

**UNIVERSIDADE FEDERAL DE MINAS GERAIS  
INSTITUTO DE CIÊNCIAS EXATAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Felipe Gomes de Oliveira

**MAPEAMENTO DE TRAFEGABILIDADE BASEADO EM FUSÃO DE  
DADOS INERCIAIS E NUVENS DE PONTOS**

Belo Horizonte  
2020

FELIPE GOMES DE OLIVEIRA

**MAPEAMENTO DE TRAFEGABILIDADE  
BASEADO EM FUSÃO DE DADOS INERCIAIS  
E NUVENS DE PONTOS**

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais como requisito parcial para a obtenção do grau de Doutor em Ciência da Computação.

**ORIENTADOR: DOUGLAS GUIMARÃES MACHARET  
COORIENTADOR: MÁRIO FERNANDO MONTENEGRO CAMPOS**

Belo Horizonte

Agosto de 2020

Oliveira, Felipe Gomes de.

O48m Mapeamento de trafegabilidade baseado em fusão de dados inerciais e nuvens de pontos [manuscrito] / Felipe Gomes de Oliveira.- 2020.  
xxix, 117 f. il.

Orientador: Douglas Guimarães Macharet.  
Coorientador: Mario Fernando Montenegro Campos.  
Tese (Doutorado) - Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Ciência da Computação.  
Referências: f.97-103.

1. Computação – Teses. 2. Mapeamento de terreno – Teses. 3. Aprendizado profundo – Teses. 4. Robótica – Teses.  
I. Macharet, Douglas Guimarães. II. Campos, Mario Fernando Montenegro. III. Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Ciência da Computação. IV. Título.

CDU 519.6\*82.9(043)



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
INSTITUTO DE CIÊNCIAS EXATAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

## FOLHA DE APROVAÇÃO

Mapeamento de Trafegabilidade Baseado em Fusão de Dados Inerciais e  
Nuvens de Pontos

**FELIPE GOMES DE OLIVEIRA**

Tese defendida e aprovada pela banca examinadora constituída pelos Senhores:

PROF. DOUGLAS GUIMARÃES MACHARET - Orientador  
Departamento de Ciência da Computação - UFMG

PROF. MARIO FERNANDO MONTENEGRO CAMPOS - Coorientador  
Departamento de Ciência da Computação - UFMG

PROF. DENIS FERNANDO WOLF  
Instituto de Ciências Matemáticas e de Computação - USP

PROF. JOSÉ REGINALDO HUGHES CARVALHO  
Instituto de Computação - UFAM

PROF. ARMANDO ALVES NETO  
Departamento de Engenharia Eletrônica - UFMG

PROF. LUIZ CHAIMOWICZ  
Departamento de Ciência da Computação - UFMG

Belo Horizonte, 26 de Agosto de 2020.

*Agradeço a Deus por me permitir alcançar tudo o que conquistei em minha vida.*

# Agradecimentos

Agradeço aos meus filhos Pedro Felipe e Dalila por me permitirem a emoção da paternidade.

À minha esposa Daniela por estar sempre ao meu lado em todos os momentos.

Aos meus pais Pedro Flávio e Josemeire pelo amor, carinho, dedicação e principalmente pela educação proporcionada.

Às minhas irmãs Micaelle e Rochelle pelo amor e compreensão.

Aos meus orientadores Douglas Guimarães Macharet e Mário Fernando Montenegro Campos por todo o suporte dado durante o doutorado.

Ao meu supervisor Paulo Borges, pela incrível oportunidade e pela valiosa contribuição durante o período de intercâmbio científico.

À todos os amigos por me alegrarem nos momentos de dificuldade.

Ao VeRlab por todo o conhecimento, suporte, amizades e momentos de alegria.

À Universidade Federal do Amazonas por ter me proporcionado essa oportunidade.

À Universidade Federal de Minas Gerais por todo o suporte.

Ao Commonwealth Scientific and Industrial Research Organisation (CSIRO) por todo o suporte.

Às instituições que fomentaram esta pesquisa. Este trabalho foi financiado por Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM).

À todos que tiveram contribuição direta ou indireta para a realização deste trabalho.

*“A única coisa que ninguém tira de você nessa vida é o estudo.”*

(Pedro Flávio)

# Resumo

Com o crescente interesse no desenvolvimento de veículos autônomos para ambientes externos, faz-se necessária a ampla investigação de técnicas que favoreçam a navegação autônoma. A navegação autônoma tem sido largamente estudada pela comunidade acadêmica, sendo analisados os fatores que possibilitem um deslocamento seguro e eficiente. Para a navegação autônoma, normalmente são considerados apenas obstáculos no ambiente. No entanto, terrenos desconhecidos e não-estruturados podem representar um desafio crucial para a segurança do robô ou a viabilidade da tarefa.

Este trabalho aborda o problema de mapeamento do grau de dificuldade para o deslocamento de um robô móvel terrestre em ambientes externos a partir da fusão das aquisições de múltiplos sensores usando aprendizado profundo. Neste trabalho são considerados terrenos onde podem ser encontrados diversos tipos de dificuldades, tais como: *i)* diferentes superfícies; *ii)* disparidade entre os níveis de rugosidade; *iii)* e inclinações dessas superfícies. Portanto, o objetivo principal da abordagem proposta consiste em criar mapas tridimensionais (3D) das regiões percorridas acrescidos do custo correspondente ao deslocamento, favorecendo a tomada de decisão de algoritmos de planejamento de caminho.

A metodologia proposta é dividida em três etapas principais: *i)* Mapeamento tridimensional e localização, onde é criado um mapa 3D a partir das nuvens de pontos providas por um *laser*; *ii)* Estimção do custo de navegação usando informação inercial computada a partir dos dados providos por uma IMU; e *iii)* Incremento do mapa tridimensional com custo de navegação usando aprendizado profundo, onde os dados inerciais e geométricos são combinados por meio de aprendizado profundo para estimar os custos de navegação de regiões não visitadas pelo robô terrestre.

Para validar essas etapas, foram realizados experimentos com robôs reais, em diferentes ambientes, no intuito de avaliar a qualidade das principais operações propostas e do processo completo de mapeamento do custo de navegação. Ao final, são discutidos os resultados alcançados em cada etapa.



**Palavras-chave:** Mapeamento de Terreno, Navegação Autônoma, Aprendizado Profundo, Robótica de Campo.

# Abstract

With the growing interest in the development of autonomous vehicles for outdoor environments, it is necessary to investigate techniques that support autonomous navigation. Autonomous navigation has been widely studied by the academic community and several factors that provide a safe and efficient displacement. For autonomous navigation, they are often considered only obstacles in the environment. However, unknown and unstructured terrains may represent a crucial feature for the robot's security or viability of the task.

This work addresses the problem of mapping the difficulty level when navigating through outdoor environments from multi-sensor fusion using deep learning. In this work are considered terrains, where difficulties can be found, such as: *i)* different types of surfaces; *ii)* roughness levels disparities; and *iii)* highly sloping surfaces. In this way, the main objective is to create three-dimensional (3D) maps augmented with navigation costs, improving the decision making of path planning algorithms.

The proposed methodology in this thesis is divided into three main steps: *i)* Three-dimensional mapping and localization, where is created a 3D map from point clouds provided by a laser; *ii)* Navigation cost estimation using inertial data, where the navigation costs are computed from inertial data provided by an IMU; and *iii)* 3D map augmentation with navigation cost using deep learning, where inertial and geometric data are combined through deep learning to estimate the navigation costs of unvisited regions by the ground robot. Several experiments were carried out with real robots in different environments to evaluate the quality of the proposed tasks and the complete process of navigation cost mapping. In the end, the achieved results at each proposed step are discussed.

**Keywords:** Terrain Mapping, Autonomous Navigation, Deep Learning, Field Robotics.

# Lista de Figuras

1.1	Exemplos de aplicações em <i>Field Robotics</i> . . . . .	2
1.2	Exemplos de tipos diferentes de robôs móveis. . . . .	2
1.3	Exemplos de aplicação considerando navegação autônoma. . . . .	5
1.4	Exemplos de aplicação considerando a utilização de múltiplos sensores para mapear um determinado ambiente. . . . .	7
1.5	Exemplos de ambientes externos, cujos terrenos correspondem à verdadeiros obstáculos para a realização das tarefas pré-definidas. . . . .	8
1.6	Mapa tridimensional do ambiente externo com o custo de navegação associado. . . . .	10
2.1	Exemplos de imagens capturadas durante o deslocamento, com ênfase nas maiores dificuldades encontradas durante a navegação em Marte. . . . .	14
2.2	Detecção de obstáculo em ambiente com alta vegetação [Manduchi et al., 2005]. . . . .	16
2.3	Esquemático da abordagem proposta pelos autores para a classificação de terrenos [Otsu et al., 2016]. . . . .	16
2.4	Diagrama de bloco do sistema proposto [Souza et al., 2014]. . . . .	18
2.5	Definição e avaliação de limiares para diferenciação entre asfalto e grama [Castelnovi et al., 2005]. . . . .	20
2.6	Processo de remoção de impulso [C. Ward & Iagnemma, 2009]. . . . .	21
2.7	Roda rígida com ressaltos utilizada para extração de características [Lv et al., 2018]. . . . .	21
2.8	Mapa de traversabilidade construído em [Helmick et al., 2009], por meio da função de custo proposta. . . . .	23
2.9	Ambiente externo representado por meio da combinação entre <i>laser</i> e câmeras. . . . .	24
2.10	Veículo utilizado durante os experimentos e disposição dos sensores acoplados [Brooks & Iagnemma, 2007]. . . . .	25
2.11	Construção do mapa de traversabilidade e planejamento de caminho [Tanaka et al., 2015]. . . . .	28

2.12	Análise de traversabilidade com planejamento de caminho ótimo [Guo et al., 2011]. . . . .	29
2.13	Exemplos de classificação de traversabilidade usando <i>superpixel</i> e quadrantes de tamanho fixo [Kim et al., 2007]. . . . .	30
2.14	Esquemático da abordagem proposta em [Sock et al., 2016], com a combinação de múltiplos sensores. . . . .	31
4.1	Esquemático para ilustrar a representação das coordenadas visitadas ( $g_f^v$ ) e as respectivas regiões visitadas ( $r_f^v$ ). . . . .	43
4.2	Esquemático da metodologia proposta. . . . .	45
5.1	Arcabouço utilizado para realizar a captura de dados inerciais e geométricos, providos por uma IMU e um <i>laser</i> , respectivamente. . . . .	48
5.2	Resultados do processo de mapeamento tridimensional e computação da localização do veículo terrestre. . . . .	49
6.1	Impacto da variação de velocidade na aquisição de dados inerciais. . . . .	52
6.2	Representação de um dado inercial unidimensional, onde o mesmo sinal pode ser interpretado tanto no domínio do tempo, quanto no domínio da frequência. . . . .	54
6.3	Sinal transformado para o domínio da frequência por meio da FFT, evidenciando o teorema de <i>Nyquist</i> no espelhamento do vetor. . . . .	55
6.4	Ilustração do processo de formação da descrição de rugosidade. . . . .	55
6.5	Esquemático da função de custo proposta. . . . .	57
6.6	Modelo de regressão polinomial de terceira ordem ( $\Omega$ ), aplicado na combinação entre os ângulos <i>roll</i> e <i>pitch</i> do veículo, resultando no custo de <i>attitude</i> do robô. . . . .	58
6.7	Modelo de regressão polinomial de terceira ordem ( $\Lambda$ ), aplicado na combinação entre o nível de rugosidade e o custo de <i>attitude</i> do robô, resultando no custo de navegação da região percorrida. . . . .	58
7.1	Aquisição dos dados inerciais e geométricos. . . . .	62
7.2	Identificação das medições inerciais e geométricas que correspondem à mesma região. . . . .	63
7.3	Discretização de regiões contendo medições geométricas. . . . .	65
7.4	Arquitetura da CNN proposta para predição de custos de navegação. . . . .	65
7.5	Terreno em ambiente externo, representado em três dimensões, com coordenadas contínuas. . . . .	67

