arbitrariamente ($R_x = 37^\circ, R_y = 21^\circ, R_z = 82^\circ$).



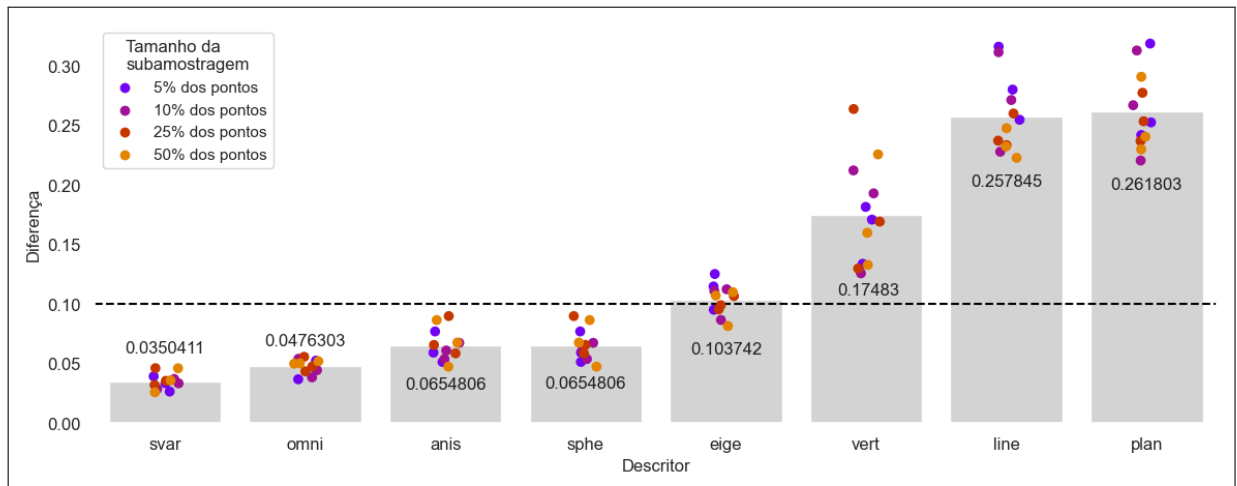
Fonte: elaborada pelo autor.

4.2 Subamostragem

O objetivo deste experimento é avaliar se a seleção de regiões utilizando descritores de superfície mantém alguma similaridade entre amostras com diferentes densidades de pontos. Para isso, as nuvens de pontos foram subamostradas utilizando o algoritmo *Farthest Point Sampling* (FPS) (ELDAR *et al.*, 1997), em que foram geradas nuvens de pontos com tamanhos correspondentes a 5%, 10%, 25% e 50% da nuvem de pontos original. O algoritmo FPS tem a característica de escolher pontos que estejam espacialmente bem distribuídos, capturando a diversidade e as características essenciais da nuvem de pontos original.

Considerando que o algoritmo FPS seleciona os pontos da nuvem original sem alterá-los, é possível calcular a diferença entre os pontos na nuvem subamostrada e seus correspondentes na nuvem original. Os resultados das diferenças médias por descritor estão apresentados no gráfico da Figura 6. Observamos que nenhum dos descritores obteve diferenças tão pequenas quanto aquelas obtidas no experimento da subseção anterior. Os descritores de variação de superfície, omnivariância, anisotropia e esfericidade conseguiram obter diferenças inferiores a 0.1 em todas as amostras avaliadas, e podem, portanto, ser considerados valores minimamente semelhantes. Além disso, ao analisarmos aspectos relativos à severidade da subamostragem, notamos que não há uma grande discrepância entre os valores obtidos nos níveis severos e mais brandos de subamostragem, especialmente nos descritores que obtiveram as cinco menores diferenças médias.

Figura 6 – Gráfico diferença média ponto à ponto por descritor das nuvens originais e subamostradas.




Fonte: elaborada pelo autor.

Nota: os pontos indicam o a diferença média por amostra (objeto e nível de subamostragem). A linha tracejada representa o limiar para um erro de transformação aceitável.

Na Figura 7, são apresentadas as amostras do objeto *Dragon* com cores atribuídas aos valores obtidos por cada ponto da nuvem nos oito descritores avaliados. É possível observar visualmente que, com base no mapa de cores escolhido, há uma relativa consistência nos valores obtidos na maioria das regiões em todas as amostras, especialmente nas subamostragens que possuem mais de 10% da quantidade de pontos da nuvem original. É natural esperar alguma divergência em amostras severamente subamostradas, porém mesmo nesses casos é possível notar, por inspeção visual, uma boa correspondência entre as regiões coloridas, mesmo que a diferença numérica não seja tão expressiva.

Figura 7 – Mapa de calor dos valores obtidos por descritor nas nuvens original e subamostradas do objeto *Dragon*.



Fonte: elaborada pelo autor.

Nota: nas nuvens de pontos menos densas, o tamanho dos pontos na visualização foi ampliado a fim de facilitar a identificação das regiões. Os valores percentuais atribuídos à subamostragem denotam a proporção dos pontos selecionados da nuvem original.

Embora haja uma diferença considerável entre os valores obtidos para alguns descritores na nuvem original e subamostrada, é importante destacar que no contexto do registro, ambas as entradas devem ser subamostradas. Portanto, o importante é que haja consistência entre as regiões do par de nuvens, o que pode ser observado na inspeção visual dos resultados. Em vista disso, podemos especular que a seleção de regiões subamostradas resultará em alinhamentos próximos aos obtidos pelas nuvens originais. Essa investigação será aprofundada na Subseção 7.2.4.

4.3 Ruído

As nuvens de pontos 3D podem fornecer informações detalhadas sobre a forma e a estrutura dos objetos e cenas que representam. No entanto, é importante reconhecer que essas nuvens de pontos podem conter imperfeições e serem afetadas por diferentes fontes de ruído, tais como erros de medição, imprecisões do sensor e interferência ambiental. Essas imperfeições podem resultar em modificações significativas na representação da superfície do objeto. Portanto, é de suma importância compreender o impacto desse ruído no cálculo de descritores de superfície.

Para simular a presença de ruído com características semelhantes às de um sensor real, optou-se pelo uso do ruído gaussiano. Esse tipo de ruído, seguindo uma distribuição normal, é capaz de modelar de maneira mais precisa a variabilidade encontrada nos sensores de profundidade. Neste estudo, foram adicionados cinco níveis de intensidade de ruído gaussiano, com média zero e desvios-padrão determinados conforme a Equação 4.1, aos pontos das amostras. É significativo mencionar que não foram gerados novos pontos, apenas adicionamos ruído aos pontos existentes. Essa abordagem nos permite obter um valor de ruído proporcional à escala dos objetos avaliados.

Para cada nuvem de pontos P do conjunto de amostras, calculamos o desvio padrão do i -ésimo nível de ruído usando a seguinte fórmula:


$$std_i = \frac{\min(\max(P_x) - \min(P_x), \max(P_y) - \min(P_y), \max(P_z) - \min(P_z))}{w_i}, \quad (4.1)$$

onde $w_i \in \{100, 80, 60, 40, 20\}$ foi determinado empiricamente.

Os resultados apresentados no mapa de calor da Figura 8 indicam que o incremento da severidade do ruído é diretamente proporcional a diferença observada entre as nuvens original e com ruído, em todas amostras. Além disso, podemos notar que apenas os dois últimos níveis

de ruído apresentaram médias superiores a 0.1 em algumas amostras. A variação de superfície foi aquela que apresentou os melhores resultados em um maior número de amostras (60%) indicando a robustez desse descritor quanto a esse tipo de interferência. Esse comportamento pode ser explicado pelo fato de que os valores de variação de superfície obtidos para os pontos das amostras avaliadas não apresentaram uma grande variabilidade, ao contrário dos valores de planaridade, por exemplo.

Figura 8 – Mapa de calor da diferença média ponto à ponto por descritor nas nuvens originais e com ruído.




Fonte: elaborada pelo autor.

Nota: valores em negrito indicam o descritor que obteve a menor diferença por amostra, considerando uma margem de erro de 1%.

A verticalidade é menos afetada pelo ruído gaussiano devido à sua natureza menos suscetível a pequenas flutuações aleatórias introduzidas por esse tipo de ruído. Como o ruído gaussiano não possui um viés específico em direções verticais, as estimativas de orientação vertical não são significativamente afetadas pelas variações adicionadas pelo ruído. Por outro lado, os descritores de superfície que dependem de características em outras direções podem ser mais influenciados pelo ruído gaussiano.

Na Figura 9, são apresentadas as amostras do objeto *Buddha* com cores atribuídas aos valores obtidos por cada descritor. Observa-se que a adição de ruído modifica consideravelmente a superfície do objeto, resultando na suavização ou remoção de detalhes da imagem, principalmente nos níveis mais severos de interferência. Conseqüentemente, amostras com intensidades de ruído acima do terceiro nível ($w_i < 60$) apresentam uma suavização (mesclagem) das menores

Figura 9 – Mapa de calor dos valores obtidos por descritor nas nuvens original e com ruído do objeto *Buddha*.



Fonte: elaborada pelo autor.

regiões destacadas nas nuvens originais. Por exemplo, no nível mais severo de ruído, é notável a modificação das regiões destacadas, especialmente ao analisar os descritores de autoentropia, anisotropia, esfericidade e omnivariância. No entanto, em intensidades menores de ruído, é possível observar uma consistência entre as regiões demarcadas, o que sugere que mesmo nessas situações ainda é viável utilizar os descritores de superfície para selecionar regiões em nuvens com ruído. Essa hipótese será investigada em maior detalhe na Subseção 7.2.3.

4.4 Considerações finais

Neste capítulo, foram realizados experimentos para analisar o comportamento dos descritores de superfície em diferentes condições, incluindo mudanças de rotação, subamostragem e presença de ruído. Os resultados mostram que a maioria dos descritores apresentaram pouca variação de valores, mesmo diante das mudanças de rotação. No entanto, a verticalidade demonstrou ser sensível à rotação, sugerindo que não é um descritor adequado para selecionar regiões similares em nuvens de pontos rotacionadas. Em relação à subamostragem, todos os descritores de superfície mostraram-se capazes de manter alguma similaridade entre amostras com diferentes densidades de pontos, indicando sua robustez nesse aspecto. Quanto ao ruído, observou-se que, em níveis menos severos, os valores calculados para os descritores de superfície apresentaram consistência entre regiões correspondentes. Em resumo, os resultados sugerem que todos os descritores, com exceção da verticalidade, são relativamente robustos e capazes de selecionar regiões similares correspondentes entre nuvens de pontos.

No próximo capítulo, iremos investigar algumas estratégias de registro que utilizam técnicas de filtragem e geração de subnuvens com base nos valores calculados para os descritores de superfície.

5 ANÁLISE DE DIFERENTES ESTRATÉGIAS DE FILTRAGEM DE REGIÕES COM BASE EM DESCRITORES DE SUPERFÍCIE

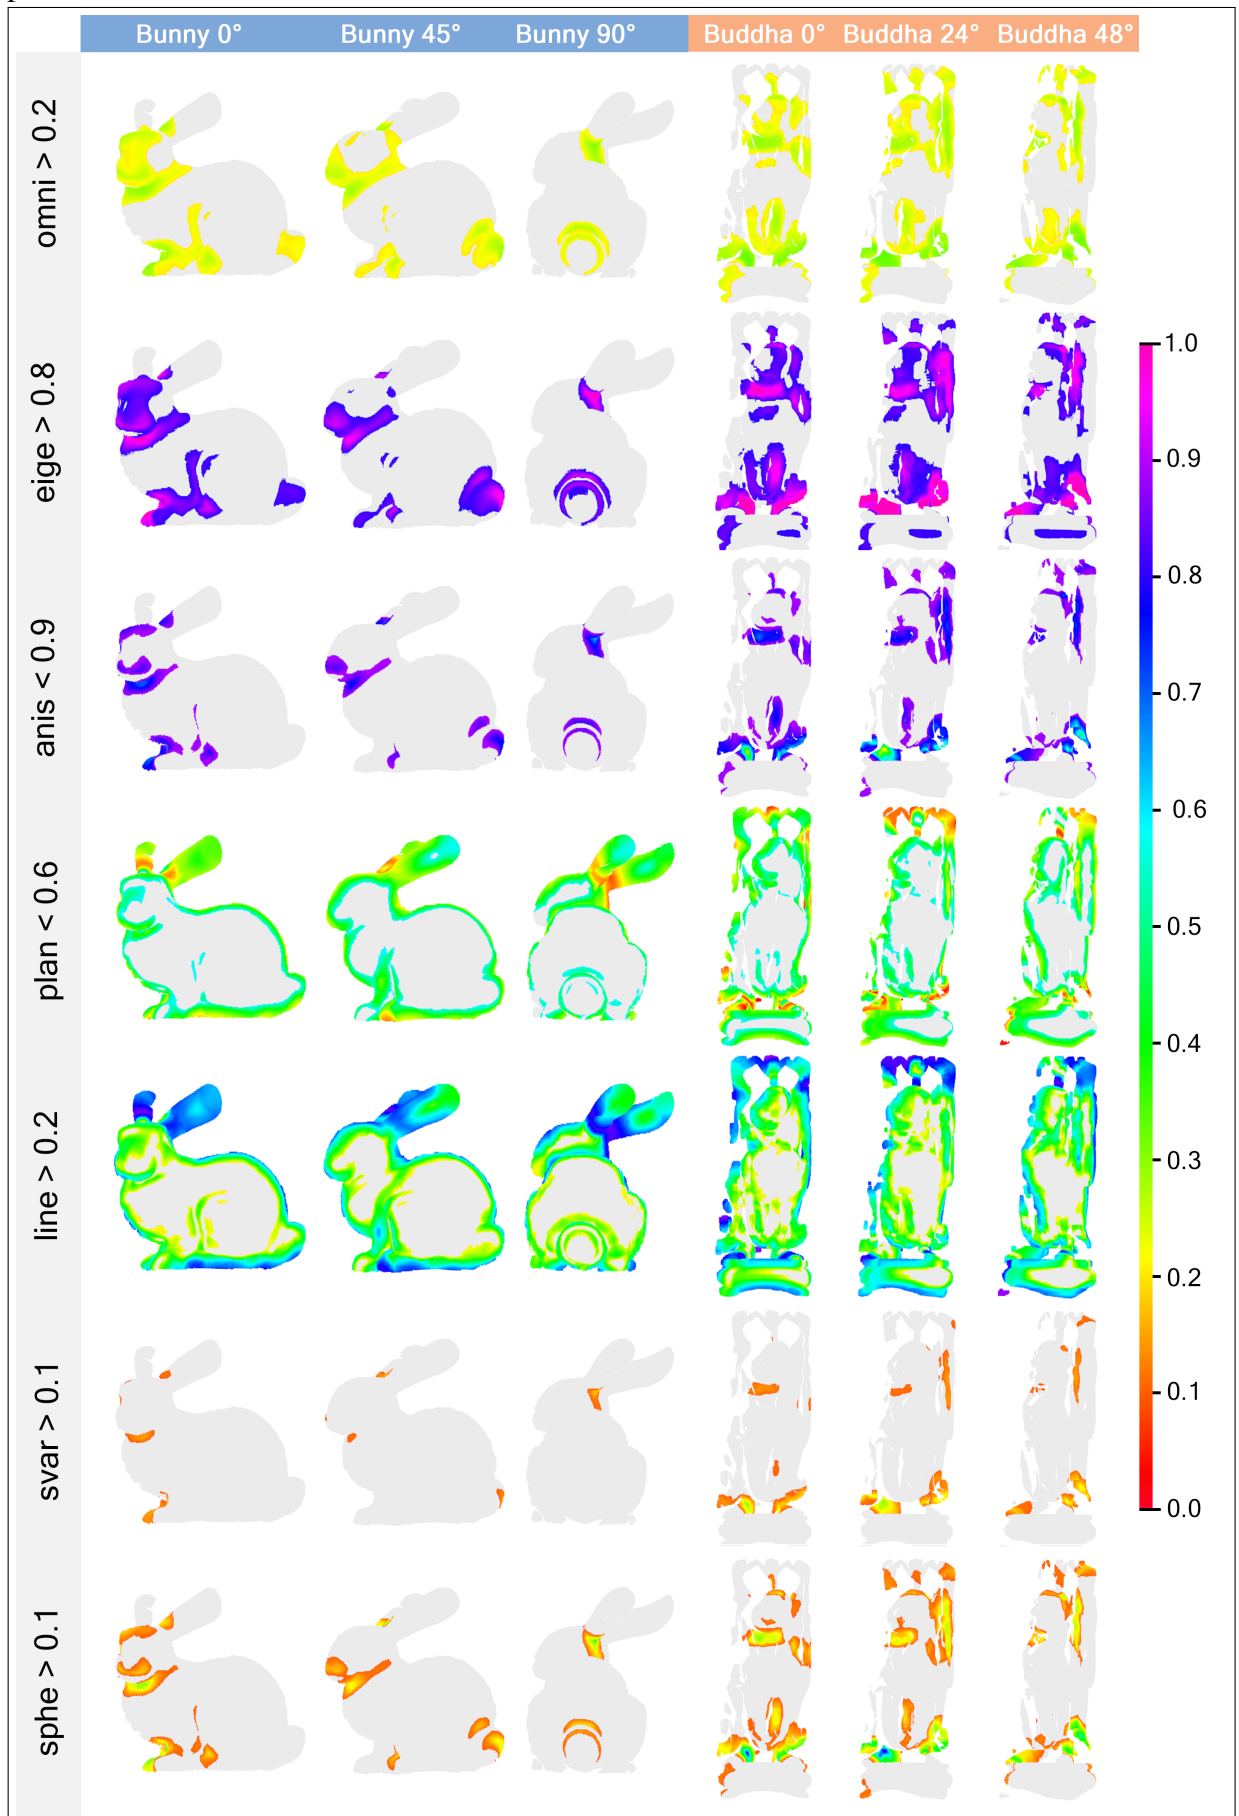
A partir dos resultados obtidos nos testes do capítulo anterior, onde todos os descritores de superfície, exceto a verticalidade, apresentaram valores consistentes em regiões correspondentes dos conjuntos de pontos em cenários típicos de registro, podemos conjecturar que a seleção de regiões com menor redundância de informação pode melhorar a qualidade do alinhamento.

5.1 Filtragem empregando um único descritor

Com base na premissa de que regiões mais complexas, caracterizadas por maior irregularidade e menor planaridade, podem exibir atributos mais discriminativos que favorecem uma correspondência mais precisa entre os pares de nuvens de pontos, resultando em um alinhamento de maior qualidade, realizamos uma etapa de filtragem nos conjuntos de pontos destinados ao registro. Esse processo consistiu na extração dos pontos pertencentes a essas regiões, utilizando valores limiares estabelecidos para cada descritor. Os limiares foram determinados empiricamente, utilizando a amostra *Bunny 0°*, na qual ajustamos o intervalo de filtragem até que as regiões de maior curvatura fossem selecionadas. Em seguida, aplicamos as mesmas filtrações definidas para cada descritor nas amostras *Bunny 0°, 45°, 90°* e *Buddha 0°, 24°, 48°*. Os resultados dessas filtrações e os respectivos valores de limiares utilizados são apresentados na Figura 10.

Após a obtenção das subnuvens filtradas, o processo de registro foi executado para cada um dos dois pares de amostras de cada objeto, sendo então comparados com os alinhamentos obtidos a partir das nuvens originais. Os resultados obtidos, apresentados no mapa de calor da Figura 11, indicam que nenhuma das abordagens avaliadas conseguiu um alinhamento médio satisfatório, tanto para as subnuvens filtradas quanto para as nuvens originais. No entanto, observamos que a filtragem utilizando o descritor de linearidade obteve médias de erro menores em comparação com as amostras sem filtragem em dois dos três algoritmos de registro avaliados. Os registros utilizando o algoritmo GICP apresentaram os menores erros de transformação médios e conseguiram um alinhamento satisfatório em, pelo menos, três dos quatro pares de amostras, com exceção da variação de superfície (*svar*), que obteve um alinhamento satisfatório apenas nas duas das amostras do objeto *Buddha*.

