

Monitoramento e predição de sistemas autônomos

Enzo Guido Americano da Costa¹, Adilson Luiz Bonifácio¹

¹Departamento de Computação – Universidade Estadual de Londrina (UEL)
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

enzoguido.a375@uel.br, bonifacio@uel.br

Abstract. *The goal of this research is to unite information that is usually splited and segmented in several articles and other researches related to the topic of simultaneous localization and mapping (SLAM), in order to understand what this challenge provides as a solution and advance on several issues, from commercial and business to housewares. In addition, all topics of this theme will be unraveled and explained separately, thus demonstrating a simulation of a real application using all the means and methods described.*

Resumo. *O objetivo dessa pesquisa é unir informações que geralmente se encontram separadas e segmentadas em diversos artigos e outras pesquisas relacionadas com o tema de localização e mapeamento simultâneos (SLAM), com o intuito de entender o que esse desafio proporciona como solução e avanço sobre diversos quesitos, desde comerciais e empresariais até utilidades domésticas. Além disso, todos os tópicos desse tema serão destrinchados e explicados de forma isolada para, assim, demonstrar uma simulação de aplicação real utilizando todos os meios e métodos descritos.*

1. Introdução

A busca por sistemas de navegação autônoma tem sido uma das principais fronteiras tecnológicas nas últimas décadas, impulsionando avanços significativos em áreas como robótica, inteligência artificial e processamento de dados. Um dos elementos-chave para permitir que robôs e veículos autônomos operem em ambientes desconhecidos e em constante mudança é a capacidade de construir mapas do ambiente em tempo real enquanto se localizam de forma simultânea, esse é o desafio enfrentado pelo Simultaneous Localization and Mapping (SLAM), ou Mapeamento e Localização Simultâneos.

O problema do SLAM envolve a integração de informações sensoriais e de movimento para criar um mapa preciso do ambiente em que um robô ou veículo autônomo está operando, ao mesmo tempo em que estima sua própria posição nesse mapa. Essa tarefa complexa tem sido objeto de intensa pesquisa e desenvolvimento, gerando uma série de abordagens e algoritmos com o objetivo de lidar com as diversas incertezas inerentes a um ambiente real.

Uma das técnicas mais fundamentais e amplamente utilizadas para abordar o problema do SLAM é o Filtro de Kalman, publicado e descrito pela primeira vez em [2]. O filtro de Kalman é um algoritmo de rastreamento e predição, que utiliza medições de grandezas realizadas ao longo do tempo (contaminadas com ruído e outras incertezas), a partir de sensores do sistema autônomo, para estimar sua posição atual e prever a próxima.

A motivação da escolha do tema veio de um estudo prévio sobre o mesmo e a dificuldade encontrada para poder reunir toda a informação necessária e, dessa forma,

utilizar desse conhecimento para reunir todas as teorias, algoritmos e estruturas em uma só aplicação que possa solucionar um problema real.

2. Fundamentação

Sistemas autônomos são capazes de realizar tarefas e tomar decisões de forma independente, sem a necessidade de intervenção humana direta, como descrito em [5], são capazes de mudar sua estrutura de ações mediante a eventos inesperados. Um desafio crucial para esses sistemas é obter informações precisas sobre o meio e estimar sua própria posição e orientação em relação a esse ambiente em constante mudança. É aqui que o filtro de Kalman desempenha um papel fundamental.

Ele é especialmente útil em sistemas onde os dados de entrada são afetados por erros de medição e ruído, como é o caso de sensores utilizados em sistemas autônomos. Como já citado anteriormente, o filtro de Kalman funciona combinando duas fontes de informações: as medições e previsões sobre o estado do sistema. As medições são fornecidas pelos sensores, como GPS, giroscópios, acelerômetros, câmeras, lidars (permite calcular distâncias de objetos em uma faixa de ângulo por meio de refração da luz), radares ou outros dispositivos que capturam informações do ambiente. Já as previsões do sistema são obtidas por meio de um modelo matemático que descreve o comportamento dinâmico do mesmo. O filtro de Kalman combina essas informações de maneira ponderada, levando em consideração as incertezas associadas a cada uma delas para que, ao final dos tratamentos necessários, evite ao máximo a distorção da confiança do sistema em sua posição e orientação, como explicado em [4].