7.6	Etapas 1 e 2 do processo de propagação de custos de navegação para regiões não visitadas. . . . .	68
7.7	Etapas 3 e 4 do processo de propagação de custos de navegação para regiões não visitadas. . . . .	69
7.8	Etapas 5 e 6 do processo de propagação de custos de navegação para regiões não visitadas. . . . .	69
8.1	Plataformas de robótica móvel. . . . .	72
8.2	Diferentes tipos de terrenos encontrados no primeiro ambiente. . . . .	74
8.3	Diferentes tipos de terrenos encontrados no segundo ambiente. . . . .	75
8.4	Segundo ambiente e as áreas que o compõe. . . . .	76
8.5	Avaliação do impacto da variação de velocidade no dado inercial. . . . .	77
8.6	Dados inerciais (acelerações lineares no eixo Z), reais e transformados, capturados em diferentes áreas e velocidades. . . . .	79
8.7	Diferentes tipos de irregularidades (cavidades e elevações) encontradas nos terrenos durante a navegação. . . . .	86
8.8	Ambientes utilizados neste experimento, com diferentes níveis de rugosidade e inclinação. . . . .	87
8.9	Apresentação das principais características do terreno, contidas na área 2, do segundo ambiente. Adicionalmente, são apresentados os mapas tridimensionais aumentados com custo de navegação, criados a partir de diferentes modelos preditivos. . . . .	88
8.10	Caminhos computados a partir do mapa tridimensional incrementado com custo de navegação proposto. . . . .	91
8.11	Custos de navegação computados durante a navegação do robô, em processo de planejamento de caminho. . . . .	92
A.1	Esquemático da metodologia proposta para o mapeamento AVF. . . . .	105
A.2	Exemplos da representação AVF. . . . .	106
A.3	Exemplos de representações AVF em ambientes externos. . . . .	108
A.4	Diferentes caminhos obtidos através dos mapas AVF propostos, considerando diferentes métricas (distância e custo de navegação). . . . .	110
B.1	Dados inerciais (velocidades angulares no eixo Y), reais e transformados, capturados em diferentes áreas e velocidades. . . . .	114

# Lista de Tabelas

2.1	Principais trabalhos encontrados na literatura e as tarefas por eles abordadas, contextualizando o problema proposto neste trabalho. . . . .	34
8.1	Dispersão das magnitudes de dados inerciais reais, para acelerações lineares no eixo Z, capturados em diferentes áreas e aplicando diferentes velocidades.	81
8.2	Dispersão das magnitudes de dados inerciais reais, para velocidades angulares no eixo Y, capturados em diferentes áreas e aplicando diferentes velocidades. . . . .	81
8.3	Dispersão das magnitudes de dados inerciais transformados, considerando acelerações lineares no eixo Z, capturados em diferentes áreas e aplicando diferentes velocidades. . . . .	82
8.4	Dispersão das magnitudes de dados inerciais transformados, considerando velocidades angulares no eixo Y, capturados em diferentes áreas e aplicando diferentes velocidades. . . . .	82
8.5	Resultados da classificação do nível de rugosidade em terrenos externos. Neste experimento é apresentada a acurácia dos classificadores Random Forest, Ada Boosting e SVM, em relação a três velocidades diferentes, para cada execução. . . . .	84
8.6	Matrizes de confusão computadas pelo classificador <i>Random Forest</i> (RF), com variação de velocidade. Neste experimento, os modelos de classificação treinados consideram 5 níveis de rugosidade, porém os dados de teste consideram apenas 3 níveis de rugosidade (NR), em 3 velocidades distintas (0.4, 0.6 e 0.8 m/s). . . . .	85
8.7	Custos dos caminhos gerados pelo algoritmo de planejamento de caminho (Dijkstra), considerando diferentes modelos preditivos em diferentes cenários.	90
8.8	Custos dos caminhos gerados pelo algoritmo de planejamento de caminho (Dijkstra), considerando diferentes métricas (distância e custo de navegação) para tomada de decisão, em diferentes cenários. . . . .	93

A.1	Custos dos caminhos gerados pelo planejador de caminho, de acordo com diferentes estratégias de propagação, em diferentes terrenos. . . . .	109
A.2	Custos dos caminhos gerados a partir do mapeamento ??AVF?? proposto, de acordo com diferentes métricas (distância ou custo de navegação), em diferentes terrenos. . . . .	111
A.3	Medidas ??RMSE?? entre: <i>i</i> ) mapa ??AVF?? + propagação <i>baseline</i> e o <i>ground-truth</i> ; e <i>ii</i> ) mapa ??AVF?? + propagação proposta e o <i>ground-truth</i> , para ambientes simulados. . . . .	112
C.1	Matrizes de confusão computadas pelo classificador SVM, com variação de velocidade. Neste experimento, os classificadores treinados consideram 5 níveis de rugosidade, porém os dados de teste consideram apenas 3 níveis de rugosidade (NR), em 3 velocidades distintas (0.4, 0.6 e 0.8 m/s) . . . . .	116
C.2	Matrizes de confusão computadas pelo classificador <i>Ada Boosting</i> (AB), com variação de velocidade. Neste experimento, os classificadores treinados consideram 5 níveis de rugosidade, porém os dados de teste consideram apenas 3 níveis de rugosidade (NR), em 3 velocidades distintas (0.4, 0.6 e 0.8 m/s). . . . .	117

# Lista de Acrônimos

- 3D** *Three-dimensional* (Tridimensional)
- BOVW** *Bag of Visual Words* (Saco de Palavras Visuais)
- FFT** *Fast Fourier Transform* (Transformada de Fourier)
- GPS** *Global Positioning System* (Sistema de Posicionamento Global)
- HSV** *Hue, Saturation, Value* (Matiz, Saturação, Valor)
- IMU** *Inertial Measurement Unit* (Unidade de Medição Inercial)
- KNN** *K-Nearest Neighbors* (K-Vizinhos Mais Próximos)
- LUT** *Lookup Table* (Tabela de consulta)
- RBF** *Radial basis function* (Função de Base Radial)
- RGB** *Red, Green, Blue* (Vermelho, Verde, Azul)
- DOF** *Degrees of Freedom* (Graus de liberdade)
- AVF** *Augmented Vector Field*
- GP** *Gaussian Process* (Processo Gaussiano)
- PCA** *Principal Component Analysis*
- RMSE** *Root Mean Square Error* (Raiz do Erro Quadrático Médio)
- RMS** *Root Mean Square* (Erro Quadrático Médio)
- SURF** *Speed Up Robust Features* (Características Robustas Aceleradas)
- SUV** *Sport Utility Vehicle* (Veículo Utilitário Esportivo)
- SVM** *Support Vector Machine* (Máquina de Vetor de Suporte)



**UFMG** Universidade Federal de Minas Gerais

**QCAT** Queensland Centre for Advanced Technologies

**CSIRO** Commonwealth Scientific and Industrial Research Organisation

**ISIT** *Inertial Speed-Invariant Transformation* (Transformação de Dados Inerciais Invariantes a Velocidade)

**CNN** *Convolutional Neural Networks* (Redes Neurais Convolucionais)

**ICP** Iterative Closest Point

**GLCM** *Gray-Level Co-occurrence Matrix* (Matriz de Co-ocorrência em Escala de Cinza)

# Lista de Símbolos

- $\vec{\mathcal{I}}$  Conjunto de dados inerciais capturados
- $\mathcal{P}$  Conjunto total de nuvens de pontos capturadas
- $\mathcal{P}^v$  Conjunto de nuvens de pontos representando as regiões visitadas pelo robô
- $\mathcal{P}^u$  Conjunto de nuvens de pontos representando as regiões não visitadas pelo robô
- $\mathcal{G}$  Conjunto total de coordenadas do mapa do terreno
- $\mathcal{G}^v$  Conjunto de coordenadas visitadas pelo robô
- $\mathcal{G}^u$  Conjunto de coordenadas não visitadas pelo robô
- $\mathcal{R}$  Conjunto total de regiões do mapa do terreno
- $\mathcal{R}^v$  Conjunto de regiões visitadas pelo robô
- $\mathcal{R}^u$  Conjunto de regiões não visitadas pelo robô
- $\mathcal{V}$  Conjunto de velocidades aplicadas pelo robô
- $\vec{\mathcal{S}}$  Conjunto de dados inerciais invariantes a velocidade
- $\mathcal{L}$  Conjunto de níveis de rugosidade previamente conhecidos
- $\mathcal{B}$  Conjunto de níveis de rugosidade estimados
- $\mathcal{C}$  Conjunto total de custos de navegação
- $\mathcal{M}$  Mapa tridimensional aumentado com custo de navegação
- $\Xi(\cdot)$  Função de transformação do dado inercial
- $\eta(\cdot)$  Função de estimação do fator de transformação
- $\Lambda(\cdot)$  Função de custo de navegação

$\Omega(\cdot)$  Função de nível de *attitude* do robô  
 $\Delta(\cdot)$  Função de estimação do custo de navegação para regiões não visitadas pelo robô  
 $\alpha^z$  Aceleração linear no eixo Z, no domínio do tempo  
 $\omega^y$  Velocidade angular no eixo Y, no domínio do tempo  
 $f\alpha^z$  Aceleração linear no eixo Z, transformada para o domínio da frequência  
 $f\omega^y$  Velocidade angular no eixo Y, transformada para o domínio da frequência  
 $\rho^y$  Orientação *roll* do robô  
 $\pi^x$  Orientação *pitch* do robô  
 $\lambda$  Largura do robô terrestre  
 $\gamma$  Comprimento do robô terrestre  
 $k$  Tamanho da janela deslizante de medição  
 $\nu_c$  Velocidade corrente do robô  
 $\nu_g$  Velocidade alvo da transformação  
 $X$  Matriz do modelo de regressão  
 $Y$  Vetor contendo as respostas do modelo de regressão  
 $\beta$  Parâmetros do modelo de regressão  
 $\varepsilon$  Erro do modelo de regressão  
 $d$  Distância considerada para definir a janela deslizante de medição  
 $\Delta t$  Intervalo de tempo entre medições inerciais  
 $\nu$  Velocidade linear do robô terrestre  
 $T$  Quantidade de frequências que representa o sinal inercial  
 $\chi$  Quantidade de linhas da representação bidimensional fornecida à CNN  
 $\tau$  Quantidade de colunas da representação bidimensional fornecida à CNN  
 $\delta$  Número total de medições inerciais em  $\vec{\mathcal{I}}$ , ou seja,  $\delta = |\vec{\mathcal{I}}|$

