
Análise da Aplicação de Filtro de
Partículas a VANTS

Fabrício Pereira de Freitas

São Carlos - SP

Análise da Aplicação de Filtro de Partículas a VANTs

Fabrício Pereira de Freitas

Orientador: Kalinka Regina Lucas Jaquie Castelo Branco

Monografia referente ao projeto de conclusão de curso dentro do escopo da disciplina SSC0670 – Projeto de Formatura I do Departamento de Sistemas de Computação do Instituto de Ciências Matemáticas e de Computação – ICMC-USP para obtenção do título de Engenheiro de Computação.

Área de Concentração: Robótica.

**USP – São Carlos
Novembro de 2019**

Agradecimentos

À orientadora, Prof^a Dr^a Kalinka Regina Lucas Jaquie Castelo Branco, pelo suporte, correções e sugestões disponibilizados durante o desenvolvimento do projeto.

À Dr^a Natássya Barlate Floro da Silva por ter disponibilizado, em nome do Laboratório de Sistemas Embarcados Críticos, parte das ferramentas e dados utilizados no desenvolvimento do trabalho bem como por seu apoio na concepção do projeto.

Resumo

Este trabalho consiste de um estudo quanto a viabilidade do uso de Filtros de Partículas aplicados ao contexto de navegabilidade de Veículos Aéreos Não Tripulados (VANTs). Estimar o estado de um dispositivo é essencial quando se trata de tomada automatizada de decisões. No contexto de VANTs, esse estado normalmente é caracterizado pela posição, velocidade e orientação da aeronave. Entretanto, estimar o estado da aeronave durante o voo nem sempre é simples devido a fatores como ruído nas medidas dos sensores e forças externas ao sistema. Construiu-se um filtro capaz de fazer uso dos dados advindos de uma Unidade de Medida Inercial (IMU – *Inertial Measurement Unit*) bem como de um receptor de Sistema de Posicionamento Global (GPS – *Global Positioning System*) a fim de obter uma estimativa mais precisa do estado da aeronave e avaliar a viabilidade de tal filtro para fusão sensorial em navegação de VANTs. Foram realizadas simulações de voo utilizando-se de dados sensoriais de dispositivos IMU e receptores de GPS para estudar a capacidade do filtro de estimar corretamente o estado da aeronave quando utilizado como módulo de fusão de dados sensoriais.

Palavras-chave: Filtro de Partículas, IMU, GPS, VANT

Sumário

LISTA DE GRÁFICOS.....	V
LISTA DE TABELAS	VI
LISTA DE FIGURAS.....	VII
LISTA DE ALGORITMOS.....	I
CAPÍTULO 1: INTRODUÇÃO	1
1.1. CONTEXTUALIZAÇÃO E MOTIVAÇÃO.....	1
1.2. OBJETIVOS.....	2
1.3. ORGANIZAÇÃO DO TRABALHO	2
CAPÍTULO 2: REVISÃO BIBLIOGRÁFICA.....	3
2.1. CONSIDERAÇÕES INICIAIS.....	3
2.2. SENsoRES	3
2.2.1. <i>IMU</i>	3
2.2.2. <i>Receptor de GPS</i>	4
2.3. O FILTRO DE PARTÍCULAS	4
2.3.1. <i>Descrição e Características Gerais</i>	6
2.3.2. <i>Propriedades e Possíveis Problemas do Filtro de Partículas</i>	9
2.3.3. <i>Amostragem por Importância e Reamostragem</i>	10
2.3.4. <i>O Filtro de Partículas no Contexto de Localização</i>	13
2.4. CONSIDERAÇÕES FINAIS	14
CAPÍTULO 3: DESENVOLVIMENTO DO TRABALHO	15
3.1. CONSIDERAÇÕES INICIAIS.....	15
3.2. CONTEXTO DO PROJETO	15

3.3. DESCRIÇÃO DAS ATIVIDADES REALIZADAS	16
3.3.1. <i>Modelo de Navegabilidade</i>	16
3.3.2. <i>Implementação do Filtro de Partículas</i>	18
3.3.3. <i>Amostragem por Importância</i>	19
3.3.4. <i>Reamostragem</i>	21
3.3.5. <i>Outras Etapas Implementadas no Filtro</i>	22
3.3.6. <i>Simulações</i>	23
3.4. RESULTADOS OBTIDOS	24
3.4.1. <i>Filtro de Partículas</i>	24
3.4.2. <i>Filtro de Partículas – Sem Reamostragem</i>	26
3.4.3. <i>Filtro de Partículas – IMU</i>	27
3.4.4. <i>Comparação Entre as Simulações</i>	29
3.5. DIFÍCULDADES E LIMITAÇÕES	29
3.6. CONSIDERAÇÕES FINAIS	30
CAPÍTULO 4: CONCLUSÃO	31
4.1. CONTRIBUIÇÕES	31
4.2. TRABALHOS FUTUROS	31
REFERÊNCIAS.....	33

Lista de Gráficos

Gráfico 1 - RMS das distâncias ao longo da simulação do Filtro de Partículas	25
Gráfico 2 - RMS das distâncias ao longo da simulação sem reamostragem	27
Gráfico 3 - RMS das distâncias ao longo da simulação com apenas IMU.....	28

Lista de Tabelas

Tabela 1 – Filtro de Partículas: Vantagens e Desvantagens 5

Lista de Figuras

Figura 1 - Representação de uma Distribuição por meio de Partículas	7
Figura 2 - Processo de Amostragem Por Importância	12
Figura 3 - Rota Utilizada durante as Simulações.....	23
Figura 4 - Rota Estimada pelo Filtro de Partículas	25
Figura 5 - Rota Estimada pelo Filtro de Partículas - Sem Reamostragem	26
Figura 6 - Rota Estimada pelo Filtro de Partículas usando apenas IMU	28

Lista de Algoritmos

Algoritmo 1 - Filtro de Partícula Básico.....	13
Algoritmo 2 – Algoritmo Monte Carlo Localization (MCL)	14

CAPÍTULO 1: INTRODUÇÃO

1.1. Contextualização e Motivação

Medir precisamente o estado de um dispositivo é essencial quando se trata de tomada automatizada de decisões. No contexto de Veículos Aéreos Não Tripulados (VANTs), esse estado normalmente é caracterizado pela posição, velocidade e orientação. Dois tipos de sensores se destacam na determinação do estado de um VANT, a Unidade de Medida Inercial (IMU – *Inertial Measurement Unit*) e o receptor de Sistema de Posicionamento Global (GPS – *Global Positioning System*) são frequentemente utilizados nesse contexto.

Apesar de ambos os sensores serem capazes de proporcionar informações sobre o estado da aeronave, as particularidades de cada sensor justificam o uso de ambos em conjunto para obtenção de uma melhor estimativa do estado. A IMU é um dispositivo que mede a força específica, velocidade angular e, em alguns casos, a orientação do corpo utilizando-se de um conjunto de dispositivos incluindo acelerômetros, giroscópios. Algumas IMUs também fazem uso de magnetômetros. Os pontos positivos de uma IMU se caracterizam por sua elevada taxa de atualização e capacidade de prover dados variados sem depender de um sistema externo. Porém, uma grande desvantagem normalmente apresentada por IMUs é o acúmulo de erros ao longo do tempo, o que pode resultar em uma situação onde a posição medida e a posição real estão cada vez mais distantes. O sensor de GPS, por sua vez, é um dispositivo capaz de produzir medidas consistentes ao longo do tempo, evitando o acúmulo de erros, porém suas medidas não possuem grande precisão, além de apresentar uma taxa de atualização significativamente menor do que a de uma IMU.

Dadas as vantagens e desvantagens de ambos os dispositivos, nenhum deles seria capaz de produzir uma estimativa aceitável do estado atual de posição e orientação da aeronave. Entretanto, utilizar ambos os sensores em conjunto torna possível contornar suas deficiências individuais e obter estimativas adequadas à navegação de uma aeronave. Para tal, pode-se fazer uso de diversos filtros, cada um com suas vantagens e desvantagens.

1.2. Objetivos

O objetivo deste trabalho é estudar a viabilidade do uso de Filtros de Partículas aplicados ao contexto de navegabilidade de VANTs. Espera-se construir um filtro capaz de fazer uso dos dados advindos tanto da IMU quanto do sensor de GPS a fim de obter uma estimativa precisa do estado de uma aeronave.

1.3. Organização do Trabalho

No Capítulo 2 são abordados os conceitos utilizados no desenvolvimento deste trabalho. São discutidas as características e limitações dos sensores bem como sua aplicação no sistema de navegabilidade. São discutidas as características do filtro utilizado e o seu papel, incluindo as vantagens que o seu uso traz em comparação com um sistema que não faz uso de um filtro para unir dados de diferentes sensores. A seguir, no Capítulo 3, é discutida a abordagem adotada no trabalho, bem como os resultados obtidos. Finalmente, no Capítulo 4 apresentam-se as conclusões, contribuições deste trabalho e os possíveis trabalhos futuros. A relação deste trabalho com o curso de Engenharia da Computação também é discutida no Capítulo 4.

CAPÍTULO 2: REVISÃO BIBLIOGRÁFICA

2.1. Considerações Iniciais

Este capítulo apresenta conceitos relacionados aos sensores utilizados, discutindo seu papel na obtenção da orientação bem como as vantagens e limitações de cada sensor. A seguir, é apresentada uma introdução aos conceitos de um filtro de partículas, explorando a teoria e descrevendo resumidamente as etapas necessárias a fusão dos dados do sensor. Vale notar que, salvo a presença de uma citação explícita, a teoria apresentada na Seção 2.3, dedicada aos conceitos relacionados a um filtro de partículas, foi embasada na explicação fornecida em (THRUN, BURGARD, & FOX, 2006).

