

**Estudo da Aplicação dos Filtros de Partículas e Filtro de Kalman Estendido em  
Dados de Sensores RADAR e LIDAR**

**Study of the Application of Particle Filters and Extended Kalman Filter in RADAR  
and LIDAR Sensor Data**

DOI:10.38152/bjtv4n4-002

Recebimento dos originais: 10/11/2021

Aceitação para publicação: 02/12/2021

**Moisés de Oliveira Neto**

MSc

LACTEC

Rua João Schleder Sobrinho, 1300 – Boa Vista – Curitiba/PR

moyctba@gmail.com

**Luiz Felipe Ribeiro Barrozo Toledo**

DSc

LACTEC

BR116 Km 98, Centro Politécnico da UFPR, Prédio LACTEC

luiz.toledo@lactec.org.br

**RESUMO**

Este artigo aborda o estudo das técnicas de filtragem e fusão de dados conhecidas como Filtro de Kalman Estendido (Extended Kalman Filter – EKF) e Filtro de Partículas (Particle Filter – PF), quando aplicadas aos dados de leitura de dois sensores, o RADAR e o LIDAR, presentes na maioria dos veículos e equipamentos móveis autônomos. O estudo é feito aplicando os filtros a uma amostra de dados obtida através do processo de leitura dos sensores. Com isso, se possibilitou o entendimento e também demonstrar situações onde foi possível observar o comportamento dos filtros e através destes resultados evidenciar seus pontos fortes e fraquezas diante do cenário apresentado, bem como os resultados da fusão dos dados destes dois sensores.

**Palavras-chave:** sensores, Kalman, Partículas.

**ABSTRACT**

This article addresses the study of data filtering and fusion techniques known as Extended Kalman Filter (EKF) and Particle Filter (PF), when applied to the reading data of two sensors, the RADAR and LIDAR present in most autonomous vehicles and equipment. The study was developed by applying the filters to a sample of data obtained through the process of sensors reading. With that, it was possible to understand and demonstrate situations where it was possible to observe the behavior of the filters and through these results to highlight their strengths and weaknesses in view of the presented scenario, as well as the results of the data fusion of these two sensors.

**Keywords:** sensors, Kalman, Particle.

## 1 INTRODUÇÃO

Com o surgimento e aperfeiçoamento de diferentes tipos de sensores que vão desde biosensores, sensores químicos, sensores remotos acoplados em satélites, aeronaves, veículos, dispositivos móveis como celulares, drones e até mesmo dispositivos de uso doméstico, o volume de dados gerado é absurdamente grande. Quanto maior o volume de dados e o número de sensores envolvidos no processo de aquisição destes dados, maior é a necessidade da filtragem, combinação ou fusão destes dados. A fusão é uma forma eficaz de otimizar a utilização de um grande volume de dados oriundos de diferentes sensores.

O problema de localização é de extrema importância no estudo da robótica móvel, e é de fundamental importância para a realização das tarefas que envolvam robôs móveis em ambientes reais [1]. Determinar a sua própria posição dentro de um ambiente, é uma capacidade básica e fundamental para que tarefas de navegação, como o planejamento de uma trajetória, sejam executadas [2].

O problema em torno da localização está no elevado grau de incerteza dos dados fornecidos pelos sensores, incertezas essas geradas muitas vezes por ruídos e influências externas. Esta imprecisão reforça a real necessidade da filtragem e tratamento dos dados dos sensores através de algoritmos especialmente desenvolvidos para este fim.

A navegação robótica autônoma tem ligação direta a diversos fatores como: características do ambiente, orientação de rota, distâncias de rotas e colisão com obstáculos. Os algoritmos e filtros são de extrema importância no tratamento dos dados obtidos através dos sensores, são eles que irão tornar a navegação de fato autônoma através de tomadas de decisão baseadas nas informações externas.

O estudo de métodos de filtragem e fusão de dados gera resultados que precisam ser observados, interpretados e apresentados de forma que representem logicamente o ganho, ou não, da aplicação dos algoritmos para determinada amostra de dados.