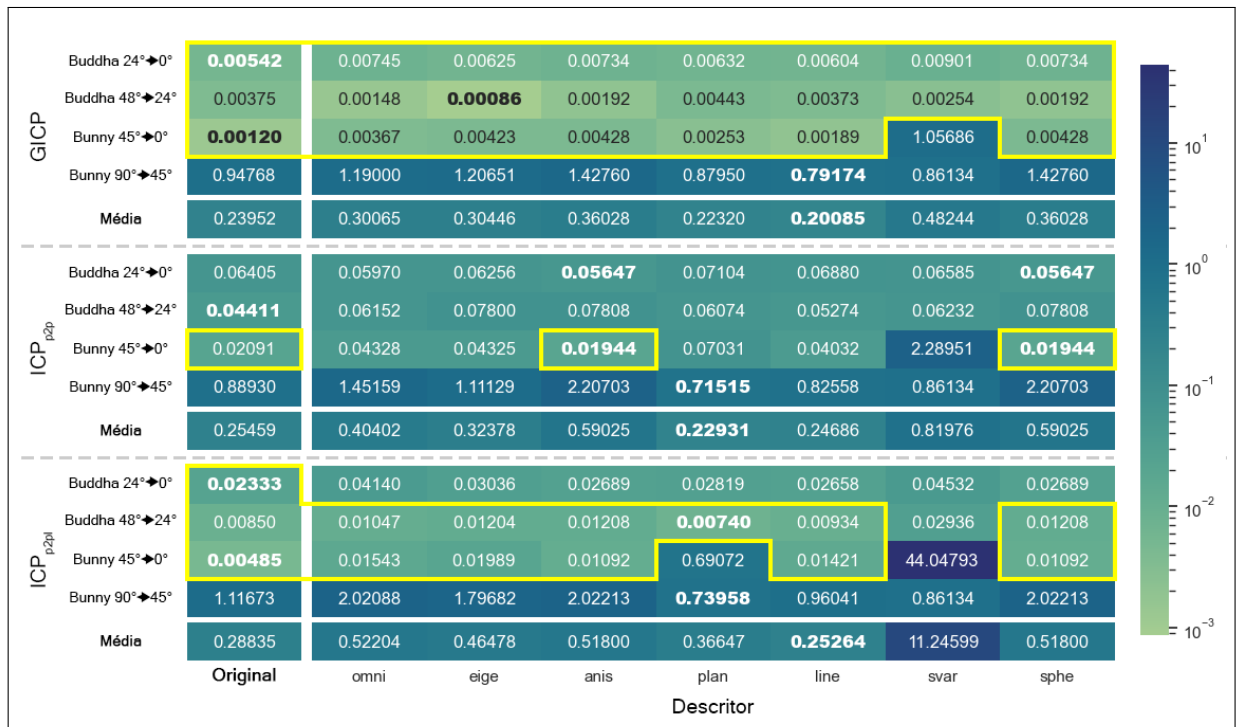
Figura 10 – Subnuvens resultantes da filtragem por meio de limiares empiricamente determinados para cada descritor.



Fonte: elaborada pelo autor.

Nota: as regiões cinza representam os pontos descartados das nuvens originais.

Figura 11 – Mapa de calor do erro de transformação obtido no alinhamento das amostras filtradas e não filtradas.



Fonte: elaborada pelo autor.

Nota: as regiões delimitadas pelos polígonos amarelos indicam um erro de transformação aceitável e os valores em negrito indicam os melhores resultados, considerando uma margem de erro de 1%.

5.2 Filtragem completa e filtragem reduzida

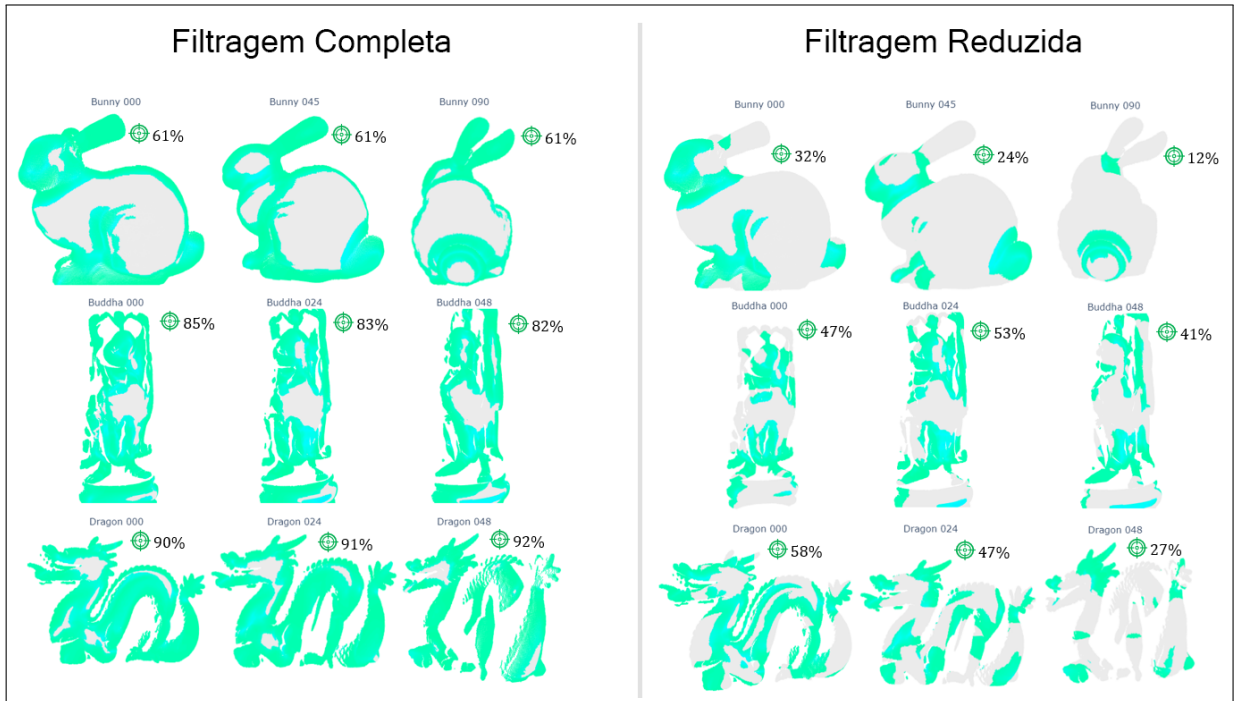
Na seção anterior, foi demonstrado que algumas técnicas de filtragem utilizando descritores de superfície são capazes de selecionar regiões correspondentes em capturas distintas do mesmo objeto. No entanto, o alinhamento utilizando apenas a filtragem com um único descritor não foi suficiente para obter resultados consistentemente melhores do que aqueles obtidos utilizando as entradas originais. Contudo, é possível especular que a combinação de algumas dessas filtragens, seguida da submissão aos algoritmos de registro, pode levar a resultados melhores, uma vez que a busca de correspondência será ampliada para as regiões selecionadas utilizando mais de um descritor. Para testar essa hipótese, foram criados dois filtros, um “completo” e um “reduzido”, combinando as regiões selecionadas por alguns descritores, com o objetivo de obter uma região mais uniforme e robusta.

A “filtragem completa” utiliza todos os descritores, exceto a verticalidade, que não apresentou nem mesmo invariância rotacional. Já na “filtragem reduzida”, foram utilizados apenas os descritores que selecionaram regiões relativamente próximas, como esfericidade, variação de superfície, anisotropia, autoentropia e ominvariância. Para a seleção dos conjuntos de

pontos em ambos os casos, as filtragens obtidas por cada descritor foram combinadas utilizando os mesmos intervalos de filtragem apresentados na Seção 5.1. Em outras palavras, foram selecionados os pontos que foram escolhidos em pelo menos uma das filtragens.

A Figura 12 apresenta as regiões selecionadas em cada uma das filtragens nos objetos *Bunny*, *Buddha* e *Dragon*. É possível observar que, na filtragem completa, foi obtida uma seleção mais abrangente de pontos, especialmente das regiões de contorno da imagem, resultando em uma redução mais modesta na densidade de pontos. Já na filtragem reduzida, a seleção de regiões está mais focada na seleção de conjuntos de pontos que representam uma variação de superfície mais elevada.

Figura 12 – Regiões selecionadas pelas filtragens completa e reduzida nos objetos *Bunny*, *Buddha* e *Dragon*.



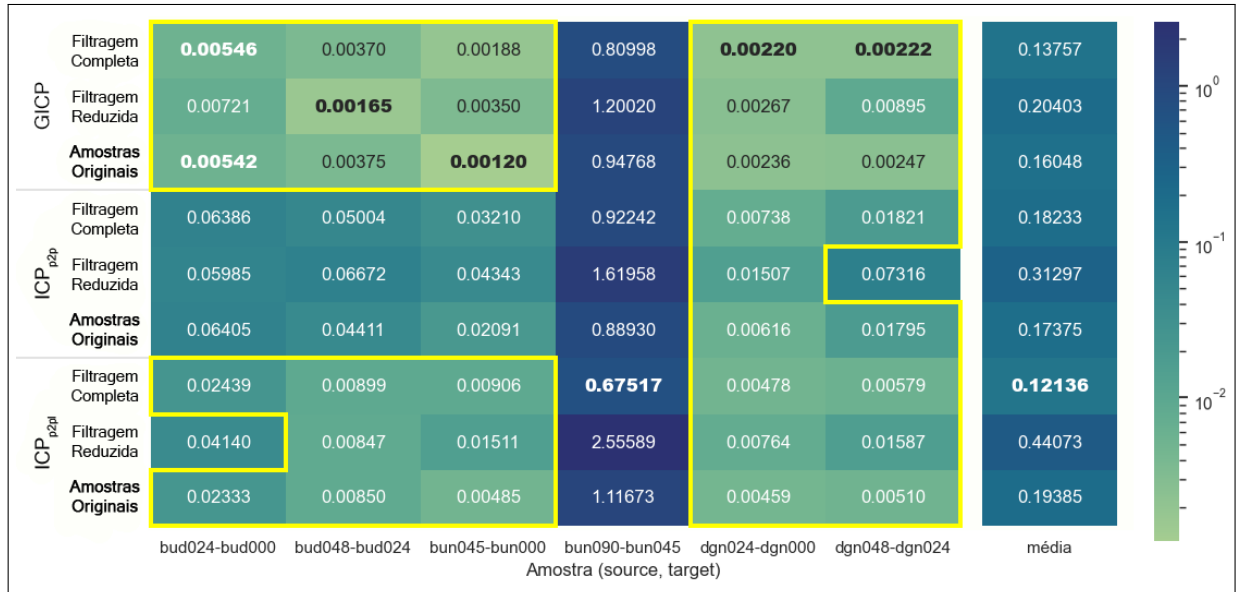
Fonte: elaborada pelo autor.

Nota: os valores em destaque indicam o percentual de pontos da nuvem original que foram selecionados.

O mapa de calor exibido na Figura 13 apresenta os erros de transformação resultantes dos alinhamentos realizados tanto com as amostras filtradas quanto com as amostras originais, organizados de acordo com os diferentes algoritmos de registro utilizados. As observações extraídas desses resultados revelam que nenhuma das estratégias de filtragem conseguiu atingir um nível de alinhamento satisfatório para todas as amostras analisadas, sendo notável que o par *bun090-bun045* exibiu os maiores valores de erro.

No que tange à quantidade de amostras que foram alinhadas satisfatoriamente, é

Figura 13 – Mapa de calor do erro de transformação obtido pelo registro utilizando filtragem completa, reduzida e amostras originais.



Fonte: elaborada pelo autor.

Nota: as regiões delimitadas pelos polígonos amarelos indicam um erro de transformação aceitável e os valores em negrito indicam os melhores resultados, considerando uma margem de erro de 1%.

possível constatar que a abordagem de filtragem completa e a ausência de filtragem (amostras originais) proporcionaram resultados semelhantes entre si. Por outro lado, a estratégia de filtragem reduzida apresentou uma ligeira redução na quantidade de amostras alinhadas quando empregada nas estratégias de registro ponto-à-plano e ponto-à-ponto. Ademais, ao considerarmos o valor absoluto do erro de transformação, a estratégia de filtro reduzido conseguiu superar as demais em apenas uma amostra com cada algoritmo de registro.

Em suma, a estratégia de registro com filtragem reduzida resultou em valores de erro de transformação maiores do que aqueles obtidos utilizando as amostras originais ou com filtragem completa em 83.3% dos casos, independentemente do algoritmo de registro utilizado. Por outro lado, o registro com filtragem completa obteve um alinhamento superior em relação às amostras originais em dois terços das amostras usando o algoritmo GICP. No entanto, os resultados foram tão insatisfatórios quanto os obtidos pela filtragem reduzida ao utilizar os algoritmos ICP_{p2p} e ICP_{p2pl} . Além disso, ao desconsiderarmos o par de amostras (bun090-bun045) que não foi adequadamente alinhado por nenhuma das abordagens, observamos que nem mesmo a filtragem completa conseguiu obter médias de erro inferiores às obtidas pelo registro com as entradas originais.

5.3 Clusterização de nuvens filtradas

Com base na análise dos resultados obtidos na seção anterior, constatamos que nenhuma das estratégias de filtragem avaliadas conseguiu consistentemente superar os resultados utilizando as amostras originais, motivando a adição de mais um passo ao *pipeline* de registro. Ao analisarmos a Figura 12, observamos que o filtro reduzido seleciona regiões relativamente separadas, as quais apresentam alguma sobreposição. Dessa forma, decidimos investigar a hipótese de que a clusterização dessas nuvens filtradas poderia auxiliar no pareamento dos pontos e, conseqüentemente, otimizar o registro. Para isso, submetemos as nuvens filtradas a dois algoritmos de clusterização bastante utilizados no contexto de nuvens de pontos 3D: *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN) (ESTER *et al.*, 1996) e k-médias (MACQUEEN, 1965).

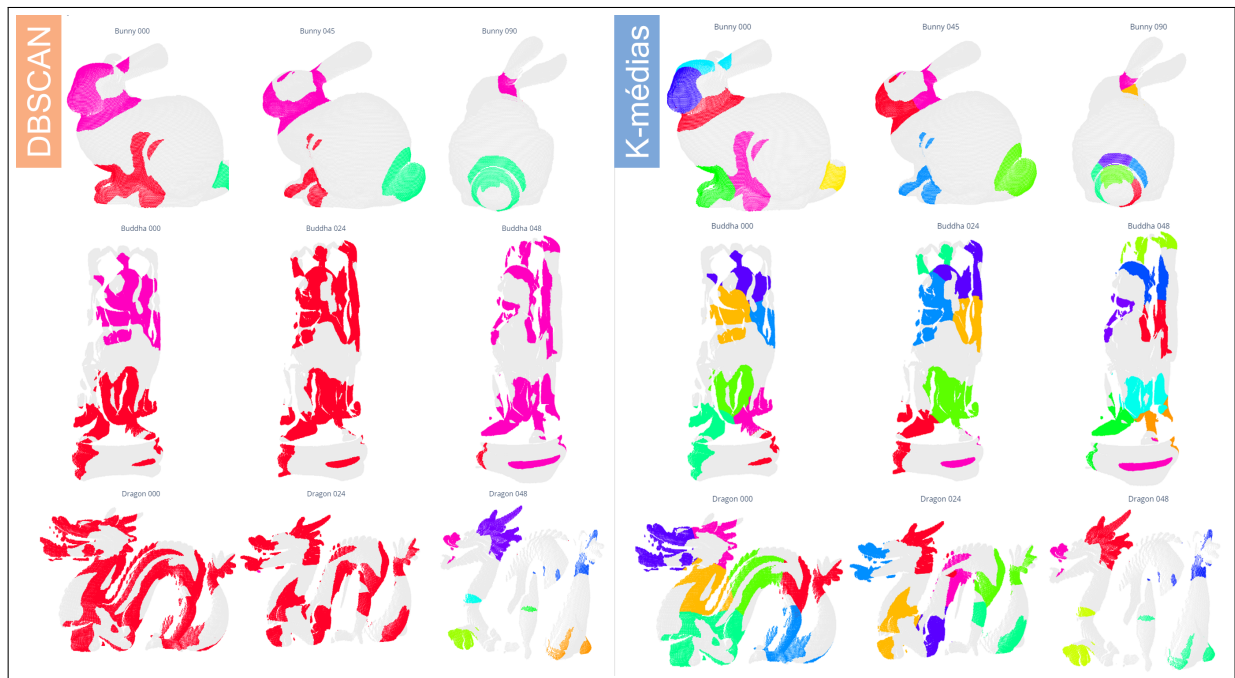
O DBSCAN é um método que se baseia em densidade e procura por regiões densas de pontos em um espaço de alta dimensionalidade, enquanto o k-médias tem como objetivo agrupar os pontos em k grupos, onde cada grupo representa um conjunto de pontos com características semelhantes. No experimento em questão, o DBSCAN foi configurado para considerar uma vizinhança máxima de $0.02m$ e o número mínimo de pontos em uma partição foi configurado como 1% do tamanho da nuvem filtrada. Já para a clusterização utilizando o k-médias, foi utilizado o método do cotovelo (MERLIANA *et al.*, 2015) para determinar o número ótimo de *clusters* para cada nuvem ser particionada.

Na Figura 14, é apresentado o particionamento obtido por meio das duas estratégias de clusterização mencionadas anteriormente. É possível observar que o particionamento ótimo obtido pelo algoritmo k-médias resultou em um fracionamento maior das nuvens filtradas, ao passo que o DBSCAN gerou menos partições e, em alguns casos, não particionou as amostras filtradas.

Após a clusterização, as nuvens foram particionadas em subnuvens, cujo pareamento ideal entre as partições das nuvens *source* e *target* não pode ser determinado *a priori*. Para resolver esse problema, realizamos o registro combinando todas as partições dos pares de entrada clusterizados, selecionando o alinhamento que proporcionou o menor erro de transformação.

Os resultados apresentados no mapa de calor da Figura 15 mostraram que, de forma semelhante ao observado na seção anterior, nenhuma das estratégias foi capaz de alcançar um bom alinhamento no par de amostras *Bunny090-Bunny045*. Além disso, a adoção das estratégias de clusterização resultou em uma melhoria no alinhamento em apenas um terço das amostras

Figura 14 – Segmentação das nuvens filtradas por meio das abordagens de algoritmos DBSCAN e K-médias.



Fonte: elaborada pelo autor.

Nota: o fundo cinza representa as regiões descartadas na etapa de filtragem.

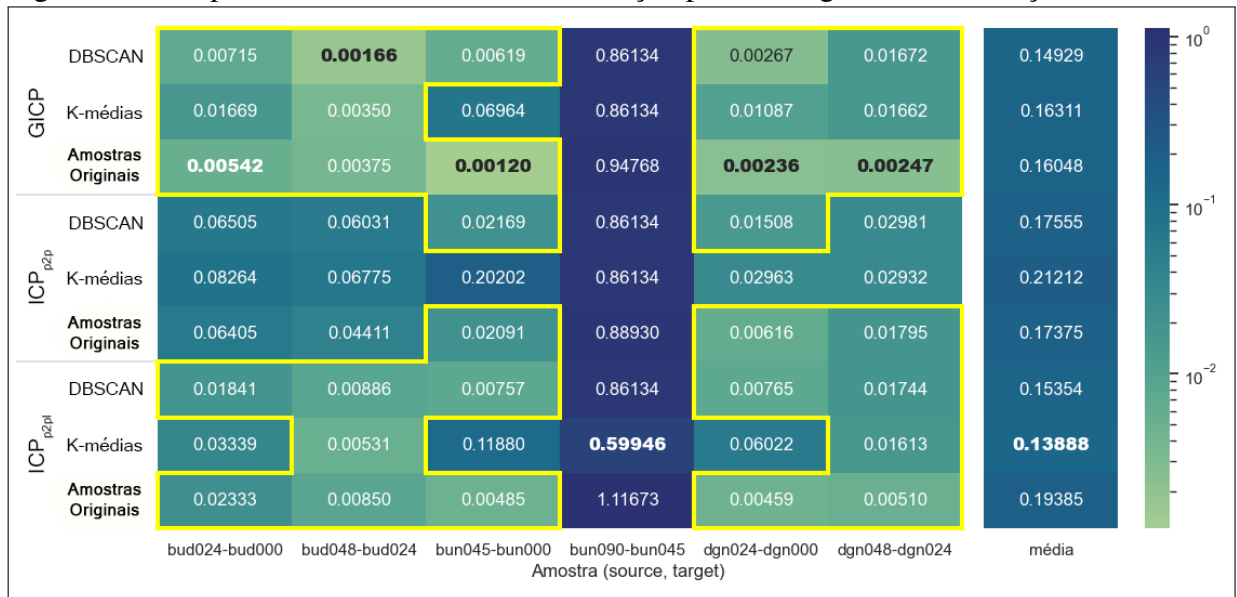
utilizando os algoritmos ICP_{p2pl} e $GICP$, enquanto que utilizando o algoritmo ICP_{p2p} , a melhoria foi observada apenas em um dos seis pares de nuvens. Especula-se que esses resultados, ainda piores do que os obtidos utilizando a filtragem completa e reduzida, estejam relacionados com a grande quantidade de informação perdida no particionamento, visto que as partições possuem tamanho reduzido, no qual os pontos estão localizados em regiões específicas da imagem.