2.2. Sensores

Os sensores utilizados na determinação do estado do VANT foram a Unidade de Medida Inercial (IMU – *Inertial Measurement Unit*) e o receptor de Sistema de Posicionamento Global (GPS – *Global Positioning System*). Individualmente, ambos são capazes de produzir dados relevantes a obtenção do estado da aeronave, entretanto o uso de apenas um dos sensores não produz resultados satisfatórios devido as suas limitações e particularidades.

2.2.1. IMU

A IMU é um dispositivo que mede a posição, velocidade e aceleração de um veículo por meio do uso de acelerômetros e giroscópios. IMUs possuem uma alta taxa de atualização e são capazes de operar independentemente de sistemas externos. Segundo (SICILIANO & KHATIB, 2008, p. 484), esses dispositivos são sensíveis a erros nas medidas dos acelerômetros e giroscópios. Desalinhamentos nos giroscópios podem levar a estimativas incorretas da orientação do veículo em relação a gravidade resultando no cancelamento parcial do vetor da gravidade. Como não é possível eliminar completamente o vetor de gravidade e os erros acumulam ao longo do tempo, a distância entre a posição real e a

posição medida pelo sistema cresce indefinidamente. Esse problema é considerado inerente ao funcionamento desse dispositivo devido as suas limitações.

2.2.2. Receptor de GPS

O receptor de GPS é um sensor capaz de fornecer uma referência absoluta ao sistema já que ele é capaz de estimar a localização de um objeto em coordenadas absolutas tridimensionais. Isso significa que esse sensor é capaz de prevenir o acúmulo de erros ao longo do tempo que seria criado pela IMU, porém, de forma geral, suas medidas não possuem elevada precisão e apresentam uma taxa de atualização significativamente menor do que a de uma IMU. Sendo assim, o seu uso principal no sistema é a capacidade de fornecer uma referência absoluta que limita o acúmulo de erros por meio do uso de um filtro. No caso deste projeto, o filtro escolhido é um Filtro de Partículas.

2.3. O Filtro de Partículas

De acordo com (ARULAMPALAM, MASKELL, GORDON, & CLAPP, 2002, p. 4), o filtro de partículas é uma técnica para implementação de um filtro bayesiano recursivo, cuja base para a maioria dos filtros de partículas é dada pelo algoritmo SIS (*Sequential Importance Sampling*). Outras variações, como *Sampling Importance Resampling* (SIR), *Auxiliary Sampling Importance Resampling* (ASIR) e *Regularized Particle Filter* (RPF) existem, mas normalmente são casos especiais derivados a partir do SIS.

(THRUN, BURGARD, & FOX, 2006, p. 96) explicam que um filtro de partículas é uma implementação não paramétrica do filtro de Bayes no qual a probabilidade *a posteriori* é aproximadamente representada por um número finito de partículas. O ponto principal desse filtro é representar *a posteriori bel*(x_t) por um conjunto de estados aleatórios retirados dessa *posteriori*. Ou seja, a ideia de criar uma representação paramétrica é descartada em favor de representar a distribuição por um conjunto de amostras retiradas dessa distribuição. Essa representação é aproximada, entretanto é não paramétrica e, portanto, pode representar uma gama muito maior de distribuições quando comparadas a outras representações. De forma

geral, podemos definir as vantagens e desvantagens do filtro conforme apresentado na Tabela 1.

Tabela 1 – Filtro de Partículas: Vantagens e Desvantagens

Vantagens	Desvantagens
<ul style="list-style-type: none"> • Altamente paralelizável. • Precisão tende a crescer com a quantidade de processamento dedicado ao filtro. • Não paramétrico. Permite grande flexibilidade nos tipos de distribuições que o filtro é capaz de representar. • Extremamente flexível quanto aos modelos de medida e movimento que o filtro é capaz de suportar. • Independente do número de dimensões apresentados pelo sistema, ou seja, é capaz de modelar sistemas que possuem elevado número de dimensões. Entretanto, um maior número de dimensões costuma implicar em um maior custo computacional dependendo dos modelos de observação e movimento utilizados. 	<ul style="list-style-type: none"> • Tende a ser computacionalmente caro. • Filtro requer mais processamento quanto maior o número de subestados contido em cada partícula. • Não existe relação direta entre a quantidade de partículas e a precisão obtida. • Não determinístico. Pode ser desvantajoso em situações que se requer uma solução imediata. • Dificuldade na medida de performance. • Não oferece garantia de confiança nos resultados.

É interessante ressaltar a relação entre o ponto positivo do filtro de ser capaz de trabalhar com sistemas modelando elevados números de dimensões a custo de um

maior requerimento de poder de processamento. O número de dimensões que o sistema trabalha tenta a ter um impacto considerável no custo computacional do filtro.

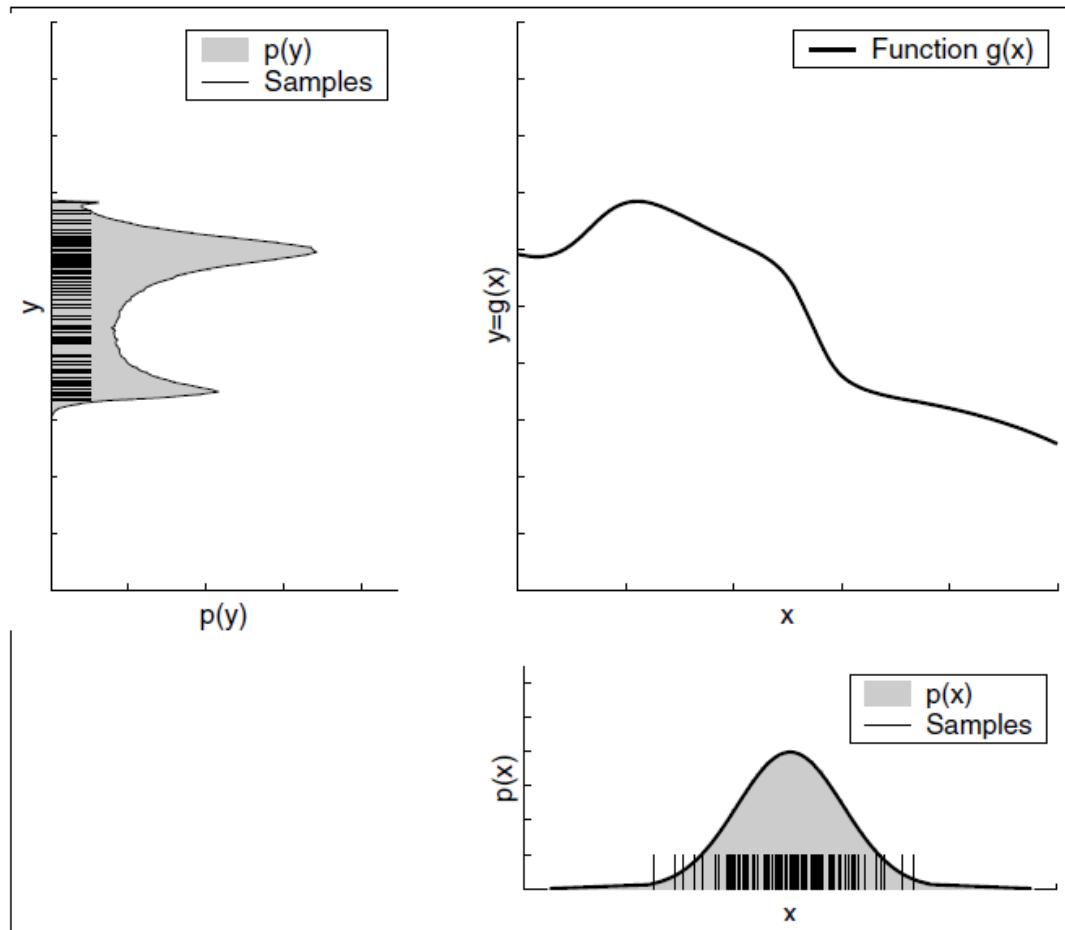
2.3.1. Descrição e Características Gerais

Em um filtro de partículas, as amostras de uma distribuição *a posteriori* são chamadas partículas e são representadas pela Equação (1).

$$X_t := x_t^{[1]}, x_t^{[2]}, \dots, x_t^{[M]} \quad (1)$$

Cada partícula $x_t^{[m]}$ ($1 \leq m \leq M$) é uma instanciação concreta de um estado no tempo t . Ou seja, a partícula é uma hipótese do que o estado real pode ser no tempo t . Vale notar que M representa o número de partículas no conjunto M (normalmente esse valor é um número elevado). Dado que o conjunto de partículas X_t é uma aproximação da *posteriori* $bel(x_t)$, a probabilidade de cada hipótese x_t pertencer ao conjunto X_t é proporcional a *posteriori* $bel(x_t)$ e consequentemente quanto mais densamente populada for a sub-região do espaço de estados, maiores serão a probabilidade do estado verdadeiro estar presente nessa região. Essa característica pode ser observada na Figura 1. Nota-se que áreas de maior probabilidade em ambas distribuições são representadas por uma concentração maior de partículas. Como a construção da distribuição *a posteriori* $bel(x_t)$ é feita recursivamente a partir da distribuição $bel(x_{t-1})$ e dado que a distribuição é representada por um conjunto de partículas, dá-se que o filtro constrói o conjunto X_t recursivamente a partir do conjunto X_{t-1} .

