

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL

MARCO ANTONIO SIMÕES TEIXEIRA

**PREDIÇÃO DE MAPEAMENTO PARA NAVEGAÇÃO AUTÔNOMA
DE UM ROBÔ DE INSPEÇÃO EM VASOS DE PRESSÃO ESFÉRICOS**

DISSERTAÇÃO

CURITIBA

2017

MARCO ANTONIO SIMÕES TEIXEIRA

**PREDIÇÃO DE MAPEAMENTO PARA NAVEGAÇÃO AUTÔNOMA
DE UM ROBÔ DE INSPEÇÃO EM VASOS DE PRESSÃO ESFÉRICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Ciências” – Área de Concentração: Engenharia de Automação e Sistemas.

Orientadora: Prof. Dra. Lúcia Valéria Ramos de Arruda

Co-orientador: Prof. Dr. André Schneider de Oliveira

CURITIBA

2017

Dados Internacionais de Catalogação na Publicação

T266p
2017
Teixeira, Marco Antonio Simões
Predição de mapeamento para navegação autônoma de um robô de inspeção em vasos de pressão esféricos / Marco Antonio Simões Teixeira.-- 2017.
89 f. : il. ; 30 cm.

Texto em português, com resumo em inglês
Disponível também via World Wide Web
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2017
Bibliografia: f. 84-89

1. Gás liquefeito de petróleo. 2. Vasos de pressão – Inspeção. 3. Gás liquefeito de petróleo – Produção. 4. Fusão de dados multissensores. 5. Vasos de pressão – Medidas de segurança. 6. Engenharia elétrica – Dissertações. I. Arruda, Lúcia Valéria Ramos de. II. Oliveira, André Schneider de. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

CDD: Ed. 22 -- 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba

Título da Dissertação N°. _____

Predição de Mapeamento para Navegação Autônoma de um Robô de Inspeção em Vasos de Pressão Esféricos

por

Marco Antônio Simões Teixeira

Orientadora: Prof.^a Dr.^a Lúcia Valéria Ramos de Arruda (UTFPR)

Coorientador: Prof. Dr. André Schneider de Oliveira (UTFPR)

Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM CIÊNCIAS – Área de Concentração: **ENGENHARIA DE AUTOMAÇÃO E SISTEMAS** do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às 09h do dia 31 de março 2017. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores doutores:

Prof. Dr. André Schneider de Oliveira
(Presidente – UTFPR)

Prof. Dr. Fernando Santos Osório
(USP)

Prof. Dr. Daniel Rodrigues Pipa
(UTFPR)

Visto da coordenação:

Prof. Jean Carlos Cardozo da Silva, Dr.
(Coordenador do CPGEI)

Dedico este trabalho a todos que sempre me apoiaram e estiveram ao meu lado ao longo desta trajetória.

AGRADECIMENTOS

Primeiramente agradeço aos professores Lúcia Valéria Ramos de Arruda e André Schneider de Oliveira pela oportunidade dada de trabalhar junto a seu grupo de pesquisa, pela confiança, pelos ensinamentos científicos, pela compreensão e pela amizade.

Agradeço também aos membros do LASCA (Laboratório de Automação e Sistemas de Controle Avançado) pela ajuda prestada ao longo do trabalho, tanto de alunos como de professores presentes, e também pela amizade criada.

Por fim, agradeço à minha família, minha companheira, meus amigos e todos aqueles que de alguma forma me apoiaram e incentivaram.

Este trabalho teve apoio financeiro da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis - ANP, da Financiadora de Estudos e Projetos - FINEP, do Ministério da Ciência, Tecnologia e Inovação - MCTI por meio do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás - PRH-ANP/MCTI do Programa de Formação de Recursos Humanos da PETROBRAS - PRH10-UTFPR e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES.



Ministério da
Ciência, Tecnologia
e Inovação



PETROBRAS



“Se o dinheiro for a sua esperança de independência, você jamais a terá. A única segurança verdadeira consiste numa reserva de sabedoria, de experiência e de competência.”

Henry Ford

RESUMO

TEIXEIRA, Marco A. S. PREDIÇÃO DE MAPEAMENTO PARA NAVEGAÇÃO AUTÔNOMA DE UM ROBÔ DE INSPEÇÃO EM VASOS DE PRESSÃO ESFÉRICOS. 90 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

Vasos de pressão esféricos usados para armazenar gás liquefeito de petróleo necessitam ser inspecionados periodicamente a fim de identificar problemas em sua estrutura e evitar futuros acidentes. Este trabalho visa desenvolver uma técnica de mapeamento com base na predição do mapa para a navegação de um robô de inspeção autônomo. A técnica desenvolvida consiste na realização dos seguintes passos: busca autônoma de características conhecidas, percepção do ambiente, estimativa do ambiente, predição das características, mapa por técnica de grade de ocupação e voxel, aplicação de grau de incerteza nas medições e planejamento de trajetória. Ao final desta etapa tem-se a predição do mapeamento completo do tanque a ser inspecionado, contendo as suas principais características físicas como centro, raio, placas e cordões de soldas. Este trabalho auxilia a tarefa de inspeção em vasos de pressão esféricos realizado por um robô autônomo fornecendo um mapa completo do ambiente, com a possibilidade de armazenar a posição de fissuras e outros problemas identificados durante a inspeção.

Palavras-chave: Mapeamento, Predição, Reconstrução, Robô, Fusão de Dados e Estimativa do Ambiente.

ABSTRACT

TEIXEIRA, Marco A. S. 100. 90 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

Spherical pressure vessels used for the storage of liquefied petroleum gas need to be periodically inspected in order to identify problems in their structure and to prevent future accidents. This work aims at the development of a mapping technique based on map prediction for the navigation of an autonomous inspection robot. The technique developed consists of the following steps: autonomous search of known characteristics, perception of the environment, estimation of the environment, prediction of the characteristics, creation of occupation grid filled by voxels, application of degree of uncertainty in measurements and path planning. In the end, it is predicted the complete mapping of the tank to be inspected, containing its main physical characteristics, such as center, radius, plates and weld bead. This work assists the task of inspection in spherical pressure vessels performed by an autonomous robot providing a complete map of the environment, with the possibility of storing the position of fissures and other problems identified during the inspection.

Keywords: Mapping, Prediction, Reconstruction, Robot, Data Fusion and Environmental Estimation.

LISTA DE FIGURAS

FIGURA 1	– Vaso de alta pressão esférico.	18
FIGURA 2	– Inspeção por rapel.	19
FIGURA 3	– Chiba, Japão.	20
FIGURA 4	– Robô de sucção.	21
FIGURA 5	– Robô magnético.	21
FIGURA 6	– À esquerda: mapa de profundidade com cores escuras representando perto e cores claras longe. À direita: nuvem de pontos com cor (RGB-D) com vermelho representando perto e verde longe.	26
FIGURA 7	– Exemplo de funcionamento da técnica de luz estruturada. Um projetor emite uma luz estruturada enquanto uma câmera captura a luz e através da triangulação e posição desta luz, é realizado o mapa de profundidade. .	27
FIGURA 8	– À esquerda: sensor Microsoft Kinect adaptado. À direita: sensor Intel RealSense f200.	27
FIGURA 9	– Exemplo de luz estruturada utilizado pelo sensor Kinect, a imagem foi obtida com a ajuda de um sensor capaz de capturar infravermelho.	28
FIGURA 10	– Exemplo de funcionamento de um sensor ToF: Um sinal é enviado para o ambiente, e ao encontrar um obstáculo parte deste sinal é refletido, o sensor capta o sinal refletido e calcula a distância do objeto pelo tempo de voo. .	29
FIGURA 11	– Câmera SR4000 vista de frente, em destaque o sistema de iluminação e o filtro óptico utilizado dará receber o sinal.	30
FIGURA 12	– À esquerda: Princípio de funcionamento dos sensores Dimetix EDS-C. À direita: sensor Dimetix EDS-Co 20.	31
FIGURA 13	– À esquerda: Esquema de funcionamento de um sensor de varredura laser. À direita: sensor de varredura laser hokuyo URG-04LX-UG01.	31
FIGURA 14	– À esquerda: Grade de ocupação 2D. À direita: Grade de ocupação 3D com 90000 células ocupadas de um total de 4 milhões de células.	34
FIGURA 15	– Exemplo Grades de Certeza: Células ocupadas estão representadas por quadrados sombreados, células desocupadas estão na cor branca e células com incerteza representadas com o sinal “+”.	35
FIGURA 16	– Abordagem para o planejamento de inspeção inteligente.	39
FIGURA 17	– À esquerda: Robô Autônomo de Inspeção (AIR-1) em sua primeira versão. À direita: Robô Autônomo de Inspeção (AIR-2) em sua segunda versão. .	40
FIGURA 18	– À esquerda: Robô Autônomo de Inspeção (AIR-1) no início deste trabalho. À direita: Robô Autônomo de Inspeção (AIR-1) ao final deste trabalho. ..	41
FIGURA 19	– À esquerda: Fontes de percepção do Robô Autônomo de Inspeção v1 (AIR-1). À direita: Diagrama de Hardware presente no AIR-1.	43
FIGURA 20	– Fontes de percepção do AIR-1, possibilitando uma visualização do campo de visão de cada sensor.	43
FIGURA 21	– Fontes de percepção com uma vista de seu alcance, possibilitando uma visualização do alcance de cada sensor.	44
FIGURA 22	– Exemplo de dois entroncamentos de solda vistos de dentro do vaso de pressão esférico.	45

FIGURA 23	– Visão expandida das percepções do AIR-1 vistos de dentro do vaso de pressão esférico.	45
FIGURA 24	– Fluxograma com as regras para a busca autônoma do ponto de observação padrão.	46
FIGURA 25	– Algoritmo de Harris-Stephens na detecção de cantos e bordas. Os cantos se encontram em branco, enquanto as bordas em preto.	47
FIGURA 26	– Máscaras do filtro de detecção de bordas de Roberts. À Esquerda: filtro horizontal. À direita: filtro vertical.	48
FIGURA 27	– Método de detecção de bordas de Roberts. A esquerda: figura utilizada para a detecção. A Direita: resultado da aplicação do filtro de Roberts.	48
FIGURA 28	– Funções binárias de dilatação e erosão. A esquerda: imagem binária utilizada como exemplo, Ao centro esquerdo: máscara utilizada nas duas funções. Ao centro a direita: máscara aplicada a imagem original com a função dilatação. A direita: máscara aplicada a imagem original com a função erosão.	49
FIGURA 29	– Sistemas de coordenadas das fontes de percepção.	50
FIGURA 30	– Demais sistemas de coordenadas, referentes a posição do robô.	50
FIGURA 31	– Árvore de transformação do AIR-1, apresentando os principais sistemas de coordenadas.	51
FIGURA 32	– Fontes de percepção sobrepostas, fato ocorre por existir uma parede a curta distância.	53
FIGURA 33	– À esquerda: Vaso de pressão esférico com seus cordões de solda pontilhados. À direita: divisão de seções existentes no vaso de pressão esférico.	57
FIGURA 34	– Um exemplo de uma grade de ocupação predita do ambiente de inspeção.	59
FIGURA 35	– Ilustração da estratégia utilizada para a análise de confiabilidade para cada voxel.	61
FIGURA 36	– Funções de pertinência do modelo <i>fuzzy</i> desenvolvido. À esquerda superior: Menor distância entre o ponto analisado e um ponto observado. À direita superior: Porcentagem de pontos conhecidos dentro do raio do limite de vizinhança. À esquerda inferior: Raio da esfera. À Direita inferior: Grau de confiabilidade dada ao ponto analisado.	62
FIGURA 37	– Gráficos de superfície <i>fuzzy</i>	62
FIGURA 38	– Topologia da rede neural artificial (RNA) com 3 neurônios na camada de entrada, 6 neurônios na camada oculta e 1 neurônio na camada de saída. .	63
FIGURA 39	– Exemplo de funcionamento do modelo <i>fuzzy</i> e RNA desenvolvidos na aplicação de grau de confiabilidade para pontos preditos em uma esfera de 10 metros, contendo 20% dos pontos conhecidos. À esquerda superior: <i>Fuzzy</i> com pontos agrupados. À direita superior: <i>Fuzzy</i> com pontos distribuídos. À esquerda inferior: RNA com pontos agrupados. À direita inferior: RNA com pontos distribuídos.	64
FIGURA 40	– Diagrama de caixa com a diferença entre os dados obtidos pelo modelo <i>Fuzzy</i> e RNA na aplicação de grau de confiabilidade para uma esfera de 10 metros de diâmetro com 20% dos voxels conhecidos. À esquerda: Voxels agrupados. À direita: Voxels distribuídos aleatoriamente.	65
FIGURA 41	– Trajetória pura	66
FIGURA 42	– Vaso de pressão esférico e robô AIR-1 simulados. À esquerda: Vista de fora do vaso de pressão. À direita: vista interna do vaso de pressão esférico	

	simulado.	68
FIGURA 43	– Passos para a obtenção dos entroncamentos de solda com a câmera de profundidade longo-alcance ToF. À esquerda: nuvem de pontos. Ao centro: nuvem de pontos convertida em imagem. À direita: entroncamentos de soldas identificados.	69
FIGURA 44	– Correção de proximidade com o uso da câmera de meio-alcance. À esquerda: visão interna do vaso de pressão esférico simulado com a rota feita pelo robô marcada em azul. À direita: nuvem de pontos da câmera de profundidade meio-alcance com o cordão de solda identificado.	70
FIGURA 45	– Passos para a identificação de entroncamentos de solda com a câmera de profundidade meio-alcance. À esquerda superior: nuvem de pontos convertida em imagem em tons de cinza. À direita superior: filtro de Roberts aplicado a imagem. À esquerda inferior: função morfológica erosão e dilatação aplicada a imagem. À direita inferior: identificação dos entroncamentos de solda.	70
FIGURA 46	– Todas as fontes de percepção unidas em uma única nuvem de pontos.	71
FIGURA 47	– Todas as fontes de percepção unidas em uma única nuvem de pontos após a aplicação da fusão.	71
FIGURA 48	– Estimativas do ambiente: raio e centro preditos com base em dados da esfera.	72
FIGURA 49	– Características do ambiente preditas: Cordões de solda e placas da esfera preditas.	73
FIGURA 50	– Grade de ocupação criada a partir dos dados da estimativa do ambiente, esfera com raio de 9,105 metros e voxels com tamanho de 20 centímetros cúbicos, sendo 26184 voxels.	73
FIGURA 51	– Grade de ocupação com a análise de confiabilidade. À esquerda: grade de ocupação com voxels e grau de confiabilidade. À direita: grade de ocupação com voxels com grau de confiabilidade e características do ambiente preditas.	74
FIGURA 52	– Planejamento de trajetória para a esfera predita pelo experimento simulado. À esquerda: Visão frontal do planejamento de trajetória. À direita: Visão interna do planejamento de trajetória.	75
FIGURA 53	– Validação da busca autônoma do ponto de observação padrão com o quadro a esquerda. À esquerda superior: Posição inicial, a 1,5 metros do quadro. Ao centro superior: correção angular. À direita superior: correção linear chegando a 1 metro do quadro. À esquerda inferior: correção angular. Ao centro inferior: correção linear chegando a 0,7 metros do quadro. À direita inferior: Correção angular, chegando ao ponto de observação padrão.	76
FIGURA 54	– Validação da busca autônoma do ponto de observação padrão com o quadro ao centro. À esquerda superior: Posição inicial, a 1,5 metros do quadro. Ao centro superior: correção angular. À direita superior: correção linear chegando a 1 metro do quadro. À esquerda inferior: correção angular. Ao centro inferior: correção linear chegando a 0,7 metros do quadro. À direita inferior: Correção angular, chegando ao ponto de observação padrão.	76
FIGURA 55	– Validação da busca autônoma do ponto de observação padrão com o quadro a direita. À esquerda superior: Posição inicial, a 1,5 metros do quadro. Ao centro superior: correção angular. À direita superior: correção linear chegando a 1 metro do quadro. À esquerda inferior: correção angular. Ao	

	centro inferior: correção linear chegando a 0,7 metros do quadro. À direita inferior: Correção angular, chegando ao ponto de observação padrão.	77
FIGURA 56	– Robô autônomo de inspeção (AIR-1) com o quadro de soldas em um corredor utilizado para a validação real.	77
FIGURA 57	– Características do ambiente preditas: Cordões de solda e placas da esfera preditas.	78
FIGURA 58	– Grade de ocupação criada a partir dos dados da estimativa do ambiente, esfera com raio de 1,334 metros e voxels com tamanho de 20 centímetros, sendo 528 voxels.	78
FIGURA 59	– Grade de ocupação com a análise de confiabilidade. À esquerda: grade de ocupação com voxels e grau de confiabilidade. À direita: grade de ocupação com voxels com grau de confiabilidade e características do ambiente preditas.	79
FIGURA 60	– Planejamento de trajetória para a esfera predita pelo experimento real. À esquerda: visão aérea do planejamento de trajetória. À direita: visão frontal do planejamento de trajetória.	80

LISTA DE TABELAS

TABELA 1	– Fontes de percepção e seus respectivos sensores.	44
TABELA 2	– Especificações das fontes de percepção	54
TABELA 3	– Regras e conceitos	55

LISTA DE SIGLAS

AIR-1	Robô Autônomo de Inspeção 1
AIR-2	Robô Autônomo de Inspeção 2
END	Ensaio Não Destrutivo
GLP	Gás Liquefeito de Petróleo
<i>LIDAR</i>	<i>LI</i> ght <i>DE</i> tecti <i>ON</i> and <i>RA</i> nging - Detecção e Telemetria por Luz
<i>MSE</i>	<i>ME</i> an <i>SQ</i> ua <i>RE</i> d <i>E</i> rror – Erro Quadrático Médio
RNA	Rede Neural Artificial
<i>SLAM</i>	<i>SI</i> multane <i>OU</i> s <i>LO</i> calizati <i>ON</i> And <i>MA</i> pping – Localização e Mapeamento Simultâneos
<i>ToF</i>	<i>TI</i> me of <i>FL</i> ight – Tempo de Voo

SUMÁRIO

1 INTRODUÇÃO	17
1.1 TEMA	19
1.2 PROBLEMAS E PREMISSAS	21
1.3 OBJETIVOS	22
1.3.1 Objetivo Geral	22
1.3.2 Objetivos Específicos	22
1.4 ESTRUTURA DA DISSERTAÇÃO	23
2 PERCEPÇÃO DO AMBIENTE	24
2.1 FONTES DE PERCEPÇÃO 3D	24
2.1.1 Luz Estruturada	26
2.1.2 Tempo de Voo	28
2.1.3 Laser	30
2.2 REPRESENTAÇÃO TRIDIMENSIONAL	32
2.2.1 Reconstrução	32
2.2.2 Mapeamento	33
2.2.3 Predição	36
2.3 CONCLUSÃO	37
3 PREDIÇÃO DE MAPEAMENTO EM VASOS DE PRESSÃO ESFÉRICOS	39
3.1 ROBÔ AUTÔNOMO DE INSPEÇÃO	40
3.2 BUSCA AUTÔNOMA DO PONTO DE OBSERVAÇÃO PADRÃO	44
3.3 PERCEPÇÃO DO AMBIENTE E FUSÃO DOS SENSORES	49
3.4 ESTIMATIVA DO AMBIENTE	55
3.5 PREDIÇÃO DAS CARACTERÍSTICAS DO AMBIENTE	57
3.6 GRADE DE OCUPAÇÃO PREDITA	59
3.7 GRAU DE CONFIABILIDADE	61
3.8 PLANEJAMENTO DE TRAJETÓRIA	65
3.9 CONCLUSÃO	67
4 RESULTADOS EXPERIMENTAIS	68
4.1 EXPERIMENTO VIRTUAL	68
4.2 EXPERIMENTO REAL	75
4.3 CONCLUSÃO	80
5 CONSIDERAÇÕES FINAIS	81
5.1 CONCLUSÃO	81
5.2 TRABALHOS FUTUROS	83
REFERÊNCIAS	84

1 INTRODUÇÃO

O petróleo é um óleo mineral natural de cor muito escura que pode ser processado em diversos produtos como gasolina, gás natural veicular, óleo diesel, óleo lubrificante, gás natural industrial, parafina, óleo básico, gás liquefeito de petróleo (GLP), entre outros (DICIO, 2016). O processamento do petróleo em reservas de águas profundas (offshore) é realizado em diversas etapas antes de chegar ao consumidor final. Primeiramente é coletado de reservas naturais, passando então para plataformas marítimas, transportados para terminais no litoral. Na sequência é direcionado para as refinarias, onde é tratado e transformado em diversos produtos utilizados no nosso dia a dia (PETROBRAS, 2016). Durante o processo de coleta, transformação e distribuição do petróleo e seus derivados, existe a necessidade de armazenamento desses produtos temporariamente ou permanentemente.

Os tanques de armazenamento são reservatórios passíveis de serem utilizados para armazenar petróleo e seus derivados. É importante que sejam bem projetados e respeitem as normas de montagem e fabricação como API 650, API 620, ABNT NBR-17505, NBR-7821, NBR-15461, PBR N-270 e código ASME VIII seção I e II, a fim de evitar possíveis desastres. Os tanques são tradicionalmente do tipo atmosférico ou de Baixa Pressão. Os tanques atmosféricos são projetados para operar com pressão semelhante à pressão da atmosférica que é $0,05 \text{ kg/cm}^2$ acima do nível do líquido armazenado. Este tipo de tanque é comumente utilizado para petróleo bruto, óleo pesado, gasolina, entre outros produtos químicos não voláteis. Já o tanque de baixa pressão opera com pressão entre $0,05 \text{ kg/cm}^2$ a $1,05 \text{ kg/cm}^2$, sendo comumente utilizado para armazenar produtos voláteis, como o petróleo bruto leve (COSTA, 2011).

Para armazenar produtos em pressões superiores são utilizados os vasos de pressão, que são equipamentos capazes de conter fluidos pressurizados. No caso do armazenamento do gás liquefeito de petróleo (GLP), a indústria normalmente utiliza vasos de pressão do tipo esférico, também conhecidos como tanque de armazenamento esféricos. No Brasil, normalmente são utilizados dois tamanhos de vasos esféricos para armazenamento de GLP, sendo eles de diâmetro interno aproximado de 14,60 m e 18,25 m, com capacidade de armazenamento de 1590 m^3 e 3180 m^3 respectivamente (N-268, 2012). Uma ilustração do

vaso de pressão esférico pode ser vista pela Figura 1.



Figura 1: Vaso de alta pressão esférico.

Fonte: Fukuda (2016)

Esses tanques estão sujeitos a graves acidentes pela natureza de seus produtos estocados. O estudo realizado por Chang e Lin (2006) analisou 242 acidentes em tanques de armazenamento ocorridos entre 1960 e 2003, com a finalidade de encontrar os principais causadores dos incidentes. Os autores constataram que 74% desses acidentes ocorreram em refinarias de petróleo e 85% desses acidentes acarretaram em incêndios e explosões. Desses, 33% dos acidentes foram causados por relâmpagos e 30% causados por erros humanos. Outras causas são sabotagens, vazamentos e rupturas.

Uma tentativa de diminuir o número de acidentes é a realização de inspeções preventivas periódicas nos tanques de armazenamento. Estas inspeções seguem normas técnicas, sendo a mais importante delas a norma API 653. Esta norma define os procedimentos para a inspeção dos tanques, desenvolvidas pela “*American Petroleum Institute*” (INSTITUTE, 2003).

A inspeção pode ser dividida em três partes principais, sendo elas a limpeza do tanque, a inspeção e o reparo. A limpeza do tanque consiste em deixar o tanque em condições adequadas para que seja possível realizar a inspeção. Todo o conteúdo do tanque deve ser drenado e armazenado temporariamente ou permanentemente em outro tanque ou recipiente. A fase de inspeção é realizada pelos técnicos de inspeção e consiste em uma varredura completa no tanque a fim de encontrar possíveis falhas na estrutura e/ou equipamentos. A etapa de reparo consiste em realizar as correções necessárias para que o tanque possa voltar à atividade. Estes procedimentos podem levar de uma semana a seis meses, dependendo de alguns fatores, como tamanho do tanque (TOOLBOXES, 2003).

Uma das formas de se realizar a inspeção é por meio do uso de *ensaios não destrutivos* (END), como a técnica de ultrassom, que verifica o ambiente e identifica possíveis falhas nas chapas metálicas dos tanques, assim como em suas soldas sem danificar a sua estrutura. O técnico de inspeção necessita varrer com o equipamento de ensaio não destrutivo todo o tanque a fim de encontrar possíveis defeitos e em alguns casos é necessário fazer um rapel dentro e fora da esfera, o que pode colocar em perigo a sua integridade física. Neste contexto, o uso de robôs autônomos de inspeção é uma alternativa segura e eficiente para a realização de tais tarefas. A Figura 2 traz o técnico de inspeção realizando a tarefa de inspeção sem apoio.



Figura 2: Inspeção por rapel.

1.1 TEMA

Os vasos de pressão esféricos são capazes de resistirem a altas pressões e diferentes temperaturas. Estes tanques são projetados e fabricados de acordo com a norma ASME VII (ENGINEERS, 2004) e para a sua fabricação são soldadas várias chapas de metal, formando no final uma esfera. As soldas e as chapas podem sofrer danos ao longo do tempo, como corrosão, oxidação e possíveis falhas no cordão de solda durante o processo de fabricação, como mencionado por Wu et al. (2001) e Topp (1999). Esses danos podem causar acidentes graves como o ocorrido em Chiba, no Japão no ano de 2011, quando um terremoto provocou uma grave explosão em tanques de GLP, como visto pela Figura 3.

Tanto em tanques cilíndricos como em tanques esféricos, é evidente o quão catastrófica uma falha pode se tornar, o que aumenta a importância da inspeção nesses tipos de reservatórios. Por outro lado, a inspeção se torna cara e coloca a vida de técnicos em risco. Uma alternativa é a utilização de robôs autônomos ou teleoperados para realizar a inspeção.