A fusão de sensores pode ser descrita como a fusão de fluxos de dados de vários sensores em uma saída unificada com todos os dados disponíveis incorporados [3]. A fusão de sensores é uma excelente maneira de fazer uso da força complementar de vários sensores em praticamente qualquer aplicação, pois possui muitas vantagens quando comparada ao processo de cada fonte de dados independentemente [4]. A fusão de sensores é a solução para a combinação das faixas de precisão de diferentes sensores, a fim de contornar a imprecisão um do outro [5].

Este trabalho busca desenvolver estudos sobre métodos de fusão e filtragem de dados resultantes de multi-sensoriamento. Avaliar os resultados dos métodos aplicados aos sensores, apresentando informações que demonstrem os comportamentos dos Filtros de

Kalman Estendido e do Filtro de Partículas quando aplicados aos dados captados pelos sensores LIDAR e RADAR.

## 2 DESENVOLVIMENTO E METODOLOGIA

O estudo de métodos e técnicas de fusão e filtragem de sensores, permite um melhor entendimento e compreensão em termos de aplicabilidade e relevância de cada técnica. A criação de um modelo através do *software* Matlab, permite principalmente avaliar a filtragem e refinamento dos dados de cada sensor individualmente em relação aos dados brutos.

Foram feitas simulações que consistem basicamente na inserção de dados pré-processados dos sensores, com o intuito de criar situações de leitura de um ambiente real.

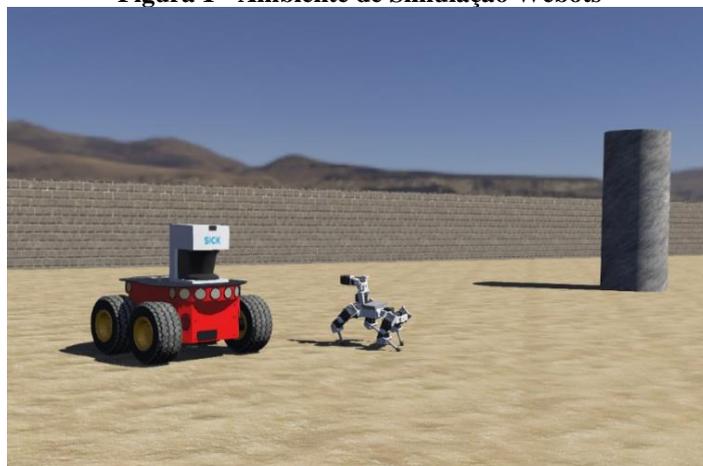
A coleta de dados de saída destas simulações alimenta os relatórios de resultados, onde são apresentados os resultados e conclusões proveniente dos testes e simulações, bem como o comparativo entre os dois métodos apresentados.

### 2.1 MATERIAIS

Sensores são dispositivos que por vários meios, coletam informações sobre o estado de um sistema ou ambiente. Existem inúmeras maneiras de detectar o estado, cada método tem seus benefícios e problemas inerentes.

Como recurso para verificação do funcionamento dos múltiplos sensores através da coleta e processamento dos seus dados, utilizou-se uma plataforma virtual de simulação robótica. Na etapa de desenvolvimento da plataforma e robô virtuais, foi utilizado o simulador Webots da Cyberbotics. A Figura 1 ilustra o robô autônomo equipado com sensores LIDAR e RADAR, desviando de obstáculos inseridos no ambiente de simulação.

**Figura 1 - Ambiente de Simulação Webots**



Para desenvolver um sistema de simulação da filtragem e fusão dos dados dos sensores e para apresentar os resultados obtidos, utilizou-se o MATLAB. Este *software* permite o *input* de dados simulando a leitura dos sensores, o processamento e a aplicação dos métodos de filtragem e fusão, obtendo assim dados de saída conclusivos em relação aos pontos fortes e fracos de cada método quando aplicados a cada um dos sensores.

