

ANÁLISE DE ALGORITMOS DE FUSÃO DE SENSORES PARA LOCALIZAÇÃO DE VEÍCULO TERRESTRE APÓS PERCORRER GRANDE DISTÂNCIA SEM CURVAS

Lucas Marins Batista¹; Valéria Loureiro da Silva²

¹Bolsista e Mestrando Modelagem Computacional e Tecnologias Industriais; PDI-3 EMBRAPII; lucasmrbatista@gmail.com

²Doutora em Física; Centro Universitário SENAI CIMATEC; Salvador-BA; valeria.dasilva@fieb.org.br

RESUMO

Localização a partir da fusão de sensores em sistemas robóticas é frequentemente utilizada, permitindo obter erros menores, a partir da junção de dados obtidos por sensores inerciais, modelos e informações do ambiente. Alguns desses são a partir dos algoritmos de filtro de Kalman Estendido, Kalman Unscented e o filtro de partículas (AMCL), cada um com sua forma de identificar posição. Como parte desse trabalho, foi realizada simulação 3D em Gazebo e ROS do veículo Husky com a fusão de sensores inerciais e Lidar, com o objetivo de comparar o erro obtido de cada um dos algoritmos, citados anteriormente, em um ambiente não estruturado por uma grande distância sem a presença curvas.

PALAVRAS-CHAVE: Filtro de partículas, Kalman Filter, ROS, Gazebo, Husky.

1. INTRODUÇÃO

A localização de veículo autônomo relativo a um mapa fixo é um método utilizado que permite identificar posição de uma forma mais precisa em ambientes internos com a ajuda de sensores que percebem o ambiente ao seu redor. O equipamento mais utilizado para essa atividade de reconhecimento 2D ou 3D do ambiente é o Lidar, inserido no topo do veículo, que usa escaneamento de feixes de laser (LaserScan) para identificar a distância do robô até alguns objetos. Através do uso desse sensor, um mapa pré-existente e de alguns algoritmos, como o filtro de partícula, é possível criar uma estimativa absoluta de localização local no ambiente inserido, obtendo resultados possivelmente mais acurados e precisos do que em outros métodos que não usam estruturas ao redor do veículo. No entanto, em ambientes externos com pouca informação, sensores com pouca definição ou um mapa pouco definido podem causar um aumento de incertezas. Por isso, é interesse não descartar os dados de posição adquiridos por sensores inerciais e a fusão deles¹.

Assim sendo, um outro exemplo é possibilidade de estimar a posição e orientação do robô através da odometria das rodas, com medidores que identificam o seu giro e velocidade, e sensores IMU (*Inertial Measurement Unit*) ou Unidade de Medição Inercial, com acelerômetros (aceleração) e giroscópios (orientação). Cada sensor utilizado tem suas especificidades e incertezas associadas, definidos através de suas características físicas, do ambiente e como é utilizado em determinadas situações. Algoritmos de fusão de sensores, como o filtro de *Kalman* Estendido e o filtro de *Kalman Unscented*, são utilizados para reduzir o ruído das informações obtidas e estimar um valor ótimo de localização, a partir de dados obtidos de duas ou mais fontes^{1 2 3 4}.

Esse trabalho tem o objetivo de avaliar através de um modelo e simulação do ROS (*framework*) e *Gazebo* (*software*), a eficiência de algoritmo de filtro de partículas com Lidar e compara-los com filtro de *Kalman* estendido e *Kalman unscented*, a partir de um ambiente longo, sem curvas e com poucos obstáculos.

2. METODOLOGIA

Para esse trabalho, foram utilizados dois softwares principais, o framework ROS na distribuição Kinetic e Gazebo na versão 7.16.0, para criar o robô e ambiente simulados, com Ubuntu 16.04 Xenial como sistema operacional principal de programação. Como apresentado anteriormente, o ROS é um framework de robótica que contém centenas de bibliotecas que permitem processar informações, simular e controlar sistemas. Ele também permite fazer a conexão com o simulador Gazebo, onde é possível montar robôs totalmente do zero com eixos e motores. Duas linguagens de programação são utilizadas, C++11 e Python 2 para criação de códigos executáveis e bibliotecas. Para visualização gráfica dos dados, é utilizado a ferramenta RQT e o plugin Multiplot^{5 6}.