Em sistemas autônomos, o filtro de Kalman é frequentemente usado para estimar a posição, orientação e velocidade do veículo ou robô em relação a um mapa do ambiente que, em muitos casos, está em constante mudança, como citado em [1]. Os sensores fornecem informações sobre a movimentação e percepção do sistema a partir de medidas diretas, como odometria e IMU, e/ou indiretas, como comparação de mapas que retornam um valor aproximado da sua movimentação, como descrito em [3]. Tais informações são utilizadas pelo filtro de Kalman para atualizar continuamente a estimativa do estado do sistema, permitindo que o objeto de estudo autônomo entenda sua posição em relação ao ambiente e tome decisões apropriadas.

Antes de saltar direto para as fórmulas e métodos de aplicação, são necessários alguns conhecimentos prévios para poder entender e interpretar corretamente o algoritmo e sistema como um todo, são eles:

- Média, é o estado do sistema conhecido, apresenta a concentração dos dados em uma distribuição, representada por μ .
- Valor esperado, média ponderada de eventos aleatórios levando em conta suas probabilidades associadas, representado por E .
- Variância, mede a dispersão dos valores sobre um conjunto de dados em relação à sua média, representada por σ^2 .
- Desvio padrão, quantifica a dispersão dos valores sobre um conjunto de dados em relação à média, é calculado como a raiz quadrada da variância, representado por σ .
- Distribuição normal, ou distribuição gaussiana, é o valor da média mais ou menos o desvio padrão, descrita por momentos/intervalos de acordo com o desvio padrão.

- Variável aleatória, é uma função que associa valores numéricos possíveis a eventos em um espaço amostral de um experimento probabilístico, pode ser contínua ou discreta.

Contínua: pode assumir qualquer valor dentro de um intervalo dado.

Discreta: pode assumir apenas um conjunto finito ou enumerável de valores.

- Momento, descreve a forma e o comportamento da distribuição em um determinado instante, por exemplo, a média e distribuição normal no instante k .

Momento bruto: é calculado diretamente a partir dos dados originais ou da distribuição de probabilidade, é o valor esperado da k -ésima potência da variável aleatória $E(X^k)$.

Momento central: é calculado em relação à média da distribuição ou conjunto de dados, é o valor esperado da k -ésima potência da distribuição de variáveis aleatórias em torno de sua média $E((X - \mu_X)^k)$.

- Estimativa, é uma aproximação ou cálculo de um valor desconhecido baseado em informações disponíveis, ou seja, avalia o estado "oculto" (não conhecido) do sistema de acordo com dados provenientes de maneira interna ou externa, por exemplo os sensores descritos previamente.
- Acurácia/exatidão, indica o quão próxima a medição está do valor real absoluto.
- Variância, quantifica o grau de dispersão dos valores em um conjunto de dados em relação à média.

Variância da estimativa do estado, é o grau de erro sobre uma estimativa para o valor real, representada por p .

Variância da medição, é desvio padrão entre o valor real e o valor medido, representada por r .

- Peso, é a importância ou influência de algo, utilizado para médias ponderadas como medição, estimativa, etc, representado por w .

Algumas notações também serão utilizadas nas fórmulas e exemplo mais a frente:

- x = valor real do estado (por exemplo, peso de uma pessoa ou posição atual do robô).
- z_n = valor medido no tempo n .
- \hat{x} = valor estimado.
- $\hat{x}_{n,n}$ = estimativa de x no tempo n depois da medida de z_n .
- $\hat{x}_{n+1,n}$ = previsão de x em um estado futuro ($n + 1$) no tempo n .
- α = precisão da medição (quanto maior mais significativa é) para posição.
- β = precisão da medição para velocidade.
- γ = precisão da medição para aceleração.
- K_n (ou α_n) = ganho de Kalman, determina o quanto a estimativa atual do estado de um sistema será ajustada com base na diferença entre as medições reais e as previsões feitas pelo filtro de Kalman, pode mudar a cada iteração.
- \dot{x} = derivada de x .
- $p_{n,n}$ = variância da estimativa no tempo n ($\hat{x}_{n,n}$).
- $p_{n,n-1}$ = variância da estimativa anterior ($\hat{x}_{n,n-1}$).
- r_n = variância da medição atual (z_n).
- q_n = variância do ruído do processo (embutido na leitura dos dados).