5.4 Seleção de regiões utilizando pontos-chave

A fim de investigar a hipótese de que a seleção de regiões contínuas pode contribuir para a redução do erro de transformação, foi desenvolvida uma estratégia utilizando pontos-chave. A partir da clusterização obtida utilizando o DBSCAN (Figura 14), foram selecionados pontos-chave em cada *cluster*, correspondentes aos seus centroides. Posteriormente, nas nuvens originais, foram delimitadas regiões em torno de cada ponto-chave por meio da aplicação do algoritmo KNN com uma vizinhança cujo tamanho corresponde a 20% da quantidade de pontos da nuvem original. A determinação desse tamanho de vizinhança foi realizada empiricamente, buscando abranger regiões próximas às exibidas na Figura 14. As regiões selecionadas de acordo com essa estratégia estão representadas na Figura 16.

As partições obtidas foram submetidas aos algoritmos de registro utilizando a mesma

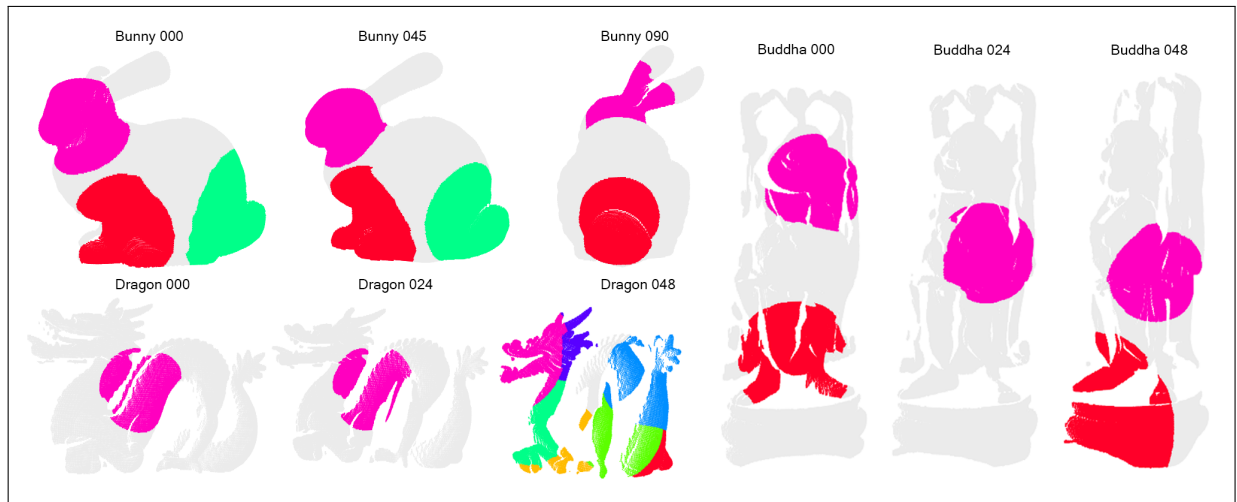
Figura 15 – Mapa de calor do erro de transformação por estratégia de clusterização.



Fonte: elaborada pelo autor.

Nota: as regiões delimitadas pelos polígonos amarelos indicam um erro de transformação aceitável e os valores em negrito indicam os melhores resultados, considerando uma margem de erro de 1%.

Figura 16 – Particionamento obtido utilizando KNN a partir dos pontos-chave da nuvens filtradas clusterizadas com DBSCAN.




Fonte: elaborada pelo autor.

Nota: o fundo cinza representa as regiões descartadas na etapa de filtragem.

estratégia de pareamento “todos contra todos” utilizada nos testes da seção anterior. No entanto, os resultados apresentados na Figura 17 mostram que a seleção de regiões em torno dos centroides das filtragens clusterizadas não produziu resultados melhores em comparação com a clusterização direta apresentada anteriormente. Isso sugere que a utilização dessas regiões em torno dos pontos-chave degradou a qualidade do alinhamento. Mesmo em casos onde as partições possuíam uma boa sobreposição, como no par *bun045-bun000*, observamos apenas uma pequena vantagem da estratégia com pontos-chave utilizando os algoritmos GICP e ICP_{p2pl} em relação à estratégia

que utilizou apenas o DBSCAN, mas ainda não foi capaz de superar o alinhamento com as nuvens originais. Em outros casos, como o par *bud024-bud000*, observamos que as regiões selecionadas possuem pouca sobreposição, o que resulta em um alto erro de transformação na maioria dos experimentos. Além disso, é possível notar que a estratégia de particionamento utilizando pontos-chave obteve a menor quantidade de alinhamentos aceitáveis, com no máximo três amostras utilizando o GICP.

Figura 17 – Mapa de calor do erro de transformação por estratégia de particionamento.



Fonte: elaborada pelo autor.

Nota: as regiões delimitadas pelos polígonos amarelos indicam um erro de transformação aceitável e os valores em negrito indicam os melhores resultados, considerando uma margem de erro de 1%.

5.5 Considerações finais

Os testes realizados neste capítulo demonstraram que nenhuma das abordagens avaliadas foi capaz de obter consistentemente resultados superiores aos dos algoritmos clássicos no alinhamento de objetos simples. No entanto, os limites de filtragem foram estabelecidos com base em uma especulação inicial de que as regiões determinadas na Seção 5.1 seriam as mais adequadas para o propósito do alinhamento. Portanto, é plausível supor que outros tipos de filtragem utilizando os descritores de superfície possam obter resultados melhores. Além disso, pode não existir um único intervalo de filtragem capaz de obter bons resultados em todos os tipos de nuvens de pontos.

No capítulo seguinte, investigaremos várias combinações de parâmetros de filtragem e registro com o objetivo de verificar se de fato existe alguma configuração capaz de superar de forma consistente os algoritmos clássicos com as amostras originais.

6 INVESTIGAÇÃO DE MÚLTIPLAS CONFIGURAÇÕES DE REGISTRO

Ao realizar o alinhamento de nuvens de pontos 3D, nem sempre os parâmetros de configuração padrão dos algoritmos são suficientes para obter um resultado satisfatório. Por essa razão, é comum a necessidade de ajustar essas configurações de acordo com as características dos conjuntos de dados. No entanto, essa abordagem pode demandar um grande esforço manual e não ser viável em muitos casos. Uma alternativa para superar essa limitação é desenvolver um *pipeline* de registro flexível, capaz de obter uma configuração de registro mais adequada para cada caso. Nesse sentido, neste capítulo iremos explorar as melhores configurações de registro em relação às seguintes variáveis: descritor de superfície, intervalo utilizado na filtragem e algoritmo de registro das entradas filtradas.

Nos experimentos subsequentes, foram examinadas diversas configurações utilizando todos os descritores de superfície apresentados anteriormente (omnivariância, autoentropia, anisotropia, planaridade, linearidade, variação de superfície e esfericidade), com exceção da verticalidade que mostrou-se inadequada para o registro nos testes realizados no Capítulo 4. Para investigar o intervalo de filtragem mais eficaz, foram testados um total de 55 intervalos. Esses intervalos correspondem a combinações de dois elementos selecionados de forma a cobrir todo o intervalo de valores possíveis para os descritores normalizados (0-1), com um incremento de 0.1, de acordo com a seguinte expressão:

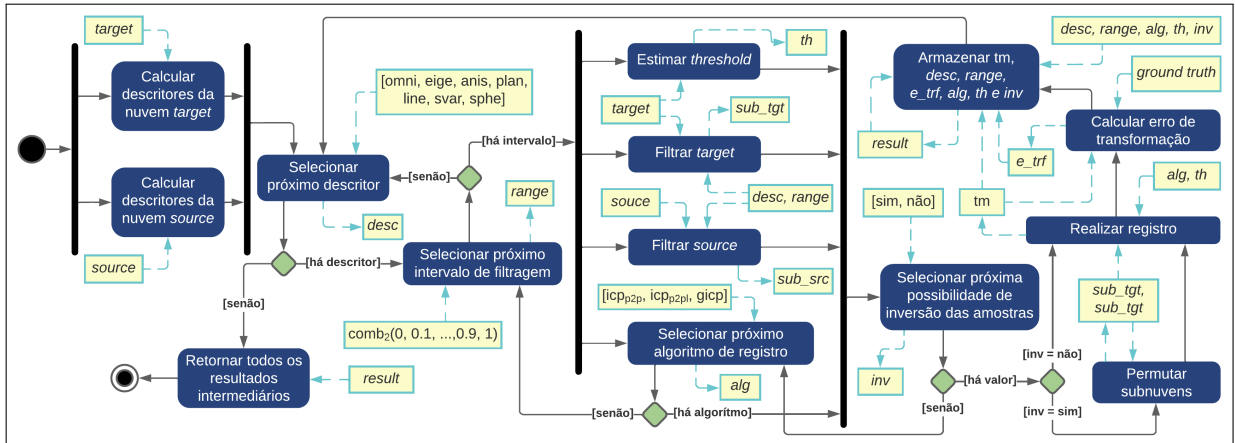
$$Intervalos_{(min,max)} = comb_2(0.0, 0.1, 0.2, \dots, 1.0). \quad (6.1)$$

Para realizar o registro dos pares de nuvens filtrados, foram aplicados as variante sem centralização dos algoritmos ICP_{p2p} , ICP_{p2p} e GICP, juntamente com o limiar de distância máxima obtido por meio da estratégia de desalinhamento da nuvem *target* apresentada na Seção 3.3. Além disso, em todas as configurações avaliadas foi considerada a possibilidade de inverter as entradas, ou seja, trocar a nuvem *source* pela *target* e vice-versa, uma vez que a simples mudança da ordem pode levar a um melhor alinhamento. É importante ressaltar que a definição de qual conjunto de pontos será o *source* e *target* é totalmente arbitrária e, portanto, não foi considerada uma possível variável fixa.

Foi realizado um experimento utilizando um conjunto de seis modelos de objetos. Para cada objeto, foram utilizados dois pares de nuvens, a saber: *Bunny00* e *Bunny45*; *Bunny45* e *Bunny90*; *Buddha00* e *Buddha24*; *Buddha24* e *Buddha48*; *Dragon00* e *Dragon24*; *Dragon24* e *Dragon48*. Para cada par de nuvens, foram aplicadas 2310 combinações de parâmetros de

registro mencionados anteriormente, totalizando assim 13860 alinhamentos avaliados neste experimento. A Figura 18 apresenta uma ilustração do *pipeline* utilizado para o registro de todas as possíveis combinações de parâmetros para um determinado par de nuvens de entrada.


Figura 18 – Pipeline de registro para explorar todas as combinações de parâmetros avaliadas.



Fonte: elaborada pelo autor.

O gráfico da Figura 19 apresenta a quantidade de configurações que alcançaram um alinhamento satisfatório em relação ao número de amostras. Além disso, o número total de combinações é reduzido à metade, uma vez que duas combinações que diferem apenas na inversão das entradas são consideradas como uma única configuração, escolhendo-se aquela que apresentou o menor erro de transformação.

Figura 19 – Gráfico do total de configurações alinhadas satisfatoriamente por número de pares alinhados.



Fonte: elaborada pelo autor.

Os resultados obtidos revelaram que uma grande parte das configurações avaliadas, cerca de 73%, apresentou baixa eficácia no alinhamento das amostras (menos de 5), sendo que, 36% não foram capazes de alinhar satisfatoriamente nenhum dos pares de objetos 3D. Por

outro lado, aproximadamente 26% das configurações testadas obtiveram sucesso no alinhamento satisfatório de cinco dos seis pares de entradas, sendo esta a mais frequente entre as configurações que alinharam alguma das amostras. Por fim, apenas 14 configurações (1.2%) foram capazes de alinhar adequadamente o conjunto completo de amostras.

Os resultados apontaram que nenhum das configurações que empregaram o algoritmo ICP_{p2p} obteve sucesso em alinhar mais do que três amostras, sendo esse o algoritmo mais frequente entre as configurações que não obtiveram sucesso no alinhamento dos pares de nuvens. Em contrapartida, os algoritmos ICP_{p2pl} e GICP foram os que conseguiram alinhar adequadamente todas as amostras em maior quantidade de configurações, com 8 e 6 configurações, respectivamente. No que diz respeito aos descritores utilizados, apenas os descritores de autoentropia, planaridade, linearidade e omnivariância foram empregados em pelo menos uma das configurações que alinharam todas as amostras. Com relação aos limites de filtragem, somente um intervalo (0.2-0.8) obteve sucesso em, no mínimo, duas configurações.

Embora tenha sido possível obter um alinhamento satisfatório para todas as amostras em 14 das combinações avaliadas, é plausível que uma abordagem iterativa, combinando algumas dessas configurações, possa produzir resultados ainda melhores. Com esse intuito, foram estabelecidas novas configurações de registro, nas quais alguns parâmetros foram fixados, enquanto outros receberam um grau de liberdade, permitindo a avaliação de todas as possibilidades dentro do *pipeline* de registro. Nesse contexto, se um dos limites utilizado no intervalo de filtragem dos pontos for fixo, teremos um total de $(lim_{max} - lim_{min})/0.1$ intervalos avaliados. O objetivo foi encontrar as combinações de parâmetros fixos e variáveis que produzissem o menor erro médio de transformação para o alinhamento de todas as amostras.

Na Tabela 1, são apresentados os resultados obtidos para as configurações de parâmetros fixos que alcançaram os melhores resultados, sendo ordenados pela média do erro de transformação. Por exemplo, na configuração 1, fixamos o descritor a ser utilizado na filtragem. Das sete opções possíveis de descritores, a linearidade obteve os menores erros de transformação, sendo escolhida como o descritor fixo nessa configuração.

No teste realizado, a configuração 1 obteve o menor erro de transformação, entretanto, foi a quarta em número de iterações necessárias. Essa configuração manteve apenas o descritor linearidade fixo em seu *pipeline*, ou seja, todos os 55 limites foram iterativamente combinados com esse descritor e com as três funções de registro a fim de selecionar o melhor alinhamento. Ao comparar essa configuração com a melhor combinação obtida no teste anterior (que corresponde

Tabela 1 – Erro de transformação e RMSE médios das configurações avaliadas.

Conf.	Descritor	Parâmetros		Alg. registro	N.º iterações	Erro de transf.	RMSE
		Lim. min.	Lim. max.				
1	line	-	-	-	330	0.0017028	0.020596
4	-	-	-	gicp	770	0.0017514	0.020017
3	-	-	1	-	420	0.0017517	0.006869
7	line	-	-	gicp	110	0.0019045	0.020571
2	-	0.2	-	-	336	0.0019389	0.023938
9	-	0.2	-	gicp	112	0.0019389	0.023938
10	-	-	0.8	gicp	112	0.0019724	0.016651
8	-	0.2	0.8	-	42	0.0020777	0.016653
14	-	0.2	0.8	gicp	14	0.0020777	0.016653
6	line	-	0.9	-	54	0.0022470	0.009569
5	plan	0	-	-	60	0.0022575	0.009542
12	plan	0	-	gicp	20	0.0022706	0.019322
13	plan	-	0.7	gicp	14	0.0023836	0.020018
11	plan	0.1	0.7	-	6	0.0026327	0.014157
15	line	0.2	0.8	gicp	2	0.0026614	0.016645

Fonte: elaborada pelo autor.

Nota: o RMSE e o erro de transformação foram calculados a partir da média dos erros de alinhamento das amostras.

à configuração 15 neste último experimento) que obteve um erro de transformação de 0.002661, observou-se que a configuração 1 obteve um valor de erro em média 36% abaixo desse. Cabe destacar que este teste utiliza apenas um conjunto reduzido de amostras, logo é natural esperar que essas configurações possam alcançar resultados ainda melhores em cenários de testes mais abrangentes.

No próximo capítulo desta investigação, realizamos uma análise mais detalhada das seis melhores configurações iterativas (1, 4, 3, 7, 2 e 9) em cenários de teste mais rigorosos, incluindo sobreposição parcial e total de objetos, registro de nuvens com presença de ruído, subamostragem, bem como cenas desafiadoras tanto em ambientes internos (*indoor*) quanto externos (*outdoor*).

7 AVALIAÇÃO DAS MELHORES CONFIGURAÇÕES EM DIFERENTES CENÁRIOS DE REGISTRO

Após seleção das configurações de registro mais apropriadas, conforme os critérios discutidos no capítulo anterior, tem-se por objetivo neste capítulo apresentar os resultados obtidos em cenários de testes mais amplos. Tal análise visa confrontar as abordagens de registro fundamentadas na seleção de pontos a partir dos descritores geométricos obtidos da matriz de covariância com os algoritmos clássicos de registro, seguindo uma metodologia cuidadosamente estabelecida e detalhada a seguir. Desta forma, busca-se fornecer uma avaliação abrangente e rigorosa do desempenho das técnicas de registro testadas, possibilitando uma análise mais consistente e conclusiva acerca de sua eficácia em contextos mais complexos e desafiadores.

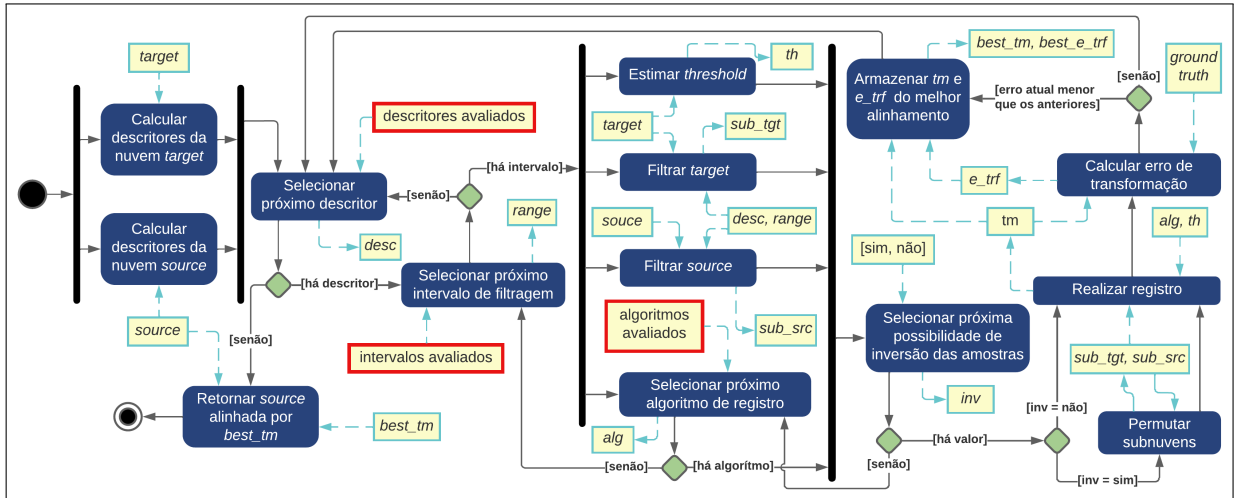
7.1 Metodologia

Com o propósito de abranger as características frequentemente encontradas no registro de nuvens de pontos 3D, tanto simples quanto complexas, foram selecionados cenários de teste que possibilitam avaliar a capacidade de generalização das estratégias de alinhamento propostas, bem como investigar o comportamento das mesmas em cada contexto de forma mais específica. Os cenários de teste escolhidos são detalhados nas seções subsequentes e incluem:

- **Cenário A** - Registro de objetos com sobreposição parcial;
- **Cenário B** - Registro de objetos com sobreposição total;
- **Cenário C** - Registro de nuvens com ruído gaussiano;
- **Cenário D** - Registro de nuvens subamostradas;
- **Cenário E** - Registro de cenas *indoor* com sobreposição parcial;
- **Cenário F** - Registro de cenas *outdoor* com sobreposição parcial.

