

# Uma Revisão Sobre as Abordagens de Particionamento e de Seleção de Regiões Relevantes para Registro de Nuvens de Pontos 3D

Daniel A. C. Souza\* José M. Soares\* George A. P. Thé\*

\* Departamento de Engenharia de Teleinformática, Universidade  
Federal do Ceará, Fortaleza, CE,  
e-mails: daniel.araujo@alu.ufc.br, marques@ufc.br, george.the@ufc.br

**Abstract:** The registration of 3D point clouds consists of correcting the pose of two or more partial views of objects or scenes captured in different perspectives, which finds applications in robotics and autonomous navigation. In that domain, a relevant issue involves the complexity of the alignment operation, and some methods seek to reduce it by selecting subsets of relevant points from the original clouds. In order to understand the state-of-the-art in this context, a review of the methods published between 2017 and 2021 was carried out. Eleven methods were evaluated in relation to the following questions: approach, way of selecting points of interest, type of application, technical limitations and evaluation methodology of the registration. In order to support research in this domain, the protocol adopted and the results of this evaluation were carefully documented. The review revealed that the approaches found have similar purposes, such as dense cloud alignment, recording of captures by heterogeneous sensors, merging of noisy clouds and optimization of approaches from the literature.

**Resumo:** O registro de nuvens de pontos 3D consiste em corrigir a pose de duas ou mais visões parciais de objetos ou cenas capturadas em diferentes perspectivas, o qual encontra aplicações em robótica e navegação autônoma. No referido domínio, uma questão relevante envolve a complexidade da operação de alinhamento, e alguns métodos buscam reduzi-la por meio da seleção de subconjuntos de pontos relevantes das nuvens originais. Com vistas a compreender o estado-da-arte neste contexto, realizou-se uma revisão dos métodos publicados entre 2017 e 2021. Onze métodos foram avaliados em relação aos seguintes quesitos: abordagem, forma de seleção de pontos de interesse, tipo de aplicação, limitações técnicas e metodologia de avaliação do registro. Visando oferecer suporte a pesquisas neste domínio, o protocolo adotado e os resultados dessa avaliação foram criteriosamente documentados. A revisão revelou que as abordagens encontradas possuem finalidades semelhantes, como alinhamento de nuvens densa, registro de capturas por sensores heterogêneos, fusão de nuvens ruidosas e otimização de abordagens da literatura.

*Keywords:* Point cloud; registration; 3D; partitioning; pre-processing.

*Palavras-chaves:* Nuvem de pontos; registro; 3D; particionamento; pré-processamento.

## 1. INTRODUÇÃO

O avanço tecnológico de dispositivos sensores de profundidade e do poder computacional torna mais fácil realizar aquisições e processamento de imagens em três dimensões com qualidade, rapidez e baixo custo. Exemplos que atestam a popularização desta tecnologia são os sensores encontrados em videogames (*Microsoft Kinect*), drones, robôs, dispositivos domésticos inteligentes (*Intel RealSense*) e smartphones (*Apple iPhone X*) (Zhang, 2018).

Sensores de profundidade, como os LiDARs e as câmeras RGB-D, são capazes de amostrar espacialmente a superfície de um objeto em um conjunto de pontos coordenados  $(x, y, z)$ , frequentemente armazenados em um formato denominado *nuvem de pontos 3D*. Além desses escâneres, nuvens de pontos também podem ser produzidas utilizando *softwares* para a medição de distâncias e dimensões

reais de objetos por meio de imagens bidimensionais – fotogrametria (Mikhail et al., 2001).

Devido à oclusão por outro objeto ou à auto-occlusão, em que a perspectiva de captura impede o sensoriamento das áreas encobertas, como mostrado no exemplo da Figura 1-b, várias nuvens de pontos precisam ser obtidas em diferentes posições em torno dos objetos de interesse. Isso é feito, por exemplo, para que se possa realizar a reconstrução parcial ou total de tais objetos. Entretanto, as diferentes capturas realizadas em posições distintas precisam ser alinhadas em um mesmo sistema de referência espacial, como exemplificado na Figura 1-c. Este procedimento é denominado registro (ou fusão) de nuvens de pontos.

Muitas são as técnicas desenvolvidas para registro de nuvens de pontos 3D (Yang et al., 2021; Huang et al., 2017; Han et al., 2013; Besl and McKay, 1992). Tais técnicas, entretanto, costumam apresentar bons resultados para fconjuntos de pontos com características particulares. A neces-




Figura 1. a) e (b) visões parciais do coelho de Stanford (Stanford, 2014) em duas perspectivas com diferença de 45°. (c) superposição de (a) e (b).

sidade de algoritmos de registro genéricos, mais precisos e computacionalmente eficientes tem impulsionado novas pesquisas por parte da comunidade científica. Algumas abordagens aplicam uma etapa de pré-processamento para reduzir o tamanho dos conjuntos de pontos submetidos ao algoritmo de registro (Yang et al., 2021; Aoki et al., 2019; Yang et al., 2016; Bouaziz et al., 2013). Assim, a seleção de pontos ou regiões particulares das nuvens que serão alinhadas deve, ao mesmo tempo, preservar as informações geométricas relevantes e permitir um alinhamento mais rápido e de qualidade.