Os sensores que foram utilizados como base para as pesquisas foram os modelos LIDAR RS-16 (Figura 2) e o sensor RADAR IWR1443 (Figura 3).

### 2.1.1 LIDAR

Os LIDARs (*Light Detection and Ranging*) determinam a distância de objetos utilizando para isso sensores infravermelhos. Um sistema rotativo permite enviar ondas e medir o tempo necessário para que essas ondas voltem a ele. Isso torna possível gerar uma nuvem de pontos do ambiente ao redor do sensor. Um LIDAR pode gerar cerca de 2 milhões de pontos por segundo. Com esta nuvem de pontos que oferece diferentes formas 3D, é possível determinar e classificar os objetos detectados [5]. O sensor LIDAR utilizado como base para as pesquisas foi o modelo LIDAR RS-16 (Figura 2).

Figura 2 - Sensor LIDAR RS-16 [5]



### 2.1.2 RADAR

O RADAR (*Radio Detection and Ranging*), é um sensor que opera transmitindo pulsos de ondas de rádio, medindo o sinal que é refletido quando este encontra uma barreira, neste caso um objeto. Este tipo de sensor tem melhores resultados sobre objetos móveis em comparação a objetos estáticos. Diferentemente de outros sensores, o RADAR calcula a diferença de posição entre duas medições.

A sua baixa resolução muitas vezes não permite identificar com precisão o tipo do objeto detectado, mas consegue com um alto grau de confiabilidade determinar a posição e a velocidade do objeto. O modelo de RADAR utilizado como base para o desenvolvimento deste trabalho é o da linha Industrial *mmWave Sensors*, da fabricante *Texas Instruments*. Este é um sensor avançado e já aplicado pela fabricante em estudos de caso relacionados a

navegação de robôs autônomos. Assim sendo, o modelo selecionado é o IRW1443 (Figura 3).

Figura 3 - Sensor RADAR IWR1443 [6]



## 2.2 FILTRO DE KALMAN ESTENDIDO

O filtro de Kalman é uma solução recursiva para o problema de filtros lineares discretos. Ele utiliza um conjunto de equações para estimar estados de um processo, mesmo quando este processo apresenta incertezas [7].

O seu método consiste basicamente em duas etapas, previsão ou estimação e atualização ou correção, baseado em técnicas recursivas do sistema representado no espaço de estados, sendo uma estimação sobre a dinâmica do sistema. Durante a primeira etapa é realizada uma previsão sobre a dinâmica do modelo e no segundo passo uma correção, atuando na covariância do erro [8]. Desta forma o Filtro de Kalman pode ser de forma básica, definido pelas equações (1) e (2).

$$X_k = F_{k-1}x_{k-1} + v_{k-1} \quad (1)$$

$$y_k = H_k x_k + w_k, \quad (2)$$

## 2.3 FILTRO DE PARTÍCULAS

Os métodos sequenciais de Monte Carlo – MCL (*Monte Carlo Localization*), em particular sua variação conhecida como Filtro de Partículas, reproduzem o trabalho do filtro de Kalman naqueles ambientes não lineares e ou não gaussianos [9].

Esta técnica baseia-se na distribuição randômica de possíveis estados em um espaço, como áreas navegáveis de um mapa, por exemplo. Cada estado é representado por uma partícula, e é utilizado um número significativamente grande de partículas, fator que, tem influência direta na precisão e velocidade de convergência, assim como no peso computacional do algoritmo [10].

Este método de localização se baseia na distribuição de probabilidade da localização do robô no momento  $t$  que pode ser representado pela equação (3).

$$bel(x_t) = p(x_t | z_{1:t}, u_{1:t}) \quad (3)$$

### 3 RESULTADOS E DISCUSSÕES

Os resultados apresentados nas figuras (Figura 4) e (Figura 5), originalmente extraídas do MATLAB, demonstram que houve uma melhora na acurácia quando aplicado o Filtro de Kalman Estendido (EKF) aos dados lidos pelos sensores LIDAR e RADAR, em relação ao aferido ou dado real.