Para avaliar a eficácia das configurações selecionadas no capítulo anterior em um conjunto abrangente e diversificado de amostras, confrontamos os resultados de alinhamento obtidos pelas configurações 1, 2, 3, 4, 7 e 9 com os algoritmos clássicos de registro, apresentados na Seção 3.2, tanto com centralização quanto sem centralização. A Figura 20 ilustra o *pipeline* adotado para o registro das amostras em cada uma dessas configurações. É importante notar que o *pipeline* é comum a ambas as configurações e deriva do fluxo apresentado na Figura 18, onde os resultados intermediários são descartados. A única variação ocorre nas combinações de parâmetros empregadas em cada configuração (destacadas em vermelho).

Figura 20 – Pipeline utilizado para o registro das amostras em ambas as configurações avaliadas.



Fonte: elaborada pelo autor.

Nota: em vermelho estão destacadas as entradas correspondentes os parâmetros da configuração de registro.

7.1.1 Critério de avaliação

Para avaliar os alinhamentos intermediários e finais em ambos os cenários de testes a seguir, utilizamos o erro de transformação obtido por meio da verdade fundamental, conforme detalhado na Seção 3.3. Essa métrica nos permite medir a qualidade das transformações obtidas durante o processo de registro, permitindo comparar e selecionar as melhores configurações de forma precisa.

Para garantir uma análise imparcial, utilizamos nos algoritmos clássicos de referência a mesma estratégia de desalinhamento da nuvem alvo (conforme explicado na Seção 3.3), utilizada nas estratégias propostas, para determinar a distância máxima na qual um ponto na nuvem de origem pode encontrar uma correspondência na nuvem alvo.

7.1.2 Conjuntos de dados

Para a realização dos testes propostos neste estudo, utilizou-se um conjunto de nuvens de pontos distintas em cada cenário de teste. Essas imagens foram obtidas a partir de bases de dados diferentes ou foram modificadas para incorporar características específicas às nuvens originais. No primeiro cenário de teste, cenário A, utilizaram-se dois pares de nuvens para cada objeto do Repositório de Digitalização 3D da Universidade de Stanford (STANFORD, 2014). No cenário B, utilizou-se uma captura de objetos diversos das seguintes bases/estudos: Aleotti *et al.* (2014), Mian *et al.* (2006) e EPFL (2014). Para cada um desses objetos, aplicou-se uma transformação aleatória para obter a nuvem *source*. Já nos cenários C e

D, respectivamente, foram utilizados os mesmos objetos do cenário A, porém, para o cenário C, foram adicionados dez níveis de ruído gaussiano a cada modelo, enquanto no cenário D, as entradas foram subamostradas em quatro resoluções diferentes usando um filtro *VoxelGrid*. Por fim, o quinto cenário de teste, cenário E, utilizou três pares de nuvens de cenas internas (indoor) das cenas *House* e *Automation Lab*, enquanto o cenário F, utilizou três pares de digitalizações 3D de cenas externas (outdoor) realizadas no centro da cidade de Bremen e no centro de Bremen em torno do *Gaussian Point*. Todas as digitalizações foram obtidas do *Robotic 3D Scan Repository* (NüCHTER; LINGEMANN, 2016).

A seguir, apresenta-se uma síntese das informações correspondentes a cada cenário de teste (Quadro 2).

Quadro 2 – Informações sobre os cenários de teste e os conjuntos de dados utilizados

Cenário	Descrição	Repositório	Amostras	Quantidade Média de Pontos
A	Registro de objetos com sobreposição parcial	Stanford 3D Scanning Repository	Armadillo, Bunny, Buddha e Dragon	40964
B	Registro de objetos com sobreposição total	Aleotti <i>et al.</i> (2014), Mian <i>et al.</i> (2006), EPFL (2014)	Hammer, Horse, Cheff, Chicken high, Parasaurolophus high, T-rex high, Aquarius, Bears, Eagle, Femme, Fountain e Owl	44311
C	Registro de nuvens com ruído gaussiano	Stanford 3D Scanning Repository	Armadillo, Bunny, Buddha e Dragon adaptadas	43316
D	Registro de nuvens subamostradas	Stanford 3D Scanning Repository	Armadillo, Bunny, Buddha e Dragon adaptadas	20264
E	Registro de cenas indoor com sobreposição parcial	Robotic 3D Scanning Repository	House e Automation Lab adaptadas	162342
F	Registro de cenas outdoor com sobreposição parcial	Robotic 3D Scanning Repository	Bremen City e Gaussian Point adaptadas	154189

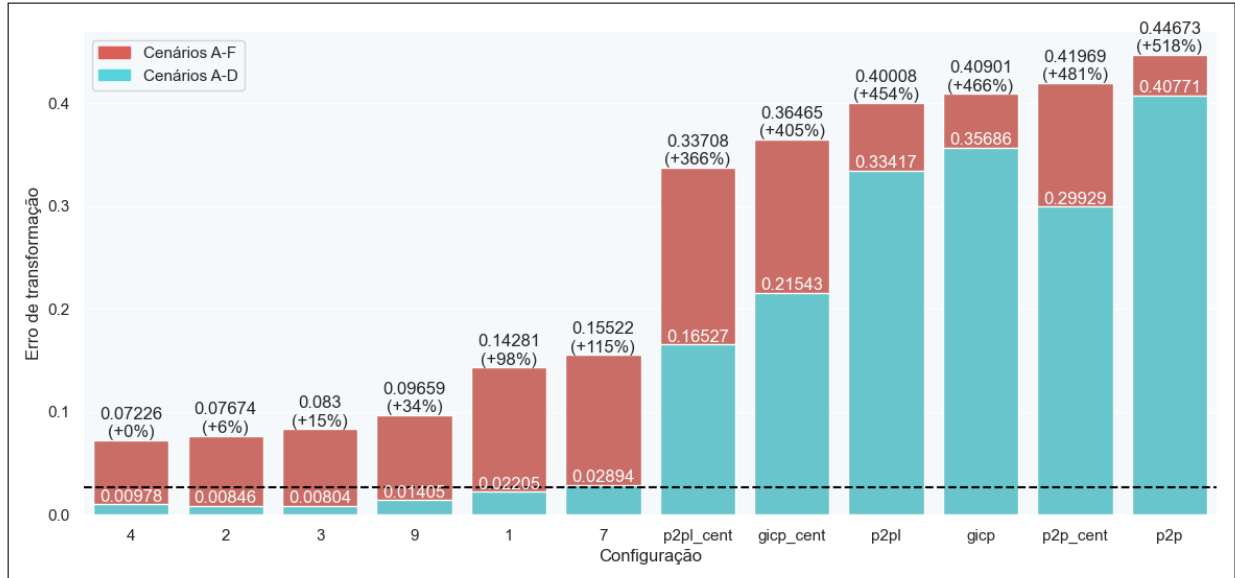
Fonte: elaborado pelo autor.

7.2 Resultados

A Figura 21 ilustra os valores médios do erro de transformação obtidos em todos os cenários de teste para cada uma das configurações avaliadas. É importante ressaltar que o gráfico destaca em verde o erro médio considerando apenas os cenários nos quais foram utilizados

modelos 3D de objetos (cenários A-D).

Figura 21 – Gráfico do erro de transformação médio em todos os cenários (A-F, vermelho) e nos cenários com objetos (A-D, verde) agrupados por configuração



Fonte: elaborada pelo autor.

Nota: entre parênteses é informada a diferença percentual para a configuração de melhor desempenho. A linha tracejada representa o limiar para um erro de transformação aceitável.

Ao analisar os resultados apresentados na Figura 21 para os cenários A-F, é possível observar que todas as configurações propostas neste trabalho superaram as técnicas clássicas de registro em termos de erro de transformação, embora nenhuma delas tenha alcançado um erro de transformação médio satisfatório. A configuração 4 apresentou o melhor resultado médio, ao contrário da projeção inicial que indicava a configuração 1 (ver Tabela 1) como a melhor opção. As configurações 2 e 3 também obtiveram bons resultados, ocupando a segunda e terceira posições, respectivamente, com uma diferença de no máximo 15% em relação à configuração 4. Vale destacar que a configuração 7, uma variação das configurações 1 e 4 que fixa o descritor de superfície e a função de registro utilizados na seleção do conjunto de pontos, obteve os piores resultados tanto no contexto geral quanto nos cenários com objetos. Embora essa flexibilização tenha beneficiado as configurações 1 e 4, ela resultou em um aumento significativo na quantidade de iterações, sete e três vezes, respectivamente.

Ao realizar a comparação dos resultados obtidos nos cenários que utilizaram somente modelos de objetos, verificamos que a configuração 7 foi a única a não alcançar um alinhamento médio satisfatório, sugerindo uma menor adaptabilidade dessas configurações para o registro de nuvens de pontos de objetos. Ademais, observamos que a configuração 4, que havia sido apontada como a melhor nos cenários A-F, foi superada pelas configurações 3 e 2, respectivamente,

apresentando um erro médio 22% maior que o observado na configuração 3. Além disso, todas as configurações e os algoritmos clássicos de referência apresentaram maior facilidade em alinhar amostras de objetos, especialmente as estratégias que utilizaram as variantes com centralização dos algoritmos de registro. Esse aspecto é interessante pois destaca a complexidade envolvida no alinhamento de cenas *indoor* e *outdoor*.

De modo geral, as configurações que empregaram a centralização obtiveram resultados superiores em comparação às suas variantes sem centralização. Esse comportamento é especialmente evidente nos cenários com objetos, onde todas as configurações com centralização obtiveram resultados superiores às demais. Esse melhor desempenho das variantes centralizadas pode ser atribuído ao fato de que a centralização pode facilitar o pareamento e a convergência do algoritmo, uma vez que pontos com distância superior ao limiar de distância máxima não seriam pareados. Além disso, a centralização pode fornecer uma estimativa inicial grosseira de alinhamento que favorece a convergência do algoritmo em casos em que as regiões de sobreposição estão próximas.

Para fornecer uma análise mais ampla dos resultados, a Tabela 2 apresenta uma visão geral das medidas de desempenho utilizadas, além do erro de transformação médio. Essas medidas incluem a redução média da quantidade de pontos das entradas, o erro de rotação e translação em relação ao *ground truth* e o RMSE. Cabe destacar que o erro de transformação médio observado, embora seja elevado no contexto geral (A-F), não representa necessariamente um alinhamento extremamente ruim no contexto de objetos. Isso se deve, em grande parte, à grande escala das nuvens de pontos provenientes das cenas *indoor* e, em particular, *outdoor*.

Os algoritmos de registro, como o ICP e suas variantes, apresentam um custo computacional que é diretamente proporcional ao tamanho das entradas. Portanto, a redução dos conjuntos de pontos é uma estratégia importante e comumente considerada quando se busca otimizar o custo de registro. Nessa conjuntura, todas as configurações baseadas em filtragem apresentaram uma boa taxa média de redução do conjunto de pontos, acima dos 58%. Contudo, o desafio nesse tipo de filtragem é remover os pontos e/ou regiões que não agregam informação relevante para o registro ou que poderiam atrapalhar o alinhamento, como, por exemplo, regiões não sobrepostas entre a nuvem *source* e *target*.

A configuração 4, que registrou o menor erro de transformação, também demonstrou a maior taxa de redução de pontos, aproximadamente 72%, excedendo em mais de 10% as demais configurações que apresentaram reduções em torno de 58% e 62%. Cabe ressaltar que

Tabela 2 – Média dos principais indicadores de qualidade avaliados nos cenários A-F.

Configuração	Redução de pontos	E_{rot}	$E_{trans}(m)$	E_{transf}	RMSE (m)	Acurácia
4	72.2%	5.6°	19.4841	0.0723	1.6382	72.6%
2	61.5%	5.7°	9.2676	0.0767	18.2146	71.5%
3	60.6%	7.1°	39.3713	0.0830	2.8196	71.5%
9	62.3%	8.2°	30.8765	0.0966	14.9976	65.8%
1	59.5%	10.7°	179.5560	0.1428	inf	59.7%
7	58.4%	12.1°	191.7322	0.1552	13.7843	57.6%
p2pl _{cent}	-	21.7°	384.1519	0.3371	13.9307	38.3%
gicp _{cent}	-	25.2°	380.9923	0.3646	13.5834	36.5%
p2pl	-	29.0°	76.5527	0.4001	10.3564	33.8%
gicp	-	29.6°	107.6401	0.4090	9.0898	29.9%
p2p _{cent}	-	28.3°	363.0593	0.4197	11.6000	14.7%
p2p	-	32.6°	77.0762	0.4467	11.2090	9.2%

Fonte: elaborada pelo autor.

Nota: a média total é calculada utilizando a média por cenário. Um valor de RMSE igual a “inf” indica que não houve pontos pareados. A acurácia refere-se à média por cenário da quantidade de amostras que obtiveram um alinhamento satisfatório.

uma redução excessiva de pontos pode impactar negativamente o processo de registro, uma vez que informações cruciais da nuvem de pontos podem ser perdidas. No entanto, mesmo aplicando uma redução mais severa do que configuração 7, considerada a pior, a configuração 4 ainda obteve resultados superiores.

Para suprir uma eventual curiosidade do leitor, além das medidas de erro fundamentadas na verdade fundamental, também adicionamos os resultados obtidos em termos do RMSE. Em alguns casos, o menor valor médio de RMSE não se traduz na melhor configuração em relação à verdade fundamental. Isso pode ser observado, por exemplo, nas configurações 2 e 9, que, apesar de estarem entre as quatro melhores em termos do erro de transformação, apresentaram um valor de RMSE superior em mais de 30% ao da pior configuração (ICP_{p2p}). Cabe ressaltar que o RMSE foi utilizado apenas para calcular o alinhamento final, pois nos *pipelines* de registro propostos é necessário selecionar a melhor transformação obtida no passo iterativo. Para essa seleção, foi utilizado o erro de transformação, garantindo que a transformação escolhida seja a melhor entre todas as avaliadas.


Com o intuito de fornecer uma análise mais aprofundada sobre os resultados obtidos e o desempenho das diferentes configurações que utilizam descritores geométricos de superfície, as próximas subseções apresentam uma análise detalhada dos resultados obtidos em cada um dos cenários de testes. Essa abordagem tem como objetivo fornecer uma compreensão mais refinada dos resultados obtidos, permitindo uma avaliação mais precisa e detalhada do comportamento e desempenho de cada configuração em diferentes cenários

7.2.1 Cenário A – Registro de objetos com sobreposição parcial

Este cenário corresponde a uma situação relativamente simples de registro 3D, onde as nuvens de pontos de entrada apresentam uma grande sobreposição, o desalinhamento angular está dentro de um limite razoável (inferior ou igual a 45 graus) e as nuvens de pontos não são muito densas (menos de 100 mil pontos).

A Figura 22 apresenta o gráfico dos erros médios de transformação obtidos para cada objeto. Foi constatado que todas as configurações avaliadas apresentaram resultados médios superiores às abordagens de referência em todos os objetos testados, com diferenças significativas em alguns modelos. Devido a isso, optou-se por utilizar a escala logarítmica para facilitar a comparação entre diferentes objetos para cada configuração. Ademais, traçou-se uma linha horizontal representando o limite máximo de erro de transformação aceitável, conforme especificado no capítulo anterior.

Figura 22 – Gráfico do erro de transformação médio do cenário A por configuração e objeto registrado.



Fonte: elaborada pelo autor.

Nota: a linha tracejada representa o limiar para um erro de transformação aceitável.

Considerando a média de todas as amostras deste cenário, foi verificado que todas as configurações propostas alcançaram um alinhamento satisfatório para todos os objetos, com um erro médio uma ordem de grandeza abaixo do limiar de qualidade estabelecido (linha tracejada). Além disso, todas essas configurações conseguiram alinhar corretamente todas as amostras, onde

a amostra que obteve o maior erro de transformação foi representada por um desalinhamento de apenas 0.36° e $5.67 \times 10^{-4}m$, o que proporciona um alinhamento excelente para os conjuntos de pontos em questão. Em contrapartida, as configurações que utilizaram exclusivamente os algoritmos clássicos obtiveram resultados com erro de transformação, em média, pelo menos 56 vezes acima do valor obtido pela configuração 1, mesmo que, em algumas amostras, alguns dos algoritmos clássicos tenham alcançado resultados interessantes. Cabe destacar que as amostras do objeto *Dragon* foram facilmente alinhadas por todas as configurações, sendo as únicas imagens alinhadas pelos algoritmos ICP_{p2p} e sua variante centralizada. Além disso, o objeto *Bunny* foi o único a apresentar, em todas as configurações de referência, um erro médio superior ao limiar estabelecido, enquanto que todas as configurações propostas apresentaram o melhor resultado médio exatamente nesse objeto.

Em relação às configurações testadas, a configuração 1 apresentou os melhores resultados em termos de média para todas as amostras e, juntamente com a configuração 4, se destacaram como as melhores em 62.5% das amostras, considerando uma margem de erro de 1% para o menor erro observado. As configurações 7 e 2 também obtiveram bons resultados, estando entre as melhores em 37,5% das amostras. Nenhuma das configurações de referência conseguiu obter o menor erro de transformação em nenhum dos pares de amostras, mesmo considerando uma margem de erro de 1%. Embora em alguns casos a diferença percentual entre as melhores configurações seja considerável, deve-se ressaltar que estamos avaliando um erro muito pequeno, e, em termos práticos, essa diferença acaba não proporcionando uma melhoria significativa. Além disso, embora não tenham alcançado os melhores resultados, alguns dos algoritmos de referência apresentaram desempenho semelhante às abordagens propostas nas digitalizações dos objetos *Armadillo*, *Buddha* e *Dragon*, que possuem menor desalinhamento inicial (conforme observado na Tabela 3).

Diferentemente das configurações propostas, nenhuma das configurações de referência foi capaz de alinhar todas as amostras. O algoritmo ICP_{p2pl} e sua variante foram os que alinharam minimamente a maior quantidade de amostras (7), seguidos das variantes do GICP (6 amostras) e das variantes do ICP_{p2p} (2 amostras), que foram capazes de alinhar apenas as nuvens do objeto *Dragon*. Ademais, nenhuma das configurações de referência foi capaz de alinhar o par de nuvens *Bunny45* e *Bunny90*, que pode ser considerado um caso difícil, enquanto as configurações propostas obtiveram bons resultados nesse caso. Na Figura 23, é possível observar a comparação dos alinhamentos obtidos pela configuração proposta que apresentou o maior erro


Tabela 3 – Erro de transformação e RMSE médio para os múltiplos alinhamentos de cada objeto.

Config.	E_{transf}					RMSE (m)				
	Arma.	Budd.	Bunn.	Drag.	Média	Arma.	Budd.	Bunn.	Drag.	Média
1	2.8e-03	2.6e-03	1.1e-03	1.4e-03	2.0e-03	1.3e-03	3.3e-03	1.9e-03	2.3e-03	2.2e-03
4	3.4e-03	2.8e-03	1.1e-03	1.3e-03	2.2e-03	2.4e-03	3.3e-03	1.9e-03	2.3e-03	2.5e-03
3	3.8e-03	2.2e-03	1.2e-03	1.8e-03	2.3e-03	3.6e-03	3.3e-03	7.9e-04	8.6e-04	2.1e-03
2	3.5e-03	3.0e-03	1.3e-03	1.6e-03	2.3e-03	1.3e-03	3.3e-03	1.9e-03	3.8e-03	2.6e-03
7	4.3e-03	3.2e-03	1.1e-03	1.4e-03	2.5e-03	1.3e-03	3.3e-03	1.9e-03	2.3e-03	2.2e-03
9	4.4e-03	3.0e-03	1.3e-03	1.6e-03	2.5e-03	2.4e-03	3.3e-03	1.9e-03	3.8e-03	2.8e-03
p2pl _{cent}	5.4e-03	7.8e-03	4.3e-01	4.4e-03	1.1e-01	1.3e-03	1.1e-03	1.2e-03	8.7e-04	1.1e-03
p2pl	5.4e-03	7.8e-03	5.2e-01	4.4e-03	1.3e-01	1.3e-03	1.1e-03	1.3e-03	8.7e-04	1.1e-03
gicp	4.9e-03	4.4e-03	5.8e-01	2.4e-03	1.5e-01	1.3e-03	1.1e-03	2.1e-03	8.7e-04	1.3e-03
gicp _{cent}	1.4e-01	4.4e-03	5.8e-01	2.4e-03	1.8e-01	1.9e-03	1.1e-03	1.2e-03	8.7e-04	1.3e-03
p2p _{cent}	4.1e-01	5.3e-02	4.9e-01	1.5e-02	2.4e-01	2.7e-03	1.4e-03	2.6e-03	9.3e-04	1.9e-03
p2p	2.5e-01	3.7e-02	6.8e-01	7.8e-03	2.5e-01	2.7e-03	1.3e-03	2.3e-03	8.7e-04	1.8e-03

Fonte: elaborada pelo autor.

