

## Fusão de Dados para a Estimativa de Localização de Robôs Móveis no Sistema MobiLysa

Matheus D. Oliveira \* Vinícius H. Izabel \* Leonardo A. Silva \*\*  
Alexandre P. Do Carmo \*\* Flávio Machado \*\*\* Raquel F. Vassallo \*

\* Departamento de Engenharia Elétrica,  
Universidade Federal do Espírito Santo - ES  
(e-mail: matheus.oliveira.73@edu.ufes.br,

vinicius.izabel@edu.ufes.br, raquel.vassallo@ufes.br).

\*\* Coord. de Eletrotécnica, Instituto Federal do Espírito Santo, ES  
(e-mail: alexandre.carmo@ifes.edu.br, leonardo.assis@ifes.edu.br )

\*\*\* IS Vision, Vitória, ES, (e-mail: flavio@isvision.com.br)

---

**Abstract:** The MobiLysa System aims to integrate the Lysa robot into an intelligent environment to assist visually impaired or low vision people to move in indoor spaces. This paper presents the robot's localization module, which uses sensor fusion of two sources of position and orientation data: multicamera three-dimensional reconstruction by computer vision and map-based estimation using the Monte Carlo algorithm. The data fusion is performed by the Extended Kalman Filter, increasing the accuracy and precision of the estimates. The paper describes in detail the data fusion and presents experiments to validate the proposed approach.

**Resumo:** O Sistema MobiLysa tem como proposta integrar o cão-guia robô Lysa em um ambiente inteligente para ajudar na locomoção de pessoas com deficiência visual ou subvisão em espaços internos. Este artigo apresenta o módulo de localização do robô, que utiliza a fusão sensorial de duas fontes de dados de posição e orientação: reconstrução tridimensional multicâmera por visão computacional e estimativa baseada em mapas usando o algoritmo de Monte Carlo. A fusão de dados é realizada pelo Filtro de Kalman Estendido, aumentando a precisão e acurácia das estimativas. O artigo descreve a fusão de dados e apresenta experimentos de erro de localização para validar a abordagem proposta.

*Keywords:* Data fusion; EKF; Computer vision; Localization; Intelligent Spaces.

*Palavras-chaves:* Fusão de dados; EKF; Visão Computacional; Localização; Espaços Inteligentes.

---

### 1. INTRODUÇÃO

Inclusão e diversidade são temas extremamente relevantes dentro da sociedade, principalmente no que se refere às pessoas com deficiência. De acordo com o Censo 2010, 24% da população brasileira vive com algum tipo de deficiência ou grau de dificuldade (IBGE, 2010), o que representa um grande número de pessoas para as quais políticas de inclusão e acessibilidade precisam ser consideradas. Ainda segundo o IBGE, que analisou dados da Pesquisa Nacional de Saúde, sete em cada dez pessoas com deficiência estão fora do mercado de trabalho (IBGE, 2022).

A adoção de boas práticas ambientais, sociais e de governança (ESG - *Environmental, Social and Governance*) têm se tornado uma pauta importante dentro do mercado corporativo. Iniciativas de diversidade e inclusão estão contempladas nesse escopo. Nesse sentido, as empresas têm um papel fundamental na promoção da igualdade e equidade para a construção de um ambiente mais inclusivo e acessível.

\* Apoio financeiro através do Projeto "MOBILYSA - Sistema de localização e navegação do cão-guia robô Lysa para ambientes internos baseado em visão computacional", via FAPES, TO 092/2021.

Com o objetivo de tornar os ambientes corporativos, industriais ou públicos mais acessíveis e inclusivos para pessoas com deficiência visual ou subvisão, foi pensado o Sistema MobiLysa. Este projeto consiste em incluir um cão-guia robô chamado Lysa em espaços inteligentes para promover a locomoção dessas pessoas de forma segura e confiável.

O robô Lysa foi desenvolvido pela *startup* capixaba VixSystem. Já a idealização do Sistema MobiLysa ocorreu em 2019, na Universidade Federal do Espírito Santo (UFES), como um projeto de pesquisa onde foram realizadas as primeiras implementações dos microsserviços para uma arquitetura de espaço inteligente, assim como a realização dos primeiros experimentos de navegação (Cotta et al., 2019). Nos anos seguintes, novas funcionalidades foram incorporadas ao sistema e este foi implantado em outro espaço inteligente para validar a sua replicabilidade e flexibilidade (Izabel et al., 2022). Atualmente, o sistema segue sendo aperfeiçoado, integrando tecnologias próprias e também providas do *Robot Operating System* (ROS).