Visando fornecer aos pesquisadores uma visão consistente sobre as abordagens mais relevantes publicadas na literatura especializada, foi realizada uma revisão, por meio de um protocolo rigoroso, sobre os trabalhos mais relevantes publicados no período de janeiro de 2017 a dezembro de 2021. Com foco nos algoritmos que selecionam subconjuntos dos pontos originais para realização do registro de nuvens de pontos 3D, são descritas técnicas e fornecidas referências que possam apoiar o desenvolvimento de novas contribuições neste domínio, identificando-se, ainda, os cenários mais adequados para a aplicação das abordagens estudadas.

A seção seguinte descreve o protocolo utilizado para seleção dos estudos primários e extração dos dados avaliados. Na seção 3 são apresentados os trabalhos selecionados e as informações extraídas por meio do protocolo da revisão sistemática. Em seguida, na seção 4 os dados sumarizados são discutidos à luz das questões de pesquisa. Por fim, a seção 5 descreve as conclusões obtidas em forma de resposta às questões de pesquisa que nortearam este estudo.

## 2. PROTOCOLO DA REVISÃO SISTEMÁTICA

Para alcançar os objetivos definidos na primeira seção, esta revisão foi norteada pelas seguintes questões de pesquisa:

- QP1.** Quais são as metodologias utilizadas para o registro de nuvens de pontos 3D que se fundamentam no uso de partes ou segmentos particulares das nuvens de entrada?
- QP2.** Como as técnicas operam a redução do número de pontos das nuvens originais para aplicação das técnicas de registro?
- QP3.** Para que tipo de aplicação as técnicas baseadas em seleção de regiões da nuvem são recomendadas?
- QP4.** Quais as limitações apresentadas pelos procedimentos de registro baseados em sub-nuvens?
- QP5.** Como são avaliados qualitativamente e quantitativamente os registros realizados a partir de sub-nuvens de pontos?

### 2.1 Estratégia de Busca

Os trabalhos primários considerados nesta revisão foram obtidos por meio de buscas automáticas. Uma *string* de busca genérica foi constituída e sua sintaxe foi devidamente adaptada a cada fonte.

Devido à relevância para a área temática deste trabalho, foram selecionadas as seguintes fontes de busca: (1) *ACM Digital Library*<sup>1</sup>; (2) *IEEE Xplore*<sup>2</sup>; (3) *Scopus*<sup>3</sup> e (4) *Web of Science*<sup>4</sup>.

Foram definidos quatro grupos de palavras-chave que se associam aos propósitos deste trabalho, considerando-se os seguintes termos equivalentes:

- GP1** – *point+cloud, pointcloud, point-cloud, point+set, pointset, point-set*;
- GP2** – *registration, align, fusion*;
- GP3** – *3d, 3-d, threedimensional, three-dimensional*;
- GP4** – *segmentation, feature+extraction, partitioning, sub+cloud, subcloud, sub-cloud*.

A *string* de busca, construída com estes agrupamentos, leva em consideração a ocorrência dos termos no resumo e no título dos estudos da seguinte maneira:

**Resumo:** (GP1 AND GP2 AND GP3 AND GP4) AND  
**Título:** (GP2 AND (GP1 OR GP3 OR GP4)).

A partir dessa *string* de busca genérica, foram elaboradas *strings* de busca equivalentes adaptadas à cada fonte de busca.

Para verificar a qualidade da *string* de busca, devido à relevância, exigiu-se que os seguintes estudos de controle estivessem entre os resultantes da aplicação da busca automática:

- AC1:** The registration of non-cooperative moving targets laser point cloud in different view point (Wang et al., 2018).
- AC2:** Integrating Deep Semantic Segmentation Into 3-D Point Cloud Registration (Zaganidis et al., 2018).
- AC3:** Fast Point Cloud Registration using Semantic Segmentation (Truong et al., 2019).

### 2.2 Estratégia de seleção

O conjunto de estudos obtido pela busca automática foi refinado em quatro etapas. Na primeira etapa (**ES1**) foram removidos os trabalhos que são evolução entre conferências, duplicados ou que não foram publicados no período considerado nesta revisão. Na etapa seguinte (**ES2**), foi realizada a leitura do título e do resumo para avaliar a conformidade do trabalho ao tema da revisão. Na etapa seguinte (**ES3**), foi realizada a leitura da seção de desenvolvimento do algoritmo ou equivalente, pois espera-se nela encontrar as informações necessárias para a efetiva inclusão ou exclusão dos estudos na revisão. Por fim, na etapa **ES4**, foi feita a leitura do texto completo para seleção do conjunto final de estudos. Nas etapas de leitura (**ES2-**

<sup>1</sup> <https://dl.acm.org/>

<sup>2</sup> <https://ieeexplore.ieee.org/>

<sup>3</sup> <https://www.scopus.com/>

<sup>4</sup> <https://webofscience.com>

4), foram considerados os critérios de inclusão e exclusão descritos nas subseções seguintes.