(configuração 9) e pela configuração de referência que obteve o menor erro (ICP_{p2p} centralizado) para o registro do par *Bunny45* e *Bunny90*. É possível constatar que até mesmo a configuração proposta com pior erro médio (Figura 23-b) foi capaz de alinhar de forma excelente essa amostra, enquanto a melhor configuração de referência (Figura 23-c) ficou visivelmente muito distante de um alinhamento minimamente satisfatório.

Figura 23 – Comparativo entre os alinhamentos obtidos para o par de nuvens *Bunny45* (azul) e *Bunny90* (vermelho). À esquerda está o par de nuvens de entrada (a), no meio é exibido o alinhamento obtido pela configuração 9 (b) e à direita temos o alinhamento obtido pela variante centralizada do algoritmo ICP ponto-ao-plano.



Fonte: elaborada pelo autor.


7.2.2 Cenário B – Registro de objetos com sobreposição total

O objetivo deste cenário é expandir os testes anteriores utilizando uma maior variedade de objetos oriundos de três bases diferentes, conforme descrito na Seção 8.4, com desalinhamento inicial (rotação e translação) obtido de forma aleatória para cada nuvem. Além

disso, os pares de nuvens apresentam sobreposição total uma vez que as transformações aleatórias foram aplicadas às nuvens alvo para obter o conjunto de pontos a ser alinhado.

Os resultados obtidos no experimento demonstraram que todas as configurações propostas obtiveram desempenho superior em relação às configurações de referência em termos do erro médio de transformação. Especificamente, as configurações 4, 3, 2 e 9 se destacaram por obterem médias pelo menos oito ordens de grandeza inferiores às das configurações de referência. Além disso, essas quatro configurações foram as únicas que conseguiram manter o erro de transformação abaixo do limiar de qualidade aceitável para todas as amostras, como evidenciado no gráfico apresentado na Figura 24.

Figura 24 – Gráfico do erro de transformação médio, por configuração, para os objetos do cenário B.



Fonte: elaborada pelo autor.

Nota: a linha tracejada representa o limiar para um erro de transformação aceitável e os pontos são os pares de objetos.

Observando a dispersão dos resultados nas configurações 1 e 7, que obtiveram média superior ao limiar de alinhamento satisfatório, podemos notar que apenas uma das amostras (*eagle*) não alcançou um alinhamento satisfatório. Por outro lado, as demais amostras obtiveram resultados comparáveis às quatro melhores configurações, sugerindo que as configurações 1 e 7 ainda podem ser consideradas como opções viáveis para o alinhamento desses tipos de nuvens de pontos. Ao analisar a configuração 1, que é um caso mais geral da configuração 7, notamos que ela fixa apenas o tipo de descritor utilizado, no caso a linearidade. Portanto, podemos inferir que, para a amostra *eagle*, a filtragem utilizando a linearidade não conseguiu selecionar regiões que proporcionassem um bom alinhamento em nenhum dos intervalos avaliados. No entanto, é necessário realizar uma avaliação mais aprofundada para entender os motivos que levaram ao

alinhamento ruim do objeto *eagle* utilizando esse descritor.

Ao analisarmos os resultados deste cenário em relação às configurações de referência, é possível observar que as abordagens que utilizaram a técnica de centralização apresentaram um desempenho superior em relação às demais, conforme apresentado na Tabela 4. Essas configurações obtiveram erros de rotação e translação significativamente menores em algumas amostras, sendo capazes de alinhar corretamente pelo menos 25% dos pares de objetos. Dentre essas configurações, destaca-se a variante com centralização do GICP, que obteve um resultado comparável aos melhores resultados em 42% das amostras avaliadas. Por outro lado, nenhuma das estratégias que não utilizaram a centralização (ICP_{p2p} , GICP e ICP_{p2pl}) conseguiu atingir um alinhamento aceitável em ao menos uma das amostras.

Tabela 4 – Média dos principais indicadores de qualidade para o cenário B.

Configuração	Redução de pontos	E_{rot}	$E_{trans}(m)$	E_{transf}	RMSE (m)
4	63.7%	0.00°	1.95e-07	5.147e-10	inf
3	41.5%	0.00°	2.15e-07	5.177e-10	inf
2	59.1%	0.00°	2.34e-07	5.649e-10	inf
9	56.2%	0.00°	4.62e-07	1.155e-09	inf
1	55.2%	4.39°	1.63e-02	4.165e-02	inf
7	58.8%	4.39°	1.63e-02	4.165e-02	inf
$p2pl_{cent}$	-	21.57°	4.57e+01	3.545e-01	inf
$gicp_{cent}$	-	27.16°	3.59e+01	4.032e-01	inf
$p2p_{cent}$	-	32.62°	1.86e+00	5.190e-01	1.33e-01
$p2p$	-	60.70°	2.99e+01	9.127e-01	inf
$gicp$	-	61.00°	2.99e+01	9.188e-01	inf
$p2pl$	-	66.22°	3.00e+01	9.872e-01	inf

Fonte: elaborada pelo autor.

Nota: valor de RMSE igual à *inf* indica que não houve pontos pareados.

Uma explicação plausível para o fato de todas as estratégias que utilizaram a centralização dos conjuntos de pontos terem obtido resultados melhores do que as demais é que o par de entrada (*source*, *target*) corresponde à mesma imagem 3D. Isso facilita o problema de alinhamento, uma vez que a centralização dos conjuntos de pontos reduz o erro de translação a zero, deixando apenas o erro de rotação a ser corrigido. Portanto, ao aplicar a técnica de centralização, o problema de alinhamento é simplificado, restando apenas a correção do erro de rotação, uma vez que o erro de translação já foi eliminado pela centralização dos conjuntos de pontos.

Para avaliar o desempenho das configurações propostas diante de rotações mais elevadas, foi conduzido um teste adicional, considerando uma amostra selecionada de cada

conjunto de dados, *Horse*, *eagle* e *cheff*. Rotações de 60°, 90° e 120° foram aplicadas no eixo Z de cada amostra para gerar as amostras utilizadas como *source* nos experimentos a seguir. Todos os testes realizados anteriormente contemplaram rotações menos agressivas, com valores iguais ou inferiores a 45°. O objetivo desse teste adicional era verificar se as configurações propostas ainda seriam capazes de fornecer alinhamentos satisfatórios em condições mais desafiadoras.

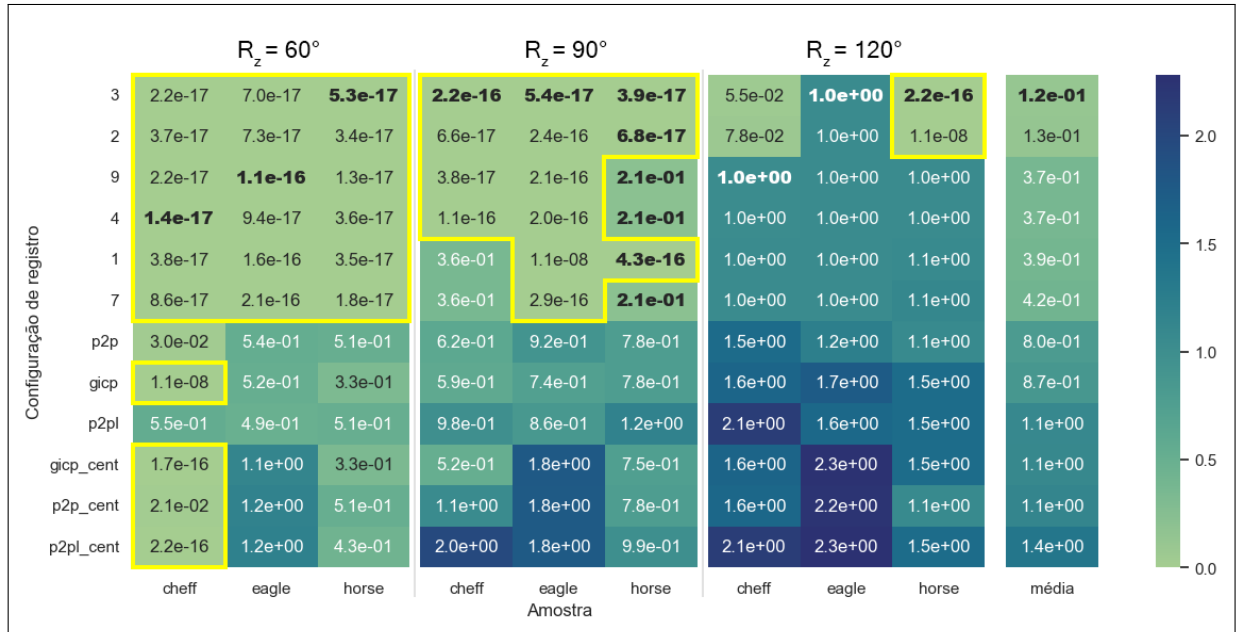
Os resultados do teste complementar apresentados na Figura 25 mostraram que todas as configurações propostas obtiveram resultados satisfatórios para as amostras com rotação de 60°, enquanto que as demais configurações obtiveram no máximo um alinhamento satisfatório. Dentre as configurações propostas, as configurações 3 e 2 se destacaram por terem sido capazes de alinhar todas as amostras com rotação de 90°, seguidas das configurações 9, 4 e 1 que conseguiram alinhar dois terços dessas amostras. Entretanto, nenhuma das abordagens testadas foi capaz de alinhar todas as amostras com rotação de 120°, sendo o melhor caso proporcionado pelas configurações 3 e 2 que foram capazes de alinhar ao menos uma amostra (*horse*). Esse comportamento pode estar relacionado à distância máxima adotada ou ao número reduzido de iterações do algoritmo de registro utilizado após a etapa de seleção dos pontos. Observou-se ainda que apenas quatro das configurações de referência foram capazes de alinhar no máximo uma amostra (*cheff* 60°), o que indica a limitação desses algoritmos clássicos nesses cenários e o ganho proporcionado pela estratégia de seleção de pontos com base nos descritores de superfície.

Cabe destacar que rotações tão elevadas não são frequentes em ambientes reais, uma vez que o uso de ângulos de rotação tão altos, em aquisições realizadas por um sensor de profundidade real, resultará em uma região de sobreposição limitada e, portanto, em um esforço maior para realizar o alinhamento. Entretanto, todas as configurações propostas mantiveram resultados excepcionais, com erro de transformação praticamente nulo em rotações de 60°, apesar da dificuldade adicional.

7.2.3 Cenário C – Registro de nuvens com ruído gaussiano

Comumente, as digitalizações 3D realizadas por sensores de profundidade apresentam ruído, seja devido à imprecisão do dispositivo de aquisição ou devido à natureza do objeto ou cena capturado (HAN *et al.*, 2017). Com o objetivo de investigar o comportamento das abordagens propostas em relação a esse tipo de perturbação, neste cenário de testes, foi adicionado ruído gaussiano a ambos os pares de nuvens dos objetos (*Armadillo*, *Buddha*, *Bunny* e *Dragon*) – o mesmo conjunto de dados utilizado no cenário A. Para cada objeto, foi utilizado

Figura 25 – Mapa de calor do erro de transformação médio, por configuração, para os objetos com rotações agressivas.



Fonte: elaborada pelo autor.


Nota: as regiões delimitadas pelos polígonos amarelos indica um erro de transformação aceitável e os valores em negrito indicam os melhores resultados, considerando uma margem de erro de 1%.

um par de nuvens, adquiridos em posições consecutivas, e foram aplicados 10 níveis de ruído, com média zero e desvios-padrão de 0.0001 (1), 0.00065 (2), 0.0012 (3), 0.00175 (4), 0.0023 (5), 0.00285 (6), 0.0034 (7), 0.00395 (8), 0.0045 (9) e 0.00505 (10). Em seguida, os descritores foram recalculado a partir das amostras com ruído.

O mapa de calor apresentado na Figura 26 exibe os resultados médios do erro de transformação das amostras agrupadas por configuração e nível de ruído. As regiões/células em tonalidades mais claras indicam resultados melhores, especialmente a região delimitada pelo polígono amarelo, que remete a um alinhamento aceitável. Além disso, a média total por configuração também é exibida e utilizada para ordenar o eixo vertical, a fim de facilitar a identificação das melhores configurações no contexto geral.

Ao analisar os resultados apresentados, constatou-se que a configuração 2 apresentou os menores valores de erro, em destaque, em um maior número de níveis de ruído avaliados (50%), seguida da configuração 3 (40%) e da configuração 1 (10%). Ao considerar o alinhamento médio das amostras, observou-se que as configurações 3 e 2 conseguiram um resultado satisfatório até o quinto nível de ruído, seguidas pelas configurações 1 e 4, que obtiveram bons resultados até o quarto e terceiro níveis de ruído, respectivamente. As demais configurações (7 e 9), juntamente com as configurações de referência ICP_{p2pl} e sua variante, conseguiram registrar amostras até o

Figura 26 – Mapa de calor do erro de transformação médio obtido em cada configuração por nível de ruído.



Fonte: elaborada pelo autor.

Nota: a região delimitada pelo polígono amarelo indica um erro de transformação aceitável e os valores em negrito indicam os melhores resultados por nível de ruído, considerando uma margem de erro de 1%.

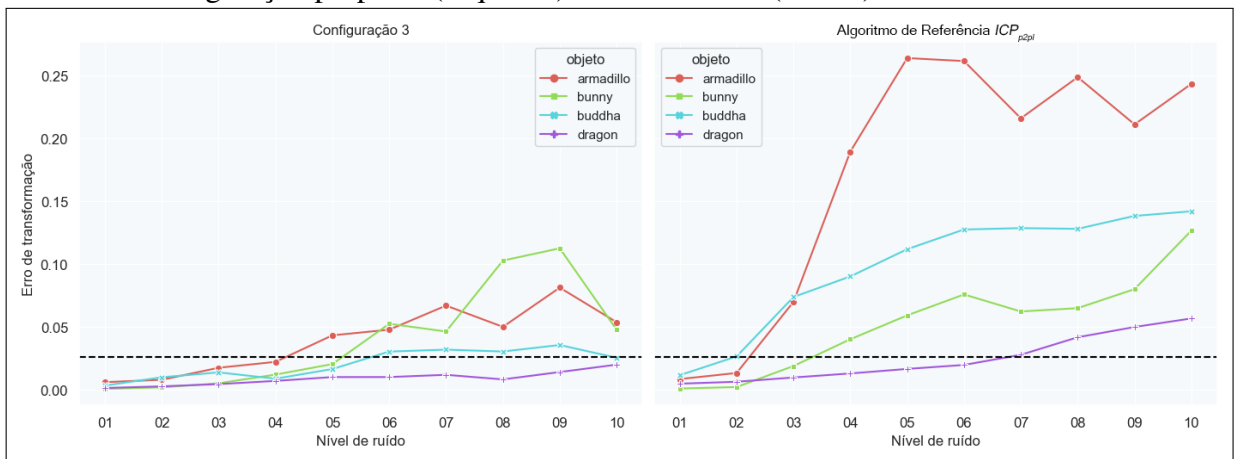
segundo nível de ruído. Por outro lado, três das configurações de referência ($GICP$, ICP_{p2p} e sua variante) não obtiveram resultados satisfatórios em nenhum dos níveis de ruído avaliados, sendo que as duas piores versões foram as que não realizaram centralização.

Neste cenário de testes, é relevante notar que as configurações de referência que se destacaram foram aquelas que empregaram a estratégia de registro ponto-ao-plano. De fato, a configuração 4, que adotou exclusivamente a função de registro $GICP$ e havia se mostrado a melhor em testes anteriores, apresentou desempenho inferior às configurações 3 e 2, que possibilitam a escolha flexível da função de registro. Ao analisarmos os resultados de alinhamento das amostras, verificamos que, de fato, nas duas melhores configurações, o algoritmo mais utilizado nas amostras que obtiveram alinhamento satisfatório foi o ICP_{p2pl} , com uma frequência de 66%. Esses resultados indicam uma superioridade do algoritmo ponto-ao-plano em situações com amostras ruidosas.

Uma análise minuciosa dos resultados evidencia que cada objeto avaliado apresentou comportamentos distintos em relação ao aumento do nível de ruído e ao tipo de configuração de registro utilizada (conforme apresentado na Figura 27). Ao comparar os resultados da melhor configuração com filtragem (configuração 3) e da melhor configuração de referência (ICP_{p2pl}), constata-se que a configuração 3 alcançou um alinhamento satisfatório em todas as amostras do objeto *Dragon*. Em relação aos demais objetos, os resultados foram semelhantes, sendo que

o objeto *Armadillo* foi o único que não atingiu um alinhamento satisfatório acima do quarto nível de ruído nessa configuração. Por outro lado, a configuração ICP_{p2pl} obteve resultados pontualmente melhores no objeto *Bunny*, mas apresentou resultados particularmente ruins para o objeto *Armadillo*. Ademais, essa configuração não conseguiu resultados satisfatórios acima do sexto nível de ruído para *Dragon*, que pode ser considerado o objeto mais fácil de alinhar.

Figura 27 – Gráficos comparativos do erro de transformação médio dos objeto por nível de ruído da melhor configuração proposta (esquerda) e de referência (direita).




Fonte: elaborada pelo autor.

Nota: a linha tracejada representa o limiar para um erro de transformação aceitável.

Contudo, os níveis de ruído mais elevados examinados são extremamente agressivos e raramente encontrados em ambientes reais, sendo utilizados exclusivamente com a finalidade de explorar ao máximo a capacidade das abordagens investigadas. A Figura 28 ilustra a nuvem de pontos original e três dos níveis de ruído empregados neste cenário de testes, aplicados ao objeto *Bunny*. Nessa figura, constata-se que mesmo o terceiro nível de ruído (b) encobre diversos detalhes da superfície da nuvem original dificultando o registro e a extração de descritores úteis.

Figura 28 – Níveis de ruído para o objeto *Bunny*. a) nuvem original; b) terceiro nível de ruído; c) sexto nível de ruído; d) décimo nível de ruído.



Fonte: elaborada pelo autor.

7.2.4 Cenário D – Registro de nuvens subamostradas


A redução da densidade de pontos é uma das estratégias para minimizar o custo computacional do registro. No entanto, essa prática pode resultar na perda de informações relevantes. O objetivo deste cenário é ampliar os testes apresentados na Subseção 4.2 com o intuito de verificar a hipótese de que a seleção de regiões com base nos descritores de superfície pode compensar a perda de informações decorrente da subamostragem. Além disso, busca-se investigar os limites de redução do conjunto de pontos sem comprometer a qualidade do alinhamento.

Neste cenário de testes, foram realizados cinco níveis de subamostragem utilizando o filtro *VoxelGrid*, nas nuvens originais, gerando nuvens de pontos com reduções de 90% (1), 70% (2), 50% (3), 30% (4) e 10% (5) do tamanho dos conjuntos de pontos originais, com uma margem de erro de 3.5% para mais ou para menos. Essa margem foi adotada para que um mesmo tamanho de *voxel* pudesse ser usado para subamostrar todas as capturas de um mesmo objeto, minimizando assim a distorção. As amostras utilizadas foram os objetos *Armadillo* (0°, 30°, 60°), *Bunny* (0°, 45°, 90°), *Buddha* (0°, 24°, 48°) e *Dragon* (0°, 24°, 48°), alinhados dois a dois, totalizando dois pares por objeto. Além disso, para cada nível de redução, os descritores foram recalculados a partir das nuvens subamostradas.