$\sigma$  Número total de nuvens de pontos em  $\mathcal{P}$ , ou seja,  $\sigma = |\mathcal{P}|$

$\phi$  Número total de coordenadas e regiões visitadas pelo robô em  $\mathcal{G}^v$  e  $\mathcal{R}^v$ , ou seja,  $\phi = |\mathcal{G}^v|$  e  $\phi = |\mathcal{R}^v|$

$\vartheta$  Número total de coordenadas e regiões não visitadas pelo robô em  $\mathcal{G}^u$  e  $\mathcal{R}^u$ , ou seja,  $\vartheta = |\mathcal{G}^u|$  e  $\vartheta = |\mathcal{R}^u|$

# Sumário

Agradecimentos	viii
Resumo	xi
Abstract	xiii
Lista de Figuras	xv
Lista de Tabelas	xix
Lista de Acrônimos	xxi
Lista de Símbolos	xxiii
<b>1 Introdução</b>	<b>1</b>
1.1 Contextualização . . . . .	1
1.2 Motivação . . . . .	4
1.3 Problema . . . . .	7
1.4 Contribuições . . . . .	9
1.5 Organização do texto . . . . .	11
<b>2 Trabalhos Relacionados</b>	<b>13</b>
2.1 Classificação do nível de rugosidade de terrenos . . . . .	13
2.1.1 Sensores exteroceptivos . . . . .	14
2.1.2 Sensores propioceptivos . . . . .	17
2.2 Análise de dados inerciais considerando a velocidade . . . . .	19
2.3 Estimação de custo de navegação . . . . .	21
2.4 Fusão entre múltiplos sensores . . . . .	23
2.5 Mapeamento de ambientes externos . . . . .	27
2.6 Contextualização do trabalho . . . . .	32

<b>3</b>	<b>Fundamentação Teórica</b>	<b>35</b>
3.1	Aprendizado de Máquina . . . . .	35
3.1.1	Classificação . . . . .	36
3.1.2	Regressão . . . . .	37
<b>4</b>	<b>Metodologia</b>	<b>42</b>
4.1	Definição do problema geral . . . . .	42
4.2	Visão geral da metodologia proposta . . . . .	44
<b>5</b>	<b>Mapeamento tridimensional e localização</b>	<b>47</b>
<b>6</b>	<b>Estimação do custo de navegação usando dados inerciais</b>	<b>50</b>
6.1	Definição dos problemas . . . . .	50
6.2	Transformação dos dados inerciais . . . . .	51
6.3	Classificação do nível de rugosidade de terrenos . . . . .	53
6.4	Estimação do custo de navegação . . . . .	56
<b>7</b>	<b>Incremento do mapa tridimensional com custo de navegação usando aprendizado profundo</b>	<b>60</b>
7.1	Definição dos problemas . . . . .	60
7.2	Registro dos dados inerciais e geométricos . . . . .	61
7.3	Fusão entre múltiplos sensores . . . . .	63
7.4	Mapeamento do custo de navegação . . . . .	66
7.4.1	Representação de terrenos . . . . .	67
7.4.2	Propagação do custo de navegação . . . . .	68
<b>8</b>	<b>Experimentos</b>	<b>71</b>
8.1	Aquisição de dados . . . . .	71
8.2	Ambiente experimental . . . . .	73
8.3	Análise de comportamento dos dados inerciais com variação de velocidade	74
8.4	Avaliação da transformação de dados inerciais invariantes a velocidade	77
8.4.1	Análise qualitativa . . . . .	78
8.4.2	Análise quantitativa . . . . .	80
8.5	Avaliação da classificação do nível de rugosidade . . . . .	82
8.5.1	Acurácia da classificação com velocidades individuais . . . . .	83
8.5.2	Matrizes de confusão . . . . .	85
8.6	Avaliação do mapeamento do custo de navegação . . . . .	86
8.6.1	Análise qualitativa . . . . .	87

8.6.2	Análise quantitativa . . . . .	89
8.7	Avaliação da efetividade do mapeamento de terrenos externos . . . . .	90
<b>9</b>	<b>Conclusões e Trabalhos Futuros</b>	<b>94</b>
9.1	Conclusões . . . . .	94
9.2	Trabalhos Futuros . . . . .	96
	<b>Referências Bibliográficas</b>	<b>97</b>
<b>A</b>	<b>Mapeamento de ambientes externos baseado em <i>vector fields</i> usando sensores inerciais</b>	<b>104</b>
A.1	Metodologia . . . . .	104
A.1.1	Função do custo de navegação . . . . .	105
A.1.2	Representação AVF . . . . .	106
A.1.3	Propagação das magnitudes dos vetores . . . . .	107
A.2	Experimentos . . . . .	108
A.2.1	Avaliação da propagação das magnitudes dos vetores . . . . .	109
A.2.2	Avaliação da efetividade dos mapas AVF . . . . .	110
A.2.3	Avaliação da precisão dos mapas AVF . . . . .	111
<b>B</b>	<b>Resultados da transformação de dados inerciais invariantes à velocidade</b>	<b>113</b>
<b>C</b>	<b>Resultados das matrizes de confusão</b>	<b>115</b>

# Capítulo 1

## Introdução

Atualmente, tem se tornado cada vez mais recorrente a aplicação de veículos autônomos para a realização de atividades pré-definidas em ambientes externos. Grande esforço tem sido feito para que robôs terrestres possam navegar de maneira eficiente e segura por uma determinada área de interesse. Para navegar por um ambiente externo, além de identificar e desviar de obstáculos, também é importante analisar o terreno em que o veículo está se deslocando. A análise de um terreno deve considerar suas irregularidades e inclinações, visando mensurar o custo de se navegar por determinadas regiões.

Neste trabalho são apresentados os conceitos, as etapas de desenvolvimento e a validação de uma abordagem para o mapeamento do custo de navegação de terrenos em ambientes externos usando um robô terrestre.

### 1.1 Contextualização

O avanço da tecnologia tem proporcionado grande evolução para a Robótica, viabilizando a aplicação de robôs em atividades que demandam grande capacidade de movimentação. A utilização de robôs móveis tem despertado nos últimos anos grande interesse da comunidade acadêmica, principalmente quando se trata de ambientes externos, ou seja em terrenos naturais. Esse tipo de aplicação, em ambientes externos e não estruturados, é chamado de *Field Robotics* [Thorpe & Durrant-Whyte, 2001].

*Field Robotics* abrange uma grande variedade de aplicações, já que consiste no emprego de robôs autônomos e inteligentes em ambientes externos, tais como: veículos autônomos, mineração, busca e salvamento, rodovias inteligentes, aplicações militares, agricultura, mapeamento em desastres naturais, aplicações espaciais, dentre outras [Manduchi et al., 2005; Thrun et al., 2006; Kim et al., 2007; Forster et al., 2013; Souza et al., 2014; Ono et al., 2015]. Na Figura 1.1 podem ser visualizados alguns exemplos.





(a) Busca e salvamento.



(b) Coleta e pulverização.

Figura 1.1: Exemplos de aplicações em *Field Robotics*. A Figura 1.1a apresenta uma aplicação, considerando a tarefa de busca e salvamento em ambientes de desastre natural. A Figura 1.1b apresenta outra aplicação, considerando demandas encontradas na agricultura como a coleta de frutos e pulverização.


Os tipos de robôs móveis mais utilizados em aplicações voltadas para ambientes externos são: os veículos terrestres, os veículos aéreos e os veículos aquáticos [Thorpe & Durrant-Whyte, 2001]. Robôs terrestres são dispositivos capazes de se deslocar pelo solo, podendo utilizar diversas configurações para deslocamento, tais como: rodas, esteiras e pernas. Robôs aéreos são dispositivos capazes de se deslocar pelo ar, podendo ser do tipo: asa fixa, asa rotativa ou dirigível. Enquanto os robôs aquáticos são dispositivos capazes de se deslocar pela água, podendo se movimentar sobre a água ou submersos, conforme Figura 1.2.



(a) Robôs terrestres.



(b) Robôs aéreos.



(c) Robôs aquáticos.

Figura 1.2: Exemplos de tipos diferentes de robôs móveis. Na Figura 1.2a são apresentados alguns modelos de robôs terrestres. Na Figura 1.2b são apresentados alguns modelos de robôs aéreos. Na Figura 1.2c são apresentados alguns modelos de robôs aquáticos.

Os robôs móveis podem ainda ser classificados quanto ao modo de operação, como: Teleoperados, Semi-autônomos ou Autônomos. Os robôs teleoperados são controlados remotamente por um operador humano, que é responsável por transmitir ao robô quais movimentos o mesmo deve executar. Os robôs semi-autônomos recebem as sequências de instruções a serem executadas, porém, os mesmos são capazes de decidir se devem executar as instruções fornecidas. Os robôs autônomos não apresentam qualquer tipo de interferência humana, sendo os mesmos responsáveis por tomar suas próprias decisões com o intuito de alcançar o objetivo geral [Lynch & Park, 2017].

Com o crescimento das aplicações em *Field Robotics*, muito esforço tem ocorrido para aprimorar a tarefa de navegação autônoma. Isso ocorre devido à grande necessidade de prover maior autonomia aos robôs móveis durante sua movimentação. A navegação consiste em se deslocar por um determinado ambiente visando alcançar o objetivo principal, de maneira eficiente e segura [Lynch & Park, 2017]. Uma navegação eficiente consiste na realização de um deslocamento considerando o melhor gerenciamento de recursos tais como: distância, consumo de energia e tempo. Uma navegação segura consiste em realizar o deslocamento sem qualquer risco à integridade do robô, durante a movimentação. No entanto, o ambiente onde ocorre a navegação impactará diretamente no desempenho da tarefa, tendo em vista as características do robô [Siciliano & Khatib, 2007].

Na navegação autônoma, tem sido abordado fortemente a detecção e desvio de obstáculos. No entanto, um terreno desconhecido pode configurar um grande desafio para um robô terrestre realizar sua navegação, uma vez que a falta de conhecimento sobre os níveis de rugosidade ou os níveis de inclinação do terreno podem aumentar o custo ou inviabilizar o deslocamento do robô por essa região [Thrun et al., 2006].

Nesse contexto, uma das alternativas mais eficientes para proporcionar uma navegação autônoma, eficiente e segura, por ambientes externos, desconhecidos e não estruturados é a prévia computação de um mapa dos custos de navegação da cena. Com isso, um algoritmo de planejamento de caminhos pode encontrar um trajeto que minimize o custo ao se deslocar pelo ambiente, considerando não apenas a distância entre as coordenadas de origem e destino. Os custos podem estar associados à diferentes critérios, como energia ou tempo, porém neste trabalho os custos de navegação quantificam o grau de facilidade ou dificuldade de navegar por um determinado ambiente.

Neste trabalho, é proposta uma abordagem para a construção de um mapa contendo os custos de navegação de ambientes externos, desconhecidos e não estruturados, por meio da utilização de um robô terrestre, promovendo maior eficiência e segurança durante a navegação do mesmo.

## 1.2 Motivação

Na Robótica Móvel, a autonomia continua sendo um dos principais interesses dos pesquisadores nos últimos anos. Ao agregar maior autonomia aos robôs móveis, espera-se que os mesmos possam realizar tarefas complexas reduzindo a intervenção humana, ou seja, que os mesmos possam tomar suas próprias decisões em tempo real [Ben-Ari & Mondada, 2017]. Nesse contexto, um dos principais desafios está relacionado à navegação.