Para selecionar os artigos relevantes e que possam fornecer dados para responder as questões de pesquisa, foi definido apenas um critério de inclusão, avaliado após a etapa **ES2** descrita na seção anterior:

**CI1** – O estudo propõe alguma técnica de registro de nuvem de pontos que utilize partes ou conjuntos particulares de pontos das nuvens *source* e *target* para o alinhamento.

Os estudos de baixa ou nenhuma relevância para esta revisão foram removidos caso incorram em, ao menos, um dos seguintes critérios de exclusão:

**CE1** – O texto do estudo não está disponível na íntegra, em idioma inglês ou português (especialmente considerado na etapa **ES2**);

**CE2** – Estudo fora do período especificado;

**CE3** – Estudo duplicado ou evolução entre conferências;

**CE4** – O estudo é descrição de curso, nota de aula, patente, editorial, resumo de palestra, tutorial, *survey*, *review*, tese, dissertação ou acesso antecipado;

**CE5** – O estudo não detalha a técnica de seleção do conjuntos de pontos particulares utilizados no registro;

**CE6** – O estudo não utiliza apenas nuvens de pontos 3D como entradas para a técnica de alinhamento;

**CE7** – O estudo utiliza somente nuvens de pontos coloridas para o registro;

**CE8** – A técnica de alinhamento necessita que os pontos das nuvens de entrada estejam pré-classificados ou pré-rotulados.

### 2.3 Formulário de Extração

Para realizar a mineração de informações nos estudos selecionados, foi utilizado um formulário de extração composto pelos seguintes elementos:

**Metadados:** Diz respeito ao identificador (ID); título do trabalho; autores; ano de publicação; base onde o trabalho foi publicado;

**Pré-processamento:** Diz respeito ao método de seleção das regiões de interesse; outro(s) pré-processamento(s) utilizado(s); tipo de seleção de pontos (particionamento, filtragem ou transformação);

**Dados:** Diz respeito à(s) base(s) de nuvens utilizada(s); tipo de base (pública, privada ou própria);

**Comparação:** Diz respeito às limitações de técnica de seleção; tipo de aplicação para o método proposto; técnicas de registro utilizadas para comparação de resultados; tipo de nuvem utilizada (específica ou genérica);

**Qualidade:** Diz respeito à(s) métrica(s) utilizada(s) para avaliar a qualidade alinhamento.

## 3. RESULTADOS

Após as buscas automatizadas, foram encontrados 253 trabalhos: 53 no *IEEE Xplorer*, 29 no *ACM Digital Library*, 72 no *Web of Science* e 99 no *Scopus*.

Após a busca, a estratégia de seleção foi aplicada. Na primeira etapa (ES1), a grande maioria dos artigos removidos (98) foram os enquadrados no CE3, seguido por

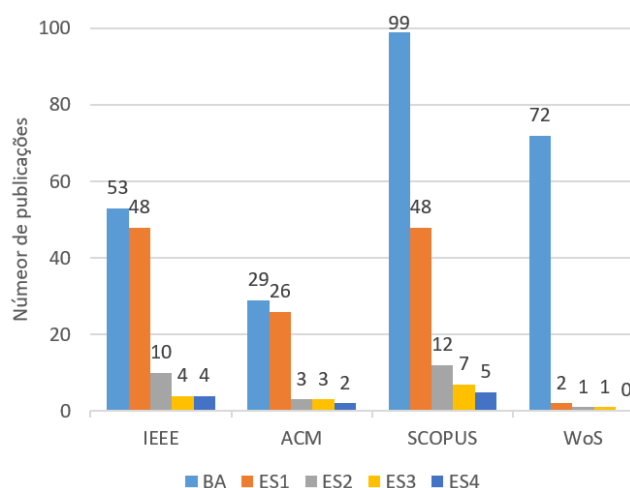


Figura 2. Quantidade de artigos selecionados em cada uma das etapas de triagem.

CE1 (27) e CE4 (4). Na segunda etapa (ES2), dos 124 trabalhos restantes, 98 foram removidos após a leitura do resumo e do título. Na terceira etapa (ES3), foi realizada a leitura da seção de desenvolvimento ou equivalente e, dos 26 trabalhos remanescentes, 11 foram eliminados. Por fim, na quarta etapa (ES4), foram removidos 4 artigos após a leitura do texto completo, restando os **11 artigos** que foram analisados nesta revisão. Na Figura 2 são mostrados os quantitativos de estudos eliminados por base em cada etapa.