As fórmulas que descrevem os passos e estados do filtro de Kalman e transformam os dados de entrada em estimativas e previsões são:

- Equações de atualização de estado (State Update Equations), utiliza a predição realizada na iteração anterior para determinar o estado estimado do objeto. Depende do α , β e γ para determinar o quão impactante será cada leitura no decorrer do programa, dessa forma, como já citado anteriormente na sessão "Notações", se as leituras forem mais precisas, ou seja, α , β e γ maiores, maior será o seu impacto na dinâmica do sistema.

$$\hat{x}_{n,n} = \hat{x}_{n,n-1} + \alpha * (z_n - \hat{x}_{n,n-1}) \text{ (posição)}$$

$$\hat{\dot{x}}_{n,n} = \hat{\dot{x}}_{n,n-1} + \beta * \frac{z_n - \hat{x}_{n,n-1}}{\Delta t} \text{ (velocidade)}$$

$$\hat{\ddot{x}}_{n,n} = \hat{\ddot{x}}_{n,n-1} + \gamma * \frac{z_n - \hat{x}_{n,n-1}}{0.5 * \Delta t^2} \text{ (aceleração)}$$

- Equações de extrapolação de estado (State Extrapolation Equations), utiliza a estimativa calculada na iteração atual para tentar prever qual será a posição do objeto na iteração posterior.

$$\hat{x}_{n+1,n} = \hat{x}_{n,n} + \hat{\dot{x}}_{n,n} * \Delta t + \hat{\ddot{x}}_{n,n} * (\Delta t^2 * 2) \text{ (posição)}$$

$$\hat{\dot{x}}_{n+1,n} = \hat{\dot{x}}_{n,n} + \hat{\ddot{x}}_{n,n} * \Delta t \text{ (velocidade)}$$

$$\hat{\ddot{x}}_{n+1,n} = \hat{\ddot{x}}_{n,n} \text{ (aceleração)}$$

- Relação entre variâncias (medição e predição), é uma medida de incerteza que é usada para combinar informações provenientes de duas fontes diferentes, que são as medições reais do sistema e as estimativas de estado baseadas no modelo de predição do sistema, fazendo uma relação entre o quão precisa é uma medição e o quão preciso é o modelo do sistema.

Dessa forma, as variâncias de ambos os dados são levadas em conta para determinar a melhor estimativa do estado atual do sistema.

$$p_{n,n} = (w_1)^2 * r_n + (w_2)^2 * p_{n,n-1} \text{ sendo } w_1 + w_2 = 1$$

- Equação do ganho de Kalman (Kalman Gain), é resultado de derivações em algumas fórmulas já apresentadas previamente. Como o objetivo do filtro de Kalman é achar uma estimativa ótima, deve-se minimizar a sua variância, resultando em:

$$p_{n,n} = (w_1)^2 * r_n + (1 - w_1)^2 * p_{n,n-1} \text{ (relação entre variâncias)}$$

$$\frac{dp_{n,n}}{dw_1} = 2 * w_1 - 1 * r_n - 2 * (1 - w_1) * p_{n,n-1} = 0$$

Dessa forma:

$$w_1 = \frac{p_{n,n-1}}{p_{n,n-1} + r_n} = K_n$$

Assim, substituindo na equação de estimação do estado atual temos:

$$\hat{x}_{n,n} = K_n * z_n + (1 - K_n) * \hat{x}_{n,n-1} = \hat{x}_{n,n-1} + K_n * (z_n - \hat{x}_{n,n-1})$$

Portanto, pode-se perceber que o ganho de Kalman é um balanceamento entre variâncias, sendo sobre a predição da estimativa anterior e a medição atual, para minimizar a variância ao calcular a estimativa do estado atual, atuando melhor no balanceamento da mesma e, portanto, também na predição ao se comparar com os filtros α - β - γ , que são puramente precisões das medições recebidas como parâmetros iniciais e imutáveis.

