



ANTONIO MENDES MAGALHÃES JÚNIOR

**O USO DO ALGORITMO MAPA DE ROTAS
PROBABILÍSTICO NA ROBÓTICA MÓVEL:
PLANEJAMENTO DE CAMINHOS PARA AMBIENTES
ESTÁTICOS COM FOCO EM CASAS DE VEGETAÇÃO**

LAVRAS-MG

2018

ANTONIO MENDES MAGALHÃES JÚNIOR

**O USO DO ALGORITMO MAPA DE ROTAS PROBABILÍSTICO NA ROBÓTICA
MÓVEL: PLANEJAMENTO DE CAMINHOS PARA AMBIENTES ESTÁTICOS COM
FOCO EM CASAS DE VEGETAÇÃO**

Monografia apresentada à Universidade Federal de Lavras como parte das exigências do Curso de Engenharia de Controle e Automação para obtenção do título de Bacharel.

Prof. Dr. Leonardo Silveira Paiva
Orientador

LAVRAS-MG
2018

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Magalhães Junior, Antonio Mendes.

O uso do algoritmo Mapa de Rotas Probabilístico na robótica móvel: planejamento de caminhos para ambientes estáticos com foco em casas de vegetação / Antonio Mendes Magalhães Junior. - 2018.

54 p.

Orientador(a): Leonardo Silveira Paiva.

TCC (graduação) - Universidade Federal de Lavras, 2018.
Bibliografia.

1. robótica móvel. 2. path planning. 3. probabilistic roadmap. I. Paiva, Leonardo Silveira. II. Título.

ANTONIO MENDES MAGALHÃES JÚNIOR

**O USO DO ALGORITMO MAPA DE ROTAS PROBABILÍSTICO NA ROBÓTICA
MÓVEL: PLANEJAMENTO DE CAMINHOS PARA AMBIENTES ESTÁTICOS COM
FOCO EM CASAS DE VEGETAÇÃO**

**THE USE OF ALGORITHM PROBABILISTIC ROADMAP IN MOBILE
ROBOTICS: PLANNING OF PATHS FOR STATIC ENVIRONMENTS WITH FOCUS
ON GREENHOUSES**

Monografia apresentada à Universidade Federal de Lavras como parte das exigências do Curso de Engenharia de Controle e Automação para obtenção do título de Bacharel.

APROVADA em 25 de junho de 2018.

Dr. Leonardo Silveira Paiva UFLA

Dr. Carlos Renato Borges dos Santos IFMG

Bel. Matheus Feres Freitas UFLA

Prof. Dr. Leonardo Silveira Paiva

Orientador

LAVRAS-MG

2018

Dedico o presente trabalho a todos que me ajudaram a seguir nesta jornada quando eu não mais conseguiria sozinho.

AGRADECIMENTOS

A conclusão dessa longa jornada se faz presente neste trabalho. Fico imensamente grato pela enorme contribuição que me foi dada, de várias frentes, ao longo deste caminho. Desta forma, agradeço aos meus familiares por todo incentivo dado durante toda a minha formação, me tornando alguém apto a chegar até aqui. Obrigado à minha mãe Verli, ao meu pai Antonio, ao meu padrasto Ventura, à minha madrinha Ivany e a todos mais que contribuíram comigo.

Agradeço também aos meus amigos que estiveram presentes nos momentos de maior dificuldade durante minha jornada acadêmica, contribuindo direta ou indiretamente, Rodrigo Afonso, Rodrigo Wesley, Matheus Feres, Priscila Delbem e Moisés Martins.

Agradecimento especial à minha grande amiga Livia Souza pela ampla cooperação durante a execução deste trabalho e pelo enorme apoio nos momentos mais marcantes, acadêmicos ou não.

À Marina Macedo pelo apoio incondicional e por estar presente neste importante momento da minha vida, tornando os dias mais leves e agradáveis. Sua presença me faz desfrutar mais do hoje e desejar o amanhã.

À Ariana Alves pela sincera e duradoura amizade e por estar comigo nos mais diversos momentos, o que certamente aliviou o peso dessa jornada. Ohana quer dizer família.

Aos bons professores que encontrei até aqui em toda minha jornada de aprendizado, em especial àqueles que dispunham de poucos recursos para o exercício de sua profissão e ainda assim me encheram de esperança e admiração.

Ao meu orientador Prof. Dr. Leonardo Silveira Paiva pelo incentivo, contribuições, sugestões, esclarecimentos e principalmente pela compreensão durante este trabalho.

“Eu sei que essa situação pode ser intimidadora. Você olha ao redor e é tudo assustador e diferente, mas sabe... encará-las, avançar contra elas como um touro – é assim que crescemos como pessoas.”

(Rick Sanchez)

RESUMO

A Robótica Móvel vem se destacando nos últimos anos e tendo como um de seus principais campos de pesquisa os métodos para geração de percursos mínimos entre pontos de determinados ambientes. O presente trabalho consiste na geração de caminhos por meio do algoritmo de Mapa de Rotas Probabilístico (MRP) para o deslocamento de uma plataforma robótica simulada em uma representação de uma casa de vegetação, buscando a facilitação da automatização de aplicações de agentes químicos de controle de pragas agrícolas em ambientes controlados por meio de robôs móveis. O algoritmo recebe os pontos de partida e chegada do robô e, considerando a menor distância entre estes no grafo gerado pelo MRP e as restrições do ambiente em que se encontra, traça a rota a ser percorrida. Para tal, a representação do ambiente, que é estático, foi fornecida previamente ao robô de maneira *off-line*. Inicialmente foi realizado o tratamento das imagens representando os mapas, com utilização do software Matlab, a fim de obter a discretização das mesmas. Foram escolhidos mapas de diferentes complexidades para que se testasse a robustez e eficiência do método MRP. Por meio da ferramenta de planejamento de caminhos presente na *toolbox* de sistemas robóticos (*Robotic System Toolbox*) do software Matlab, foi executado o algoritmo MRP e encontrada uma matriz de conjunto de pontos que descrevem o caminho de menor custo a ser percorrido. O robô simulado foi então alimentado com essa matriz e foram configurados os parâmetros do robô, como tamanho, velocidade linear e velocidade angular de acordo com o requerido na situação. A utilização de bibliotecas existentes no Matlab tornou a realização do projeto facilitada, ajudando no planejamento do caminho e na simulação do robô, levando em consideração as características do ambiente e do robô. Dessa maneira, este estudo mostrou que o algoritmo é robusto e eficiente em mapas de diferentes complexidades, provando-se uma ótima opção de ferramenta para planejamento de rotas em ambientes estáticos, fazendo deste um método promissor para aplicações em casas de vegetação.

Palavras-chave: Robótica Móvel. PRM. Casas de Vegetação. Path Planning.

ABSTRACT

Mobile Robotics is increasingly evolving in recent years; one of its main fields of research is the fundamental task of path planning, generating the shortest path for a robot towards the goal point in determinant environments. This study used the algorithm of *Probabilistic Roadmaps* (PRM) for path planning, considering the displacement of a simulated robotic platform of a greenhouse. The aim was to facilitate the applications of chemical agents for the control of agricultural pests in controlled environments. The algorithm received the starting and ending points of the robot, tracing the route to be traveled. It considered the smaller distance from the graph generated by the PRM and the constraints of the environment. For this, the representation of the environment, which is static and already known, was previously provided to the robot in off-line mode. Initially, the treatment of the images representing the maps was performed using the Matlab software in order to obtain image discretization. Different complexity maps were chosen in order to test the robustness and efficiency of the PRM algorithm. Using the path planning tool present in the Robotic System Toolbox of Matlab software, the PRM was run and a two-dimensional point set matrix was found that describes the least cost path to be covered. The simulated robot was then fed with this matrix and the robot parameters, such as size, linear velocity, and angular velocity were configured as required in the situation. The use of existing Matlab libraries favored the path planning and simulation taking into account the characteristics of the environment and the robot. Therefore, this study showed that the algorithm is robust and efficient for maps of different complexities, being a great tool option for path planning in static environments, which can be a promising method for greenhouse applications.

Keywords: Mobile Robotics. Probabilistic Roadmaps. Greenhouse. Path Planning.

LISTA DE FIGURAS

Figura 1 - Exemplos de aplicações para robôs móveis. a) Robôs Kiva movendo estoque na Amazon; b) Robô BigDog para carregamento de cargas; c) Robô para desarmamento de bombas; d) Robô aspirador de pó Roomba; e) Manipulador móvel da ActiveMedia.....	15
Figura 2 - Robô Aurora – Universidade de Málaga, Espanha.....	17
Figura 3 - Caminho percorrido por um robô usando campos potenciais para se orientar.....	24
Figura 4 - Demonstração do algoritmo RRT.....	25
Figura 5 - Funcionamento de um AG tradicional.....	26
Figura 6 - Exemplo de caminho gerado pelo algoritmo MRP.....	28
Figura 7 - Representações de diversos ambientes. a) Ambiente livre de obstáculos; b) Ambiente com obstáculos de diferentes geometrias; c) Labirinto.	31
Figura 8 - Mapa da UFLA. a) Mapa da UFLA gerada pelo Google Maps; b) Mapa da UFLA discretizado.....	31
Figura 9 - Casa de vegetação do Departamento de Fitopatologia da UFLA.....	32
Figura 10 - Modelagem 3D referente a casa de vegetação do Departamento de Fitopatologia da UFLA.....	33
Figura 11 - Representação discretizada da casa de vegetação do Departamento de Fitopatologia da UFLA.....	33
Figura 12 - Grades de Ocupação Binária. a) Grade de ocupação binária da casa de vegetação; b) Grade de ocupação binária da casa de vegetação com obstáculos inflados.....	34
Figura 13 - Mapa de Rotas Probabilístico para a casa de vegetação do Departamento de Fitopatologia da UFLA.....	35
Figura 14 - Robô móvel com tração diferencial.....	37
Figura 15 - Funcionamento do parâmetro de visão antecipada (<i>look ahead</i>).....	37
Figura 16 - Aplicação do MRP no ambiente sem obstáculos. a) Caso 1; b) Caso 2.	39
Figura 17 - Aplicação do MRP no ambiente com obstáculos geométricos de diversas formas. a) Caso 1; b) Caso 2.....	40
Figura 18 - Aplicação do MRP no ambiente labirinto. a) Caso 1; b) Caso 2; c) Caso 3.....	41
Figura 19 - Aplicação do MRP no mapa da Universidade Federal de Lavras	42
Figura 20 - Aplicação do MRP no mapa da casa de vegetação a) Mapa de rotas gerado; b) Caminho a ser percorrido pelo robô.....	43
Figura 21 - Caminho percorrido (em azul) pelo robô.....	44

LISTA DE TABELAS

Tabela 1 – Parâmetros e resultados para aplicação do MRP no cenário livre de obstáculos. ...	39
Tabela 2 – Parâmetros e resultados da aplicação do MRP no cenário com obstáculos geométricos.....	40
Tabela 3 – Parâmetros e resultados da aplicação do MRP no cenário labirinto.....	41

LISTA DE SIGLAS

A*	A-Estrela
AGs	Algoritmos Genéticos
MAPRM	<i>Medial Axis Probabilistic Roadmap</i>
MRP	Mapa de Rotas Probabilístico
RRT	Rapidly Exploring Random Tree
UFLA	Universidade Federal de Lavras

SUMÁRIO

1 INTRODUÇÃO	12
2 OBJETIVOS	14
2.1 Objetivo geral	14
2.2 Objetivos específicos	14
3 REFERENCIAL TEÓRICO	14
3.1 Robótica móvel e suas aplicações	14
3.1.1 A robótica móvel e sua utilização em casas de vegetação.....	16
3.2 Planejamento de caminhos e trajetórias	18
3.3 Principais algoritmos para geração de caminhos	22
3.3.1 O algoritmo A*	22
3.3.2 Campo Potencial.....	23
3.3.3 O algoritmo Árvores Aleatórias de Rápida Exploração (RRT).....	24
3.3.4 Algoritmos Genéticos (AGs).....	26
3.3.5 Mapa de Rotas Probabilístico (MRP).....	27
4 MATERIAIS E MÉTODOS	30
4.1 Descrição dos ambientes	30
4.2 Planejamento do caminho	34
4.3 Configuração do simulador	36
5 RESULTADOS E DISCUSSÃO	38
5.1 Aplicação do algoritmo MRP em ambiente livre de obstáculos	38
5.2 Aplicação do algoritmo MRP em ambiente com obstáculos geométricos.....	39
5.3 Aplicação do algoritmo MRP em um labirinto.....	40
6 CONCLUSÃO	45
6.1 Perspectivas futuras	46
7 REFERÊNCIAS	48

1 INTRODUÇÃO

A robótica tem sido usada de forma crescente em diversos setores, sendo os robôs geralmente classificados em móveis ou industriais, de acordo com sua estrutura (NIKU, 2013). Os robôs industriais geralmente são fixos, com braço articulado e com elemento final, enquanto que os robôs móveis possuem capacidade de locomoção pelo ambiente (Paiva, 2017). A robótica móvel se mostra atual e relevante, com grandes saltos no desenvolvimento das pesquisas relacionadas a ela nas últimas décadas. Além disso, sua aplicação prática em diferentes setores da sociedade vem demonstrando o grande potencial desta área (WOLF et al., 2009). Os robôs móveis são considerados mais versáteis que os industriais por não precisarem estar fixos em uma célula de trabalho, sendo frequentemente utilizados em tarefas sem limites geográficos, usando diferentes tipos de locomoção, como rodas, esteiras e pernas (PIO; CASTRO; CASTRO JÚNIOR, 2006; SECCHI, 2008). Estes robôs são utilizados em diferentes áreas, tais como limpeza de ambientes, desarmamento de bombas e minas, transporte autônomo de carga, exploração de ambientes hostis, vigilância militar e civil e inclusive na agricultura. (SECCHI, 2008; VICTORINO; RIVES; SLAM, 2006; WOLF et al., 2009). A utilização da robótica móvel neste último setor tem se mostrado extremamente relevante, seja em campo ou casas de vegetação. A possibilidade do aumento de produção com a automatização das diversas tarefas desenvolvidas na produção agrícola, como plantio, irrigação, pulverização e colheita é a principal pretensão ao se utilizar esses robôs (ABRAHÃO; MEGDA; BECKER, 2010).

No contexto da robótica móvel, o planejamento de rotas consiste em fazer com que o robô saia de um ponto de origem e chegue em um ponto de destino, por meio de uma sequência de movimentos, sem colidir com obstáculos presentes no ambiente (ADÔRNO; BORGES, 2006). Em geral, os métodos de planejamento desses caminhos são divididos em determinísticos e probabilísticos (PAIVA, 2017). Os determinísticos partem da ideia de que são conhecidas todas as combinações possíveis de configurações livres do robô, o que faz com que os recursos computacionais necessários para a execução desses algoritmos de planejamento geralmente cresçam de forma exponencial com a dimensão do espaço de configurações, tornando impraticável para aplicações em ambientes de grandes dimensões (LATOMBE, 1991; SIGWART; NOURBAKHS, 2004; SILVEIRA, 2016). Já os métodos probabilísticos utilizam amostras do espaço de trabalho para a construção de uma

aproximação do mesmo, fazendo com que sejam necessários menos recursos computacionais, tornando praticável o seu uso mesmo em ambientes de grandes dimensões (MARTINS et al., 2003).