Os 11 artigos selecionados são:

**EP01** – Integrating deep semantic segmentation into 3-D point cloud registration (Zaganidis et al., 2018);

**EP02** – A systematic approach for cross-source point cloud registration by preserving macro and micro structures (Huang et al., 2017);

**EP03** – Fast point cloud registration using semantic segmentation (Truong et al., 2019);

**EP04** – 3D registration of the point cloud data using ICP algorithm in medical image analysis (Sinko et al., 2018);

**EP05** – A Fast Weighted Registration Method of 3D Point Cloud Based on Curvature Feature (Liu et al., 2018);

**EP06** – VI-eye: semantic-based 3D point cloud registration for infrastructure-assisted autonomous driving (He et al., 2021);

**EP07** – 3D registration and integrated segmentation framework for heterogeneous unmanned robotic systems (Balta et al., 2020);

**EP08** – Point Cloud Registration Using Virtual Interest Points from Macaulay’s Resultant of Quadric Surfaces (Ahmed et al., 2021);

**EP09** – The registration of non-cooperative moving targets laser point cloud in different view point (Wang et al., 2018);

**EP10** – Contextual global registration of point clouds in urban scenes (Ge and Wu, 2019);

**EP11** – Precise Point Set Registration Based on Feature Fusion (Liu et al., 2021).

Dos estudos selecionados na etapa de busca automatizada (156), 78% foram publicados nos últimos 3 anos do período estabelecido (Figura 3-a). Também é observada uma ten-




Figura 3. Quantidade de artigos publicados por ano. a) Estudos selecionados após a remoção de duplicatas; b) Estudos selecionados após todas as etapas de seleção.

dência de crescimento na quantidade de publicações. Por outro lado, dos artigos selecionados para este estudo secundário, registra-se uma relativa homogeneidade na quantidade de trabalhos publicados por ano, como mostrado no Figura 3-b.

### 3.1 Bases de Dados

Dos estudos avaliados, cinco (EP01, EP02, EP05, EP08, EP09) utilizam nuvens de pontos genéricas, três (EP03, EP07, EP10) utilizam nuvem de pontos em grande escala (alta densidade de pontos), dois estudos (EP04, EP11) utilizam nuvens de pontos de imagens médicas e um estudo (EP06) utilizou nuvens de pontos de tráfego/trânsito. Na Tabela 1 são sumarizadas as bases de dados encontradas e o tipo de nuvem que é utilizada em cada estudo.

## 4. DISCUSSÃO

Embora a própria metodologia de seleção de regiões da nuvem de pontos seja considerada um tipo de pré-processamento da etapa de registro, em alguns casos, são necessárias outras etapas de pré-processamento para adequá-la ao registro.

### 4.1 Metodologias de Pré-processamento e Registro (QP1)

Dos estudos selecionados, seis (EP02, EP04-08) utilizaram outros tipos de pré-processamento além do método de seleção das regiões de interesse. Dentre esses, 67% dos estudos (EP04-07) utilizam uma importante etapa de pré-processamento, a remoção de *outliers*. Técnicas robustas aplicadas a cenários realistas exigem este procedimento, pois as nuvens de pontos obtidas pelos escâneres 3D são, frequentemente, contaminadas por um grande número de dados atípicos, principalmente se o objeto digitalizado for caracterizado por uma superfície refletiva (Wang and Feng, 2016). Além disso, a presença desse tipo de ruído prejudica, por exemplo, as etapas de segmentação de regiões de interesse, pois podem modificar as características de regiões da nuvem. Os dois estudos restantes utilizam normalização das nuvens de entrada (EP02), representação de superfície quádrada e cálculo de descritores para a etapa de seleção das regiões de interesse (EP08).

Os métodos de seleção das regiões de interesse foram categorizados em três tipos de estratégia de seleção:

Tabela 1. Bases de dados de nuvens de pontos utilizadas em cada estudo.

Estudo	Bases de Nuvens	Tipo de Base
EP01	Semantic3d.net, KITTI	Pública
EP02	3D de Stanford, Conjunto próprio	Pública e própria
EP03	Semantic 3D	Pública
EP04	-	-
EP05	Stanford University Graphic Laboratory data set	Pública
EP06	Campus Traffic Dataset, Indoor Simulated Traffic Dataset, KITTI	Pública e própria
EP07	Dovo, Rubble e Village	Própria
EP08	Object, Lab, Plant, Goose, Elmo, Rabbit, Sailor, Office, Storage, Stanford-office, Stanford-stage	Própria
EP09	Stanford Bunny	Pública
EP10	Escritório, Terraço com jardim de nível amplo e arranha-céus modernos, conjunto do campos da Technische Universität München (TUM), ThermalMapper adquirido pela Jacobs Universität Bremen, Capturas do campus da Universidade Politécnica de Hong Kong	Pública e própria
EP11	Imagens médicas ortodônticas	Própria

- **Filtragem** - técnicas que realizam a remoção de pontos sem modificar os pontos restantes (EP05, EP06, EP09-11);
- **Particionamento** - técnicas que dividem a nuvem de pontos em grupos de pontos ou sub-nuvens (EP01, EP03, EP08);
- **Transformação** - técnicas de reamostragem da nuvem de pontos que não preservam os pontos originais (EP01-04, EP07, EP08).

Os estudos categorizados como filtragem fazem uso de estratégias diversas para seleção dos pontos de interesse. Em EP06 é utilizada uma rede neural RangeNet++ (Milioto et al., 2019) para obter rótulos semânticos para cada ponto da nuvem; em seguida, esses pontos são agrupados por rótulo e os pontos que não pertencem a nenhuma das categorias de interesse são descartados. Essa estratégia é particularmente interessante, pois automatiza a tarefa de rotulação dos pontos e possibilita que o modelo aprenda as características mais relevantes, otimizando a posterior etapa de seleção de pontos. EP05 e EP10 utilizam metodologias baseadas em pesquisa de vizinhos mais próximos. EP11 utiliza uma metodologia baseada em clusterização via *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN) (Ester et al., 1996) para seleção dos *clusters* de pontos mais densos.