Figura 3: Chiba, Japão.

Fonte: Fukuda (2016)

A utilização de robôs em tarefas de manutenção não é algo novo. Em Sawada et al. (1991), foi apresentado um robô móvel para a manutenção de linhas de transmissão de energia. Vários testes mecânicos foram realizados para garantir o sucesso do robô móvel. Como resultado, os autores obtiveram sucesso em uma navegação simulada entre duas torres.

Para realizar a inspeção um robô necessitaria ter a habilidade de escalar as paredes do tanque tanto por dentro como por fora. Várias técnicas de escalada podem ser utilizadas, por exemplo em Morris e Xiao (2008) foi desenvolvido um robô capaz de escalar qualquer superfície. O robô utiliza uma tecnologia denominada no artigo como atração aerodinâmica, que não necessita da vedação completa, como acontece nos robôs escaladores que utilizam a tecnologia de sucção. Já em Tummala et al. (2002) foi apresentado um robô escalador que utiliza tecnologia de sucção para executar a tarefa de escalar, onde o robô utiliza dois braços para realizar a escalada. Enquanto um dos braços esta preso à parede, o outro braço executa a manobra de se locomover a frente, prendendo na parede e alterando os papéis, como pode ser visto pela Figura 4.

Outra forma de dar a um robô móvel a capacidade de escalar uma parede é através do uso da adesão magnética. Quando o robô executa tarefas em superfícies metálicas, é possível utilizar rodas magnéticas para escalar as paredes. Por exemplo em Eich e Vögele (2011) são utilizadas rodas magnéticas para dar ao robô móvel a capacidade de escalar as paredes de um barco. O robô foi desenvolvido com a finalidade de fazer inspeções em embarcações. Este projeto está em desenvolvimento pela “*EU-founded MINOAS project*”, o robô pode ser observado na Figura 5.



Figura 4: Robô de sucção.

Fonte: Tummala et al. (2002)



Figura 5: Robô magnético.

Fonte: Eich e Vögele (2011)

Um trabalho inicial para a realização de inspeção em vasos de pressão esféricos foi desenvolvido em Okamoto et al. (2012) onde foi desenvolvido um robô para a inspeção em tanques de armazenamento esférico. O robô procura e segue o cordão de solda com o auxílio de câmeras, porém não realiza o mapeamento do ambiente.

A capacidade de escalar uma parede metálica é apenas uma das várias capacidades que um robô de inspeção necessita ter. A fim de assegurar uma realização detalhada de inspeção, o robô necessita saber onde ele se encontra em cada momento (posição sobre o tanque), mapear o ambiente (identificar cordões de soldas, válvulas, escadas, etc) e outros problemas relacionados à robótica móvel.

1.2 PROBLEMAS E PREMISSAS

Robôs móveis necessitam interagir com o ambiente em que se encontram para que consigam executar suas tarefas, sendo capazes de atuarem em ambientes dinâmicos e imprevisíveis. O robô necessita também se localizar no ambiente, esta tarefa é comumente referenciada como localização.

A localização se torna facilitada quando se possui um mapa prévio do local onde se pretende atuar, pois torna-se possível fazer uma fusão entre o posicionamento fornecido pelo mapa do ambiente e os sensores responsáveis por executar a localização, para aumentar a precisão (THRUN et al., 2005). Em muitos casos, não é possível obter um mapa prévio do ambiente como, por exemplo, um robô projetado para identificar e coletar minas terrestres, onde o robô deve atuar em diferentes áreas e terrenos desconhecidos. Neste caso é necessário que uma representação do ambiente seja criada em tempo de execução (THRUN et al., 2002) (THRUN et al., 2001) (LEONARD; DURRANT-WHYTE, 1991a).

A construção de mapas com uso de sensores é considerada como um problema de estimação fundamental para o desenvolvimento de robôs autônomos, pois através deles é possível desenvolver rotas, identificar obstáculos, entre outras atividades (THRUN et al., 2002) (MORAVEC; ELFES, 1985) (WOLF; SUKHATME, 2008).

Quando se necessita da localização do robô sem a existência do mapa do ambiente em que ele está inserido, o grau de complexidade aumenta, uma vez que para criar um mapa do ambiente existe a necessidade de saber a posição do robô e esta exige a necessidade de se ter um mapa do ambiente. Este problema é conhecido como “Mapeamento e Localização Simultâneos”, do inglês “*Simultaneous Localization and Mapping*”– (SLAM), como visto em Leonard e Durrant-Whyte (1991b). Trabalhar com o SLAM exige mais complexidade do que resolver o problema de localização e mapeamento de forma independente (DISSANAYAKE et al., 2001). Ao se resolver o problema de mapeamento e localização, o robô móvel pode operar livremente de acordo com a função a que se destina. Ter um mapa do ambiente é de fundamental importância para as tarefas posteriores, como planejamento de trajetórias e navegação.

1.3 OBJETIVOS

1.3.1 OBJETIVO GERAL

O objetivo dessa dissertação é desenvolver um método para a predição inicial do mapeamento em vasos de pressão esféricos, a fim de permitir o planejamento preciso da trajetória de navegação. O mapa será construído através da medição do tanque por diferentes sistemas de percepção: câmera ToF (Time-of-flight), LIDAR (Light Detector And Ranging) e sensor de luz estruturada. Após o fim da predição das características da esfera, será desenvolvida uma grade de ocupação com voxels, onde cada voxel possuirá um grau de certeza baseado em voxels conhecidos observados pelos sensores.

1.3.2 OBJETIVOS ESPECÍFICOS

1. Análise das fontes de percepção existentes e suas características, desenvolvimento das estratégias de mapeamento e visão computacional, com a finalidade de encontrar soluções em outras áreas para o problema de mapeamento e predição na robótica móvel;
2. Realizar a medição do ambiente a ser inspecionado, por meio da fusão de medições distintas de diferentes sistemas de percepção, para a extração dos seus parâmetros físicos (localização, dimensão, topologia, entre outros);

3. Realizar a predição do mapa do ambiente considerando as informações de medição do tanque, suas características, particularidades e as normas de fabricação;
4. Atribuir índices de confiabilidade à predição por meio de uma estratégia inteligente utilizando uma rede neural artificial (RNA), levando em consideração dados conhecidos do tanque;
5. Validar o método proposto através de experimentos em ambiente simulado e no robô real.

1.4 ESTRUTURA DA DISSERTAÇÃO

Este trabalho está dividido em 5 capítulos. No segundo capítulo é apresentada uma análise sobre as fontes de percepção e estratégias de mapeamento, assim como estudos de técnicas de visão computacional como reconstrução de objetos. No terceiro capítulo a metodologia proposta é apresentada, abordando as estratégias adotadas durante o desenvolvimento desta dissertação. No quarto capítulo, é realizada a validação das metodologias propostas, tanto em ambiente simulado quanto em ambiente real. O capítulo 5 apresenta as considerações finais deste trabalho e sugestões de trabalhos futuros.

2 PERCEPÇÃO DO AMBIENTE

Para que o robô possa identificar a sua posição e também reconhecer o ambiente em que está inserido, é necessário que seja dotado de capacidade de percepção. Da mesma forma que nós seres humanos somos capazes de perceber o ambiente a nossa volta com nossos sensores naturais, um robô necessita de sensores capazes de coletar dados do ambiente. Cada sensor pode fornecer um tipo de percepção diferente ao robô e são inúmeros os sensores existentes no mercado.

Percepção é a capacidade do robô de perceber o que está acontecendo em sua volta ou com ele mesmo. Para que o robô seja dotado de percepção são utilizado sensores que são capazes de realizar medições sobre o ambiente dos mais diversos tipos.

Este capítulo tem por finalidade trazer uma explicação do funcionamento dos sensores utilizados durante o trabalho, assim como apresentar as principais técnicas de mapeamento existentes. Para realizar o mapeamento do ambiente, o robô precisa percebê-lo de alguma forma, e para isso são utilizados os sensores.

2.1 FONTES DE PERCEPÇÃO 3D

Um robô não difere de um ser vivo na necessidade de capturar informações do seu meio para que gere comportamentos e interação (MURPHY, 2000). Para que o robô seja capaz de interagir no meio é necessário algum método de percepção e, na robótica, isso ocorre com o uso de sensores (SIEGWART et al., 2011). Esta seção tem por objetivo apresentar conceitos sobre os sensores, como as suas classificações, além de trazer uma explicação do funcionamento dos sensores e seus mecanismos de funcionamento e as principais técnicas utilizadas para obtenção de informações do ambiente em que o robô está inserido.

Os sensores podem ser classificados de duas formas distintas, dependendo de seu funcionamento e energia utilizada, podendo ser proprioceptivo ou exteroceptivo além de passivo ou ativo (MURPHY, 2000; SIEGWART et al., 2011).

A classificação em passivo ou ativo esta relacionado com a energia utilizada pelo sensor:

- **Ativo:** são aqueles sensores que emitem algum tipo de energia para o meio ambiente a fim de executar suas medições. Essa energia pode ser infravermelho, laser ou sonar, por exemplo.
- **Passivo:** são aqueles que não emitem energia no ambiente, apenas executam suas medições capturando a energia disponível no ambiente, como câmeras, termômetros e microfones, por exemplo.

A classificação por proprioceptivo ou exteroceptivo diz respeito ao local de medição:

- **Proprioceptivo:** são aqueles sensores utilizados para medir valores do próprio robô, como temperatura, orientação do robô e velocidade, por exemplo. Esses sensores podem ser ativos ou passivos.
- **Exteroceptivo:** são aqueles sensores utilizados para medir valores do ambiente e não do robô, que podem ser ativos ou passivos.

Além da classificação em ativo e passivo e proprioceptivo e exteroceptivo, também é possível classificar os sensores por sua técnica de obtenção de dados. Existem 2 técnicas comuns de obtenção de dados em medidas de distância, sendo elas *tempo de voo* e *luz estruturada*. A principal informação obtida pelas duas técnicas é a distância entre o objeto e o sensor, informação esta que pode ser em 2D ou 3D.

Essas medidas de distância podem ser convertidas em *mapa de profundidade* ou em *nuvem de pontos*. Um mapa de profundidade é uma imagem 2D onde a profundidade dos objetos é representada de alguma forma, como em cores podendo ser escuro para perto e branco para longe. Já nuvem de pontos são pontos em um sistema de coordenadas 3D (x,y,z), onde o ambiente é representado por meio destes pontos (ALDOMA et al., 2012). Quando é adicionado cor aos pontos, a nuvem de pontos passa a ter 4D sendo a nova dimensão a cor. Este tipo de nuvem de pontos também é conhecida como RGB-D (HENRY et al., 2012). A Figura 6 traz um exemplo de um mapa de profundidade ao lado de uma nuvem de pontos.

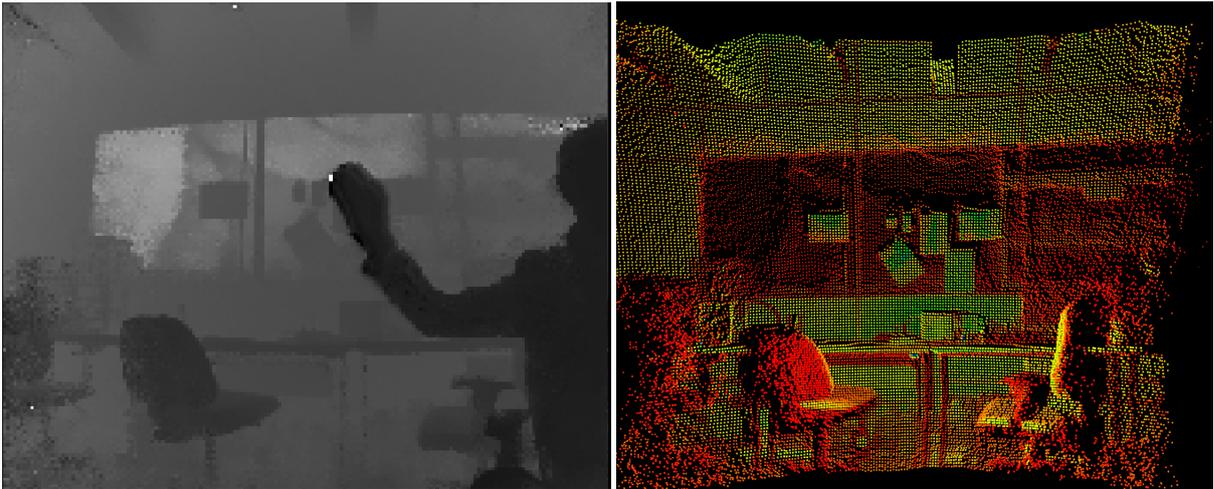


Figura 6: À esquerda: mapa de profundidade com cores escuras representando perto e cores claras longe. À direita: nuvem de pontos com cor (RGB-D) com vermelho representando perto e verde longe.

2.1.1 LUZ ESTRUTURADA

Luz estruturada é uma técnica utilizada para obter um mapa de profundidade tanto em 2D quanto em 3D, em que seu princípio de funcionamento envolve a triangulação e o uso de um emissor e receptor de luz. A luz estruturada projeta um padrão conhecido (um ponto, uma linha ou uma textura) sobre o ambiente e através de valores geométricos conhecidos é possível utilizar um método de triangulação para estabelecer as medidas (SIEGWART et al., 2011).

Um emissor de luz (um projetor, por exemplo) é utilizado para gerar a luz estruturada, enquanto um receptor (uma câmera RGB, por exemplo) é utilizado para ler este padrão. Se a cena for uma superfície plana sem nenhuma variação, o padrão obtido pela câmera será semelhante ao padrão projetado. Mas se a superfície não for plana, o padrão observado pela câmera será uma distorção do padrão projetado. A técnica de luz estruturada consiste em extrair as informações 3D deste padrão distorcido em relação ao padrão projetado (GENG, 2011). A Figura 7 traz um exemplo do uso da técnica de luz estruturada.

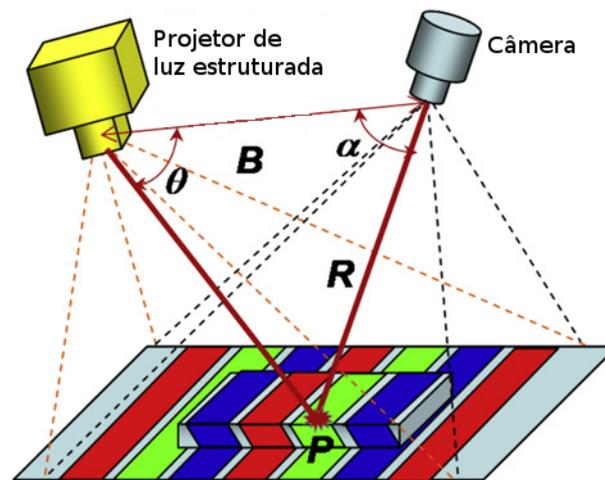


Figura 7: Exemplo de funcionamento da técnica de luz estruturada. Um projetor emite uma luz estruturada enquanto uma câmera captura a luz e através da triangulação e posição desta luz, é realizado o mapa de profundidade.

Fonte: (GENG, 2011)

Um emissor de infravermelho pode ser utilizado para projetar a luz estruturada desde que exista uma câmera capaz de capturar o sinal infravermelho projetado. O infravermelho possui a vantagem de atuar de forma despercebida pelo olho humano. A Figura 8 traz dois exemplos de sensores que utilizam essa técnica: o sensor Kinect v1 (Xbox 360), que é capaz de fornecer um mapa de profundidade e nuvem de pontos a uma resolução de 640x480 pixels com uma distância máxima de 4 metros com um campo de visão de 57°h (horizontal) por 43°v (vertical) (PAGLIARI; PINTO, 2015), e o sensor RealSenseF200 que é capaz de fornecer um mapa de profundidade e nuvem de pontos em resolução de 640x480 pixels e uma distância de até 1.2 m (INTEL, 2016).



Figura 8: À esquerda: sensor Microsoft Kinect adaptado. À direita: sensor Intel RealSense f200.

Fonte: (MICROSOFT, 2016) e (INTEL, 2016)

A técnica de luz estruturada é considerada ativa, pois existe a necessidade de irradiar o ambiente com algum tipo de luz ou sinal. Um exemplo da luz estruturada utilizada pelo Kinect pode ser observado na Figura 9.



Figura 9: Exemplo de luz estruturada utilizado pelo sensor Kinect, a imagem foi obtida com a ajuda de um sensor capaz de capturar infravermelho.

Fonte: (KINGMOB, 2017)

2.1.2 TEMPO DE VOO

A técnica de tempo de voo, ou do inglês *Time of Flight*, (ToF) faz uso da velocidade de propagação do som ou de uma onda eletromagnética (ondas de rádio, micro-ondas, infravermelho, luz visível, ultravioleta, raios x e raios gama) para se calcular o tempo e a distância percorrida pelo sinal (SIEGWART et al., 2011). Como o próprio nome sugere, esta técnica consiste em calcular o tempo em que o sinal levou para chegar do ponto A ao ponto B. A distância de viagem da onda pode ser obtida pela seguinte fórmula:

$$d = v.t, \quad (1)$$

onde d é a distância, v é a velocidade da onda e t é o tempo percorrido pela onda.

Porem é necessário saber a velocidade de propagação da onda. Segundo Siegart et al. (2011), a velocidade de propagação do som é de aproximadamente 0,3 m/ms enquanto a velocidade de propagação de um sinal eletromagnético é de aproximadamente 0,3 m/ns. Esta diferença significa que, para percorrer uma distância de 3 m, um sinal de ultrassom leva 10 ms e uma onda eletromagnética leva 10 ns.

Sensores que utilizam a técnica ToF possuem um transmissor e um receptor. O transmissor emite o sinal e o receptor se torna responsável por lê-lo para então ser calculado o tempo de voo. Quando o receptor e o transmissor se encontram no mesmo local, o tempo de voo é calculado pela reflexão do sinal em um objeto, logo a equação 1 pode ser alterada de modo a considerar apenas o tempo de ida da onda:

$$d = \frac{v \cdot t}{2} \quad (2)$$

Câmeras 3D ToF também funcionam com a técnica de tempo de voo, seu funcionamento consiste em iluminar a cena através de uma fonte de luz modulada e receber a luz refletida. A distância é obtida através do deslocamento de fase entre a luz emitida e recebida. Normalmente a iluminação é fornecida por um LED que produz uma onda de luz infravermelho invisível ao olho humano (LI, 2014). A Figura 10 traz um exemplo desta tecnologia.

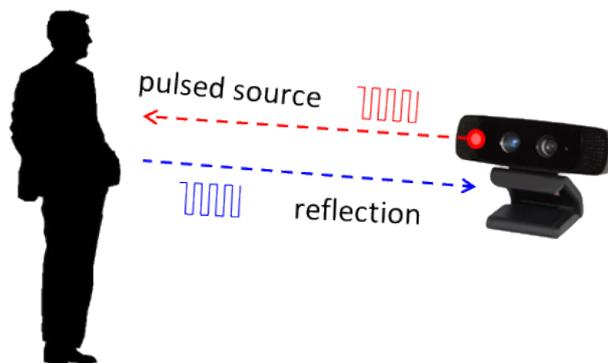


Figura 10: Exemplo de funcionamento de um sensor ToF: Um sinal é enviado para o ambiente, e ao encontrar um obstáculo parte deste sinal é refletido, o sensor capta o sinal refletido e calcula a distância do objeto pelo tempo de voo.

Fonte: (LI, 2014)

Um exemplo de câmera 3D ToF é a SR4000, vista na Figura 11. Seu princípio de funcionamento consiste em emitir um sinal infravermelho modulado e através dos sensores de imagem CCD/CMOS é medida a fase do sinal refletido modulado para cada pixel. A fração de um ciclo completo do sinal modulado é utilizada para determinar a distância de cada pixel, onde a distância corresponde a um ciclo completo. O mapa de profundidade deste sensor é de 176 por 144 pixel, a uma distância de 5 m para uma frequência de modulação de 30 MHz e 10 metros para 15 MHz (MESA IMAGING, 2011).

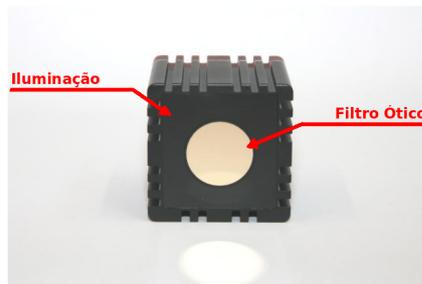


Figura 11: Câmera SR4000 vista de frente, em destaque o sistema de iluminação e o filtro óptico utilizado para receber o sinal.

Fonte: (IMAGING, 2011)

2.1.3 LASER

O princípio de ToF pode ser aplicado ao laser, quando um feixe laser é emitido e sua reflexão medida. Diferente de um sonar que possui um campo de visão de 30° , o laser possui um campo de visão muito menor possibilitando uma maior confiança nas medições. Quando se usa um único feixe de luz não é possível obter medidas diferentes se não aquela em que o laser está apontado. Uma solução é adicionar ao laser uma varredura para cobrir uma maior área e até mesmo produzir imagens com mapa de profundidade. Sensores que utilizam laser para se obter mapas de profundidade são chamados muitas vezes de *laser radar*, *LADAR* (Laser Detection And Ranging) ou *LIDAR* (Light Detection and Ranging) (MURPHY, 2000).

Existem assim dois tipos de sensores laser: um que obtém uma única informação de distância, e outro que executa uma varredura e obtém várias informações utilizando um único laser. O sensor de distância laser EDS-Co 20 utiliza um diodo emissor de luz (LED) de classe 2 para enviar um feixe de laser. Uma quantidade de luz é refletida para o sensor e a partir desses dados é determinada a distância (DIMETIXUSA, 2014). Este tipo de sensor pode alcançar longas distâncias, de ordem de 500 m (DIMETIXUSA, 2016). Um exemplo deste sensor pode ser observado na Figura 12, assim como um esquemático de seu funcionamento.

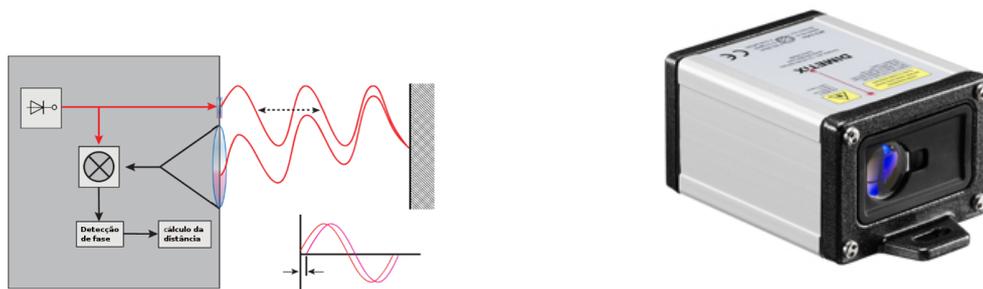


Figura 12: À esquerda: Princípio de funcionamento dos sensores Dimetix EDS-C. À direita: sensor Dimetix EDS-Co 20.

Fonte: (DIMETIXUSA, 2014)

Um exemplo de funcionamento de um sensor de varredura laser pode ser visto na Figura 13 a esquerda, onde um laser é apontado para um espelho que executa movimentos giratórios cobrindo uma grande área horizontal. Ao sensor a direita desta Figura utiliza esta técnica, e possui uma resolução angular de $0,36^\circ$ com campo de visão de 240° atingindo uma distância máxima de 4 metros. Este tipo de sensor que combina o laser e uma parte mecânica para rotacioná-lo, fornecendo um mapa horizontal do ambiente, é chamado neste trabalho de LIDAR.



Figura 13: À esquerda: Esquema de funcionamento de um sensor de varredura laser. À direita: sensor de varredura laser hokuyo URG-04LX-UG01.

Fonte: (SIEGWART et al., 2011)

Sensores do tipo LIDAR apresentam alguns problemas. Como é possível apenas uma seção planar do ambiente, pode ocorrer de o robô não enxergar algum obstáculo que está em uma orientação diferente da que o sensor se encontra e assim provocar sérios danos (MURPHY, 2000). Uma solução para isto é dotar o robô com sensores 3D, como câmeras de profundidade por exemplo.

2.2 REPRESENTAÇÃO TRIDIMENSIONAL

Um robô necessita conhecer o ambiente em que está inserido para ser capaz de navegar com segurança por ele. Para criar o mapa do ambiente, o robô precisa navegar por todo o ambiente, esta ação gera custos e acarretar em possíveis danos ao sistema. Uma alternativa é ter o mapa prévio do ambiente armazenado, antes da navegação.

O objetivo desta seção é levantar as principais técnicas utilizadas na área de mapeamento de ambientes e objetos, sendo elas denominadas de *Reconstrução*, *Mapeamento* e *Predição*. A reconstrução tem a finalidade de criar um modelo objeto real no mundo virtual sem se preocupar com a localização do objeto. O mapeamento, por sua vez, se preocupa em construir uma representação do ambiente real em um mapa, preocupando-se com a posição de cada objeto no mundo. Já a predição se preocupa em construir um mapa do ambiente, levando em consideração a posição de cada item neste mapa sem a necessidade de se conhecer todo o ambiente ou objeto.

2.2.1 RECONSTRUÇÃO

As informações fornecidas pelos sensores podem ser tratadas e manipuladas a fim de identificar e reconstruir um objeto, por exemplo. Reconstrução significa construir de novo, redefinir (DICIO, 2016). A técnica de reconstrução em visão computacional consiste no ato de se recriar um objeto real em um mundo tridimensional, podendo ser apenas um conjunto de pontos 3D ou ainda possuir texturas e cores criando um modelo do objeto. Este modelo pode ser utilizado para diversos fins como, por exemplo, impressões em uma impressora 3D, ou então utilizado para se fazer o reconhecimento de objetos procurando padrões entre o que é obtido pelo sensor e os modelos 3D.

