

1

Introdução

Avanços significativos têm sido feitos no sentido de criar um robô capaz de realizar tarefas completamente autônomas. As tarefas básicas como planejamento de trajetórias, localização e navegação são bem compreendidas, e até um certo grau, foram resolvidas. Estes componentes são as ferramentas básicas para a resolução de tarefas de um nível superior, e permitir que o robô possa realizar alguma missão sem supervisão ou intervenção humana. Para alcançar qualquer nível útil de autonomia, mesmo meramente viajar sem ajuda de um ponto específico para outro, o robô precisa ter um retrato bastante completo do mundo, um bom mapa do meio ambiente. Este mapa, além de ser preciso, deve ser bastante completo englobando todos os lugares que o robô possa alcançar na sua exploração. Este problema de monitorar a posição de um robô e construir um mapa é conhecido como Localização e Mapeamento Simultâneo, ou SLAM.

O problema geral de SLAM tem sido objeto substancial de pesquisa para a comunidade robótica inclusive em áreas como sistemas de navegação de veículos tripulados e prospecção geofísica. Thrun [1] define a localização de robôs móveis como o problema de determinar a posição de um robô em relação a um determinado mapa do meio ambiente. No entanto, em muitas aplicações da robótica, não é possível dispor de um mapa, a priori, do meio ambiente. Em tais situações, o problema pode ser tratado através da construção de mapas locais do meio ambiente, enquanto o robô está executando uma missão e, posteriormente, determinar a posição do robô, combinando os mapas locais[3].

"SLAM tem sido um obstáculo para robôs autônomos. Os problemas de localização e mapeamento aparecem como dois desafios distintos mas, de fato, são intrinsecamente problemas entrelaçados."[4]. Para que um robô atualize o mapa corretamente, é necessário conhecer a localização do robô quando a observação do ambiente é feita. No entanto, para monitorar a localização do robô, é essencial ter um bom mapa com o qual comparar as observações. Resolver ambos problemas de forma incremental e simultânea significa que um pequeno erro em cada solução pode facilmente corromper todas as estimativas futuras.

Assim, a rápida acumulação de erros pequenos pode causar o fracasso de quase todos os métodos para resolver o problema de SLAM.

SLAM aborda o problema de um robô móvel autônomo que começa seu movimento em um local desconhecido, em um ambiente desconhecido e utilizando apenas observações relativas do meio ambiente, incrementalmente constroi um mapa deste ambiente, e simultaneamente usa este mapa para computar a localização absoluta do robô móvel[5][6]. Assim, a principal vantagem de SLAM, é que elimina a necessidade de infraestruturas artificiais ou um conhecimento topológico a priori do ambiente.

Para isso, o robô precisa interagir com o ambiente, que normalmente é um sistema dinâmico que apresenta inúmeras características. O robô móvel pode adquirir informações do ambiente usando seus sensores e também pode influenciar a percepção do seu ambiente através de seus atuadores.

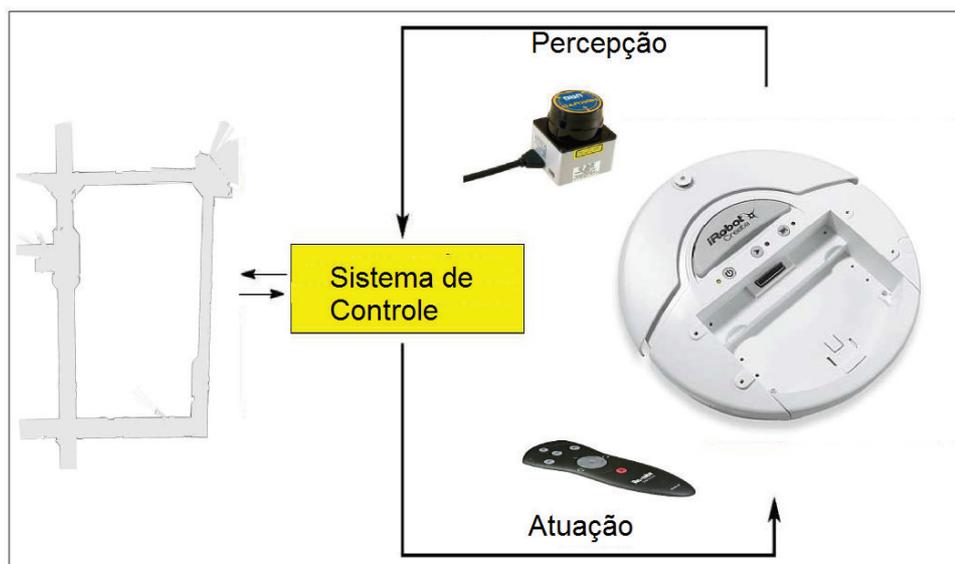


Figura 1.1: Interação do robô Móvel com o ambiente.