Figura 4 - Leitura com LIDAR e Filtragem por EKF.

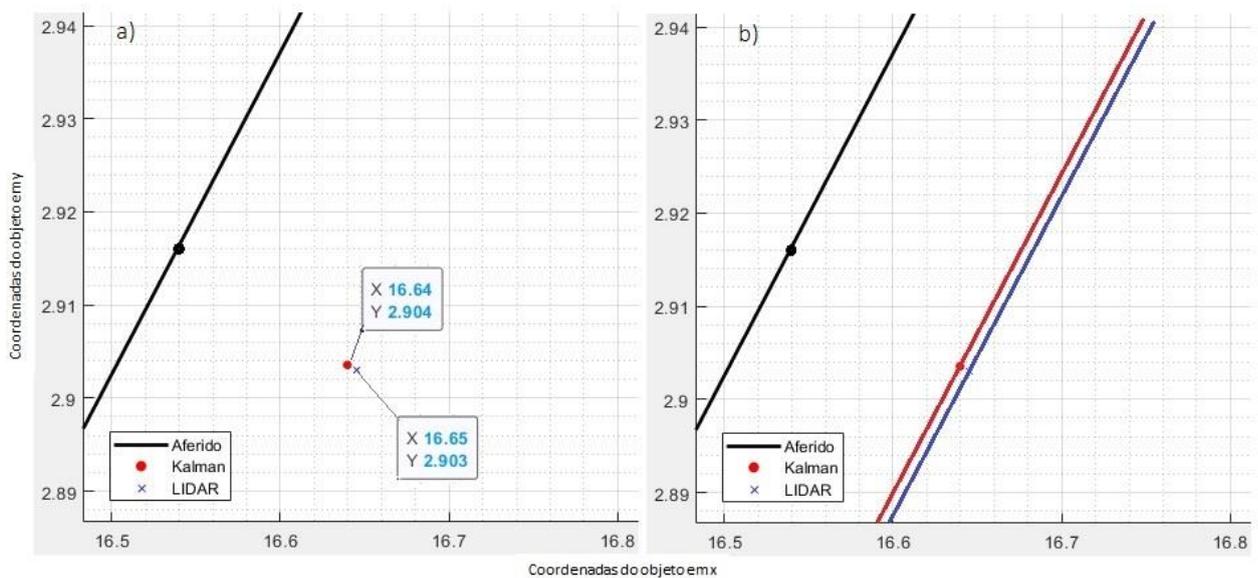
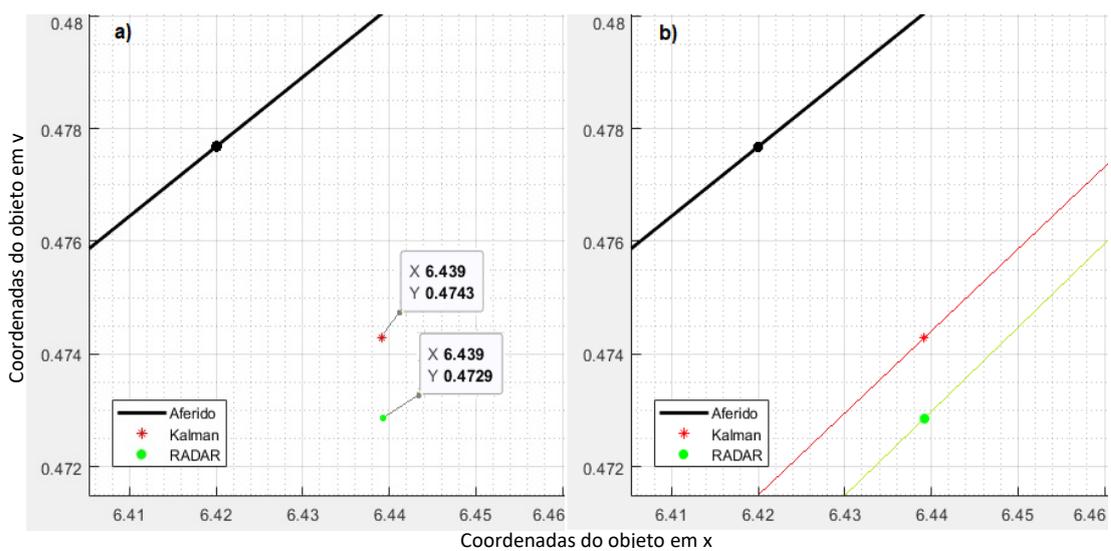