Alguns trabalhos da literatura tratam desse assunto. Em (PRANKL et al., 2015) é apresentada uma técnica de reconstrução de objetos utilizando sensores RGB-D a fim de que esses modelos ajudem em outras áreas, como reconhecimento e ou identificação de objetos. Além de objetos, é possível reconstruir uma cena inteira como acontece em (IZADI et al., 2011) onde é realizada a reconstrução de uma cena em tempo real, com a finalidade de se observar a interação do homem com os objetos presentes na cena. A reconstrução se dá através do uso do sensor Microsoft Kinect e sua câmera de profundidade para se criar o modelo 3D, e de sua câmera RGB para se criar a textura, criando então um modelo 3D de toda a cena. O trabalho desenvolve um sistema de escaneamento de objetos 3D de baixo custo.

A reconstrução tem por objetivo criar um modelo 3D fiel de algo que existe no mundo real. A técnica despreza a posição dos objetos em um mapa, o que é relevante para a robótica. O robô necessita da cena ou mapa do ambiente para traçar trajetórias e navegar. Não é necessária a utilização de modelos 3D precisos e completos, já que os modelos ocupam muito espaço de memória e exigem um alto processamento que podem sobrecarregar sem necessidade o robô, salvo exceções onde o robô utiliza o modelo para alguma outra tarefa tal que reconhecimento de objetos. A reconstrução de objetos é favorece a visão computacional.

2.2.2 MAPEAMENTO

O mapeamento se preocupa em criar um mapa do ambiente e salvá-lo em memória. Primeiro, para se mapear o ambiente é preciso saber onde o robô está localizado e para saber onde o robô está localizado é preciso ter um mapa do ambiente. Este é um dos problemas mais conhecidos na robótica móvel onde as duas necessidades precisam ser supridas simultaneamente (LEONARD; DURRANT-WHYTE, 1991c).

Este problema de localização e mapeamento é conhecido na literatura como SLAM do inglês Simultaneous Localization and Mapping que significa Localização e mapeamento Simultâneos. Desde o seu desenvolvimento teórico várias soluções surgiram, podendo até dizer que o problema se encontra resolvido hoje (DURRANT-WHYTE; BAILEY, 2006).

Para se criar um mapa do ambiente e localizar-se neste mapa, o robô necessita fazer uso de sua percepção, ou seja, o uso de sensores capazes de perceber o ambiente. Por meio dos dados desses sensores é possível criar estratégias de mapeamento do ambiente e de localização. Os principais sensores utilizados para mapeamento de ambiente são lasers capazes de medir a distância de objetos em relação ao robô, câmeras 3D que trabalham com tecnologias como tempo de voo, e sonares. Além de recriar o ambiente em que o robô está localizado, é preciso localizar-se, ou seja, é preciso saber onde o robô está em relação ao mapa que está sendo construído. Para resolver este problema várias técnicas podem ser utilizadas, sendo a odometria a mais tradicional. Conforme o robô anda, uma nova cena é reconstruída e adicionada a cena antiga, criando então um mapa dinâmico do ambiente de navegação.

São vários os trabalhos que se preocupam em resolver ou abordar técnicas diferentes de SLAM, em (TSARDOULIAS; PETROU, 2013) é desenvolvida uma técnica de mapeamento 2D utilizando o sensor do tipo LIDAR. Esta técnica considera a posição do robô e utiliza o sensor para criar o mapa do ambiente, fazendo uma transformação dos dados em relação ao robô e posteriormente ao mapa.

Trabalhos recentes fazem uso de sensores 3D para gerar o mapa, um exemplo de um sensor muito utilizado é o Microsoft Kinect. Em (ENDRES et al., 2012) é apresentado o uso desse sensor para fazer o mapeamento do ambiente tendo como resultado um mapa 3D com cores. Uma técnica semelhante é proposta em (HENRY et al., 2012) onde é utilizado o sensor para se criar um mapa a cores, neste trabalho uma fusão é feita entre a câmera RGB presente no sensor e os dados de profundidade também fornecidos pelo sensor. Mapas 3D do ambiente também podem ser obtidos através de sensores 2D, em (LEE et al., 2013) é utilizado um LIDAR para mapear um ambiente e desenvolver um mapa 3D. Para se obter o resultado desejado, o sensor precisa ser rotacionado para que o laser varra toda a superfície.

É possível representar o mapa com o uso de grades de ocupação. Grade de ocupação 2D (ou occupancy grid) é uma técnica apresentada por Moravec e Elfes (1985) onde cada célula da grade é ocupada com um valor binário, 1 para ocupado e 0 para livre. Este valor de ocupação pode ser chamado de pixel (*Picture Element*). Grade de ocupação 3D é vista em (MORAVEC, 1996) onde o mesmo conceito de grade 2D é aplicado (a célula esta ocupada ou não) desta vez em um ambiente de três dimensões, aumentando o numero de células presentes na grade de ocupação e o custo computacional. Grades de ocupação 3D podem ser ocupadas por voxels (*Volume Elements*) que podem assumir diferentes tamanhos, cores e formatos ocupando as células vazias da grade de ocupação. A Figura 14 ilustra a diferença entre uma grade de ocupação 2D e 3D.

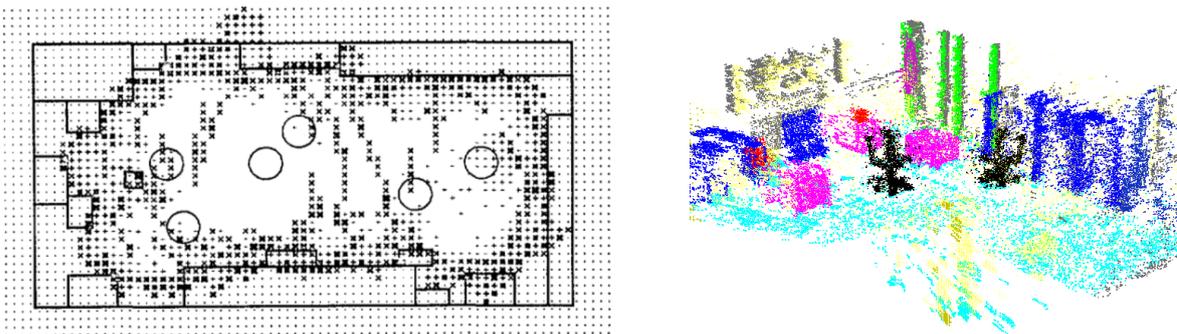


Figura 14: À esquerda: Grade de ocupação 2D. À direita: Grade de ocupação 3D com 90000 células ocupadas de um total de 4 milhões de células.

Existem diferentes técnicas de mapeamento que utilizam o conceito de grade de ocupação. Por exemplo, em Wang e Yang (1995) é apresentado o conceito de *Certainty Grids* que em uma tradução livre significa *Grades de Certeza* para a percepção e navegação de robôs. Grades de certeza podem utilizar estimativas probabilísticas para definir se a célula da grade de ocupação está ou não ocupada, sendo conhecido como *Probabilistic Occupancy Grid* (Grade de ocupação probabilística). Esta incerteza pode ser representada na grade de ocupação, como

em (MORAVEC, 1988) (Figura 15) , onde é utilizado quadrados sombreados para marcar áreas ocupadas, áreas desocupadas são marcadas com a cor branca, e áreas desconhecidas são marcadas com o sinal “+”.



Figura 15: Exemplo Grades de Certeza: Células ocupadas estão representadas por quadrados sombreados, células desocupadas estão na cor branca e células com incerteza representadas com o sinal “+”.

Fonte: (MORAVEC, 1988)

Vários autores podem ser citados na área de mapeamento de ambiente, onde novas técnicas e sensores surgem continuamente. Contudo, o mapeamento de ambiente se preocupa em mapear apenas o ambiente a sua volta, sendo necessário varrer todo o local para que se tenha um mapa completo.

2.2.3 PREDIÇÃO

A reconstrução se preocupa em criar um modelo 3D de um objeto, enquanto o mapeamento se preocupa em criar um mapa do ambiente, sem focar os objetos e sim com a identificação de caminhos livres para navegação. Ambas as soluções são promissoras e funcionam para diferentes casos, mas ambas apresentam o mesmo problema: o robô necessita colher dados de todo o ambiente. Em muitos casos, esta necessidade não se torna um problema, mas imagine um robô autônomo que deve executar uma ação em uma fábrica, como ele traçaria a rota para executar sua função sem conhecer o mapa do ambiente previamente? Com as soluções existentes hoje, o robô teria que navegar com cuidado por todo o ambiente para criar o mapa do local e então ser capaz de executar a tarefa a qual se deseja. Uma opção para resolver este problema seria o desenvolvimento de uma estratégia de predição de mapa. De alguma forma deve ser possível prever o mapa ao qual o robô irá navegar, e assim o robô seria capaz de planejar trajetórias para executar a sua tarefa.

Em (EIGEN et al., 2014) é apresentada a predição de profundidade em uma imagem 2D, o trabalho utiliza uma imagem normal, adquirida por meio de sensores RGB, para conseguir identificar a profundidade dos objetos na imagem. Primeiro a imagem é tratada de forma global, e então começa a se tratar em locais específicos, trabalhando com 5x5, 3x3 ou 2x2 pixels.

Um trabalho interessante, mas não relacionado diretamente com a robótica, é o (FIRMAN et al., 2016) onde é apresentado o uso da predição para se criar modelos 3D de objetos. Para se criar o modelo 3D é utilizado dados observados por um sensor de profundidade, como o Microsoft Kinect, que observa partes de um objeto e então é desenvolvido a predição de partes não observadas. Os autores trabalham com vários conceitos considerados estado da arte na área de visão computacional, como o uso de grid 3D (ou grade 3D) e voxel (*Volume Element*).

Técnicas de predição também estão sendo usadas para o planejamento de trajetória, com a finalidade de desviar de obstáculos móveis. Em (KOLLMITZ et al., 2015) é desenvolvido um sistema para prever a trajetória de uma pessoa, a fim de se criar rotas para um robô móvel. O trabalho consiste em prever os movimentos humanos em uma caminhada por exemplo, a fim de que o robô seja capaz de andar junto ao humano, desviar ou esperar o humano passar. Estudos semelhantes são feitos em outros trabalhos, como (BAYOUMI; BENNEWITZ, 2016) e (UNHELKAR et al., 2015).

Em (CHANG et al., 2007) é apresentado um novo modelo de SLAM, denotado P-SLAM (Simultaneous Localization and Mapping With Environmental-Structure Prediction) que trata de uma predição da estrutura do mapa. O trabalho consiste em mapear ambientes internos, gerando uma hipótese do ambiente não conhecido com base no ambiente já conhecido. Esta hipótese consiste em afirmar que a estrutura desconhecida é semelhante a medida anteriormente, com base em busca de padrões que se repetem e então é criado o mapa previsto. Para criar a hipótese e o mapa, o trabalho executa quatro passos: localiza as fronteiras do mapa; coleta a estrutura das fronteiras; procura por estruturas similares na parte conhecida do mapa e gera a hipótese se existir similaridade. Uma outra variante do SLAM, é o SLAMMOT (Simultaneous Localization and Mapping and Moving Object Tracking) que pode ser encontrado em (WANG et al., 2003) e tem por finalidade detectar e seguir objetos. Em (CHUNG; HUANG, 2008) é apresentado uma técnica de predição de mapa junto com a predição de movimentos de objetos em ambientes desconhecidos, esta técnica consiste na fusão do P-SLAM com o SLAMMOT.

2.3 CONCLUSÃO

Os sensores são dispositivos de extrema importância para a robótica móvel, pois eles permitem que o robô perceba o mundo a sua volta. Cada sensor é capaz de perceber o meio de uma forma diferente, alguns em 2D outros em 3D mas cada sensor possui um método específico de coleta de dados fazendo com que cada sensor apresente uma experiência diferente e forneça informações diferentes para o robô. Este capítulo apresentou uma classificação dos sensores, além de trazer duas técnicas utilizadas para a obtenção de dados do meio, como a luz estruturada e o tempo de voo e trouxe uma explicação do funcionamento de sensores lasers e câmeras 3D ToF. Este estudo apresentou o estado da arte sobre mapeamento de ambiente, a fim de se gerar novas ideias e conhecimentos para se trazer ao domínio da robótica. Ao mesmo tempo que realizou uma discussão resumida dos principais termos relacionados para entender sua aplicabilidade dentro da robótica.

A reconstrução é a técnica motivada em criar modelos 3D de um objeto com base em dados observados do mundo real. O mapeamento se preocupa com a localização do robô no mapa do ambiente, diferenciando da reconstrução. A predição, por sua vez, se preocupa em descobrir partes ocultas de um objeto o reconstruindo apenas com partes observadas. A reconstrução e o mapeamento necessitam varrer o objeto ou o mapa para se ter um modelo, ambos colocam em seu modelo apenas aquilo que foi observado pelos seus sensores.

Como resultado deste estudo, se mostrou possível desenvolver uma estratégia de mapeamento em que o robô parado ou com a mínima movimentação, seja possível criar o mapa do ambiente em que o robô necessita navegar, através do uso de técnicas de predição como já acontece em trabalhos como a reconstrução de objetos em visão computacional e a predição de movimentos de pessoas em robótica móvel.

3 PREDIÇÃO DE MAPEAMENTO EM VASOS DE PRESSÃO ESFÉRICOS

Este capítulo tem por finalidade apresentar o robô autônomo de inspeção utilizado nesta dissertação, assim como apresentar a abordagem utilizada para a predição do mapeamento para navegação autônoma. Primeiro será apresentado o robô, assim como uma explicação sobre as suas fontes de percepção e características físicas. Após a apresentação do robô, cada subseção será referente a uma parte da abordagem proposta. A inspeção dos tanques de armazenamento só pode ser iniciada após um planejamento rigoroso de trajetória de inspeção que leva em consideração algumas informações específicas sobre as características do tanque. O robô deve executar vários procedimentos para entender o ambiente ao seu redor e se preparar para a tarefa de inspeção, como visto na Figura 16, onde cada procedimento diz respeito a uma subseção deste capítulo.

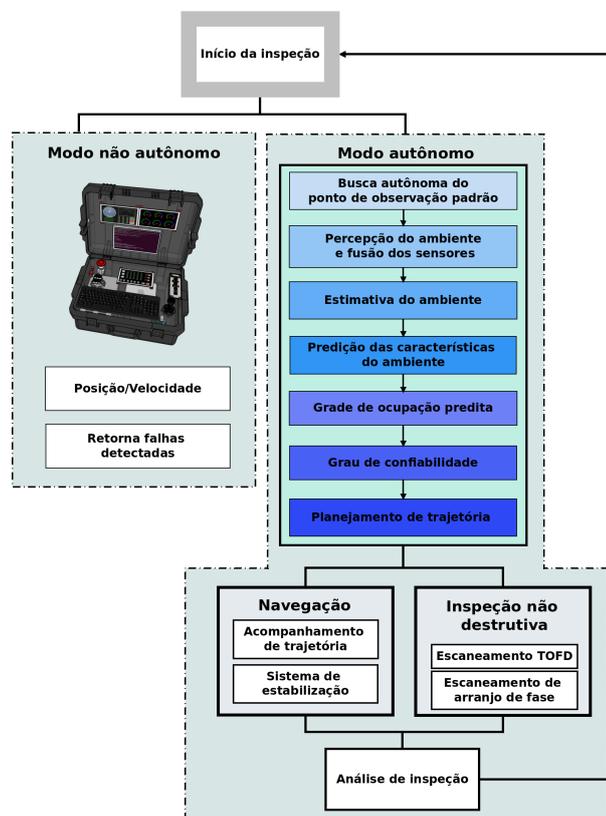


Figura 16: Abordagem para o planejamento de inspeção inteligente.

A *busca autônoma do ponto de observação padrão* diz respeito à navegação autônoma feito pelo robô até chegar ao ponto de observação padrão, que é o lugar onde se torna possível extrair as características da esfera. A *percepção do ambiente e fusão dos sensores* traz uma explicação sobre as transformações realizadas para que todas as fontes de percepção possam ser vistas pela mesma referência, e traz também uma estratégia de fusão de pontos. A *estimativa do ambiente* consiste em levantar características da esfera como raio e centro, enquanto a *predição das características do ambiente* consiste em levantar informações particulares da esfera como cordões de solda. Por fim a *predição da grade de ocupação e análise de confiabilidade* desenvolvem estratégias de representação da esfera predita utilizando pontos conhecidos e não conhecidos da esfera para então realizar o *planejamento de trajetória*, que tem por finalidade desenvolver a trajetória que o robô deve seguir para realizar a inspeção.

3.1 ROBÔ AUTÔNOMO DE INSPEÇÃO

Visando resolver o problema de inspeção em vasos de pressão esféricos, está sendo desenvolvido no Laboratório de Automação e Sistemas de Controle Avançado (LASCA), na Universidade Tecnológica Federal do Paraná (UTFPR), um robô para inspeção autônoma em tanques de armazenamento. O nome dado ao robô é *Robô Autônomo de Inspeção* (RAI), ou do inglês *Autonomous Inspection Robot* (AIR). Existem atualmente duas versões do robô, sendo elas AIR-1 e AIR-2. O AIR-1 é um protótipo funcional enquanto o AIR-2 está em sua fase de prototipagem e por esta razão este trabalho utilizou como padrão o robô AIR-1. A Figura 17 traz uma ilustração dos dois robôs.

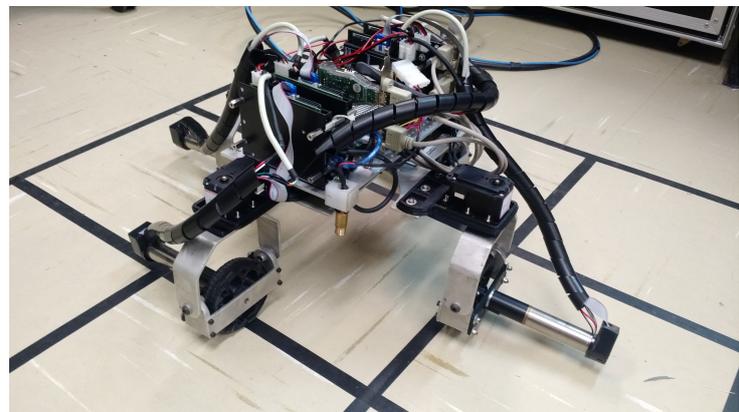


Figura 17: À esquerda: Robô Autônomo de Inspeção (AIR-1) em sua primeira versão. À direita: Robô Autônomo de Inspeção (AIR-2) em sua segunda versão.

Para o desenvolvimento deste trabalho, o robô AIR-1 sofreu alterações em sua estrutura original. No início do projeto, o robô era equipado somente com 2 fontes de percepção, o LIDAR e a câmera de meio-alcance (Kinect). Houve a necessidade de criar uma plataforma móvel que comportasse todas as fontes de percepção necessárias para este trabalho. A plataforma foi modelada para ser produzida em uma impressora 3D, com espaço para os sensores e também suporte para os dois servo motores que controlam a rotação da plataforma. Os dois servos motores foram programados para atuarem juntos conduzindo a plataforma móvel, de acordo com o ângulo desejado. A posição da câmera de profundidade meio-alcance (Kinect) foi alterada, a fim de não sofrer interferência dos sensores fixados na base móvel. Além das alterações mencionadas, cada fonte de percepção necessita de uma fonte de alimentação específica, que foram ligadas ao robô. Também houve a necessidade de adicionar um novo hub USB para gerenciar todas as novas fontes de percepção, assim como instalar os pacotes necessários no processador para que todas as fontes de percepção funcionem. A Figura 18 traz o robô AIR-1 ilustrando de forma visual as contribuições desenvolvidas pelo autor durante o desenvolvimento deste trabalho.



Figura 18: À esquerda: Robô Autônomo de Inspeção (AIR-1) no início deste trabalho. À direita: Robô Autônomo de Inspeção (AIR-1) ao final deste trabalho.

O AIR-1 utiliza a plataforma de software ROS (Robot Operating System) que une todas as informações provenientes de seus sensores, motores e atuadores em um repositório central acessível por qualquer computador que tenha permissão. É possível haver múltiplos processadores coletando informações ao mesmo tempo assim como controlando as ações do robô. Um exemplo do uso do ROS é no controle dos servo motores presentes no AIR-1, que são controlados por um Arduino conectado ao ROS. Para executar algum movimento no servomotor, basta enviar o grau em um tópico localizado no repositório central, o Arduino lê este comando e executa a ação. Outras informações sobre o ROS podem ser acessadas em (ROS, 2015), informações sobre o AIR-1 e AIR-2 utilizando o ROS podem ser acessadas em (VEIGA, 2015) e (SANTOS, 2016).

O AIR-1 possui estrutura mecânica baseada em dois conjuntos paralelos de rodas magnéticas fixas (não orientáveis). Cada conjunto de rodas é ligado por uma correia em V, onde apenas dois motores são responsáveis por movimentar as quatro rodas magnéticas, isto é, o robô tem dois graus de liberdade controláveis, como é possível observar na Figura 18. Os conjuntos de rodas magnéticas estão desalinhados para superar pequenos obstáculos (como cordões de solda) sem diminuir a sua força de adesão. O sistema de adesão foi projetado para fornecer uma adesão segura entre o robô e a superfície, transportando os sistemas eletrônicos e de inspeção. O robô pesa 12kg e o cabo umbilical pesa 0,4kg/m, o robô carregará um cordão umbilical de até 20m. Cada roda consiste em um conjunto de dois ímãs de neodímio em forma de anel posicionados entre dois discos de aço e presos por parafusos com baixa permeabilidade magnética. Uma borracha de poliuretano de alta dureza cobre o conjunto ligado, sendo que sua força magnética é de aproximadamente 45kgf. Um sistema de adesão inteligente foi desenvolvido para o reconhecimento inteligente de distúrbios de adesão com base na saída de uma rede neural que modela o campo magnético para prever o deslocamento, usando ainda um eletroímã de segurança. Mais detalhes sobre a construção mecânica do robô, conceito de roda e análise de força magnética podem ser encontrados em (ROVANI, 2013; SANTOS et al., 2016; ESPINOZA et al., 2014, 2013; OLIVEIRA et al., 2012).

O robô possui um amplo conjunto de sistemas de percepção, composto por cinco fontes principais, como mostrado na Figura 19. Um conjunto de câmeras de profundidade é usado para mapeamento de ambiente e detecção de obstáculos. Estas câmeras são fixas, uma na frente do robô (*Câmera de profundidade curto-alcance*) e outra em uma estrutura acima do robô (*Câmera de profundidade meio-alcance*). Um subconjunto de fontes de percepção é montado em uma plataforma móvel que pode ser girada em torno do eixo de inclinação e melhora seu alcance de detecção e sua precisão. Um deles é o *sensor de longa-distância* (até 70 metros com precisão de milímetros), aplicado para medir a distância relativa entre robô e ambiente, permitindo a estimativa dos parâmetros do tanque. O *LIDAR* é empregado para detectar qualquer obstáculo durante a navegação e para medir as características laterais do ambiente. A *Câmera de profundidade longo-alcance ToF* fornece uma nuvem de pontos com campo de visão larga e é utilizada para melhorar o reconhecimento do ambiente.

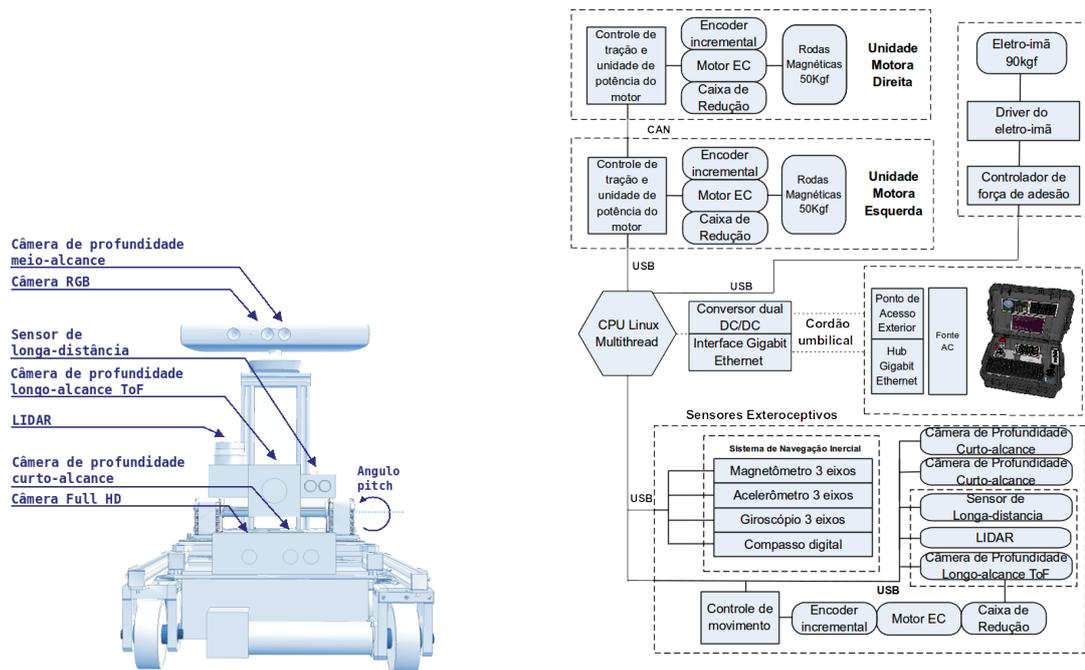


Figura 19: À esquerda: Fontes de percepção do Robô Autônomo de Inspeção v1 (AIR-1). À direita: Diagrama de Hardware presente no AIR-1.

É possível visualizar o alcance e campo de visão de cada fonte de percepção pelas figuras 20 e 21. O *LIDAR* possui um campo de visão horizontal de 240° e opera a uma distância entre 0,2 e 5,6 metros. A *câmera de profundidade curto-alcance* possui um campo de visão de 46° vertical por 59° horizontal operando a uma distância entre 0,2 e 1,2 metros, fornecendo uma nuvem de pontos em uma resolução de 640×480 pontos. A *câmera de profundidade meio-alcance* possui um campo de visão de 43° (v) por 57° (h) atuando entre 0,8 e 4 metros, fornecendo uma nuvem de pontos com resolução de 640×480 pontos. A *câmera de profundidade longo-alcance ToF* possui um campo de visão de 56° (v) por 69° (h) atuando a uma distância de 0,1 a 10 metros. Por último, o *sensor de longa-distância* atua a uma distância entre 0,05 e 70 metros com campo de visão de 135° (v) fornecidos pela plataforma móvel. É possível visualizar a marca e modelo de cada fonte de percepção através da Tabela 1.