Figura 1 - Representação de uma Distribuição por meio de Partículas



Fonte: (THRUN, BURGARD, & FOX, 2006, p. 97)

De forma geral, o algoritmo de um filtro de partículas pode ser descrito pelas seguintes etapas:

1. Inicialização

- a) O filtro deve receber o conjunto de partículas X_{t-1} , a variável de controle u_t e a leitura, normalmente dos sensores, z_t .
- b) O conjunto de partículas X_{t-1} consiste num conjunto de M amostras do estado estimado pelo filtro na iteração $t-1$.
- c) A variável de controle u_t é determinada segundo o modelo adotado pelo sistema.

d) A variável z_t depende do formato de saída dos sensores utilizados. Caso o filtro seja incapaz de trabalhar com os dados no formato original, pode-se realizar um processo de conversão dos dados para uma estrutura mais adequada ao filtro.

2. Estado Esperado

- a) Construção da Distribuição *a Posteriori* Temporária $\overline{bel(x_t)}$
- b) A partícula $x_t^{[m]}$ é construída a partir da partícula $x_{t-1}^{[m]}$ e do controle u_t . Essa etapa é iterada M vezes e representa a transição do estado X_t para o estado X_{t-1} .
- c) Essa distribuição representa qual seria o estado esperado pelo filtro no tempo t. Ela é apenas uma aproximação da distribuição $bel(x_t)$ que representa de fato o estado do sistema no tempo t.

3. Amostragem por Importância

- a) Construção da Distribuição *a Posteriori* $bel(x_t)$.
- b) Calcula-se o peso $w_t^{[m]}$ de cada partícula baseado na medida z_t . Ou seja, o peso representa a probabilidade da medida z_t ser verdadeira dado o estado representado pela partícula $x_t^{[m]}$.
- c) Este novo conjunto de partículas e seus respectivos pesos representam aproximadamente a *posteriori* $bel(x_t)$.

4. Reamostragem

- a) Construção do Conjunto de Partículas X_t .
- b) Força o conjunto de partículas X_t a se aproximar da distribuição *a posteriori* $bel(x_t)$
- c) M novas partículas são extraídas do conjunto temporário criado na etapa anterior X_{t-1} segundo o seu peso. Ou seja, quanto maior o peso de uma partícula, maior a probabilidade de ela pertencer ao conjunto X_t . É importante notar que apesar da abordagem padrão ser extrair M novas partículas, é possível construir um filtro que altera o número de partículas utilizadas iteração, normalmente utiliza-se o grau de certeza que o filtro apresenta na estimativa obtida como métrica para alterar o número de partículas do conjunto.

d) O conjunto X_t normalmente contém várias partículas duplicadas dado que esse conjunto costuma possuir o mesmo número de partículas que o conjunto X_t e que partículas com um peso elevado tendem a ser selecionadas mais de uma vez.

e) Partículas com peso pequeno normalmente são eliminadas nessa etapa. Essa característica é importante dado que esse peso representa a probabilidade de dada partícula representar o estado verdadeiro.

2.3.2. Propriedades e Possíveis Problemas do Filtro de Partículas

- **Ausência de uma estimativa contínua**

Dado que o filtro representa a distribuição por meio de um conjunto de partículas discretas, ele não é imediatamente compatível com aplicações que necessitem de uma estimativa contínua da função de densidade. Todavia, existem abordagens capazes de realizar uma extração da função de densidade a partir de um conjunto de amostras, como por exemplo, o processo de estimativa de densidade por Kernel.

- **Variância inerente ao processo de amostragem**

As características de uma densidade de probabilidade são levemente alteradas sempre que um número finito de amostras é extraído. Ou seja, o processo de amostragem do filtro gera um certo nível de erro inerente ao filtro de partículas. Entretanto, esse efeito se reduz conforme aumenta-se o número de amostras.

- **Amostragem polarizada**

Dado que é utilizado um número finito de amostras durante a execução do filtro, tem-se um efeito de *bias* na distribuição *a posteriori*. Esse efeito diminui quanto maior o número de amostras utilizadas.

- **Depleção de partículas em dada região**

Devido à natureza não determinística do filtro, pode ocorrer de não existirem partículas em uma região correta do espaço de estados. Na prática, entretanto, essa situação ocorre apenas para casos em que um número reduzido de partículas é utilizado, seja em número absoluto de partículas ou em número de partículas relativo ao espaço de estado que

está sendo mapeado. Uma abordagem prática para reduzir o efeito desse problema é gerar aleatoriamente algumas partículas em cada etapa de reamostragem. Idealmente, essas partículas podem ser geradas utilizando-se de informações disponíveis sobre o estado atual do sistema.

2.3.3. Amostragem por Importância e Reamostragem

As etapas de amostragem por importância e reamostragem são fundamentais ao mecanismo de operação do filtro de partículas. É possível criar um filtro de partículas que não executa a etapa de reamostragem, representando a distribuição *a posteriori* do estado apenas com o uso de amostras avaliadas conforme a sua probabilidade de representarem estados válidos, ou seja, os pesos das partículas são atualizados a cada etapa sem extrair uma nova amostragem do conjunto de partículas original. Entretanto esse filtro tende a apresentar resultados significativamente inferiores a um filtro que realiza a etapa de reamostragem dado que várias das partículas ocupariam regiões de probabilidade muito baixa. Isso implica que esse filtro necessitaria de muito mais partículas para representar o estado do sistema quando comparado a um filtro que executa a reamostragem.

A etapa de reamostragem tem a função de forçar o conjunto de partículas a se aproximar da distribuição *a posteriori* $bel(x_t)$ por meio de uma abordagem similar à abordagem empregada nos algoritmos genéticos. Segundo (THRUN, BURGARD, & FOX, 2006, p. 100), a reamostragem é uma implementação probabilística do processo Darwiniano de sobrevivência do mais apto, processo no qual as partículas continuam a existir ou desaparecem conforme o seu peso. Apesar de essencial para o mecanismo de operação do filtro, o processo de reamostragem também causa consequências negativas. O fato de as partículas sobreviverem ou desaparecerem conforme o seu peso pode levar a perda de diversidade das partículas (propriedade descrita na Seção 2.3.2). Outra consequência indesejável que o processo de reamostragem pode causar é o aumento da variância do conjunto de partículas devido ao processo de amostragem (propriedade descrita na Seção). Algumas estratégias podem ser empregadas a fim de reduzir ou, em alguns casos, evitar essas consequências como por exemplo o uso de um algoritmo de reamostragem com baixa variância. De forma geral, deve-se evitar realizar reamostragens desnecessariamente, por

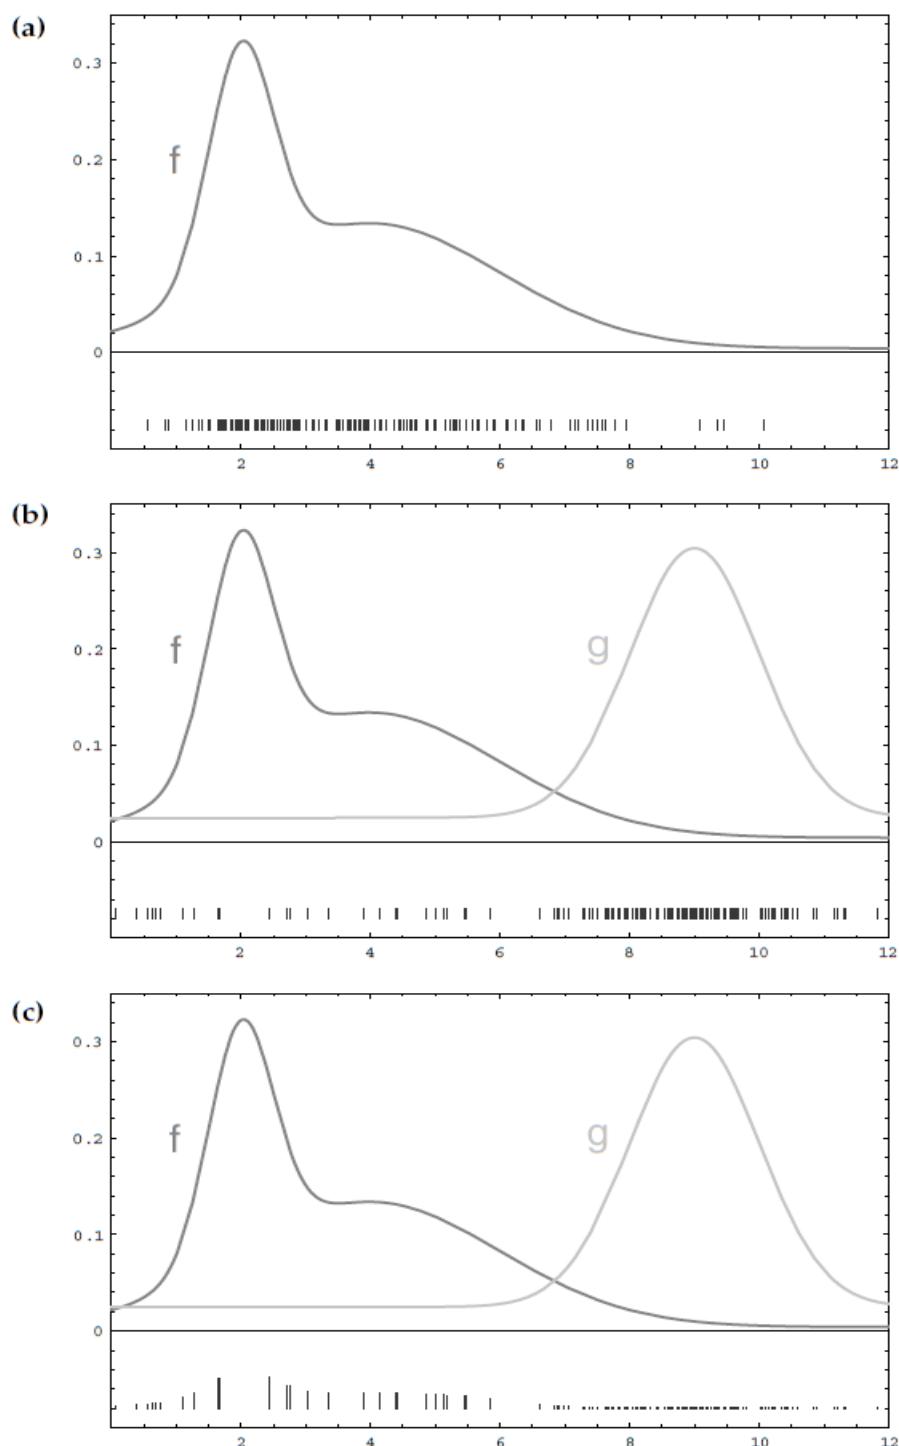
exemplo quando é conhecido que o estado não mudou. Além disso, utilizar um algoritmo de reamostragem eficiente e que apresenta baixa variância se mostra benéfico nesse contexto.