Figura 5 - Leitura com RADAR e Filtragem por EKF



As mesmas simulações foram refeitas, mas desta vez aplicando o algoritmo do Filtro de Partículas. Os resultados obtidos e apresentados nas figuras (Figura 6) e (Figura 7), demonstram que assim como no caso do Filtro de Kalman Estendido, o Filtro de Partículas

foi capaz de melhorar a acurácia da leitura dos sensores em comparação com os dados reais.

Figura 6 - Leitura com RADAR e Filtragem por PF.

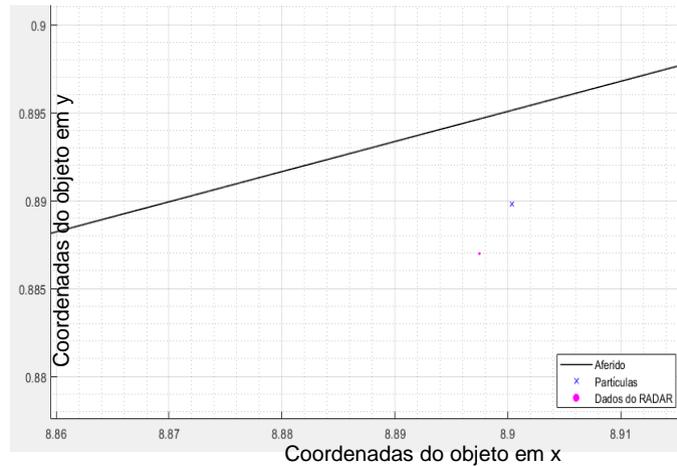
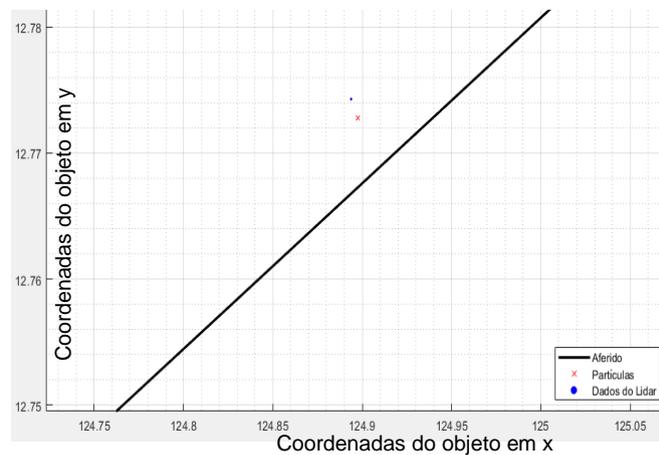


Figura 7 - Leitura com LIDAR e Filtragem por PF.



Traduzindo em números (Tabela 1), é possível observar principalmente através do EMQ (Erro Médio Quadrático), que os valores dos erros são menores quando aplicados os métodos de filtragem em comparação aos dados brutos.