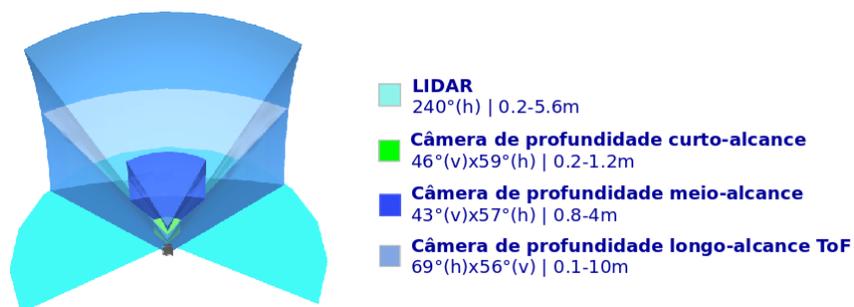


Figura 20: Fontes de percepção do AIR-1, possibilitando uma visualização do campo de visão de cada sensor.

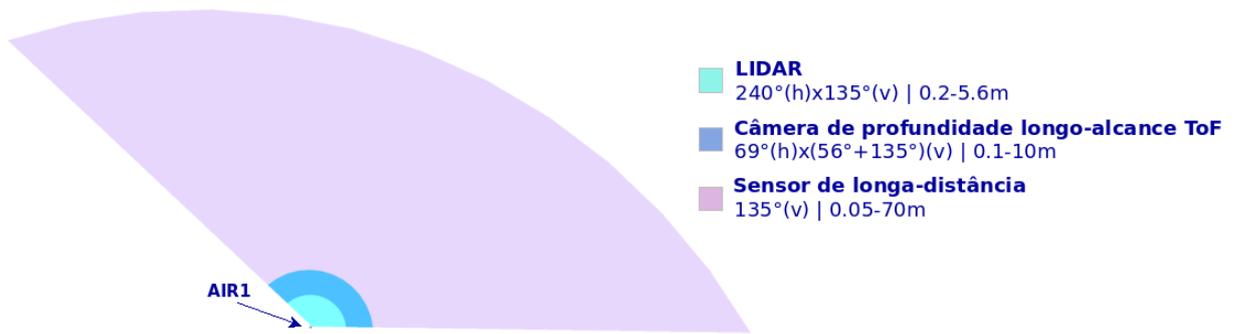


Figura 21: Fontes de percepção com uma vista de seu alcance, possibilitando uma visualização do alcance de cada sensor.

Tabela 1: Fontes de percepção e seus respectivos sensores.

Fonte de percepção	Sensor
Câmera de profundidade meio-alcance	Microsoft Kinect v1 (Xbox 360)
Sensor de longa-distância	Dimetix EDS-Co 20
Câmera de profundidade longo-alcance ToF	Mesa SR4000
LIDAR	Hokuyo URG-04LX-UG01
Câmera de profundidade curto-alcance	Intel RealSense F200

3.2 BUSCA AUTÔNOMA DO PONTO DE OBSERVAÇÃO PADRÃO

O robô precisa localizar dois pontos de referência, que no caso de tanques esféricos são formados pelo entroncamento de dois cordões de solda para realizar uma estimativa confiável do tanque de armazenamento, sendo esta condição chamada de *ponto de observação padrão*. Para elucidar os entroncamentos de solda, a Figura 22 traz um exemplo. O ponto onde o cordão de solda vertical e horizontal se encontram é denominado *entroncamento*. O ponto de observação padrão é o lugar onde o robô por meio de suas fontes de percepção consiga encontrar dois entroncamentos de solda com uma boa precisão. O ponto de observação padrão é qualquer ponto onde o robô esteja posicionado entre dois entroncamentos de solda, não sendo único. As características desses entroncamentos (como distância e ângulo entre eles) são cruciais para a previsão do ambiente. A busca pelo ponto de observação padrão deve ser executada autonomamente sem qualquer interferência do operador.



Figura 22: Exemplo de dois entroncamentos de solda vistos de dentro do vaso de pressão esférico.

O robô usa dois sensores de profundidade para esta tarefa: a câmera de profundidade longo-alcance ToF e a câmera de profundidade meio-alcance. As duas câmeras são posicionadas de tal forma que uma complemente a outra, evitando o máximo possível de sobreposição. A câmera de profundidade meio-alcance é apontada o mais próximo possível do robô, enquanto a câmera de profundidade longo-alcance ToF é girada em 15 graus, através da plataforma de sensores, para que tenha um maior alcance. O efeito desta estratégia pode ser vista na Figura 23. Estes sensores funcionam com pouca ou nenhuma luminosidade, a não ser a emitida pelo próprio sensor (como o infravermelho), o que é ideal pois o ambiente de inspeção possui pouca ou nenhuma luminosidade.

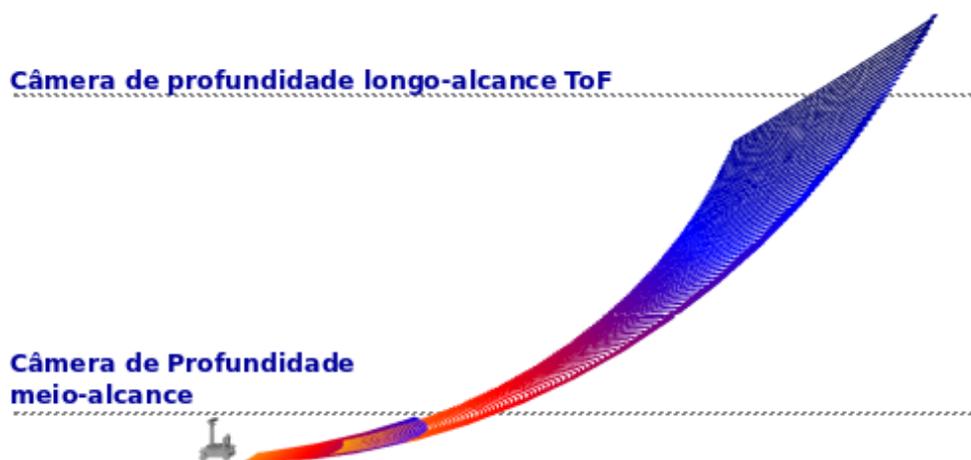


Figura 23: Visão expandida das percepções do AIR-1 vistos de dentro do vaso de pressão esférico.

As ações de busca autônoma são descritas no fluxograma da Figura 24, onde o robô executa uma sequência de movimentos para localizar os entroncamentos de solda em sua visão de profundidade. O primeiro passo é se orientar corretamente em relação ao cordão de solda. O robô executa esta ação através da *câmera de profundidade longo-alcance ToF* com 10 metros de alcance. A percepção de profundidade é obtida em formato de nuvem de pontos e então convertida em imagem em escala de cinza ou mapa de profundidade. Para encontrar os entroncamentos é utilizado o algoritmo de *Harris-Stephens* (HARRIS; STEPHENS, 1988). Se nenhum entroncamento é encontrado, o robô gira para a direita e repete este passo até encontrar qualquer entroncamento, quando o primeiro é encontrado o robô gira para o lado oposto para detectar o segundo.

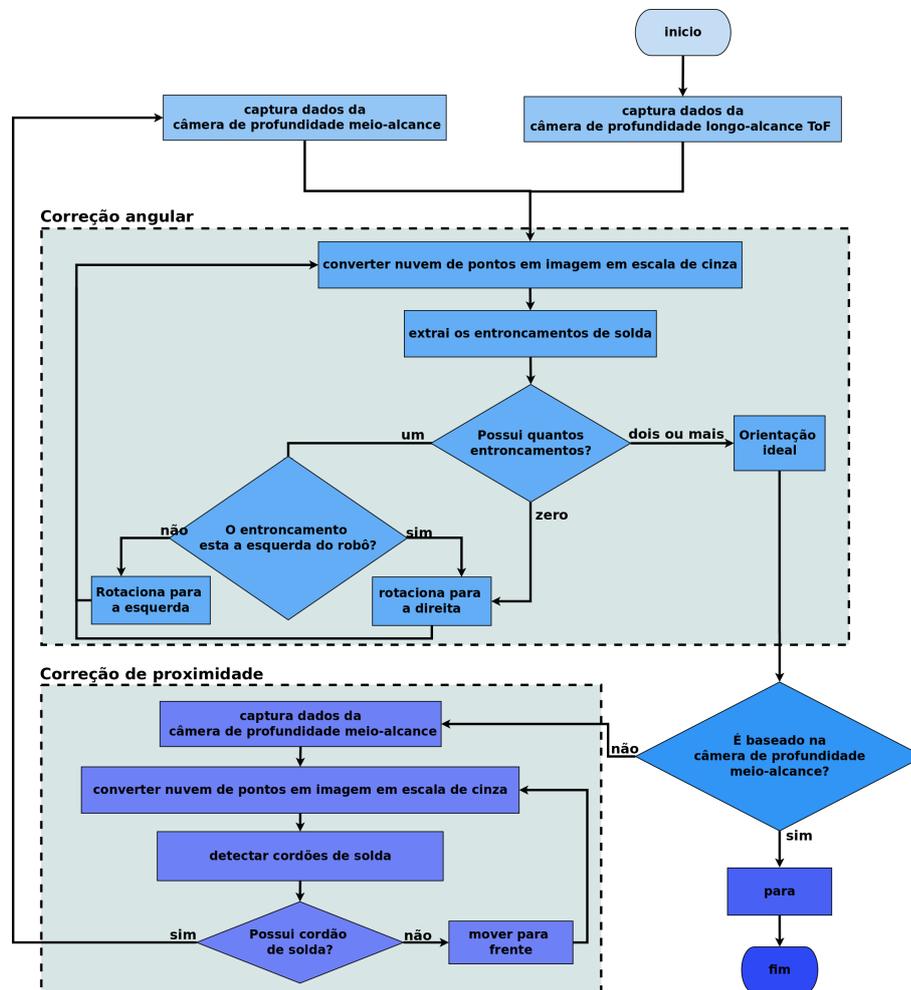


Figura 24: Fluxograma com as regras para a busca autônoma do ponto de observação padrão.

O algoritmo de Harris-Stephens foi apresentado em 1988 (HARRIS; STEPHENS, 1988), com a intenção de resolver problemas existentes com relação a algoritmos de detecção de bordas. Estes algoritmos se preocupam em detectar todas as bordas de uma imagem, e muitas vezes deformam algum objeto o tornando irreconhecível. Este fato acontece por ser utilizado um limiar para a detecção de bordas, e bordas perto deste limiar se perdem. A solução proposta no algoritmo Harris-Stephens é o uso de um detector de cantos e bordas e não mais somente detector de bordas. O algoritmo detector de cantos de Moravec (MORAVEC, 1980) funciona considerando uma janela local na imagem e determinando as mudanças médias de intensidade de imagem que resultam do deslocamento da janela por uma pequena quantidade em várias direções. Alguns problemas são levantados com relação ao detector de bordas de Moravec, entre esses o fato de somente um conjunto discreto de mudanças a cada 45 graus ser considerado. Os autores propõem soluções para os problemas apontados, chegando então ao algoritmo de Harris-Stephens, capaz de identificar bordas e cantos. Um exemplo do uso do algoritmo pode ser visto na Figura 25.

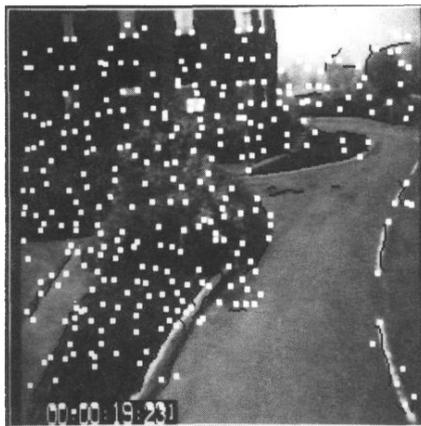


Figura 25: Algoritmo de Harris-Stephens na detecção de cantos e bordas. Os cantos se encontram em branco, enquanto as bordas em preto.

Fonte: (HARRIS; STEPHENS, 1988)

Após o alinhamento frontal do robô no meio de dois entroncamentos de solda pela câmera de profundidade longo-alcance ToF, o robô pode estar posicionado a uma longa distância do cordão de solda e dos entroncamentos, sendo necessário executar a *correção de proximidade*. O robô se move para frente até detectar e focar o cordão de solda em sua câmera de profundidade meio-alcance. A correção de proximidade ocorre para que o robô esteja a uma curta distância do cordão de solda e de seus entroncamentos, para que os próximos passos (extração de dados) sejam executados. A distância ideal entre o robô e seus entroncamentos é entre 0,8 e 4 metros, distância de atuação da câmera de profundidade meio-alcance. O reconhecimento do cordão de solda é obtido através do uso do *filtro de Roberts* (SENTHILKUMARAN; RAJESH, 2009).

O detector de bordas de *Roberts* opera de maneira simples, executando uma medição do gradiente espacial. São aplicadas duas máscaras convolucionais em sequência, uma na horizontal e outra na vertical. Essas duas máscaras são dadas na Figura 26. O valor de cada pixel na imagem de saída representa a magnitude absoluta estimada do gradiente espacial. Um exemplo do uso do filtro de Roberts pode ser visto na Figura 27.

+1	0
0	-1

0	+1
-1	0

Figura 26: Máscaras do filtro de detecção de bordas de Roberts. À Esquerda: filtro horizontal. À direita: filtro vertical.

Fonte: (SENTHILKUMARAN; RAJESH, 2009)



Figura 27: Método de detecção de bordas de Roberts. A esquerda: figura utilizada para a detecção. A Direita: resultado da aplicação do filtro de Roberts.

Fonte: (SENTHILKUMARAN; RAJESH, 2009)

A correção de direção é feita para assegurar a orientação entre o robô e o alvo (isto é, entroncamentos de cordão de solda) após o movimento para a frente, dentro do tanque de pressão esférico. Neste momento, o robô deve procurar um par de entroncamentos de solda em sua câmera de profundidade meio-alcance. A nuvem de pontos é convertida em um mapa de profundidade em escalas de cinza e é aplicado o filtro de Roberts para reconhecer os entroncamentos de solda. Por fim, aplica-se a função de dilatação morfológica para que os entroncamentos de solda se tornem maiores e mais visíveis, permitindo o reconhecimento correto por meio do algoritmo de *Harris-Stephens*. Todas as técnicas apresentadas aqui poderão ser melhor vistas no capítulo 4, onde são apresentadas por meio de experimentos reais.

A função morfológica dilatar é uma das funções morfológicas simples, juntamente com a função erosão (DOUGHERTY et al., 2003). A função de dilatação expande os artefatos de uma imagem ou características desta imagem, enquanto a função de erosão tem como objetivo comprimir os artefatos de uma imagem. As máscaras para as duas funções podem ser as mais diversas, dependendo do quanto se deseja dilatar ou erodir uma imagem. Um exemplo do uso das duas funções pode ser visto na Figura 28, onde é apresentada a imagem utilizada como exemplo, a máscara e o resultado das duas operações, (estas funções são apropriadas para imagens binárias). No trabalho, a função de dilatação é utilizada após a identificação das bordas da imagem com a função de Roberts para que os cordões de solda se tornem maiores.

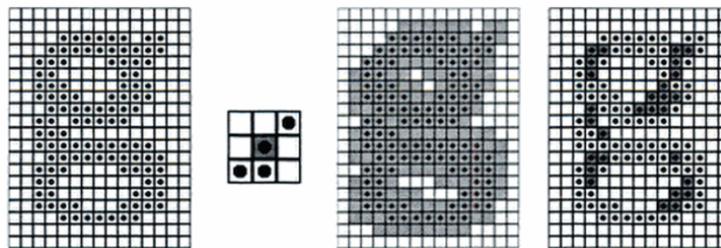


Figura 28: Funções binárias de dilatação e erosão. A esquerda: imagem binária utilizada como exemplo, Ao centro esquerdo: máscara utilizada nas duas funções. Ao centro a direita: máscara aplicada a imagem original com a função dilatação. A direita: máscara aplicada a imagem original com a função erosão.

3.3 PERCEPÇÃO DO AMBIENTE E FUSÃO DOS SENSORES

Esta seção tem por objetivo apresentar uma técnica de fusão de nuvens de pontos a fim de reduzir redundâncias de medições e assim o número de pontos armazenados (quanto menor o número de pontos, menor o custo computacional). Para que seja possível realizar a fusão, as nuvens de pontos das fontes de percepção devem ser todas deslocadas para a mesma posição, fazendo assim com que todas as fontes de percepção informem a mesma medida em relação ao mesmo objeto. Para fazer este deslocamento é preciso adotar uma estratégia com sistemas de coordenadas e transformações lineares.

Cada sensor do robô se encontra em uma posição diferente gerando referências diferentes. Para resolver este problema são criados *sistemas de coordenadas*. Estes sistemas de coordenadas consistem em definir a distância de todos os sensores a um ponto comum, e então é feita uma *transformação* dos dados medidos pelos sensores para o ponto de referência, fazendo com que todos os dados medidos tenham origem no mesmo ponto. A Figura 29 traz o sistema de coordenadas do robô, onde todas as medições são convertidas para a coordenada no centro do robô (base-link). Foi utilizando uma abordagem empírica de calibração dos sensores.

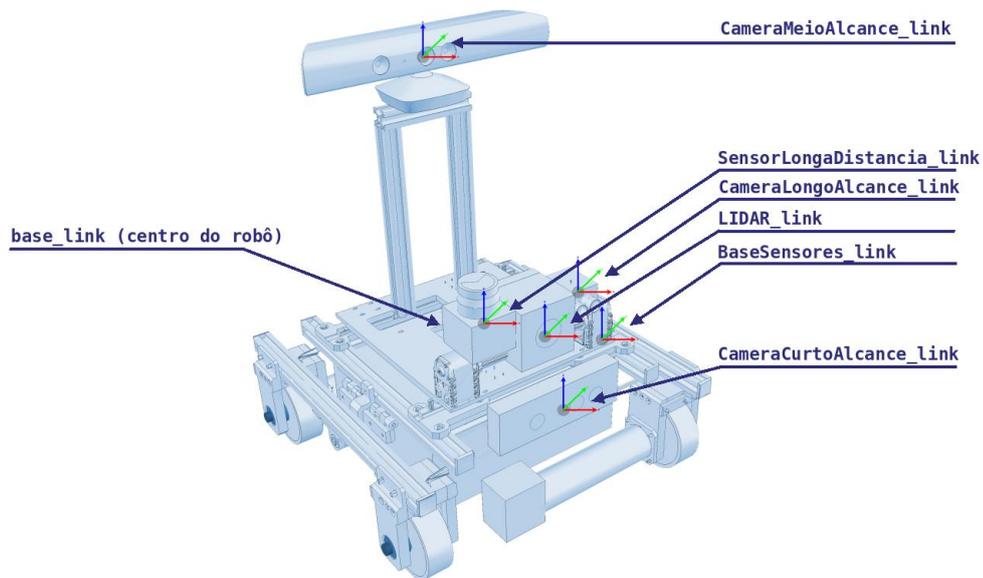


Figura 29: Sistemas de coordenadas das fontes de percepção.

Além dos sistemas de coordenadas apresentados que são referentes às fontes de percepção, existem outros sistemas de coordenadas relevantes como *map* (mapa), *odom* (odometria) e *base_footprint*. O *map* é considerado a referência global, o *odom* diz respeito a posição inicial do robô e o *base_footprint* diz respeito ao centro do robô, mas diferente do *base_link* está localizado ao chão do robô. O nome de cada sistema de coordenada foi escolhido respeitando a norma REP-105 (MEEUSSEN, 2017). A Figura 30 traz um exemplo destes sistemas de referência, onde AIR-1 diz respeito ao *base_link* e os sistemas de coordenadas apresentados pela Figura 29.

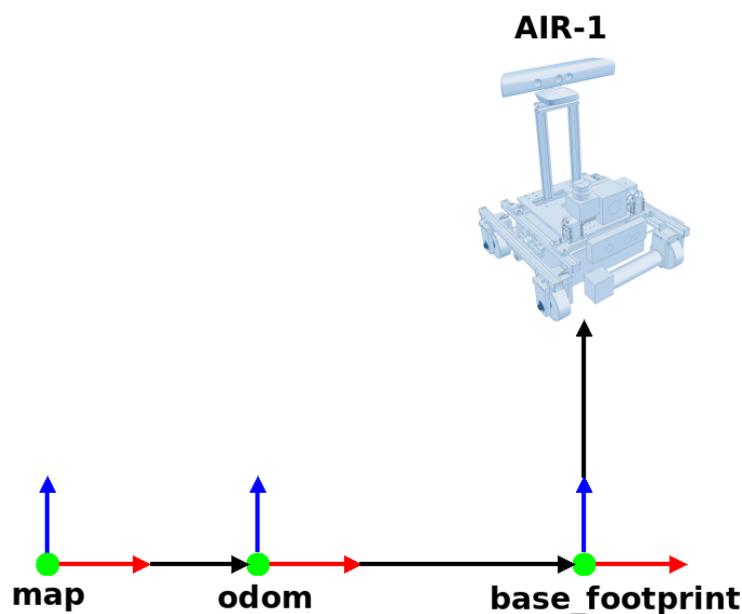


Figura 30: Demais sistemas de coordenadas, referentes a posição do robô.

É possível fazer com que as medições sejam transformadas para diferentes sistemas de coordenadas. Por exemplo, o valor medido por um sensor de distância pode ser convertido (transformado) para o base_link, odometria ou mapa. A Figura 31 traz a árvore de transformação do AIR-1. Por exemplo, o sensor de longa-distância é dependente do base_link, que por sua vez é dependente do base_footprint que é dependente do odom que é dependente do map. Esta relação significa que o dependente é medido em relação ao seu nó superior, sendo assim é necessário saber o deslocamento de cada dependente em relação ao seu nó superior para que seja possível desenvolver as transformações.

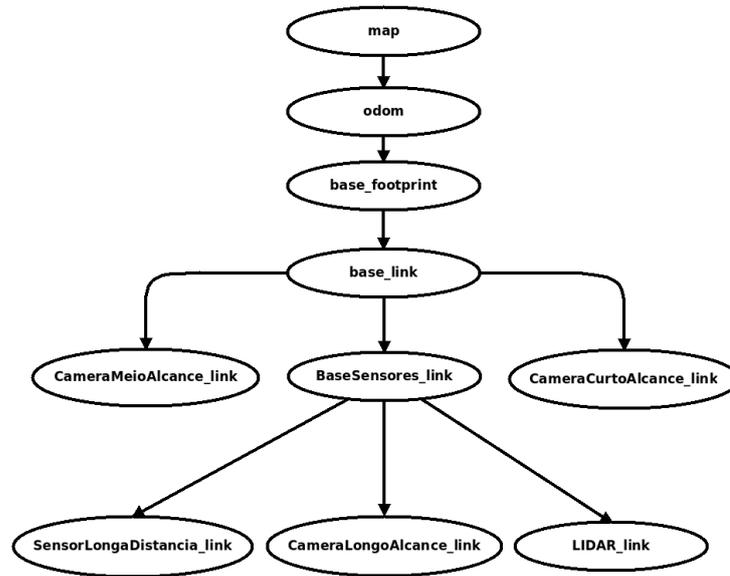


Figura 31: Árvore de transformação do AIR-1, apresentando os principais sistemas de coordenadas.

Matematicamente, os pontos são representados por vetores e cada transformação é representada por uma matriz de transformação homogênea, onde é executada rotação e translação de um ponto a outro. A transformação entre os nós n e $n + 1$ pode ser definida por

$$p^n = o_{n+1}^n + R_{n+1}^n p^{n+1} \quad (3)$$

onde p^{n+1} é o vetor de entrada para a transformação, o representa a translação, R é a transformação rotacional, p^n é o vetor resultante e o é um vetor coluna que representa a translação ou deslocamento dos eixos.

$$o = \begin{bmatrix} o_x \\ o_y \\ o_z \end{bmatrix} \quad (4)$$

O termo R corresponde às rotações nos eixos x , y e z , onde existe uma matriz de rotação para cada um dos eixos, que combinadas geram a matriz de rotação completa. A rotação no eixo x é função do ângulo ψ (psi), enquanto no eixo y tem-se o ângulo θ (theta) e por fim, no eixo z é função do ângulo ϕ (phi).

$$R_x(\psi) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\psi) & -\sin(\psi) \\ 0 & \sin(\psi) & \cos(\psi) \end{bmatrix} \quad (5)$$

$$R_y(\theta) = \begin{bmatrix} \cos(\theta) & 0 & \sin(\theta) \\ 0 & 1 & 0 \\ -\sin(\theta) & 0 & \cos(\theta) \end{bmatrix} \quad (6)$$

$$R_z(\phi) = \begin{bmatrix} \cos(\phi) & -\sin(\phi) & 0 \\ \sin(\phi) & \cos(\phi) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (7)$$

Com as três matrizes definidas, é possível combiná-las para criar a matriz de rotação completa, com todos os eixos:

$$R = R_x(\psi)R_y(\theta)R_z(\phi) = \quad (8)$$

$$\begin{bmatrix} \cos(\phi)\cos(\theta) & \cos(\phi)\sin(\theta)\sin(\psi) - \sin(\phi)\cos(\psi) & \cos(\phi)\sin(\theta)\cos(\psi) + \sin(\phi)\sin(\psi) \\ \sin(\phi)\cos(\theta) & \sin(\phi)\sin(\theta)\sin(\psi) + \cos(\phi)\cos(\psi) & \sin(\phi)\sin(\theta)\cos(\psi) - \cos(\phi)\sin(\psi) \\ -\sin(\theta) & \cos(\theta)\sin(\psi) & \cos(\theta)\cos(\psi) \end{bmatrix}$$

A matriz de transformação homogênea, a partir da equação 3, é dada então por:

$$p^n = A_{n+1}^n [p^{n+1}] \quad (9)$$

onde

$$A_{n+1}^n = \begin{bmatrix} R_{n+1}^n & o_{n+1}^n \\ 0^T & 1 \end{bmatrix} \quad (10)$$

É possível desenvolver a transformação entre qualquer nó da árvore, por serem encadeadas. Por exemplo, para transformar entre o primeiro nó e o quarto nó da árvore de transformação, basta encadear as transformações entre os nós, da seguinte forma,

$$A_0^3 = A_0^1 A_1^2 A_2^3, \quad (11)$$

e em seguida transformar o ponto desejado.

$$p^3 = A_0^3 p^0. \quad (12)$$

Converter os pontos com base no sistema de coordenadas do map ou odom são boas estratégias quando o objetivo é mapear o ambiente, pois o robô realizará diversas medições em lugares diferentes e a posição desses lugares deve ser levada em consideração. Para a fusão dos sensores, a melhor estratégia é converter todas as fontes de percepção para o centro do robô para que seja possível identificar os pontos que se interseccionam e permitir identificar os pontos mais adequados de cada sensor.