Dentre os métodos probabilístico se destaca o algoritmo Mapa de Rotas Probabilístico por apresentar alta eficiência e tempo computacional reduzido. Este algoritmo demonstra bons resultados para aplicações em robôs com vários graus de liberdade em ambientes estáticos (KAVRAKI et al., 1996). Os diversos usos deste método incluem a limpeza de dutos de resfriamento em usinas nucleares, soldas ponto-a-ponto em indústrias automobilísticas e limpeza de fuselagem de aviões, além disso, tem como aplicações emergentes o uso em animações gráficas e biologia molecular (KAVRAKI et al., 1996).

Para atingir maior produtividade, os robôs precisam cada vez mais aumentar a velocidade de suas ações, entretanto, essa alta velocidade pode dificultar o seu controle e causar um maior desgaste físico devido à exigência de desempenhos extremos do atuador (GASPARETTO et al., 2015). Nesse sentido, a geração de trajetória visa buscar o equilíbrio entre produtividade e desgaste dos atuadores, encontrando uma trajetória de rápida execução e que ao mesmo tempo evite acelerações excessivas dos atuadores. Há de se atentar então para a diferenciação entre o planejamento de caminho (*path planning*) e o planejamento de trajetórias (*trajectory planning*).

No planejamento de caminho, o qual foi o abordado neste trabalho, é gerado um caminho geométrico, indo de um ponto inicial até um ponto final, considerando os obstáculos no caminho, enquanto que no planejamento de trajetória se assume um determinado caminho geométrico e, além das restrições de obstáculos, há as restrições impostas pela dinâmica do atuador (GASPARETTO et al., 2015). No planejamento de trajetória leva-se em conta leis temporais, a trajetória é planejada em termos de sequências temporais de valores alcançados pela posição, velocidade e aceleração (SICILIANO et al., 2009). Os algoritmos de planejamento de caminho e trajetória se tornam cada vez mais importantes na robótica e estudos relacionados a esses algoritmos se mostram essenciais para criação e aperfeiçoamento de métodos que visam encontrar percursos ideais a fim de otimizar o trabalho dos robôs.

Uma das áreas de destaque de aplicação de plataformas móveis é a agricultura, a qual foi o enfoque deste trabalho, especificamente no uso desses robôs em casas de vegetação. Tarefas como plantio, colheita e aplicação de agentes químicos e biológicos podem ser realizadas por plataformas robóticas móveis (MANDOW et al., 1996).

Por meio da realização deste trabalho, pretendeu-se demonstrar que o algoritmo MRP pode ser usado satisfatoriamente para controle de robôs móveis em ambientes estáticos de

manejo de plantas, como as casas de vegetação. Os benefícios do uso de robôs nesses ambientes residem principalmente em garantir a uniformidade na aplicação de compostos fertilizantes e inseticidas e principalmente em evitar o contato humano com agentes químicos potencialmente prejudiciais à saúde humana.

2 OBJETIVOS

2.1 Objetivo geral

Este trabalho teve como objetivo o planejamento de caminho de menor custo e livre de colisões, a ser percorrido por um robô simulado, em uma representação de uma casa de vegetação real, utilizando o algoritmo MRP.

2.2 Objetivos específicos

Os objetivos específicos foram divididos nos seguintes itens, de acordo com a ordem de execução do presente trabalho:

- a) Obter uma imagem representativa da casa de vegetação e realizar o tratamento da mesma a fim de torná-la discretizada.
- b) Aplicar o algoritmo MRP, utilizando a *toolbox* de sistemas robóticos do Matlab, obtendo o grafo de conexões do ambiente.
- c) Realizar a busca do caminho de menor custo no grafo gerado
- d) Configurar o robô simulado de acordo com os parâmetros requeridos e realizar a simulação, fazendo com o que o robô percorra o caminho planejado.

3 REFERENCIAL TEÓRICO

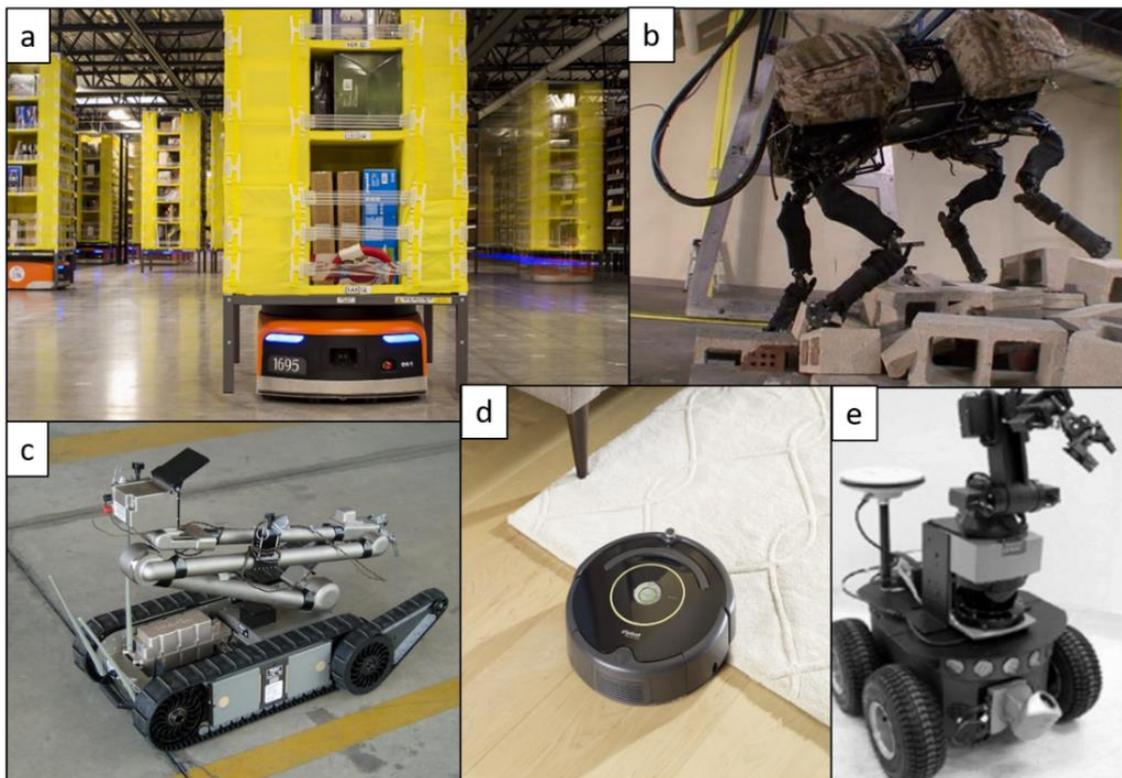
3.1 Robótica móvel e suas aplicações

Com o desenvolvimento de tecnologias de navegação para veículos autônomos e o aumento da capacidade de processamento dos computadores, surgiram os primeiros robôs móveis (MAHADEVAN; NARENDRAN, 1990). Apesar dos enormes benefícios e

aplicações, existem restrições quanto ao uso destas plataformas robóticas, tais como o sistema de alimentação, normalmente feito com baterias, e a dificuldade no desenvolvimento de métodos de navegação seguros e eficientes (ROCHA, 1998).

Estes robôs possuem uma ampla variedade de aplicações no mundo moderno, sendo frequentemente usados no meio industrial, comercial, militar, doméstico e agrícola (KAVRAKI; KOLOUNTZAKIS; LATOMBE, 1998; SECCHI, 2008; VICTORINO; RIVES; SLAM, 2006; WOLF et al., 2009). Na indústria e comércio, os robôs móveis transportam materiais entre máquinas e postos de trabalho e na logística agem assegurando o fluxo correto de materiais e produtos entre armazéns. Na área militar, possuem enorme variedade de aplicações, seja com locomoção aquática, terrestre ou aérea. Eles são usados em vigilância, reconhecimento de território, desarmamento de explosivos, transporte de cargas e ataques a alvos. Nas aplicações domésticas são comumente utilizados para limpeza de ambientes e vigilância, sendo os robôs aspiradores bastante difundidos e acessíveis atualmente (FIGURA 1).

Figura 1 - Exemplos de aplicações para robôs móveis. a) Robôs Kiva movendo estoque na Amazon; b) Robô BigDog para carregamento de cargas; c) Robô para desarmamento de bombas; d) Robô aspirador de pó Roomba; e) Manipulador móvel da ActiveMedia.



Fonte: a) Reuters; b) Boston Dynamics; c) Polícia Federal do Brasil; d) iRobot; e) ActiveMedia.

3.1.1 A robótica móvel e sua utilização em casas de vegetação

Diante do crescimento acelerado da população mundial, a produção de alimentos ganha contornos cada vez mais importantes. Visando o aumento da produtividade e cultivos em regiões pouco favoráveis ao desenvolvimento das plantas, são usadas as estufas agrícolas para o manejo das mesmas (GASPARETO, 2013). O cultivo em casas de vegetação permite que as plantas se desenvolvam em um ambiente favorável, evitando doenças e pragas. Além disso, nesses locais, é possível obter um controle mais preciso de algumas variáveis importantes, como temperatura, umidade do solo e umidade relativa do ar (VIDA et al., 2004). Segundo Lenteren e Woets (1988) e Mandow et al. (1996), as casas de vegetação são amplamente utilizadas para a produção intensiva de produtos hortícolas e mudas em geral em regiões com clima adverso, melhorando a produtividade por meio da irrigação controlada e da redução da possibilidade de ataques de pragas e doenças por se tratar de um ambiente fechado. Usualmente as estufas são construções retangulares, frequentemente cobertas com plástico de polietileno de baixa densidade (GASPARETO, 2013) e a distribuição das plantas dentro delas varia de acordo com as diferentes instalações e culturas, mas geralmente as plantas ficam dispostas em linhas, com corredores estreitos para a circulação de pessoas que operam neste ambiente (MANDOW et al., 1996).

Diversos países utilizam o sistema de casas de vegetação, que contribuem significativamente para a produção agrícola (SANCHEZ-HERMOSILLA et al., 2010). Apesar das diversas vantagens para a produção de plantas nessas estruturas, muitas das tarefas realizadas nelas ainda são executadas de forma manual, como plantio, colheita, monitoramento e pulverização (GASPARETO, 2013). Além disso, de acordo com Mandow et al. (1996), as condições favoráveis criadas nas estufas, buscando o crescimento das plantas, podem também ser favoráveis ao desenvolvimento de pragas e outros organismos indesejáveis que porventura consigam invadir o ambiente, estes geralmente podem ser combatidos com o uso de pesticidas, fungicidas e outros produtos químicos. Este problema, aliado com a alta temperatura e baixa ventilação, faz com que o trabalho no interior desses ambientes seja difícil e até mesmo prejudicial à saúde humana (ACACCIA et al., 2003; GONZALEZ et al., 2009; MANDOW et al., 1996; MEHTA; BURKS; DIXON; 2008; SAMMONS; FURUKAWA; BULGIN, 2005).

Segundo Mandow et al. (1996), estudos em uma província da Espanha, com mais de 20 mil hectares de culturas em casas de vegetação, mostraram doenças de pele, alterações mucosas e conjuntivite em uma amostra de trabalhadores destes ambientes. Neste cenário, a

automatização da pulverização, assim como de outras operações nas casas de vegetação, como controle das condições ambientais, colheita, inspeção de plantas e polinização artificial, possui um significativo impacto socioeconômico. Porém os métodos tradicionais atuais para a automação da pulverização nestes ambientes são baseados em estruturas fixas que fazem a aspersão por cima (Mandow, 1996). Dessa forma, possuem como maior desvantagem o elevado custo, pois se torna necessária a instalação de todo o sistema exclusivamente para cada ambiente, requerendo um sistema por casa de vegetação. Assim, o uso da robótica nesse tipo de ambiente se torna uma alternativa importante.

A aplicação da robótica móvel no setor agrícola tem se destacado nos últimos anos, concentrando grande investimento de recursos de países e empresas de todo mundo, a fim de diminuir os custos de produção e aumentar a produtividade (ABRAHÃO; MEGDA; BECKER, 2010). Neste setor são diversas as funções que podem ser desempenhadas pelas plataformas móveis, como o plantio, colheita, irrigação e aplicações de agentes de controles de pragas e doenças (ALVES, 2015; MANDOW et al., 1996). O uso de robôs autônomos na condição de aplicadores de pesticidas também possui viés econômico e ambiental, uma vez que estes robôs podem executar essa tarefa de forma mais precisa que uma aplicação manual e de acordo com a necessidade da cultura em diferentes pontos da casa de vegetação e assim reduzir os custos financeiros e a agressão ambiental (WOLF et al., 2009). Um exemplo clássico do uso de robôs em casas de vegetação é o robô Aurora, desenvolvido na Universidade de Málaga, Espanha. O Aurora é capaz de navegar de forma autônoma pelos corredores desses ambientes por meio do uso de sensoriamento de baixo custo e possui um pulverizador integrado em sua estrutura, visando a eliminação da aplicação de produtos químicos por humanos (MANDOW et al, 1996), como pode ser observado na Figura 2.

Figura 2 - Robô Aurora – Universidade de Málaga, Espanha



Fonte: Universidade de Málaga

No que se refere ao uso de robôs nas casas de vegetação, a elaboração de sistemas que permitam a navegação autônoma no interior da estufa é uma das tarefas mais importantes e de maior complexidade no desenvolvimento desses robôs. De acordo com Gonzalez et al. (2009); Metha, Burks e Dixon (2008) e Sales, Osório e Wolf (2011), a navegação é o principal ponto no que diz respeito a robôs móveis. Portanto, a escolha dos métodos de navegação, tanto em questão de *hardware* (formas de locomoção) quanto de *software* (planejamento de caminhos ou trajetórias), se torna tarefa crucial ao desenvolver um robô deste tipo. Uma meta importante no desenvolvimento de sistemas de navegação em estufas agrícolas é a detecção de obstáculos no seu interior. Entre eles, é possível citar as paredes, os corredores e as plantas. Espera-se que o desenvolvimento de robôs possibilite não apenas a automação de tarefas comumente realizadas por seres humanos, mas que também realize contribuições para o desenvolvimento da agricultura (GASPARETO, 2013).

3.2 Planejamento de caminhos e trajetórias

O planejamento de caminhos e trajetórias é questão de extrema importância no campo da robótica. De acordo com Gasparetto et al. (2015), a tendência para os robôs e outras máquinas é operar de maneira cada vez mais veloz, a fim de reduzir o tempo de produção, porém a alta velocidade de operação pode acabar por dificultar a repetibilidade e precisão dos movimentos, já que a alta velocidade exige desempenho extremo dos atuadores e sistemas de controle. Busca-se então por uma trajetória suave, isto é, uma trajetória que possa ser executada em alta velocidade, mas que evite acelerações excessivas dos atuadores e vibrações da estrutura mecânica.

Realizar o planejamento de caminho é uma questão meramente geométrica, pois é definido como a geração de um caminho geométrico, de um ponto inicial até um ponto final, sem qualquer lei temporal especificada, enquanto que o planejamento de trajetória consiste em atribuir uma lei temporal especificada ao caminho geométrico, sendo crucial na robótica por influenciar nas propriedades dinâmicas do movimento, constituindo assim a diferença entre planejamento de caminho e planejamento de trajetória (GASPARETTO et al., 2015).

Segundo Raja (2012), os algoritmos dos planejamentos descritos podem ser divididos entre os de planejamento *off-line* e os de planejamento *on-line*, de acordo com as informações disponíveis sobre o ambiente de atuação do robô. No planejamento *off-line*, ou global, há informações prévias e completas sobre obstáculos estacionários e trajetórias de obstáculos dinâmicos. Já no planejamento *on-line*, ou local, as informações completas sobre o ambiente

não são conhecidas previamente, e o robô deve então obter informações por meio de sensores, enquanto se movimenta.