A maioria dos algoritmos utilizados para resolver o problema de SLAM precisam de sensores para capturar a percepção do ambiente, como sensores para capturar o deslocamento do robô móvel[7]. No entanto, os sensores são sensíveis ao ruído, e existem alguns objetos no ambiente que podem não ser detectados diretamente pelo sensor. Mas os sensores a laser, como Laser Range Finders (LRF) apresentam grandes vantagens, porque são capazes de localizar o robô móvel, mapear o ambiente e detectar obstáculos.

Para evitar a utilização de sensores que percebem o movimento das rodas do robô móvel (por exemplo os sensores de odometria), algoritmos de Correspondência de Varreduras têm sido amplamente utilizados nos últimos anos para realizar a localização do robô móvel[8]. Eles não assumem restrições geométricas nem representações do ambiente. Assim, é bem adaptado para a localização de um robô móvel com uma precisão elevada, tanto em ambientes estruturados e não estruturados [9].

Pelos motivos mencionados acima, este trabalho concentra-se no desenvolvimento de um método para resolver o problema de SLAM com um único sensor (LRF) de baixo custo que pode produzir uma aproximada representação do ambiente interno.

1.1

Motivação

- Uma solução para o problema de SLAM seria de valor inestimável para uma gama de aplicações em que a posição absoluta ou a informação exata de um mapa é inalcançável, incluindo, entre outros, exploração planetária autônoma, veículos autônomos submarinos, aéreos e de todo o terreno em tarefas como mineração e construção.
- Mapas poderiam ser feitos em, ambientes fechados, áreas que são perigosas ou inacessíveis aos seres humanos, tais como ambientes no fundo do mar ou estruturas instáveis.
- Uma solução para o problema de SLAM evitaria o uso de métodos alternativos de localização, como GPS. Seria assim possível a navegação de robôs em lugares onde o sinal GPS não esteja disponível, estações espaciais e outros planetas. Mesmo em locais onde esteja disponível um sistema GPS, a solução para o problema de SLAM seria inestimável devido à baixa precisão do GPS.
- O uso de sensores de odometria não é uma boa escolha devido ao fato das rodas do robô normalmente podem deslizar no chão. A localização por câmeras também não apresenta bons resultados em alguns ambientes naturais, devido à alta similaridade entre as imagens de vegetação, tornando difícil um confiável estabelecimento de pontos-chave.

1.2

Objetivos do Trabalho

Os objetivos principais do trabalho são:

- Realizar um Mapeamento e Localização Simultânea de Robôs Móveis em Ambientes Internos, utilizando um robô (iRobot Create) equipado com um único sensor 2D-LRF de baixo custo e de capacidade limitada (*URG – 04LX – UG01*).
- Propor uma variante do algoritmo DP-SLAM, modificando o modelo de movimento do robô móvel por um modelo de varredura do sensor LRF, para utilizar o algoritmo sem nenhuma informação de odometria.
- Trabalhar o problema de Mapeamento e Localização Simultânea com um único sensor e sem conhecer a modelagem do robô móvel.
- Desenvolver um algoritmo para obter o deslocamento do robô móvel utilizando as medições do sensor 2D-LRF de baixo custo (*URG – 04LX – UG01*), e otimizando o deslocamento mediante Algoritmos Genéticos .

1.3

Revisão Bibliográfica

1.3.1

SLAM

Uma forma de categorizar algoritmos de mapeamento é pelo tipo de mapa. Em geral, o mapa pode ser topológico ou métrico. Mapas métricos representam distâncias explícitas do meio ambiente. Estes mapas podem ser *2D*, geralmente uma projeção vertical, ou em *3D*, ou seja, um mapa volumétrico do ambiente. Além disso, as abordagens de SLAM podem ser classificadas pelo número de graus de liberdade da posição do robô móvel [10]. Uma representação estimada em *3D* contém coordenadas (x, y) e a rotação θ , enquanto uma representação estimada em *6D*, considera todos os graus de liberdade que o robô móvel pode ter, ou seja coordenadas (x, y, z) e os ângulos rolagem, guinada e arfagem.