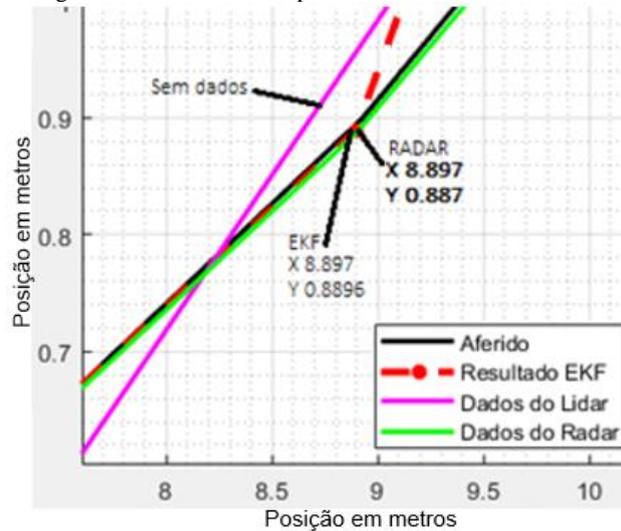
Tabela 1. Medição dos Erros

	LIDAR			RADAR		
	KALMAN	PARTICLE	NO FILTER	KALMAN	PARTICLE	NO FILTER
EMQ	0.08685	0.08765	0.08767	0.09737	0.09730	0.09738
Erro Máx.	0.69025	0.69473	0.69524	0.83695	0.83663	0.83695
Erro Mín.	0.03513	0.03360	0.03629	0.02921	0.03091	0.02954
Erro Médio	0.26259	0.26408	0.26354	0.27006	0.26999	0.27009
Coef. Var.	0.50950	0.50681	0.50998	0.57880	0.57860	0.57875
Des. Padrão	0.13379	0.13384	0.13440	0.15631	0.15622	0.15631

No que diz respeito a utilização dos métodos de filtragem aplicados na fusão dos dados, optou-se por avaliar apenas o Filtro de Kalman Estendido, pois este modelo dispensa a construção de um mapa virtual do ambiente para que possa ser utilizado.

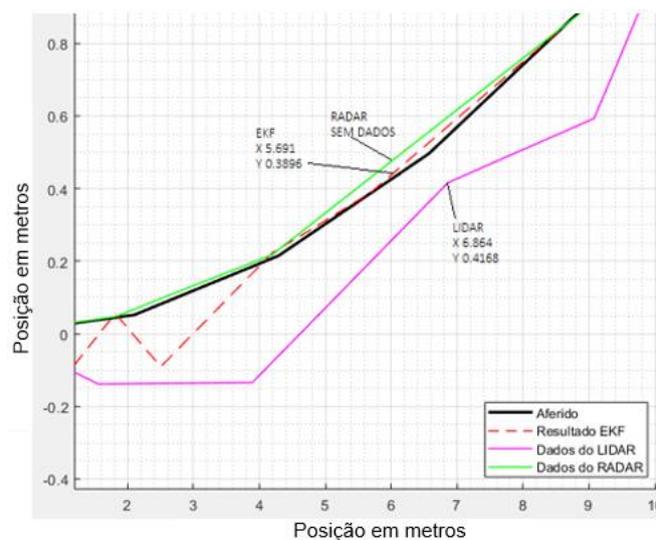
Para observar melhor a atuação do algoritmo de fusão de dados, os dados dos sensores foram propositalmente omitidos em um determinado ponto. A Figura 8 apresenta os resultados desta fusão e como o Filtro de Kalman foi capaz de manter a trajetória em relação ao aferido mesmo não contando com os valores de medição do sensor LIDAR.

Figura 8 - Fusão de Dados por EKF – Omissão do LIDAR.



O mesmo teste foi feito com o sensor RADAR, ou seja, os dados deste sensor foram omitidos para um determinado ponto para que fosse possível observar o comportamento do Filtro de Kalman Estendido como fusor de dados. A Figura 9, apresenta o resultado visual deste comportamento para o ponto em questão.

Figura 9 - Fusão de Dados por EKF – Omissão do RADAR.



A utilização do Filtro de Partículas exigiu um maior poder computacional para rodar o modelo em comparação com o Filtro de Kalman.

Um outro fator importante observado, é que apesar do Filtro de Partículas funcionar bem enquanto método de estimativa de estado, trata-se de um método de auto localização

onde para que seja possível a fusão dos dados, faz-se necessário um conhecimento prévio do ambiente onde o dispositivo irá operar. Ou seja, é necessário criar uma representação deste ambiente em forma de um mapa virtual. A necessidade de um mapa virtual cria uma dependência do modelo ao ambiente, tornando-o menos flexível à sua aplicação.