O planejamento *off-line* tem como exemplos robôs de serviço que operam em usinas nucleares e veículos guiados automaticamente em fábricas etc., onde não pode haver mudanças no ambiente capturado, ou seja, os obstáculos devem ser estacionários. Nesse tipo de planejamento as principais abordagens clássicas são a de Decomposição Celular e a de *Roadmap* e as evolutivas são as de Algoritmos Genéticos, Otimização de Enxame de Partículas e Otimização de Colônia de Formigas (RAJA; PUGAZHENTHE, 2012).

No entanto, atualmente, o planejamento *on-line* tem recebido maior atenção, já que os robôs precisam trabalhar de forma autônoma em ambientes dinâmicos (MASEHIAN; KATEBI, 2007) ou com informações incompletas, como em explorações planetárias, indústrias de mineração e robôs de reconhecimento (HACHOUR, 2008). Abordagens clássicas como a de Campo Potencial e Cone de Colisão têm sido seguidas nesse tipo de planejamento, porém as abordagens evolutivas, como Algoritmos Genéticos e Otimização de Enxame de Partículas, têm sido cada vez mais usadas em conjunto com as abordagens clássicas para superar algumas limitações impostas, como o tempo computacional requerido e ambientes de alta complexidade. O uso do planejamento *on-line* é mais desafiador quando se busca eficiência computacional, se comparado ao *off-line*. Além disso, por não ser possível trabalhar com informações completas do ambiente, não é possível obter um percurso pré-planejado, o que faz com que soluções ótimas globais raramente sejam atingidas com este tipo de planejamento (RAJA; PUGAZHENTHE, 2012).

Uma forma de simplificar a representação dos robôs, uma vez que eles podem ter diversos tamanhos e formatos, com variados tipos de estruturas e meios de locomoção, é por meio da abordagem de espaço de configurações, ou “Espaço C” (LOZANO-PEREZ; WESLEY, 1979). Nessa abordagem, a ideia central é a representação do robô como algo pontual, isto é, representado por um único ponto. Dessa forma, o Espaço C do problema do planejamento do caminho se torna um problema bidimensional, onde cada obstáculo é ampliado pela dimensão do raio do robô para que se realize a compensação das dimensões dos obstáculos (RAJA; PUGAZHENTHE, 2012). No contexto do espaço de configurações, dois conjuntos podem auxiliar a formulação de problemas de planejamento de movimento, sendo eles o espaço de configuração ocupado por obstáculos (*Cobs*), que é o conjunto de configurações para as quais existe intersecção entre o robô e os obstáculos, e o espaço de configurações livre (*Cfree*), que é o espaço onde não ocorre intersecção entre o robô e os obstáculos (SANTANA, 2007).

No planejamento de caminho também deve-se considerar a necessidade do conhecimento do mapa do ambiente e a localização do robô, para que se consiga determinar o caminho mais eficiente, uma vez que por meio do mapa o robô consegue verificar os obstáculos presentes no percurso e encontrar os possíveis trajetos que o levam até seu destino (THRUN, 2002). Existem basicamente dois tipos de mapas que podem ser utilizados por robôs móveis, os topológicos e os métricos (WOLF et al., 2009). Os topológicos retratam o ambiente por grafos, onde os nós representam as regiões de interesse do ambiente e as arestas as ligações entre essas regiões (KUIPERS; BYUN, 1991; MATARIC 1990). Esses mapas são eficientes em estimar trajetórias, porém fornecem uma representação pobre do ambiente físico (WOLF et al., 2009). Já os mapas métricos, segundo Elfes (1989), representam o ambiente físico detalhadamente e entre eles se destaca a representação em Grades de Ocupação (*Occupancy Grids*). Essa é uma representação bidimensional do ambiente, onde o espaço de operação do robô é particionado em pequenas regiões denominadas células (BORENSTEIN; KOREN, 1991; MARTIN; MORAVEC, 1996; MORAVEC, 1989; MORAVEC; ELFES, 1985; WOLF et al., 2009) e cada uma dessas células contém a informação indicando se ela está livre ou ocupada, sendo assim uma variável binária (THRUN, 2002). Dessa maneira, é possível fazer a abstração dessa representação em uma matriz, onde cada elemento representa uma única região do espaço de operação do robô, tornando essa uma abordagem robusta e unificada para representar o espaço de navegação (ALVES, 2015).

Segundo Choset et al. (2005) e LaValle (2006), as abordagens de planejamento de caminhos podem ser divididas basicamente entre métodos que utilizam *roadmap* (mapa de rotas), os que utilizam decomposição de células e os que utilizam campo potencial artificial. Já os algoritmos para o planejamento de trajetórias são geralmente nomeados pela função a ser otimizada, como tempo mínimo e energia mínima (GASPARETTO et al., 2015).

Segundo Gasparetto et al. (2015), as técnicas *roadmap* se baseiam na redução do espaço de configurações n-dimensional em caminhos unidimensionais. Dessa forma, essa abordagem realiza o mapeamento da conectividade do espaço livre (Cfree) em um sistema de curvas unidimensionais, conhecido como roteiro. O roteiro então obtido possui um conjunto de rotas, dessa forma o planejamento do caminho consiste em realizar a vinculação das configurações inicial e final ao roteiro, encontrando assim um percurso viável. Para tanto, é usual associar um gráfico ao roteiro e definir então algum índice de otimização, como por exemplo o comprimento euclidiano. Dessa forma, o gráfico pode então ser pesquisado para obter a solução ideal para o problema do planejamento do caminho, geralmente o caminho mais curto (CANNY; DONALD, 1988; TAKAHASHI; SCHILLING, 1989).

Outro método para planejamento de caminhos é o de decomposição de células. O espaço livre do robô é subdividido em diversas regiões, denominadas células, de forma que um caminho entre duas configurações encontradas na mesma célula seja de fácil geração. Define-se então um gráfico de conectividade, que representa as relações de adjacência entre as células. Os nós do grafo representam as células extraídas do espaço livre e há uma conexão entre dois nós somente se as células correspondentes forem adjacentes. Dessa forma, o problema de planejamento do caminho é reduzido em um problema de pesquisa de grafo, podendo ser resolvido usando técnicas de busca em grafos (GASPARETTO et al., 2015).

Já na abordagem de campo potencial, a ideia básica é considerar o robô no espaço de configurações como um ponto móvel que está a mercê de um campo potencial gerado pela configuração de objetivos e obstáculos no espaço. A configuração final ou objetivo gera um potencial atrante, enquanto que os obstáculos geram um potencial repulsivo. Assim, a soma desses campos é o potencial total, que pode ser entendido como uma força artificial aplicada ao robô, que visa o aproximar do objetivo e o desviar dos obstáculos. Dessa forma, a próxima configuração pode ser determinada pela direção da força artificial sujeitada ao robô. (GASPARETTO et al., 2015; KHATIB, 1985; VOLPE, 1990; VOLPE; KHOSLA, 1990).

De acordo com Gasparetto et al. (2015), a resolução do planejamento de trajetórias significa a geração de entradas de referência para o sistema que realiza o controle do robô. Geralmente o algoritmo usado para o planejamento de trajetória tem como entradas o caminho que já foi gerado por um planejador de caminho e as restrições, cinemáticas e dinâmicas, do robô. Já a saída do planejador de trajetória é a trajetória das juntas ou *end-effector*, sendo uma sequência de valores que representam a posição, velocidade e aceleração. Dessa forma, o planejamento da trajetória no espaço de operação significa gerar uma sequência de valores que representam a posição e orientação que o *end-effector* deve assumir em cada intervalo de tempo. Os critérios de otimizade mais usados são o do tempo e energia.

O critério de tempo mínimo foi o primeiro a ser considerado no planejamento de trajetórias, uma vez que o tempo de execução está intimamente ligado com a alta produtividade industriais. Foram propostos muitos algoritmos destinados a minimizar o tempo de execução. Os algoritmos descritos em Bobrow et al. (1985) e Shin e McKay (1985), são definidos no plano de fase posição-velocidade. A ideia básica desses algoritmos é escrever a equação dinâmica do manipulador em uma forma paramétrica usando a abscissa curvilínea do caminho como parâmetro independente. Já no planejamento de trajetória com base em critérios energéticos, há geração de trajetórias suaves que são mais fáceis de rastrear e reduzem as tensões nos atuadores e estrutura mecânica do robô. Este critério permite atender

melhor os requisitos de economia energética, muitas vezes impostas por aplicações em que a fonte de energia é limitada, como exploração subaquática e tarefas militares (GASPARETTO et al., 2015).

Na etapa de planejamento, deve-se também considerar as restrições impostas pela plataforma robótica, físicas e cinemáticas, como tamanho e limitações dos movimentos de translação e rotação. Além disso, uma forma de melhorar o percurso planejado é a suavização ou otimização do mesmo, que visa diminuir ainda mais o tamanho do caminho gerado e/ou a complexidade dos movimentos que o robô deve realizar para percorrê-lo. Isso permite que o robô consiga cortar cantos triangulares e realizar movimentos mais suaves, diminuindo o esforço cinemático e o tempo gasto para que se realize o trajeto (Kavraki et al., 1996). Algumas técnicas de suavização foram discutidas nos trabalhos de Berchtold e Glavina (1994) e Laumond, Taix e Jacobs (1990).

3.3 Principais algoritmos para geração de caminhos

Esta seção apresenta alguns dos algoritmos mais utilizados para a resolução do problema de geração de percursos para a robótica móvel, apresentando uma síntese sobre o funcionamento e os pontos fortes e fracos de cada algoritmo descrito.

3.3.1 O algoritmo A*

O algoritmo A* (lê-se A-estrela) é um dos mais conhecidos e utilizados algoritmos para buscas em espaços de configuração métrica ou topológica (CUI; WANG; YANG, 2012). O A* combina o uso de busca heurística e pesquisa com base no caminho mais curto (DUCHONĚ et al., 2014). O espaço de busca é reduzido estimando o custo de deslocamento da posição de origem até a posição de destino, sendo que o custo estimado do caminho que passa por um determinado vértice é dado pela Equação 1:

$$f(v) = g(v) + h(v) \quad (1)$$

Nessa equação, $f(v)$ é custo total da configuração de origem até a de destino, passando pelo vértice v , $g(v)$ é o custo calculado do caminho da configuração de origem ao vértice v , seguindo o caminho gerado para chegar a ele e $h(v)$ é o custo estimado do caminho do vértice v até a configuração de destino (AYRES, 2017; DUCHONĚ et al., 2014; SANTANA, 2007). Cada célula adjacente a atual é avaliada pela heurística e a célula com o

menor valor de $f(v)$ é escolhida como a próxima na sequência, o processo então é repetido até se chegar ao destino (DUCHOŇ et al., 2014).

Segundo Gonçalves (2013) e Santana (2007), o algoritmo A* usa o conceito de listas abertas e fechadas. Em cada iteração, o vértice de menor custo é retirado da lista de abertos para ser explorado e para cada sucessor do vértice explorado é tomado o seguinte roteiro:

- É ignorado se estiver na lista de fechados.
- Se estiver na lista de abertos, tem suas informações atualizadas quando o custo do caminho atual é menor do que o custo calculado anteriormente para ele.
- Caso não estiver em nenhuma das duas listas é considerado um novo vértice e é adicionado na lista de abertos.

O vértice que for removido da lista de abertos é colocado na de fechados após ter seus vizinhos processados. A cada iteração, o vértice da lista de abertos com menor custo estimado será o escolhido pelo algoritmo (GONÇALVES, 2013; SANTANA, 2007).

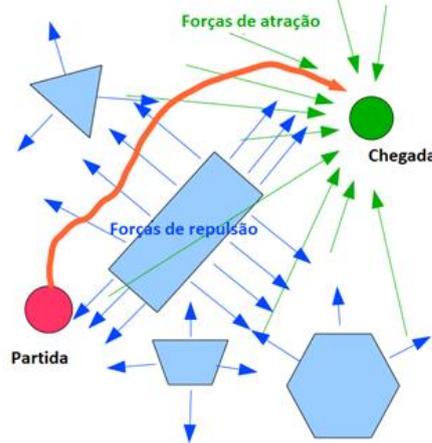
Segundo Duchoň et al. (2014), uma das vantagens desse algoritmo é o fato de poder ser modificado, adotando mais critérios na função $f(v)$, como por exemplo adicionando um termo que penalize caminhos perigosos. Porém, sua maior desvantagem é o grande uso de recursos computacionais para mapas muito grandes.

3.3.2 Campo Potencial

A abordagem de Campo Potencial Artificial foi proposta por Khatib (1985) e se tornou popular na robótica móvel (RAJA; PUGAZHENTHE, 2012). Os planejadores de caminho que fazem uso de campos potenciais para a orientação dos robôs têm por princípio a geração de campos potenciais por meio de funções que criam um potencial atrativo para o ponto de chegada do robô e um potencial negativo em torno dos obstáculos que o robô deve evitar (BARRAQUAND; LANGLOIS; LATOMBE, 1992; RAJA; PUGAZHENTHE, 2012). Este método utiliza o robô como um ponto sob influência dos campos gerados e o move de acordo

com seu gradiente por um percurso entre os pontos inicial e final (DEICU, 2012; QUEIRÓS, 2014), como mostra a Figura 3.

Figura 3 - Caminho percorrido por um robô usando campos potenciais para se orientar



Fonte: Adaptado de

www.gamasutra.com/blogs/MattKlingensmith/20130907/199787/Overview_of_Motion_Planning.php

Segundo Raja e Pugazhenth (2012), a abordagem de Campo Potencial Artificial é reconhecida por sua elegância matemática e simplicidade, já que geralmente resulta em caminhos mais suaves e apresenta soluções de forma rápida, sendo um dos métodos mais rápidos no planejamento de caminhos. Porém, a grande desvantagem dessa técnica é sua ineficiência quanto aos mínimos locais, onde as forças de atração e repulsão se anulam. Para que este problema seja contornado, normalmente são utilizadas funções de navegação que definem como único mínimo local possível o ponto de chegada (QUEIRÓS, 2014).

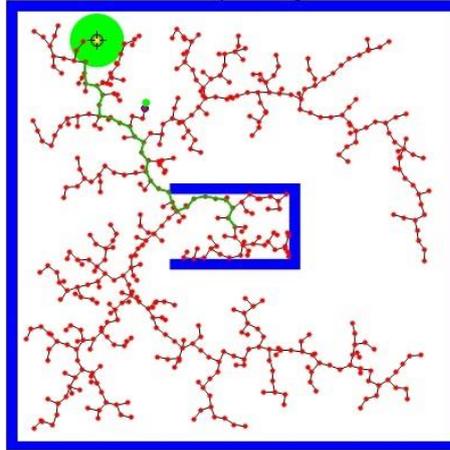
3.3.3 O algoritmo Árvores Aleatórias de Rápida Exploração (RRT)

O algoritmo RRT (*Rapidly-Exploring Random Trees*) surgiu da necessidade de um algoritmo para planejamento de trajetórias considerando a dinâmica dos movimentos dos robôs, considerando velocidade e aceleração. Esse método permite uma rápida solução por meio da criação de ramos aleatórios a partir de um ponto de início (LAVALLE, 1998).

Este algoritmo tem início com uma árvore vazia e o ambiente, os pontos inicial e final e o número limite de amostras são conhecidos. Amostras são geradas de forma aleatória até que seja atingido o número máximo de amostras ou que seja encontrado um caminho válido entre os pontos de partida e destino (QUEIRÓS, 2014). Sendo assim, quanto maior a

quantidade de amostras permitidas, maior a probabilidade de encontrar uma trajetória válida e maior o tempo computacional demandado. A Figura 4 exemplifica o uso deste algoritmo.