Ao analisar os resultados apresentados no gráfico da Figura 29 (apresentados em escala logarítmica para facilitar a visualização), observa-se que todas as configurações propostas obtiveram resultados médios melhores do que as configurações de referência e alcançaram um alinhamento satisfatório em todas as amostras testadas (pontos coloridos). Ademais, a configuração 4 obteve os melhores resultados em quase todos os níveis de subamostragem, apenas no nível menos agressivo a configuração 1 apresentou resultados médios ligeiramente melhores. As configurações de referência, com exceção das configurações ICP_{p2p} e sua variante centralizada, apresentaram resultados interessantes na maioria das amostras, mas apresentaram alinhamentos insatisfatórios nas amostras do objeto *Bunny*, especialmente no par de nuvens *Bunny45* e *Bunny90*, que se mostraram particularmente desafiadores. As duas piores configurações (ICP_{p2p} e sua variante centralizada) obtiveram resultados insatisfatórios, alinhando apenas as amostras do objeto *Dragon*, que, ao longo dos experimentos, mostrou ser o caso mais fácil.

Os resultados obtidos até o momento indicaram que as configurações propostas para o alinhamento de objetos foram capazes de produzir resultados satisfatórios em todos os níveis de subamostragem considerados. Entretanto, com o aumento da severidade de subamostragem,

Figura 29 – Gráfico do erro de transformação médio, por configuração, para os objetos do cenário D.




Fonte: elaborada pelo autor.

Nota: a linha tracejada representa o limiar para um erro de transformação aceitável.

é razoável presumir que a qualidade do alinhamento possa ser comprometida. Para testar essa hipótese, os dados foram reorganizados para obter médias em relação aos diferentes níveis de subamostragem, incluindo as amostras do cenário sem subamostragem (cenário A), que foi utilizado como referência. Os resultados obtidos para as três melhores configurações propostas (4, 2 e 3) e as três melhores configurações de referência (GICP, ICP_{p2pl} e sua variante centralizada) estão apresentados na Figura 30.

Figura 30 – Gráficos do erro de transformação médio, por nível de subamostragem, das três melhores configurações propostas e de referência.



Fonte: elaborada pelo autor.

Observa-se que, de fato, há uma tendência nas configurações propostas de aumento do erro de transformação à medida que se aumenta a severidade da subamostragem, especialmente em reduções superiores a 30%. Por outro lado, as configurações de referência demonstraram uma diminuição no erro de transformação em algumas amostras, embora de maneira discreta nas duas configurações que empregaram uma das variantes do algoritmo *ICPp2pl*. No entanto, observou-se uma melhoria mais substancial na configuração que utilizou a variante centralizada do GICP, a qual alcançou resultados mais favoráveis, com reduções de 50% e 90%. Apesar do aumento no erro de transformação nas configurações propostas, esse acréscimo é substancialmente modesto, sendo aproximadamente uma ordem de grandeza inferior ao limiar de qualidade estabelecido previamente.

Os resultados obtidos sugerem que a aplicação de subamostragem nas nuvens originais, antes do cálculo dos descritores de superfície, pode ser uma estratégia viável para reduzir o elevado custo computacional associado a esse processo. Essa abordagem possibilita uma significativa diminuição no tamanho das nuvens de pontos, sem comprometer de forma significativa a qualidade do registro. Além disso, essa técnica também contribui para a redução do custo computacional do alinhamento das subnuvens filtradas, uma vez que os algoritmos de alinhamento empregados neste estudo são sensíveis ao tamanho das amostras.

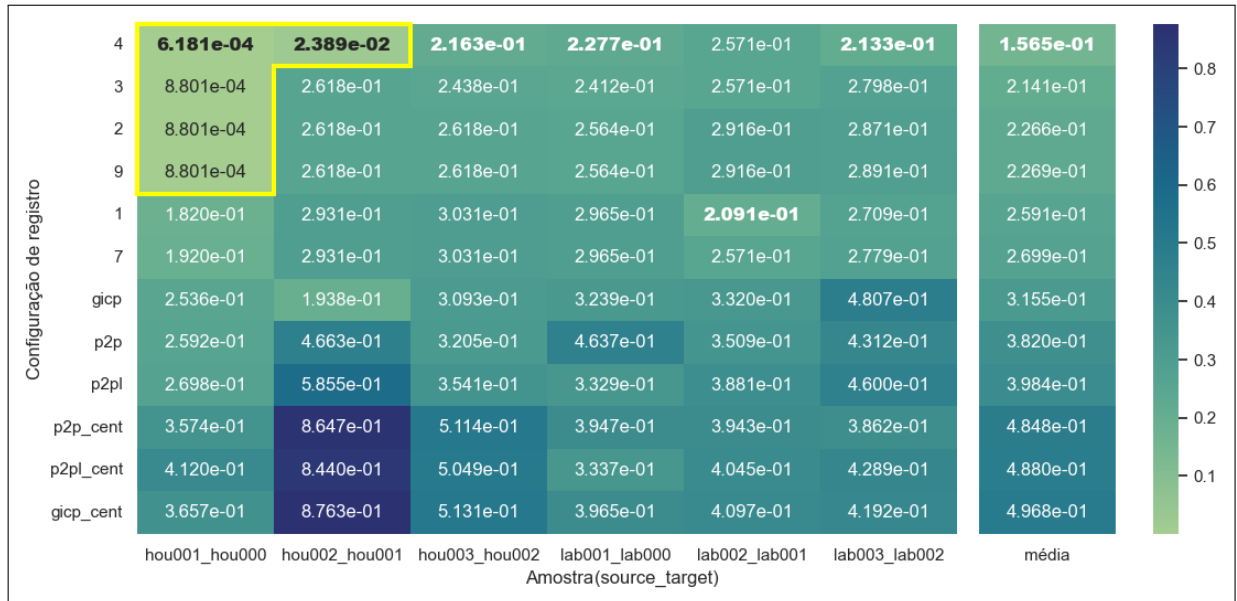
7.2.5 Cenário E – Registro de cenas indoor com sobreposição parcial

Este cenário destina-se a examinar o desempenho de abordagens propostas no contexto do alinhamento de cenas internas, em contraste com cenários anteriores que utilizaram modelos tridimensionais de objetos. Esses modelos têm várias aplicações, incluindo aprimorar a navegação de agentes móveis autônomos e fornecer serviços baseados em localização (LEHTOLA *et al.*, 2017). No entanto, os modelos utilizados neste estudo diferem dos cenários anteriores, uma vez que apresentam uma maior densidade de pontos, além da presença de múltiplos objetos e uma inerente oclusão, o que aumenta a complexidade do processo de alinhamento de cenas.

Neste experimento foram utilizadas quatro capturas provenientes de duas cenas distintas, nomeadas como *house* e *laboratory*. Para criar pares de amostras com sobreposição significativa, as amostras originais foram combinadas em pares consecutivos, conforme descrito na Subseção 7.1.2. Como resultado, foram obtidos três pares de amostras a serem alinhados em cada cena. Os resultados foram registrados em um mapa de calor, ilustrado na Figura 31. Neste

mapa, cada coluna representa o erro de transformação de uma amostra específica, enquanto a coluna destacada à direita mostra a média obtida para cada configuração. Os valores em negrito no mapa indicam os melhores resultados por amostra, considerando uma margem de 1% em relação ao melhor alinhamento, e o polígono amarelo identifica os resultados considerados satisfatórios em termos de alinhamento.

Figura 31 – Mapa de calor do erro de transformação médio para as cenas internas.



Fonte: elaborada pelo autor.

Nota: a região delimitada pelo retângulo amarelo indica um erro de transformação aceitável e os valores em negrito indicam os melhores resultados por amostra, considerando uma margem de erro de 1%.


A partir da análise dos resultados obtidos, constatou-se que nenhuma das configurações testadas conseguiu alcançar um erro de transformação médio considerado aceitável. Somente a configuração 4 foi capaz de obter um alinhamento satisfatório em pelo menos duas das amostras, e ainda apresentou o menor erro de transformação em cinco das seis amostras, enquanto a configuração 1 foi a melhor na amostra restante. Além dessa, as configurações 3, 2 e 9 conseguiram alinhar apenas uma das amostras. As configurações que obtiveram alinhamento satisfatório em pelo menos uma das amostras (configurações 4, 3, 2 e 9) alcançaram esse resultado explorando qual descritor seria utilizado na filtragem. Logo, pode-se inferir que a flexibilização em relação ao descritor utilizado é uma característica relevante para obter um melhor alinhamento em conjuntos de pontos complexos como os investigados neste cenário.

Ao analisar os resultados das configurações de referência, observa-se que aquelas que adotaram a centralização dos dados apresentaram um desempenho inferior em relação à média e a pelo menos 50% das amostras testadas. Isso indica que, para o conjunto de dados

utilizado neste experimento, a centralização das imagens 3D não beneficia o alinhamento. Como resultado, podemos especular que a utilização de algoritmos de registro que não requerem a centralização dos dados possa levar a resultados melhores. É importante ressaltar que as configurações propostas neste estudo utilizam as versões centralizadas dos algoritmos clássicos para alinhar os conjuntos de dados filtrados. Portanto, é possível supor que essas configurações possam obter resultados mais promissores se forem utilizadas as variantes não centralizadas dos algoritmos de alinhamento.

Com o intuito de investigar tal hipótese, foi realizado um teste adicional empregando as mesmas amostras mas, desta vez, utilizando algoritmos sem centralização para alinhar os conjuntos de pontos filtrados. Os resultados comparativos entre as estratégias com e sem centralização estão disponíveis na Figura 32. Observa-se que, exceto para a configuração 4, todas as demais configurações apresentaram um erro médio de transformação ligeiramente menor ao utilizar algoritmos sem centralização. Entretanto, ao avaliar a quantidade de amostras com alinhamento satisfatório, nota-se que nenhuma das amostras foi corretamente alinhada pelas configurações sem centralização. Tais resultados sugerem que a utilização de algoritmos sem centralização não proporcionam melhorias efetivas no alinhamento de conjuntos de pontos filtrados e podem, em alguns casos, resultar em alinhamentos piores.

Figura 32 – Gráfico do erro médio de transformação por configuração e tipo de algoritmo de registro.



Fonte: elaborada pelo autor.

Nota: a linha tracejada representa o limiar para um erro de transformação aceitável.

Podem ser especuladas algumas hipóteses para explicar a falta de sucesso das

configurações propostas na maioria das amostras. Uma delas é a possibilidade de haver um número insuficiente de iterações no algoritmo de registro aplicado aos pares de nuvens filtradas, o que poderia resultar em um pareamento inadequado. Outra hipótese é que o limite estabelecido para a distância máxima, através da estratégia de desalinhamento da nuvem alvo, não tenha sido adequado para obter um pareamento preciso nas amostras deste cenário. Além disso, é possível que o tamanho da vizinhança utilizado para o cálculo dos descritores (5%) seja grande para este tipo de cenário. Outra consideração é a possibilidade de que a sobreposição entre as nuvens mescladas não tenha sido suficiente para permitir um alinhamento preciso. Por fim, os parâmetros de filtragem utilizados nas configurações podem não ter sido os mais adequados. Contudo, uma análise pormenorizada de cada uma dessas hipóteses ultrapassa os limites deste estudo, sugerindo, portanto, que sejam objeto de investigação em futuras pesquisas.


7.2.6 Cenário F – Registro de cenas outdoor com sobreposição parcial

Neste último cenário, foi realizado um conjunto de testes para avaliar o desempenho das configurações baseadas em filtragem em ambientes externos, utilizando nuvens de pontos de alta densidade e elevada complexidade. Tais nuvens de pontos apresentam características como uma maior dispersão, maior alcance espacial e uma distribuição mais complexa e variável, o que pode tornar o registro dessas nuvens um desafio significativo (LU *et al.*, 2021).

Para realizar a análise, foram utilizados três pares de nuvens de pontos coletadas em duas cenas ao ar livre na cidade de Bremen. Todas as amostras foram subamostradas e as amostras obtidas em torno do Gaussian Point foram mescladas para obter uma sobreposição significativa, conforme descrito na Subseção 7.1.2. Os resultados obtidos foram ilustrados no gráfico exibido na Figura 33, no qual as barras representam a média do erro de transformação para cada configuração, enquanto que os pontos coloridos retratam a dispersão dos valores para cada amostra, sendo coloridos de acordo com a cena a que pertencem.

Assim como no cenário anterior (cenário E), nenhuma das configurações testadas obteve uma média de erro inferior ao limite de qualidade estabelecido. A configuração 2 foi a que apresentou os melhores resultados em termos da média total e, juntamente com as configurações 4 e 3, conseguiu obter um alinhamento adequado em metade das amostras. As demais configurações propostas conseguiram obter um bom alinhamento em pelo menos uma das amostras, sendo que a configuração 9 conseguiu um erro de transformação abaixo do limiar em duas amostras. Conforme observado no cenário E, as configurações de referência que

Figura 33 – Gráfico do erro de transformação médio, por configuração, para as cenas do cenário F.



Fonte: elaborada pelo autor.

Nota: a linha tracejada representa o limiar para um erro de transformação aceitável.


empregaram a centralização obtiveram resultados médios piores do que todas as variantes sem centralização. Ademais, destaca-se que, entre as configurações de referência, apenas o algoritmo *GICP* foi capaz de alinhar ao menos uma das amostras.

As amostras utilizadas neste contexto apresentam um alto nível de complexidade, uma vez que foram adquiridas por sensores reais diretamente do ambiente físico, refletindo todas as características e desafios presentes na cena. Isso inclui variações de iluminação, ruído, oclusões e movimento da cena, conforme ilustrado na Figura 34. Portanto, é esperado que o processo de alinhamento dessas amostras com alta complexidade seja desafiador. Além disso, devido a indisponibilidade de recursos computacionais mais robustos, as nuvens originais foram subamostradas de forma significativa em razão da elevada densidade de pontos, o que, conseqüentemente, resultou na perda de informações valiosas que poderiam ter impactado nos resultados alcançados. Além disso, as hipóteses apresentadas no final da subseção anterior para o baixo desempenho no alinhamento de cenas *indoor* também são aplicáveis a esse cenário. Portanto, sugere-se que estudos futuros explorem essas possibilidades em busca de uma estratégia mais adequada para a utilização de descritores de superfície nesse cenário desafiador.

7.3 Considerações finais

Os resultados dos testes indicaram que as configurações 4, 3 e 2 demonstraram consistência e foram capazes de obter resultados satisfatórios em todos os cenários avaliados

Figura 34 – Amostras das cenas *outdoor* alinhadas satisfatoriamente pela melhor configuração (2). a) centro da cidade de Bremen; b) vista em torno do *Gaussian Point*.



Fonte: elaborada pelo autor.

que utilizaram modelos de objetos (cenários A-D), evidenciando sua robustez e versatilidade em diferentes situações. Embora tenham apresentado desempenho variado nos cenários com cenas *indoor* e *outdoor*, essas configurações obtiveram os menores valores de erro médio e conseguiram alinhar pelo menos uma das amostras, ao contrário dos algoritmos clássicos que utilizaram as nuvens completas subamostradas e não conseguiram alinhar nenhum dos conjuntos de pontos. A configuração 4 se destacou, demonstrando o melhor desempenho em metade dos cenários avaliados (cenários B, D e E). Além disso, ela consistentemente se posicionou entre as três melhores configurações em todos os testes realizados, abrangendo também os testes complementares, com a exceção do teste adicional no cenário B, no qual ficou em quarto lugar. Além disso, as configurações 3 e 2 também obtiveram bom desempenho, sendo frequentemente classificadas entre as três melhores configurações.

No capítulo subsequente, procederemos com análises mais minuciosas sobre o funcionamento iterativo das configurações 4, 3 e 2, examinando em detalhes como as regiões de interesse são selecionadas e filtradas. Além disso, buscaremos investigar se é viável otimizar essas configurações, resultando em um conjunto mais limitado de possibilidades, e conseqüentemente,

reduzindo a quantidade de iterações necessárias pelo *pipeline* iterativo de registro.

8 OTIMIZAÇÃO DAS CONFIGURAÇÕES DE MELHOR DESEMPENHO

As configurações de registro estudadas no Capítulo 6 visam obter o melhor alinhamento através de iterações que exploram diferentes combinações de parâmetros e/ou filtros. É importante considerar que configurações mais flexíveis requerem um maior número de iterações, resultando em um custo computacional mais elevado. No entanto, é possível que nem todas as combinações de parâmetros sejam necessárias, levantando a possibilidade de que um conjunto reduzido de combinações possa levar a um alinhamento igual ou semelhante. Portanto, o objetivo deste capítulo é investigar as configurações 4, 3 e 2, que apresentaram o melhor desempenho nos testes discutidos no capítulo anterior, a fim de verificar essa hipótese.

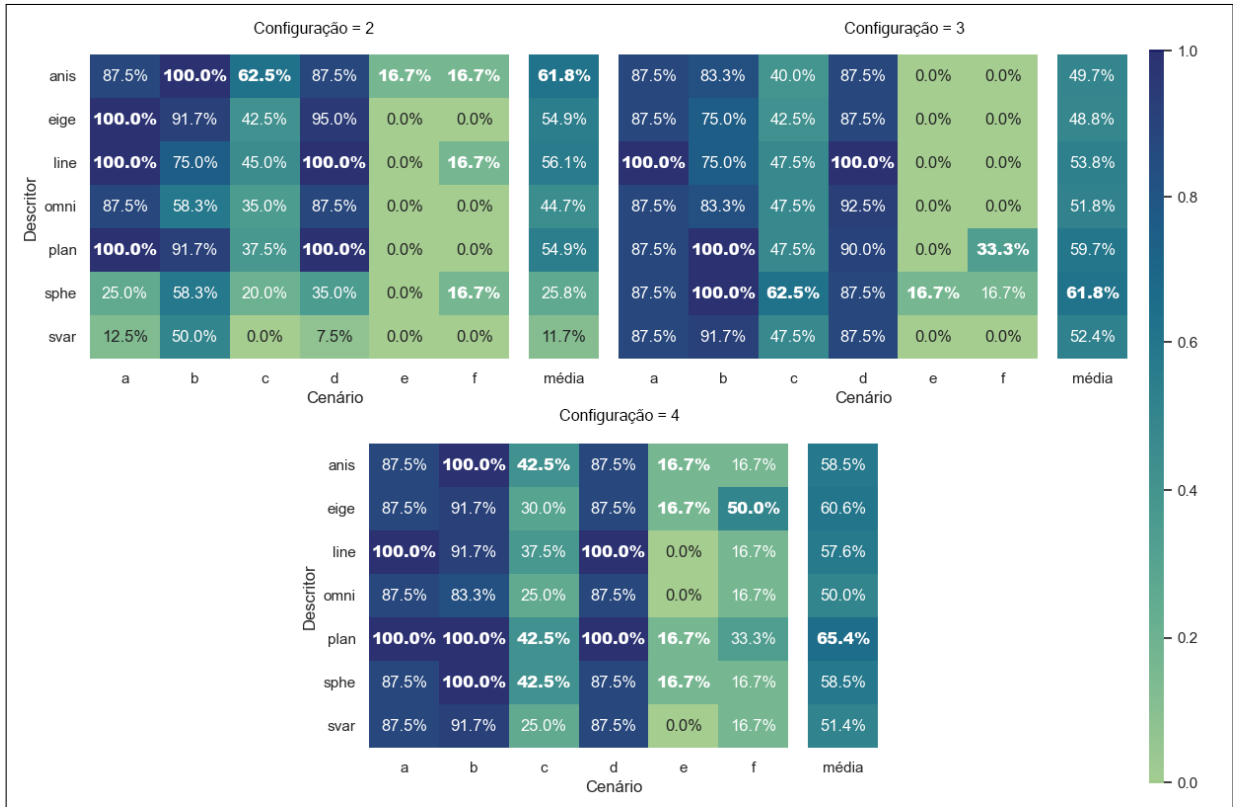
O *pipeline* de alinhamento original adota uma abordagem de seleção da melhor combinação possível dentre todas as opções de parametrização avaliadas, mesmo que outras combinações que não sejam numericamente as melhores possam ter gerado resultados adequados. Nesta investigação, ao invés de considerar apenas a combinação que gerou o menor erro de transformação, como feito no capítulo anterior, serão consideradas todas as combinações que resultaram em um erro de transformação dentro do limite admissível, de forma a permitir uma análise justa das combinações que apresentam resultados equivalentes.