- Equação de atualização de covariância (Covariance Update Equation), como seu valor é utilizado na equação anterior, assim como as outras equações, é necessário atualizá-lo a cada iteração, sendo assim:

$$p_{n,n} = (K_n)^2 * r_n + (1 - K_n)^2 * p_{n,n-1}$$

Para achar w_2 , $1 - K_n$, temos:

$$1 - K_n = 1 - p_{n,n-1} / (p_{n,n-1} + r_n) = r_n / (p_{n,n-1} + r_n)$$

Substituindo:

$$p_{n,n} = \left(\frac{p_{n,n-1}}{p_{n,n-1}+r_n}\right)^2 * r_n + \left(\frac{r_n}{p_{n,n-1}+r_n}\right)^2 * p_{n,n-1} = \frac{p_{n,n-1}*r_n}{p_{n,n-1}} + r_n * \frac{p_{n,n-1}}{p_{n,n-1}+r_n} + \frac{r_n}{p_{n,n-1}+r_n} = (1 - K_n) * p_{n,n-1}$$

- Equação de predição de covariância, reduz erros de estimativa ao adicionar incerteza do modelo dinâmico (Process Noise), como o valor de um resistor poder mudar de iteração a iteração por conta da temperatura ambiente

$$p_{n+1,n} = p_{n,n} + q_n$$

Agora, suponha num cenário simples (unidimensional e apenas uma medida) que deseja-se estimar a temperatura de um líquido num recipiente. Sabemos que o líquido está sendo aquecido, porém não sabemos com qual proporção o líquido se aquece (quantos graus por segundo), e, além disso, algumas medições podem conter algum ruído/erro aleatório.

Iteração 0 (Inicialização) Na inicialização do algoritmo alguns parâmetros precisam ser definidos. Podemos definir, de forma aleatória, uma temperatura inicial de 10°C ($\hat{x}_{0,0}$) para o líquido. Como nosso palpite é aleatório e impreciso, inicializamos os parâmetros σ como 100, dessa forma, $p_{0,0} = 100^2 = 10.000$, q como 0,15 e r como 0,01, ou seja, um baixo ruído da medição implicando em medições mais confiáveis/precisas.

Como temos apenas uma medida para usar de referência em nosso sistema, a predição da próxima iteração é igual a estimativa do estado atual, portanto $\hat{x}_{1,0} = \hat{x}_{0,0}$ e $p_{1,0} = p_{0,0} + q = 10.000, 15$.

Iteração 1 A cada iteração um sensor (por exemplo um termômetro) lê a temperatura do líquido (medição), dessa forma, com base nas variáveis setadas no chute inicial, predição do estado atual 0 e confiabilidade do sistema/sensor, e com a temperatura medida, começamos a execução do algoritmo tendo uma estimativa do estado atual. Assim, podemos tentar prever qual será o estado posterior do líquido, onde na próxima iteração será realizada outra medição dando continuidade ao ciclo.

– Medição (z_n) = 50,486°C

– Estimativas do estado atual:

$$K_1 = \frac{10.000,15}{10.000,15+0,01} = 0,999999$$

$$\hat{x}_{1,1} = 10 + 0,999999 * (50,486 - 10) = 50,486C$$

$$p_{1,1} = (1 - 0,999999) * 10.000,15 = 0,01$$

– Predições:

$$\hat{x}_{2,1} = \hat{x}_{1,1} = 50,486C$$

$$p_{2,1} = 0,01 + 0,15 = 0,16$$

Iteração 2

– Medição (z_n) = 50,963°C

– Estimativas do estado atual:

$$K_2 = \frac{0,16}{0,16+0,01} = 0,9412$$

$$\hat{x}_{2,2} = 50,486 + 0,9412 * (50,963 - 50,486) = 50,934C$$

$$p_{2,2} = (1 - 0,9412) * 0,16 = 0,0094$$

– Predições:

$$\hat{x}_{3,2} = \hat{x}_{2,2} = 50,934C$$

$$p_{3,2} = 0,0094 + 0,15 = 0,1594$$

Iteração 3

- Medição (z_n) = 51,597°C
- Estimativas do estado atual:
 $K_3 = \frac{0,1594}{0,1594+0,01} = 0,941$
 $\hat{x}_{3,3} = 50,934 + 0,941 * (51,597 - 50,934) = 51,556C$
 $p_{3,3} = (1 - 0,941) * 0,1594 = 0,0094$
- Predições:
 $\hat{x}_{4,3} = \hat{x}_{3,3} = 51,556C$
 $p_{4,3} = 0,0094 + 0,15 = 0,1594$