Figura 4 - Demonstração do algoritmo RRT



Fonte: Adaptado de

<http://demonstrations.wolfram.com/RapidlyExploringRandomTreeRRTAndRRT/>

De acordo com LaValle (1998), este tipo de algoritmo possui algumas vantagens, as quais são listadas abaixo:

- A expansão da árvore é fortemente tendenciosa para porções inexploradas do mapa.
- A distribuição dos vértices se aproxima da distribuição de amostragem, levando a um comportamento consistente.
- Uma RRT é probabilisticamente completa em condições gerais.
- O algoritmo é relativamente simples, facilitando a análise da sua performance.
- A RRT permanece sempre conectada a todos os nós gerados, mesmo que sejam mínimos.
- Uma RRT pode ser considerada um módulo de planejamento de caminho, aumentando sua aplicabilidade numa variedade de sistemas de planejamento.

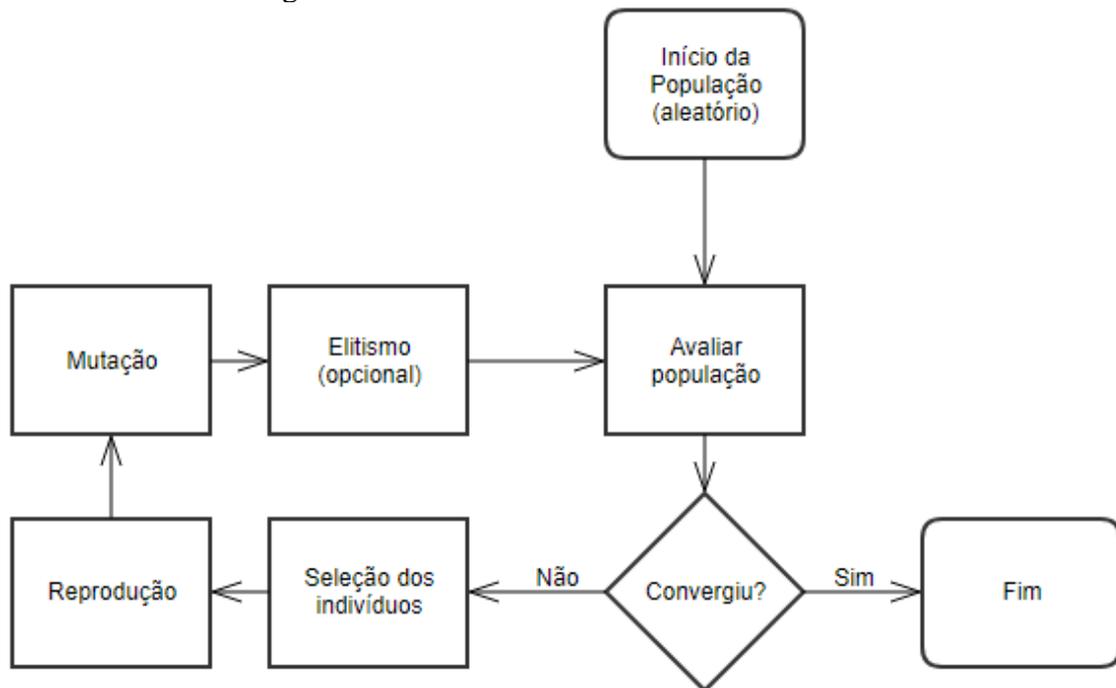
- Todo o algoritmo de planejamento de movimento pode ser implementado sem requerer a capacidade de orientar o sistema entre dois estados.

Após a publicação da RRT, foram propostas diversas extensões do algoritmo clássico que podem ser aplicadas para alcançar um melhor desempenho (SOUSA, 2017).

3.3.4 Algoritmos Genéticos (AGs)

O conceito de Algoritmos Genéticos foi introduzido por John Holland da Universidade de Michigan, nos Estados Unidos, entre as décadas de 60 e 70 (MITCHELL, 1999). Em seu livro “*Adaptation in Natural and Artificial Systems*”, Holland (1975), estruturou o funcionamento dos AGs como uma abstração da evolução biológica e os conceitos de seleção natural propostos por Charles Darwin, conforme mostrado na Figura 5.

Figura 5 - Funcionamento de um AG tradicional



Fonte: Do autor (2018)

Entretanto, apesar dos AGs serem usados em uma grande variedade de problemas de otimização, possuem limitações. Exemplos dessas limitações são a dificuldade de superar as armadilhas de ótimos locais em problemas de otimização e ter seu desempenho sujeito a oscilações, mesmo que com pequenas modificações no problema proposto (OCHI, 2010).

O funcionamento dos AGs, de acordo com Paiva (2017), consiste basicamente em criar uma população de possíveis resoluções para o problema proposto e assim submetê-las ao processo evolutivo conforme as seguintes etapas:

1. Seleção: os indivíduos da população são selecionados para a reprodução.
2. Cruzamento: realizado com determinada probabilidade de gerar descendente.
3. Mutação: algumas características dos indivíduos resultantes do cruzamento são alteradas, a fim de garantir maior variedade “genética”.
4. Atualização: os indivíduos dessa geração são acrescentados à população.
5. Finalização: verifica se as condições de encerramento foram atingidas.

Diversas inovações foram propostas no decorrer dos anos, no que diz respeito aos AGs, entre elas vários tipos de cruzamento, seleção e técnicas de convergência (PAIVA, 2017), visando melhorar a eficiência desses métodos.

3.3.5 Mapa de Rotas Probabilístico (MRP)

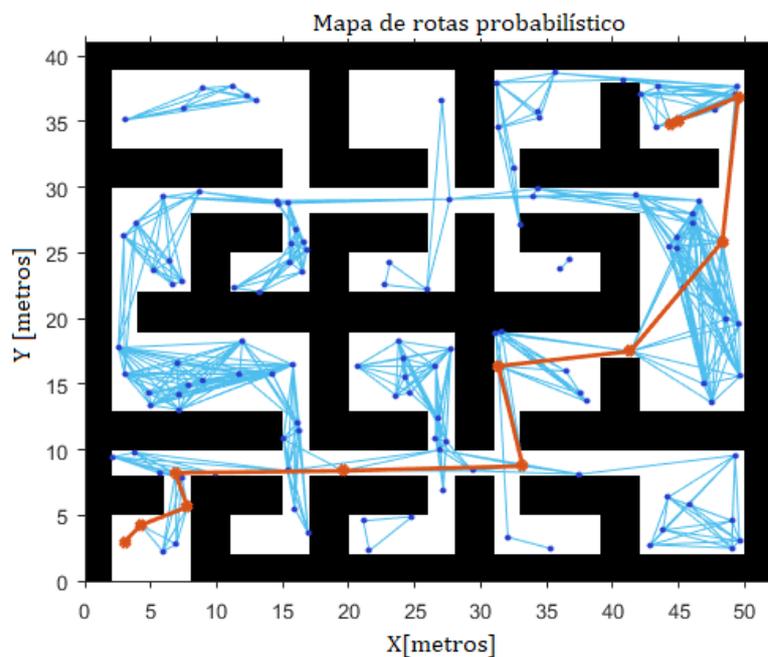
O Mapa de Rotas Probabilístico (*Probabilistic Roadmaps*) é um dos mais eficientes algoritmos para planejamento de caminhos entre dois pontos (PAIVA, 2017) e foi um dos primeiros algoritmos baseados na amostragem do espaço de configurações a ser viável na prática (KAVRAKI et al., 1996). Este algoritmo pode ser usado para obter caminhos livres de colisões para quaisquer tipos de plataformas robóticas que precisam se mover entre obstáculos estacionários. Contudo, é normalmente utilizado no problema de planejamento de trajetórias para robôs de vários graus de liberdade em ambientes estáticos (KAVRAKI et al., 1996).

A estrutura do MRP consiste em um grafo $R(N, E)$ localizado no espaço livre (*Cfree*) de um espaço de configurações m -dimensional, onde (m) representa o número de graus de liberdade do robô, (N) os nós do grafo (R) e (E) suas arestas (ADÔRNO, 2008). Este algoritmo é dividido em duas fases denominadas fase aprendizado e fase de questionamento.

Na fase de aprendizado, a construção do *roadmap* acontece gerando amostras aleatórias de configurações do robô (nós) no espaço de configurações e os adicionando ao conjunto de nós do grafo (N). A partir disso, um planejador local realiza a tentativa de conectar esses nós, por meio de segmentos de retas, com seus nós vizinhos que estejam a uma distância máxima já predefinida. (KAVRAKI et al., 1996; KAVRAKI; KOLOUNTZAKIS; LATOMBE, 1998). As conexões que obtiverem êxito são então adicionadas ao conjunto de arestas do grafo (E). Áreas mais difíceis do mapa podem ser detectadas heurísticamente e assim, em um pós-processamento, ter mais nós gerados nelas a fim de aumentar a conectividade do mapa (KAVRAKI; LATOMBE, 1994). Em Kavraki et al. (1996) e Kavraki; Kolountzakis e Latombe (1998), são discutidas técnicas para esta finalidade.

Na etapa de questionamento, o grafo resultante da fase de aprendizado é consultado para encontrar um caminho que ligue os pontos de partida e chegada, basicamente um problema de busca em grafo (SOUSA, 2017). Como o planejador local é determinístico, o caminho gerado será sempre o mesmo para as mesmas configurações de entrada, ou seja, mesmo grafo gerado na etapa de aprendizado e mesmas configurações inicial e final do robô (ADÔRNO, 2008). O objetivo dessa divisão é fazer com que a maior parte do gasto computacional fique na fase de aprendizado e que a fase de questionamento se dê de maneira bastante veloz. A Figura 6 exemplifica o uso deste algoritmo.

Figura 6 - Exemplo de caminho gerado pelo algoritmo MRP



Fonte: Adaptado de www.mathworks.com/help/robotics/examples/path-planning-in-environments-of-different-complexity.html

O algoritmo MRP é considerado um planejador multi-consulta, já que seu maior investimento de processamento se dá na fase de aprendizado e depois múltiplas consultas podem ser realizadas no grafo gerado, buscando caminhos entre novos pontos escolhidos (SOUSA, 2017). O MRP é probabilisticamente completo, ou seja, se a quantidade de configurações amostradas tende ao infinito, a probabilidade de encontrar um caminho válido, desde que ele exista, se aproxima de 100% (BARRAQUAND et al., 2000). Porém, uma maior quantidade de amostras, apesar de resultar em uma representação mais fiel do espaço de configurações, fará aumentar muito o gasto computacional. Dessa forma, é importante encontrar valores para o tamanho da amostra e para a distância máxima de ligação entre os nós, de modo que resultem em uma boa representação do espaço de configurações, mas ao mesmo tempo não demande muitos recursos computacionais (KAVRAKI et al., 1996).

A abordagem probabilística, como é a deste algoritmo, tem como principal vantagem a velocidade com que pode fornecer soluções para problemas de elevadas dimensões, porém possui como desvantagem encontrar solução sub-ótimas, uma vez que não se conhece completamente o mapa, apenas uma representação dele (SOUSA, 2017). No estudo de Janson; Ichter e Pavone (2015), eles mostram que, para uma certa seleção de parâmetros de sintonia e sequências determinísticas de amostragem de baixa dispersão, o algoritmo retorna um caminho que converge de forma determinista para o custo mínimo, já que o número de pontos passa para o infinito. Muitas variantes desse algoritmo já foram feitas a fim de maximizar sua eficiência, como o melhoramento do método de amostragem e o uso de um planejador local mais eficiente. Além disso, foram propostas variantes para ocasiões específicas, como MAPRM (*Medial Axis Probabilistic Roadmap*), que tem o intuito de ser um método melhor para o planejamento de caminho em locais muito estreitos (WILMARTH; AMATO; STILLER 1999).

Dentre os algoritmos discutidos nessa seção, o MPR se mostra uma das melhores opções para o uso no planejamento de caminho *off-line* para manipuladores e para robôs móveis, tendo se mostrado robusto e eficiente em trabalhos encontrados na literatura, como em Kavraki (1996) e Paiva (2017). No trabalho de Paiva (2017), os algoritmos descritos nesta seção foram testados e o MRP se sobressaiu para aplicações em ambientes de maior complexidade, encontrando caminhos válidos e geralmente de menor esforço cinemático se comparado aos demais. Contudo, este método geralmente apresenta tempo de processamento maior que o de outros dessa seção, como também visto em Paiva (2017). Apesar disso, por se tratar de um planejamento *off-line*, o tempo de processamento não foi tomado como uma variável de grande importância no presente trabalho. A característica de ser

probabilisticamente completo aliado ao fato do tempo de processamento não ser de grande relevância e a facilidade de implementação do algoritmo foram determinantes para a escolha do MRP.

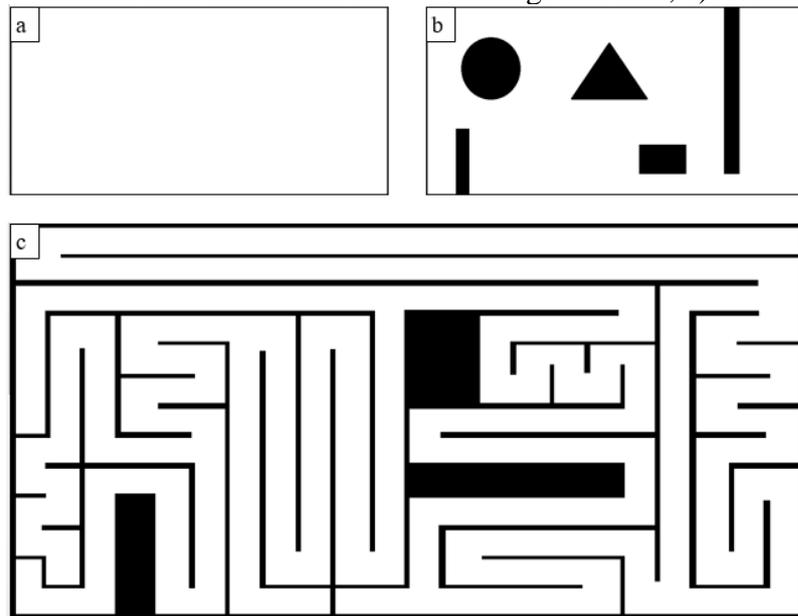
4 MATERIAIS E MÉTODOS

Por meio da observação de uma casa de vegetação presente na Universidade Federal de Lavras, foi elaborado um mapa representativo do ambiente. A imagem foi então tratada a fim de se tornar discretizada. O planejamento do caminho a ser percorrido, o qual foi o enfoque deste trabalho, foi realizado por meio do algoritmo MRP e se deu em âmbito global, uma vez que o ambiente é completamente conhecido de antemão e com obstáculos estáticos. Assim, o caminho foi gerado do ponto de partida ao ponto de chegada antes de se iniciar a simulação do deslocamento pelo trajeto. Além disso, demonstrações com representações de ambientes de diferentes complexidades foram realizadas a fim de comprovar a robustez e eficiência do algoritmo. Este trabalho foi dividido nas seguintes etapas: elaboração e construção da representação do ambiente, configuração dos parâmetros e construção do mapa probabilístico, planejamento do caminho de menor custo entre os pontos que foram especificados e simulação do deslocamento do robô pelo caminho planejado.

4.1 Descrição dos ambientes

Ambientes de diferentes complexidades foram analisados, variando de um ambiente completamente livre, sem quaisquer obstáculos, até um labirinto, visando demonstrar a robustez do método MRP (FIGURA 7). As representações dos locais se deram em forma de mapas de bits (*bitmaps*), onde a imagem contém a descrição de cada pixel e é representada em forma matricial. No Matlab, definiu-se um valor limiar e cada elemento da matriz representante da imagem que superasse o limiar recebeu valor 1, enquanto que os valores inferiores receberam valor 0, tornando a matriz binária. O algoritmo MRP também foi utilizado para planejar um caminho entre dois pontos no mapa da Universidade Federal de Lavras (UFLA). Este mapa foi obtido por meio do Google Maps, serviço de mapas da empresa Google. Posteriormente, a imagem foi discretizada e utilizada para o planejamento do caminho (FIGURA 8).