O AIR-1 é composto por cinco fontes de percepção 3D, no entanto, essas percepções possuem várias seções de intercepção onde as medições de diferentes fontes se sobrepõem. Esta condição ocorre nos limites de alcance das fontes de percepção ou perto de um obstáculo. Neste caso, duas ou mais fontes se sobrepõem porque há um obstáculo perto do robô e as fontes de percepção estão apontadas na mesma direção, como mostrado na Figura. 32.

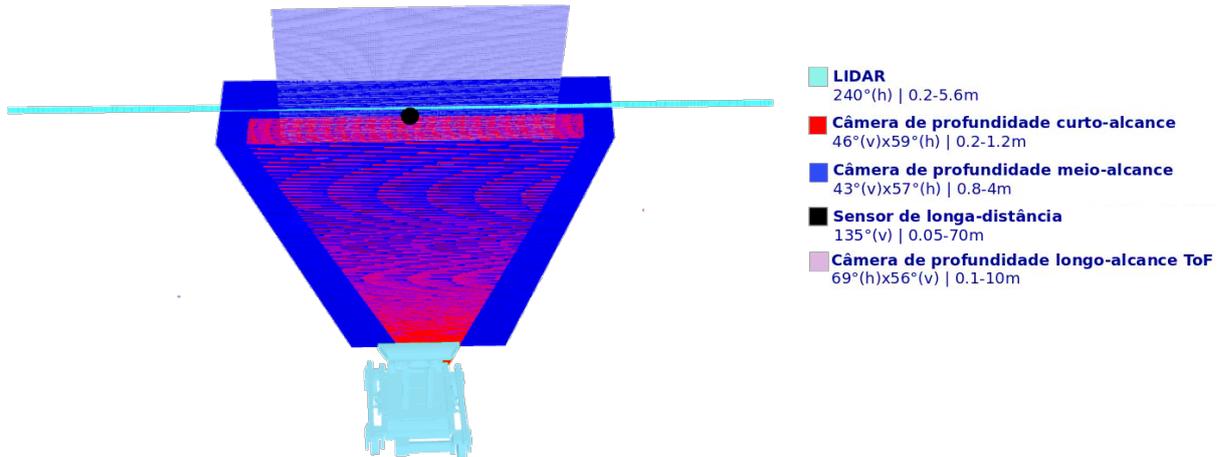


Figura 32: Fontes de percepção sobrepostas, fato ocorre por existir uma parede a curta distância.

Para amenizar o número de pontos e resolver o problema da duplicação (quando sobrepostos) uma estratégia de fusão de pontos foi adotada. Esta estratégia consiste em determinar uma importância para cada ponto medido (p_n), fundindo os pontos por uma distância Euclidiana entre o ponto medido e seus vizinhos, definido como:

$$\frac{\delta_1}{\delta T} p_1 + \frac{\delta_2}{\delta T} p_2 + \dots + \frac{\delta_n}{\delta T} p_n, \quad (13)$$

onde δ_n é a importância atribuída a cada ponto e δT é a importância global.

O valor δ_n de cada dado de percepção é aplicado como entrada na fusão de sensores onde seu valor varia de 0 (menos relevante) a 1 (mais relevante). A especificação de cada fonte de percepção é empregada (Tabela 2) para delimitar a região de medição ideal de cada sensor, permitindo o uso da medição ideal de cada fonte de percepção. Regras são projetadas para trabalhar com a região ideal de cada fonte de percepção. Essa região ideal é aquela onde o erro é menor em relação às outras fontes de percepção, como visto pela Tabela 2. A 1 metro, o sensor câmera de profundidade longo-alcance ToF apresenta um erro menor que o sensor câmera de profundidade meio-alcance, mas possui um erro maior que o sensor de longa-distância.

Tabela 2: Especificações das fontes de percepção

	LIDAR	Câmera de Profundidade Curto-alcance	Câmera de Profundidade Meio-alcance	Câmera de Profundidade Longo-alcance ToF	Sensor de Longa-distância
Alcance	0,02 a 4m	0,2 a 1,2m	0,8 a 4m	0,1 a 10,0m	0,05 a 70m
Erro Mínimo	3cm	*ne	*ne	1cm	0,2cm
Erro Máximo	3%	5%	5%	1%	0,3%
Erro (em centímetros)					
0,5m	3	2,5	*fa	1	0,2
1m	3	5	5	1	0,2
2,5m	7,6	*fa	12,5	2,5	0,75
4m	12	*fa	20	4	1,2
5,5m	*fa	*fa	*fa	5,5	1,65
7m	*fa	*fa	*fa	7	2,1
9m	*fa	*fa	*fa	9	2,7
11m	*fa	*fa	*fa	*fa	3,3

*fa é fora de alcance, *ne é não especificado

A partir da tabela 1 uma estratégia foi desenvolvida, para que cada sensor possua uma ponderação diferente na fusão, dependendo de seu erro. A Tabela 3 mostra a base de regras do interpolador desenvolvido, onde as linhas representam a distância entre o sensor e o ponto medido, e as colunas são as fontes de percepção. As regras representam a relevância de cada ponto de acordo com as propriedades da fonte de percepção, como muito baixa (MB), baixa (B), razoável (R), alta (A) ou muito alta (MA). A relevância de cada ponto medido é especificada quanto à precisão de sua fonte de percepção que varia com a faixa de atuação. Quando a fonte de percepção tem precisão indefinida para uma região específica, sua medida terá uma relevância muito baixa.

Tabela 3: Regras e conceitos

	Fonte de percepção	Distância [m]					
		>1	2,5	4	5,5	7	<10
1	LIDAR	R	R	R	MB	MB	MB
2	Câmera de Profundidade Curto-alcance	B	MB	MB	MB	MB	MB
3	Câmera de Profundidade Meio-alcance	MB	B	B	MB	MB	MB
4	Câmera de Profundidade Longo-alcance ToF	A	A	A	A	A	MB
5	Sensor de Longa-distância	MA	MA	MA	MA	MA	MA

A relevância de cada ponto na fusão depende da distância entre a fonte de percepção e objeto e também seu erro em relação ao erro de outros sensores presentes no AIR-1. A tabela 3 mostra as regras adotadas com base nestes valores (distância e erro) sendo possível obter um conceito para cada ponto dependendo de sua origem e distância. A relevância é dada de acordo com o conceito, onde MB (muito baixo) recebe grau de relevância 0,2, B (baixo) recebe grau de relevância 0,4, R (razoável) recebe grau de relevância 0,6, A (alto) recebe grau de relevância 0,8 e MA (muito alto) recebe grau de relevância 1,0.

3.4 ESTIMATIVA DO AMBIENTE

Para realizar a estimativa do ambiente, alguns pontos são coletados do vaso de pressão esférico com o uso das fontes de percepção do robô. Esses pontos então são aplicados nas formulas matemáticas que ao final são capazes de informar o raio e o centro da esfera. Para melhorar o método de identificação, é aplicada uma filtragem nos pontos. A filtragem de desvio é realizada aplicando o desvio padrão em todos os pontos medidos e descartando todos os pontos fracos. Esta metodologia foi apresentada também em (TEIXEIRA et al., 2016).

A estimativa da topologia do vaso de pressão esférica é calculada através do uso da técnica dos mínimos quadrados, como mostrado na equação 14. A técnica otimiza matematicamente um conjunto de dados buscando o melhor ajuste, minimizando a soma das diferenças quadráticas entre os dados estimados e observados, como em (MURALIKRISHNAN; RAJA, 2008).

$$E = \sum_{i=1}^m r_i - r, \quad (14)$$

onde r é o valor inicial do raio estimado e r_i é o valor observado para um total de m pontos.

O raio r pode ser obtido por

$$r = \sqrt{(x - x_c)^2 + (y - y_c)^2 + (z - z_c)^2}, \quad (15)$$

E o raio observado r_i pode ser calculado como

$$r_i = \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2 + (z_i - z_c)^2}, \quad (16)$$

onde x_c, y_c e z_c representam o centro da esfera; x, y e z representam qualquer ponto da esfera; e x_i, y_i e z_i representam um ponto na esfera com índice i .

Após a definição das equações 15-16, torna-se possível reescrever a equação 14 como

$$E = \sum_{i=1}^m \left((x_i - x_c)^2 + (y_i - y_c)^2 + (z_i - z_c)^2 - r^2 \right)^2, \quad (17)$$

onde o centro pode ser obtido pela equação

$$\begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} = \arg \min E. \quad (18)$$

A equação 17 pode ser convertida em um sistema matricial e resolvido o problema $Ax = B$, como

$$A = \begin{bmatrix} 2x_1 & 2y_1 & 2z_1 \\ 2x_2 & 2y_2 & 2z_2 \\ \vdots & \vdots & \vdots \\ 2x_n & 2y_n & 2z_n \end{bmatrix}, \quad (37) \quad B = \begin{bmatrix} x_1^2 & y_1^2 & z_1^2 \\ x_2^2 & y_2^2 & z_2^2 \\ \vdots & \vdots & \vdots \\ x_n^2 & y_n^2 & z_n^2 \end{bmatrix}. \quad (38)$$

O centro do vaso de pressão esférico c pode ser calculado como

$$x = \begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} = \left((A'A)^{-1} A'B \right) = c \quad (39)$$

O raio da esfera sr pode ser calculado como uma média de raio (Eq.15), definida como

$$sr = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_i - x_c)^2 + (y_i - y_c)^2 + (z_i - z_c)^2} \quad (40)$$

Ao fim das equações, é possível obter o centro e o raio da esfera, valores fundamentais para o desenvolvimento dos próximos passos, como a predição das características da esfera.

3.5 PREDIÇÃO DAS CARACTERÍSTICAS DO AMBIENTE

Após o reconhecimento do ambiente através da estimação de suas propriedades é possível classificar a topologia do tanque e prever suas características particulares. Os vasos de pressão esféricos são construídos com quatro tipos de arranjos de placas (MOSS; BASIC, 2012), como

- *cubo expandido, segmento quadrado ou bola de futebol* é comumente aplicado à esferas pequenas com menos de cerca de 6 metros de diâmetro;
- *meridiano, casca de laranja, ou melancia em versão de 3 cursos* está relacionado a esferas com diâmetro entre 6 e 9 metros;
- *tipo de bola de futebol parcial* é projetado para esferas com diâmetro entre 9 e 18 metros;
- *meridiano, casca de laranja, ou melancia em versão de 5 cursos* é aplicado à grandes esferas com mais de 18 metros de diâmetro.

Os vasos de pressão esféricos são projetado de acordo com padrões de fabricação para vasos de pressão esféricos (N-268, 2012; N-1281, 2014; N-1520, 2010; N-2111, 2011), e podem atingir mais de 18 metros de diâmetro e são utilizados em refinarias de petróleo para armazenamento de GLP.

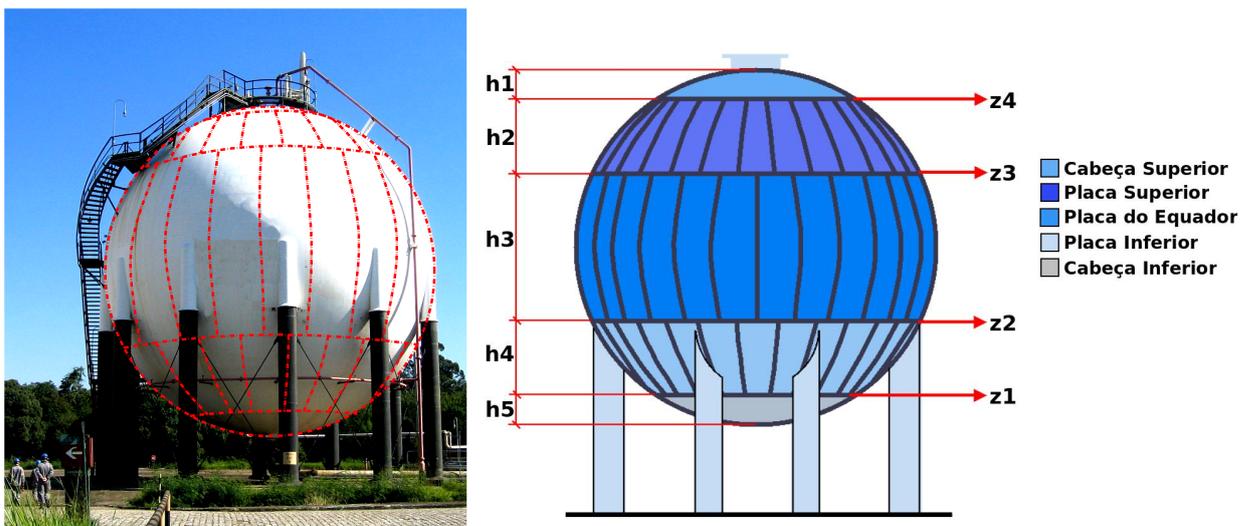


Figura 33: À esquerda: Vaso de pressão esférico com seus cordões de solda pontilhados. À direita: divisão de seções existentes no vaso de pressão esférico.

O vaso de pressão esférico, tipo meridiano em versão de 5 cursos, é subdividido equatorialmente em cinco seções (como visto na Figura 33 a direita), de acordo com a distância entre duas placas (h_N), como *Cabeça Superior* (h_1), *Placa Superior* (h_2), *Placa do Equador* (h_3), *Placa Inferior* (h_4) e *Cabeça Inferior* (h_5).

Com o robô localizado entre dois entroncamentos de cordão de solda (seção 3.2) tendo a estimativa do centro e do raio do vaso de pressão esférico (seção 3.4), torna-se possível determinar a altura de cada seção equatorial (h_N) e a posição em relação à base do tanque (z_N), como mostrado na Figura 33. O cálculo de valores de seções equatoriais considera os padrões de projeto e fabricação para vasos de pressão, que especificam o equilíbrio de volumes entre essas áreas (MOSS; BASIC, 2012), como

$$\begin{aligned}
 h_3 h_4 &= z_4 - c \\
 h_5 &= sr - h_3 h_4 \\
 h_4 &= 0.54065 * h_3 h_4 \\
 h_3 &= 0.91870 * h_3 h_4 \\
 h_2 &= h_4 \\
 h_1 &= h_5,
 \end{aligned}
 \tag{41}$$

onde sr é o raio do vaso de pressão esférico (calculado na equação 40) e c é o centro deste tanque (como estimado por 39).

Após esses procedimentos, é possível estimar a posição de toda a seção equatorial em relação à base do tanque (z_N), como

$$\begin{aligned}
 z_3 &= z_4 + h_4 \\
 z_2 &= z_3 + h_3 \\
 z_1 &= z_2 + h_2,
 \end{aligned}
 \tag{42}$$

onde, z_4 é a posição da seção equatorial observada, estimada em busca autônoma do ponto de observação padrão (seção 3.2).

Até aqui já se torna possível identificar todos os h_s e z_s presentes no vaso de pressão esférico. O que significa que o tamanho de todas as seções (placas) que são os h_s e a posição de interseção entre todas as seções que são os z_s , que podem representar também as soldas que ligam as placas no plano, vertical foram obtidas.

Um último passo se faz necessário para que seja possível reconstruir toda a esfera: os pontos de conexão entre as placas no plano horizontal. Este cálculo é feito através da posição dos dois entroncamentos de soldas encontrados. Primeiro se calcula o ângulo entre os dois pontos para se saber a distância entre eles em um círculo, e então é dividido pelo tamanho da largura do raio de Z_n , fazendo com que sejam espaçados uniformemente. Este procedimento identifica todos os pontos de conexão das placas em uma seção hn , normalmente sendo a h_4 . As demais conexões podem ser identificadas pelo fato de h_4 e h_2 possuírem as mesmas propriedades e h_3 possuir as suas conexões no meio das presentes em h_4 e h_2 . Logo, identificando as conexões de h_4 é possível deduzir h_2 e h_3 . O mesmo ocorre com h_3 e h_2 . As chapas em h_5 e h_1 não possuem entroncamentos de solda, portanto evita falsos resultados. Os entroncamentos sempre serão encontrados em z_1, z_2, z_3 ou z_4 e dizem respeito as placas h_4, h_3 e h_2 .

3.6 GRADE DE OCUPAÇÃO PREDITA

Após a estimativa e predição do ambiente e suas características, a grade de ocupação pode ser criada. Esta tarefa é baseada na distribuição uniforme de voxels na grade de ocupação prevista, assegurando o espaçamento igual entre um voxel e todos os seus voxels vizinhos. A grade de ocupação é estimada para envolver o ambiente de inspeção, criando uma grade regular no espaço tridimensional que representa o tanque previsto, como mostrado na Figura 34.



Figura 34: Um exemplo de uma grade de ocupação predita do ambiente de inspeção.

O procedimento para determinar a distribuição uniforme de voxels na grade de ocupação é baseado na previsão do ambiente, onde são estimados os seus principais recursos como centro c (equação 39) e raio sr (equação 40). A resolução da grade de ocupação é determinada pelo tamanho físico da sonda de ensaio não destrutivo, chamada como tamanho de voxel vs . O voxel é um cubo com os seis lados iguais, o tamanho do voxel refere-se ao tamanho em centímetros cúbicos do voxel, podendo ser definido ao executar o algoritmo. O algoritmo 1 traz os passos utilizados para a criação da grade de ocupação.

Algoritmo 1: Predição da grade de ocupação.

Entrada: $c[x, y, z]$ é o vetor de coordenadas do centro da esfera; sr é o raio da esfera; vs é o tamanho do voxel.

Saída: $o_p[m][3]$ é a $m \times 3$ matriz de pontos distribuídos na esfera.

```

/* comprimento de uma volta na esfera */
1  $le \leftarrow 2 * \pi * sr$  /* relação do comprimento da seção da esfera
   pelo tamanho do voxel */
2  $np \leftarrow le / vs$  /* contador */
3  $i \leftarrow 0$ 
   /* define o espaço no eixo Z */
4 para  $\theta \leftarrow (-\pi/2) : \frac{2\pi}{np} : (\pi/2)$  faça
   /* computa o próximo ponto no eixo Z */
5    $z \leftarrow (\sin(\theta) * sr) + c[z]$ 
   /* radio da esfera na seção no eixo Z */
6    $rc \leftarrow \sqrt{(2 * sr) - (2 * (sr - (z + sr)))}$ 
   /* define o espaço nos eixos X e Y */
7   para  $\phi \leftarrow (-\pi) : \frac{2\pi}{np} : (\pi)$  faça
     /* computa a coordenada do voxel no eixo X */
8      $o_p[i, x] \leftarrow (\cos(\phi) * rc) + c[x]$ 
     /* computa a coordenada do voxel no eixo Y */
9      $o_p[i, y] \leftarrow (\sin(\phi) * rc) + c[y]$ 
     /* computa a coordenada do voxel no eixo Z */
10     $o_p[i, z] \leftarrow z$ 
11     $i \leftarrow i + 1$ 
   /* retorna a matriz com as coordenadas de todos os
     voxels */
12 retorna  $o_p[m][3]$ 

```

3.7 GRAU DE CONFIABILIDADE

Após a construção da grade de ocupação, o ambiente de inspeção é estimado e decomposto em um grupo de pontos tridimensionais (voxels) uniformemente distribuídos na superfície do tanque, criando a grade de ocupação. No entanto, a maioria destes pontos são estimados e não observados, o que introduz incertezas na medição. A confiabilidade de um voxel estimado está diretamente relacionada com sua distância de voxels medidos e a porcentagem de voxels vizinhos conhecidos. Assim, um modelo *fuzzy* foi desenvolvido para quantificar esta incerteza, em termos da confiabilidade da estimativa, a cada voxel estimado na grade de ocupação.

O modelo *fuzzy* para inferência do grau de confiabilidade de um voxel utiliza como entrada a porcentagem de voxels observados conhecidos na vizinhança do voxel analisado, a menor distância para um voxel observado e o raio do vaso de pressão esférico. A Figura 35 ilustra a abordagem utilizada, onde o voxel verde representa o ponto analisado para cálculo do grau de confiança e os pontos em azul representam os voxels observados através de fontes de percepção. O círculo vermelho representa os limites de vizinhança usados para identificar a porcentagem de pontos conhecidos. Além disso, a porcentagem de voxels observados é a soma dos pontos conhecidos na vizinhança divididos pelo total de pontos conhecidos. A menor distância entre o voxel analisado e o ponto observado mais próximo, ilustrado na Figura 35 por uma seta vermelha, pode estar fora dos limites de vizinhança. Neste caso, apenas a distância é levada em consideração e a porcentagem de pontos conhecidos é igual a 0, uma vez que não possui nenhum ponto conhecido dentro do círculo que delimita a vizinhança.

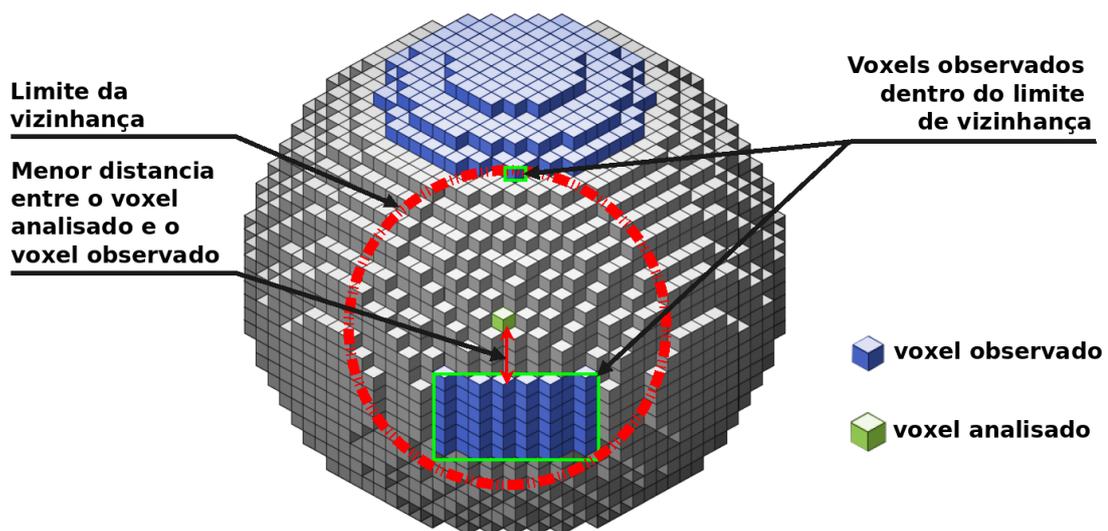


Figura 35: Ilustração da estratégia utilizada para a análise de confiabilidade para cada voxel.

A Figura 36 traz as funções de pertinência de entrada e saída do modelo *fuzzy* enquanto a figura 37 apresenta o gráfico de superfície gerado pela base de regras considerada. As funções de pertinência foram projetadas de tal maneira que o raio da esfera influencie no grau de confiança. Por exemplo, em uma esfera grande é interessante que o grau de confiança se dissipe de forma lenta e por uma região maior. Caso o mesmo ocorra em uma esfera pequena, todos os pontos da esfera receberão um alto grau de confiança. Desta forma, a dissipação do grau de confiança na esfera esta diretamente relacionada a seu tamanho.

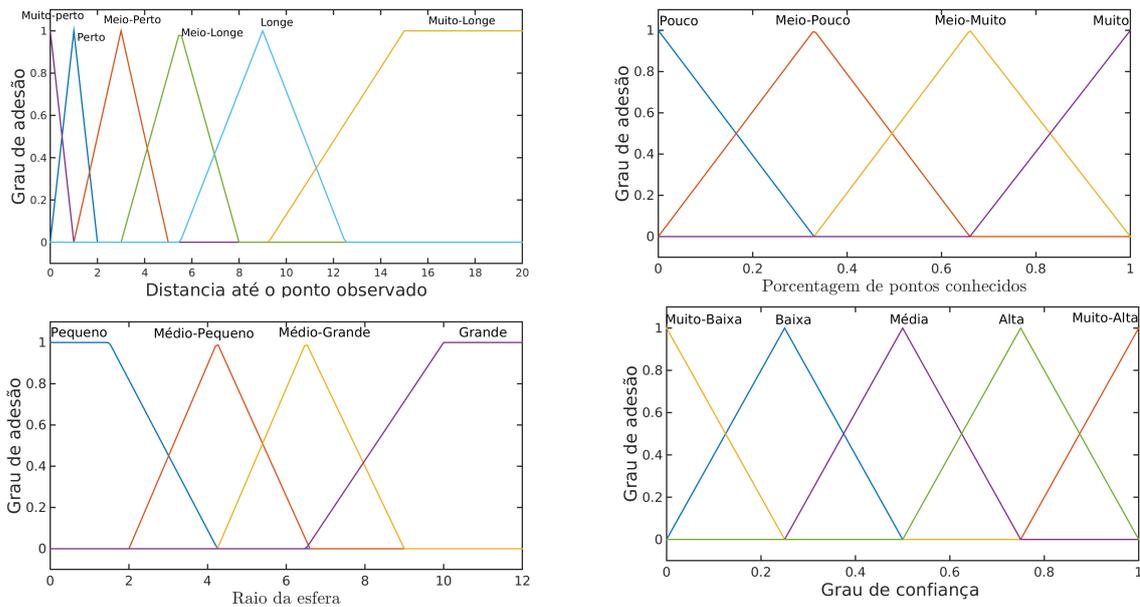


Figura 36: Funções de pertinência do modelo *fuzzy* desenvolvido. À esquerda superior: Menor distância entre o ponto analisado e um ponto observado. À direita superior: Porcentagem de pontos conhecidos dentro do raio do limite de vizinhança. À esquerda inferior: Raio da esfera. À Direita inferior: Grau de confiabilidade dada ao ponto analisado.