Inicialmente, foram explorados os recursos do ROS e Gazebo para simulação de um sistema de localização usando robôs disponíveis no ROS. Para isso foi desenvolvido um ambiente de simulação no Gazebo para veículo genérico, o Husky, e um experimento para entendimento dos algoritmos de fusão de sensores inerciais de localização e Lidar acoplado ao veículo, fazendo uso do pacote "*robot_localization*"⁷, uma coleção de bibliotecas que contém algoritmos de filtro de Kalman Estendido, Unscented e filtro de partículas (AMCL)².

O experimento é realizado no ambiente descrito da Figura 1 e Tabela 1, com o objetivo de simular uma grande área não estruturada com obstáculos, em branco, muito similares e menos variáveis. No qual é realizado movimento em linha reta por 400 m, que permite a comparação entre valores de localização sem erro, ou ground truth, e os valores estimados para três algoritmos de fusões de sensores com as configurações padrões disponibilizados pelo algoritmo. Esses são o filtro de Kalman estendido, filtro de Kalman unscented e filtro de partículas (AMCL), utilizando o pacote “robot_localization”. Dessa forma, é possível verificar a eficiência dos algoritmos e um percurso de grande distância sem a realização de curvas, mas com escorregamento.

Tabela 1 – Características do mapa avaliado

Mapa	400 m x 20 m	15 caixas localizadas ao decorrer do percurso. 2 tipos de caixas localizadas em pontos com espaçamento não definido,	Percurso retilíneo
------	--------------	---	--------------------



Figura 1 – Mapa onde o veículo percorre o caminho, da esquerda à direita no Gazebo

3. RESULTADOS E DISCUSSÃO

O caminho percorrido para esse mapa é mostrado na Figura 2, com o erro máximo desse percurso apresentado na Tabela 2. A curva verde mostra a localização prevista apenas pela odometria, e como observado, há um crescimento do erro inicial no início que continua a acumular linearmente com a distância percorrida do valor verdadeiro em preto. O uso de EKF (filtro de Kalman estendido) e UKF (filtro de Kalman unscented) permite detectar adequadamente a localização em ambos os casos e a posição prevista, seguindo o *ground truth*, valor verdadeiro sem erro, em preto, como mostrado na Figura 2, resultando em um erro mais baixo para esses filtros. No entanto, a estimativa da AMCL não é satisfatória no mapa pouco estruturado mostrado na Figura 2, quando não há caixas dentro da faixa de varredura do Lidar.