Figura 7 - Representações de diversos ambientes. a) Ambiente livre de obstáculos; b) Ambiente com obstáculos de diferentes geometrias; c) Labirinto.



Fonte: Do autor (2018).

Figura 8 - Mapa da UFLA. a) Mapa da UFLA gerada pelo Google Maps; b) Mapa da UFLA discretizado.



Fontes: a) Google Maps; b) Adaptado de Google Maps

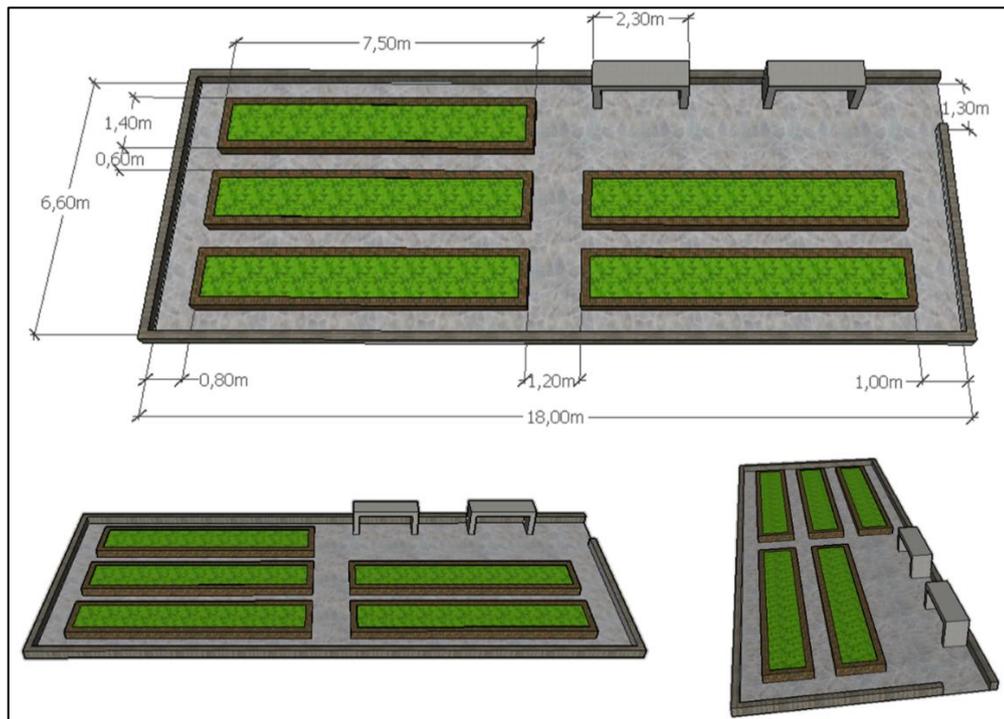
Como o objetivo deste trabalho foi a utilização de plataformas robóticas em casas de vegetação, foi construída uma representação baseada em um desses ambientes, presente no Departamento de Fitopatologia da UFLA. Primeiramente foi realizada uma visita à casa de vegetação para análise do ambiente e medições do mesmo (FIGURA 9). Após obter todas as medidas necessárias, foi feita a modelagem 3D desse ambiente por meio do software SketchUp (FIGURA 10). Por fim foi obtida a representação do ambiente em uma imagem discretizada (FIGURA 11).

Figura 9 - Casa de vegetação do Departamento de Fitopatologia da UFLA.



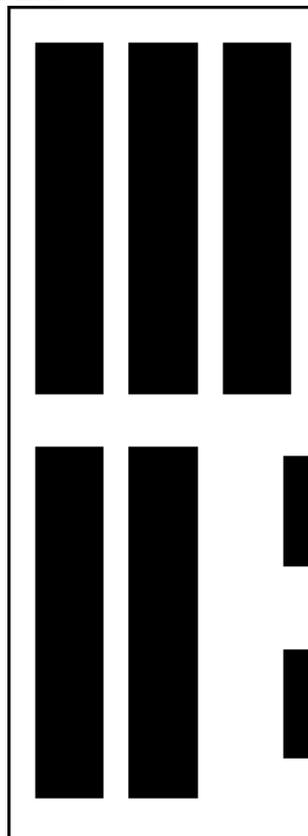
Fonte: Do autor (2018)

Figura 10 - Modelagem 3D referente a casa de vegetação do Departamento de Fitopatologia da UFLA.



Fonte: Do autor (2018)

Figura 11 - Representação discretizada da casa de vegetação do Departamento de Fitopatologia da UFLA.

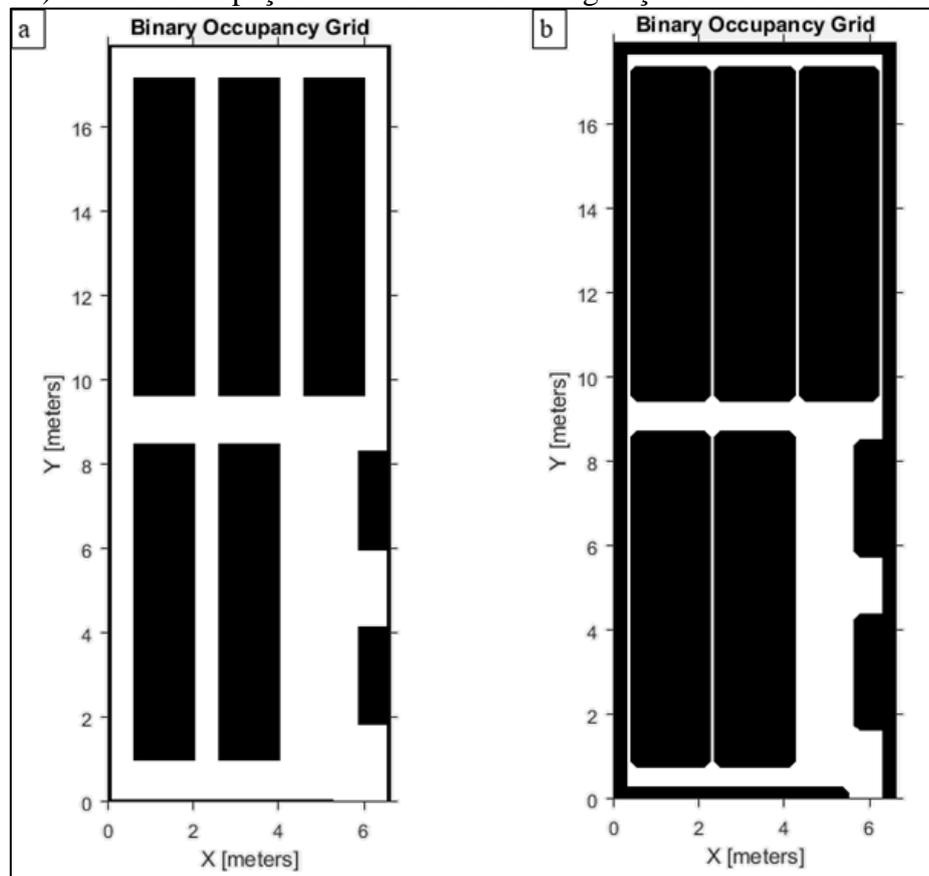


Fonte: Do autor (2018)

4.2 Planejamento do caminho

Após a discretização da imagem representativa do ambiente, foi realizado o planejamento do caminho. Para isso, utilizou-se o método MRP, contido na *Robotic System Toolbox* do software Matlab. No código de programação, foi criada uma Grade de Ocupação Binária (*Binary Occupancy Grid*), onde cada fração, ou pixel, do mapa recebeu valor 1 para ocupado e 0 para desocupado. Nesta etapa também foi definida a resolução do mapa, em células por metro, onde cada célula é uma fração da Grade de Ocupação Binária. Em seguida, o mapa foi inflado na proporção do raio do robô. Nesta etapa, foi informado ao algoritmo o raio do robô e, por meio da função *inflate* da *toolbox* utilizada, uma nova representação do mapa foi gerada, desta vez com os obstáculos inflados (FIGURA 12). Na prática, esse processo é o resultado da restrição em função das dimensões do robô e é relevante para evitar a colisão do mesmo com os obstáculos, uma vez que na abordagem de espaço de configurações o robô é representado como um único ponto.

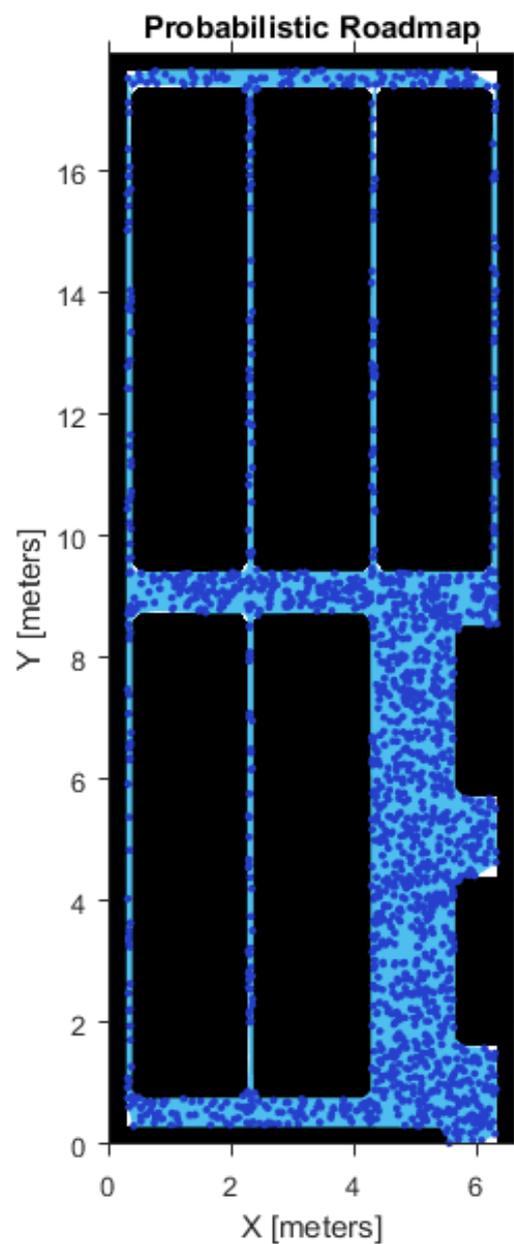
Figura 12 - Grades de Ocupação Binária. a) Grade de ocupação binária da casa de vegetação; b) Grade de ocupação binária da casa de vegetação com obstáculos inflados.



Fonte: Do autor (2018)

Após a obtenção do mapa inflado, foram definidas a quantidade de nós do grafo e a distância máxima de conexão entre eles, além de serem informados os pontos de início e fim do percurso. Dessa forma, o grafo foi gerado e por fim foi utilizada a função *findpath*, que retornou um conjunto de pontos que representavam o menor caminho, em distância euclidiana, entre os pontos informados (FIGURA 13). As implicações da escolha do número de nós e distância máxima de conexão são discutidas posteriormente.

Figura 13 - Mapa de Rotas Probabilístico para a casa de vegetação do Departamento de Fitopatologia da UFLA.



Fonte: Do autor (2018)

4.3 Configuração do simulador

Foi criado um robô móvel simulado utilizando a ferramenta computacional *Robotic System Toolbox*. Este robô possui duas rodas e transmissão diferencial, além de um raio de 20cm, como mostra a Figura 14. As equações 2, 3 e 4 descrevem a cinemática do robô. A matriz gerada na etapa de planejamento, contendo os pontos de referência (*waypoints*) que formam o caminho planejado, foi informada ao simulador. A orientação inicial do robô foi configurada em 160° e foi fornecida ao simulador a pose inicial do robô, contendo o par de pontos iniciais e o ângulo da orientação inicial do mesmo. A seguir, foi criado um controlador do tipo Pura Perseguição (*Pure Pursuit*) para guiar o robô ao longo do caminho planejado e foram configuradas, de forma empírica, a velocidade linear desejada (0,30m/s) e a velocidade angular máxima (1,00rad/s), funcionando como restrições de velocidade que teria uma plataforma robótica real. Além disso, foi definida para o controlador a propriedade distância de visão antecipada (*look ahead*) de 0,80m. A distância de visão antecipada é a propriedade mais importante neste tipo de controlador, pois define quão longe o robô deverá olhar no caminho planejado, a partir de sua localização atual, para calcular os comandos de velocidade angular que devem ser tomados. Dessa forma, o robô consegue cortar cantos através da rota definida, trabalhando como um método de suavização do caminho (FIGURA 15).

Em seguida, foi definido um raio de 0,10m como margem de erro para o ponto de chegada. O algoritmo calcula continuamente a distância entre a posição atual do robô e o ponto de chegada, fazendo com que o robô pare quando a distância calculada é menor que este raio. O controlador, que trabalhou a uma frequência configurada de 10Hz, calculou os comandos de controle, forneceu os sinais para o robô e os utilizou para conduzi-lo pelo caminho planejado até atingir o alvo.

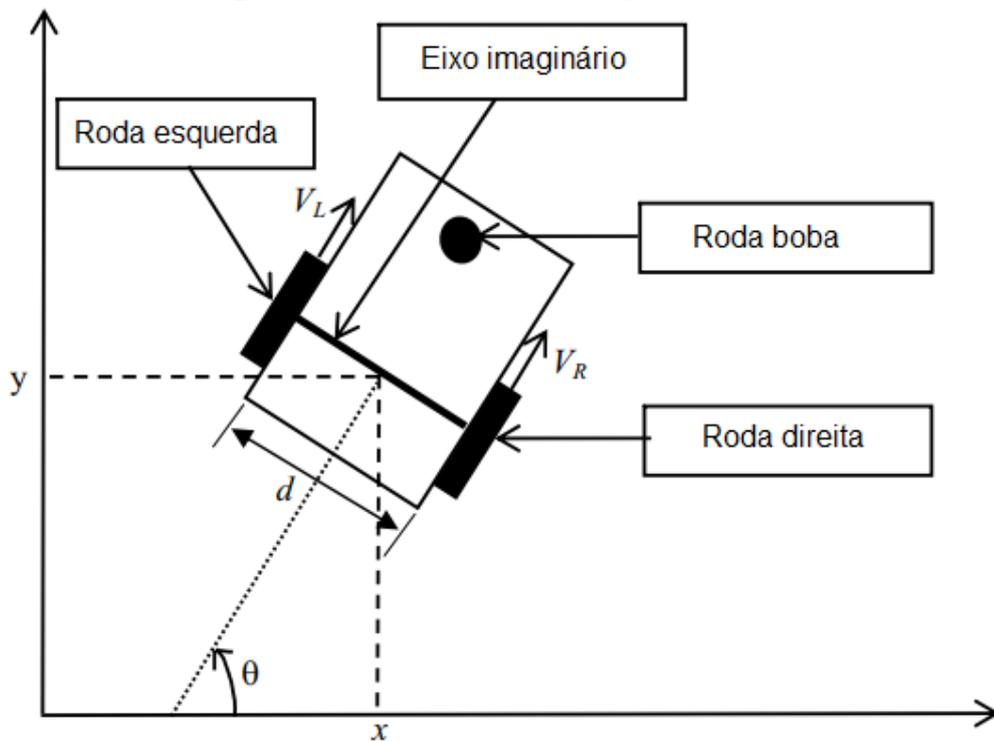
$$\begin{bmatrix} x_{i+1} \\ y_{i+1} \\ \theta_{i+1} \end{bmatrix} = \begin{bmatrix} x_i \\ y_i \\ \theta_i \end{bmatrix} + \begin{bmatrix} \Delta s \times \cos(\theta_i + \Delta\theta) \\ \Delta s \times \sin(\theta_i + \Delta\theta) \\ \Delta\theta \end{bmatrix} \quad (2)$$

$$\Delta s = \frac{(V_{dir} + V_{esq})}{2} \quad (3)$$

$$\Delta\theta = \frac{(V_{dir} - V_{esq})}{d} \quad (4)$$

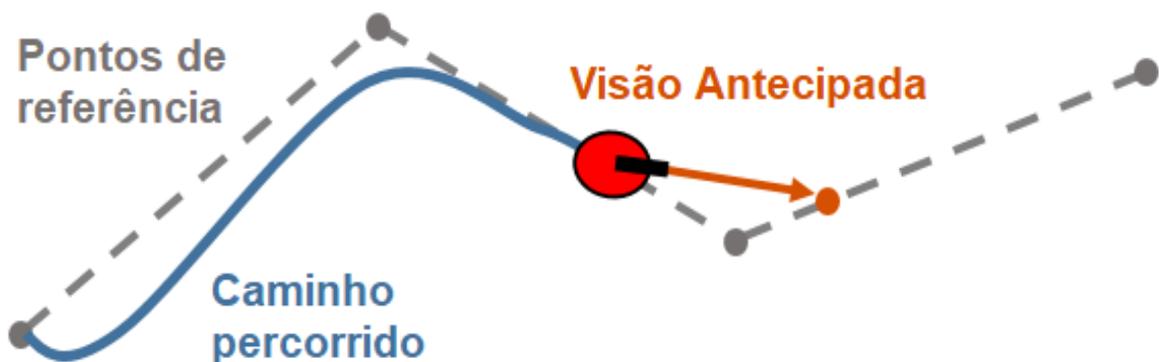
Onde θ é o ângulo entre o ponto de guiamento do robô e o eixo x, V_{dir} e V_{esq} as velocidades das rodas direita e esquerda, respectivamente, Δs a velocidade linear e $\Delta\theta$ a velocidade angular do robô.