8.1 Descritor utilizado

Ao considerar apenas o tipo de descritor geométrico de superfície utilizado na etapa de filtragem, é possível avaliar quais deles são capazes de proporcionar um alinhamento razoável na maior quantidade de amostras. Para isso, foram analisados os percentuais de amostras que obtiveram um alinhamento satisfatório utilizando uma combinação de parâmetros com um determinado descritor, conforme apresentado na Figura 35.

A análise dos resultados apresentados revela que nenhum dos descritores utilizados na etapa de filtragem foi capaz de realizar o alinhamento de todas as amostras em todos os cenários. Os descritores que demonstraram melhor desempenho foram a planaridade na configuração 4 (65,4%), a anisotropia na configuração 2 (61,8%) e a esfericidade na configuração 3 (61,8%). A utilização da planaridade na configuração 4 obteve os melhores resultados na maioria dos cenários, exceto no cenário F, no qual a autoentropia nessa configuração apresentou melhores resultados. Além disso, a planaridade foi o único descritor a conseguir, em pelo menos uma configuração, alinhar todas as amostras de forma satisfatória em metade dos cenários avaliados

Figura 35 – Mapa de calor do percentual de amostras que alcançaram um alinhamento aceitável por descritor e cenário.



Fonte: elaborada pelo autor.

Nota: os valores em negrito indicam os melhores resultados por cenário, considerando uma margem de erro de 1%.

(cenários A, B e D) e em 75% dos cenários com objetos.

Além disso, a média dos percentuais de amostras alinhadas satisfatoriamente por descritor foi relativamente próxima, com exceção da esfericidade e variação de superfície na configuração 2, que apresentaram médias abaixo de 26%. Destaca-se que que nos cenários *indoor* (cenário E) e *outdoor* (cenário F) existe um subconjunto de descritores que não resulta em alinhamentos adequados. No cenário E, os descritores de linearidade, omnivariância e variação de superfície não foram capazes de alinhar nenhuma das amostras em nenhuma das configurações testadas. Já no cenário F, apenas a configuração 4 foi capaz de obter alinhamentos satisfatórios em pelo menos uma das amostras, independentemente do descritor utilizado. Nas demais configurações, a utilização dos descritores de autoentropia, omnivariância e variação de superfície não resultou em nenhum alinhamento satisfatório. Isso indica que, pelo menos nessa configuração específica, esses descritores podem ser desconsiderados.

Os resultados apresentados na Figura 35 sugerem que o uso de um único descritor não é adequado para alinhar todas as amostras em determinados cenários. Essa constatação reforça a ideia inicial de se realizar filtragens consecutivas, alterando o descritor utilizado em

cada iteração. Embora a utilização de todos os descritores disponíveis não seja capaz de alinhar todas as amostras nos cenários C, E e F, como discutido no Capítulo 7, é possível investigar qual subconjunto de descritores é suficiente para obter os melhores resultados.

Com esse objetivo, foram avaliadas todas as combinações possíveis de descritores e foram selecionadas aquelas que conseguiram alinhar a maior quantidade de amostras de acordo com cada cenário, como mostrado na Tabela 5.

Tabela 5 – Combinação mínima de descritores para os melhores resultados por configuração e cenários.

Configuração	Cenário	Descritor	Amostras Alinhadas
2	a	<i>eige</i> <i>line</i> <i>plan</i>	100.0%
2	b	<i>anis</i>	100.0%
2	c	<i>anis</i>	62.5%
2	d	<i>line</i> <i>plan</i>	100.0%
2	e	<i>anis</i>	16.7%
2	f	<i>anis</i> & <i>line</i> & <i>sphe</i>	50.0%
3	a	<i>line</i>	100.0%
3	b	<i>plan</i> <i>sphe</i>	100.0%
3	c	<i>sphe</i>	62.5%
3	d	<i>line</i>	100.0%
3	e	<i>sphe</i>	16.7%
3	f	<i>plan</i> & <i>sphe</i>	50.0%
4	a	<i>line</i> <i>plan</i>	100.0%
4	b	<i>anis</i> <i>plan</i> <i>sphe</i>	100.0%
4	c	(<i>anis</i> & <i>eige</i> & <i>plan</i>) (<i>eige</i> & <i>plan</i> & <i>sphe</i>)	52.5%
4	d	<i>line</i> <i>plan</i>	100.0%
4	e	(<i>anis</i> & <i>eige</i>) (<i>eige</i> & <i>plan</i>) (<i>eige</i> & <i>sphe</i>)	33.3%
4	f	<i>eige</i>	50.0%

Fonte: elaborada pelo autor.

Nota: o percentual de amostras alinhadas diz respeito à quantidade de amostras que alcançaram um alinhamento satisfatório. A utilização dos símbolos “|” e “&” entre descritores ou conjuntos de descritores indica que, respectivamente, qualquer um deles pode ser usado individualmente e que todos devem ser utilizados em conjunto para obter os mesmos resultados.

Ao avaliar os resultados apresentados na Tabela 5, pode-se observar que a utilização de mais de um descritor apresentou vantagens nos cenários F das configurações 2 e 3, e nos cenários C e E da configuração 4. Na configuração 2, a utilização da anisotropia, linearidade e planaridade no *pipeline* iterativo proporcionou um alinhamento aceitável em metade das amostras, superando as abordagens com um único descritor, que alinharam apenas 16.7% das amostras. De forma análoga, na configuração 3, a utilização de dois descritores (planaridade e esfericidade) resultou no alinhamento satisfatório de metade das amostras. Nos cenários C e E da configuração 4, a utilização de múltiplos descritores resultou em um aumento moderado na quantidade de amostras alinhadas de forma aceitável, alcançando 52.5% e 33% respectivamente.

Em alguns cenários, como A e D na configuração 2, B na configuração 3, e C e E na configuração 8, a utilização de um dos descritores listados ou de uma das combinações de descritores gerou os mesmos resultados.

Ao considerarmos todos os cenários, é possível observar que a combinação de apenas três descritores de superfície (ver Tabela 6) é suficiente para alcançar resultados semelhantes aos obtidos ao utilizar todos os sete descritores, em termos do percentual de amostras alinhadas satisfatoriamente. Essa combinação reduz em aproximadamente 57% a quantidade de iterações necessárias em ambas as configurações.

Tabela 6 – Combinação mínima de descritores que obtém os melhores resultados por configuração.

Configuração	Descritor	Amostras Alinhada
2	<i>anis & line & sphe</i>	71.5%
3	<i>plan & line & sphe</i>	71.5%
4	<i>(anis & eige & plan) (eige & plan & sphe)</i>	72.6%

Fonte: elaborada pelo autor.

Nota: o percentual de amostras alinhadas diz respeito à quantidade de amostras que alcançaram um alinhamento satisfatório. A utilização dos símbolos “|” e “&” entre descritores ou conjuntos de descritores indica que, respectivamente, qualquer um deles pode ser usado individualmente e que todos devem ser utilizados em conjunto para obter os mesmos resultados.

8.2 Intervalo de filtragem

Outro aspecto que pode ser investigado com o objetivo de verificar uma possível redução no número de iterações está relacionado aos intervalos (mínimo e máximo) adotados na etapa de filtragem. Esses intervalos são explorados pelo *pipeline* de registro proposto, que realiza uma busca iterativa por intervalos ideais para a filtragem de cada amostra, como descrito no Capítulo 6. Utilizando uma estratégia de análise semelhante à empregada na avaliação dos descritores mencionados anteriormente, foram identificadas as combinações de intervalos mais eficazes que permitiram o alinhamento aceitável da maior quantidade possível de amostras. Os resultados dessas análises estão apresentados na Tabela 7. É importante ressaltar que, de acordo com a Tabela 1, nas configurações 2 e 3, um dos limites (mínimo ou máximo) é fixo. Portanto, ao examinarmos essas duas configurações, não consideraremos os 55 intervalos possíveis, como na configuração 4. Em vez disso, iremos focar em um subconjunto desses intervalos que possuem os respectivos limites fixos de cada configuração. Isso ocorre porque qualquer outra variação de intervalo resultaria em configurações diferentes das 2 e 3.

Tabela 7 – Combinação mínima de intervalos de filtragem para obtenção dos melhores resultados com as configurações 6 e 8 em cada cenário.

Config.	Cenário	Intervalo de filtragem dos pontos (min., max.)	Amostras Alinhadas
2	a	(0.2, 0.7) (0.2, 0.8) (0.2, 0.9) (0.2, 1.0)	100.0%
2	b	(0.2, 0.4) (0.2, 0.7) (0.2, 0.8) (0.2, 0.9)	100.0%
2	c	(0.2, 0.7)&(0.2, 0.5)&(0.2, 0.9)	62.5%
2	d	(0.2, 0.7) (0.2, 0.8) (0.2, 0.9) (0.2, 1.0)	100.0%
2	e	(0.2, 0.6) (0.2, 0.7)	16.7%
2	f	(0.2, 0.6)&(0.2, 0.7)&(0.2, 0.3)	50.0%
3	a	(0.2, 1.0)	100.0%
3	b	(0.4, 1.0) (0.5, 1.0) (0.8, 1.0) (0.9, 1.0)	100.0%
3	c	(0.5, 1.0)&(0.1, 1.0)	62.5%
3	d	(0.2, 1.0)	100.0%
3	e	(0.3, 1.0) (0.4, 1.0)	16.7%
3	f	(0.4, 1.0)	50.0%
4	a	(0.0, 0.7) (0.1, 0.7) (0.2, 0.7) (0.2, 0.8) (0.2, 0.9) (0.2, 1.0)	100.0%
4	b	(0.2, 0.9) (0.5, 0.8) (0.5, 1.0) (0.9, 1.0)	100.0%
4	c	(0.8, 0.9)&(0.5, 0.8)&(0.1, 0.4)	52.5%
4	d	(0.0, 0.7) (0.1, 0.7) (0.2, 0.7) (0.2, 0.9) (0.2, 1.0)	100.0%
4	e	(0.3, 0.6)	33.3%
4	f	(0.6, 0.8)	50.0%

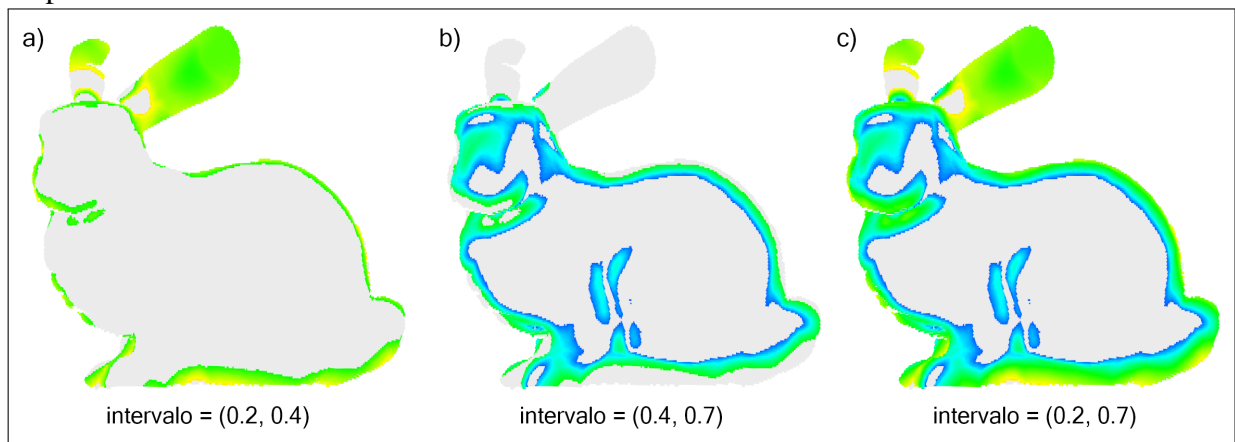
Fonte: elaborada pelo autor.

Nota: o percentual de amostras alinhadas diz respeito à quantidade de amostras que alcançaram um alinhamento satisfatório. Os intervalos (mínimo, máximo) são utilizados para selecionar os pontos de interesse a partir do valor dos descritores normalizados. A utilização dos símbolos “|” e “&” entre intervalos ou conjuntos de intervalos indica que, respectivamente, qualquer um deles pode ser usado individualmente e que todos devem ser utilizados em conjunto para obter os mesmos resultados.

Ao analisarmos os resultados obtidos na seleção dos intervalos de filtragem, é possível notar que, em todos os cenários e configurações, foram necessários, no máximo, três intervalos de filtragem para obter a mesma quantidade de amostras com alinhamento satisfatório em comparação aos experimentos realizados no Capítulo 7. No entanto, o cenário C, que avaliou vários níveis de ruído, foi aquele que necessitou de mais de um intervalo para alcançar os

melhores resultados em ambas as configurações avaliadas. Nos demais cenários, com exceção do cenário F na configuração 2, o melhor alinhamento foi alcançado utilizando um único intervalo de filtragem. É importante destacar que, nesta subseção, os intervalos representados na forma $intv = (intv_{min}, intv_{max})$ correspondem à filtragem realizada em uma única iteração, e não a um conjunto de intervalos como $(intv_{min}, intv_{min} + 0.1), \dots, (intv_{max} - 0.1, intv_{max})$ utilizado em capítulos anteriores. A Figura 36 ilustra um exemplo de diferentes subnuvens obtidas por meio da utilização de intervalos de filtragem distintos.

Figura 36 – Subnuvens selecionadas a partir de intervalos de filtragem distintos, usando o descritor de planaridade.



Fonte: elaborada pelo autor.

Nota: as regiões cinza representam os pontos descartados das nuvens originais.

No contexto geral (cenários A-F), a configuração 2 obteve uma redução mais modesta (38%) na quantidade de intervalos necessários, passando de oito para cinco intervalos, em relação aos limites originais para alcançar os melhores resultados. Por outro lado, as configurações 4 e 3 obtiveram reduções mais significativas, diminuindo de 55 para, no máximo, seis intervalos na primeira e de dez para quatro na segunda, representando uma redução de 89% e 60% respectivamente no número de iterações necessárias. Isso demonstra que, mesmo considerando uma grande quantidade de amostras com características variadas e elevado grau de complexidade, avaliar um pequeno conjunto de intervalos foi suficiente para alcançar os melhores resultados em ambas as configurações.

8.3 Algoritmo de registro

Em seguida, avaliamos quais algoritmos de registro foram mais frequentemente utilizados para alcançar os melhores resultados. Considerando que a configuração 4 fixa o GICP

como a função de registro, a mesma foi excluída desta avaliação. Os resultados por cenário das configurações 2 e 3 estão disponíveis na tabela da Figura 8.

Tabela 8 – Combinação mínima de algoritmos de registro que obtém os melhores resultados por configuração e cenário.

Configuração	Cenário	Função de registro	Amostras Alinhadas
2	a	$p2pl \mid gicp$	100.0%
2	b	$p2p \mid gicp$	100.0%
2	c	$p2p \ \& \ p2pl \ \& \ gicp$	62.5%
2	d	$p2pl \mid gicp$	100.0%
2	e	$p2p \mid p2pl \mid gicp$	16.7%
2	f	$p2pl \ \& \ gicp$	50.0%
3	a	$gicp$	100.0%
3	b	$p2p \mid p2pl \mid gicp$	100.0%
3	c	$p2p \ \& \ p2pl$	62.5%
3	d	$gicp$	100.0%
3	e	$p2p \mid p2pl \mid gicp$	16.7%
3	f	$p2pl \ \& \ gicp$	50.0%

Fonte: elaborada pelo autor.

Nota: o percentual de amostras alinhadas diz respeito à quantidade de amostras que alcançaram um alinhamento satisfatório. A utilização dos símbolos “|” e “&” entre intervalos ou conjuntos de intervalos indica que, respectivamente, qualquer um deles pode ser usado individualmente e que todos devem ser utilizados em conjunto para obter os mesmos resultados.

Observamos que GICP foi a função de registro mais comumente utilizada, não contribuindo para os melhores resultados apenas no cenário C da configuração 3. Além disso, somente o GICP foi suficiente para alcançar o melhor resultado em quatro dos seis cenários em ambas as configurações. Isso indica que, embora haja casos em que outros algoritmos se saiam melhor, o GICP mostrou-se consistente e não por acaso foi utilizado na configuração 4, recorrentemente a melhor em vários cenários de teste. Entretanto, se avaliarmos o panorama completo com todos os cenários de testes, somente utilizando os três algoritmos de registro (com centralização) considerados neste trabalho podemos alcançar o maior número de amostras alinhadas satisfatoriamente em ambas as configurações propostas avaliadas neste capítulo.


8.4 Considerações finais

Neste capítulo, realizamos uma investigação para confirmar a suposição de que é possível otimizar as melhores configurações apresentadas no Capítulo 7 por meio de iterações em um subconjunto reduzido de combinações de parâmetros. Os resultados obtidos demonstraram que essa abordagem é eficaz, permitindo uma redução significativa na quantidade de iterações necessárias no *pipeline* proposto. Para o conjunto de amostras avaliadas, foi observada

uma redução significativa na quantidade de iterações necessárias, passando de 336 para 18 na configuração 2 (redução de 94.6%), de 420 para 18 na configuração 3 (redução de 95.7%) e de 770 para 20 na configuração 4 (redução de 97.4%). Essa redução significativa no número de iterações proporciona uma otimização valiosa para o processo de registro das nuvens de pontos utilizando as estratégias avaliadas.

A Figura 37 resume a quantidade de iterações necessárias para obter o maior percentual de amostras alinhadas satisfatoriamente (indicado entre parênteses), após a implementação das otimizações mencionadas nas seções anteriores. Nota-se que, ao reduzir o escopo do problema para apenas um dos cenários, há uma redução significativa no número de iterações necessárias para alcançar os melhores resultados. Por exemplo, para os cenários A e D, foi necessário apenas uma única combinação de intervalo de filtragem, descritor e algoritmo de registro para alinhar todas as amostras – a Figura 37 apresenta o dobro de iterações devido ao passo adicional que considera a inversão das entradas. Esse resultado é particularmente útil quando se pretende alinhar nuvens de pontos com apenas algumas das características avaliadas neste trabalho, possibilitando a redução do esforço computacional necessário para o registro em cenários específicos.

Figura 37 – Mapa de calor do número otimizado de iterações por configuração e cenário.




Fonte: elaborada pelo autor.

Nota: os valores entre parenteses correspondem ao percentual de amostras alinhadas satisfatoriamente.

Embora a redução no número de iterações tenha sido significativa considerando todas as amostras, é importante ressaltar que algumas amostras correspondem a cenários extremos. Ao remover essas amostras da avaliação, é possível alcançar reduções ainda maiores. A Figura 38 apresenta os resultados para os cenários que utilizaram objetos (A-D), nos quais as amostras com ruído severo (acima do quarto nível de ruído) foram removidas do cenário C, resultando em um cenário mais realista (C*). Nesse contexto, as configurações 2 e 3 demonstraram reduções mais significativas na quantidade de iterações, com 97.0% e 97.6% respectivamente, além de

obterem um alinhamento satisfatório em todas as amostras de ambos os cenários. A configuração 4 também obteve uma redução maior na quantidade de iterações (98.2%), porém não conseguiu alcançar um alinhamento razoável em todas as amostras do cenário C*.

Figura 38 – Mapa de calor do número otimizado de iterações por configuração dos cenários com objetos.



Fonte: elaborada pelo autor.

Nota: os valores entre parênteses correspondem ao percentual de amostras alinhadas satisfatoriamente. A configuração C* é um subconjunto da configuração C que contém as amostras até o quarto nível de ruído.

A Tabela 9 fornece uma comparação entre a quantidade de iterações e o número de alinhamentos satisfatórios necessários para a execução do *pipeline* original, conforme apresentado no Capítulo 7, o *pipeline* otimizado para os cenários A-F e o *pipeline* otimizado para os cenários A, B, C* e D.

Tabela 9 – Comparação entre o *pipeline* original, o *pipeline* otimizado para os cenários A-F e o *pipeline* otimizado para os cenários A, B, C* e D.