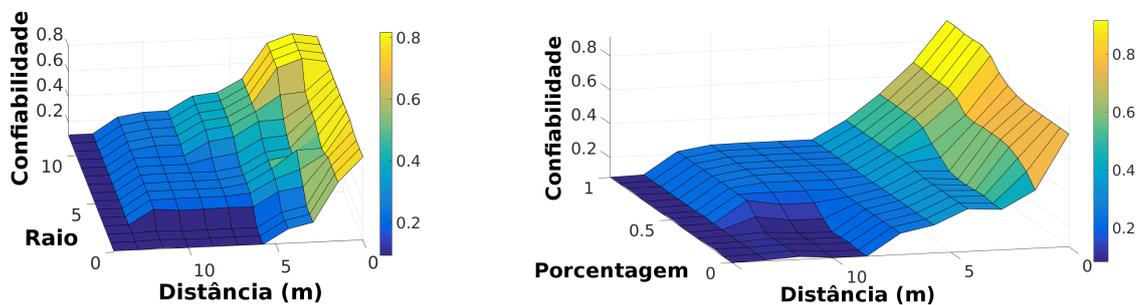


Figura 37: Gráficos de superfície *fuzzy*.

O modelo *fuzzy* proposto apresenta bons resultados. A fim de diminuir o custo computacional, uma rede neural artificial (RNA) foi desenvolvida para reproduzir o comportamento do modelo *fuzzy* desenvolvido. A RNA utiliza como entrada a porcentagem de voxels conhecidos ao redor, menor distância entre voxel analisado e observado, e raio da esfera. A estrutura da RNA pode ser observada na Figura 38, onde possui 3 entradas, 6 neurônios na camada oculta e como saída a confiabilidade do voxel estimado.

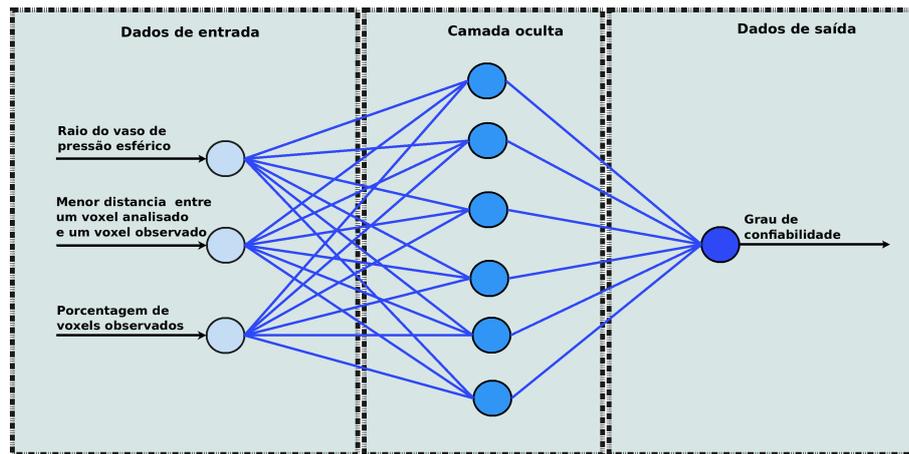


Figura 38: Topologia da rede neural artificial (RNA) com 3 neurônios na camada de entrada, 6 neurônios na camada oculta e 1 neurônio na camada de saída.

A coleta de dados para o treinamento da RNA foi realizada em ambiente virtual, levando em consideração quatro tamanhos de vasos de pressão esféricos diferentes, assim como quantidade de pontos conhecidos diferentes. Os pontos conhecidos foram agrupados ou espalhados de maneira aleatória pela esfera. Os experimentos foram realizados com 1% e 99% de pontos conhecidos em uma distribuição agrupada e com 20%, 40% e 60% em distribuições agrupadas e aleatórias, totalizando dez experimentos para cada tamanho de vaso de pressão. Um total de 40 experimentos foram realizados em quatro vasos de pressão, com diâmetros de 6, 10, 14.6 e 18.25 metros.

O conjunto de pontos utilizados para treinar a RNA foi composto pelos pontos de todos os vasos de pressão (539.410 pontos), menos o número de pontos observados (270,705), resultando em 268.705 pontos. Sendo que 70% dos pontos foram utilizados para treinamento (188.793), 15% para validação (40.456) e 15% para testes (40.456). O Mean Squared Error (MSE) de treinamento foi $8.21e-04$, para o teste foi $8.16e-04$ e para validação foi $8.21e-04$. A Figura 39 traz um exemplo do uso modelo *fuzzy* e da RNA desenvolvidos para uma esfera de 10 metros de diâmetro, com pontos conhecidos agrupados e espalhados.

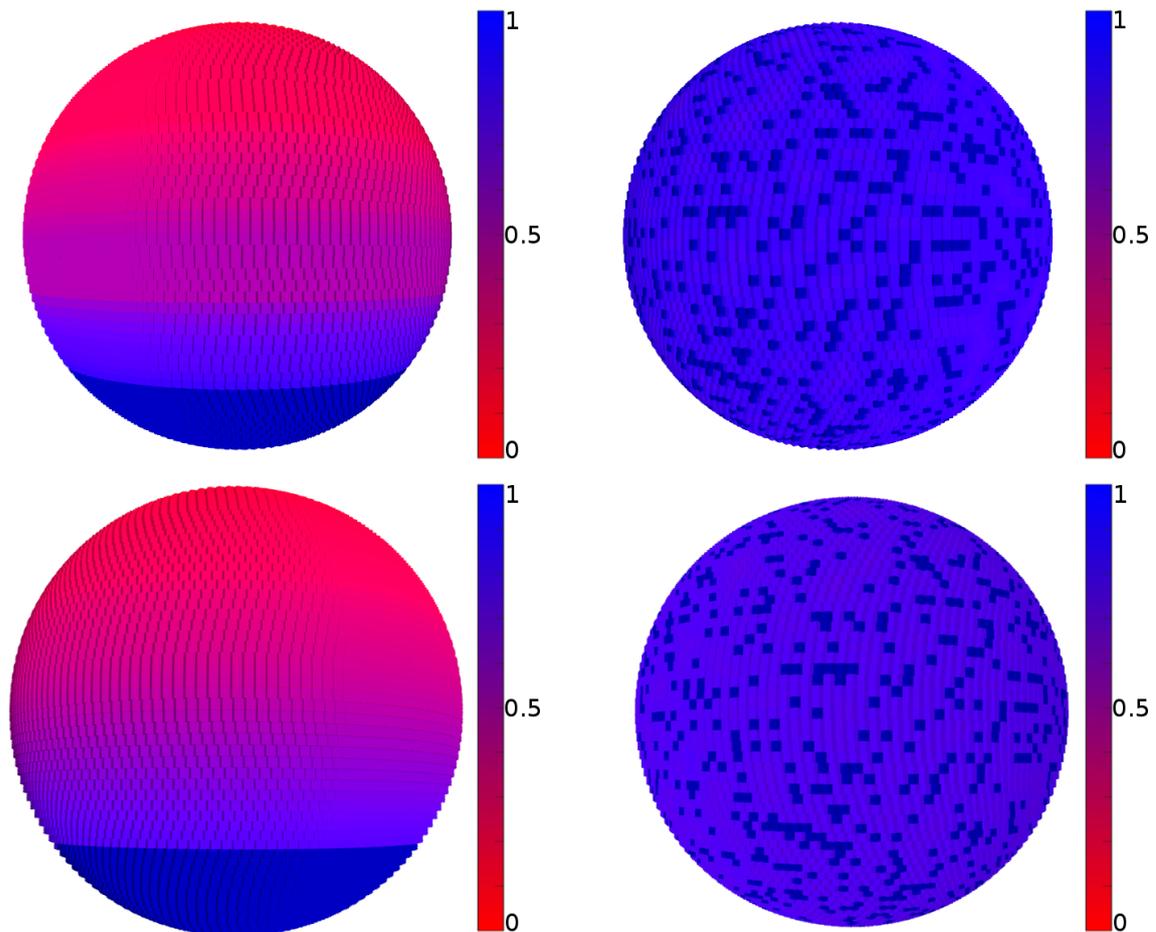


Figura 39: Exemplo de funcionamento do modelo *fuzzy* e RNA desenvolvidos na aplicação de grau de confiabilidade para pontos preditos em uma esfera de 10 metros, contendo 20% dos pontos conhecidos. À esquerda superior: *Fuzzy* com pontos agrupados. À direita superior: *Fuzzy* com pontos distribuídos. À esquerda inferior: RNA com pontos agrupados. À direita inferior: RNA com pontos distribuídos.

A RNA mostrou maior suavidade em relação ao modelo *Fuzzy* e um menor tempo de execução, enquanto o modelo *Fuzzy* leva 0,05 segundos para aplicar o grau de confiabilidade a um voxel, a RNA leva 0,03 segundos. Para uma esfera de 10 metros de diâmetro, são gerados 7926 voxels, fazendo com que a diferença de tempo entre o modelo *Fuzzy* e RNA seja de 158,53 segundos. Para ilustrar os resultados obtidos pela RNA após o treinamento, um diagrama de caixa foi desenvolvido analisando a diferença do grau de confiabilidade aplicado aos voxels da esfera pelo modelo *Fuzzy* e RNA para uma esfera de 10 metros de diâmetro, possuindo 20% dos voxels conhecidos agrupados e posteriormente 20% dos voxels conhecidos distribuídos (Figura 40), seguindo o que foi apresentada pela Figura 40.

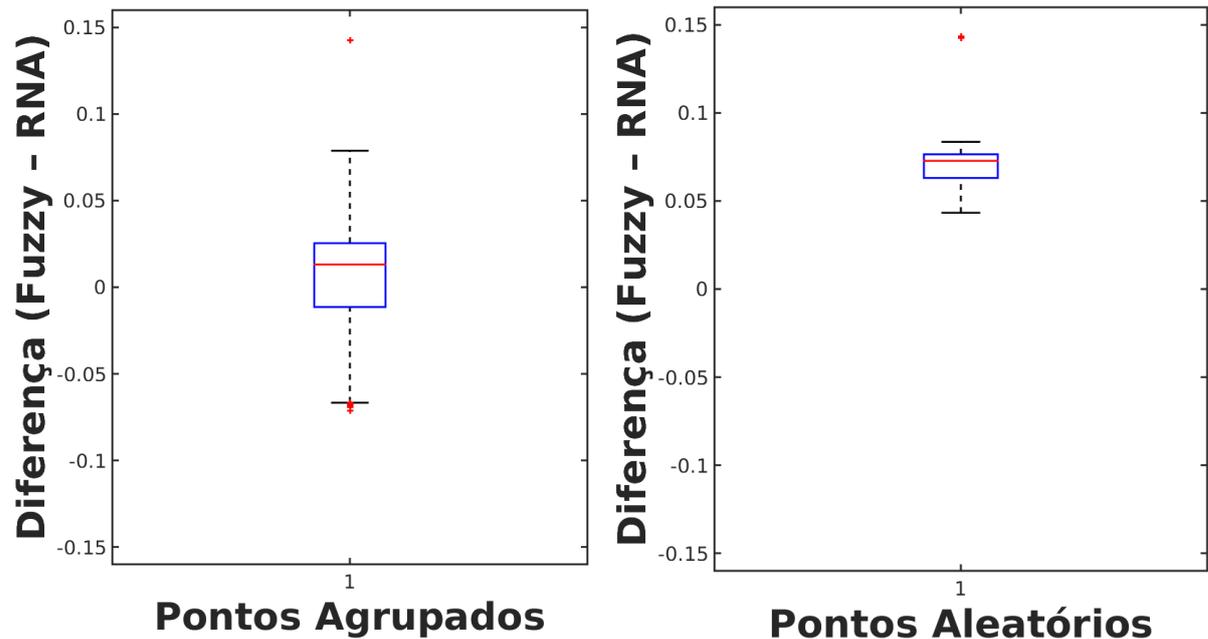


Figura 40: Diagrama de caixa com a diferença entre os dados obtidos pelo modelo *Fuzzy* e RNA na aplicação de grau de confiabilidade para uma esfera de 10 metros de diâmetro com 20% dos voxels conhecidos. À esquerda: Voxels agrupados. À direita: Voxels distribuídos aleatoriamente.

3.8 PLANEJAMENTO DE TRAJETÓRIA

Com o tanque totalmente predito, é possível desenvolver uma estratégia de planejamento de trajetória, que consiste em desenvolver rotas de navegação com base em um mapa conhecido (neste caso, a esfera predita). O planejamento de trajetória tem como objetivo fazer com que o robô passe por todo o vaso de pressão, fazendo várias voltas pelo tanque com um espaço definido entre eles (algoritmo 2). O espaço entre os laços diz respeito ao tamanho da sonda de inspeção utilizada pelo sensor AIR-1.

Algoritmo 2: Planejamento de inspeção em vaso de pressão esférico

Entrada: $c = [x, y, z]$ vetor de coordenadas do centro da esfera; sr é raio da esfera; vs é o tamanho do voxel e p_p é o numero de pontos por volta

Saída: $i_{path}[n]$ é o vetor de pontos 3D do caminho da inspeção

```

1 Inicializações:  $loop \leftarrow \left(\frac{2\pi sr}{vs}\right)$ ;  $i \leftarrow 1$ 
  /* computando o numero de voltas */
2 para  $\varphi \leftarrow 0$  :  $\left(\frac{\pi}{loop}\right)$  até  $\pi$  faça
  /* computando o numero de pontos por volta */
3   para  $\theta \leftarrow \left(-\frac{\pi}{2}\right)$  :  $\left(\frac{2\pi}{p_p}\right)$  até  $\left(\frac{3\pi}{2}\right)$  faça
4      $x \leftarrow (c[x] + sr \cos(\theta)) \cos(\varphi)$ 
5      $y \leftarrow (c[x] + sr \cos(\theta)) \sin(\varphi)$ 
6      $z \leftarrow \theta$ 
  /* orientação espacial por unidade quaternion */
7      $q \leftarrow [\cos(\frac{\varphi}{2}), 0, 0, \sin(\frac{\varphi}{2})]$ 
8      $i_{path}[i] \leftarrow \{x, y, z\}\{q\}$ 
9      $i \leftarrow i + 1$ 
10 retorna  $i_{path}$ 

```

É possível analisar pelo Algoritmo 2 que o cálculo consiste em criar voltas ao redor da esfera levando em consideração o tamanho do robô. O robô possui uma limitação quanto ao grau de liberdade angular causada pela força da adesão magnética de suas rodas, fazendo com que esta estratégia de planejamento de trajetória se torne adequada, embora possa ocorrer de o robô passar pelo mesmo ponto algumas vezes, como na cabeça superior e inferior da esfera. Um exemplo do planejamento de trajetória pode ser visto na figura 41, com uma esfera de 18 metros.

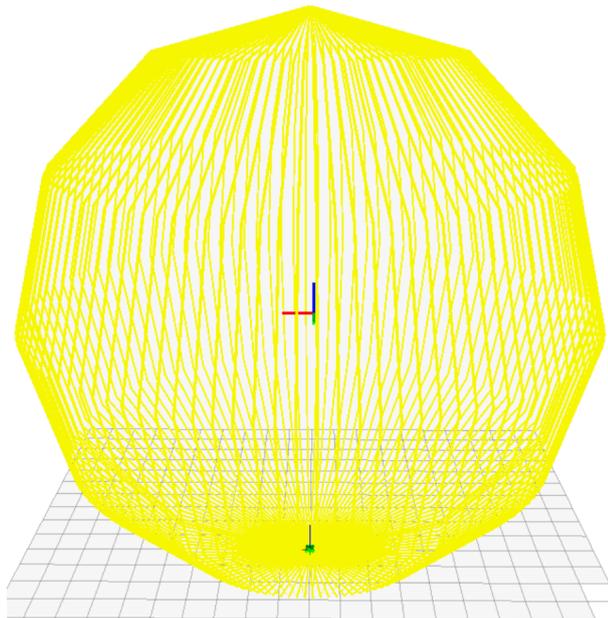


Figura 41: Trajetória pura

3.9 CONCLUSÃO

Este capítulo apresentou o robô AIR-1 desenvolvido pelo LASCA que é capaz de transportar equipamentos e realizar inspeções em vasos de pressão esféricos. Como visto no capítulo 2, para desenvolver trajetórias de navegação é preciso conhecer o ambiente e para conhecer o ambiente o robô precisa navegar às cegas para identificá-lo. Este capítulo desenvolveu várias técnicas utilizadas em separado, e uma forma de combiná-las para que juntas forneçam uma predição do mapa. Esta predição evita que o robô perca tempo andando em lugares desconhecidos para conhecê-los. No capítulo 4 será apresentado a validação das técnicas apresentadas por este capítulo tanto em ambiente simulado quanto em ambiente real.

4 RESULTADOS EXPERIMENTAIS

Este trabalho foi avaliado em dois experimentos, em ambiente virtual e real. No experimento virtual um simulador é utilizado, onde o robô AIR-1 e o vaso de pressão de armazenamento esférico são modelados de acordo com as suas especificações reais, levando em consideração dados como a adesão da roda magnética no tanque. No experimento real, as validações são feitas em laboratório com o robô AIR-1 real.

4.1 EXPERIMENTO VIRTUAL

Para o experimento virtual foi utilizado o *Virtual Robot Experimentation Platform (V-Rep)* (ROBOTICS, 2017) onde foi simulado um vaso de pressão esférico com a finalidade de validar toda a abordagem proposta, onde nele foram consideradas as características reais do robô e do tanque de armazenamento, como cordões de solda em relevo. O robô virtual foi projetado com as mesmas fontes de percepção e adesão magnética que o robô real. O vaso de pressão esférico possui um raio de 9,125 metros. Um exemplo do tanque virtual utilizado pode ser visto na Figura 42, onde também é possível ver o robô dentro do tanque, assim como a posição inicial do robô no experimento.



Figura 42: Vaso de pressão esférico e robô AIR-1 simulados. À esquerda: Vista de fora do vaso de pressão. À direita: vista interna do vaso de pressão esférico simulado.

A primeira tarefa consiste da busca autônoma pelo ponto de observação padrão. O primeiro passo da busca autônoma do ponto de observação padrão consiste em identificar dois entroncamentos de solda com o uso da câmera de profundidade longo-alcance ToF. Esta fonte de percepção foi escolhida pelo fato de possuir um alcance maior, 10 metros, fazendo assim com que ela seja capaz de identificar os entroncamentos mesmo que estejam distantes do robô. Para que seja possível executar esta ação, a nuvem de pontos é convertida em uma imagem em tons de cinza e então é aplicado o algoritmo de *Harris-Stephens*. Os resultados deste procedimento podem ser visto na Figura 43, onde é apresentada a nuvem de pontos da câmera de profundidade longo-alcance ToF, ao centro uma imagem em tons de cinza convertidos diretamente da nuvem de pontos, e direita a identificação dos entroncamentos de solda.



Figura 43: Passos para a obtenção dos entroncamentos de solda com a câmera de profundidade longo-alcance ToF. À esquerda: nuvem de pontos. Ao centro: nuvem de pontos convertida em imagem. À direita: entroncamentos de soldas identificados.

O próximo passo consiste em ir a frente até que seja possível identificar os cordões de solda com a câmera de profundidade meio-alcance. O robô anda para a frente, transforma a nuvem de pontos em imagens em tons de cinza e verifica se existe algum cordão na imagem. Caso não haja, ele anda para frente novamente até identificar o cordão. Este procedimento pode ser visto na Figura 44, onde os dois pontos vermelhos representam os entroncamentos de solda identificados.



Figura 44: Correção de proximidade com o uso da câmera de meio-alcance. À esquerda: visão interna do vaso de pressão esférico simulado com a rota feita pelo robô marcada em azul. À direita: nuvem de pontos da câmera de profundidade meio-alcance com o cordão de solda identificado.

Por fim, uma última correção angular é feita com o uso da câmera de profundidade meio-alcance. Ao final deste procedimento, os dois entroncamentos de solda são identificados e estão próximos ao robô, aumentando assim a acurácia dos dados obtidos. Este último procedimento pode ser visto na Figura 45.

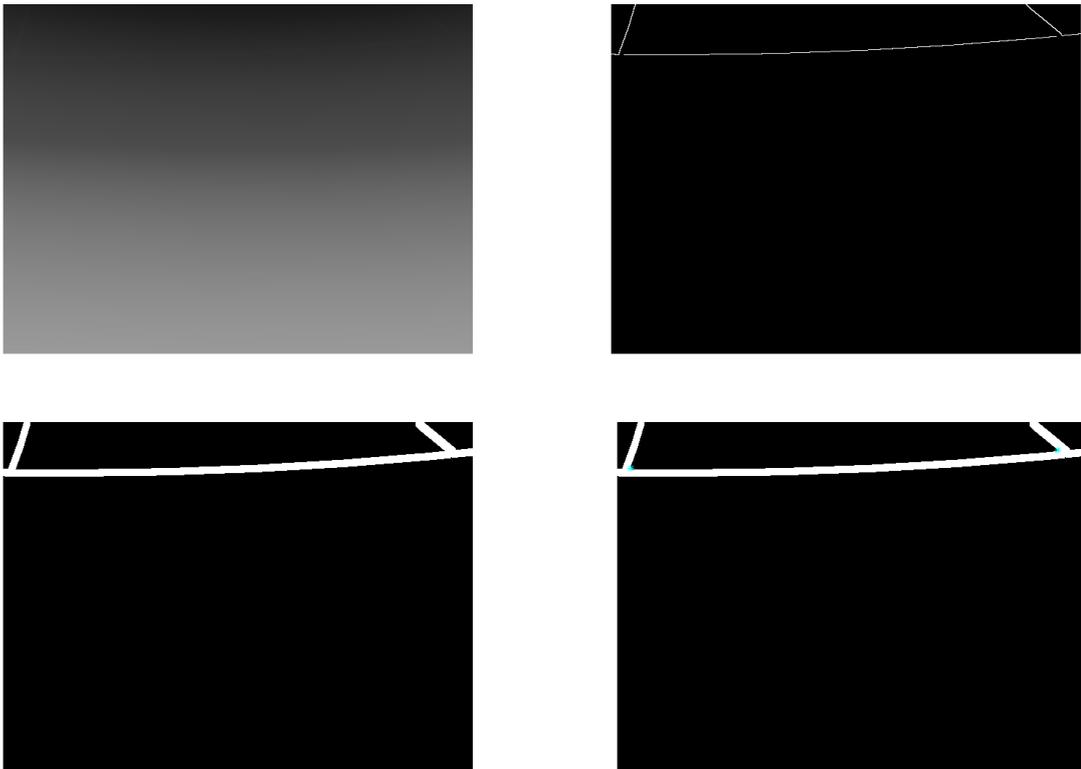


Figura 45: Passos para a identificação de entroncamentos de solda com a câmera de profundidade meio-alcance. À esquerda superior: nuvem de pontos convertida em imagem em tons de cinza. À direita superior: filtro de Roberts aplicado a imagem. À esquerda inferior: função morfológica erosão e dilatação aplicada a imagem. À direita inferior: identificação dos entroncamentos de solda.

Tendo encontrado o ponto de observação padrão, é realizado em seguida a fusão dos sensores. A fusão dos sensores consiste em unir os pontos próximos, o que faz com que a nuvem de pontos se torne menor e diminua o custo computacional. Para isso, todas as fontes de percepção são adicionadas em uma única nuvem de pontos. O resultado pode ser visto na Figura 46, onde é possível de forma visual, identificar a sobreposição de pontos. A nuvem de pontos com todas as fontes de percepção possui ao todo 640.256 pontos.



Figura 46: Todas as fontes de percepção unidas em uma única nuvem de pontos.

Após ser aplicada a fusão dos pontos, houve uma diminuição do tamanho da nuvem de pontos, de 640.256 pontos para 107850 pontos, representado 16,85% do total de pontos iniciais, sem perder a confiança dos pontos, pois a fusão apenas uniu os pontos próximos e levou em consideração a faixa ótima de cada sensor. O resultado pode ser visto pela Figura 47.

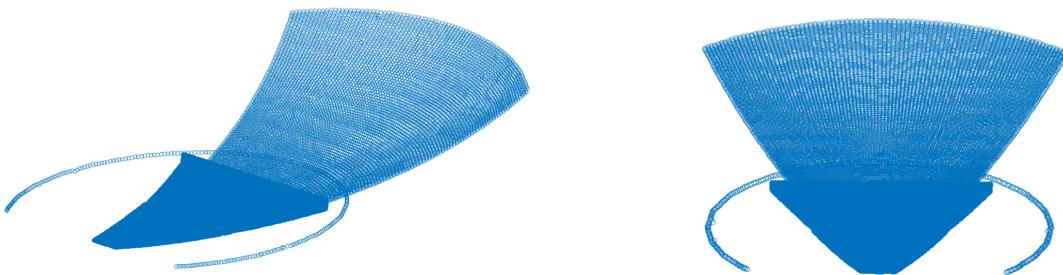


Figura 47: Todas as fontes de percepção unidas em uma única nuvem de pontos após a aplicação da fusão.