Figura 14 - Robô móvel com tração diferencial



Fonte: Adaptado de Mathew e Hiremath (2016)

Figura 15 - Funcionamento do parâmetro de visão antecipada (*look ahead*)



Fonte: Adaptado de www.mathworks.com/help/robotics/ug/pure-pursuit-controller.html

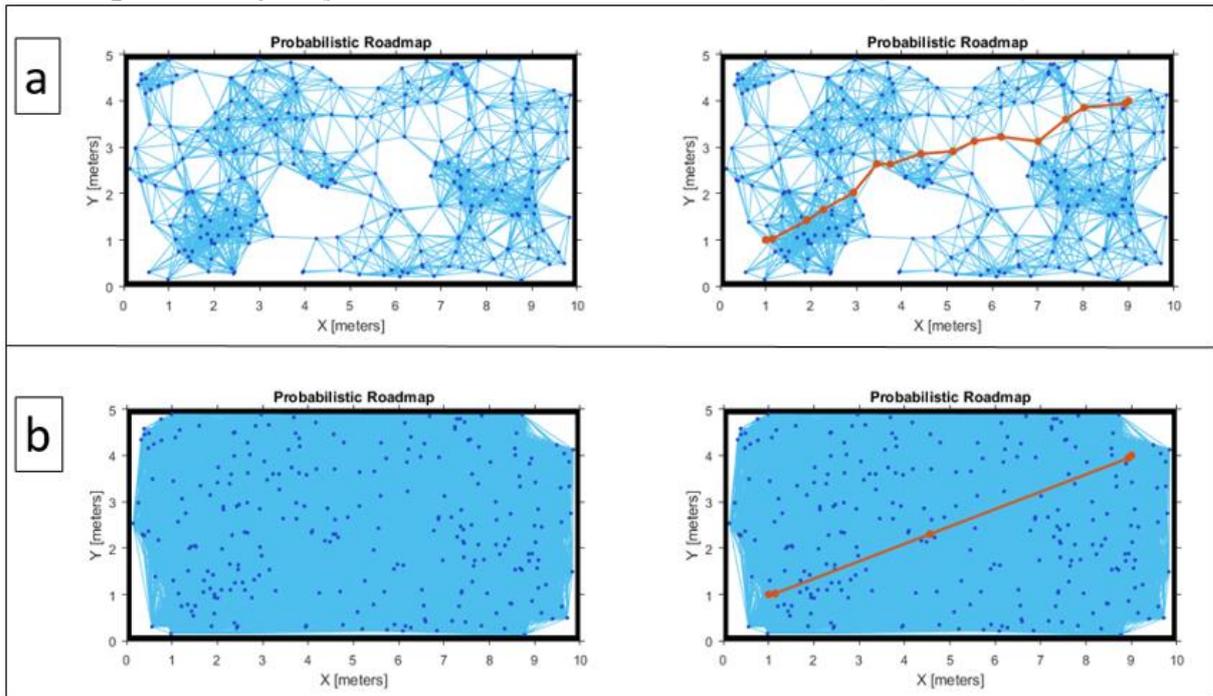
5 RESULTADOS E DISCUSSÃO

Nesta seção foi avaliado o correto funcionamento do método MRP para cada um dos ambientes, bem como suas configurações e resultados. Ao tempo de processamento não foi imputada grande importância, já que utilizou apenas o planejamento *off-line*, com ambientes estáticos, sendo o planejamento inteiramente realizado antes da efetiva operação do robô.

5.1 Aplicação do algoritmo MRP em ambiente livre de obstáculos

Para este cenário foram testadas duas opções de configuração do algoritmo, variando o tamanho máximo da conexão entre os nós, a fim de ilustrar sua influência no grafo gerado. A quantidade de nós e os nós amostrados foram iguais nos dois casos. O MRP foi executado com 250 nós, porém no primeiro caso foi utilizada distância máxima de conexão de 1m, contra 8m no segundo. Foi observada diferença de densidade entre os grafos gerados (FIGURA 16). Essa diferença se deu pela menor quantidade de conexões no grafo em que a distância máxima de conexão era menor. Também houve diferença no tempo de execução da fase de aprendizagem do algoritmo, onde o segundo caso demandou um tempo de execução consideravelmente maior que o primeiro caso, em razão da quantidade de conexões. Já na fase de questionamento não houve grande diferença no tempo de execução dos dois casos. Esses resultados mostram que, mesmo para um grafo de maior densidade, o tempo de questionamento ainda é baixo se comparado ao tempo de execução da etapa de aprendizagem. Dessa forma, é confirmada na prática a teoria do método MRP de que o maior gasto computacional se concentra na etapa de aprendizagem, assim como afirmado por Kravaki et al., 1996. A distância euclidiana do segundo caso é menor, sendo um caminho mais retilíneo se comparado ao caminho do primeiro caso, pois há uma representação melhor do ambiente no segundo caso. As distâncias euclidianas de ambos os casos, assim como outros dados resultantes, podem ser vistas na Tabela 1.

Figura 16 - Aplicação do MRP no ambiente sem obstáculos. a) Caso 1; b) Caso 2.



Fonte: Do autor (2018)

Tabela 1 – Parâmetros e resultados para aplicação do MRP no cenário livre de obstáculos.

Caso	Número de nós	Distância máxima de conexão (m)	Tempo de execução da etapa de aprendizagem (s)	Tempo de execução da etapa de questionamento (s)	Distância euclidiana (m)
1	250	1	0,3109	0,0364	8,9170
2	250	8	5,0784	0,0266	8,5532

Fonte: Do autor (2018)

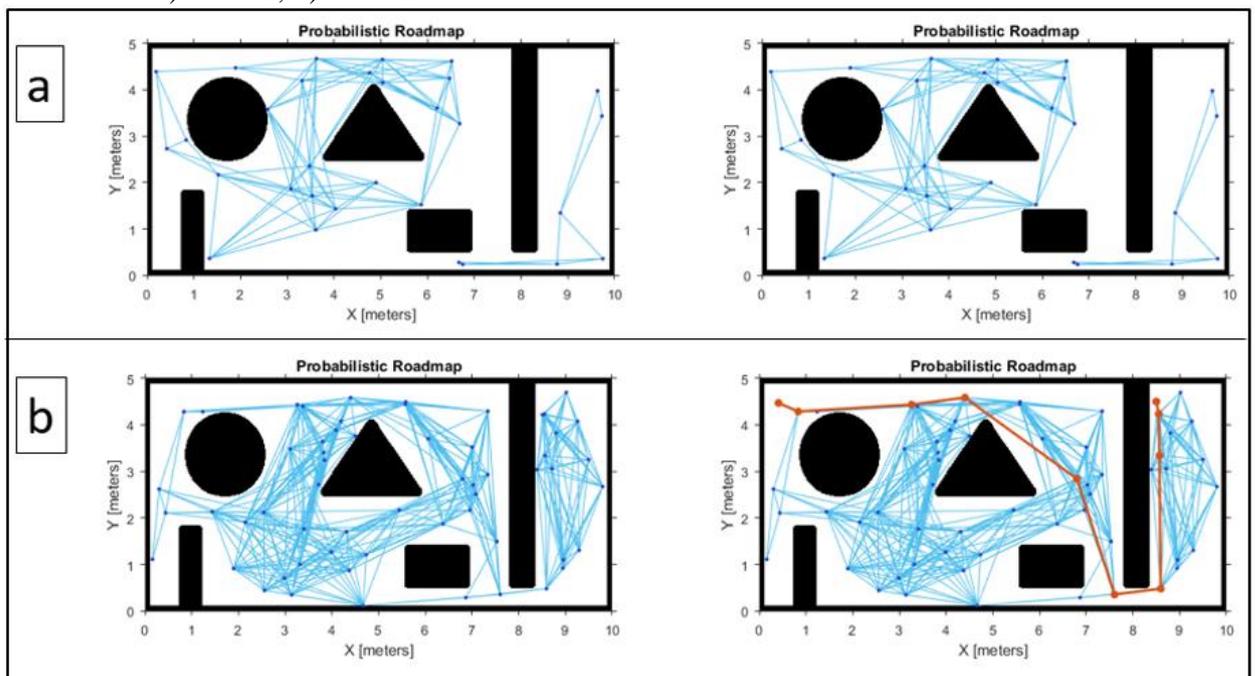
5.2 Aplicação do algoritmo MRP em ambiente com obstáculos geométricos

Neste cenário foram incluídos obstáculos em forma de figuras geométricas e realizadas variações no número de nós do grafo, ou amostras do ambiente. Assim como observado no tópico anterior, foi encontrada diferença na densidade do grafo gerado, uma vez que o grafo com menor número de nós possui menos conexões e consequentemente, menor densidade. No primeiro caso, onde foi usado um número de nós igual a 30 e distância de conexão de 3 metros, o algoritmo não conseguiu encontrar um caminho válido, pois não há conectividade em toda a extensão do percurso entre os pontos inicial e final (FIGURA 17a). Isso mostra que o ambiente não foi bem representado por esta quantidade de amostras, sendo necessário aumentar o número de nós do grafo. Esse aumento foi realizado no segundo caso,

passando de 30 para 60 nós amostrados e mantendo a distância máxima de conexão em 3 metros. Desta vez o algoritmo conseguiu encontrar um caminho válido (FIGURA 17b).

Os parâmetros encontrados em ambos os casos são apresentados na Tabela 2. A distância euclidiana do primeiro caso não é apresentada, pois não houve conectividade e consequentemente, não foi possível encontrar um caminho válido.

Figura 17 - Aplicação do MRP no ambiente com obstáculos geométricos de diversas formas. a) Caso 1; b) Caso 2.



Fonte: Do autor (2018)

Tabela 2 – Parâmetros e resultados da aplicação do MRP no cenário com obstáculos geométricos.

Caso	Número de nós	Distância máxima de conexão (m)	Tempo de execução da etapa de aprendizagem (s)	Tempo de execução da etapa de questionamento (s)	Distância euclidiana (m)
1	30	3	0,0933	0,0214	-
2	60	3	0,1579	0,0312	14,6505

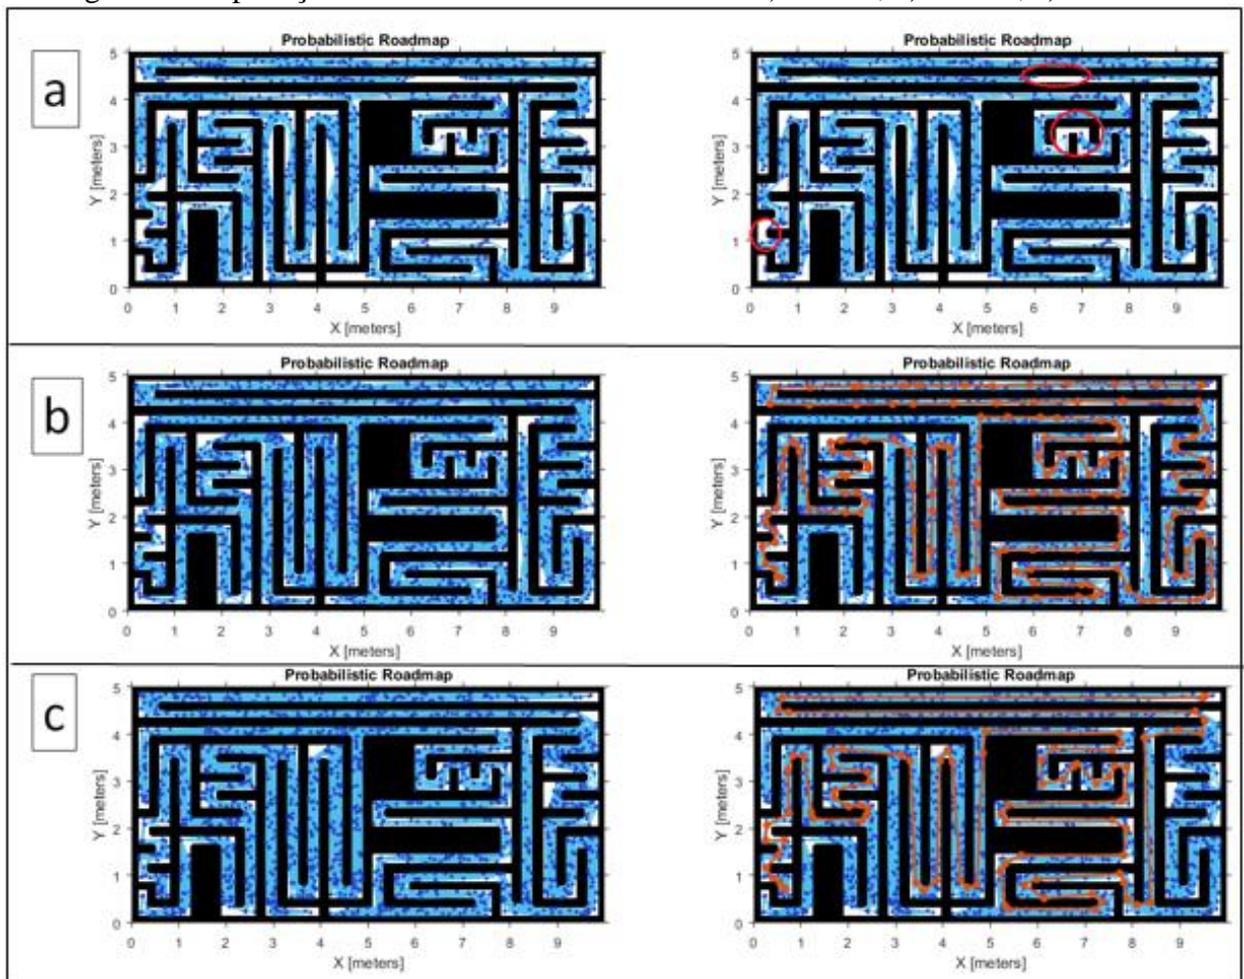
Fonte: Do autor (2018)

5.3 Aplicação do algoritmo MRP em um labirinto

A fim de verificar o comportamento do algoritmo para ambientes mais complexos, o MRP foi usado para planejamento de caminhos em um labirinto. Foram testados casos com distância máxima de conexão de 1m e 10m e com número de nós de 1000 e 1500. No

primeiro caso, utilizando 1000 nós, o algoritmo não conseguiu encontrar um caminho válido, tendo diversos pontos de quebra de conectividade, marcados em vermelho na figura. Já nos casos dois e três, utilizando 1500 nós, foi possível encontrar caminhos válidos, entretanto o tempo de execução da fase de aprendizagem no caso três foi consideravelmente maior que o do caso dois, em razão do aumento da distância máxima de conexão (FIGURA 18). Os parâmetros de aplicação do MRP e os resultados estão na Tabela 3.