Os estudos baseados em técnicas de particionamento utilizam rótulos ou características dos pontos para realizar os agrupamentos e a divisão das nuvens de pontos, preservando todos os pontos originais. Esse tipo de particionamento visa agrupar as massas de pontos com informações contextuais semelhante. Com isso, posteriormente, é possível comparar os agrupamentos semelhantes das nuvens de entrada a fim de facilitar o alinhamento. EP01 e EP03 utilizam modelos de redes neurais – PointNet (Qi et al., 2017) e uma estrutura de aprendizado profundo proposta, respectivamente – para obter rótulos semânticos e EP08 utiliza características de curvatura para rotular os pontos.

Quatro (EP01-03, EP07) dos seis estudos que são baseados em técnicas de transformação da nuvem de pontos utilizam subamostragem por grade voxel (Lee et al., 2001). O estudo EP04 emprega subamostragem por meio de estruturas 3D SIFT (Scovanner et al., 2007). O estudo EP08 realiza a transformação dos dados de entrada propondo uma técnica baseada em interseção de superfícies quadráticas.

A maioria dos estudos avaliados (EP01, EP04, EP05, EP07, EP09, EP11) utilizam o algoritmo de registro ICP ou alguma de suas variantes para o alinhamento final das nuvens pré-processadas ou parcialmente alinhadas por meio de alguma etapa de alinhamento grosseiro. Outros dois estudos (EP06, EP08) utilizam o algoritmo RANSAC para alinhar os conjuntos de entrada. O estudo EP02 utiliza emparelhamento de grafos, gerados a partir dos super *voxels*, para estimar a melhor transformação. Os estudos EP03 e EP10 utilizam, respectivamente, uma variação rápida do algoritmo *Branch and Bound* (BnB) (Landrieu and Obozinski, 2017) intitulada *Fast BnB* e um estratégia baseada em congruência de pontos chaves para registrar as nuvens de pontos.

#### 4.2 Seleção das Regiões de Interesse (QP2)

Todas as técnicas categorizadas como *filtragem* fazem uso de estratégias de seleção que buscam preservar as regiões com características mais distintivas para otimização da etapa de registro, utilizando, como forma de seleção, a características de curvatura e a segmentação semântica. Um dos estudos (EP06) utiliza uma rede neural para obtenção dos rótulos semânticos dos pontos. Tal abordagem automatiza a etapa de extração de características, por meio da rede neural, para a rotulação dos pontos, superando as limitações inerentes à rotulação manual.

Todos os estudos categorizados como *particionamento* também foram categorizados como *transformação*, pois, após a etapa de particionamento, também é feita uma etapa de reamostragem. As técnicas apresentadas nesses estudos utilizam estratégias de segmentação baseadas em rótulos, obtidos de forma automatizada.

Dos estudos categorizados como *transformação*, 67% utilizaram, em alguma etapa, o filtro de grade de *voxels* para reamostragem dos dados das nuvens de pontos. Dois desses estudos (EP02, EP07) utilizaram esse filtro como a única estratégia de segmentação. Os demais estudos empregaram esse filtro após o agrupamento dos pontos. Dessa forma, busca-se reduzir a perda de informação intrínseca do processo de voxelização, pois a informação semântica

estará atrelada ao agrupamento e não individualmente à cada ponto.

A utilização de conjuntos de dados disponíveis a outros pesquisadores é de fundamental importância para a garantia da reprodutibilidade dos experimentos conduzidos em um estudo científico. Outro aspecto importante é o conhecimento prévio a respeito da natureza dos dados que estão sendo submetidos aos algoritmos de pré-processamento e registro. Isto permite avaliar se alguma característica do conjunto de dados é preponderante para obtenção de bons resultados na execução do *pipeline* de registro proposto. Nessa perspectiva, é interessante destacar que apenas 27% dos estudos utilizaram em seus experimentos exclusivamente bases de dados próprias, 36% utilizaram exclusivamente bases públicas, 27% utilizam bases públicas e próprias. Um dos estudos (EP04) não utiliza arquivos de nuvens de pontos diretamente, mas faz a conversão de arquivos de tomografia computadorizada (TC) e ressonância magnética (RM) para nuvens de pontos e, além disso, não as disponibilizou por se tratarem de imagens médicas. Embora o referido estudo faça um comparativo de sua técnica com outras encontradas na literatura, esse tipo de abordagem inviabiliza uma análise justa e livre de viés.

A maioria dos estudos (73%) utiliza ao menos dois conjuntos de nuvens de pontos diferentes. Estudos que utilizam somente bases públicas fazem uso de, no máximo, duas bases, enquanto um estudo utiliza onze bases de dados (EP08), todas próprias. A utilização de bases de dados diversificadas agrega qualidade aos métodos tanto do ponto de vista do desenvolvimento, pois evita o enviesamento do método proposto e eleva a generalidade da solução, quanto da perspectiva da avaliação da metodologia proposta.