Ao contrário da etapa reamostragem, a etapa de amostragem por importância normalmente é obrigatória. Segundo (THRUN, BURGARD, & FOX, 2006, p. 100), esse processo pode ser representado pela Equação (2). Tem-se que I é a função indicadora com valor igual a 1 se o seu argumento for verdadeiro e 0 caso contrário. A função de densidade $f(x)$ representa a distribuição conhecida enquanto a função de densidade $g(x)$ representa a distribuição alvo.

$$\begin{aligned}
 E_f[I(x \in A)] &= \int f(x)I(x \in A)dx \\
 &= \int \frac{f(x)}{g(x)} g(x)I(x \in A)dx \\
 &= \int w(x) g(x)I(x \in A)dx \\
 &= E_g[w(x)I(x \in A)]
 \end{aligned} \tag{2}$$

O termo $w(x) = f(x)/g(x)$ é o fator de importância que representa a diferença entre $f(x)$ e $g(x)$. A Figura 2 ilustra esse processo. Em (a), apresenta-se a distribuição $f(x)$ e o conjunto de partículas que representaria essa distribuição, nota-se que esse conjunto não é conhecido. De (b) para (c), pode-se observar a relação entre $g(x)$ e $f(x)$. Apesar de apenas o conjunto de partículas que representa $g(x)$ ser conhecido, pode-se aproximar um conjunto de partículas capaz de representar $f(x)$ por meio do cálculo do peso de cada partícula pertencente ao conjunto que representa $g(x)$. A partir desse ponto, a etapa de reamostragem transforma o conjunto de partículas de $g(x)$ no novo conjunto que representa $f(x)$ conforme o peso de cada partículas.

Figura 2 - Processo de Amostragem Por Importância



Fonte: (THRUN, BURGARD, & FOX, 2006, p. 101)

2.3.4. O Filtro de Partículas no Contexto de Localização

Um exemplo básico do algoritmo de um filtro de partículas é apresentado no Algoritmo 1. Pode-se observar as etapas de inicialização (linha 2), obtenção do estado esperado e a etapa de amostragem por importância (linhas 3 a 7) e a etapa de reamostragem (linhas 8 a 11).

Algoritmo 1 - Filtro de Partícula Básico

```
1: Algorithm Particle_filter( $\mathcal{X}_{t-1}, u_t, z_t$ ):
2:    $\bar{\mathcal{X}}_t = \mathcal{X}_t = \emptyset$ 
3:   for  $m = 1$  to  $M$  do
4:     sample  $x_t^{[m]} \sim p(x_t | u_t, x_{t-1}^{[m]})$ 
5:      $w_t^{[m]} = p(z_t | x_t^{[m]})$ 
6:      $\bar{\mathcal{X}}_t = \bar{\mathcal{X}}_t + \langle x_t^{[m]}, w_t^{[m]} \rangle$ 
7:   endfor
8:   for  $m = 1$  to  $M$  do
9:     draw  $i$  with probability  $\propto w_t^{[i]}$ 
10:    add  $x_t^{[i]}$  to  $\mathcal{X}_t$ 
11:   endfor
12:   return  $\mathcal{X}_t$ 
```

Fonte: (*THRUN, BURGARD, & FOX, 2006, p. 98*)

Quando aplicado ao contexto de localização, um filtro sensorial baseado na estratégia do filtro de partículas pode ser representado pelo algoritmo apresentado no Algoritmo 2. Pode-se perceber uma das grandes vantagens do filtro de partículas. Ele é relativamente independente do sistema ao qual ele é aplicado. De forma geral, para alterar o sistema a que o filtro é aplicado, basta mudar os modelos de movimento e de medida.

Algoritmo 2 – Algoritmo Monte Carlo Localization (MCL)

```
1:   Algorithm MCL( $\mathcal{X}_{t-1}, u_t, z_t, m$ ):
2:      $\bar{\mathcal{X}}_t = \mathcal{X}_t = \emptyset$ 
3:     for  $m = 1$  to  $M$  do
4:        $x_t^{[m]} = \text{sample\_motion\_model}(u_t, x_{t-1}^{[m]})$ 
5:        $w_t^{[m]} = \text{measurement\_model}(z_t, x_t^{[m]}, m)$ 
6:        $\bar{\mathcal{X}}_t = \bar{\mathcal{X}}_t + \langle x_t^{[m]}, w_t^{[m]} \rangle$ 
7:     endfor
8:     for  $m = 1$  to  $M$  do
9:       draw  $i$  with probability  $\propto w_t^{[i]}$ 
10:      add  $x_t^{[i]}$  to  $\mathcal{X}_t$ 
11:    endfor
12:    return  $\mathcal{X}_t$ 
```

Fonte: (*THRUN, BURGARD, & FOX, 2006, p. 252*)

Os exemplos apresentados anteriormente no Algoritmo 1 e no Algoritmo 2 são exemplos da versão básica do filtro de partículas. Existem diferentes abordagens que alteram o algoritmo base a fim de neutralizar efeitos indesejados que se manifestam decorrente do uso do filtro básico, como por exemplo as propriedades citadas na Seção 2.3.2, ou para obter melhores resultados.

2.4. Considerações Finais

A familiarização com diversos conceitos foi necessária para a realização deste trabalho, a implementação do filtro requer conhecimentos tanto da área de estatística como da área de aeronáutica. Esses conceitos foram abordados brevemente neste capítulo e servem de base para o desenvolvimento do trabalho que é descrito no Capítulo 3.

CAPÍTULO 3: DESENVOLVIMENTO DO TRABALHO

3.1. Considerações Iniciais

Este capítulo apresenta o trabalho desenvolvido e discute etapas executadas ao longo do projeto em detalhes. Dentre as atividades realizadas, destacam-se a adaptação do modelo de naveabilidade, construção do filtro e a realização de simulações. A Seção 3.2 discute o contexto geral do projeto de forma a providenciar uma descrição sucinta das atividades realizadas. A Seção 3.3 discute as atividades realizadas durante o projeto em maiores detalhes. Na Seção 3.4 são apresentados tanto os resultados obtidos com a simulações quanto uma análise comparativa entre eles. A Seção 3.5 trata das dificuldades e limitações do projeto. Finalmente, a Seção 3.6 discute as considerações finais pertinentes ao Capítulo 3.

3.2. Contexto do Projeto

O projeto desenvolvido a fim de analisar a viabilidade da aplicação de um filtro de partículas como módulo responsável pela fusão dos dados sensoriais num VANT está dentro do contexto dos projetos do Laboratório de Sistemas Embarcados Críticos. Serão analisados 3 aspectos principais do desenvolvimento do projeto, sendo eles o modelo de naveabilidade utilizado, o conjunto de dados que foi gerado para realização das simulações e o planejamento e desenvolvimento do filtro.

Criou-se um modelo de naveabilidade capaz de utilizar os dados disponíveis para simular uma rota de um VANT, tendo a sua disposição as medidas de uma IMU contendo acelerômetros, giroscópios e barômetros. A modelagem do sistema de naveabilidade utilizado neste projeto foi baseada no sistema de naveabilidade apresentado em (SILVA, WILSON, & BRANCO, 2015).

As simulações de execução do filtro foram feitas utilizando-se de um conjunto de dados providenciado pelo Laboratório de Sistemas Embarcados Críticos. Para fins de comparação e validação, uma versão sem ruído e uma versão com ruído foram providenciadas.

Quanto ao desenvolvimento do filtro, modelou-se as etapas de predição e atualização a partir do modelo de navegabilidade. Incorporou-se os dados dos acelerômetros e giroscópios na etapa de predição, efetivamente utilizando os dados desses sensores como leituras indiretas do comando de controle que a aeronave recebeu. Já na etapa de atualização, utilizou-se os dados do receptor de GPS e do barômetro para cálculo dos pesos de cada partícula. Essa abordagem adotada caracteriza o sistema como um sistema de navegação inercial auxiliado por GPS. Como medida de avaliação, analisou-se os valores *RMS* (*Root Mean Square*) das distâncias envolvidas, ou seja, calculou-se a raiz quadrada da média aritmética dos quadrados dos valores de distâncias obtidos durante cada iteração da execução do filtro.