O próximo passo da abordagem é a estimativa do ambiente, que consiste em obter dados através de suas fontes de percepção e aplicar os cálculos, discutidos no capítulo 4, para se obter o centro e o raio da esfera. São retirados 7 pontos do sensor de longa-distância, sendo eles a 0 , $\frac{\pi}{11}$, $\frac{\pi}{8}$, $\frac{\pi}{16}$, $\frac{\pi}{3}$ e $\frac{\pi}{7}$ no sentido vertical. Da fonte de percepção LIDAR são retirados 6 pontos no sentido horizontal, sendo eles em $-\pi$, $\frac{-\pi}{3}$, $\frac{-\pi}{4}$, $\frac{\pi}{4}$, $\frac{\pi}{3}$ e π . São retirados 9 pontos da câmera de profundidade meio-alcance, sendo eles na posição $[639,1]$, $[639,200]$, $[639,300]$, $[320,1]$, $[320,200]$, $[320,300]$, $[1,1]$, $[1,100]$ e $[1,300]$. Gerando ao todo 22 pontos do ambiente, o suficiente para executar a estimativa do ambiente apresentados na seção 3.4.

Após a coleta de dados e realização dos cálculos, tem-se o raio e o centro do vaso de pressão esférico como resultado. O raio estimado para o exemplo considerado foi de 9,105, com erro de 0,021% em relação ao real (9,125) e o centro estimado foi [0.098,-0.088,9.037] com um erro de 1,47 % em relação ao vaso de pressão esférico utilizado na simulação. O erro ocorre devido ao cálculo que procura o melhor ajuste minimizando a diferença entre dados observados e dados estimados. A Figura 48 apresenta o robô na esfera, onde o centro e o raio estão sendo indicados.

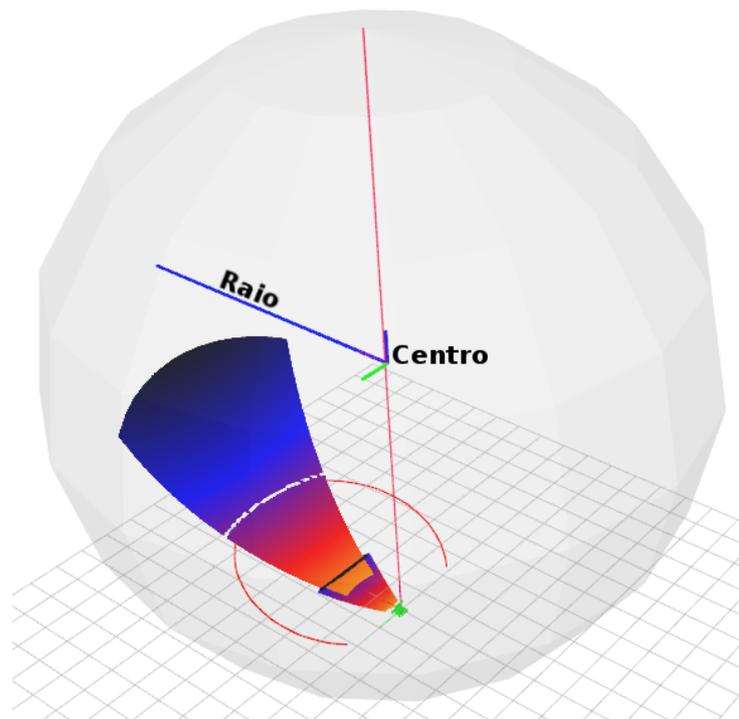


Figura 48: Estimativas do ambiente: raio e centro preditos com base em dados da esfera.

Quando o robô executa a estimativa do ambiente e encontra o ponto de observação padrão com a posição dos dois entroncamentos de solda, todos os dados necessários para a predição do vaso de pressão esféricos são conhecidos. Tendo o raio e o centro, o que falta são os dimensionamentos de cada solda e placa. Os procedimentos utilizados para identificá-los encontram-se na seção 3.5. Como resultado final da execução dos procedimentos tem-se uma esfera predita com todas as características da original, como pode ser visto na Figura 49, onde as soldas são representadas por linhas na cor preta. Os dois entroncamentos de solda utilizados para calcular as características da esfera são representados por duas esferas pequenas de cor rosa, juntamente com a fonte de percepção câmera de meio-alcance, que foi utilizada para identificá-los.

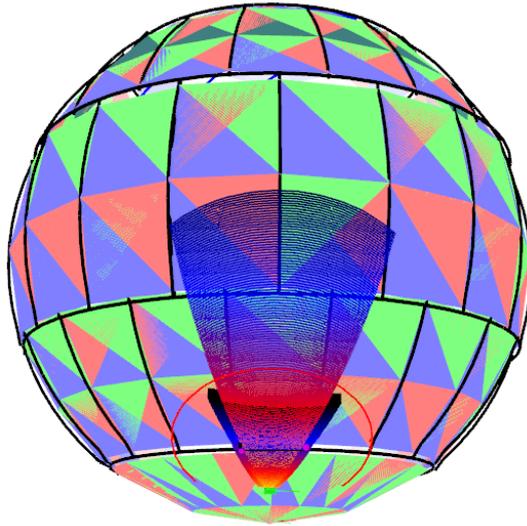


Figura 49: Características do ambiente previstas: Cordões de solda e placas da esfera previstas.

Com a previsão das características do ambiente, se torna possível construir a grade de ocupação, para em seguida desenvolver a análise de confiabilidade para cada voxel da grade. O algoritmo *Predição da grade de ocupação*, apresentado na seção 3.6, foi executado levando em consideração o raio e o centro da esfera prevista, com tamanho de voxel de 20 centímetros cúbicos. Este tamanho de voxel foi escolhido levando em consideração o tamanho físico da sonda de inspeção, para armazenar a posição de defeitos detectados durante a inspeção, porém o algoritmo permite utilizar diferentes tamanhos de voxel. A Figura 50 traz a grade ocupação para a esfera prevista.

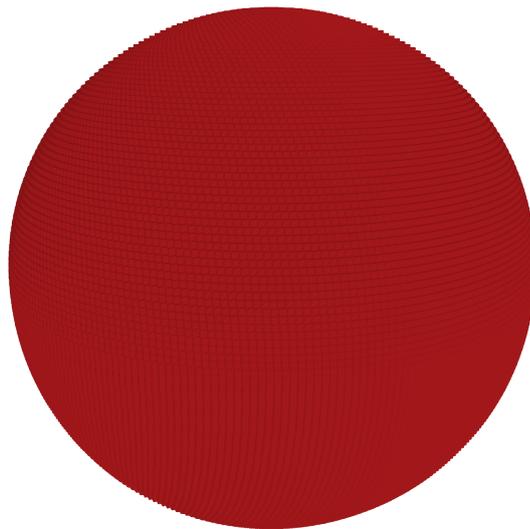


Figura 50: Grade de ocupação criada a partir dos dados da estimativa do ambiente, esfera com raio de 9,105 metros e voxels com tamanho de 20 centímetros cúbicos, sendo 26184 voxels.

Com a grade de ocupação criada, é possível seguir para a análise de confiabilidade. A análise de confiabilidade, como discutido na seção 3.7, tem por objetivo adicionar um grau de confiabilidade em cada voxel, levando em consideração a porcentagem de pontos conhecidos em sua vizinhança, a menor distância entre o voxel analisado e o primeiro voxel observado, e o raio da esfera. Estes dados servem como entrada em uma rede artificial neural (ANN), que possui como saída o grau de confiabilidade, (que vai de 0 para 0% e 1 para 100% confiável). De forma visual, o grau de confiabilidade é apresentado em forma de cores, sendo vermelho 0 e azul 1. A Figura 51 traz o grau de confiabilidade aplicados a esfera predita, onde é possível observar que os voxels observados pelas fontes de percepção estão em azul escuro. À esquerda da figura, tem-se somente a grade de ocupação com os voxels, enquanto à direita a esfera com a predição das características do ambiente, grade de ocupação e voxels.

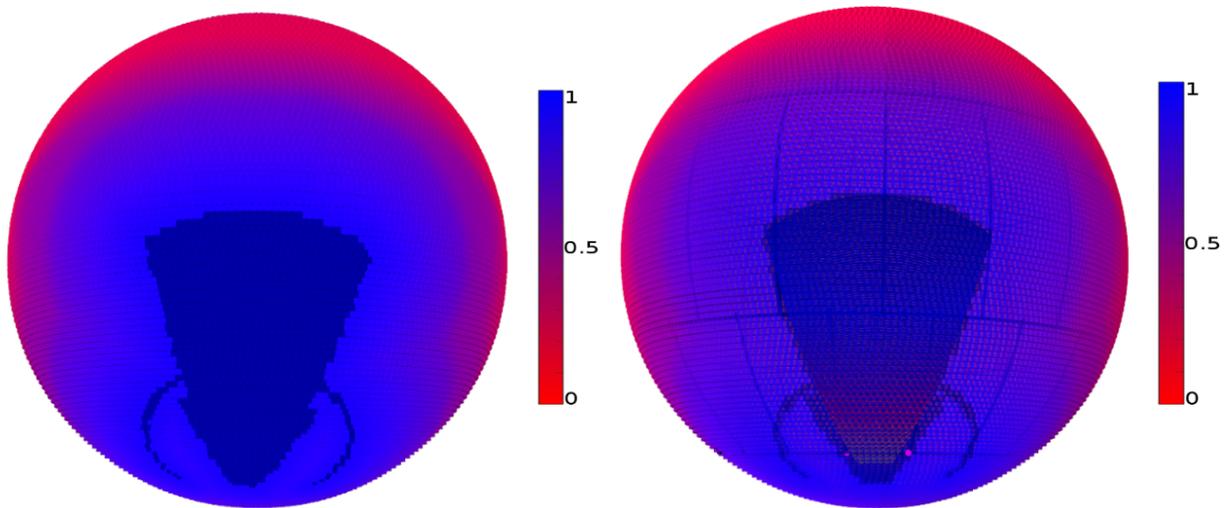


Figura 51: Grade de ocupação com a análise de confiabilidade. À esquerda: grade de ocupação com voxels e grau de confiabilidade. À direita: grade de ocupação com voxels com grau de confiabilidade e características do ambiente preditas.

Por fim, é executado o planejamento de trajetória. Voltas na esfera são computadas para que sejam utilizadas como trajetória permitindo que o robô passe por toda a esfera e execute a inspeção. A distância entre as voltas diz respeito ao tamanho físico da sonda de ultrassom, que também é o tamanho de cada voxel. A Figura 52 apresenta o planejamento de trajetória para o experimento simulado, onde a trajetória planejada encontra-se em amarelo.

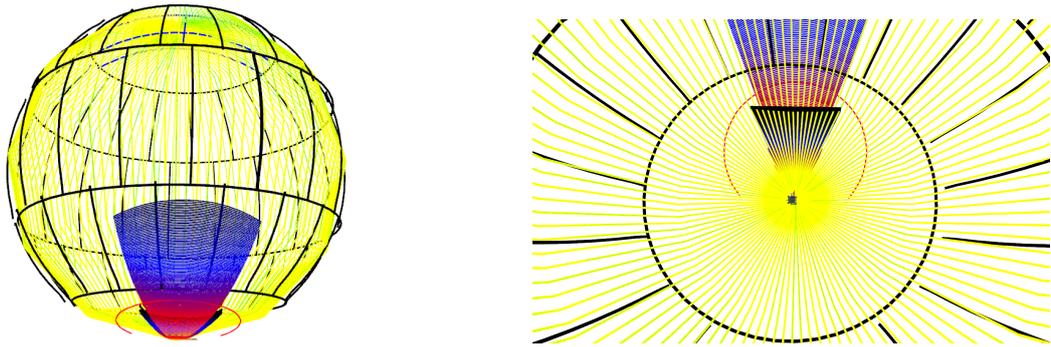


Figura 52: Planejamento de trajetória para a esfera predita pelo experimento simulado. À esquerda: Visão frontal do planejamento de trajetória. À direita: Visão interna do planejamento de trajetória.

4.2 EXPERIMENTO REAL

A validação da metodologia proposta em ambiente real foi realizada com o Robô Autônomo de Inspeção (AIR-1), e ocorreu em duas etapas separadas: Primeiro se validou a busca autônoma do ponto de observação padrão e posteriormente se validou os demais métodos propostos. As validações foram realizadas separadas devido à busca autônoma só ser necessário os entroncamentos de solda, podendo ser realizado em qualquer ambiente, enquanto as demais abordagens devem ser executadas em lugares que apresentem o mínimo necessário para realizar a extração de características do ambiente. Uma estrutura foi montada em um quadro, com a finalidade de simular dois entroncamentos de solda. A solda foi desenvolvida com a mesma cor do quadro para que não houvesse influência nos resultados.

Para validar a busca autônoma do ponto de observação padrão, o quadro com as soldas foi adicionado em 3 posições diferentes, sendo elas esquerda, centro e direita em relação ao robô, com o robô sempre iniciando na mesma posição e orientação. O objetivo é que o robô consiga chegar ao ponto de observação padrão, onde seja possível identificar as soldas e os entroncamentos de soldas com a câmera de profundidade meio-alcance. Para realizar esta validação, primeiro o robô executa uma correção angular, se alinhando ao cordão de solda a 1,5 metros. Então é executado uma correção linear, chegando a 1 metro do cordão de solda, executando a segunda correção angular, e então executa uma nova correção linear chegando a 0,7 metros do cordão de solda e é executado a última correção angular, chegando ao ponto de observação padrão. Todo o procedimento é feito de forma autônoma, o robô encontra o ponto de observação padrão com as soldas em qualquer uma das 3 posições, sem sofrer nenhuma alteração em seu código ou qualquer tipo de ajustes pelo operador. A Figura 53 traz um exemplo do experimento com a solda a esquerda, enquanto a Figura 54 com a solda ao centro e a Figura 55 com a solda a direita.

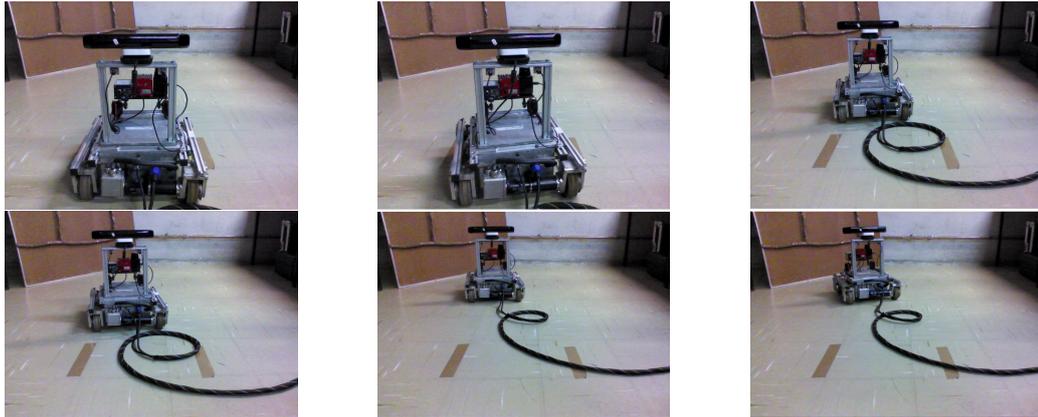


Figura 53: Validação da busca autônoma do ponto de observação padrão com o quadro a esquerda. À esquerda superior: Posição inicial, a 1,5 metros do quadro. Ao centro superior: correção angular. À direita superior: correção linear chegando a 1 metro do quadro. À esquerda inferior: correção angular. Ao centro inferior: correção linear chegando a 0,7 metros do quadro. À direita inferior: Correção angular, chegando ao ponto de observação padrão.



Figura 54: Validação da busca autônoma do ponto de observação padrão com o quadro ao centro. À esquerda superior: Posição inicial, a 1,5 metros do quadro. Ao centro superior: correção angular. À direita superior: correção linear chegando a 1 metro do quadro. À esquerda inferior: correção angular. Ao centro inferior: correção linear chegando a 0,7 metros do quadro. À direita inferior: Correção angular, chegando ao ponto de observação padrão.

Para as demais validações, o AIR-1 é colocado em um corredor, onde possui poucas condições para que seja possível estimar o vaso de pressão esférico. O robô já é adicionado no ponto de observação padrão, restando assim executar as demais tarefas, como identificação dos entroncamentos de solda e estimativa do ambiente para que seja possível executar a predição das características do ambiente, predição da grade de ocupação, análise de confiabilidade e planejamento de trajetória. O robô AIR-1 juntamente com a solda no corredor utilizado para os experimentos pode ser visto na Figura 56.

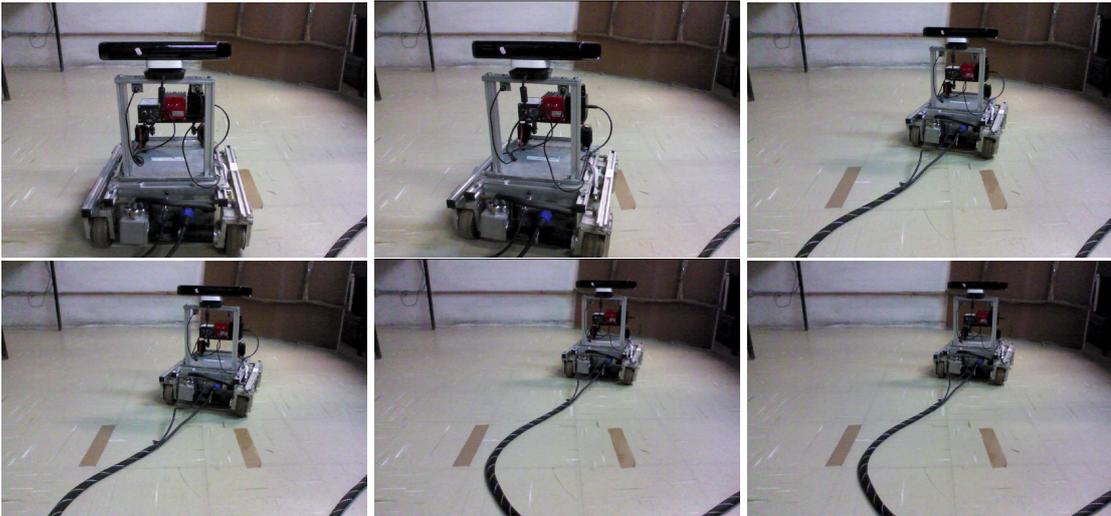


Figura 55: Validação da busca autônoma do ponto de observação padrão com o quadro a direita. À esquerda superior: Posição inicial, a 1,5 metros do quadro. Ao centro superior: correção angular. À direita superior: correção linear chegando a 1 metro do quadro. À esquerda inferior: correção angular. Ao centro inferior: correção linear chegando a 0,7 metros do quadro. À direita inferior: Correção angular, chegando ao ponto de observação padrão.

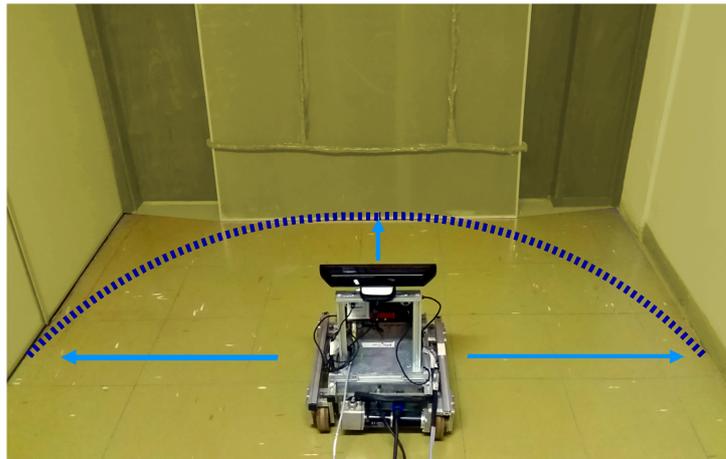


Figura 56: Robô autônomo de inspeção (AIR-1) com o quadro de soldas em um corredor utilizado para a validação real.

O primeiro passo, após a busca pelo ponto de observação padrão é a execução da estimativa do ambiente. O robô utilizou pontos específicos para que fosse possível realizar a estimativa do ambiente, visto que esferas não possuem pontas, como acontece com o corredor, portanto pontos desta natureza foram descartados. No final da estimativa do ambiente, o robô retornou um raio de 1,334 metros. Para realizar a predição das características, o robô utiliza a distância entre os dois entroncamentos de solda, retirados do quadro e o raio da esfera predita. O resultado da predição das características do ambiente pode ser visto na Figura 57, onde também é possível observar o robô e as suas fontes de percepção.

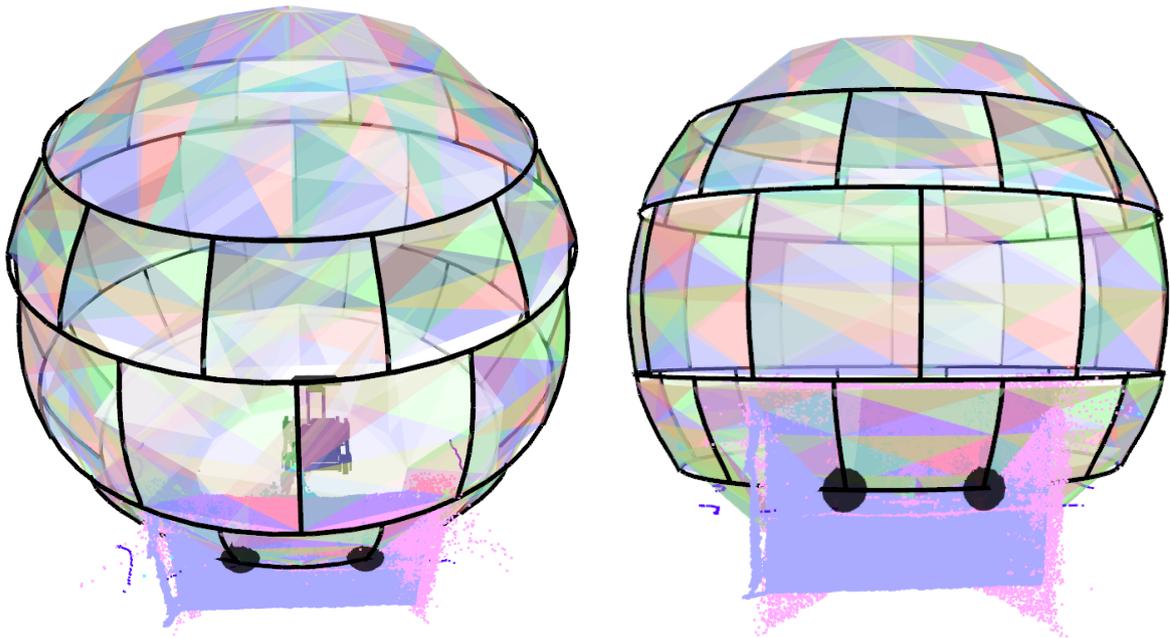


Figura 57: Características do ambiente preditas: Cordões de solda e placas da esfera preditas.

Com as características do ambiente predita, é possível desenvolver a grade de ocupação. A Figura 58 apresenta a grade de ocupação para a esfera predita, com os voxels com tamanho de 20 centímetros cúbicos, gerando um total de 528 voxels. Como o tamanho da esfera é menor que o desenvolvido no experimento simulado, se torna possível observar com mais detalhes os voxels.

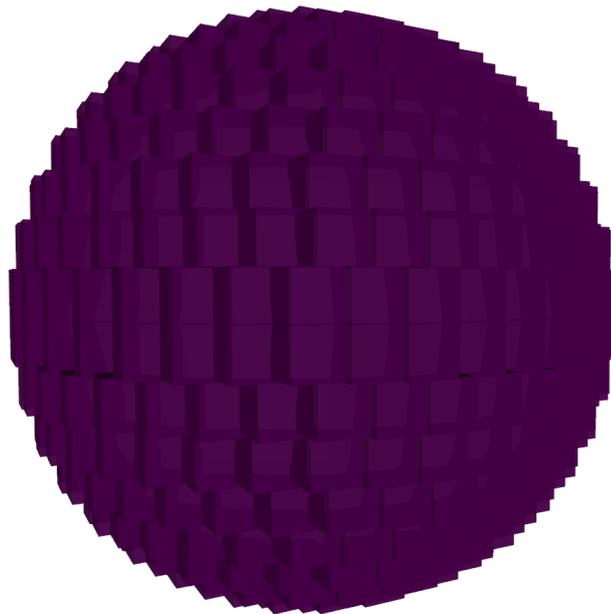


Figura 58: Grade de ocupação criada a partir dos dados da estimativa do ambiente, esfera com raio de 1,334 metros e voxels com tamanho de 20 centímetros, sendo 528 voxels.

O próximo passo é a análise de confiabilidade para cada voxel na grade de ocupação. Da mesma forma que no experimento simulado, aqueles voxels que são observados pela fonte de percepção recebem o grau máximo de confiança, os demais são calculados de acordo com a distância dos observados e pela quantidade de voxels observados em uma vizinhança com o limite definido, sendo esses dois dados, juntamente com o raio da esfera, as entradas para a rede neural artificial. O resultado da análise de confiança pode ser visto pela Figura 59.