#### 4.3 Cenários de Aplicação das Técnicas Encontradas (QP3)

As metodologias de registro propostas pelos estudos avaliados tem propósitos distintos. Alguns desses estudos (EP03, EP07, EP10), são voltados para o cenário do registro de nuvens de pontos de grande escala. Outros estudos (EP02, EP06) propõem técnicas para o cenário do registro de nuvens de pontos obtidas por sensores heterogêneos. É importante ressaltar que, embora a metodologia proposta no estudo EP07 utilize fusão de recursos obtidos por sensores de profundidade e câmeras 2D, para os propósitos desta revisão, foi considerada apenas a etapa de registro *Local Minima Escape ICP* (LME-ICP) que diz respeito ao registro de nuvens de pontos. Os demais estudos propõem técnicas para o alinhamento de cenas de ambientes com estrutura limitada (EP01), aprimoramento da velocidade e qualidade do registro (EP04, EP05), registro de conjuntos de pontos com diferença distinta entre plano de fundo e primeiro plano com estruturas geométricas diferentes (EP11), registro de nuvens ruidosas (EP08) ou com baixa taxa de sobreposição (EP09).

#### 4.4 Limitações das Técnicas Encontradas (QP4)

Os artigos EP01, EP03, EP04 não relataram as eventuais limitações que os métodos propostos para registro ou seleção das regiões de interesse possuem. Entretanto, a presença desse tipo de informação é importante, pois ajuda

a identificar potenciais pontos de melhoria na metodologia proposta.

Dentre os estudos que discutem alguma limitação, 38% apresentaram deficiência no registro de pares de nuvens de pontos que possuem baixa taxa de sobreposição (EP02, EP05, EP10). Especialmente no estudo EP02, é relatado que o método tende a falhar no caso em que as nuvens de entrada apresentem uma sobreposição inferior a 60%. Outra limitação registrada no estudo EP10 é possuir melhor desempenho em cenas onde os principais objetos digitalizados possuem certa continuidade, como, por exemplo, as estruturas feitas pelo homem em cenas urbanas.

Os demais trabalhos apresentaram limitações específicas: EP06 - depende de uma boa segmentação; EP07 - necessita da marcação manual de pelo menos três pares de pontos correspondentes em ambas as nuvens de pontos; EP08 - requer pelo menos três superfícies implícitas não paralelas na nuvem de pontos para calcular um único VIP; EP09 - para determinados regiões extraídas, o tempo de iteração pode ser prolongado; EP11 - requer conjuntos de pontos com diferenças significativas entre o fundo e o primeiro plano.

#### 4.5 Avaliação do Registro (QP5)

Nenhum dos estudos avaliados propôs uma métrica inovadora para avaliar a qualidade do registro, sendo este um problema em aberto. Com exceção do estudo EP03, que cita apenas métricas para avaliação da segmentação, e EP09, que não utilizou nenhuma métrica para avaliação do registro, os demais estudos verificam a qualidade do alinhamento por meio do *Root Mean Squared Error* (RMSE), *Mean Squared Error* (MSE) ou erro de rotação e translação. Dessas, RMSE e MSE são as métricas mais frequentemente utilizadas, embora as medidas obtidas não sejam comparáveis entre aplicações distintas. Além disso, mesmo grandes desalinhamentos podem levar a valores pequenos de erro quadrático médio, comprometendo a capacidade da métrica representar quantitativamente a qualidade do alinhamento. As métricas baseadas em erro de rotação e translação permitem apenas avaliar os resultados obtidos com base no conhecimento prévio do resultado esperado (padrão ouro). Entretanto esses valores de referência nem sempre estão disponíveis e podem depender de processos não automatizados para sua identificação. Além disso, essa é uma dependência indesejável para a avaliação genérica de algoritmos em múltiplos cenários e situações.

Um dos estudos selecionados (EP01) utilizou a função de distribuição cumulativa aliada ao erro de rotação e translação para avaliar o alinhamento das nuvens de pontos. Os gráficos da função de distribuição cumulativa (CDF), gerados a partir dos valores de erro da métrica utilizada, são interpretados como a probabilidade (eixo vertical) de que o erro de registro seja menor que o valor correspondente no eixo horizontal. Dessa forma, quanto maior a precisão do método, mais sua curva se aproxima do eixo vertical e, quanto maior a robustez do método, maior é a área delimitada entre sua curva e a curva de perturbação inicial (Zaganidis et al., 2018). Por exemplo, na figura 4 é apresentado um gráfico de distribuição cumulativa para dois métodos (A e B). O método A apresenta maior precisão do que o método B, pois se aproxima mais do

eixo vertical. Por outro lado, o método B apresenta maior robustez, pois a área delimitada entre sua curva e a curva da perturbação inicial é maior.