3.3. Descrição das Atividades Realizadas

As atividades realizadas consistiram de criar um filtro de partículas baseado no modelo de navegabilidade desenvolvido previamente e posterior simulação e análise do comportamento do filtro. O projeto foi desenvolvido utilizando-se da ferramenta MATLAB versão R2015a.

3.3.1. Modelo de Navegabilidade

O modelo de navegabilidade foi baseado no modelo descrito em (SILVA, WILSON, & BRANCO, 2015, p. 3). Ele utiliza as equações padrões para mecanização inercial, com os valores de posição e de velocidade dentro da referência de navegação e uma representação da atitude da aeronave por meio de quaternions, conforme apresentado no conjunto de Equações (3).

$$\begin{aligned} p &= [p_n, p_e, p_d]^T \\ v &= [v_n, v_e, v_d]^T \\ q &= [q_1, q_2, q_3, q_4]^T \end{aligned} \tag{3}$$

A referência de navegação é uma referência tangencial à Terra no nível local e tangente à gravidade. As equações de mecanização inercial que compõem o modelo de navegabilidade são apresentadas no conjunto de Equações (4).

$$\begin{aligned}\dot{p} &= v \\ \dot{v} &= C_b^n \tilde{a} + g^n \\ \dot{q} &= \frac{1}{2} \Omega_{\tilde{w}} q\end{aligned}\tag{4}$$

Tem-se que $\Omega_{\tilde{w}}$ é a forma antissimétrica de \tilde{w} que por sua vez representa a angulação do corpo com relação a referência de navegação. g^n é o vetor gravidade na referência de navegação e \tilde{a} é o vetor de força específica medido pelos acelerômetros. C_b^n é uma matriz de cossenos diretores utilizada na transformação de vetores da referência do corpo para a referência de navegação. C_b^n é dado pela Equação (5), enquanto $\Omega_{\tilde{w}}$ é dado pela Equação (6).

$$C_b^n = \begin{pmatrix} q_1^2 + q_2^2 - q_3^2 - q_4^2 & 2(q_2 q_3 - q_1 q_4) & 2(q_2 q_4 + q_1 q_3) \\ 2(q_2 q_3 + q_1 q_4) & q_1^2 - q_2^2 + q_3^2 - q_4^2 & 2(q_3 q_4 - q_1 q_2) \\ 2(q_2 q_4 - q_1 q_3) & 2(q_3 q_4 + q_1 q_2) & q_1^2 - q_2^2 - q_3^2 + q_4^2 \end{pmatrix} \tag{5}$$

$$\Omega_{\tilde{w}} = \begin{pmatrix} 0 & \tilde{w}_p & \tilde{w}_q & \tilde{w}_r \\ -\tilde{w}_p & 0 & -\tilde{w}_r & \tilde{w}_q \\ -\tilde{w}_q & \tilde{w}_r & 0 & -\tilde{w}_p \\ -\tilde{w}_r & -\tilde{w}_q & \tilde{w}_p & 0 \end{pmatrix} \tag{6}$$

No modelo adotado, os dados do barômetro são utilizados para o cálculo da altura referente à altura de inicialização conforme as Equações (7) e (8). A Equação (7) é utilizada na etapa de inicialização para obtenção dos parâmetros iniciais de referência enquanto a Equação (8) é utilizada na etapa de amostragem por importância e faz parte do modelo utilizado para o cálculo do peso de cada partícula.

$$\rho_{h_0} = \rho_0 \left(1 - \frac{Lh_0}{T_0} \right)^{\frac{RL}{gM}} \quad (7)$$

$$\tilde{h} = \frac{T_0}{L} \left(1 - \left(\frac{\tilde{\rho}}{\rho_{h_0}} \right)^{\frac{RL}{gM}} \right) \quad (8)$$

Nas Equações (7) e (8), L, g, M, R, T_0 são as constantes atmosféricas padrão enquanto ρ_0 e h_0 representam a pressão atmosférica inicial e a altura inicial, respectivamente.

3.3.2. Implementação do Filtro de Partículas

O sistema foi modelado como um sistema de navegação inercial auxiliado por GPS, ou seja, o filtro de partículas desenvolvido pode ser subdividido em duas grandes etapas que se repetem a cada iteração: a etapa de predição e a etapa de atualização. Cada etapa por sua vez pode ser subdividida em diferentes atividades.

A etapa de predição é caracterizada pela atividade de movimentação e é realizada em todas as iterações do filtro. Nessa etapa, os dados dos acelerômetros e giroscópios são utilizados como o vetor de controle para alteração do conjunto de partículas conforme as equações de mecanização iniciais. O código que executa as operações das equações iniciais foi fornecido por Laboratório de Sistemas Embarcados Críticos. Ele recebe como entrada a leitura das medidas geradas pelos acelerômetros e giroscópios, o intervalo de tempo decorrido desde a última atualização dos sensores, o vetor gravidade e um vetor de 10 posições o qual representa o estado do sistema no final da iteração anterior. Este vetor contém as informações consolidadas de posição, velocidade e os quaternions representados pelo conjunto de Equações (3). Vale notar que devido ao cálculo da velocidade, é necessário fornecer também o vetor de quaternions do início da iteração anterior. O resultado da etapa

predição é um novo vetor de 10 posições consolidando as informações de posição e velocidade, bem como os quaternions que representam o estado da aeronave. Dado que o filtro de partículas utiliza uma partícula para representar cada um dos estados estimados, esta etapa é realizada tantas vezes em uma iteração quanto o número de partículas definidas para o filtro. Cada partícula possui o seu próprio vetor para representar um estado completo com as informações de posição, velocidade e quaternions.

A etapa de atualização, consiste na amostragem por importância e na reamostragem. Na amostragem por importância é realizado o cálculo do peso de cada partícula. Na reamostragem, um novo conjunto de partículas é gerado conforme o peso de cada partícula do conjunto original. Ao contrário da etapa de predição, a qual é realizada em toda iteração, a etapa de atualização deve ser executada apenas quando certas condições forem satisfeitas. No caso do nosso sistema essas condições são dadas por:

- O receptor de GPS está ativo
- A posição indicada pelo receptor de GPS se alterou desde a última medida.

Essas condições foram impostas a fim de minimizar o impacto das consequências negativas da etapa de reamostragem, principalmente em casos nos quais o filtro não elevaria sua taxa de confiança quanto a posição real do VANT bem como para ganho de performance ao evitar gastar processamento com essa atividade a menos que necessário. Visto que o filtro já é computacionalmente caro, esse ganho é bem-vindo.

3.3.3. Amostragem por Importância

O processo de amostragem por importância é essencial ao filtro desenvolvido e uma das razões pelas quais filtros de partícula são considerados versáteis. Essa etapa requer apenas que seja modelada uma metodologia de como classificar cada partícula segundo sua probabilidade de ser uma estimativa correta. A modelagem utilizada foi a mesma modelagem utilizada pelos dados fornecidos pelo Laboratório de Sistemas Embarcados Críticos quanto aos sensores, ou seja, modelou-se os dados tanto do receptor de GPS como do barômetro como uma gaussiana independente em cada uma das dimensões aplicáveis. Conforme apresentado no conjunto de Equações (9), os dados do GPS foram modelados em 3 coordenadas espaciais com média igual ao resultado do receptor de GPS e desvio padrão

σ_{GPS} . Para o barômetro, a abordagem foi um pouco diferente, como os dados do barômetro são utilizados para cálculo da altura, a qual representa a média da gaussiana, derivou-se das simulações realizadas um desvio padrão $\sigma_{GPS_{height}}$ para a altura calculada a partir das informações de pressão do barômetro.

$$\begin{aligned}\sigma_{GPS_x} &= 2.5 \\ \sigma_{GPS_y} &= 2.5 \\ \sigma_{GPS_z} &= 4.0 \\ \sigma_{GPS_{height}} &= 0.8\end{aligned}\tag{9}$$

Adotou-se uma abordagem por meio do uso de uma distribuição normal multivariada na qual as 4 gaussianas mencionadas foram modeladas como variáveis independentes. Sendo assim, o peso de uma partícula qualquer é dado pela função de densidade de probabilidade (FDP) da distribuição normal multivariada utilizada no modelo, representada pela Equação (10). $p_t^{[m]}$ é um vetor coluna contendo as posições nos 3 eixos dado pelo GPS e a altura do ponto representado pela partícula em questão, ou seja, $p_t^{[m]} = [p_x, p_y, p_z, (p_z - p_{z_0})]^T$. Quanto a variável μ_i , esta contém os mesmos dados que $p_t^{[m]}$, contudo os valores são derivados dos sensores de GPS e pressão.

$$w_t^{[m]} = \frac{\exp\left(-\frac{1}{2}\left(p_t^{[m]} - \mu_t\right)^T \Sigma^{-1} \left(p_t^{[m]} - \mu_t\right)\right)}{\sqrt{(2\pi)^4 |\Sigma|}}\tag{10}$$

Σ^{-1} e $|\Sigma|$ representam o inverso da matriz de covariância e o determinante da matriz de covariância, respectivamente. Segundo (CHUONG, 2008, p. 4), uma distribuição normal multivariada com uma matriz de covariância diagonal $(\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2)$ é o mesmo que uma coleção de variáveis gaussianas aleatórias com média μ_i e variância σ_i^2 , respectivamente. Sendo assim, a matriz de covariância é dada pela Equação (11).

$$\Sigma = \begin{pmatrix} \sigma_{GPS_x}^2 & 0 & 0 & 0 \\ 0 & \sigma_{GPS_y}^2 & 0 & 0 \\ 0 & 0 & \sigma_{GPS_z}^2 & 0 \\ 0 & 0 & 0 & \sigma_{GPS_{height}}^2 \end{pmatrix} \quad (11)$$

3.3.4. Reamostragem

A etapa de reamostragem foi implementada baseando-se no algoritmo de reamostragem do tipo *Stochastic Universal Sampling (SUS)* sugerido no curso (THRUN, Artificial Intelligence for Robotics). Entretanto, conforme discutido na Seção 2.3.2, o processo de reamostragem pode acarretar em consequências indesejáveis para o bom funcionamento do filtro. Por esse motivo, o algoritmo foi modificado para que durante o processo de reamostragem, duas medidas corretivas fosse utilizadas.

