

FUSÃO DE SENSORES INERCIAIS DE UM VEÍCULO ROBÓTICO TERRESTRE EM AMBIENTE SIMULADO

Lucas Marins Batista¹; Valéria Loureiro da Silva²

¹Mestrando em Modelagem Computacional e Tecnologia Industrial pelo SENAI CIMATEC - BA; PDI 3 EMBRAPPII; lucasmarbatista@gmail.com

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

RESUMO

A utilização de robôs autônomos cresce em diversas aplicações com o objetivo de automatizar atividades na indústria e permitir o acesso desses veículos a regiões inacessíveis. Dessa forma, a localização em um ambiente é determinada através de sensores, como acelerômetros, giroscópios, medidores de giro das rodas e *laser scan*. Através dos dados obtidos de fontes diversas, a aplicação de algoritmos de fusão de sensores é necessária, permitindo o reconhecimento da posição e orientação dos objetos. A partir dessa abordagem, esse artigo tem o objetivo de utilizar esses algoritmos e comparar o erro associado obtido, através da simulação de um veículo robótico terrestre.

PALAVRAS-CHAVE: Filtro de Kalman, Localização, ROS, Simulação

1. INTRODUÇÃO

O emprego de veículos móveis autônomos e teleoperados crescem em diversas áreas do conhecimento, como inspeção em áreas externas e internas não acessíveis e automatização de processos de logística, por exemplo. Junto a isso, a quantidade e qualidade dos sensores e algoritmos para localização a serem utilizados aumentou da mesma forma, permitindo o robô saber onde está de um modo mais preciso e acurado, a partir de informações do ambiente de forma absoluta e dos movimentos relativos.¹

Seguindo a abordagem clássica para localização de robôs terrestres, esse artigo tem objetivo de estudar e analisar de forma simulada o funcionamento de alguns desses sensores, a partir da fusão dos dados obtidos com o uso de pacotes do *framework* de robótica ROS (*Robot Operating System*) e o simulador de física *Gazebo*, que permitem desenvolver e empregar algoritmos e modelos 3Ds que representam a física dos sensores e o mundo real.^{2 3}

Dessa forma, é possível estimar a posição e orientação do robô através da odometria das rodas, com medidores que identificam o seu giro e velocidade, e sensores inerciais, IMU (*Inertial Measurement Unit*), com acelerômetros e giroscópios, que medem aceleração e a orientação de objetos. Posteriormente, após obter esses dados, é possível utilizar algoritmos de fusão de sensores para reduzir o ruído e melhorar o valor de localização estimado pela odometria.




Figura 1 - Robô móvel *Husky* em ambiente simulado do *Gazebo* com ROS.

Nesse artigo, três dos principais algoritmos clássicos serão comparados. O primeiro é o *Extended Kalman Filter*, que utiliza de informações obtidas por sensores inerciais, com incerteza associada, para estimar o valor de localização, a partir da linearização, previsão, comparação e atualização das variáveis das equações dos sistemas não lineares.⁴ Da mesma forma, o *Unscented Kalman Filter* contém as mesmas expressões da versão *Extended*, porém usa da distribuição probabilística para lidar com os sistemas que contém expressões não lineares.⁵ Em contrapartida, o sistema de localização probabilística (AMCL), baseado no algoritmo de filtro de

partículas, cruza as informações coletadas pelo sensor de percepção *laser scan* e odometria das rodas para medir a distância entre ele e os obstáculos, gerando partículas que são randomicamente alocadas e após algumas atualizações, estimam a possível posição e orientação do robô. ⁶ Todos esses processos são feitos de forma iterativa constante, de modo, que utilizam informações passadas e atuais para estimar seus resultados finais.

2. METODOLOGIA

O ROS disponibiliza uma coleção de pacotes de programas que permitem a simulação de um ambiente 3D, *Gazebo*, sensores e sistemas robóticos de forma otimizada, respeitando à uma física pré-determinada. Com essa abordagem de pesquisa, foram realizados testes simulados, utilizando os sensores inerciais como IMU, com acelerômetros e giroscópios de 3 eixos, e odometria das rodas do robô diferencial *Husky*, veículo robótico terrestre especializado em realizar missões em ambientes abertos e íngremes. ⁷