O Sistema MobiLysa é composto por microsserviços, em que cada um tem uma funcionalidade para a realização de

alguma tarefa no espaço inteligente como, por exemplo, captura de *frames* das câmeras instaladas no espaço, detecção e rastreamento de pessoas ou objetos, mapeamento, planejamento de caminhos e navegação do robô Lysa, além de outros serviços. Seu principal objetivo, de forma simplificada, consiste em permitir que um usuário possa informar o local que deseja ir, por meio de um comando de voz, e ser guiado pelo robô Lysa no ambiente até o seu destino final, desviando de obstáculos estáticos e dinâmicos de forma a mantê-lo em segurança. Logo, para que o robô consiga guiar uma pessoa até o local desejado, sua posição deve sempre ser conhecida em tempo real e quanto melhor for sua estimativa, mais confiável será o sistema durante a navegação.

A localização é uma área amplamente estudada no contexto da robótica e apresenta desafios específicos em cada aplicação (Thrun et al., 2005). Neste artigo, será apresentado um recorte do Sistema MobiLysa, com foco em seu método de localização. O método utiliza a fusão de dados de múltiplas fontes, por meio de técnicas estatísticas, para obter estimativas de localização do robô. As fontes para essa estimativa de localização incluem métodos baseados em sensores proprioceptivos (odometria), mapas construídos a partir de nuvens de pontos obtidas com laser e reconstrução de informação tridimensional a partir de visão computacional. A fusão de dados aumenta a precisão e acurácia das estimativas, além de garantir uma maior redundância de informação e confiabilidade por meio da filtragem de *outliers*.

Ao longo deste artigo, serão detalhadas cada uma dessas fontes e a fusão de dados utilizada. Primeiramente, alguns trabalhos relacionados serão discutidos na Seção 2. A seguir, a abordagem proposta é descrita na Seção 3. Também serão apresentados os experimentos para validar o método adotado e a localização do robô em um espaço inteligente, assim como a navegação do robô, obtida por meio da implantação do sistema no campus Guarapari do Instituto Federal do Espírito Santo (IFES). Tais experimentos e resultados podem ser vistos na Seção 4. Finalmente, as conclusões e trabalhos futuros são discutidos na Seção 5.

## 2. TRABALHOS RELACIONADOS

Uma técnica de localização baseada em visão, que usa matrizes de homografia contínuas e discretas, IMU e odometria, foi proposta em (Shen et al., 2011). As imagens, capturadas por uma câmera instalada no topo do robô, são usadas para estimar a sua postura (homografia discreta) e sua velocidade (homografia contínua). Além disso, a IMU mede a velocidade angular e os *encoders* das rodas medem a velocidade linear. Essas informações são fundidas através de um *Extended Kalman Filter* (EKF). Nesse trabalho, utilizam-se apenas os sensores embarcados no robô, diferente da proposta deste trabalho, que utiliza câmeras fixas no ambiente e um mapa prévio do local para fornecer uma localização fundida em um referencial global.

Já em (Yan et al., 2022), o EKF é usado para a fusão de dados de odometria visual, IMU e odometria das rodas de um robô. O objetivo é alimentar o sistema de mapeamento com os dados fundidos, para que tanto o mapa quanto a localização global do robô sejam mais precisos. No entanto, ao contrário do presente trabalho, que se concentra em

ambientes internos, o sistema proposto tem o foco em ambientes externos agrícolas.

A abordagem em (Peavy et al., 2023) apresenta um sistema de localização, baseado no método de Monte Carlo. As imagens de uma câmera embarcada no robô são usadas para reconhecimento de objetos e atualização do mapa, os quais foram integrados ao método de Monte Carlo para minimizar erros causados por elementos não estruturais do ambiente e melhorar a localização. De forma semelhante, neste artigo, Monte Carlo é aplicado para fornecer uma estimativa de localização a partir de um mapa que, então, é fundida com outra estimativa de localização baseada em informação visual, só que desta vez proveniente de câmeras presentes no ambiente e não a bordo do robô.

O trabalho de do Carmo et al. (2020) destaca o uso de um espaço inteligente programável baseado em visão computacional para controlar robôs móveis. Uma das vantagens é a obtenção de uma localização com erro reduzido em comparação com outras técnicas. No entanto, a utilização exclusiva de câmeras fixas para localização de um robô torna inviável a implantação deste sistema em ambientes que não possuem cobertura total de câmeras. Por isso, neste artigo, é proposto um sistema de localização que utiliza outro método de localização global, além da visão computacional, por meio de uma fusão sensorial. Isso permite que o robô navegue por todo o ambiente, mesmo que não haja cobertura visual completa em algumas regiões.

## 3. PROPOSTA

Nesta seção, serão apresentados alguns conceitos para uma melhor compreensão do trabalho. A Figura 1 mostra a proposta do sistema em que estão indicadas cada uma das fontes de localização e o método de fusão utilizado.