A primeira medida se caracteriza por cerca de 10% das partículas serem alteradas de forma aleatória com o objetivo de prevenir ou amenizar os problemas de depleção de partículas e o “problema do robô sequestrado,” (problema que discute o cenário no qual o robô é retirado de sua posição atual e reposicionado sem receber informações dessa alteração). Apesar de a abordagem utilizada envolver aleatoriedade, informações determinísticas dos sensores e do conjunto de partículas são utilizados a fim de melhorar a precisão dessa abordagem. Dado que os dados do receptor de GPS fornecem uma posição absoluta da região em que a aeronave deveria estar, pode-se inferir que a região ao redor da medida indicada pelo GPS é uma região de alta probabilidade de o estado estar correto. Ou seja, 10% das partículas escolhidas pelo processo de reamostragem terão sua posição alterada para uma região próxima do indicado pelo GPS.

A segunda medida corretiva utilizada durante o processo de reamostragem é a inserção de uma pequena incerteza na posição e velocidade da partícula durante o processo de reamostragem. Dado que o filtro tem a tendência de escolher partículas com elevado peso múltiplas vezes, essa é uma abordagem que permite uma melhor cobertura do espaço amostral sem sacrificar a precisão do filtro quanto a sua posição. Esse processo é reforçado pelo princípio fundamental do filtro, partículas que se aproximarem do estado real com essa

alteração serão reforçadas por receberem um peso maior e partículas que se afastarem do estado real serão descartadas ao longo do tempo.

3.3.5. Outras Etapas Implementadas no Filtro

Além das etapas principais do filtro mencionadas anteriormente, algumas outras operações são executadas, especificamente a etapa de inicialização e a etapa de extração do estado estimado do sistema a partir das amostras obtidas. Durante a etapa de inicialização, constrói-se o conjunto inicial de partículas e calcula-se os parâmetros iniciais dos sensores, como por exemplo o cálculo por meio da Equação (7) da altura inicial de referência e pressão inicial de referência utilizado pelo barômetro.

A construção do conjunto inicial de partículas pode ser feita de forma aleatória, mas essa abordagem requer um número muito maior de partículas, pelo menos durante as etapas iniciais até que o filtro seja capaz de se estabilizar. A abordagem adotada utiliza algumas informações dos sensores ao assumir que são conhecidas com um certo grau de certeza tanto a orientação inicial quanto a posição inicial acusada pelo sensor de GPS. Ou seja, gera-se um conjunto de partículas mapeando a região inicial que se espera encontrar o estado verdadeiro a fim de melhorar as estimativas iniciais dado que normalmente elas são as mais imprecisas devido a necessidade de mapear um espaço muito maior que durante o resto da execução do filtro.

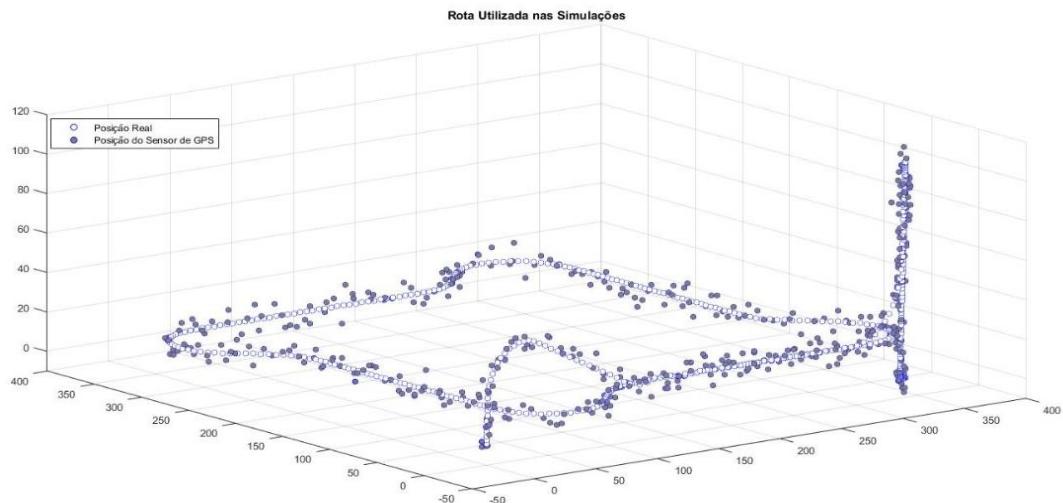
A etapa de extração do estado estimado do sistema a partir das amostras obtidas tem como objetivo produzir uma representação concreta do estado estimado. Pode-se adotar diferentes abordagens, como por exemplo, utilizar a partícula com o maior peso como o estado encontrado pelo filtro. No contexto do projeto, obteve-se uma estimativa mais precisa do estado verdadeiro ao realizar uma média ponderada segundo o peso de cada partículas. Dado que o estado é representado pela combinação dos vetores de posição, velocidade e quaternions conforme o conjunto de Equações (3), extrair a posição e velocidade é apenas uma questão de calcular uma média ponderada segundo os pesos para todas as partículas, mas como essa abordagem não pode ser utilizada para quaternions, utilizou-se a abordagem descrita em (MARKLEY, CHENG, CRASSIDIS, & OSHMAN) a fim de obter-se o quaternion esperado. Esse processo deve ser realizado sempre que o conjunto de partículas

sofrer qualquer alteração, considerando a possibilidade de pode-se pular essa etapa sem perdas ao funcionamento do filtro caso as informações da extração não sejam necessárias em uma dada iteração.

3.3.6. Simulações

Foram utilizados os dados fornecidos pelo Laboratório de Sistemas Embarcados Críticos para simular o comportamento do filtro numa rota predeterminada ilustrada pela Figura 3. Os pontos em branco e azul representam a posição verdadeira do sensor de GPS, ou seja, sem ruídos enquanto os pontos em preto representam as medidas do sensor de GPS quando com o ruído do dispositivo.

Figura 3 - Rota Utilizada durante as Simulações



Fonte: Autor

Para cada simulação, traçou-se a rota estimada pelo filtro e calculou-se o valor RMS da distância entre a posição estimada pelo filtro e a posição real do dispositivo. Para fins de comparação, calculou-se também o valor RMS de outras duas medidas de distância. O

primeiro é calculado a partir da distância entre a posição estimada pelo filtro e a posição medida pelo receptor de GPS, enquanto o segundo é calculado a partir da distância entre a posição medida pelo receptor GPS e a posição real do dispositivo. Ou seja, tem-se três medidas RMS da distância, sendo elas:

- Valor RMS da distância entre a posição estimada pelo filtro e a posição real do dispositivo (apresentado em verde nos Gráficos 1, 2 e 3)
- Valor RMS da distância entre a posição estimada pelo filtro e a posição medida pelo receptor GPS (apresentado em azul nos Gráficos 1, 2 e 3)
- Valor RMS da distância entre a posição medida pelo receptor GPS e a posição real do dispositivo (apresentado em vermelho nos Gráficos 1, 2 e 3)

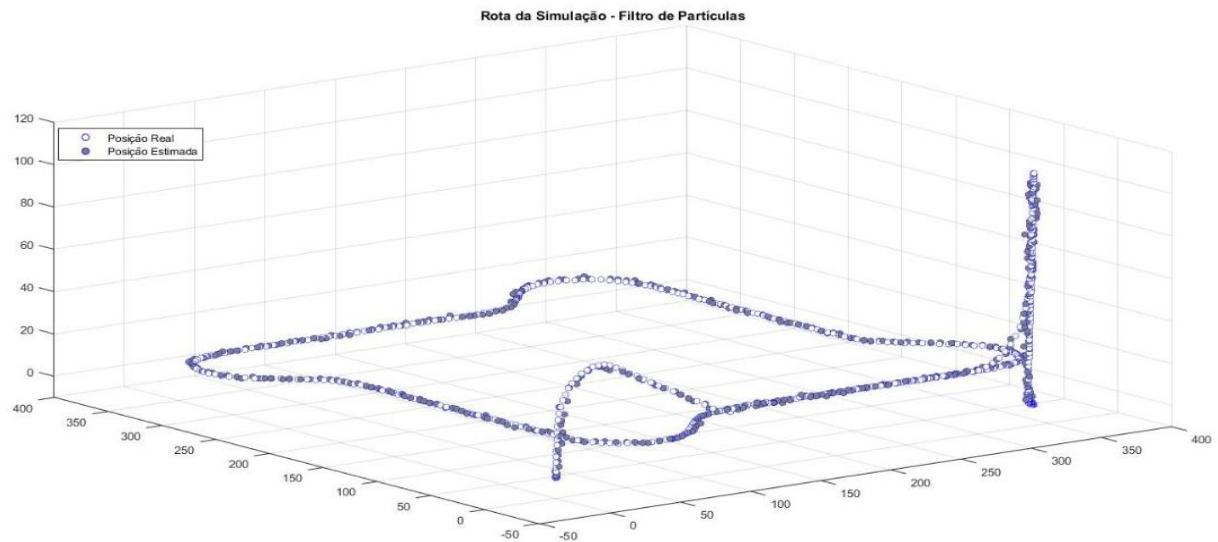
3.4. Resultados Obtidos

Foram realizadas simulações a fim de comparar os resultados do sistema utilizando o filtro implementado utilizando-se de todos os sensores contra apenas o uso da IMU. Além disso, analisou-se a precisão do filtro quando a etapa de reamostragem não é executada. Para cada uma das simulações, traçou-se a rota estimada pelo filtro e calculou-se o valor das distâncias RMS conforme especificado na Seção 3.3.5. Todas as simulações foram executadas utilizando-se de 200 partículas.