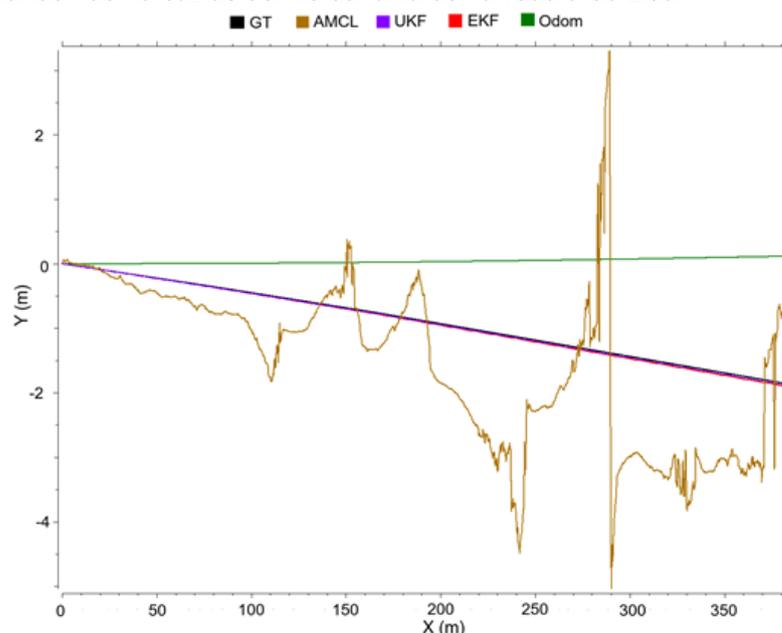


Figura 2 – Cálculo da distância percorrida pelo veículo no eixo X e Y. Preto = Valor verdadeiro (GT); Verde = Odometria das rodas; Vermelho = EKF; Roxo = UKF; Amarelo = AMCL.

Tabela 2 – Erro máximo do experimento para Odometria das rodas, filtro de kalman estendido, Unscented e AMCL (filtro de partículas)

Erro no eixo x estimado	Odometria das rodas	Filtro de Kalman Estendido	Filtro de Kalman Unscented	AMCL (filtro de partículas)
Mapa	0.01 m	0.01 m	0.01 m	1.1 m

Essa discrepância pode ocorrer, pois o ambiente não é estruturado o suficiente, repetitivo ou não tem elementos suficientes dentro do alcance do sensor de percepção, que nesse caso é o Lidar. Como consequência, para os casos apresentados neste trabalho com recursos esparsos e semelhantes, a localização AMCL não é recomendada e a estimativa de posição pelos dois filtros de Kalman obtém resultados mais precisos.

4. CONSIDERAÇÕES FINAIS

Nesse trabalho foi analisado, através de um modelo e simulação do ROS (*framework*) e Gazebo (*software*), a eficiência de algoritmo de filtro de partículas com Lidar, quando ele percorre uma distância longa em um ambiente pouco estruturado, e finalmente compara-lo com filtro de Kalman estendido e Kalman Unscented. Os resultados indicaram que num ambiente caracterizado com poucos objetos, o filtro de partículas não é recomendado. Logo, é mais interessante utilizar sensores inerciais e fundir os dados obtidos com algoritmos de Kalman, considerando que o erro dos sensores não cresce no mesmo nível que o filtro de partículas.

Agradecimentos

Agradecimentos à EMBRAPPII pelo financiamento da bolsa, à Shell e colegas do SENAI CIMATEC pelo tempo disponibilizado e grandes ensinamentos.

5. REFERÊNCIAS

- CHONG, Z. J. et al. Synthetic 2D LIDAR for Precise Vehicle Localization in 3D Urban Environment. p. 1554–1559, 2013.
- LEE, D. et al. Sensor Fusion Localization System for Outdoor Mobile Robot. 2009 ICCAS-SICE, p. 1384–1387, 2009.
- ZHANG, T. et al. Sensor fusion for localization, mapping and navigation in an indoor environment. 2014 International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management, HNICEM 2014 - 7th HNICEM 2014 Joint with 6th International Symposium on Computational Intelligence and Intelligent In, n. November, p. 1–6, 2014.
- LI, Q. et al. Kalman filter and its application. **Proceedings - 8th International Conference on Intelligent Networks and Intelligent Systems, ICINIS 2015**, n. 10, p. 74–77, 2016.
- KAESTNER, R. **ROS Wiki - RQT Multiplot**. Disponível em: <http://wiki.ros.org/rqt_multiplot>. Acesso em: 21 mar. 2021.
- CLEAR PATH, R. **HUSKY - UNMANNED GROUND VEHICLE**. Disponível em: <<https://www.clearpathrobotics.com/husky-unmanned-ground-vehicle-robot/>>. Acesso em: 20 mar. 2021.
- MOORE, T. **ROS Wiki - robot_localization**. Disponível em: <http://wiki.ros.org/robot_localization>. Acesso em: 16 mar. 2021.