Os dados obtidos pelos sensores inerciais, giro das rodas e IMU, serão enviados para o ROS, e dois algoritmos clássicos de fusão de sensores serão aplicados, *Extended Kalman Filter (EKF)* e *Unscented Kalman Filter (UKF)* com o objetivo de estimar a posição e orientação com maior acurácia (exatidão), reduzindo o erro sistemático e crescente da odometria das rodas. Uma comparação entre a posição real e a estimada é disponibilizada de forma gráfica, permitindo demonstrar a eficiência de cada filtro em um ambiente e movimento do robô pré-determinado em linha reta, controlado via controle remoto. Do mesmo modo, através dos dados obtidos por um *laser scan* simulado, é possível utilizar o algoritmo de filtro de partículas, conhecido como algoritmo Adaptativo de Monte Carlo (AMCL) e um mapa pré-determinado para localização do *Husky*, através de um dos pacotes disponibilizados pelo ROS, Figura 1.

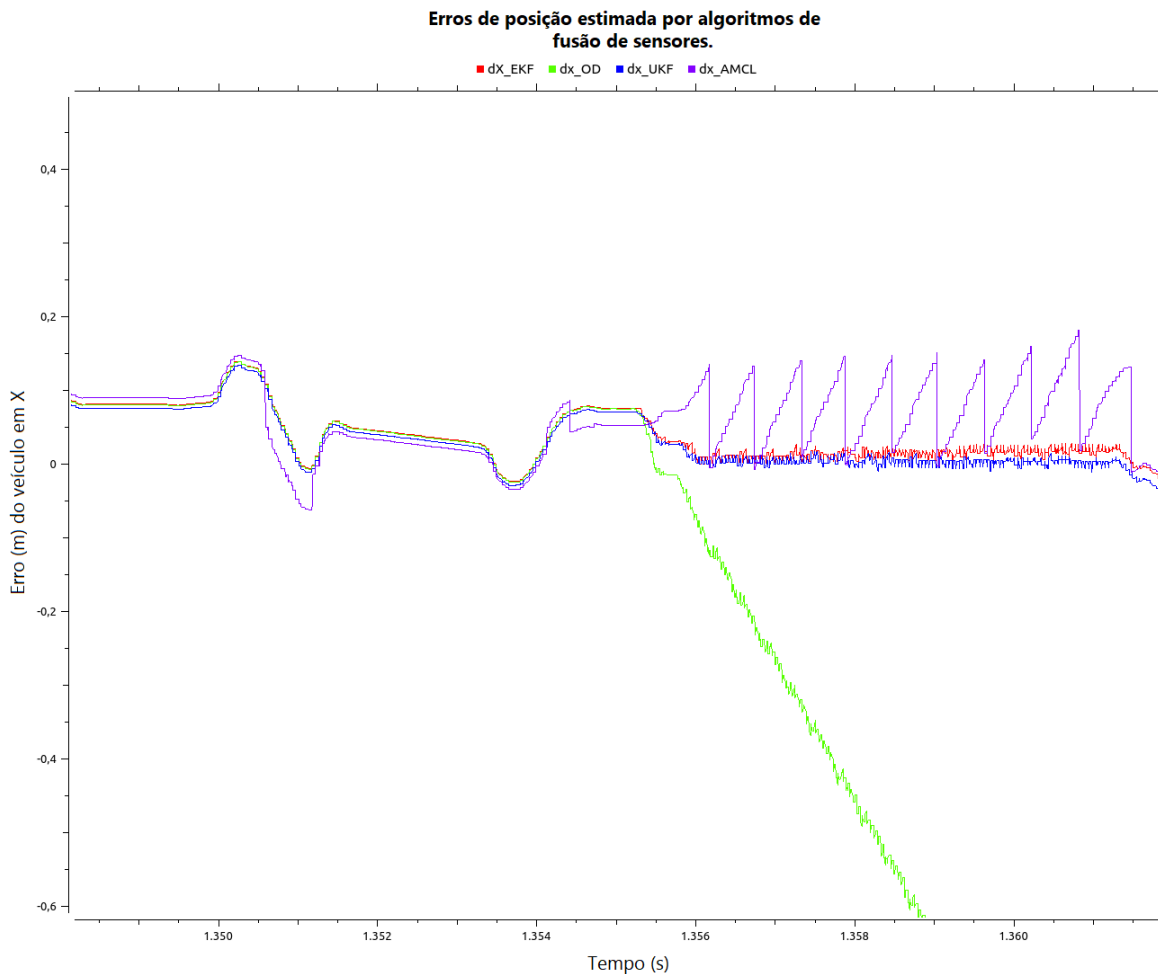


Figura 2 - Erro comparando a posição original do robô e os resultados obtidos por EKF (Vermelho), UKF (Azul), Odometria das Rodas (Verde) e AMCL (Roxo)