Figura 1. Visão geral do sistema.

### 3.1 Espaços Inteligentes Programáveis

O MobiLysa foi idealizado para funcionar em um espaço inteligente programável (PIS - *Programmable Intelligent Space*) semelhante ao descrito em (do Carmo, 2021). O PIS é uma evolução dos espaços inteligentes tradicionais (Lee and Hashimoto, 2002; Hashimoto, 2003; Vaščák et al., 2020), com recursos adicionais como orquestração multinível e programabilidade granular da infraestrutura. Além disso, é baseado em visão computacional a fim de se explorar as vantagens e riquezas provenientes de informações visuais.

O PIS adota uma arquitetura baseada em microsserviços, que são estruturas pequenas, independentes e de escopo limitado, fornecendo interoperabilidade por meio de comunicação baseada em mensagens (Nadareishvili et al., 2016).

Isso difere da arquitetura monolítica, em que os serviços são modularizados e possuem baixo acoplamento, resultando em sistemas mais eficientes, escaláveis e estáveis.

### 3.2 Reconstrução tridimensional multicâmeras

No Sistema MobiLysa, uma das fontes para localização dos robôs é a visão computacional. Cada robô no espaço possui um marcador visual do tipo ArUco (Garrido-Jurado et al., 2014), fixado em sua plataforma. Esse tipo de marcador é facilmente detectado e permite a recuperação de informações de posição e orientação, sem ambiguidades.

As imagens capturadas pelas câmeras do espaço inteligente são processadas pelo microserviço de detecção de ArUco e as posturas do marcador nas diversas imagens são enviadas para o microserviço de reconstrução multicâmera. Esse microserviço é responsável por estimar a posição 3D e orientação do marcador e, portanto, do robô, no referencial global do espaço inteligente.

A vantagem de se utilizar visão computacional para estimar a localização é a sua acurácia e precisão, devido ao fato de que o erro é estacionário e depende apenas da câmera e de sua calibração. Isso não ocorre com a odometria das rodas, que apresenta um erro acumulativo à medida que o robô se desloca.

A reconstrução 3D a partir das imagens capturadas pelas câmeras é realizada conforme (Queiroz et al., 2018). O algoritmo foi transformado em um microserviço, permitindo sua escalabilidade para  $N$  câmeras presentes no espaço e aumentando a precisão na localização sempre que o marcador visual aparece em mais de duas imagens.

### 3.3 Localização probabilística baseada em mapas

Uma vez que o erro da localização baseada em odometria aumenta à medida que o robô se move, o uso de técnicas probabilísticas associadas a um método de mapeamento por mapas é uma solução para diminuir essa incerteza e minimizar esse problema (Thrun et al., 2005). Os mais utilizados para essa finalidade são normalmente laser, ultrassom ou câmeras.

Com uma abordagem probabilística, em vez de uma única estimativa da posição do robô, é possível obter uma distribuição de probabilidade sobre todas as posições possíveis. O algoritmo de Monte Carlo, que se tornou um dos mais populares, utiliza filtros de partículas para solucionar o problema da localização global (Siegwart et al., 2011). Tal algoritmo é implementado através da distribuição de uma nuvem de partículas no mapa, no qual, cada partícula representa uma possível posição e orientação do robô. Os sensores do robô captam informações do ambiente e seus movimentos são utilizados para atribuir pesos a cada partícula. As partículas com menor peso são descartadas, enquanto aquelas com maior peso são mantidas e usadas para atualizar a estimativa da distribuição de probabilidade do estado atual do robô.

O algoritmo de Monte Carlo está disponível por meio de um pacote do ROS, chamado *Monte Carlo Localization Approach* (AMCL). Este pacote foi incorporado ao PIS como um microserviço para fornecer uma das fontes de localização neste trabalho. Para utilizar o AMCL, é

necessário criar um mapa do ambiente, o que é feito pelo microserviço de mapeamento automático, o qual usa um algoritmo de *Simultaneous Localization and Mapping* (SLAM), também do ROS. Para a criação do mapa, o robô empregado neste trabalho usa um sensor laser embarcado.

### 3.4 Fusão de dados utilizando filtro de Kalman

No Sistema MobiLysa, a precisão da localização do robô é crucial para o seu correto funcionamento, uma vez que o robô depende dela para guiar uma pessoa em ambientes internos. Portanto, é fundamental que o sistema possua uma fonte de localização confiável, capaz de fornecer redundância de informações e alta precisão.