Iteração 10

- Medição (z_n) = 55,114°C
- Estimativas do estado atual:
 $K_{10} = \frac{0,1594}{0,1594+0,01} = 0,941$
 $\hat{x}_{10,10} = 54,248 + 0,941 * (55,114 - 54,248) = 55,074C$
 $p_{10,10} = (1 - 0,941) * 0,1594 = 0,0094$
- Predições:
 $\hat{x}_{11,10} = \hat{x}_{10,10} = 55,074C$
 $p_{11,10} = 0,0094 + 0,15 = 0,1594$

A Figura 1 apresenta os resultados da aplicação do filtro de Kalman no cenário descrito.

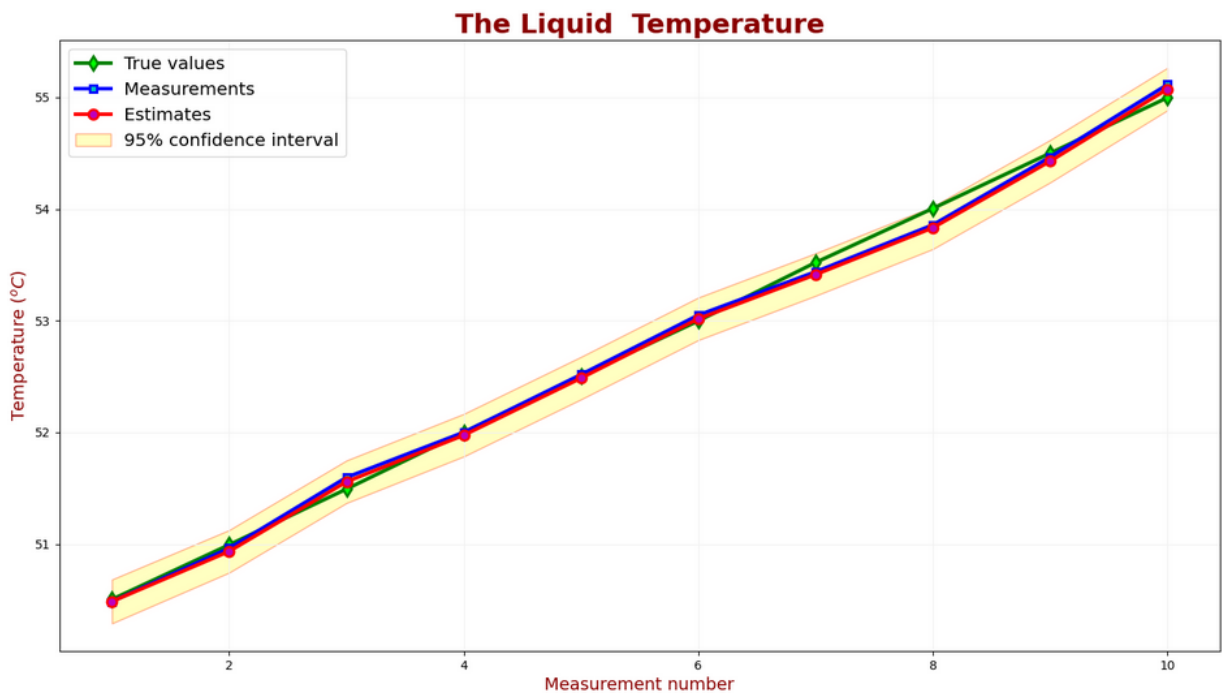


Figura 1. Resultados da aplicação

3. Objetivos

O objetivo principal desse projeto é introduzir o tema e abordar como as pesquisas, juntamente com os modelos matemáticos e aplicações, podem fazer diferença tanto no mercado

de trabalho como em um ambiente doméstico. Além de juntar e reorganizar esses temas para apresentá-los de maneira mais instrutiva e didática, afim de que qualquer um sem conhecimento prévio ou entendimento do assunto possa, ao menos, entender como foram feitos todos esses processos e acompanhar a resolução do começo ao fim.