Conf.	Num. Iter.	Alin. Satis.	Cenários A-F			Cenários A,B,C*D		
			Num. Iter.	Redução	Alin. Satis.	Num. Iter.	Redução	Alin. Satis.
2	336	71.5%	18	94.6%	71.5%	10	97,0%	100.0%
3	420	71.5%	18	95.7%	71.5%	10	97,6%	100.0%
4	770	72.6%	20	97.4%	72.6%	14	98,2%	96.9%

Fonte: elaborada pelo autor.

Nota: o percentual de redução é calculado a em relação ao numero de iterações do *pipeline* original.

9 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho, investigamos a utilização de descritores geométricos de superfície, baseados na matriz de covariância da região em torno dos pontos, para selecionar regiões em imagens 3D que resultem em um alinhamento de melhor qualidade em comparação com a utilização dos conjuntos de pontos originais. Realizamos extensivos experimentos para avaliar o comportamento desses descritores e diversas estratégias de utilização no contexto do registro.

Inicialmente, realizamos uma investigação, utilizando um conjunto reduzido de amostras, onde observamos que a maioria dos descritores de superfície apresentou consistência nos valores obtidos em diferentes níveis de rotação. Essa consistência é fundamental para a seleção de regiões correspondentes em pares de nuvens de pontos a serem alinhados, uma vez que a correção de rotação é um dos objetivos do registro. Além disso, observamos que mesmo em níveis severos de subamostragem (10% da nuvem original), os valores dos descritores mantiveram uma similaridade relativa com os valores obtidos na nuvem original, indicando a robustez em relação a esse aspecto. Também constatamos que, em quatro dos cinco níveis de ruído avaliados, os valores obtidos para os descritores mantiveram boa consistência.

A suposição inicial de que regiões com maior mudança de curvatura seriam mais apropriadas para o alinhamento foi refutada pelos experimentos realizados. Testamos diversas estratégias de registro, incluindo filtragem simples (utilizando um único descritor), filtragem combinada (utilizando vários descritores), particionamento utilizando regiões filtradas com o auxílio de algoritmos como DBSCAN e k-médias, e particionamento utilizando pontos-chave das regiões filtradas. No entanto, nenhuma destas estratégias conseguiu consistentemente alcançar resultados superiores aos obtidos pelos algoritmos clássicos de registro utilizados neste estudo (ICP_{p2p} , ICP_{p2pl} , GICP), ao utilizar as nuvens completas.

Realizamos a avaliação de diversos intervalos de filtragem (55) e confirmamos a principal hipótese deste trabalho, que é possível obter alinhamentos de melhor qualidade ao filtrar conjuntos de pontos com base nos descritores investigados. Além disso, obtivemos resultados ainda mais promissores ao aplicar o *pipeline* de registro proposto, que adicionou graus de liberdade a um ou mais parâmetros utilizados no registro.

Conduzimos experimentos abrangentes, confrontando as seis melhores configurações com os algoritmos clássicos, utilizando 194 modelos 3D em seis cenários (A-F). Em todos os cenários de teste, as seis configurações avaliadas superaram as estratégias clássicas de alinhamento. Pelo menos dois terços das configurações propostas obtiveram alinhamentos

excelentes no registro de objetos com sobreposição total e parcial (cenários A e B), enquanto nenhum dos algoritmos clássicos de referência foi consistente em todas as amostras. Além disso, duas das configurações propostas (configurações 3 e 2) conseguiram obter alinhamentos satisfatórios em cinco dos dez níveis de ruído avaliados (cenário C), enquanto os melhores algoritmos de referência obtiveram bons resultados somente até o segundo nível de ruído. Isso demonstra que essas estratégias não são significativamente afetadas por níveis menos intensos de ruído, os quais não modificam de maneira significativa a superfície dos objetos, de forma semelhante ao ruído encontrado nos sensores reais. Em relação à subamostragem (cenário D), todas as configurações propostas conseguiram alinhar satisfatoriamente todas as amostras, o que indica que a subamostragem é uma estratégia viável para reduzir a carga computacional do *pipeline* de registro proposto, que inclui filtragem e alinhamento. No entanto, nos cenários *indoor* (E) e *outdoor* (F), os resultados não se mantiveram consistentes com os observados nos demais cenários. Embora algumas configurações tenham obtido bons alinhamentos em algumas amostras e superado todas as configurações de referência, os resultados não foram consistentes. Vários fatores podem ser especulados para os resultados insatisfatórios nessas situações, como subamostragem excessiva, vizinhança muito grande no cálculo dos descritores, sobreposição insuficiente entre os pares de nuvens e distância máxima inadequada para a busca de pares de pontos, entre outros.

A partir das configurações que apresentaram os melhores resultados nos cenários de testes (configurações 2, 3 e 4), realizamos uma investigação sobre formas de redução da quantidade de iterações do *pipeline* de registro proposto. Os resultados demonstram que é possível reduzir em mais de 94% o conjunto de possibilidades inicialmente proposto, mantendo a capacidade de alinhar satisfatoriamente a mesma quantidade de amostras. Além disso, em cenários de ruído menos intenso, utilizando apenas objetos, duas das três configurações conseguiram alinhar todas as amostras com no máximo dez iterações.

Finalmente, concluímos que segmentação com base nos descritores de superfície melhora a qualidade do alinhamento em todos os cenários avaliados, especialmente nos cenários com objetos, onde foram obtidos alinhamentos excelentes. Contudo, é importante destacar que o custo computacional associado ao cálculo dos descritores é bastante elevado e pode ser um fator limitante em situações onde a eficiência computacional seja mais importante do que a qualidade do alinhamento. Portanto, como trabalhos futuros, propomos investigar meios de otimizar o custo computacional, como a utilização de subamostragem que mostrou-se promissora. Além

disso, é necessário investigar a aplicabilidade dessa estratégia em cenários *indoor* e *outdoor* utilizando um conjunto mais abrangente de amostras.

A estratégia de seleção de regiões com base nos descritores geométricos de superfície, avaliada neste estudo, não está restrita apenas ao contexto do ICP e suas variantes. Portanto, sua aplicação pode ser estendida a outras estratégias de registro e avaliada em pesquisas futuras. Além disso, uma linha de investigação interessante consiste em explorar estratégias de predição da melhor configuração a ser empregada para um determinado conjunto de dados de entrada. Por exemplo, pode-se treinar um modelo de aprendizado profundo (*deep learning*) capaz de inferir a melhor configuração para registrar um par específico de nuvens de pontos. Isso pode proporcionar uma abordagem mais eficiente e automatizada para a seleção de configurações, levando em consideração as características específicas dos dados a serem registrados. Outra possibilidade promissora envolvendo *deep learning* é treinar um modelo com base nas regiões selecionadas em alinhamentos satisfatórios, utilizando os descritores geométricos de superfície. Nesse sentido, especula-se que o modelo possa aprender a executar a segmentação de maneira otimizada.

REFERÊNCIAS

- ALEOTTI, J.; RIZZINI, D. L.; CASELLI, S. Perception and grasping of object parts from active robot exploration. **Journal of Intelligent & Robotic Systems**, Springer, v. 76, p. 401–425, 2014.
- ANACONDA. **Anaconda Distribution**. 2023. Disponível em: <https://www.anaconda.com/products/distribution>. Acesso em: 17 de março de 2023.
- AOKI, Y.; GOFORTH, H.; SRIVATSAN, R. A.; LUCEY, S. Pointnetlk: Robust & efficient point cloud registration using pointnet. In: **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition**. [S. l.: s. n.], 2019. p. 7163–7172.
- BELLO, S. A.; YU, S.; WANG, C.; ADAM, J. M.; LI, J. Review: Deep learning on 3d point clouds. **Remote Sensing**, MDPI, v. 12, n. 11, p. 1729, 2020.
- BESL, P. J.; MCKAY, N. D. Method for registration of 3-d shapes. In: SPIE. **Sensor fusion IV: control paradigms and data structures**. [S. l.], 1992. v. 1611, p. 586–606.
- BÖRCS, A.; NAGY, B.; BENEDEK, C. Instant object detection in lidar point clouds. **IEEE Geoscience and Remote Sensing Letters**, IEEE, v. 14, n. 7, p. 992–996, 2017.
- BUENO, M.; GONZÁLEZ-JORGE, H.; MARTÍNEZ-SÁNCHEZ, J.; LORENZO, H. Automatic point cloud coarse registration using geometric keypoint descriptors for indoor scenes. **Automation in Construction**, Elsevier, v. 81, p. 134–148, 2017.
- CHEN, Y.; MEDIONI, G. Object modelling by registration of multiple range images. **Image and vision computing**, Elsevier, v. 10, n. 3, p. 145–155, 1992.
- DAI, W.; CHEN, P. A point cloud registration network combined with graph convolution and fpfh for feature extraction. In: IEEE. **2022 China Automation Congress (CAC)**. [S. l.], 2022. p. 2280–2284.
- DEMANTKÉ, J.; MALLET, C.; DAVID, N.; VALLET, B. Dimensionality based scale selection in 3d lidar point clouds. **The international archives of the photogrammetry, remote sensing and spatial information sciences**, Copernicus GmbH, v. 38, p. 97–102, 2012.
- ELDAR, Y.; LINDENBAUM, M.; PORAT, M.; ZEEVI, Y. Y. The farthest point strategy for progressive image sampling. **IEEE Transactions on Image Processing**, IEEE, v. 6, n. 9, p. 1305–1315, 1997.
- EPFL. **Statue Model Repository**. 2014. Disponível em: https://lgg.epfl.ch/statues_dataset.php. Acesso em: 29 de janeiro de 2022.
- ESTER, M.; KRIEGEL, H.-P.; SANDER, J.; XU, X. *et al.* A density-based algorithm for discovering clusters in large spatial databases with noise. In: **kdd**. [S. l.: s. n.], 1996. v. 96, n. 34, p. 226–231.
- GIONGO, M.; KOEHLER, H. S.; MACHADO, S. do A.; KIRCHNER, F. F.; MARCHETTI, M. Lidar: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–231, 2010.
- GRESSIN, A. Improving 3d lidar point cloud registration using optimal neighborhood knowledge. Citeseer, 2012.

- GUMHOLD, S.; WANG, X.; MACLEOD, R. S. *et al.* Feature extraction from point clouds. In: **IMR**. [S. l.: s. n.], 2001. p. 293–305.
- GUO, Y.; WANG, H.; HU, Q.; LIU, H.; LIU, L.; BENNAMOUN, M. Deep learning for 3d point clouds: A survey. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 43, n. 12, p. 4338–4364, 2020.
- HACKEL, T.; WEGNER, J. D.; SCHINDLER, K. Fast semantic segmentation of 3d point clouds with strongly varying density. **ISPRS annals of the photogrammetry, remote sensing and spatial information sciences**, Copernicus, v. 3, p. 177–184, 2016.
- HAN, X.-F.; JIN, J. S.; WANG, M.-J.; JIANG, W.; GAO, L.; XIAO, L. A review of algorithms for filtering the 3d point cloud. **Signal Processing: Image Communication**, Elsevier, v. 57, p. 103–112, 2017.
- HUANG, X.; MEI, G.; ZHANG, J.; ABBAS, R. A comprehensive survey on point cloud registration. **arXiv preprint arXiv:2103.02690**, 2021.
- JUTZI, B.; GROSS, H. Nearest neighbour classification on laser point clouds to gain object structures from buildings. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, n. Part 1, p. 4–7, 2009.
- KOHLISCH, N.; KOCH, P.; MAY, S. Lidar-based augmented reality for the development of test scenarios on safety for autonomous operation of a shunting locomotive. In: IEEE. **2023 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)**. [S. l.], 2023. p. 23–28.
- LALONDE, J.-F.; VANDAPEL, N.; HUBER, D. F.; HEBERT, M. Natural terrain classification using three-dimensional lidar data for ground robot mobility. **Journal of field robotics**, Wiley Online Library, v. 23, n. 10, p. 839–861, 2006.
- LEE, I.; SCHENK, T. Perceptual organization of 3d surface points. **International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences**, NATURAL RESOURCES CANADA, v. 34, n. 3/A, p. 193–198, 2002.
- LEHTOLA, V. V.; KAARTINEN, H.; NÜCHTER, A.; KAIJALUOTO, R.; KUKKO, A.; LITKEY, P.; HONKAVAARA, E.; ROSNELL, T.; VAAJA, M. T.; VIRTANEN, J.-P. *et al.* Comparison of the selected state-of-the-art 3d indoor scanning and point cloud generation methods. **Remote sensing**, MDPI, v. 9, n. 8, p. 796, 2017.
- LI, Y.; BU, R.; SUN, M.; WU, W.; DI, X.; CHEN, B. Pointcnn: Convolution on x-transformed points. **Advances in neural information processing systems**, v. 31, 2018.
- LIN, C.-C.; KUO, C.-H.; CHIANG, H.-T. Cnn-based classification for point cloud object with bearing angle image. **IEEE Sensors journal**, IEEE, v. 22, n. 1, p. 1003–1011, 2021.
- LIU, W.; LAI, B.; WANG, C.; BIAN, X.; YANG, W.; XIA, Y.; LIN, X.; LAI, S.-H.; WENG, D.; LI, J. Learning to match 2d images and 3d lidar point clouds for outdoor augmented reality. In: IEEE. **2020 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)**. [S. l.], 2020. p. 654–655.
- LU, F.; CHEN, G.; LIU, Y.; ZHANG, L.; QU, S.; LIU, S.; GU, R. Hregnet: A hierarchical network for large-scale outdoor lidar point cloud registration. In: **Proceedings of the IEEE/CVF International Conference on Computer Vision**. [S. l.: s. n.], 2021. p. 16014–16023.

- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: **Proc. 5th Berkeley Symposium on Math., Stat., and Prob.** [S. l.: s. n.], 1965. p. 281.
- MERLIANA, N. P. E.; SANTOSO, A. J. *et al.* Analisa penentuan jumlah cluster terbaik pada metode k-means clustering. 2015.
- MIAN, A. S.; BENNAMOUN, M.; OWENS, R. Three-dimensional model-based object recognition and segmentation in cluttered scenes. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 28, n. 10, p. 1584–1601, 2006.
- NETO, P. S.; SOARES, J. M.; THÉ, G. A. P. Uniaxial partitioning strategy for efficient point cloud registration. **Sensors**, MDPI, v. 22, n. 8, p. 2887, 2022.
- NüCHTER; LINGEMANN. **Robotic 3D Scan Repository**. 2016. Disponível em: <http://kos.informatik.uni-osnabrueck.de/3Dscans>. Acesso em: 24 de março de 2023.
- OPEN3D. **Open3D | A Modern Library for 3D Data Processing**. 2023. Disponível em: <http://www.open3d.org/>. Acesso em: 17 de março de 2023.
- PAK, J.; SON, H. I. Semantic slam-based autonomous tributary navigation system using 3d lidar point cloud for uav. In: IEEE. **2022 22nd International Conference on Control, Automation and Systems (ICCAS)**. [S. l.], 2022. p. 1380–1382.
- PARK, J.; ZHOU, Q.-Y.; KOLTUN, V. Colored point cloud registration revisited. In: **Proceedings of the IEEE international conference on computer vision**. [S. l.: s. n.], 2017. p. 143–152.
- PEREIRA, N. S.; CARVALHO, C. R.; THÉ, G. A. Point cloud partitioning approach for icp improvement. In: IEEE. **2015 21st International Conference on Automation and Computing (ICAC)**. [S. l.], 2015. p. 1–5.
- PFRUNDER, A.; BORGES, P. V.; ROMERO, A. R.; CATT, G.; ELFES, A. Real-time autonomous ground vehicle navigation in heterogeneous environments using a 3d lidar. In: IEEE. **2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**. [S. l.], 2017. p. 2601–2608.
- POMERLEAU, F.; COLAS, F.; SIEGWART, R. *et al.* A review of point cloud registration algorithms for mobile robotics. **Foundations and Trends® in Robotics**, Now Publishers, Inc., v. 4, n. 1, p. 1–104, 2015.
- QI, C. R.; SU, H.; MO, K.; GUIBAS, L. J. Pointnet: Deep learning on point sets for 3d classification and segmentation. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S. l.: s. n.], 2017. p. 652–660.
- QI, C. R.; YI, L.; SU, H.; GUIBAS, L. J. Pointnet++: Deep hierarchical feature learning on point sets in a metric space. **Advances in neural information processing systems**, v. 30, 2017.
- RUSU, R. B.; BLODOW, N.; BEETZ, M. Fast point feature histograms (fpfh) for 3d registration. In: IEEE. **2009 IEEE international conference on robotics and automation**. [S. l.], 2009. p. 3212–3217.
- SEGAL, A.; HAEHNEL, D.; THRUN, S. Generalized-icp. In: SEATTLE, WA. **Robotics: science and systems**. [S. l.], 2009. v. 2, n. 4, p. 435.

- SI, H.; QIU, J.; LI, Y. A review of point cloud registration algorithms for laser scanners: applications in large-scale aircraft measurement. **Applied Sciences**, MDPI, v. 12, n. 20, p. 10247, 2022.
- SOUZA, D. A.; SOARES, J. M.; GEORGE, A. Uma revisao sobre as abordagens de particionamento e de selecao de regioes relevantes para registro de nuvens de pontos 3d. 2022.
- STANFORD. **The Stanford 3D Scanning Repository**. 2014. Disponível em: <http://graphics.stanford.edu/data/3Dscanrep/>. Acesso em: 17 de março de 2023.
- SUN, R.; ZHANG, E.; MU, D.; JI, S.; ZHANG, Z.; LIU, H.; FU, Z. Optimization of the 3d point cloud registration algorithm based on fpfh features. **Applied Sciences**, MDPI, v. 13, n. 5, p. 3096, 2023.
- TAM, G. K.; CHENG, Z.-Q.; LAI, Y.-K.; LANGBEIN, F. C.; LIU, Y.; MARSHALL, D.; MARTIN, R. R.; SUN, X.-F.; ROSIN, P. L. Registration of 3d point clouds and meshes: A survey from rigid to nonrigid. **IEEE transactions on visualization and computer graphics**, IEEE, v. 19, n. 7, p. 1199–1217, 2012.
- TOMBARI, F.; SALTI, S.; STEFANO, L. D. Unique signatures of histograms for local surface description. In: SPRINGER. **Computer Vision–ECCV 2010: 11th European Conference on Computer Vision, Heraklion, Crete, Greece, September 5-11, 2010, Proceedings, Part III 11**. [S. l.], 2010. p. 356–369.
- WANG, L.; YUAN, B. Curvature and density based feature point detection for point cloud data. IET, 2010.
- WANG, Y.; SUN, Y.; LIU, Z.; SARMA, S. E.; BRONSTEIN, M. M.; SOLOMON, J. M. Dynamic graph cnn for learning on point clouds. **Acm Transactions On Graphics (tog)**, ACM New York, NY, USA, v. 38, n. 5, p. 1–12, 2019.
- WEINMANN, M. Feature relevance assessment for the semantic interpretation of 3d point cloud data. Deutsche Nationalbibliothek, 2013.
- WEINMANN, M.; MALLETT, C.; HINZ, S.; JUTZI, B. Efficient interpretation of 3d point clouds by assessing feature relevance. **AVN–Allg Vermess-Nachr**, v. 10, n. 2015, p. 308–315, 2015.
- WU, W.; QI, Z.; FUXIN, L. Pointconv: Deep convolutional networks on 3d point clouds. In: **Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition**. [S. l.: s. n.], 2019. p. 9621–9630.
- XU, G.; PANG, Y.; BAI, Z.; WANG, Y.; LU, Z. A fast point clouds registration algorithm for laser scanners. **Applied Sciences**, MDPI, v. 11, n. 8, p. 3426, 2021.
- YEW, Z. J.; LEE, G. H. Rpm-net: Robust point matching using learned features. In: **Proceedings of the IEEE/CVF conference on computer vision and pattern recognition**. [S. l.: s. n.], 2020. p. 11824–11833.
- YIN, H.; XU, X.; LU, S.; CHEN, X.; XIONG, R.; SHEN, S.; STACHNISS, C.; WANG, Y. A survey on global lidar localization: Challenges, advances and open problems. **arXiv preprint arXiv:2302.07433**, 2023.
- YP, S. T.; ZELE, R. Deep learning-based 3d face recognition using masked facial point cloud. Institute of Electrical and Electronics Engineers Inc., 2022.