Nesse sentido, é necessário utilizar uma técnica que possa combinar as informações de localização disponíveis para gerar uma estimativa precisa. Uma das técnicas amplamente utilizadas em robótica é o *Extended Kalman filter* (EKF) (Thrun et al., 2005), que permite combinar informações de múltiplos sensores, mesmo com medidas ruidosas, para gerar estimativas mais confiáveis do estado do sistema. A escolha do EKF para fundir as informações de localização provenientes do método de Monte Carlo e da reconstrução tridimensional de múltiplas câmeras se justifica por ser uma técnica difundida na literatura e apresentar resultados satisfatórios em projetos na localização de robôs móveis.

Ademais, o algoritmo do EKF, descrito em (Thrun et al., 2005), é composto por duas fases: a fase de predição e a fase de atualização. Na fase de predição, o filtro estima o estado atual do robô com base na Equação (1), que representa o movimento do robô. Nessa equação,  $x_k$ ,  $y_k$  e  $\theta_k$  são os estados atuais do robô, enquanto  $x_{k-1}$ ,  $y_{k-1}$  e  $\theta_{k-1}$  são seus estados no instante de tempo  $k-1$ . O intervalo de tempo é representado pela taxa de amostragem  $\Delta_k$ , cujo o valor considerado para os experimentos foi de 0,1 segundos. Por fim,  $v$  e  $\omega$  são as velocidades linear e angular do robô, obtidas por meio da odometria.

$$\begin{bmatrix} x_k \\ y_k \\ \theta_k \end{bmatrix} = \begin{bmatrix} x_{k-1} \\ y_{k-1} \\ \theta_{k-1} \end{bmatrix} + \begin{bmatrix} \frac{v}{\omega}(-\sin(\theta_{k-1}) + \sin(\theta_{k-1} + \omega\Delta_k)) \\ \frac{v}{\omega}(+\cos(\theta_{k-1}) - \cos(\theta_{k-1} + \omega\Delta_k)) \\ \omega\Delta_k \end{bmatrix} \quad (1)$$

Para se obter a matriz de covariância da fase de predição é utilizada a Equação (2), onde  $P_k$  representa a matriz de covariância do filtro no instante  $k$ ,  $F$  é a matriz Jacobiana da equação de movimento do robô, descrito pela Equação (3),  $P_{k-1}$  é a covariância do filtro no instante  $k-1$ , e  $Q$  é a matriz de covariância do ruído do processo. Se definida de forma adequada, a matriz de covariância  $Q$  permite a obtenção de uma boa estimativa do estado do sistema mesmo em presença de ruído e incerteza. Desse modo, após a realização de experimentos, a matriz  $Q$  foi definida conforme a Equação (4).

$$P_k = FP_{k-1}F^T + Q \quad (2)$$

$$F = \begin{bmatrix} 1 & 0 & \frac{v}{\omega}(-\cos(\theta_{k-1}) + \cos(\theta_{k-1} + \omega\Delta_k)) \\ 0 & 1 & \frac{v}{\omega}(-\sin(\theta_{k-1}) + \sin(\theta_{k-1} + \omega\Delta_k)) \\ 0 & 0 & 1 \end{bmatrix} \quad (3)$$

$$Q = \begin{bmatrix} 0,008 & 0 & 0 \\ 0 & 0,008 & 0 \\ 0 & 0 & 0,0015 \end{bmatrix} \quad (4)$$

Em seguida, na fase de atualização, o EKF estima um ganho para calcular o estado do sistema. Na Equação (5), o ganho de Kalman é representado por  $K$ ,  $H$  é a matriz que modela o sensor e  $R$  é a matriz de covariância do sensor. Com o ganho  $K$ , a Equação (6) é usada para calcular o estado corrigido do sistema, onde  $X_k$  é o estado obtido na fase de predição,  $Y_k$  é a leitura do sensor e  $X_k^+$  é o estado corrigido estimado pelo filtro.

$$K = P_k H^T (H P_k H^T + R)^{-1} \quad (5)$$

$$X_k^+ = X_k + K(Y_k - H X_k) \quad (6)$$

No Sistema MobiLysa, dois métodos de localização são fundidos, o AMCL e a Reconstrução Multicâmeras. Para tanto, a matriz  $H$  do AMCL e da Reconstrução é descrita por uma matriz identidade  $3 \times 3$ . A matriz  $R$  do AMCL é determinada pelo próprio algoritmo de Monte Carlo, a partir das partículas do filtro. Quanto mais as partículas estiverem concentradas em torno da posição verdadeira do robô, menor será a covariância e maior será a confiança na posição estimada. Já a matriz  $R$  do sistema de câmeras foi obtida empiricamente, após a realização de experimentos, e está representada pela Equação (7). Vale ainda ressaltar que essas matrizes, bem como a matriz de ruído do processo, são extremamente importantes para a qualidade da fusão, e devem ser bem definidas no projeto.

$$R = \begin{bmatrix} 0,007 & 0 & 0 \\ 0 & 0,007 & 0 \\ 0 & 0 & 0,009 \end{bmatrix} \quad (7)$$