A ideia é apresentar uma aplicação final que junte os tópicos abordados em uma estrutura única e funcional simulada em um ambiente controlado, mostrando sua utilidade e praticidade.

Os objetivos específicos do projeto são:

1. Estudar sobre algoritmos de predições prévios ao filtro de Kalman e como eles conduziram para o surgimento do mesmo e sua introdução em problemas SLAM.
2. Pesquisar sobre artigos, pesquisas e outras publicações que envolvam o tema, principalmente nas partes de modelagem, estrutura, aplicação e possíveis melhorias.
3. Estudar e avaliar técnicas distintas que possibilitem a criação de um modelo que consiga centralizar todo o conteúdo em uma única aplicação.
4. Propor uma arquitetura de teste para poder desenvolver diversas ideias e chegar em um consenso sobre como será realizada a demonstração prática.
5. Implementar uma aplicação em simulação controlada que possa demonstrar visualmente o funcionamento geral de veículos e robôs autônomos.
6. Testar com diversos tipos de dados de entrada e verificar se existe uma constância positiva sobre os resultados obtidos e esperados.

4. Procedimentos metodológicos

O desenvolvimento deste trabalho seguirá um conjunto de atividades estabelecidas com o intuito de alcançar os objetivos propostos. As atividades estão previstas para serem realizadas durante o período planejado no cronograma da Tabela 1 e descritas abaixo:

1. Revisão bibliográfica sobre os temas filtro de Kalman, algoritmos SLAM e outros tópicos relacionados ao assunto.
2. Estudo e levantamento bibliográfico de aplicações realizadas e comprovadas sobre o tema.
3. Análise e avaliação de uma implementação própria que combine os diversos temas abordados em um único esquema de código.
4. Elaboração de mecanismos que possam ajudar na implementação, como estruturas a serem criadas, dados a serem inseridos e plataformas que facilitem a simulação visual.
5. Implementação da aplicação como um todo, desde sua base até a demonstração final.
6. Teste com diversos tipos de dados e estudo sobre os resultados gerados.
7. Divulgação dos resultados através de publicações.

5. Contribuições e/ou Resultados esperados

Entre os resultados esperados desse projeto estão: os estudos aprofundados sobre filtro de Kalman, algoritmos SLAM, entrada de dados e como sintetizá-los para que possam ser usados no modelo projetado e a implementação do sistema que permita uma visualização das simulações e outras aplicações a partir dele;

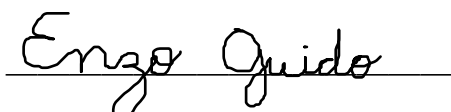
Espera-se que os métodos e ferramentas apresentados se tornem úteis para outras pesquisas e aplicações relacionadas, e também para a sintetização e junção de conhecimentos diversos em prol de um modelo que possa solucionar problemas reais.

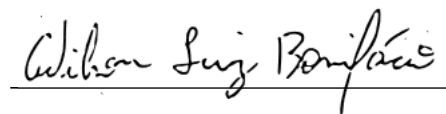
Atividade	2023					2024						
	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul
1	•											
2	•											
3		•	•									
4			•	•	•							
5					•	•	•					
6							•	•	•			
7									•	•	•	•

Tabela 1. Cronograma de execução

6. Espaço para assinaturas

Londrina, 18 de setembro de 2023.


Aluno


Orientador

Referências

- [1] Kichun Jo, Chansoo Kim, and Myoung-ho Sunwoo. Simultaneous localization and map change update for the high definition map-based autonomous driving car. *Sensors*, 18(9):3145, 2018.
- [2] Rudolph Emil Kalman. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1):35, 1960.
- [3] Ryo Kuramachi, Akihito Ohsato, Yoko Sasaki, and Hiroshi Mizoguchi. G-icp slam: An odometry-free 3d mapping system with robust 6dof pose estimation. In *2015 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pages 176–181. IEEE, 2015.
- [4] María L Rodríguez-Arévalo, José Neira, and José A Castellanos. On the importance of uncertainty representation in active slam. *IEEE Transactions on Robotics*, 34(3):829–834, 2018.
- [5] David P Watson and David H Scheidt. Autonomous systems. *Johns Hopkins APL technical digest*, 26(4):368–376, 2005.