Diversas aplicações já foram propostas apresentando a temática exposta, com destaque para:

- Mineração, como na utilização de caminhões ou escavadeiras semi-autônomas para a realização de coletas de minérios ou escavações em minas. Os veículos autônomos podem executar suas tarefas vinte e quatro horas por dia, sem a intervenção humana e sem expor o operador humano a qualquer tipo de risco à sua integridade física. Os robôs são compostos por diversos sensores, que possibilitam uma visão geral do ambiente de deslocamento, favorecendo sua movimentação por todo o local de maneira segura, maximizando a produção [Liu & Chai, 2019]. Um exemplo da aplicação mencionada pode ser observado na Figura 1.3a.
- Exploração espacial, como na exploração de Marte por veículos semi-autônomos, como por exemplo os robôs *Spirit* e *Opportunity*. Os robôs mencionados também eram equipados com diversos sensores como câmeras, *lasers*, sensores inerciais, dentre outros. Essa aplicação demandava autonomia devido à grande dificuldade de teleoperação dos veículos. Por isso, fazia-se necessário realizar, de maneira autônoma, a classificação do terreno imediatamente à frente para determinar a melhor rota para navegar, evitando obstáculos e locais que comprometam a navegação [Otsu et al., 2016]. Na Figura 1.3b, é apresentado um exemplo de navegação em Marte, pelo robô *Spirit*.
- Transporte autônomo urbano, como no uso de veículos autônomos para realizar o transporte de pessoas em ambiente urbano. Nesse segmento, a navegação, considerando as características do terreno, promoveria um deslocamento mais agradável para os passageiros e mais seguro para o veículo. Nessa aplicação, os veículos autônomos devem ser capazes de navegar em vias urbanas, tratando a dinamicidade do ambiente, como outros veículos, pedestres, semáforos, sinalizações, dentre outros eventos que ocasionalmente podem atrapalhar a navegação desses veículos [Pfrunder et al., 2017]. Veículos autônomos para transporte urbano são

equipados com câmeras, *lasers*, sensores inerciais, GPS, dentre outros. A Figura 1.3c apresenta um exemplo desse tipo de veículo autônomo.



(a) Mineração.



(b) Exploração espacial.



(c) Transporte autônomo urbano.

Figura 1.3: Exemplos de aplicação considerando navegação autônoma. Na Figura 1.3a é apresentada uma aplicação para navegação em ambientes externos não estruturados, como no caso das minas. A Figura 1.3b mostra uma aplicação envolvendo navegação autônoma, durante exploração espacial. Enquanto a Figura 1.3c apresenta uma aplicação de navegação no contexto de transporte urbano.

As aplicações supracitadas compartilham a necessidade de navegar por ambientes de maneira autônoma. Tais aplicações concentram seus esforços nas melhores alternativas para determinar a presença de obstáculos e evitá-los. Porém, ambientes externos podem apresentar características, quanto à irregularidade ou inclinação da superfície, que tornam a navegação inviável. Em determinados casos podem haver superfícies que apresentam um nível de irregularidade baixo, porém o grau de inclinação é muito alto, o que aumenta o custo de navegação para aquela região. Assim como, pode haver uma

região plana, mas com nível de irregularidade muito alto, também apresentando alto custo de navegação. Ou seja, é possível observar que para alcançar uma navegação segura e eficiente é necessário mais do que apenas evitar obstáculos.

Dessa forma, o estudo para estimar o custo da navegação em ambientes externos se torna uma boa alternativa para agregar na navegação autônoma de veículos terrestres. Para isso, destaca-se a aplicação de técnicas de mapeamento como mecanismo de armazenamento dos custos de navegação para cada posição do ambiente considerado. A aplicação de técnicas de mapeamento supracitadas, considerando as características do terreno, é chamada de *Mapeamento de Custo de Navegação*. A partir da representação dos custos de navegação do terreno, o veículo pode evitar trajetórias por regiões previamente conhecidas e com alto custo de navegação. Adicionalmente, destaca-se a possibilidade de utilização desses mapas por outros robôs ao navegarem pelo mesmo ambiente.

A construção de um mapa estimando o custo de navegação a partir de um único sensor pode apresentar algumas vulnerabilidades, tais como: *i*) imprecisão na representação do terreno; *ii*) falta de capacidade de mensurar o custo de navegação para posições não visitadas pelo veículo; *iii*) falta de uma representação direta da deformação do terreno; *iv*) e a dificuldade de processamento em tempo real. Nesse sentido, a utilização de múltiplos sensores pode ser uma alternativa eficiente para a construção do mapa de custo de navegação, já que a combinação entre diferentes sensores pode prover uma solução robusta para tratar as vulnerabilidades supracitadas.


Algumas aplicações abordaram a criação de mapas por meio da combinação entre múltiplos sensores, dentre elas destacam-se:

- Mapeamento de terrenos externos, sendo utilizado um veículo terrestre contendo uma câmera e uma Unidade de Medição Inercial (*Inertial Measurement Unit*, ou IMU), considerando características do terreno. As informações visuais e inerciais são combinadas para computar o mapa de custo de navegação do terreno. A partir do mapa é possível aplicar técnicas de planejamento de caminho para navegar no ambiente [Guo et al., 2011]. A Figura 1.4a mostra o veículo utilizado na aplicação.
- Mapeamento de traversabilidade, para mapear as regiões por onde é possível realizar a navegação, considerando apenas os obstáculos contidos no ambiente. Para isso é utilizado um veículo terrestre contendo um *laser* e um radar. A partir dos dados coletados individualmente por cada sensor, são computados dois mapas de obstáculos e os mesmos são combinados para gerar uma representação mais

eficiente do ambiente [Guerrero et al., 2015]. Na Figura 1.4b é apresentado um mapa de obstáculos resultante, auxiliando na navegação de veículos terrestres.



(a) Mapeamento de ambientes externos [Guo et al., 2011].



(b) Mapeamento de obstáculos [Guerrero et al., 2015].

Figura 1.4: Exemplos de aplicação considerando a utilização de múltiplos sensores para mapear um determinado ambiente. A Figura 1.4a expõe uma plataforma robótica usada para mapear o custo de navegação de um terreno por meio de uma câmera e uma IMU. Na Figura 1.4b é apresentada uma aplicação para o mapeamento de obstáculos de regiões, por meio da combinação entre um *laser* e um radar.

Considerando o exposto, é possível verificar que mapas de custo de navegação podem ser de extrema utilidade para uma navegação autônoma de qualidade. No entanto, o referido mapeamento ainda apresenta alguns fatores que podem inviabilizar sua aplicação, como a utilização de um único sensor. Dessa forma, a construção de mapas de custo de navegação para terrenos a partir da combinação entre múltiplos sensores surge como uma alternativa viável para a realização da tarefa supracitada de maneira eficiente e segura.

## 1.3 Problema

A navegação é uma das principais ações realizadas por robôs móveis autônomos terrestres. Diversas aplicações consideram a navegação em ambientes internos e, nesses cenários, o tipo de terreno não costuma causar problemas durante o deslocamento de veículos terrestres, já que ambientes internos apresentam terrenos com estrutura bem definida. No entanto, quando se trata de ambientes externos o veículo pode encontrar diferentes tipos de superfícies as quais podem afetar severamente a viabilidade, o custo do caminho e a execução de determinadas tarefas [Siciliano & Khatib, 2007].

Dentre as principais dificuldades encontradas ao navegar por ambientes externos, podem ser destacadas:

- A grande quantidade de tipos diferentes de superfícies (areia, grama, concreto, pedras, dentre outros);
- A grande disparidade entre níveis de rugosidade ou irregularidade das superfícies;
- As inclinações acentuadas das superfícies.

Considerando as dificuldades mencionadas acima, torna-se evidente a importância de analisar os custos de se navegar por diferentes tipos de terrenos, já que algumas superfícies podem representar um grande obstáculo para a navegação de veículos terrestres ou para a realização da tarefa, como pode ser observado na Figura 1.5.



Figura 1.5: Exemplos de ambientes externos, cujos terrenos correspondem à verdadeiros obstáculos para a realização das tarefas pré-definidas.

O mapeamento do ambiente pode prover uma solução eficiente para a navegação de veículos terrestres, uma vez que será possível determinar o custo de navegação para cada posição do mapa. Porém, a construção desse mapa, considerando um único sensor, em muitos casos, demanda muito deslocamento pelo ambiente para cobrir todo o terreno a ser mapeado. Além disso, usar os dados providos por um único sensor implica em maior imprecisão das medições, quando comparado ao uso de múltiplos sensores.

Para tratar a construção desse mapa de maneira mais eficiente, pode ser utilizada a combinação entre múltiplos sensores. Dessa forma, é possível combinar informações complementares e com isso: *i*) estimar o custo de navegação para posições não visitadas, demandando menos tempo, consumo de energia e deslocamento pelo ambiente; e *ii*) maximizar a precisão das estimativas sobre o terreno.

Dessa forma o problema abordado neste trabalho consiste em:

**Dado um veículo terrestre com rodas em um ambiente externo desconhecido e não estruturado. Computar um mapa de custo de navegação, para o referido ambiente externo desconhecido e não estruturado.**

Como pode ser observado, diversos desafios estão associados ao problema de mapeamento de custo de navegação em ambientes externos a partir da combinação entre múltiplos sensores. Podemos destacar alguns subproblemas como parte integrante do problema principal, tais como:

1. Transformação do dado inercial, tornando-o invariante à velocidade;
2. Classificação dos diferentes tipos de terrenos percorridos em seus respectivos níveis de rugosidade;
3. Estimação do custo de navegação, a partir de dados inerciais;
4. Fusão entre múltiplos sensores para estimar o custo de navegação para posições não visitadas; e o
5. Mapeamento tridimensional dos custos de navegação estimados para cada posição contínua do terreno.

Um exemplo de mapa de custo de navegação para ambientes externos, desconhecidos e não estruturados pode ser visualizado na Figura 1.6. Na Figura 1.6, quanto mais azul, menor é o custo de navegação pela respectiva região. Quanto mais vermelho, maior é o custo de navegação pela respectiva região. A cor branca corresponde à um custo de navegação intermediário.

## 1.4 Contribuições

A seguir são apresentadas as principais contribuições obtidas a partir deste trabalho, que estão agrupadas de acordo com cada um dos diferentes desafios relacionados ao problema.

- **Classificação, invariante à velocidade, de níveis de rugosidade:** Foi apresentado um novo método para classificação dos níveis de rugosidade de terrenos externos não estruturados, baseado apenas em acelerações e velocidades angulares providas por uma IMU. A técnica foi avaliada em ambientes reais, onde para diferentes velocidades a acurácia média foi superior a 84%. A abordagem






Figura 1.6: Mapa tridimensional do ambiente externo com o custo de navegação associado.

proposta também transforma o dado inercial, reduzindo o impacto da velocidade sobre as acelerações lineares e velocidades angulares, tornando o dado inercial invariante à velocidade.