Durante a fase de atualização do filtro, a matriz de covariância é atualizada usando a Equação (8), na qual é utilizado o valor de  $P_k$  obtido na fase de predição do filtro e o ganho de Kalman.

$$P_k^+ = (I - KH)P_k \quad (8)$$

É importante mencionar que normalmente as duas fases alternam-se, com a fase de predição prevendo o estado até o instante da próxima observação e a fase de atualização incorporando a informação da observação. No entanto, isso não é obrigatório. Se alguma observação estiver indisponível, a fase de atualização pode ser desconsiderada e a predição pode ser realizada. Da mesma forma, se múltiplas medições independentes estiverem disponíveis ao mesmo tempo, vários passos de atualização podem ser realizados.

#### 4. EXPERIMENTOS E RESULTADOS

Nesta seção, são apresentados os experimentos realizados para avaliar o desempenho da proposta de fusão de dados no Sistema Mobilysa. A Tabela 1 lista as câmeras utilizadas no espaço inteligente, além de fornecer informações sobre o robô e os servidores utilizados na execução dos micros serviços e na condução dos experimentos. Vale ressaltar que os dois primeiros experimentos foram realizados no espaço inteligente da UFES, enquanto o último experimento foi realizado no IFES Campus Guarapari.

Tabela 1. Equipamentos


Dispositivo	Modelo	Quantidade
Câmeras UFES	BFLY-PGE-09S2C-CS	4
Câmeras IFES	Intelbras VIP 1230 D G2 f	6
Hardware do robô	Raspberry Pi 4	1
Laser	EAI YDLIDAR X4 360	1
Servidores	ES-2660 v4 @ 56x 3.2 GHz	1

#### 4.1 Estimativa de localização do sistema multicâmera

Para análise do erro de localização, obtido pelo micros serviço de reconstrução multicâmeras, foram posicionados no chão do laboratório nove marcadores ArUcos com identificadores diferentes, espaçados 1 metro entre si, conforme mostrado na Figura 2a. Montou-se, então, o gráfico da Figura 2b, no qual são indicados quais ArUcos foram ou não detectados por cada câmera, a localização dos marcadores reconstruída por cada câmera isoladamente, e a localização obtida pelo algoritmo de reconstrução multicâmera, que utiliza a informação de duas ou mais câmeras para realizar a reconstrução. Os erros de localização obtidos por cada câmera separadamente e pelo micros serviço de reconstrução podem ser vistos na Tabela 2.



(a) ArUcos posicionados no chão do laboratório.



(b) Erros de localização de cada câmera e do micros serviço de reconstrução multicâmera.

Figura 2. Estimativa de localização obtida pelo micros serviço de reconstrução multicâmera.

Tabela 2. Erro de Localização em (m).

	Cam0	Cam1	Cam2	Cam3	Reconstrução
P1	-	0,049	0,050	-	0,070
P2	-	0,033	0,027	0,044	0,020
P3	-	0,052	0,042	0,031	0,040
P4	0,030	0,023	0,034	0,049	0,032
P5	-	0,024	0,024	0,004	0,019
P6	0,051	0,085	0,055	0,062	0,064
P7	-	0,060	0,065	0,060	0,059
P8	0,030	-	-	0,040	0,013
P9	-	-	0,065	0,099	0,072



Ao analisar o gráfico da Figura 2 e a Tabela 2, nota-se que cada câmera individualmente não detectou todos os marcadores. Entretanto, por usar informação de todas as câmeras, o microserviço de reconstrução conseguiu detectar e localizar todos os marcadores presentes na cena. Além disso, o microserviço diminuiu o erro máximo de localização observado para cada uma das câmeras e, em alguns casos, apresentou erro menor do que a estimativa de todas as câmeras separadas. O erro médio de localização do microserviço de reconstrução foi de 0.0428 m.

#### 4.2 Estimativa de localização da fusão de dados

Entre os principais objetivos da fusão de dados para a localização no Sistema MobiLysa, estão a possibilidade do uso de informação redundante e a maior precisão e acurácia. Isso é alcançado pela utilização de duas fontes de localização dissociadas entre si. Assim, caso uma fonte não esteja disponível, a outra continuará alimentando o sistema.

Neste experimento, o intuito é avaliar a melhoria na estimativa da localização quando se usa a fusão dos métodos do AMCL (inclui odometria e laser) e visão (microserviço de reconstrução multicâmera), ao invés de se utilizar os métodos separados. Para isso, o robô percorreu uma trajetória circular de raio unitário, como mostrado na Figura 3, realizando mais de uma volta para avaliação.