3.4.1. Filtro de Partículas

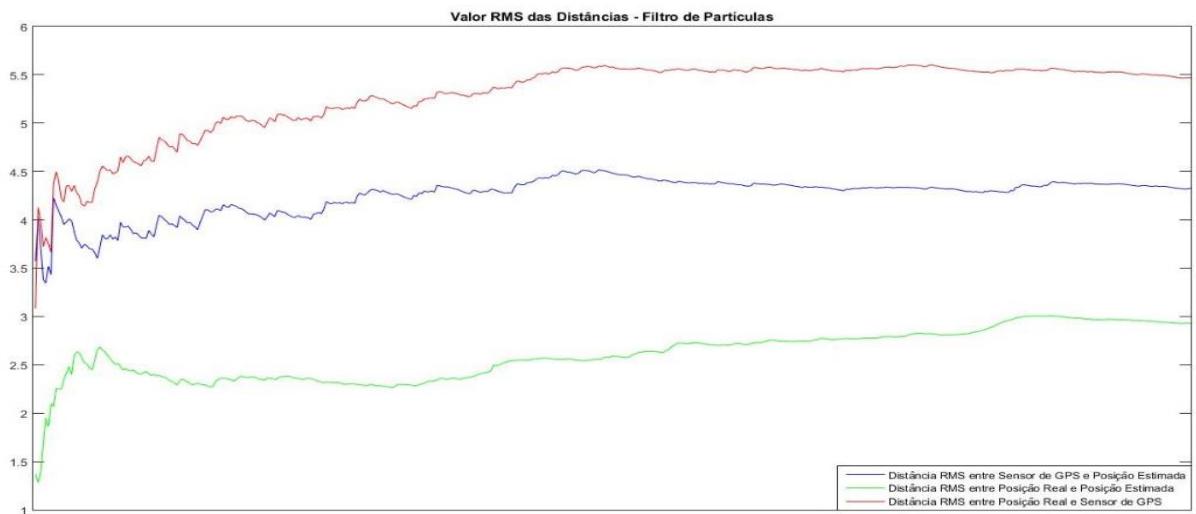
Para o filtro implementado, obteve-se a estimativa da rota percorrida apresentada na Figura 4. A rota estimada pelo filtro é representada pelos pontos escuros enquanto a rota da posição real do dispositivo de GPS é representada pelos pontos claros. A evolução do valor RMS da distância ao longo da execução da simulação é apresentado no Gráfico 1 conforme os critérios discutidos na Seção 3.3.5.

Figura 4 - Rota Estimada pelo Filtro de Partículas



Fonte: Autor

Gráfico 1 - RMS das distâncias ao longo da simulação do Filtro de Partículas

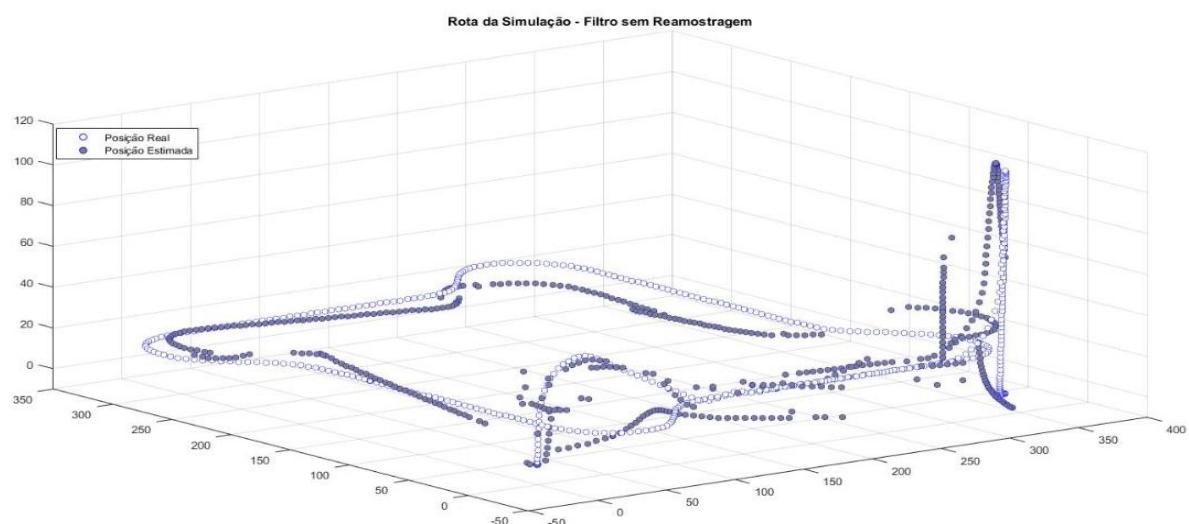


Fonte: Autor

3.4.2. Filtro de Partículas – Sem Reamostragem

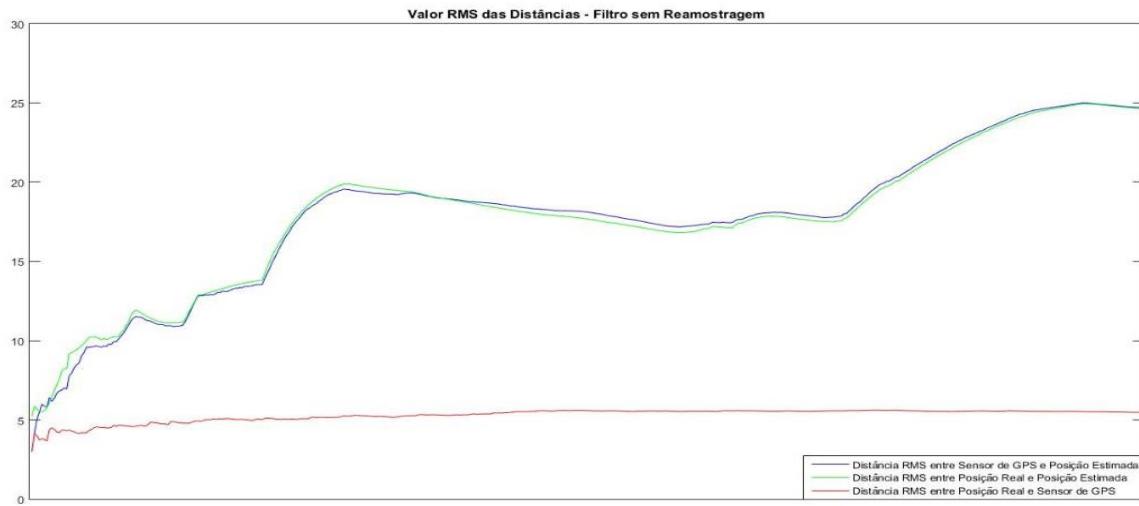
Para o filtro implementado sem o uso da etapa de reamostragem, obteve-se a estimativa da rota percorrida apresentada na Figura 5. A rota estimada pelo filtro é representada pelos pontos escuros enquanto a rota da posição real do dispositivo de GPS é representada pelos pontos claros. A evolução do valor RMS da distância ao longo da execução da simulação é apresentado no Gráfico 2 conforme os critérios discutidos na Seção 3.3.5.