Figura 18 - Aplicação do MRP no ambiente labirinto. a) Caso 1; b) Caso 2; c) Caso 3.



Fonte: Do autor (2018)

Tabela 3 – Parâmetros e resultados da aplicação do MRP no cenário labirinto.

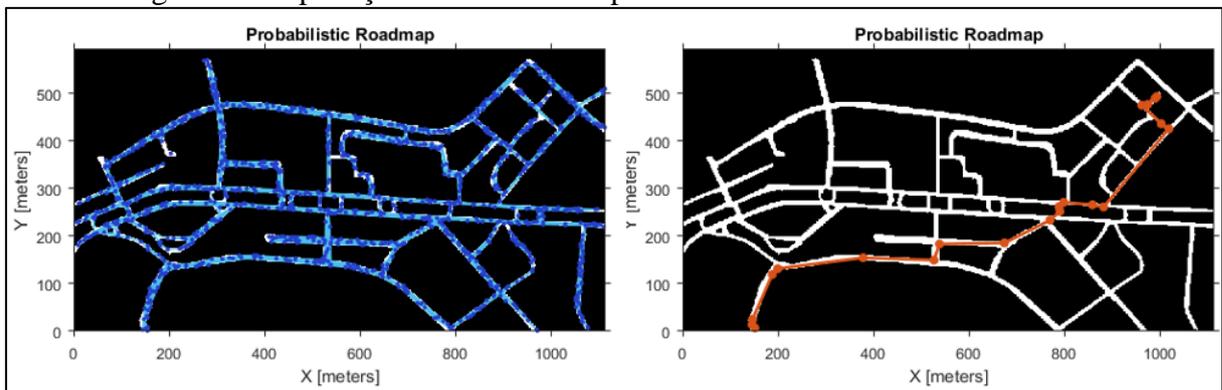
Caso	Número de nós	Distância máxima de conexão (m)	Tempo de execução da etapa de aprendizagem (s)	Tempo de execução da etapa de questionamento (s)	Distância euclidiana (m)
1	1000	1	2,5915	0,0231	-
2	1500	1	5,4760	0,4179	78,0515
3	1500	10	204,8583	0,7691	72,2846

Fonte: Do autor (2018)

5.4 Aplicação do algoritmo MRP no mapa da UFLA

Buscando demonstrar a utilização do algoritmo MRP também em ambientes reais, foi usado como cenário o mapa da Universidade Federal de Lavras (FIGURA 19). O algoritmo teve como parâmetros 1200 nós e distância máxima de conexão de 300m. O tempo de execução da fase de aprendizado foi de 26,6430s e o da fase de questionamento foi de 0,1997s. A distância euclidiana foi de 1218,7m.

Figura 19 - Aplicação do MRP no mapa da Universidade Federal de Lavras



Fonte: Do autor (2018)

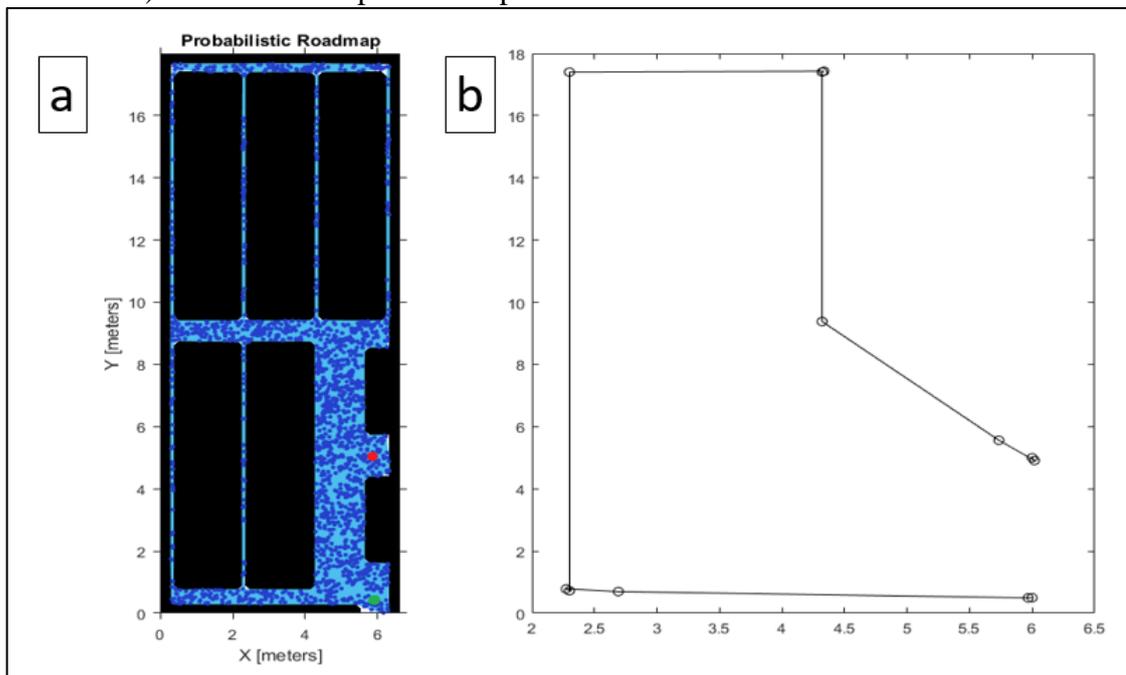
5.5 Aplicação do algoritmo MRP em uma casa de vegetação do Departamento de Fitopatologia da UFLA

Enquanto objetivo principal deste trabalho, o planejamento do caminho neste cenário foi o que recebeu maior atenção. Foram configurados parâmetros de 1700 nós e distância de conexão de 17m (FIGURA 20). A execução da etapa de aprendizado durou 167,8367s e a da etapa de questionamento 0,7020s. A distância euclidiana do caminho foi de 35,4429m. Foram também definidos os parâmetros para a realização da simulação, onde a velocidade linear desejada foi definida como 0,30m/s e a angular foi definida como 1rad/s. Além disso, foi definido o parâmetro de visão antecipada como 0,80m, o raio a ser atingido no ponto de entrada como 0,10m e o raio do robô como 0,20m.

Neste ambiente, o objetivo foi que o robô conseguisse se locomover no interior da casa de vegetação, passando entre as fileiras (FIGURAS 9 e 10). Assumiu-se que o robô consiga realizar a aplicação dos agentes químicos a partir de ambas suas laterais, sendo melhor realizar o trajeto entre duas fileiras do que passando por cada uma individualmente. Foi gerado o grafo usando o algoritmo MRP e definidos uma série de pontos intermediários

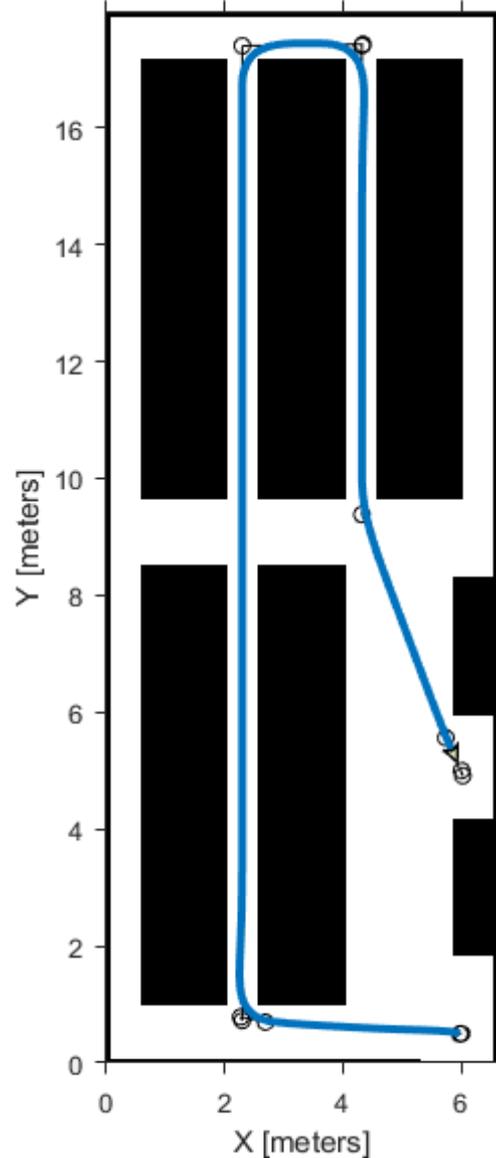
pelos quais o robô deveria passar, simulando uma aplicação completa em todas as fileiras da casa de vegetação usada como modelo (FIGURA 20). Dessa forma, a fase de aprendizagem do algoritmo foi executada uma vez e a de questionamento sucessivas vezes, para encontrar um caminho válido dos pontos A até B, depois de B até C, C até D etc., até que se formasse o caminho completo. Por fim, o conjunto de pontos descrevendo o caminho total foi informado ao simulador, onde foram ajustados os parâmetros e deu-se início a simulação (FIGURA 21).

Figura 20 - Aplicação do MRP no mapa da casa de vegetação. a) Mapa de rotas gerado; b) Caminho a ser percorrido pelo robô.



Fonte: Do autor (2018)

Figura 21 - Caminho percorrido (em azul) pelo robô.



Fonte: Do autor (2018)

Assim como observado por Paiva 2017, que testou diferentes algoritmos em quatro ambientes de variadas complexidades, o MRP se mostrou eficaz na busca de caminhos válidos em todos os ambientes analisados. Além disso, o uso deste algoritmo pode também ser estendido a aplicações em manipuladores de vários graus de liberdade, como afirmado por Kavraki et al., 1996.

O planejamento de caminho também pode ser realizado por outros métodos, tais como o algoritmo A*, Campo Potencial Artificial, Espuma Aleatória, AGs etc. Esses algoritmos foram utilizados nos trabalhos de Pacheco e Costa (2002), Paiva (2017) e Silveira (2016) e se mostraram eficientes para o planejamento de caminhos nos ambientes propostos por esses

autores. Neste contexto, é importante ressaltar o trabalho de Wilmarth, Amato e Stiller (1999), onde trabalham com o algoritmo *Medial Axis Probabilistic Roadmap* (MAPRM). Este algoritmo é uma variante do MRP e segundo estes autores, modifica a forma de amostragem dos nós, fazendo com que ela seja concentrada no eixo médio das frações livres do ambiente de estudo. Isso, de acordo com os resultados encontrados pelos autores do estudo, aumenta o desempenho do método, se comparado ao MRP tradicional, quando utilizado em ambientes com passagens estreitas.

No que diz respeito a utilização de robôs móveis no ambiente foco deste estudo, um trabalho de destaque por seu pioneirismo é o de Mandow et al., (1996). Foi elaborado e construído um robô, de nome Aurora, capaz de se locomover por entre as fileiras das casas de vegetação presentes na Universidade de Málaga. Este robô foi equipado com sensores ultrassônicos frontais e laterais e câmera de vídeo para evitar colisões durante seu deslocamento e podia trabalhar de forma autônoma ou controlada a distância. Tal como no presente trabalho, Mandow et al., (1996) teve como objetivo a automatização de tarefas potencialmente danosas à saúde humana.

6 CONCLUSÃO

Neste trabalho foi apresentada a implementação do algoritmo Mapa de Rotas Probabilístico para o planejamento de caminho para um robô móvel simulado de duas rodas e tração diferencial. Por meio da aplicação do algoritmo nos diversos mapas utilizados, foram evidenciadas a robustez e a eficiência do mesmo, uma vez que o planejamento do caminho se deu de forma extremamente satisfatória. O ambiente principal do estudo, uma casa de vegetação, se caracteriza por ser um ambiente estático e conhecido previamente, características indispensáveis para o planejamento de caminhos do tipo *off-line*, utilizado neste trabalho. Apesar disso, a presença das fileiras no ambiente constituiu um desafio para o algoritmo, uma vez que as distâncias entre elas forma corredores de pouca largura, se comparados ao diâmetro do robô simulado. Dessa forma, foi necessário configurar parâmetros mais altos para o algoritmo, buscando melhor representação do ambiente e encontrar os pontos de conectividade do mesmo. Tal escolha reflete uma das principais características do MRP, a de ser um método probabilisticamente completo, garantindo encontrar um caminho, caso ele exista, quando a quantidade de nós amostrados cresce ao infinito. Entretanto, escolher parâmetros mais altos fez com o que tempo de execução da fase de aprendizado fosse razoavelmente grande, mas por se tratar de um planejamento *off-line*, o tempo de execução

torna-se uma característica de pouca importância neste contexto. Ainda assim, meios mais eficazes de amostragem podem ser utilizados em trabalhos futuros. O caminho planejado para a casa de vegetação mostrou ter poucos pontos de rotação, o que facilita o deslocamento do robô, uma vez que grande parte da movimentação se dá apenas em movimentos de translação. Entretanto, esses pontos de rotação se mostraram bruscos, formando ângulos retos, em sua maioria. Dado o formato de construção das casas de vegetação, esta dificuldade não seria facilmente contornada, mas o uso de métodos para a suavização do caminho também poderia se fazer presente futuramente.

A simulação do deslocamento do robô no ambiente se mostrou uma ferramenta relevante na apreciação da atuação dos parâmetros escolhidos para o controlador implementado pela *toolbox* utilizada. Dessa forma, uma futura construção física do robô e a configuração de seus parâmetros se torna facilitada, uma vez que já é conhecido o deslocamento esperado do robô físico, tomando como base o deslocamento do simulado. Contudo, isso somente é válido desde que se utilize os parâmetros físicos do robô simulado.

Por fim, este estudo mostrou que o método utilizado pode ser um grande aliado no planejamento de caminho para utilização de robôs móveis na aplicação de agentes químicos de controle de pragas agrícolas em casas de vegetação. Para a utilização desses robôs, é importante que se conheça o ambiente de antemão, que o robô construído respeite as características do ambiente e que se utilize um controlador considerando as restrições cinemáticas do robô.