1.3.1.1

Mapeamento Planar *2D*

Uma das técnicas para a abordagem de mapeamento planar métrico é usando métodos probabilísticos, onde o robô tem modelos de movimento probabilísticos e modelos de percepção da incerteza. Ao integrar estas duas

distribuições, por exemplo, através do filtro de Kalman, ou de partículas, é possível localizar o robô móvel[2]. O mapeamento é muitas vezes uma extensão deste problema de estimação. Além da posição do robô, pontos de referência do mapa são estimados. Circuitos fechados, ou seja, um segundo encontro de uma área previamente visitada do ambiente, têm um papel especial aqui. Uma vez detectado, existem algoritmos que permitem limitar o erro deformando a área já mapeada de tal forma que um modelo topologicamente consistente seja criado. No entanto, não há garantia para um modelo preciso.

Um número de abordagens tem sido proposto para tratar tanto o problema de SLAM e como também problemas de navegação mais simplificada, onde um mapa adicional ou informações de localização do robô móvel são disponibilizadas. Thrun [11] fez uma revisão das técnicas existentes, como a estimativa de máxima probabilidade [12], expectativa de maximização [13], filtro de Kalman estendido (EKF) [14] ou filtros estendidos de informação (EIF) [15]. Além destes métodos, existe o FastSLAM [16], que aproxima as probabilidades posteriores por partículas e o método de Lu e Milios com base na Correspondência de Varreduras [9]. Finalmente, há o algoritmo baseado em LRF que não faz suposições de características do ambiente, DP-SLAM [4], trabalhado também por Ynoquio [2], que desempenha um papel importante no mapeamento 2D.

SLAM baseado em Filtro de Kalman O mais popular, pois diretamente proporciona tanto uma solução recursiva para o problema de navegação quanto uma forma de calcular estimativas consistentes para a incerteza do robô móvel e localizações das características do mapa, com base em modelos estatísticos para o movimento do robô e observações das características relativas.

SLAM baseado em Probabilidades A segunda filosofia é evitar a necessidade de estimativas de posição absoluta e medidas precisas de incerteza e, em vez de empregar um conhecimento mais qualitativo da localização relativa das características do mapa e do robô móvel, constroi mapas e guia o movimento. Esta filosofia geral tem sido desenvolvida por vários grupos diferentes em um número de maneiras diversas [14]. Abordagem qualitativa para a navegação e o problema de SLAM tem muitas vantagens potenciais sobre a metodologia da teoria estimativa em termos de limitar a necessidade de modelos precisos e os requisitos computacionais.

Correspondência de Varreduras-SLAM Uma filosofia muito ampla, que fornece uma alternativa ao Filtro de Kalman ou o formalismo estatístico, man-

tendo uma abordagem essencialmente numérica ou computacional para resolver o problema de SLAM e navegação. Essas abordagens incluem a utilização de correspondência de duas Varreduras [17], registro global de mapas, regiões delimitadas e outras medidas para descrever a incerteza. As primeiras tentativas de realizar a localização de um robô móvel por correspondência de duas varreduras sucessivas foram inspiradas por Besl e McKay [18], que apresentaram o algoritmo Iterative Closest Point (ICP).

Lu e Milios [9] propuseram algumas alterações ao algoritmo ICP original para torná-lo mais adequado para aplicações robóticas. Além disso Alshawa [19] propôs o algoritmo Iterative Closest Line (ICL).

FastSLAM A maioria das abordagens para resolver o problema de SLAM tem que lidar com um grande número de pontos de referência presentes em ambientes reais. Algoritmos baseados no filtro de Kalman, por exemplo, exigem um tempo quadrático em relação ao número de pontos de referência para incorporar cada observação do sensor [16]. O algoritmo FastSLAM, por outro lado recursivamente estima a completa distribuição posterior sobre a posição do robô e dos pontos de referência locais, a escalas que variam logaritmicamente com o número de pontos de referência do mapa. FastSLAM segue uma proposta feita por Murphy [20], usando um filtro de partículas Rao-Blackwellized para amostrar a posição do robô e acompanhar a posição de um número fixo de pontos de referência pre-determinados utilizando um filtro de Kalman. *"As posições dos pontos de referência são condicionalmente independentes, dada a posição do robô"* [20].