Na primeira volta, as duas fontes de localização, AMCL e visão, foram utilizadas na fusão pelo EKF. O gráfico desta primeira volta pode ser visto na Figura 4. Uma flecha preta indica onde o robô iniciou o trajeto e o sentido em que ele percorreu a circunferência. A trajetória *ground truth* e a localização do robô estimada pelo AMCL e pela visão, em separado, bem como a fusão dos dois métodos, também estão mostradas na figura.




Figura 3. Robô realizando a trajetória circular.

O erro de localização (distância euclidiana) de cada medida ao longo do tempo em relação ao *ground truth* foi calculado e está mostrado na Figura 5a. Nota-se que o filtro estimou uma localização mais precisa do que os dois métodos separados. Além disso, o filtro apresentou um erro menor que 0,05 m durante a maior parte do percurso, diferentemente da reconstrução e, principalmente, do AMCL, que apresentou erro maior que 0,05 m em uma parte considerável do trajeto.

A Figura 5b exibe o gráfico de caixa do erro de localização da primeira volta. Note que todos os quartis da fusão de dados ficaram abaixo dos 0,05 m, em contraste com os métodos separados, que apresentaram uma maior dispersão nos dados. Ademais, a média do erro de localização da fusão de dados foi de 0,025 m, enquanto as câmeras apresentaram um erro de 0,031 m e o AMCL de 0,09 m.

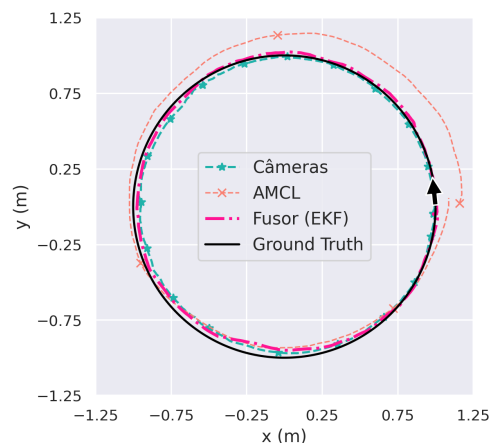




Figura 4. Localização na primeira volta.



(a) Erro de localização durante a primeira volta.



(b) Gráfico de Caixa do erro de localização da primeira volta.

Figura 5. Erro de localização da primeira volta.

Logo, a fusão de dados resultou em um erro de localização menor quando comparado aos métodos separados.

Na segunda volta, o filtro começou utilizando apenas o AMCL como fonte de localização. Entretanto, na metade do trajeto, a localização vinda das câmeras voltou a alimentar o filtro. O objetivo foi testar o desempenho do sistema de fusão em situações nas quais as câmeras não estão disponíveis em todo o ambiente de navegação do robô. Neste caso, o filtro deverá utilizar apenas uma fonte de localização para estimar a posição do robô, até o momento em que a segunda fonte retorne a fornecer suas estimativas.

A Figura 6 apresenta o *ground truth* e as localizações estimadas por cada uma das fontes, além da localização resultante da fusão de dados. É importante destacar que a contribuição das câmeras foi adicionada ao filtro, baseado

no EKF, somente após o robô ter passado pelo ponto  $(-0.9, -0.12)$  m, indicado pela flecha verde na Figura 6. Portanto, a localização dada pela reconstrução só foi exibida no gráfico a partir desse ponto.

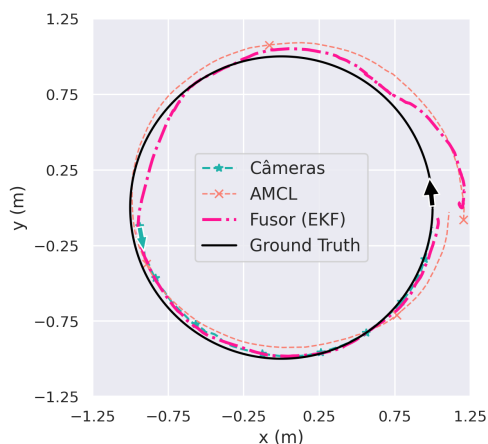


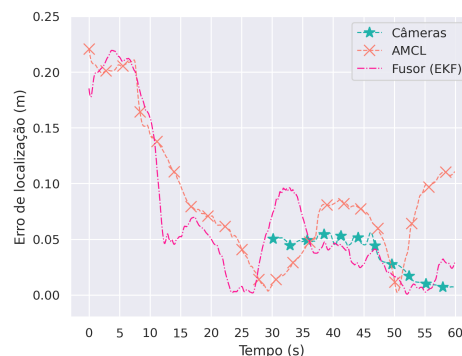
Figura 6. Localização na segunda volta.