#### 4 CONCLUSÕES

O objetivo deste trabalho foi desenvolver estudos dos resultados provenientes da aplicação dos métodos de filtragem de dados conhecidos como Filtro de Kalman Estendido e Filtro de Partículas, resultantes de multi-sensoriamento, assim como avaliar os resultados obtidos através da filtragem dos dados para cada um dos sensores e a fusão dos mesmos.

Os resultados obtidos através das simulações evidenciam o ganho na acurácia quando há aplicação de ambos os modelos.

Apesar das diferenças observadas através das figuras obtidas em simulações via Matlab e evidenciadas com a aplicação do Erro Médio Quadrático na Tabela 1 parecerem muito pequenas, é importante lembrar que para este tipo de aplicação, podem auxiliar na tomada de decisão evitando assim que o veículo móvel venha colidir com algum obstáculo. Vale também ressaltar que a amostra de dados é bastante reduzida, apenas 100 pontos. Isso aponta na direção de que a correção dos erros para uma amostra de dados ampliada à milhares de pontos, pode trazer ganhos extremamente significativos.

A mesma amostra de dados foi utilizada nos testes e simulações envolvendo os dois métodos de filtragem, no entanto, para este conjunto de dados, notou-se maior ganho utilizado o Filtro de Kalman, tanto em desempenho quanto em acurácia.

Assim sendo baseado nos resultados obtidos no experimento realizado, pode-se inferir que os testes foram conclusivos e apontam diretamente para a utilização de modelos de filtragem de dados e mais fortemente para o modelo do Filtro de Kalman.

## REFERÊNCIAS

- [1] LEITE, D.; FIGUEIREDO, K.; VELLASCO, M. (2015). Localização por Kalman Estendido Aplicado a Mapas Baseados em Marcos com e sem Correspondência Conhecida. XII Simpósio Brasileiro de Automação Inteligente (SBAI), 1–6. <http://swge.inf.br/SBAI2015/anais/570.pdf>
- [2] FOX, D. B. W. a. T. S., 1999. Markov localization for reliable robot. s.l.:s.n.
- [3] GROSSMAN, P. (1998). *Multisensor data fusion*. *GEC Journal of Technology*, vol. 15, no. 1 pp. 27-37. [https://www.researchgate.net/publication/293573229\\_Multisensor\\_data\\_fusion](https://www.researchgate.net/publication/293573229_Multisensor_data_fusion)
- [4] ELMENREICH, W. (2002). *An introduction to sensor fusion*. *Institut für Technische Informatik, Tech. Rep.* [https://www.researchgate.net/profile/Wilfried\\_Elmenreich/publication/267771481\\_An\\_Introduction\\_to\\_Sensor\\_Fusion/links/55d2e45908ae0a3417222dd9/An-Introduction-to-Sensor-Fusion.pdf](https://www.researchgate.net/profile/Wilfried_Elmenreich/publication/267771481_An_Introduction_to_Sensor_Fusion/links/55d2e45908ae0a3417222dd9/An-Introduction-to-Sensor-Fusion.pdf)
- [5] ROBOSENSE, (2020). RS-LiDAR-16 User Manual. Shenzhen Suteng Innovation Technology Co. Ltd.
- [6] IWR1443BOOST, (2020). *Evaluation Module mmWave Sensing Solution. Texas Instruments User's Guide*.
- [7] WELCH, G.; BISHOP, G. (2006) *An Introduction to the Kalman Filter*. Chap Hill, NC.
- [8] DELLAERT, F.; FOX, D.; BURGARD, W.; and THRUN, S. 1999b. *Monte Carlo localization for mobile robots*. Proc. of ICRA-99.
- [9] SEBASTIAN T. (2002). *Particle Filters in Robotics*. *Computer Science Department Carnegie Mellon Universtiy*.