- **Estimação do custo de navegação a partir de dados inerciais:** Neste trabalho também foi proposta uma função que estima o custo de navegação do terreno, a partir de dados inerciais. A referida função propõe uma representação de alto nível do grau de dificuldade de um veículo terrestre ao navegar por uma região. Para isso, um Modelo de regressão polinomial foi utilizado para estimar valores de custo de navegação, dados os níveis de rugosidade e os ângulos do veículo (*roll* e *pitch*).
- **Mapeamento baseado em *vector fields*:** Para representar ambientes externos, inicialmente, foi proposta uma nova técnica de mapeamento baseada em *vector fields*, a partir de sensores inerciais. A função de custo de navegação proposta foi utilizada para quantificar o grau de dificuldade do robô ao navegar pelo terreno externo. Com isso, em um mapa bidimensional foram representados os custos de navegação, por meio de *vector fields*, descrevendo a relação entre regiões adjacentes. A validação da técnica proposta considerou os custos dos caminhos planejados a partir dos mapas computados.
- **Mapeamento tridimensional aumentado com custo de navegação através de aprendizado profundo:** Foi proposta uma nova abordagem para mapeamento de ambientes externos, a partir da combinação entre *laser* e IMU,

através de aprendizado profundo. A combinação entre os dados geométricos e inerciais ocorreu por meio da aplicação de uma Rede Neural Convolutiva, que aprende a relação entre a representação geométrica e o custo de navegação do terreno. Com isso, é possível estimar os custos de navegação para regiões não visitadas pelo veículo terrestre. A validação da abordagem proposta se deu através da análise dos mapas tridimensionais aumentados com custo de navegação, computados a partir da abordagem de predição proposta e da técnica de predição *baseline*. Adicionalmente, foram avaliados os custos dos caminhos planejados.

Durante o desenvolvimento do projeto, partes da metodologia proposta, além de problemas correlatos, foram apresentados em artigos que se encontram publicados em conferências internacionais e *journals*:

- Felipe G. Oliveira, Elerson R. S. Santos, Armando A. Neto, Mario F. M. Campos e Douglas G. Macharet. Speed-invariant Terrain Roughness Classification and Control based on Inertial Sensors. Latin American Robotics Symposium (LARS), 2017. [Qualis-CC B1]
- Felipe G. Oliveira, Armando A. Neto, Paulo Borges, Mario F. M. Campos e Douglas G. Macharet. Augmented Vector Field Navigation Cost Mapping using Inertial Sensors. 19th International Conference on Advanced Robotics (ICAR), 2019. [Qualis-CC A3]
- Felipe G. Oliveira, Armando A. Neto, David Howard, Paulo Borges, Mario F. M. Campos e Douglas G. Macharet. Three-dimensional Mapping with Augmented Navigation Cost through Deep Learning. Journal of Intelligent & Robotic Systems (JINT), 2021. [Qualis-CC A2]

## 1.5 Organização do texto

O Capítulo 2 apresenta uma análise crítica dos trabalhos mais relevantes encontrados na literatura, relacionados ao tema abordado nesta pesquisa. O Capítulo 3 apresenta a fundamentação teórica necessária para a compreensão das técnicas de Aprendizado de Máquina utilizadas neste trabalho. No Capítulo 4 é apresentada uma visão geral da metodologia proposta para o problema de mapeamento do custo de navegação em ambientes externos a partir da combinação entre múltiplos sensores. No Capítulo 5 são discutidas as técnicas de mapeamento tridimensional e de localização empregadas neste trabalho. As abordagens propostas para estimação do custo de navegação a partir de

dados inerciais são apresentadas no Capítulo 6. As etapas para estimação do mapa de custo de navegação do terreno através de aprendizado profundo são apresentadas no Capítulo 7. No Capítulo 8 são apresentados o arcabouço experimental, os cenários e os *datasets* utilizados para a construção do modelo. Ainda no Capítulo 8, foram descritos os procedimentos experimentais e apresentados e discutidos os resultados. Por fim, no Capítulo 9 são apresentadas as conclusões do presente trabalho e são discutidos caminhos para investigações futuras.

# Capítulo 2

## Trabalhos Relacionados

Neste capítulo serão apresentadas e discutidas as contribuições dos principais trabalhos relacionados ao problema abordado, destacando o estado da arte para cada tópico relacionado à presente pesquisa. Neste trabalho, é proposto o mapeamento do custo de navegação em ambientes externos a partir da combinação entre múltiplos sensores.

Na literatura foram encontrados diversos trabalhos que tratam temas relacionados ao problema abordado, porém tais trabalhos consideram apenas algumas partes do problema alvo desta pesquisa. Dessa forma, este levantamento visa apresentar os principais trabalhos que abordam cada bloco que compõem a ideia central desta tese.

Nas seções seguintes serão apresentados trabalhos relacionados sobre: *i)* Classificação do nível de rugosidade de terrenos; *ii)* Análise de dados inerciais invariantes a velocidade; *iii)* Estimação de custo de navegação; *iv)* Fusão entre múltiplos sensores; *v)* Mapeamento de ambientes externos; *vi)* e uma contextualização sobre o presente trabalho.

### 2.1 Classificação do nível de rugosidade de terrenos

Os problemas relacionados ao planejamento de caminho e navegação são de grande importância para veículos autônomos, além de serem alvo de muitas investigações, com diferentes abordagens encontradas na literatura [Pereira et al., 2009; Souza et al., 2014; Ono et al., 2015]. Considerando a classificação do nível de rugosidade de terrenos, a maioria dos trabalhos que representam o estado da arte fazem uso de sensores exteroceptivos, tais como: *i)* câmeras e *ii)* *lasers*, para sensoriar o ambiente. Por outro lado, sensores proprioceptivos, tais como IMU, proporcionam dados de aceleração e *attitude* que indiretamente correspondem a uma representação do terreno percorrido.

### 2.1.1 Sensores exteroceptivos

Dentre os trabalhos que usam apenas imagens para proceder a classificação de terrenos destacam-se [Ono et al., 2015; Otte et al., 2015; Fujita & Ichimura, 2015].

Em Ono et al. [2015], é proposta uma abordagem que realiza a classificação de terrenos planetários baseada em imagens e o planejamento de caminho para navegação, ambos de maneira autônoma. Para tratar a classificação de terrenos, são consideradas a cor, textura e gradiente como características visuais, sendo utilizado *Random Forest* como modelo de classificação dos terrenos. As imagens são capturadas por meio de câmeras que são direcionadas para as rodas do veículo, conforme Figura 2.1.



Figura 2.1: Exemplos de imagens capturadas durante o deslocamento, com ênfase nas maiores dificuldades encontradas durante a navegação em Marte: atolamento das rodas e pedras pontiagudas que furam as rodas [Ono et al., 2015].

Em Otte et al. [2015], é realizada a classificação de terrenos baseada em Redes Neurais Recorrentes. Os autores criam as características visuais a partir da extração de características de textura em regiões da imagem, onde tais regiões sofrem sucessivas operações de borramento. Com isso, a Rede Neural Recorrente é treinada para representar as características desejadas. Com essa técnica os autores obtiveram resultados superiores aos resultados de abordagens clássicas com 83,49% de acurácia.

No trabalho proposto por Fujita & Ichimura [2015], foram utilizadas imagens e medidas de profundidade, para a classificação de terrenos em operações de exploração planetária. Para isso, foram coletadas seqüências de imagens, sendo estas analisadas por um modelo dinâmico de textura, que determina os parâmetros que descrevem as propriedades de textura encontradas nas imagens. Considerando que uma variedade de seqüências de imagens foram coletadas, é criada uma base associando os parâmetros às suas respectivas seqüências de imagens. Dessa forma, para classificar uma nova

sequência de imagens basta verificar a menor distância para as classes no espaço de parâmetros.

Alguns trabalhos encontrados na literatura fazem ainda a combinação de sensores exteroceptivos, como em Zhang et al. [2016] que combina as informações providas por um *laser* e por uma câmera para classificar terrenos em ambientes de floresta. O *laser* proporciona a detecção do terreno e calibração da imagem, enquanto que, a partir das características visuais, é possível determinar cada componente do terreno contido na imagem. As características visuais consideradas foram cor, textura e variação espacial, sendo ainda empregado um processo autossupervisionado utilizando *Random Forest* para classificação.

No trabalho de Häselich et al. [2013], é descrita uma abordagem para a classificação de terrenos baseada em *Markov Random Fields*, considerando a fusão de dados provenientes de um *laser* e de uma câmera. Para isso, é criada uma estrutura bidimensional a partir das medições do *laser* e cada célula é classificada em obstáculo, não-obstáculo ou desconhecido, de acordo com um limiar de altura das medições da superfície. A estratégia de fusão dos dados consiste em um modelo de transformação, que permite a associação de cada medição do *laser* para um determinado pixel da imagem. Nos experimentos os autores alcançaram uma acurácia de 90% e demonstraram que a abordagem é rápida o suficiente para ser executada em tempo real.

Em Manduchi et al. [2005], é proposta uma abordagem para a classificação de terrenos baseada na combinação de um par de câmeras *stereo* e um radar. Nesse trabalho é realizada a detecção de obstáculos baseada: *i*) nas medições de distância providas pelo par *stereo*; *ii*) em um sistema de classificação baseado em cor, para rotular os obstáculos de acordo com as classes de terrenos previamente definidas; e *iii*) em um algoritmo para a análise do dado gerado pelo radar, que permite a diferenciação entre grama e obstáculos. Esses algoritmos foram desenvolvidos no intuito de prover uma navegação autônoma segura, em ambientes com alta vegetação ou com grandes irregularidades, conforme Figura 2.2.

Ainda houveram trabalhos que combinaram sensores exteroceptivos com sensores próprioceptivos como em Brooks & Iagnemma [2007], onde os autores combinaram dados de imagem e vibração para identificar potenciais riscos em terrenos irregulares e desconhecidos. Um classificador de terrenos baseado em vibração (treinado previamente) provê rótulos para o treino do classificador visual, essa técnica de aprendizado é denominada autossupervisão. Em Otsu et al. [2016], foi proposto um método onde o robô aprenderá a treinar o dado a ser utilizado por meio de um processo autossupervisionado. Para isso, são utilizados dois classificadores, um para os dados visuais providos pela câmera e o outro para os dados inerciais providos pela IMU, treinados



Figura 2.2: Detecção de obstáculo em ambiente com alta vegetação [Manduchi et al., 2005].

separadamente e posteriormente usados para treinar um ao outro iterativamente, conforme pode ser observado na Figura 2.3. Pelo menos três classes diferentes de terrenos foram identificadas nos experimentos, com 82% de acurácia.

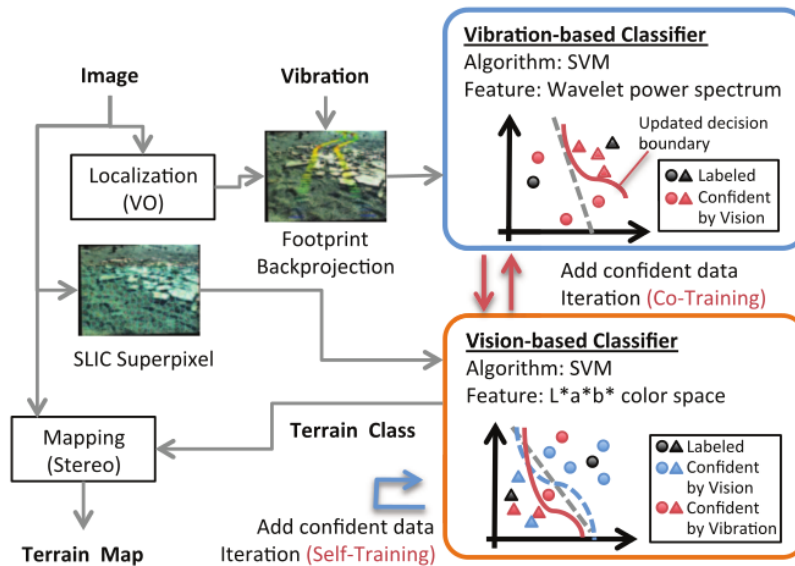


Figura 2.3: Esquemático da abordagem proposta pelos autores para a classificação de terrenos [Otsu et al., 2016].