Este método reduz alguns dos desafios em mapeamento, à custa de alguns desafios na seleção e identificação dos pontos de referência. Este último pode envolver um problema de associação de dados bastante complicado.

DP-SLAM Algoritmo puramente baseado em laser (LRF) e não faz suposições dos pontos de referência. DP-SLAM evita o problema de associação de dados, armazenando vários mapas detalhados em vez de pontos de referências esparsos, assim, assumindo associação com a localização. O algoritmo usa um filtro de partículas para representar tanto a posição do robô e as configurações possíveis do mapa. Usando uma nova representação do mapa, que chamaram de mapeamento por distribuição de partículas (PD-Mapping) [21] e [22], são capazes de manter e atualizar centenas ou mi-

lhares de candidatos de mapas e posições do robô em tempo real como o movimento do robô através do ambiente.

Em princípio, os métodos probabilísticos de mapeamento $2D$ planar são extensíveis para mapeamento $3D$ [23], No entanto, para nosso conhecimento nenhuma extração de características de confiança, nem uma estratégia para reduzir os custos computacionais, já foi publicado. O desvio qualitativo da complexidade é devido à necessidade de recolher amostras em cada dimensão.

O problema SLAM pode ser definido como um problema de otimização global, em que o objetivo é buscar o espaço de possíveis mapas do robô. Assim um algoritmo genético pode ser descrita para resolver este problema[24][25].

1.3.1.2

Mapeamento $3D$

Mapas tridimensionais podem ser gerados por três técnicas diferentes: em primeiro lugar, um método de localização planar combinado com um sensor $3D$; em segundo lugar, uma precisa estimação da posição $6D$ combinada com um sensor $2D$; e em terceiro lugar, um sensor $3D$ com um método de localização $6D$ [10]. As Tabelas 1.1 e 1.2 resume estas técnicas de mapeamento, em comparação com o mapeamento planar $3D$.

Tabela 1.1: Visão geral da dimensionalidade de abordagens SLAM-mapas $2D$.

Dados do	Dimensionalidade da representação da pose	
	3D	6D
Sensor		
2D	Mapeamento planar 2D	Slice-wise 6D SLAM
3D	Mapeamento planar 3D	Full 6D SLAM

Mapeamento $3D$ planar. Em vez de usar um sistema de varredura $3D$, que produz consistentes varreduras $3D$ scans, alguns grupos têm tentado construir representações volumétricas de ambientes com LRF $2D$. Em trabalhos anteriores, são usados dois LRF $2D$ para a aquisição de dados em $3D$. Um LRF é montado horizontalmente e outra verticalmente. Este último captura uma linha de exploração vertical, que é transformada em pontos $3D$ com base na atual posição do robô móvel, porque a varredura vertical não é capaz de capturar as laterais dos objetos [26].

Tabela 1.2: Visão geral da dimensionalidade de abordagens SLAM-mapas 3D.

Dimensionalidade da representação da pose		
Dados	3D	6D
do		
Sensor		
2D	Mapeamento 2D de sensores sonares e laser por varreduras[11]	Mapeamento 3D usando uma precisa localização, considerando a (x, y, z) posições e roll, yaw e pitch ângulos.
3D	Mapeamento 3D, utilizando um método de localização planar	Mapeamento 3D, utilizando um laser por varreduras 3D ou câmaras com posições estimadas a partir dos dados do sensor.

1.4 Roteiro da Dissertação

O capítulo 2 discute a modelagem matemática do problema, ou seja, as equações básicas de probabilidade, fundamentos de Correspondência de Varreduras, tipos de mapas e conceitos de otimização por evolução diferencial, à descrição dos métodos usados para resolver o problema de SLAM: DP-SLAM, Filtro de Partículas, e também é descrita a representação de mapas por DP-Mapping.

No capítulo 3 apresentam-se alguns detalhes da implementação, tais como Filtragem das Varreduras do sensor, Parâmetros e Considerações.

No capítulo 4 apresentam-se testes e Resultados, e é mostrado o mapeamento dos ambientes internos em 2D para ambientes simulados.

No capítulo 5 apresentam-se testes e Resultados, e é mostrado o mapeamento dos ambientes internos em 2D para ambientes reais.

As conclusões e os comentários finais são apresentados no capítulo final do trabalho.