Figura 5 - Rota Estimada pelo Filtro de Partículas - Sem Reamostragem



Fonte: Autor

Gráfico 2 - RMS das distâncias ao longo da simulação sem reamostragem

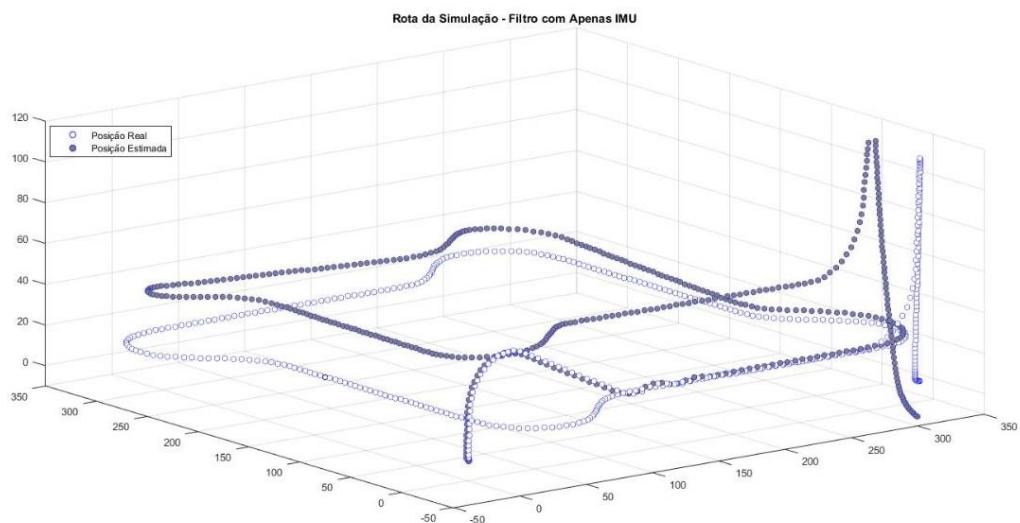


Fonte: Autor

3.4.3. Filtro de Partículas – IMU

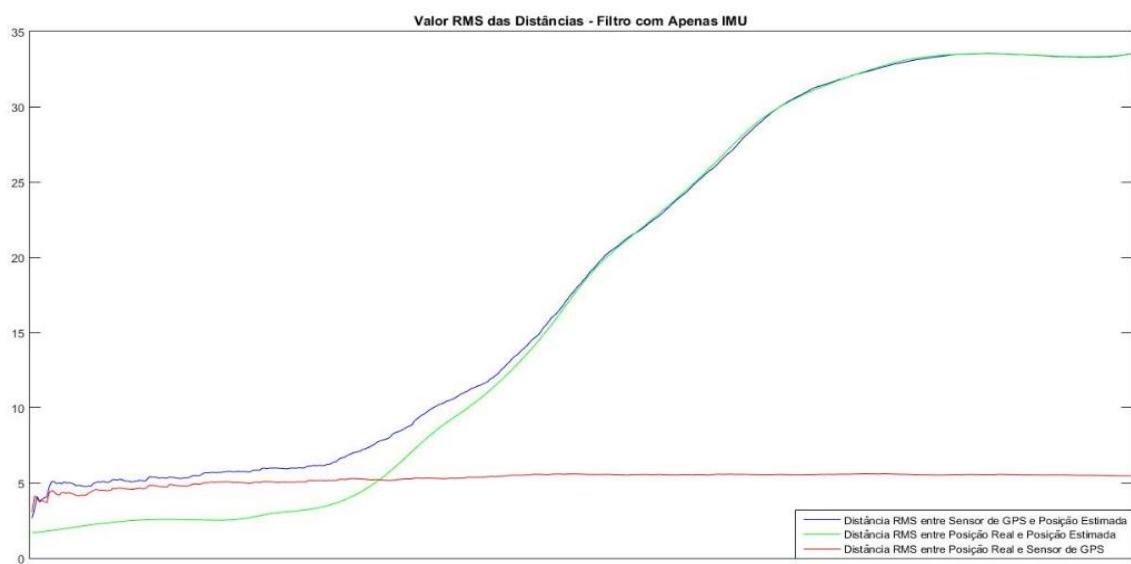
Para o filtro implementado com o uso apenas dos acelerômetros e giroscópios, obteve-se a estimativa da rota percorrida apresentada na Figura 6. A rota estimada pelo filtro é representada pelos pontos escuros enquanto a rota da posição real do dispositivo de GPS é representada pelos pontos claros. A evolução do valor RMS da distância ao longo da execução da simulação é apresentado no Gráfico 3 conforme os critérios discutidos na Seção 3.3.5.

Figura 6 - Rota Estimada pelo Filtro de Partículas usando apenas IMU



Fonte: Autor

Gráfico 3 - RMS das distâncias ao longo da simulação com apenas IMU



Fonte: Autor

3.4.4. Comparação Entre as Simulações

Ao comparar-se as rotas estimadas pelo filtro nas três simulações, temos que a rota apresentada na Figura 4 melhor aproxima o posicionamento real do dispositivo. Ou seja, o filtro obteve os melhores resultados ao executar tanto a etapa de amostragem por importância quanto a etapa de reamostragem. Conclui-se o mesmo ao comparar-se o Gráfico 1, Gráfico 2 e Gráfico 3. A precisão da estimativa de distância é maior quando o filtro executar tanto a etapa de amostragem por importância quanto a etapa de reamostragem.

Conforme previsto pela teoria apresentada no Capítulo 2, o uso exclusivo da IMU se mostra inferior a abordagem que faz uso da combinação dos dados sensoriais. O filtro utilizando apenas IMU foi capaz de estimar a posição razoavelmente, todavia o erro cresceu à medida que o tempo passa. Quanto ao filtro que não executa a etapa de reamostragem apesar de utilizar os dados de todos os sensores, tem-se que ele teve problemas ao estimar a posição apesar ter sido capaz de reduzir o erro da IMU até certo ponto. Outro fator agravante na simulação do filtro sem reamostragem, é que normalmente esse tipo de filtro requer um número muito elevado de partículas, porém foram utilizadas o mesmo número de partículas das outras duas simulações.

3.5. Dificuldades e Limitações

Uma das principais dificuldades encontradas durante a implementação do filtro se deve ao seu carácter não determinístico. A análise e comparação entre duas configurações similares do filtro é dificultada dado que execuções distintas apresentam resultados diferentes mesmo com os mesmos dados de entrada. Esse problema não é tão impactante quando as configurações apresentam resultados significativamente diferentes, porém em grande parte dos casos, as diferenças não eram grandes o suficiente.

Quanto ao filtro de partículas, esse se mostra limitado pelos fatores de poder computacional. Apesar da versatilidade do filtro, outras abordagens podem ser mais interessantes para aplicações nas quais o poder computacional disponível é reduzido. Essa limitação pode ser aliviada com o uso de paralelismo caso o dispositivo em questão tenha essa capacidade.

Em relação as dificuldades pessoais do autor, pode-se listar o elevado volume de informações relacionadas ao projeto e falta de familiaridade com diversos tópicos. As disciplinas de graduação auxiliaram nesse ponto de forma que alguns dos tópicos utilizados foram apresentadas durante o curso. Entretanto, diversos tópicos não abordados durante o curso, provavelmente por serem específicos das áreas relacionadas ao projeto, mostraram-se relevantes.

3.6. Considerações Finais

Neste capítulo foi apresentado as atividades desenvolvidas para o projeto do trabalho de conclusão do curso. Discutiu-se em detalhes os modelos utilizados, o desenvolvimento e implementação do filtro, bem como as simulações realizadas e os resultados obtidos.

No capítulo seguinte é apresentada uma análise a respeito do trabalho desenvolvido, seu relacionamento com o curso de graduação e os possíveis trabalhos futuros. O capítulo também apresentará uma discussão sobre o curso de graduação.

CAPÍTULO 4: CONCLUSÃO

4.1. Contribuições

O filtro de partículas é uma abordagem viável para resolução de problemas no contexto de fusão de dados sensoriais. Sua grande flexibilidade permite sua aplicação na maioria dos sistemas desde que seja possível criar um modelo estatístico do sistema utilizado. Os principais desafios encontrados ao escolher esse filtro, entretanto, encontram-se na minimização das suas características negativas, como por exemplo alto custo computacional.

O desenvolvimento deste projeto foi desafiador, mas recompensante para o autor. Cada problema encontrado durante o projeto foi uma oportunidade de identificar e corrigir áreas nas quais a concepção atual do projeto era falha. Esse processo normalmente envolveu a busca e utilização de novos conceitos, permitindo assim abordar uma quantidade de tópicos significativamente mais abrangente do que inicialmente estimado.

4.2. Trabalhos Futuros

Dos possíveis trabalhos futuros que podem decorrer desse projeto, se destacam:

- Paralelização do Filtro
 - Paralelizar a execução do filtro é uma excelente oportunidade de amenizar o impacto do elevado custo computacional do filtro dado a sua elevada compatibilidade com técnicas de paralelização.
- Analisar a viabilidade de executar o filtro com um número de partículas adaptável por meio da técnica de KLD-Sampling
 - KLD-Sampling é uma estratégia utilizada para alterar o número de partículas do filtro em tempo de execução baseado numa análise estatística do grau de certeza do filtro. Ou seja, quanto maior for o grau de certeza de que o estado estimado é correto, menos partículas serão utilizadas. Por outro lado, quanto

menor for o grau de certeza de que o estado estimado é correto, mais partículas serão utilizadas.

REFERÊNCIAS

- ARULAMPALAM, S., MASKELL, S., GORDON, N., & CLAPP, T. (2002). *A Tutorial on Particle Filters for Online Nonlinear/Non-Gaussian Bayesian Tracking.*
- CHUONG, B. (2008). *The Multivariate Gaussian Distribution.* Disponível em: <<http://cs229.stanford.edu/section/gaussians.pdf>>. Acesso em 31 de outubro de 2019.
- MARKLEY, F., CHENG, Y., CRASSIDIS, J., & OSHMAN, Y.. *Averaging Quaternions.* Disponível em: <http://www.acsu.buffalo.edu/~johnc/ave_quat07.pdf>. Acesso em 31 de outubro de 2019.
- SICILIANO, B., & KHATIB, O. (2008). *Springer Handbook of Robotics.*
- SILVA, N., WILSON, D., & BRANCO, K. (2015). *Performance Evaluation of the Extended Kalman Filter and Unscented Kalman Filter.*
- THRUN, S., Udacity - *Artificial Intelligence for Robotics.* Disponível em: <<https://classroom.udacity.com/courses/cs373>>. Acesso em 31 de outubro de 2019
- THRUN, S.. BURGARD, W., & FOX, D. (2006). *Probabilistic Robotics.*