Figura 4. Exemplo de gráfico da função de distribuição cumulativa

Quanto à avaliação do *pipeline* completo (pré-processamento e registro), apenas dois trabalhos (EP07 e EP09) não realizaram nenhum estudo comparativo com outras técnicas existentes na literatura. Os demais trabalhos somados fizeram uso de 42 técnicas de registro diferentes. Dentre essas técnicas, 11 se apoiam no algoritmo *Iterative closest point* (ICP) (Besl and McKay, 1992) ou em alguma de suas variações. Dentre os trabalhos que realizaram estudos comparativos, destacam-se EP08 e EP02 que compararam o método proposto com 15 e 9 outras técnicas, respectivamente.

Na Tabela 2 são apresentadas as técnicas da literatura utilizadas no estudo comparativo, as métricas de avaliação da qualidade do registro e o tipo de nuvem de pontos utilizadas em cada estudo.

## 5. CONCLUSÃO

Técnicas de pré-processamento que selecionam partes ou segmentos do conjunto de pontos completo são uma das formas utilizadas no período investigado (2017-2021) para otimização de algoritmos de registro clássicos, como o ICP, e de novos *pipelines* de registro. Esses pré-processamentos podem ser sumarizados como técnicas de filtragem – seleção de um subconjunto dos pontos originais –, particionamento – fracionamento da nuvem de pontos em vários subconjuntos de pontos – e transformação – aplicação de transformação na nuvem de pontos de forma a não preservar nenhum dos pontos originais.

No total, foram identificadas onze metodologias de registro que atenderam aos critérios especificados no protocolo desta revisão. Desses, 73% utilizaram técnicas de seleção que preservam pontos. Além disso, observou-se que, nos estudos selecionados, a técnica de subamostragem por grade de *voxels* é comumente utilizada para realizar subamostragem, embora leve a perdas de informações distintivas.

Algumas das técnicas de registro avaliadas apresentam finalidades semelhantes, como alinhamentos de nuvens de pontos de grande escala (27%), alinhamento de nuvens

Tabela 2. Métricas de avaliação, técnicas comparadas e tipos das nuvens de pontos utilizadas em cada estudo analisado.

Estudo	Métrica de avaliação	Técnica comparada	Tipo de nuvem
EP01	CDF do erro de rotação e translação	NDT, GICP, FGR	Genérica
EP02	RMSE	IDCP, Go-ICP, 4PCS, super-4PCS, TPS-RM, GMMReg, CPD, SparseICP, JP-MPC	Genérica
EP03	-	TML-PC, TMLC-MS, SnapNet, Discrete convolutions, SPGraph	Grande escala
EP04	RMSE	ICP, ICP-kDTree	Médica
EP05	MSE	ICP clássico, IRLS-ICP	Genérica
EP06	Erro de rotação e translação	ICP, NDT, SAC-IA, FGR	Tráfego
EP07	RMSE	-	Grande escala
EP08	Erro de rotação e translação	Harris 3D+FPFH, Harris 3D+SHOT, Harris 3D+SpinImages, Harris 6D+FPFH, Harris 6D+SHOT, Harris 6D+SpinImages, ISS+FPFH, ISS+SHOT, ISS+SpinImages, SIFT 2.5D+FPFH, SIFT 2.5D+SHOT, SIFT 2.5D+SpinImages, Super 4PCS, Super Generalized 4PCS, Go-ICP	Genérica
EP09	-	-	Genérica
EP10	Erro de rotação, translação e RMSE	K4PCS, SAC-IA, DNT	Grande escala
EP11	Erro de rotação e translação e RMSE	CPD, NDT, ICP com métrica ponto a ponto, ICP com métrica ponto a plano, ICP com métrica ponto a ponto baseada em MCC, ICP com métrica ponto a plano baseada em MCC	Médica

obtidas por sensores heterogêneos (18%) e otimização (velocidade e qualidade) de algoritmos existentes (18%).

Dentre as limitações das técnicas relatadas, 38% tendem a não apresentar bons resultados em cenários onde as duas nuvens de pontos possuam baixa taxa de sobreposição, sendo essa a limitação mais comum. As demais limitações relatadas são de caráter diverso. Além disso, é importante ressaltar que uma parte considerável dos estudos (27%) não apontou objetivamente a existência de limitações para o método proposto.

Todos os estudos avaliados utilizaram métricas clássicas para a avaliação da qualidade do alinhamento (RMSE/MSE e erro de rotação/translação). Apenas um dos estudos inovou ao utilizar a função de distribuição cumulativa do erro de translação e rotação para avaliar qualitativamente o alinhamento, como ilustrado na Figura 4.

Finalmente, pretende-se que este estudo ofereça o suporte necessário à pesquisa no domínio do registro de nuvens de pontos 3D, em especial para as técnicas que buscam a otimização e redução da complexidade por meio da segmentação em subpartes ou da seleção de pontos das nuvens originais.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

## REFERÊNCIAS

- Ahmed, M.T., Ziauddin, S., Marshall, J.A., and Greenspan, M. (2021). Point cloud registration using virtual interest points from macaulay's resultant of quadric surfaces. *Journal of Mathematical Imaging and Vision*, 63(4), 457–471.
- Aoki, Y., Goforth, H., Srivatsan, R.A., and Lucey, S. (2019). Pointnetlk: Robust and efficient point cloud registration using pointnet. In *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 7156–7165. doi:10.1109/CVPR.2019.00733.
- Balta, H., Velagic, J., Beglerovic, H., De Cubber, G., and Siciliano, B. (2020). 3d registration and integrated segmentation framework for heterogeneous unmanned robotic systems. *Remote Sensing*, 12(10), 1608.
- Besl, P.J. and McKay, N.D. (1992). Method for registration of 3-d shapes. In *Sensor fusion IV: control paradigms and data structures*, volume 1611, 586–606. International Society for Optics and Photonics.
- Bouaziz, S., Tagliasacchi, A., and Pauly, M. (2013). Sparse iterative closest point. In *Computer graphics forum*, 113–123. Wiley Online Library.