De maneira semelhante à primeira volta, foram calculados os erros, em relação ao *ground truth*, de cada fonte de localização e do filtro. Esses erros estão mostrados na Figura 7. Ao analisar o gráfico na Figura 7a, nota-se que o erro de localização é maior sem o sistema de câmeras, ficando a maior parte do tempo acima de 0,05 m. Isso ocorre porque o EKF tem que estimar os estados do robô com base em medições menos precisas. No entanto, a fusão de dados melhorou a estimativa de localização ao ser alimentado novamente pelo sistema de câmeras. É importante mencionar que, mesmo ao ser alimentado com uma fonte de localização que possui uma covariância menor, o filtro melhorou sua estimativa de forma gradual, evitando a deriva entre as medições, como aconteceu após os 30 segundos do trajeto.


É possível ainda observar, na Figura 7b, que o EKF é capaz de estimar a localização com precisão melhor que o AMCL mesmo quando o sistema de câmeras não está disponível. Isso pode ser comprovado pelo fato de que todos os quartis apresentaram valores menores quando comparados ao AMCL, sendo a média do erro de localização do filtro de 0,097 m, em contraste com 0,11 m do AMCL. Além disso, a Figura 7c mostra que o sistema fundido estimou os estados do robô de forma mais precisa ao ser alimentado novamente pelo microserviço de reconstrução, apresentando menor dispersão entre os valores e uma média de erro de localização de 0.033 m, que é menor do que as estimativas do sistema de câmeras e do AMCL.

#### 4.3 Aplicação no PIS do IFES Guarapari


A fusão de dados foi fundamental para o funcionamento do sistema completo, não apenas pela melhoria na acurácia e precisão das estimativas, mas também por permitir uma transição suave entre as situações de indisponibilidade das medições provenientes das câmeras. Em zonas mortas (onde não há cobertura visual), o sistema de localização utiliza apenas o AMCL, até que o robô volte a ser visto por alguma câmera e, então, o sistema volte a receber estimativas do microserviço de reconstrução. Embora o



(a) Erro de localização durante a segunda volta.



(b) Gráfico de Caixa do erro de localização da primeira parte da segunda volta.



(c) Gráfico de Caixa do erro de localização da segunda parte da segunda volta.

Figura 7. Erro de localização no segundo trajeto

Sistema MobiLysa completo, com seus microserviços de mapeamento, navegação, desvio de obstáculos e planejamento de caminhos, não esteja detalhado neste trabalho, sua aplicação no IFES Guarapari será apresentada como um estudo de caso. O intuito é mostrar, de forma qualitativa, o uso da fusão dos métodos de localização em um ambiente real e comprovar a sua funcionalidade.

O Sistema MobiLysa foi implantado em um dos blocos do instituto, que possui 6 câmeras instaladas. A Figura 8 mostra o mapa do ambiente, onde as zonas com cobertura visual estão marcadas em hachura laranja. As demais partes do mapa correspondem às zonas mortas, em que a localização é feita apenas com base no mapa pelo AMCL.

Alguns vídeos que mostram: (i) a navegação do robô dentro de um laboratório, onde é sempre detectado pelas câmeras; (ii) a navegação em zona morta; e (iii) a navegação ao longo de todo o ambiente, podem ser vistos em link <sup>1</sup>, link <sup>2</sup> e link <sup>3</sup>.

<sup>1</sup> <https://www.youtube.com/watch?v=Qg-FVGTomdk>

<sup>2</sup> <https://www.youtube.com/watch?v=DYBSTO06kRg>

<sup>3</sup> <https://www.youtube.com/watch?v=tZGkEZeTh5M>




Figura 8. Mapa IFES Guarapari.

Como pode ser observado nos vídeos, o robô tem uma localização consistente mesmo em zonas mortas. Áreas como corredores tendem a ser problemáticas para a localização por mapa devido a sua simetria, porém, devido às câmeras a estimativa se mantém consistente.

## 5. CONCLUSÃO

Neste artigo, foi apresentada uma proposta para a localização de robôs móveis em espaços inteligentes, que integra visão computacional, por meio de câmeras presentes no ambiente, e a localização baseada em mapa, com o objetivo de obter maior acurácia, precisão, disponibilidade de medidas e capacidade de autocorreção.

Uma análise das diferentes fontes de localização utilizadas (reconstrução e AMCL) foi apresentada por meio de experimentos e métricas. Inicialmente, foram avaliados os erros de localização obtidos por cada uma das câmeras separadamente e pela reconstrução multicâmera, enfatizando a melhora nas estimativas quando mais de uma câmera é utilizada. A seguir, foram apresentados os experimentos com a fusão da reconstrução multicâmera e o AMCL, empregando o EKF como fusor. Além da avaliação dos erros de localização, foi apresentada a capacidade de autocorreção do sistema quando uma nova fonte de localização se torna disponível. Portanto, a aplicação da fusão dos métodos de localização no Sistema MobiLysa, por meio da navegação do robô em um ambiente não controlado, demonstrou de forma qualitativa a eficácia da abordagem proposta.