6.1 Perspectivas futuras

A perspectiva de uso futuro da robótica móvel na agricultura é vasta, podendo ser utilizada para uma grande gama de aplicações e com variedade de métodos de planejamento de rotas. A utilização de métodos que façam uso de visão computacional e sensores como os ultrassônicos e os de odometria podem deixar a aplicação mais segura e precisa. A utilização de sensores pode trazer algumas características importantes ao robô, como a possibilidade da realização do planejamento *on-line* do percurso, eliminando a necessidade de conhecimento prévio do ambiente, tornando possível a utilização do robô em ambientes diferentes sem a necessidade de atualizar a programação realizada para o mesmo. Com relação ao trabalho desenvolvido, apesar de encontrados resultados satisfatórios para um primeiro momento,

algumas sugestões para a continuação de seu desenvolvimento e implementação de melhorias são dadas a seguir:

- Elaboração e construção de uma plataforma robótica com implementação de controlador para seu deslocamento e pulverização;
- Elaboração de um sistema retrátil, a ser acoplado ao robô, para a pulverização dos agentes químicos;
- Utilização de métodos variantes do MRP, se ainda optar por um planejamento *off-line*, como o MAPRM, para a melhoria na forma de amostragem, podendo permitir encontrar caminhos qualitativamente semelhantes, porém com menor custo computacional.
- Implementação de métodos que utilizem visão computacional e redes neurais artificiais ou afins, buscando melhorias na locomoção e adição de novas funcionalidades, tais como a verificação do estado de saúde das plantas, verificação das fases de crescimento e possivelmente até colheita. Isso permitiria também aumentar a precisão do processo de pulverização, pois o robô poderia pulverizar apenas as plantas que identificasse como afetadas. Além disso, usando tais métodos em conjunto com sensores acoplados à plataforma, o planejamento dos percursos poderia se dar de forma *on-line*.

7 REFERÊNCIAS

- ABRAHÃO, G. Q. S.; MEGDA, P. T.; BECKER, M. O Uso de Algoritmos A* e Field A* em Robôs Agrícolas. In: **Congresso Nacional de Engenharia Mecânica**. Campina Grande, 2010.
- ACACCIA, G. M. et al. Mobile robots in greenhouse cultivation inspection and treatment of plants. In: **International Workshop on Advances in Service Robotics**, Itália, 2003.
- ADÔRNO, B. V.; BORGES, G. A. Um método de planejamento de trajetória para robôs móveis através de passeios aleatórios adaptativos e mapa de rotas. In: Congresso Brasileiro de Automática, 2006, Brasília **Anais do Congresso Brasileiro de Automática**. Brasília, 2006.
- ADÔRNO, B.V. **Planejamento probabilístico de rotas no espaço de configuração e sua aplicação em robótica móvel**. 2008. 124 p. Dissertação (Mestrado em Engenharia Elétrica) - Universidade de Brasília, Brasília, DF, 2008.
- ALVES, R. J. F. **Rastreamento de Agrobots em estufas agrícolas usando modelos ocultos de Markov: Comparação do desempenho e da correção dos algoritmos de Viterbi e Viterbi com janela de observações deslizante**. 2015. 78 p. Dissertação (Mestrado em Computação Aplicada) – Universidade Estadual de Ponta Grossa, Ponta Grossa, PR, 2015.
- AYRES, L. M. et al. Desenvolvimento e implementação de uma arquitetura de navegação para um robô móvel utilizando comandos de voz, algoritmo A* e o controlador Backstepping. In: **XIII Simpósio Brasileiro de Automação Inteligente**, Porto Alegre, RS, 2017.
- BARRAQUAND, J.; KAVRAKI, L.; MOTWANI, R. A random sampling scheme for path planning. **The International Journal of Robotics Research**, v. 16, p. 759–774, 2000.
- BARRAQUAND, J.; LANGLOIS, B.; LATOMBE, J. C. Numerical Potencial Field Techniques for robot path planning. **IEEE Transactions on Systems, Man, And Cybernetics**, v. 22, p. 224-241, 1992.
- BERCHTOLD, S.; GLAVINA, B. A scalable optimizer for automatically generated manipulator motions. **International Conference on Intelligent Robots and Systems**, p. 1796-1802, Germany, 1994.
- BOBROW, J.E., DUBOWSKY, S.; GIBSON, J.S. Time-optimal control of robotic manipulators along specified paths. **The International Journal of Robotics Research**, v. 4, p. 554-561, 1985.
- BORENSTEIN, J.; KOREN, Y. The vector field histogram-fast obstacle avoidance for mobile robots. **Robotics and Automation**, v. 7, n. 3, p. 278– 288, 1991.
- CANNY J., DONALD B. Simplified Voronoi diagrams. **Discrete & Computational Geometry**, v. 3, p. 219-236, 1988.
- CHOSSET, H. et al. **Principles of Robot Motion: Theory, Algorithms and Implementations**, MIT Press, 2005.

CUI, S. G.; WANG, H.; YANG, L. A Simulation Study of A-star Algorithm for Robot Path Planning. **In: 16th International Conference on Mechatronics Technology**, p. 506-510, 2012.

DEICU, L. E. **Planejadores de caminho baseados em campos potenciais**. 2012. Monografia (Bacharel em Engenharia da Computação) – Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, RS, 2012.

DUCHON, F. et al. Path planning with modified A star algorithm for a mobile robot. **Procedia Engineering**, v. 96, p. 59-69, 2014.

ELFES, A. Using occupancy grids for mobile robot perception and navigation. **Computer**, v. 22, p. 46-57, 1989.

GASPARETO, M. J. **Seleção de atributos em imagens coletadas sob condições de iluminação não controlada e sua influência no desempenho de classificadores NAIVE BAYES para identificação de objetos em estufas agrícolas**. 2013. Dissertação (Mestrado em Computação Aplicada) – Universidade Federal de Ponta Grossa, 2013.

GASPARETTO, A. et al. Path Planning and Trajectory Planning Algorithms: A General Overview. **Research Gate**, v. 29, p. 3-27, 2015.

GOLÇALVES, M. A. **Algoritmo A-Estrela de estado híbrido aplicado à navegação autônoma de veículos**. 2013. 64 p. Dissertação (Mestre em Informática) – Universidade Federal do Espírito Santo, Vitória, ES, 2013.

GONZALEZ, R. et al. Navigation techniques for mobile robots in greenhouses. **Applied Engineering in Agriculture**, v. 25, p. 153-165, 2009.

HACHOUR, O. The proposed genetic FPGA implementation for path planning of autonomous mobile robot. **Circuits, Systems, and Signal Processing**, v. 2, p. 151-167, 2008.

HOLLAND, J. **Adaptation in natural and artificial systems**. Ed. University of Michigan Press. 232p. Ann Arbor, Estados Unidos da América, 1975.

JANSON, L.; ICHTER, B.; PAVONE, M. Deterministic sampling-based motion planning: Optimality, complexity, and performance. **The International Journal of Robotics Research**, v. 37, 16 p., 2017.

KAVRAKI, L. E. et al. Probabilistic roadmaps for path planning in high-dimensional configuration spaces. **IEEE Transactions on Robotics and Automation**, v. 12, n. 4, p. 566-580, 1996.

KAVRAKI, L. E.; KOLOUNTZAKIS, M. N.; LATOMBE, J. C. Analysis of probabilistic roadmaps for path planning. **IEEE Transactions on Robotics and Automation**, v. 14, p. 166–171, 1998.

KAVRAKI, L.; LATOMBE, J. C. Randomized preprocessing of configuration space for fast path planning. **In: IEEE International Conference on Robotics and Automation**, p. 2138-2145, San Diego, 1994.

KHATIB, O. Real-time obstacle avoidance for manipulators and mobile robots. **The International Journal of Robotics Research**, v. 5, p. 396-404, 1985.

KUIPERS, B; BYUN, Y. T. A robot exploration and mapping strategy based on a semantic hierarchy of spatial representations. **Journal of Robotics and Autonomous Systems**, v.8, p. 47-63, 1991.

LATOMBE, J. C. **Robot Motion Planning**. Boston: Kluwer Academic Publishers, 1990.

LAUMOND, J. P.; TAIX, M.; JACOBS, P. A motion planner for car-like robots based on a global/local approach. **International Workshop Intelligent Robots and Systems**, p. 765-733, 1990.

LAVALLE, S. M. **Planning Algorithms**. Cambridge University Press., 2006.

LAVALLE, S. M. **Rapidly-exploring random trees: A new tool for path planning**. Iowa State University. 4p, 1998.

LENTEREN, J. C.; WOETS, J. Biological and integrated pest control in greenhouses. **Annual Reviews**, v. 33, p. 239-269, 1988.

LOZANO-PÉREZ, T.; WESLEY, M. A. Na algorithm for planning collision-free paths among polyhedral obstacle. **Communications of the ACM**, v. 22, p. 560-570, 1979.

MAHADEVAN, B.; NARENDRAN, T. T. Design of an automated guided vehicle based material handling system for a flexible manufacturing system. **International Journal of Production Research**, v. 28, n.º 9, p. 1611-1622, 1990.

MANDOW, A. et al. The autonomous mobile robot AURORA for greenhouse operation. **IEEE Robotics & Automation Magazine**, v. 3, p.18-28, 1996.

MARTIN, M. C.; MORAVEC, H. P. **Robot evidence grids**, 1996.

MARTINS, A. D M. et al. Comparação entre tempos de localização de objetos em imagens. In: **VI Simpósio Brasileiro de Automação Inteligente, 2003**.

MASEHIAN, E.; KATEBI, Y. Robot motion planning in dynamic environments with moving obstacles and target. **International Journal of Mechanical Systems Engineering**, v. 1, p. 20-25, 2007.

MATARIC, M. J. **A distributed model for mobile robot environment-learning and navigation**. 1990. 129p. Dissertação (Mestre em Engenharia Elétrica e Ciências da Computação) - Cambridge, MA, 1990.

MEHTA, S. S.; BURKS, T.F.; DIXON, W. E. Vision-based localization of a wheeled mobile robot for greenhouse applications: A daisy-chaining approach. **Computers and electronics in agriculture**, v. 63, p. 28-37, 2008.

MITCHELL, M. **An introduction to genetic algorithms**. Ed. MIT Press. 221p. Londres, Inglaterra, 1999.

MORAVEC, H. Sensor fusion in certainty grids for mobile robots. **In: Sensor Devices and Systems for Robotics. Springer Berlin Heidelberg**, v. 52, p. 253–276, 1989.

MORAVEC, H.; ELFES, A. High resolution maps from wide angle sonar. **In: Robotics and Automation. Proceedings. IEEE International Conference**, v. 2, p. 116–121, 1985.

NIKU, S. B. **Introdução à robótica: análise, controle e aplicações**. Ed. LTC, 2. ed., 402 p., Rio de Janeiro, 2013.

OCHI, L. S. **Algoritmos genéticos: origem e evolução**. Disponível em: <<http://www.sbmec.org.br/bol/bol-2/artigos/satoru/satoru.html#algoritmos>>. Acesso em: 08 de Março de 2018.

PACHECO, R. N.; COSTA, A. H. R. Navegação de robôs móveis utilizando o método de campos potenciais. **Research Gate**, 2002.

PAIVA, L. S. **Análise e Geração de Caminho Mínimo Aplicado à Navegação de Veículos Terrestres**. 2017. 141 p. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Lavras, Lavras, MG, 2017.

PIO, J. L. S.; CASTRO, T. H. C.; CASTRO JÚNIOR, A. N. A Robótica Móvel como Instrumento de Apoio à Aprendizagem de Computação. **In: XVII Simpósio Brasileiro de Informática na Educação – SBIE**. Departamento de Ciência da Educação – Universidade Federal do Amazonas, Manaus, AM, 2006, p. 497-506.

QUEIRÓS, M. F. R. **Planejamento de caminho para robôs móveis autônomos em ambientes conhecidos e estruturados**. 2014. 98p. Dissertação (Mestre em Engenharia Eletrônica Industrial e Computadores) – Universidade do Minho, Braga, Portugal, 2014.

RAJA, P.; PUGAZHENTHI, S. Optimal path planning of mobile robots: A review. **International Journal of Physical Sciences**, v. 7, p. 1314-1320, 2012.

ROCHA, R. P. P. **Desenvolvimento de um sistema de gestão de AGVs**. 1998. Dissertação (Mestrado em Engenharia Eletrotécnica e de Computadores) -Faculdade de Engenharia da Universidade do Porto, 1998.

SALES, D; OSÓRIO, F.; WOLF, D. **Topological autonomous navigation for mobile robots in indoor environments using ann and fsm**. **In: Proceedings of the I Brazilian Conference on Critical Embedded Systems (CBSEC)**, São Carlos, Brazil, 2011.

SAMMONS, P. J.; FURUKAWA, T.; BULGIN, A. Autonomous pesticide spraying robot for use in a greenhouse. **In: Australian Conference on Robotics and Automation**, Austrália, 2005.

SANCHEZ-HERMOSILLA, J. et al. A mechatronic description of an autonomous mobile robot for agricultural tasks in green-houses. **Mobile Robots Navigation**, p. 583-608, 2010.

SANTANA, A. M. **Localização e planejamento de caminhos para um robô humanoide e um robô escravo com rodas**. 2007. 63 p. Dissertação (Mestrado em Ciências) – Universidade Federal do Rio Grande do Norte, Natal, RN, 2007.

SECCHI, H. A. **Una Introducción a los Robots Móviles**. 2008. 81 p. Monografía - Instituto de Automática – INAUT Universidade Nacional de San Juan – UNSJ – Argentina, 2008.

SHIN, K.G.; MCKAY, N.D. Minimum-time control of robotic manipulators with geometric path constraints. **IEEE Transactions on Automatic Control**, v. 30, n. 6, p. 531-541, 1985.

SICILIANO, B. et al. **Robotics - Modelling, Planning and Control**. Londres, 2009.

SIEGWART, R; NOURBAKHSI, I., R. **Introduction to Autonomous Mobile Robots**. Inglaterra, 2004.

SILVEIRA, Y. S. **Um novo método de planejamento de caminho para robôs baseado em espuma probabilística**, 2016. 51 p. Dissertação (Mestrado em Engenharia Mecatrônica) – Universidade Federal do Rio Grande do Norte, Natal, RN, 2016.

SOUSA, K. A. **Planejamento de movimento para robôs móveis baseado em uma representação compacta da rapidly-exploring random tree (RRT)**. 2017. 55p. Dissertação (Mestre em Engenharia Elétrica) – Universidade Federal de Sergipe, São Cristóvão, SE, 2017.

TAKAHASHI, O.; SCHILLING, R. J. Motion planning in a plane using generalized Voronoi diagrams. **IEEE Transactions on Robotics and Automation**, v. 5, p. 143-150, 1989.

THRUN, S. **Robotic Mapping: A Survey**. Pittsburgh: M. Kaufmann, 28 p., 2002.

VICTORINO, A. C.; RIVES, P. SLAM with consistent mapping in an hybrid model. In: IEEE/RSJ International Conference on Intelligent Robots and Systems, 2006, Beijing. *Proceedings...* (CD ROM).

VIDA, J. B. et al. Manejo de doenças de plantas em cultivo protegido. **Fitopatologia Brasileira**, v. 29, n. 4, p. 355-372, 2004.

VOLPE, R. A. **Real and artificial forces in the control of manipulators: theory and experiments**. 1990. 162 p. Tese (Doutorado em Filosofia) - Carnegie Mellon University, Pittsburgh, Pennsylvania, 1990.

VOLPE, R. A.; KHOSLA, P. K. Manipulator control with superquadric artificial potential functions: theory and experiments. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 20, p. 1423-1436, 1990.

WILLMARTH, S. A.; AMATO, N. M.; STILLER, P. F. MAPRM: A probabilistic roadmap planner with sampling on the medial axis. In: **IEE International Conference on Robotics & Automation**. Detroit, Michigan, 1999.

WOLF, D. F. et al. Robótica inteligente: Da Simulação às Aplicações no Mundo Real [Tutorial]. **JAI: Jornada de Atualização em Informática da SBC**, p. 279-330, Rio de Janeiro, 2009.