

SEGMENTAÇÃO DE OBJETOS POR POINT CLOUD EM ROBÓTICA DE SERVIÇO

Cauan Vinicius Espinha de Sousa¹, Plinio Thomaz Aquino Junior²
^{1,2} Departamento de Ciência da Computação, Centro Universitário FEI
unifcasousa@fei.edu.br; plinio.aquino@fei.edu.br

Resumo: A robótica é uma tecnologia crescente e versátil, aplicada em áreas como indústria e assistência médica. Uma função comum dos robôs é a manipulação de objetos usando técnicas de segmentação de objetos. A segmentação por *point cloud* representa a superfície de objetos em 3D. A proposta é usar essa técnica para ajudar robôs autônomos a identificar e manipular objetos desconhecidos, considerando suas características geométricas. Experimentos e simulações devem avaliar a eficácia do método, buscando avançar na robótica de serviço autônoma.

1. Introdução

A segmentação de objetos utilizando pontos de nuvem tem se revelado essencial para o avanço e a eficiência de robôs de serviço autônomos. Esta técnica de segmentação atua como uma ponte, permitindo que estes robôs identifiquem e interajam com regiões específicas de objetos no mundo real, garantindo a execução de tarefas de forma mais acurada. Diferentemente das câmeras tradicionais, os sensores de pontos de nuvem são capazes de capturar dados tridimensionais do ambiente. Isso oferece aos robôs uma perspectiva muito mais rica e detalhada do ambiente ao seu redor. Com essa riqueza de detalhes, robôs equipados com tal tecnologia podem tomar decisões mais informadas sobre posicionamento, aproximação e a melhor forma de manipular objetos específicos (Lai et al., 2022). O processo de segmentação, em si, é uma combinação intrincada de técnicas e algoritmos que trabalham para extrair informações cruciais dos pontos de nuvem, como a forma, posição, e orientação dos objetos. Diversas técnicas, incluindo análise de cores, texturas e formas, são aplicadas para alcançar uma segmentação precisa. Existem várias abordagens para a segmentação, cada uma com suas particularidades, como a segmentação baseada em regiões, que foca em dividir a cena em áreas de interesse, e a segmentação baseada em bordas, que se concentra nas bordas dos objetos para identificá-los (Qin, 2022). A importância da segmentação de objetos com pontos de nuvem transcende a mera teoria e encontra aplicações práticas em diversos setores. Desde a manufatura até a saúde, robôs estão sendo utilizados para executar tarefas que exigem precisão extrema, como pegar objetos delicados ou mover materiais em ambientes complexos. Ao melhorar a precisão e eficiência dessa segmentação, abrimos portas para inovações robóticas em diversos campos, otimizando processos e ampliando as possibilidades de automação (François et al., 2015). O objetivo dessa pesquisa é criar um modelo capaz de detectar objetos manipuláveis e detectar o plano sobre qual estão dispostos, para assim dar uma vasta gama de possibilidades, não só para fazer

a aproximação do objeto, mas também ao posicioná-lo na mesa, para a manipulação.

2. Conceitos básicos

Nesta seção, os fundamentos teóricos subjacentes ao trabalho são explorados. A **Nuvem de pontos** emerge como uma representação tridimensional de objetos e cenas, construída através da coleta massiva de pontos por dispositivos como câmeras 3D e scanners a laser. Essas representações, ao longo dos anos, tornaram-se ferramentas indispensáveis em uma variedade de campos. Em particular, em visão computacional, elas permitem a reconstrução 3D de objetos usando uma série de imagens 2D, fornecendo uma nova dimensão à análise de objetos (Lai et al, 2022). O conceito de **Segmentação de objetos** entra como um processo intrincado, porém crucial, na visão computacional e robótica. Aqui, o foco é isolar e destacar os objetos individuais presentes em uma imagem ou cena, tornando a análise subsequente mais focada e precisa. A qualidade da imagem em mãos e a intrincada composição da cena em questão podem, muitas vezes, ditar o sucesso ou o fracasso desta segmentação (Ma et al, 2022). Quando nos voltamos para a **Visão Computacional**, encontramos um campo dinâmico e em constante evolução. Esta é a disciplina que busca criar máquinas capazes de interpretar o mundo visualmente, assim como os humanos fazem. Desde o reconhecimento básico de objetos até a sofisticada análise de padrões de movimento, a visão computacional é central para muitas inovações tecnológicas atuais (Gonzalez, 2008). No centro de muitos avanços recentes em visão computacional estão as **Redes Neurais Convolucionais (CNNs)**. Estas são arquiteturas de aprendizado de máquina profundo, meticulosamente projetadas para processar dados visuais, sejam imagens ou nuvens de pontos. O poder das CNNs reside em sua capacidade de aprender automaticamente características espaciais hierárquicas dos dados, tornando-as uma ferramenta valiosa, especialmente quando se trata de análise de imagem (François et al., 2015).

3. Metodologia e Experimentação

Este estudo apresenta uma metodologia de pesquisa e experimentação baseada em simulação para aprimorar um modelo de detecção e manipulação de objetos em robótica de serviço utilizando nuvens de pontos. Inicialmente, ambientes virtuais são criados por meio de softwares de simulação robótica, permitindo a modelagem de cenários variados. Sensores de nuvem de pontos são simulados para capturar informações tridimensionais, e algoritmos de segmentação são implementados e ajustados para esses ambientes simulados. A validação ocorre pela comparação com

dados reais, avaliando o desempenho e a adaptabilidade do modelo proposto. Essa metodologia controlada possibilita explorar e otimizar a capacidade de segmentação, contribuindo para o desenvolvimento eficiente de sistemas de visão computacional em robótica de serviço. Incorporar uma metodologia baseada em simulação permite o aprimoramento de um modelo de detecção e manipulação de objetos em robótica de serviço com base em nuvens de pontos. Através da criação de ambientes virtuais simulados, implementação de algoritmos de segmentação adaptados e validação comparativa com dados reais, essa abordagem controlada facilita a otimização dos sistemas de visão computacional, melhorando sua capacidade de adaptação e desempenho em ambientes variados.