O módulo de fusão para localização ainda pode ser aprimorado em trabalhos futuros. O EKF possibilita a fusão de  $N$  fontes de localização, sejam elas locais ou globais. Neste trabalho, foi realizada a fusão de duas fontes globais de localização, havendo a pretensão de se adicionar um módulo de odometria visual, por meio de uma câmera embarcada no robô. Isso seria particularmente útil em ambientes simétricos ou zonas mortas, aumentando a precisão, eficiência e confiabilidade do sistema.

## REFERÊNCIAS

Cotta, W.A.A., Machado, F., Vassallo, R.F., do Carmo, A.P., Garcia, A.S., and de Araujo Sellin, N. (2019). Mobilysa-sistema de localização e controle do cão-guia robô lysa para ambientes internos baseado em visão computacional. In *Anais Estendidos do XXV Simpósio Brasileiro de Sistemas Multimídia e Web*, 159–162. SBC.

do Carmo, A.P. (2021). *Uma Arquitetura de Microsserviços centrada na Observabilidade Multinível para Espaços Inteligentes baseados em Visão Computacional*. Ph.D.

thesis, Universidade Federal do Espírito Santo Centro Tecnológico - Departamento de Engenharia Elétrica Programa de Pós-Graduação em Engenharia Elétrica.

do Carmo, A.P., de Queiroz, F.M., dos Santos, C.C., de Assis Silva, L., and Vassallo, R.F. (2020). Uso de um espaço inteligente baseado em visao computacional para o controle de formação de robôs móveis. In *Anais do XII Simpósio Brasileiro de Computação Ubíqua e Pervasiva*, 171–180. SBC.

Garrido-Jurado, S., Muñoz-Salinas, R., Madrid-Cuevas, F., and Marín-Jiménez, M. (2014). Automatic generation and detection of highly reliable fiducial markers under occlusion. *Pattern Recognition*, 47(6), 2280–2292. doi:https://doi.org/10.1016/j.patcog.2014.01.005.

Hashimoto, H. (2003). Intelligent space: Interaction and intelligence. *Artificial Life and Robotics*, 7, 79–85.

IBGE (2010). Pessoas com deficiência. https://educa.ibge.gov.br/jovens/conheca-o-brasil/populacao/20551-pessoas-com-deficiencia.html.

IBGE (2022). *Pessoas com deficiência e as desigualdades sociais no Brasil*. IBGE.

Izabel, V.H., de Oliveira, M.D., Menines, M.S., Vassallo, R.F., Silva, L.d.A., and do Carmo, A.P. (2022). Implantação do sistema mobilysa em espaços inteligentes programáveis. In *Anais do 14º Simpósio Brasileiro de Computação Ubíqua e Pervasiva*. SBC.

Lee, J.H. and Hashimoto, H. (2002). Intelligent space — concept and contents. *Advanced Robotics*, 16(3), 265–280.

Nadareishvili, I., Mitra, R., McLarty, M., and Amundsen, M. (2016). *Microservice architecture: aligning principles, practices, and culture*. "O'Reilly Media, Inc."

Peavy, M., Kim, P., Oyediran, H., and Kim, K. (2023). Integration of real-time semantic building map updating with adaptive monte carlo localization (amcl) for robust indoor mobile robot localization. *Applied Sciences*, 13(2), 909.

Queiroz, F., Picoreti, R., Canuto, C., Fernandes, M., and Vassallo, R. (2018). Estimating tridimensional coordinates of skeleton joints in a multicamera system. In *Anais do XIV Workshop de Visao Computacional*.

Shen, J., Tick, D., and Gans, N. (2011). Localization through fusion of discrete and continuous epipolar geometry with wheel and imu odometry. In *Proceedings of the 2011 American Control Conference*, 1292–1298. IEEE.

Siegwart, R., Nourbakhsh, I., and Scaramuzza, D. (2011). *Autonomous Mobile Robots*. MIT Press.

Thrun, S., Burgard, W., and Fox, D. (2005). *Probabilistic Robotics*. Intelligent Robotics and Autonomous Agents series. MIT Press.

Vaščák, J., Papcun, P., Zolotová, I., and Puheim, M. (2020). Intelligent space design for robotic and iot applications. In *2020 Cybernetics & Informatics (K&I)*, 1–6. IEEE.

Yan, Y., Zhang, B., Zhou, J., Zhang, Y., and Liu, X. (2022). Real-time localization and mapping utilizing multi-sensor fusion and visual-imu-wheel odometry for agricultural robots in unstructured, dynamic and gps-denied greenhouse environments. *Agronomy*, 12(8), 1740.