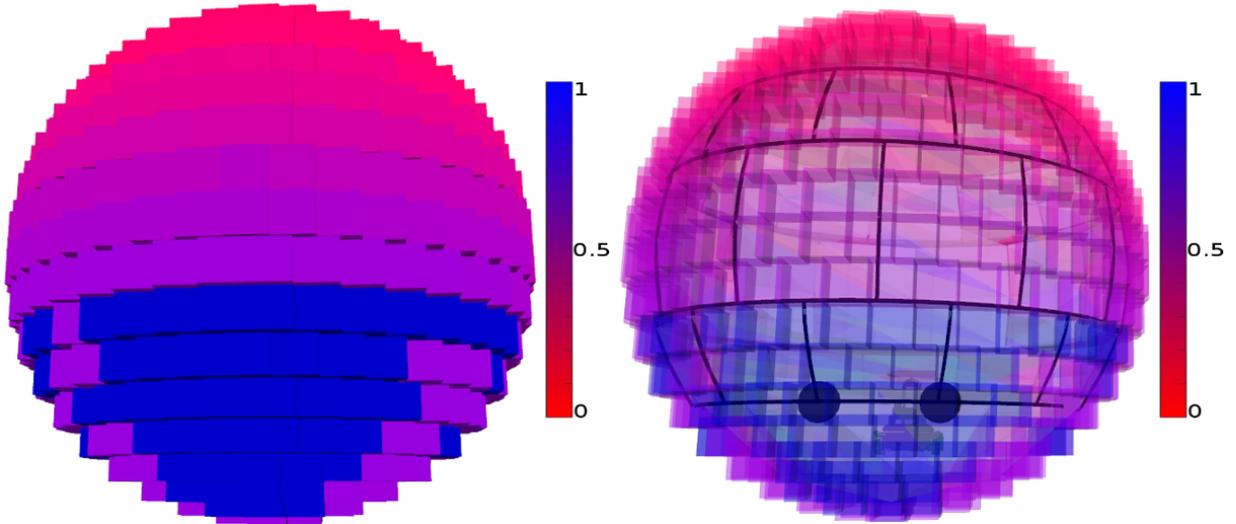


Figura 59: Grade de ocupação com a análise de confiabilidade. À esquerda: grade de ocupação com voxels e grau de confiabilidade. À direita: grade de ocupação com voxels com grau de confiabilidade e características do ambiente preditas.

Por fim, é possível executar o planejamento da trajetória de inspeção. A distância de cada laço segue a mesma lógica do experimento simulado, 20 centímetros, tamanho referente a sonda de ultrassom utilizada para a inspeção do vaso de armazenamento esférico. A Figura 60 apresenta o planejamento de trajetória. Vale ressaltar que o raio da esfera é de 1,334 metros e por isso a impressão de que as voltas do planejamento de trajetória estão mais espaçadas do que no experimento simulado.

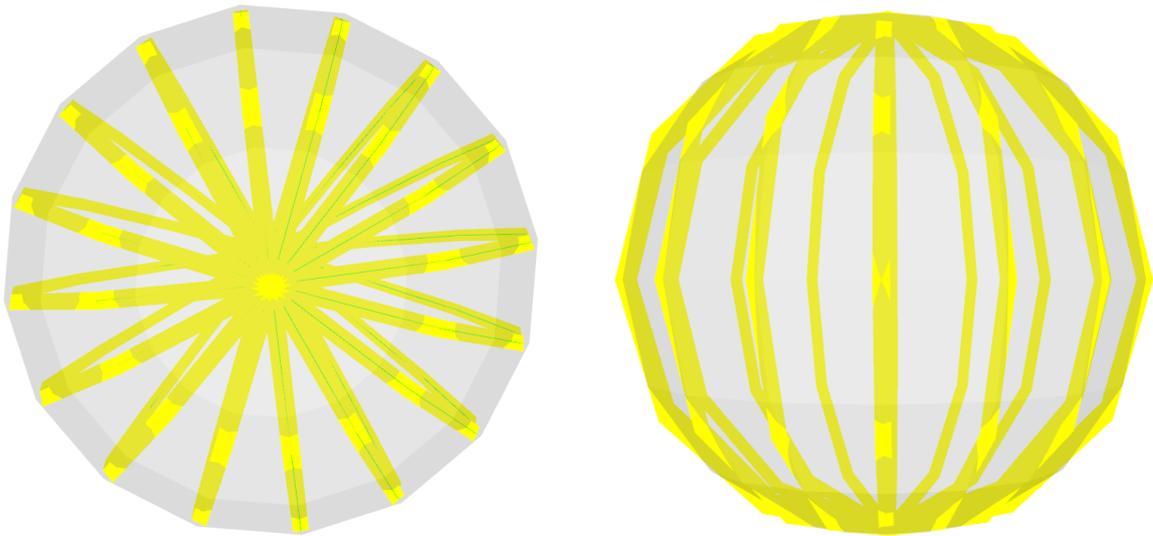


Figura 60: Planejamento de trajetória para a esfera predita pelo experimento real. À esquerda: visão aérea do planejamento de trajetória. À direita: visão frontal do planejamento de trajetória.

4.3 CONCLUSÃO

Neste capítulo, todos os métodos propostos foram validados, tanto em ambiente simulado quanto em ambiente real. No ambiente simulado, um vaso de pressão esférico foi modelado, assim como o Robô Autônomo de Inspeção. Todas as características físicas da esfera e do robô foram levadas em consideração na modelagem da cena virtual, características como a adesão magnética do robô e tamanhos de esfera e robô. Os resultados foram satisfatórios, no experimento simulado, o AIR-1 teve a capacidade de acertar o raio da esfera com um erro de apenas 0,021%.

No experimento real, por falta de um tanque, os experimentos foram conduzidos separados em duas etapas. A primeira etapa consiste em validar a busca autônoma pelo ponto de observação padrão. Para validar esta etapa, um quadro com cordões representam as soldas foi montado e colocado em lugares diferentes de uma sala, a fim de que o robô fosse capaz de identificá-lo e chegar ao ponto de observação padrão. A segunda parte da validação consiste na estimativa do ambiente e extração das características, para isso, o robô foi posicionado em um corredor, onde seria possível desenvolver a estimativa do ambiente, por possuir alguma simetria entre os lados. Neste corredor, todas as demais abordagens foram validadas.

Vídeo dos experimentos, assim como vídeos de demais trabalhos desenvolvidos pelo Laboratório de Automação e Sistemas de Controle Avançado (LASCA) na área de robótica móvel podem ser encontrados na pagina do YouTube de nome *Robo Lasca* ou pelo link <https://www.youtube.com/channel/UCtgnBqaodQAGtbh0HW9nJEA>.

5 CONSIDERAÇÕES FINAIS

Este capítulo tem como finalidade apresentar as conclusões finais deste trabalho, assim como apresentar as sugestões de trabalhos futuros que possam engrandecer esta pesquisa.

5.1 CONCLUSÃO

O objetivo deste trabalho foi desenvolver uma estratégia de mapeamento de vasos de pressão esféricos utilizados para o armazenamento de GLP – Gás Liquefeito de Petróleo. A estratégia proposta consiste em desenvolver uma predição do mapa com o robô parado, fazendo uso das fontes de percepção do robô a fim de obter medições do ambiente. No capítulo 2 foi apresentado um estudo de caso sobre as técnicas utilizadas pelos diferentes sensores para medição, assim como as diferentes estratégias de mapeamento existentes como o SLAM e o P-SLAM. Também foram estudadas estratégias de visão como a reconstrução 3D e a predição de objetos 3D com base em partes conhecidas.

No capítulo 3 foi apresentada a estratégia adotada por este trabalho para a elaboração da predição do mapa e planejamento de trajetória. A estratégia consiste em primeiro identificar o ponto de observação padrão. Para realizar esta tarefa, o robô necessita navegar até a posição ideal para a extração de características da esfera, como dois entroncamentos de solda. O próximo passo consistiu em desenvolver uma estimativa do ambiente, esta estimativa utilizou alguns pontos dos sensores para realizar uma estimativa das características do vaso de pressão esférico (centro e raio). Com o raio, o centro e dois entroncamentos de solda, foi possível desenvolver a predição das características do ambiente. Esta etapa consistiu em prever as características físicas do vaso esférico, como os cordões de solda e placas. Estas características foram previstas com base nos dois entroncamentos de solda previamente identificados, que juntamente com as normas de fabricação e montagem dos vasos de pressão esférico permitem definir a estrutura da esfera. O próximo passo consistiu em desenvolver uma grade de ocupação para a esfera prevista, ocupada com voxels. Cada voxel recebeu um grau de confiabilidade, desenvolvido na análise de confiabilidade que indica a confiança que este voxel possui com base

em voxels já observados pelo robô. Por fim foi desenvolvido um planejamento de trajetória, para que o robô seja capaz de passar por toda a esfera e posteriormente.

No capítulo 4 foi desenvolvida a validação das estratégias propostas para a predição de mapa em vasos de pressão esféricos. A validação foi realizada em experimentos reais e simulados. Os experimentos reais foram desenvolvidos em um corredor, por falta de um vaso de pressão esférico disponível. Para simular as soldas e entroncamentos de solda, um estrutura com os entroncamentos de solda foi desenvolvida. Já no experimento simulado, é utilizada uma cena com o robô AIR-1 e o vaso de pressão esférico modelados, respeitando todas as grandezas físicas dos dois, assim como todos as fontes de percepção presentes no robô.

Os experimentos tanto simulados como reais, obtiveram resultados similares. No experimento real alguns problemas ocorreram, como a falta de um vaso de pressão esférico. Para validar a estimativa do ambiente, foi necessário utilizar um corredor e escolher pontos específicos dos sensores, para que não pegasse algum canto ou quina e provocassem falsos resultados. As demais tarefas da metodologia proposta seguem o mesmo padrão para o experimento real e simulado, pois utilizam em seus cálculos o raio, o centro da esfera e a posição dos dois entroncamentos de solda. A principal diferença entre as duas validações é o tamanho da esfera predita, que por sua vez provocou uma diferença no tamanho da grade de ocupação e número de voxel.

É possível afirmar que mesmo sem o uso da esfera no experimento real, todos os objetivos propostos foram alcançados. Como resultado deste trabalho, tem-se um mapa predito do vaso de pressão esférico, com todas as suas características como cordões de solda e placas além de uma grade de ocupação, voxels com grau de confiabilidade e planejamento de trajetória.

Para desenvolver este trabalho houve a necessidade de estudar conceitos de robótica móvel, como mapeamento e navegação assim como fontes de percepção e seus sensores. Estes estudos juntamente com este trabalho, que resultaram nas seguintes publicações:

- TEIXEIRA, MARCO ANTONIO SIMOS; SANTOS, HIGOR BARBOSA ; OLIVEIRA, ANDRE SCHNEIDER DE ; ARRUDA, LUCIA VALERIA RAMOS DE ; NEVES, FLAVIO . Environment Identification and Path Planning for Autonomous NDT Inspection of Spherical Storage Tanks. In: 2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR), 2016, Recife. 2016 XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR). p. 193-198.

- TEIXEIRA, MARCO ANTONIO SIMOES; SANTOS, H. B. ; OLIVEIRA, A. S. ; ARRUDA, L. V. R. ; NEVES-JR, F. . Robots perception through 3D PointCloud sensors. Robot Operating System (ROS). 2ed.: , 2017, v. , p. 45-90.
- TEIXEIRA, MARCO ANTONIO; SANTOS, HIGOR BARBOSA ; DE OLIVEIRA, ANDRE SCHNEIDER ; FABRO, JOAO ALBERTO ; DE ARRUDA, LUCIA VALERIA RAMOS ; NEVES-JR, FLAVIO . Cooperative load transport based on fuzzy logic controllers. In: 2016 12th IEEE International Conference on Industry Applications (INDUSCON), 2016, Curitiba. 2016 12th IEEE International Conference on Industry Applications (INDUSCON), 2016. p. 1.

5.2 TRABALHOS FUTUROS

Sugestões para trabalhos futuros:

1. Testar a predição de vasos de pressão esféricos em um vaso de pressão esférico real;
2. Desenvolver uma estratégia inteligente de correção dos resultados preditos, conforme o robô se locomove. Essa estratégia consistiria em corrigir os erros da predição caso existam, fazendo uma comparação entre dados obtidos pelos sensores e dados obtidos pela predição do mapa conforme o robô se locomove;
3. Validar a aplicação, utilizando o mapa predito para a realização da inspeção, salvando e ilustrando a posição de problemas identificados;
4. Desenvolvimento de uma estratégia de navegação e auto-localização, utilizando entroncamentos de solda preditos como marcos para zerar erros de odometria e realizar o fechamento de volta (*loop closing*);

REFERÊNCIAS

- ALDOMA, A. et al. Tutorial: Point cloud library: Three-dimensional object recognition and 6 dof pose estimation. **IEEE Robotics & Automation Magazine**, IEEE, v. 19, n. 3, p. 80–91, 2012.
- BAYOUMI, A.; BENNEWITZ, M. Learning optimal navigation actions for foresighted robot behavior during assistance tasks. In: IEEE. **2016 IEEE International Conference on Robotics and Automation (ICRA)**. 2016. p. 207–212.
- CHANG, H. J. et al. P-slam: Simultaneous localization and mapping with environmental-structure prediction. **IEEE Transactions on Robotics**, IEEE, v. 23, n. 2, p. 281–293, 2007.
- CHANG, J. I.; LIN, C.-C. A study of storage tank accidents. **Journal of loss prevention in the process industries**, Elsevier, v. 19, n. 1, p. 51–59, 2006.
- CHUNG, S. Y.; HUANG, H. P. Simultaneous topological map prediction and moving object trajectory prediction in unknown environments. In: IEEE. **2008 IEEE/RSJ International Conference on Intelligent Robots and Systems**. 2008. p. 1594–1599.
- COSTA, O. **Tanques de Armazenamento: TANQUES 2011**. 03 2011.
- DICIO. **Dicio: Dicionario Online de Portugues**. Abr 2016. Disponível em: <<http://www.dicio.com.br/>>.
- DIMETIXUSA. **DIMETIX EDS-C series laser distance sensor technical supplement**. 2014. Disponível em: <<http://dimetix-usa.com/wp-content/uploads/2014/06/DIMETIX-USA-EDS-C-supplement.pdf>>.
- DIMETIXUSA. **FLS-C10**. January 2016. Disponível em: <<http://dimetix-usa.com/product/fls-c10/>>.
- DISSANAYAKE, M. et al. A solution to the simultaneous localization and map building (slam) problem. **Robotics and Automation, IEEE Transactions on**, IEEE, v. 17, n. 3, p. 229–241, 2001.
- DOUGHERTY, E. R.; LOTUFO, R. A.; SPIE, T. I. S. for O. E. **Hands-on morphological image processing**. : SPIE Optical Engineering Press Washington, 2003.
- DURRANT-WHYTE, H.; BAILEY, T. Simultaneous localization and mapping: part i. **IEEE robotics & automation magazine**, IEEE, v. 13, n. 2, p. 99–110, 2006.
- EICH, M.; VÖGELE, T. Design and control of a lightweight magnetic climbing robot for vessel inspection. In: IEEE. **Control & Automation (MED), 2011 19th Mediterranean Conference on**. 2011. p. 1200–1205.

- EIGEN, D.; PUHRSCH, C.; FERGUS, R. Depth map prediction from a single image using a multi-scale deep network. In: **Advances in neural information processing systems**. 2014. p. 2366–2374.
- ENDRES, F. et al. An evaluation of the rgb-d slam system. In: IEEE. **Robotics and Automation (ICRA), 2012 IEEE International Conference on**. 2012. p. 1691–1696.
- ENGINEERS, A. S. of mechanical. **Boiler and pressure vessel code**. : West Conshohocken, PA , USA, 2004.
- ESPINOZA, R. V. et al. Adhesion loss prediction of a climbing robot through magnetic field analysis by artificial neural networks. In: **22nd International Congress of Mechanical Engineering**. 2013. p. 3–7.
- ESPINOZA, R. V. et al. Navigation's stabilization system of a magnetic adherence-based climbing robot. **Journal of Intelligent & Robotic Systems**, Springer Netherlands, p. 1–17, 2014.
- FIRMAN, M. et al. Structured prediction of unobserved voxels from a single depth image. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. 2016. p. 5431–5440.
- FUKUDA, N. **Terremoto no Japão**. Abr 2016. Disponível em: <<http://blogs.estadao.com.br/olhar-sobre-o-mundo/terremoto-no-japao/>>.
- GENG, J. Structured-light 3d surface imaging: a tutorial. **Advances in Optics and Photonics**, Optical Society of America, v. 3, n. 2, p. 128–160, 2011.
- HARRIS, C.; STEPHENS, M. A combined corner and edge detector. In: CITESEER. **Alvey vision conference**. 1988. v. 15, n. 50, p. 10–5244.
- HENRY, P. et al. Rgb-d mapping: Using kinect-style depth cameras for dense 3d modeling of indoor environments. **The International Journal of Robotics Research**, SAGE Publications, v. 31, n. 5, p. 647–663, 2012.
- IMAGING, M. **SR4000 user manual v2. 0**. : May, 2011.
- INSTITUTE, A. P. **Tank Inspection, Repair, Alteration, and Reconstruction**. : Washington, DC, USA, 2003.
- INTEL, N. L. **A Comparison of Intel RealSense Front-Facing Camera SR300 and F200**. 2016. Disponível em: <<https://software.intel.com/en-us/articles/a-comparison-of-intel-realsensetm-front-facing-camera-sr300-and-f200>>.
- IZADI, S. et al. Kinectfusion: real-time 3d reconstruction and interaction using a moving depth camera. In: ACM. **Proceedings of the 24th annual ACM symposium on User interface software and technology**. 2011. p. 559–568.
- KINGMOB. **O Kinect e um novo paradigma para os consoles**. <http://www.hardmob.com.br/consoles/435639-kinect-paradigma-consoles.html>: , Fev 2017.
- KOLLMITZ, M. et al. Time dependent planning on a layered social cost map for human-aware robot navigation. In: IEEE. **Mobile Robots (ECMR), 2015 European Conference on**. 2015. p. 1–6.

LEE, Y.-J.; SONG, J.-B.; CHOI, J.-H. Performance improvement of iterative closest point-based outdoor slam by rotation invariant descriptors of salient regions. **Journal of intelligent & robotic systems**, Springer, v. 71, n. 3-4, p. 349–360, 2013.

LEONARD, J. J.; DURRANT-WHYTE, H. F. Mobile robot localization by tracking geometric beacons. **Robotics and Automation, IEEE Transactions on**, IEEE, v. 7, n. 3, p. 376–382, 1991.

LEONARD, J. J.; DURRANT-WHYTE, H. F. Simultaneous map building and localization for an autonomous mobile robot. In: IEEE. **Intelligent Robots and Systems' 91.'Intelligence for Mechanical Systems, Proceedings IROS'91. IEEE/RSJ International Workshop on**. 1991. p. 1442–1447.

LEONARD, J. J.; DURRANT-WHYTE, H. F. Simultaneous map building and localization for an autonomous mobile robot. In: IEEE. **Intelligent Robots and Systems' 91.'Intelligence for Mechanical Systems, Proceedings IROS'91. IEEE/RSJ International Workshop on**. 1991. p. 1442–1447.

LI, L. Time-of-flight camera—an introduction. **Technical White Paper**, May, 2014.

MEEUSSEN, W. **Coordinate Frames for Mobile Platforms**. <http://www.ros.org/reps/rep-0105.html#coordinate-frames>, Fev 2017.

MESA IMAGING. **SR4000/SR4500 User Manual**. Version 3.0. 2011. Disponível em: <http://downloads.mesa-imaging.ch/dlm.phpfname=customer/Customer_CD/SR4000_SR4500_Manual.pdf>.

MICROSOFT. **Kinect for Windows Sensor Components and Specifications**. 2016. Disponível em: <<https://msdn.microsoft.com/en-us/library/jj131033.aspx>>.

MORAVEC, H. Robot spatial perception by stereoscopic vision and 3d evidence grids. **Perception**, 1996.

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

MORAVEC, H. P. **Obstacle avoidance and navigation in the real world by a seeing robot rover**. 1980.

MORAVEC, H. P. Sensor fusion in certainty grids for mobile robots. **AI magazine**, v. 9, n. 2, p. 61, 1988.

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

MORRIS, W.; XIAO, J. City-climber: development of a novel wall-climbing robot. **J Student Res**, v. 1, p. 40–5, 2008.

MOSS, D. R.; BASIC, M. M. **Pressure vessel design manual**. : Butterworth-Heinemann, 2012.

MURALIKRISHNAN, B.; RAJA, J. **Computational surface and roundness metrology**. : Springer Science & Business Media, 2008.

MURPHY, R. **Introduction to AI robotics**. : MIT press, 2000.

N-1281. **Design, Fabrication, and Assembly of Spheres**. 2014. PETROBRAS Technical Standards.

N-1520. **Storage Spheres - Data Sheet**. 2010. PETROBRAS Technical Standards.

N-2111. **Safety in Cleanup, Inspection and Repair of Storage Tanks and Pressure Vessels**. 2011. PETROBRAS Technical Standards.

N-268. **Fabrication of Pressure Vessels**. 2012. PETROBRAS Technical Standards.

OKAMOTO, J. et al. Development of an autonomous robot for gas storage spheres inspection. **Journal of Intelligent & Robotic Systems**, Springer, v. 66, n. 1, p. 23–35, 2012.

OLIVEIRA, A. de et al. Adhesion force control and active gravitational compensation for autonomous inspection in lpg storage spheres. **Robotics Symposium and Latin American Robotics Symposium (SBR-LARS), 2012 Brazilian**, p. 232–238, Oct 2012.

PAGLIARI, D.; PINTO, L. Calibration of kinect for xbox one and comparison between the two generations of microsoft sensors. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 15, n. 11, p. 27569–27589, 2015.

PETROBRAS. **Exploração e Produção de Petróleo e Gás**. Abr 2016. Disponível em: <<http://www.petrobras.com.br/pt/nossas-atividades/areas-de-atuacao/exploracao-e-producao-de-petroleo-e-gas/>>.

PRANKL, J. et al. Rgb-d object modelling for object recognition and tracking. In: **IEEE. Intelligent Robots and Systems (IROS), 2015 IEEE/RSJ International Conference on**. 2015. p. 96–103.

ROBOTICS, C. **Coppelia Robotics v-rep: Create. Compose. Simulate. Any Robot**. Nov 2017. Disponível em: <<http://www.coppeliarobotics.com/>>.

ROS. **ROS.org - Powering the world's robots**. Nov 2015. Disponível em: <<http://www.ros.org/>>.

ROVANI, A. **Desenvolvimento do protótipo de um robô para inspeção de cordões de solda em superfícies metálicas verticais**. 2013. Trabalho de Conclusão de Curso-Engenharia Industrial Mecânica - Universidade Tecnológica Federal do Paraná, Curitiba.

SANTOS, H. B. **Controle inteligente de posição e velocidade para um robô escalador com rodas direcionáveis**. Dissertação (Mestrado) — CPGEI - Universidade Tecnológica Federal do Paraná, 2016.

SANTOS, H. B. et al. Scheduled fuzzy controllers for omnidirectional motion of an autonomous inspection robot with four fully steerable magnetic wheels. In: **XIII Latin American Robotics Symposium and IV Brazilian Robotics Symposium**. 2016. p. 263–268.

SAWADA, J. et al. A mobile robot for inspection of power transmission lines. **Power Delivery, IEEE Transactions on**, IEEE, v. 6, n. 1, p. 309–315, 1991.

SENTHILKUMARAN, N.; RAJESH, R. Edge detection techniques for image segmentation—a survey of soft computing approaches. **International journal of recent trends in engineering**, v. 1, n. 2, 2009.

SIEGWART, R.; NOURBAKHSI, I. R.; SCARAMUZZA, D. **Introduction to autonomous mobile robots**. : MIT press, 2011.

TEIXEIRA, M. A. S. et al. Environment identification and path planning for autonomous ndt inspection of spherical storage tanks. In: IEEE. **Robotics Symposium and IV Brazilian Robotics Symposium (LARS/SBR), 2016 XIII Latin American**. 2016. p. 193–198.

THRUN, S.; BURGARD, W.; FOX, D. **Probabilistic robotics**. : MIT press, 2005.

THRUN, S. et al. Robust monte carlo localization for mobile robots. **Artificial intelligence**, Elsevier, v. 128, n. 1, p. 99–141, 2001.

THRUN, S. et al. Robotic mapping: A survey. **Exploring artificial intelligence in the new millennium**, v. 1, p. 1–35, 2002.

TOOLBOXES, T. **Have you saved 70% for tank cleaning, inspection and repair costs by using robotics?** Washington, DC,USA, 2003. Disponível em: <http://www.ttoolbox.com/training/CourseDocuments/37/AST_InspectionSavingsUsingInServiceRobotics.pdf>.

TOPP, D. Quantitative in-service inspection using the alternating current field measurement(acfm) method. In: **NDTISS'99: International Symposium on Nondestructive Testing Contribution to the Infrastructure Safety Systems in the 21 st Century**. 1999. p. 48–54.

TSARDOULIAS, E.; PETROU, L. Critical rays scan match slam. **Journal of Intelligent & Robotic Systems**, Springer, v. 72, n. 3-4, p. 441–462, 2013.

TUMMALA, R. L. et al. Climbing the walls [robots]. **Robotics & Automation Magazine, IEEE**, IEEE, v. 9, n. 4, p. 10–19, 2002.

UNHELKAR, V. V. et al. Human-robot co-navigation using anticipatory indicators of human walking motion. In: IEEE. **2015 IEEE International Conference on Robotics and Automation (ICRA)**. 2015. p. 6183–6190.

VEIGA, R. S. da. **Sistema de navegação e localização para um robô escalador magnético de inspeção baseado em sensores LIDAR**. Dissertação (Mestrado) — CPGEI - Universidade Tecnológica Federal do Paraná, 2015.

WANG, C.-C.; THORPE, C.; THRUN, S. Online simultaneous localization and mapping with detection and tracking of moving objects: Theory and results from a ground vehicle in crowded urban areas. In: IEEE. **Robotics and Automation, 2003. Proceedings. ICRA'03. IEEE International Conference on**. 2003. v. 1, p. 842–849.

WANG, T.; YANG, J. Certainty grids method in robot perception and navigation. In: IEEE. **Intelligent Control, 1995., Proceedings of the 1995 IEEE International Symposium on**. 1995. p. 539–544.

WOLF, D. F.; SUKHATME, G. S. Semantic mapping using mobile robots. **Robotics, IEEE Transactions on**, IEEE, v. 24, n. 2, p. 245–258, 2008.

WU, Y.-h. et al. Development of automated electromagnetic techniques for inspecting inner cracks of lpg tanks. **Probe**, Citeseer, v. 500, p. 2, 2001.