No trabalho de Dutta & Dasgupta [2017], é proposta uma abordagem que considera múltiplos dados sensoriais providos por uma IMU e um *laser*. São usados múltiplos classificadores fracos, os quais apresentam menor complexidade para a classificação de terrenos. Para isso, os classificadores são combinados usando um algoritmo de aprendizado *ensemble*, que aprimora a taxa de treino do algoritmo. São coletados dados de aceleração linear (*nos eixos x, y e z*), velocidade angular (*nos eixos x, y e z*), *pitch*, *roll* e *yaw* e medições de profundidade. Como resultado, os autores obtiveram uma técnica de classificação de terrenos efetiva, superando o Máquina de Vetor de Suporte (*Support*

*Vector Machine*, ou SVM) em até 63% para alguns terrenos, e com ótimo tempo de execução, sendo 65 vezes mais rápido do que o SVM clássico.

Em Riopelle et al. [2018] foi proposta uma abordagem para classificação de terrenos baseada na ecolocalização realizada por morcegos. Para isso, os autores propuseram um sensor composto por um emissor e um receptor de ondas sonoras. O sinal é representado no domínio da frequência e sua dimensionalidade é reduzida após a aplicação da técnica Principal Component Analysis (PCA). A classificação de terrenos foi realizada por meio do modelo de classificação SVM, obtendo acurácia de 97.33%, considerando 3 diferentes tipos de terrenos.

### 2.1.2 Sensores proprioceptivos

Sensores proprioceptivos são responsáveis por realizar medições internas ao robô, tais como: *i) posição da roda; ii) nível da bateria; iii) ângulos das juntas do robô; iv) orientação do veículo; v) torque do motor; vi) acelerações lineares e velocidades angulares*, dentre outras informações. Alguns trabalhos realizam a classificação de terrenos considerando apenas dados inerciais providos por um acelerômetro [Souza et al., 2014; Otte et al., 2016; Bai et al., 2019]. Nos trabalhos que consideram sensores inerciais, como mecanismo de classificação de terrenos, os mesmos podem ter seus resultados impactados pela variação de velocidade em que o robô se desloca [Pereira et al., 2009; Wang et al., 2017]. Por isso, muitos trabalhos consideram velocidade constante em seus experimentos.

Em Otte et al. [2016], os autores investigam o uso de Redes Neurais Recorrentes para classificação de terrenos, com base em dados de vibração. Dentre as principais características da técnica estão a não utilização de uma janela deslizante (como nos demais trabalhos), e a não computação explícita de vetores de características. Durante a coleta de dados a velocidade do robô foi mantida constante em 0.45 m/s. Os autores obtiveram 85.0% de acurácia na classificação, na média.

No trabalho de Bai et al. [2019], é apresentada uma abordagem para classificação de terrenos em ambientes externos. Para isso, foi utilizado um veículo terrestre com um sensor de vibração acoplado. Foram coletados dados de vibração referentes a 5 diferentes terrenos: concreto, grama, areia, cascalho e pedras com grama. Os dados de vibração foram transformados do domínio do tempo para o domínio da frequência. Para a classificação de terrenos foi utilizado o modelo de Rede Neural com retroalimentação. A técnica proposta foi avaliada em ambientes reais, obtendo acurácia entre 89.9% e 100.0%, considerando terrenos com diferentes características de rugosidade.



Em Souza et al. [2014], é proposta a combinação entre um processo Gaussiano e um algoritmo de otimização Bayesiana para tomada de decisão. O objetivo principal é manter o equilíbrio entre a exploração e aproveitamento, com o objetivo de obter um modelo da rugosidade do terreno, conforme Figura 2.4. Nos experimentos, os autores consideraram velocidade constante.

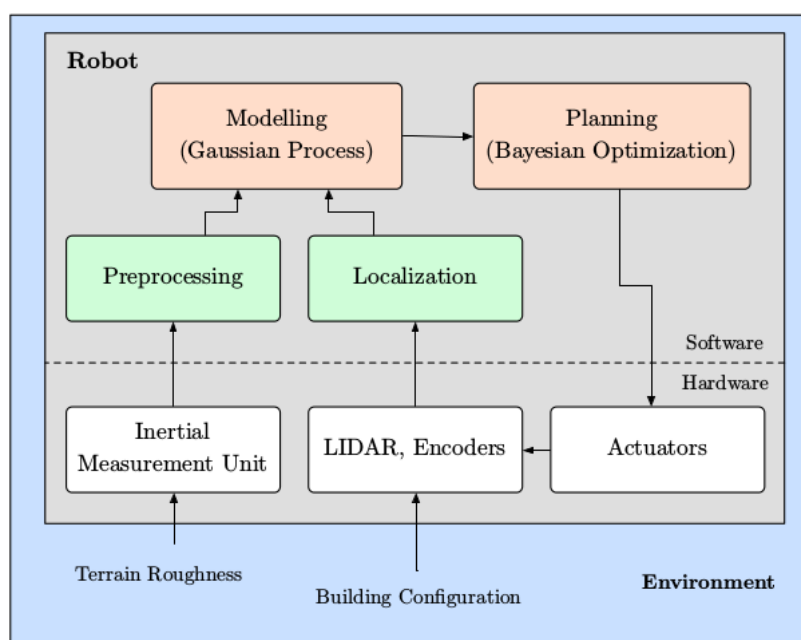


Figura 2.4: Diagrama de bloco do sistema proposto [Souza et al., 2014].

Enquanto no trabalho de Wang et al. [2017], é proposta uma abordagem para classificação de terrenos, aplicada em um carro utilitário. Para isso, é utilizado um acelerômetro montado na suspensão do veículo, no intuito de representar o terreno através das vibrações ocorridas durante o deslocamento do carro. As características investigadas para a classificação foram: *i)* o sinal no domínio do tempo; *ii)* o sinal no domínio da frequência; *iii)* e a representação do sinal em *wavelet*. Sendo avaliados os classificadores *Naive Bayes* e SVM. Nos experimentos, os autores variaram a velocidade do veículo, porém, o modelo de classificação de terreno não se adaptava às diferentes velocidades automaticamente. Foram treinados diferentes modelos de classificação para cada velocidade variada. Nos experimentos foram obtidos 69.35% de acurácia, na média.

## 2.2 Análise de dados inerciais considerando a velocidade

A classificação de terrenos permite determinar em qual tipo de terreno o veículo terrestre está se deslocando no momento. No entanto, para uma navegação segura e eficiente também é necessário analisar a velocidade do veículo e as características do terreno percorrido. Ao utilizar dados inerciais para mensurar o custo de navegação de uma região, é importante destacar que os referidos dados são sensíveis à variação de velocidade. De tal modo que, a magnitude dos sinais inerciais variam quando são capturados em diferentes velocidades, considerando o mesmo terreno [Stavens et al., 2007]. Considerando o exposto, a transformação de dados inerciais surge como alternativa viável para a análise de terrenos. Tal operação transforma dados em diferentes velocidades, tornando-os invariantes ao impacto da velocidade sobre os sinais inerciais [Lv et al., 2018], chamados neste trabalho de dados inerciais invariantes a velocidade.

Os trabalhos a seguir propuseram abordagens que visam a avaliação da velocidade para análise de terrenos externos. Em Thrun et al. [2006] foi apresentado o robô autônomo Stanley, que venceu o desafio DARPA no deserto. Os autores consideraram a análise do terreno para controle adaptativo de velocidade, como umas das tarefas essenciais para uma navegação segura e eficiente. Para isso, a abordagem considerava a rugosidade e a inclinação (*pitch*) como características na computação inteligente da velocidade máxima para cada tipo de terreno. O dado de rugosidade era obtido a partir da aceleração no eixo  $z$  e era então aplicado um filtro passa-banda, para remover os efeitos da gravidade e vibração do veículo. Para realizar o controle da velocidade, era verificado se a vibração excedia o limite máximo permitido, caso positivo a velocidade era reduzida linearmente.

No trabalho desenvolvido por Dubey et al. [2013], é proposta uma estratégia para reduzir o movimento abrupto de robôs terrestres em superfícies rugosas, visando uma navegação segura. Os autores consideram a aceleração no eixo vertical como evidencia de rugosidade do terreno, bem como entendem que existe uma forte relação entre a velocidade e a rugosidade. Nesse entendimento, propuseram uma função de custo para determinar o risco associado ao alto grau de vibração. Nos experimentos foram utilizados um *laser velodyne* e um Sistema de Posicionamento Global (*Global Positioning System*, ou GPS), montados em um Veículo Utilitário Esportivo (*Sport Utility Vehicle*, ou SUV). Para ajustar a velocidade do veículo se basearam na técnica de Diferença entre Normais, aplicada na nuvem de pontos capturada.

Em Castelnovi et al. [2005], é apresentado um sistema de controle de velocidade, que utiliza um *laser* para capturar a rugosidade da área imediatamente à frente do veículo. A classificação baseia-se na informação de profundidade coletada pelo sensor de distância, enquanto o controle de velocidade usa uma abordagem *hysteresis* para avaliar quatro níveis de rugosidade distintos, como pode ser observado na Figura 2.5.

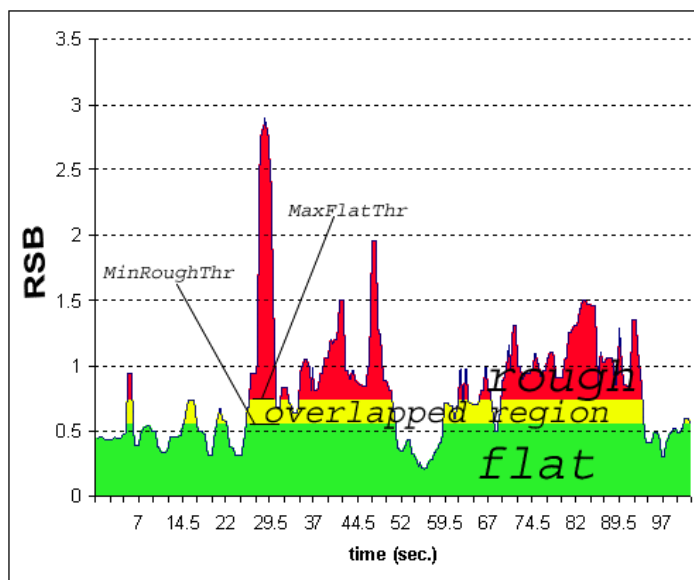


Figura 2.5: Definição e avaliação de limiares para diferenciação entre asfalto e grama [Castelnovi et al., 2005].