4. Resultados Parciais

Essa pesquisa encontra-se em execução, mas resultados parciais são compartilhados neste artigo. Para tornar a detecção mais acurada, o primeiro estágio é o processo de filtragem de pontos que se apresentam muito distantes ou descontínuos em relação ao conjunto principal de dados. A importância desta etapa não pode ser subestimada, pois, ao otimizar a qualidade dos dados de entrada, espera-se uma execução muito mais rápida e eficiente dos algoritmos de segmentação subsequentes. Uma vez que os dados estejam devidamente pré-processados, a próxima etapa envolve a assimilação destes pontos. O propósito é detectar e identificar superfícies distintas, sejam elas partes planas do ambiente ou componentes específicos do objeto em estudo. Para atingir esse objetivo, é usado algoritmos especializados tanto na detecção de planos quanto de diferentes partes dos objetos. A capacidade de separar de forma clara e precisa o plano de fundo do objeto é fundamental para o sucesso das fases posteriores. A Figura 1 ilustra os primeiros resultados do ambiente de simulação e visão do ambiente pela plataforma robótica.

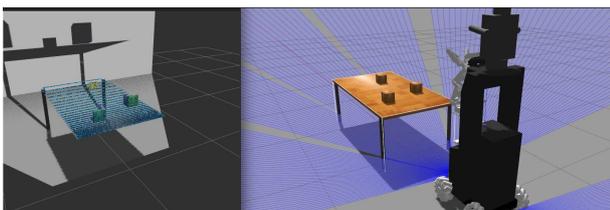


Figura 1 – Resultados em simulação

Após a segmentação bem-sucedida, o foco se volta para o cálculo do *motion plan*. Esse processo é essencial para a robótica, pois define a trajetória ideal que o robô deve seguir para interagir com o objeto. Este cálculo leva em consideração um conjunto de características físicas do robô, garantindo que qualquer interação proposta seja não apenas possível, mas realizada de forma segura e eficiente. A fim de garantir a eficácia do método proposto, é imperativo que análises experimentais detalhadas e simulações computacionais sejam conduzidas. Estas análises são diversificadas, abordando diferentes tipos de objetos, variadas condições de iluminação e ambientes para avaliar a robustez e adaptabilidade do algoritmo. Os resultados antecipados

são promissores: uma técnica de segmentação altamente eficaz e robusta, capaz de operar em uma variedade de cenários. Ao concluir este projeto, a aspiração é não apenas contribuir significativamente para o campo do processamento de nuvem de pontos, mas também facilitar a manipulação avançada de objetos em variados contextos, desde produção industrial até aplicações em saúde, elevando o padrão de eficiência dos sistemas robóticos autônomos.

5. Conclusões

O método, como ilustrado na Figura 1, revelou-se promissor em ambientes simulados. Em tais ambientes, é possível diferenciar de maneira eficaz objetos individuais e o plano de fundo, proporcionando uma visualização nítida e precisa de cada elemento. No entanto, ao aplicar esta técnica em cenários do mundo real, alguns resultados chamam atenção para melhorias. Embora em simulações tenha operado sob condições ideais, o mundo real apresentou variáveis que influenciaram os resultados. Estas variáveis, que incluem interferências lumínicas, ruídos do sensor e variações na superfície dos objetos, resultaram em uma taxa elevada de falsos positivos. Estes resultados iniciais, embora reveladores, destacaram a necessidade de refinamento na abordagem. A melhor abordagem para a situação atual foi desenvolver uma técnica mais resiliente, que se mantivesse eficaz não apenas em condições controladas, mas também frente às complexidades inerentes ao mundo real. Para combater os desafios identificados está sendo estudado a possibilidade de combinar a segmentação por bordas com outros métodos de segmentação e a incorporação de técnicas avançadas de aprendizado de máquina. O modelo está sendo conduzido a uma série de testes em diferentes ambientes e sob variadas condições, buscando uma solução holística que aborde as imperfeições detectadas. O projeto apresentou avanços significativos no domínio da segmentação por bordas, e conforme exposto neste artigo, motivou novos desafios de pesquisa para evolução do projeto.

6. Referências

- Gonzalez, R. C. (2008). *Digital Image Processing*. Pearson Education.
- Lai, X. e. (2022). Stratified Transformer for 3D Point Cloud Segmentation. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 8490-8499).
- Ma, X. e. (2022). *Rethinking Network Design and Local Geometry in Point Cloud: A Simple Residual MLP Framework 2022*.
- Qin, Y. e. (2022). DexPoint: Generalizable Point Cloud Reinforcement Learning for Sim-to-Real Dexterous Manipulation. *CONFERENCE on Robot Learning*.
- François Pomerleau, Francis Colas and Roland Siegwart (2015), "A Review of Point Cloud Registration Algorithms for Mobile Robotics", *Foundations and Trends® in Robotics*: Vol. 4: No. 1, pp 1-104.

¹ Aluno de IC do Centro Universitário FEI. Projeto com vigência de 06/2023 a 05/2024.