- Ester, M., Kriegel, H.P., Sander, J., Xu, X., et al. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. In *kdd*, 34, 226–231.
- Ge, X. and Wu, B. (2019). Contextual global registration of point clouds in urban scenes. *Photogrammetric Engineering & Remote Sensing*, 85(8), 559–571.
- Han, J.Y., Perng, N.H., and Chen, H.J. (2013). Lidar point cloud registration by image detection technique. *IEEE Geoscience and Remote Sensing Letters*, 10(4), 746–750. doi:10.1109/LGRS.2012.2221075.
- He, Y., Ma, L., Jiang, Z., Tang, Y., and Xing, G. (2021). Vi-eye: semantic-based 3d point cloud registration for infrastructure-assisted autonomous driving. In *Proceedings of the 27th Annual International Conference on Mobile Computing and Networking*, 573–586.
- Huang, X., Zhang, J., Fan, L., Wu, Q., and Yuan, C. (2017). A systematic approach for cross-source point cloud registration by preserving macro and micro structures. *IEEE Transactions on Image Processing*, 26(7), 3261–3276. doi:10.1109/TIP.2017.2695888.
- Landrieu, L. and Obozinski, G. (2017). Cut pursuit: Fast algorithms to learn piecewise constant functions on general weighted graphs. *SIAM Journal on Imaging Sciences*, 10(4), 1724–1766.
- Lee, K., Woo, H., and Suk, T. (2001). Data reduction methods for reverse engineering. *The International journal of advanced manufacturing technology*, 17(10), 735–743.
- Liu, B., Gao, X., Liu, H., Wang, X., and Liang, B. (2018). A fast weighted registration method of 3d point cloud based on curvature feature. In *Proceedings of the 3rd International Conference on Multimedia and Image Processing*, 83–87.
- Liu, Y., Du, S., Cui, W., Wang, X., Mou, Q., Zhao, J., Guo, Y., and Zhang, Y. (2021). Precise point set registration based on feature fusion. *The Computer Journal*, 64(7), 1039–1055.
- Mikhail, E.M., Bethel, J.S., and McGlone, J.C. (2001). Introduction to modern photogrammetry. *New York*, 19.
- Milioto, A., Vizzo, I., Behley, J., and Stachniss, C. (2019). Rangenet++: Fast and accurate lidar semantic segmentation. In *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 4213–4220. IEEE.
- Qi, C.R., Su, H., Mo, K., and Guibas, L.J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 652–660.
- Scovanner, P., Ali, S., and Shah, M. (2007). A 3-dimensional sift descriptor and its application to action recognition. In *Proceedings of the 15th ACM international conference on Multimedia*, 357–360.
- Sinko, M., Kamencay, P., Hudec, R., and Benco, M. (2018). 3d registration of the point cloud data using icp algorithm in medical image analysis. In *2018 ELEKTRO*, 1–6. IEEE.
- Stanford (2014). The stanford 3d scanning repository. URL <http://graphics.stanford.edu/data/3Dscanrep/>.
- Truong, G., Gilani, S.Z., Islam, S.M.S., and Suter, D. (2019). Fast point cloud registration using semantic segmentation. In *2019 Digital Image Computing: Techniques and Applications (DICTA)*, 1–8. IEEE.
- Wang, S., Sun, H., and Guo, H. (2018). The registration of non-cooperative moving targets laser point cloud in different view point. In *Nanophotonics Australasia 2017*, volume 10456, 104565G. International Society for Optics and Photonics.
- Wang, Y. and Feng, H.Y. (2016). Effects of scanning orientation on outlier formation in 3d laser scanning of reflective surfaces. *Optics and Lasers in Engineering*, 81, 35–45.
- Yang, H., Shi, J., and Carlone, L. (2021). Teaser: Fast and certifiable point cloud registration. *IEEE Transactions on Robotics*, 37(2), 314–333. doi:10.1109/TRO.2020.3033695.
- Yang, J., Li, H., Campbell, D., and Jia, Y. (2016). Go-icp: A globally optimal solution to 3d icp point-set registration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(11), 2241–2254. doi:10.1109/TPAMI.2015.2513405.
- Zaganidis, A., Sun, L., Duckett, T., and Cielniak, G. (2018). Integrating deep semantic segmentation into 3-d point cloud registration. *IEEE Robotics and automation letters*, 3(4), 2942–2949.
- Zhang, S. (2018). High-speed 3d shape measurement with structured light methods: A review. *Optics and Lasers in Engineering*, 106, 119–131.