Em C. Ward & Iagnemma [2009] é proposta uma abordagem para a classificação de terrenos, por meio da utilização de um acelerômetro montado na suspensão de um veículo para passageiros. O algoritmo envia o sinal de aceleração capturado para o modelo dinâmico do veículo, para estimar o perfil do terreno, então extrai os componentes do domínio da frequência que correspondem ao perfil estimado. O método desenvolvido pelos autores identifica e remove impulsos no terreno. Impulsos correspondem a buracos ou elevações, conforme Figura 2.6. Por fim o algoritmo SVM é utilizado para classificar os segmentos de perfis, nas classes previamente definidas.

No trabalho de Lv et al. [2018] foi proposta uma abordagem para extração de características de vibração, independente da velocidade aplicada pelo veículo terrestre. Os autores propuseram a utilização de rodas rígidas com ressaltos para capturar as características de vibração durante a movimentação pelo terreno, conforme mostrado na Figura 2.7. Foram extraídas as características: *i*) frequências; *ii*) soma das amplitude harmônicas; *iii*) valor médio; e *iv*) quadrado do valor médio das acelerações verticais. As referidas características apresentaram comportamento similar, mesmo em diferentes velocidades, demonstrando invariância a velocidade.

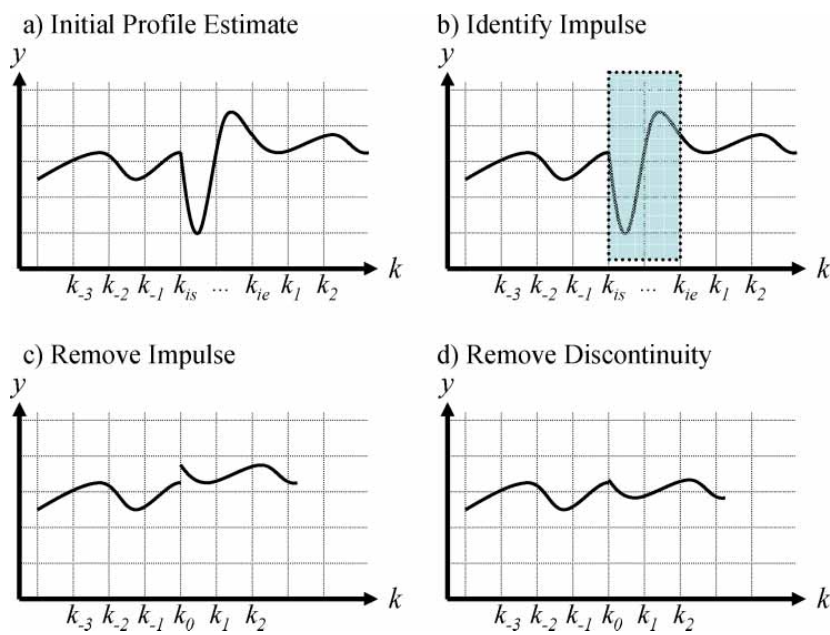


Figura 2.6: Processo de remoção de impulso [C. Ward & Iagnemma, 2009].




Figura 2.7: Roda rígida com ressaltos utilizada para extração de características [Lv et al., 2018].

A maioria dos trabalhos encontrados na literatura realiza o controle da velocidade do veículo de acordo com o nível de rugosidade no terreno. Porém, neste trabalho é realizada a transformação do dado inercial, tornando-o invariante a velocidade. Para isso, foi aplicado um modelo de regressão polinomial quadrático nos dados de aceleração vertical, no eixo Z e velocidade angular, no eixo Y. Dessa forma, é possível classificar o nível de rugosidade sem o impacto da mudança de velocidade nos dados inerciais.

## 2.3 Estimação de custo de navegação

Para realizar a avaliação de terrenos externos, muitos trabalhos encontrados na literatura utilizaram um único tipo de dados, como exposto nas subseções anteriores, [Castelnovi et al., 2005; Lv et al., 2018; Riopelle et al., 2018; Otte et al., 2016; Bai

et al., 2019]. No entanto, a combinação de diferentes tipos de dados, em uma única representação de custo do terreno, pode ser uma estratégia eficiente. Pois, dados complementares podem suprir algumas vulnerabilidades encontradas quando se considera apenas uma característica do terreno.

Em Dubey et al. [2013], os autores propuseram uma abordagem para redução de impactos durante a navegação autônoma em terrenos irregulares. Para isso, foram extraídos dados do ambiente através de uma *laser*. No intuito de combinar diferentes características coletadas, foi desenvolvida uma função de custo envolvendo 6 parâmetros. Os parâmetros consideram: *i*) a diferença entre a orientação corrente do veículo e a orientação da posição alvo; *ii*) o custo resultante das células de ocupação da trajetória de interesse; *iii*) a distância entre a posição final da trajetória e a posição alvo; *iv*) a medida do desvio da trajetória em relação ao caminho global; *v*) o custo associado a velocidade do veículo; e *vi*) o valor que define quão resistente é o veículo com relação às regiões com alto grau de rugosidade. Na função proposta cada parâmetro é ponderado e todos os termos são somados.

No trabalho desenvolvido por Guo et al. [2011], foi proposta uma abordagem para criar uma representação visando a análise de traversabilidade em terrenos externos. Para isso, foram utilizados uma câmera e uma IMU. O vetor de características obtido a partir da imagem é formado pelos termos: *i*) a média dos valores contidos na banda vermelha da imagem (R); *ii*) a média dos valores contidos na banda verde da imagem (G); *iii*) a média dos valores contidos na banda azul da imagem (B); *iv*) a média dos valores contidos na imagem em escala de cinza; *v*) o desvio padrão dos valores contidos na imagem em escala de cinza; *vi*) o grau de suavização dos valores contidos na imagem em escala de cinza; *vii*) o terceiro momento computado a partir do histograma da imagem em escala de cinza; *viii*) a uniformidade da imagem em escala de cinza; e *ix*) a entropia da imagem em escala de cinza. A função de custo para representar a traversabilidade é computada a partir dos ângulos: *i*) *roll*; e *ii*) *pitch*. Sendo a equação baseada no referido dado de vibração da região corrente, em relação a uma região plana, de mesmo tamanho.

Em Helmick et al. [2009], foi desenvolvida uma estratégia para navegação em ambientes externos, considerando câmeras *stereo* para analisar o terreno ao redor do veículo, bem como classificar tipos de terrenos. A partir das câmeras *stereo* são computados dados referentes à geometria do ambiente. Para representar a traversabilidade do terreno foi proposta uma função de custo para determinar se é possível navegar por determinada região. A função de custo é computada por meio da soma ponderada entre: *i*) diferença entre a maior e menor altura, referente à região atual; *ii*) rugosidade da região atual; e *iii*) inclinação da região atual. O mapa de traversabilidade

computado por meio da abordagem descrita é apresentado na Figura 2.8.

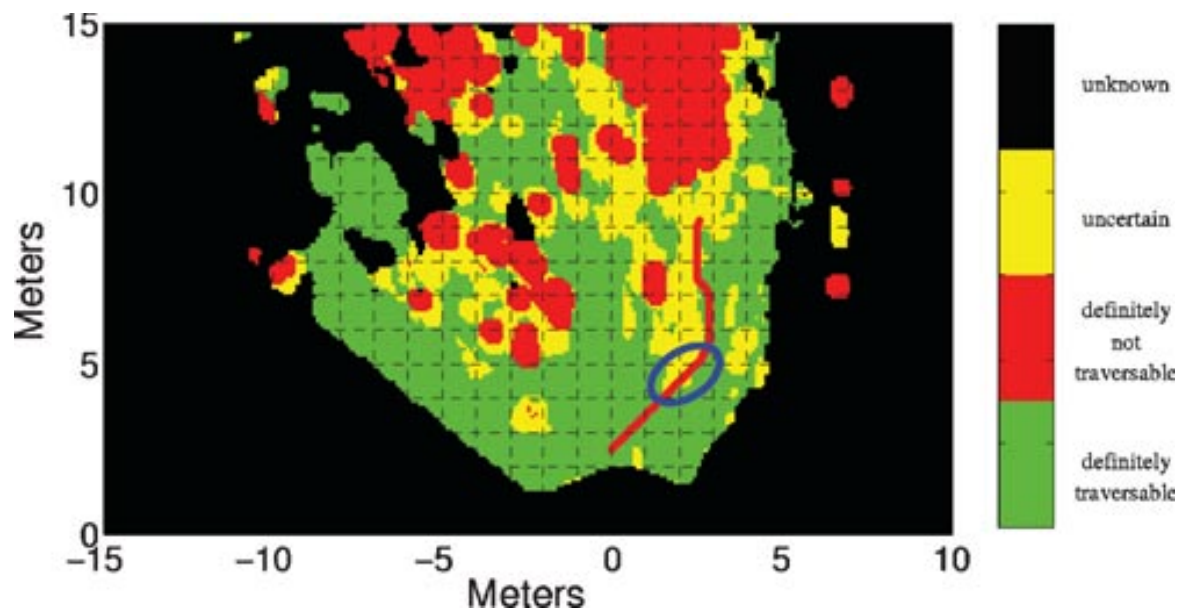


Figura 2.8: Mapa de traversabilidade construído em [Helmick et al., 2009], por meio da função de custo proposta. Para o cálculo da função de custo foram considerados dados geométricos computados a partir de câmeras *stereo*.

No trabalho de Krüsi et al. [2017], é apresentada uma abordagem para realizar a navegação em ambientes externos considerando apenas a informação geométrica ao redor do veículo (local). Um *laser* foi utilizado para representar as características do terreno, sendo utilizada uma função de custo para determinar qual a melhor trajetória a ser seguida. A melhor trajetória é aquela que apresenta a menor função de custo. A função de custo é computada pela soma dos custos entre cada par de pontos que compõe uma possível trajetória. O custo entre cada par de pontos é computado considerando a distância euclidiana entre os mesmos, levando em conta a curvatura formada pelo segmento corrente.

## 2.4 Fusão entre múltiplos sensores

A utilização de uma única fonte de dados para representar ambientes externos pode ser uma alternativa satisfatória para um conjunto limitado de terrenos. No entanto, para aplicações reais envolvendo navegação autônoma é necessário representar uma grande variedade de terrenos e características encontradas nesses ambientes. Nesse contexto, a aplicação de múltiplos sensores surge como uma opção eficiente na descrição de superfícies externas [Otsu et al., 2016].

O uso de dados providos por múltiplos sensores pode permitir a representação de um conjunto de características que não podem ser descritas por um único tipo de dados. Dessa forma, a combinação entre múltiplos sensores caracteriza uma estratégia elegante para representar de maneira confiável os principais atributos de terrenos em ambientes externos [Sock et al., 2016].

Diversos trabalhos têm investigado a fusão entre múltiplos sensores para avaliação de ambientes externos. Em Häselich et al. [2013], foram utilizados um *laser* e três câmeras. A combinação entre os referidos sensores ocorreu por meio de matrizes de transformação e os parâmetros intrínsecos correspondentes. Dessa forma, foi criada uma tabela de associação entre cada ponto coletado pelo *laser* e o respectivo pixel nas imagens. A representação resultante apresenta os pontos tridimensionais do *laser* associados às respectivas cores dos *pixels* das imagens, conforme Figura 2.9. A partir da representação combinada, supracitada, é aplicado o modelo *Markov Random Field* para classificar o terreno de acordo com os rótulos pré-definidos.