3. RESULTADOS E DISCUSSÃO

Após as devidas análises parciais dos dados obtidos, através de um visualizador, foi possível realizar uma comparação entre a localização exata do robô, disponibilizada pelo simulador, e as estimadas pelos algoritmos *Extended*, *Unscented Kalman Filter* e filtro de partículas. O robô realizará um movimento retilíneo por aproximadamente 10 m e após isso, um movimento curvo. Por causa dessa segunda forma de deslocamento, é possível analisar a capacidade de identificação de escorregamento das rodas pela IMU e a fusão dos sensores através dos filtros.

Na Figura 2, o gráfico de movimento do robô no eixo x , demonstra que até próximo do movimento de giro, o erro associado à odometria das rodas (linha verde) e a estimada pelos algoritmos são bem próximas com pequenas variações, porém, após o segundo movimento, ele cresce exponencialmente, devido a percepção errada da orientação. No entanto, os valores estimados pelos filtros (linha vermelha e azul) têm erro bastante reduzido, próximo de zero, pois os acelerômetros e giroscópios presentes na IMU identificam o movimento de rotação de forma mais acurada.

Sob outra perspectiva, o algoritmo de filtro de partículas (AMCL) consegue encontrar a localização do veículo a partir das informações do ambiente, comparando o mapa pré-carregado e os pontos com obstáculos gerados pelo *laser scan*, que consegue identificar o espaço quase totalmente ao redor do robô. Essa medição pode ser considerada absoluta e é muitas vezes utilizada para robótica terrestre, porém, como podemos observar na Figura 2 (traço roxo), é um algoritmo que disponibiliza resultados de forma lenta.

4. CONSIDERAÇÕES FINAIS

Mesmo com os bons resultados na localização de robôs móveis para um percurso de aproximadamente 20m, em maiores distâncias, as incertezas do EKF e do UKF devem crescer infinitamente, pelas próprias características dos sensores.⁸ Para uma atividade futura, seria interessante, uma fazer uma cascata de filtros de Kalman, fusionando os dados obtidos pelo AMCL, e analisar a influência dele para longas distâncias. Dessa forma, o algoritmo de filtro de partículas pode ser utilizado para corrigir a posição após uma determinada distância por ser uma medida absoluta, mesmo com a lenta atualização dos resultados

Agradecimentos

Agradecimentos à EMBRAPA pelo financiamento da bolsa, aos Eng. Rafael Barreto e Matheus Nascimento pelo tempo disponibilizado e grandes ensinamentos.

5. REFERÊNCIAS

- ¹ D. Lee, S. Son, K. Yang, J. Park, and H. Lee, "Sensor Fusion Localization System for Outdoor Mobile Robot," *2009 ICCAS-SICE*, pp. 1384–1387, 2009.
- ² Gazebo, "Gazebo - Robot simulation made easy," 2018. [Online]. Available: <http://gazebosim.org/>. [Accessed: 03-Apr-2019].
- ³ F. Open Source Robotics, "About ROS and Open Source Robotics," 2018. [Online]. Available: <http://www.ros.org/about-ros/>. [Accessed: 04-Apr-2019].
- ⁴ Q. Li, R. Li, K. Ji, and W. Dai, "Kalman filter and its application," *Proc. - 8th Int. Conf. Intell. Networks Intell. Syst. ICINIS 2015*, no. 10, pp. 74–77, 2016.
- ⁵ S.~J.~Julier and J.~K.~Uhlmann, "{U}nscented {F}iltering and {N}onlinear {E}stimation," *Proc. IEEE*, vol. 92, no. 3, pp. 401–422, 2004.
- ⁶ L. Zhang, R. Zapata, and P. Lépinay, "Self-adaptive Monte Carlo localization for mobile robots using range finders," *Robotica*, vol. 30, no. 2, pp. 229–244, 2012.
- ⁷ R. Clear Path, "HUSKY - UNMANNED GROUND VEHICLE," 2018. [Online]. Available: <https://www.clearpathrobotics.com/husky-unmanned-ground-vehicle-robot/>. [Accessed: 03-Apr-2019].
- ⁸ G. Klančar, A. Zdešar, S. Blažič, and I. Škrjanc, *Wheeled Mobile Robotics*. Oxford, 2017.