Figura 2.9: Ambiente externo representado por meio da combinação entre *laser* e câmeras. A geometria do ambiente e as características visuais da cena foram registradas em um mesmo sistema de coordenadas [Häselich et al., 2013].

No trabalho desenvolvido por Otsu et al. [2016], foram utilizados um par de câmeras *stereo* e uma IMU. Nesse trabalho, foram analisadas características de cor, no espaço de cor  $L^*a^*b$ , e dados de vibração, no domínio da frequência. A combinação entre os dados providos pelos diferentes sensores ocorreu durante o processo de treinamento proposto. Inicialmente, para cada tipo de dados foi treinado um modelo de classificação SVM, individual. A partir dos resultados estimados, inicialmente, pelo modelo de classificação visual, o modelo de classificação baseado em vibração foi treinado novamente. Assim como, a partir dos resultados estimados, inicialmente,

pelo modelo de classificação baseado em vibração, o modelo de classificação visual foi treinado novamente. Esse processo de treinamento é conhecido como co-treinamento. Dessa forma, os dados visuais foram utilizados para auxiliar a aprendizagem baseada em vibração, bem como os dados de vibração auxiliaram no processo de aprendizagem visual.

Em Brooks & Iagnemma [2007], foram considerados uma câmera e uma IMU. Os autores tentaram concatenar características de cor, textura e geométrica, mas os resultados obtidos foram considerados insatisfatórios. Posteriormente, trataram cada característica como condicionalmente independentes e propuseram um processo de classificação para cada característica. Os referidos processos de classificação foram implementados por meio de diferentes modelos de classificação SVM, usando *kernels* lineares e polinomiais de baixa ordem. Os resultados das classificações foram modelados como probabilidades e combinados por meio da técnica Naive Bayes, para a classificação final dos terrenos. Na Figura 2.10, é apresentado o veículo utilizado para a coleta de dados, assim como a disposição dos sensores utilizados.



Figura 2.10: Veículo utilizado durante os experimentos e disposição dos sensores acoplados [Brooks & Iagnemma, 2007].

No trabalho de Guerrero et al. [2015], foram utilizados um *laser* e um radar. Ambos os sensores proporcionam medidas geométricas do ambiente sensorado. Os autores construíram um mapa de traversabilidade para cada tipo de dados. A combinação entre os sensores ocorre por meio da combinação entre os diferentes mapas de traversabilidade. Para isso, os mapas de traversabilidade iniciais foram projetados em um mesmo sistema de coordenadas. Dessa forma, o mapa resultante consegue representar a ocupação das posições, bem como a elevação do terreno.



Em Guo et al. [2011], foram utilizados uma câmera e uma IMU. Foram consideradas características de cor, textura e orientações (*roll* e *pitch*). As medidas de *roll* e *pitch* foram combinadas por meio da função de custo proposta, para representar o grau de traversabilidade do terreno. A partir dos vetores de características extraídos das imagens e dos graus de traversabilidade computados a partir dos dados de vibração, foi treinado um modelo de regressão baseado em SVM. Dessa forma, a combinação entre os sensores ocorreu por meio do processo de aprendizagem envolvendo os dois tipos de dados. Pois, dada uma imagem como entrada, são extraídas as características visuais e passadas para o modelo de regressão treinado. Conseqüentemente, o modelo de regressão apresenta o grau de traversabilidade da região em análise.

No trabalho desenvolvido por Lu et al. [2011], foram utilizados um *laser* bidimensional e uma câmera infra-vermelho. Foram considerados a geometria do ambiente e a textura da imagem, como características do modelo. Os dados provenientes dos sensores mencionados foram registrados em um mesmo sistema de coordenadas. A geometria provida pelo *laser* foi modelada no domínio da frequência, usando Transformada de Fourier (*Fast Fourier Transform*, ou FFT). A textura provida pela câmera foi modelada pela técnica Matriz de Co-ocorrência em Escala de Cinza (*Gray-Level Co-occurrence Matrix*, ou GLCM). A combinação entre os sensores ocorreu por meio da definição de um vetor de características contendo características geométricas e de textura, para a posterior aplicação do modelo de classificação Rede Neural Probabilística.

Em Sock et al. [2016], foram utilizados um *laser* e uma câmera. Foram considerados a cor da imagem e a inclinação computada a partir da geometria do ambiente, como características do modelo de classificação. Os autores consideraram que os sensores eram independentes e propuseram um mapa de traversabilidade, a partir dos dados capturados por cada sensor. Os resultados obtidos em cada processo de mapeamento foram modelados como probabilidades. A combinação entre os sensores ocorreu por meio da aplicação de regras Bayesianas, aprimorando a representação de traversabilidade do ambiente externo. Considerando que o procedimento supracitado foi realizado enquanto o veículo se deslocava, o mapa de traversabilidade resultante foi modelado como cadeia de Markov.

No trabalho de Iwaszczuk et al. [2019] foi proposta uma estratégia para mapeamento de ambientes externos e internos a partir da combinação entre dados providos por *laser*, câmera e sensor RGBD. A combinação entre dados geométricos e semânticos é utilizada para aprimorar o processo de mapeamento, além de favorecer o mapeamento de transições entre ambientes externos e internos. Os autores utilizaram Redes Neurais Convolucionais (*Convolutional Neural Networks*, ou CNN) para definir os rótulos semânticos dos dados capturados. A combinação dos dados providos pelos diferentes

sensores ocorreu por meio do alinhamento dos sistemas de coordenadas.

Enquanto em Sebastian et al. [2019], foram utilizadas uma câmera RGBD e uma IMU. Foram consideradas as orientações *roll* e *pitch* e imagem de profundidade, para a construção de mapas de traversabilidade em ambientes internos e externos. A combinação das diferentes informações foi realizada por meio de CNN, onde imagens de profundidade são fornecidas como entrada para a rede enquanto as orientações são agregadas nas camadas densas da CNN. O resultado esperado para o modelo proposto é a estimativa de nível de traversabilidade do terreno.

## 2.5 Mapeamento de ambientes externos

A classificação de terrenos e a análise de dados inerciais invariantes a velocidade permitem uma navegação mais segura por terrenos irregulares. No entanto, a informação de rugosidade ou custo de navegação representado nas técnicas supracitadas correspondem a um contexto local, ou seja, não permitem determinar quais os demais custos de navegação no restante do ambiente a ser navegado.

Para ampliar o conhecimento sobre a composição do terreno, é preciso fazer uso de técnicas que tratem da construção de mapas da região desejada, popularmente conhecidas como técnicas de mapeamento. O mapeamento de ambientes pode ser realizado de diversas formas, considerando diversos aspectos. No contexto deste trabalho destacam-se os mapas de traversabilidade. Mapas de traversabilidade, correspondem à uma representação do ambiente capaz de identificar regiões por onde um veículo pode trafegar ou não [Tanaka et al., 2015].

Abordagens que tratam o problema de construção de mapas de traversabilidade são comumente divididos em três categorias: *i*) baseadas em propriedades geométricas; *ii*) baseadas em aparência, por meio de imagens ou; *iii*) híbridas, baseadas em propriedades geométricas e baseadas em aparência. A estratégia mais confiável para analisar a traversabilidade entre diferentes tipos de terrenos consiste em avaliar diferentes tipos de propriedades (híbridas) e com isso identificar cada superfície [Papadakis, 2013].

No trabalho de Suger et al. [2015], é proposta a análise de traversabilidade para ambientes externos por meio de veículos terrestres. Para isso, foi utilizada uma técnica de aprendizado semi-supervisionado baseada em dados providos por um *laser* Tridimensional (*Three-dimensional*, ou 3D). A partir dos dados coletados foram consideradas a rugosidade, inclinação e a diferença máxima entre as alturas dos pontos. Para a classificação foi utilizado algoritmo *Naive Bayes* Positivo.

Em Tanaka et al. [2015], foi desenvolvida uma análise de traversabilidade baseada

em lógica *Fuzzy*, para veículos terrestres em ambientes externos rugosos. Os autores utilizaram um *laser* para extrair a informação de rugosidade e inclinação do terreno, e utilizaram o desvio padrão como técnica de sumarização dos dados de rugosidade. A partir desses dados, é realizada uma inferência *Fuzzy*, sendo retornada uma representação da traversabilidade daquela posição, modelada como *Vector Field Histogram*. Na Figura 2.11 pode ser observado o funcionamento da técnica proposta.




Figura 2.11: Construção do mapa de traversabilidade e planejamento de caminho [Tanaka et al., 2015].

Larson et al. [2011] desenvolveram um método para analisar terrenos por meio do uso de nuvem de pontos, provida por um *laser* 3D. Com isso, é possível identificar regiões perigosas, tanto com obstáculos positivos quanto obstáculos negativos, e planejar caminhos para contornar tais regiões. Para determinar o nível de cada célula do mapa de traversabilidade são considerados obstáculos positivos, bordas do obstáculo, inclinação da vizinhança e rugosidade. Dessa forma, a técnica proposta realiza em tempo real a detecção de obstáculos presentes no ambiente, a criação do mapa de traversabilidade e propõe uma navegação segura, evitando regiões perigosas.

O trabalho de Guerrero et al. [2015], apresenta um sistema bi-modal de percepção, com dois sensores: *i)* um *laser*; e *ii)* um radar. Foram combinados um sensor óptico e um sensor eletromagnético para construir um mapa do ambiente, o qual pode ser usado para análise de traversabilidade e planejamento de caminho. A construção do supracitado mapa do ambiente foi baseada na combinação dos mapas de traversabilidade, por meio da projeção dos mesmos em um único sistema de referência. Com isso, a representação do terreno passou a ter dois níveis, propiciando mapas de traversabilidade mais precisos.

Trabalhos que abordam a análise de traversabilidade considerando a aparência tendem a modelar a solução do problema por meio do processamento de imagens juntamente com técnicas de classificação. Em Guo et al. [2011] é apresentado um método que constrói uma relação entre caminho ótimo e análise de traversabilidade em terre-

nos. Para isso, os autores utilizam as características de cor e textura da imagem, que são propriedades com alta capacidade de discriminância, para formar um conjunto de características de cada tipo de terreno. Bem como, utilizam dados de vibração para determinar a dificuldade de navegação em cada tipo de terreno. Adicionalmente, é usado o algoritmo SVM para realizar a predição a partir das características extraídas. A Figura 2.12 ilustra o funcionamento da técnica.



Figura 2.12: Análise de traversabilidade com planejamento de caminho ótimo [Guo et al., 2011].

Cunningham et al. [2015] propuseram um método para determinar as diferenças relativas de traversabilidade em superfícies rugosas, por meio de imagens termais obtidas a partir de uma câmera infravermelho. A partir da câmera infravermelho, são capturadas imagens do terreno, representando sua temperatura por um intervalo de tempo. Dessa forma, é possível verificar se a inércia termal estimada de um terreno é maior do que a de outro terreno, caracterizando a diferença abrupta ou não-traversabilidade entre os terrenos.

No trabalho proposto por Kim et al. [2007], foi desenvolvido um algoritmo eficiente para estimação de traversabilidade baseado na técnica *superpixel*. Para a estimação de profundidade os autores utilizam características de cor, por meio de histogramas no modelo de cor Matiz, Saturação, Valor (*Hue, Saturation, Value*, ou HSV) e médias de intensidades no modelo de cor Vermelho, Verde, Azul (*Red, Green, Blue*, ou RGB). Além disso, também são consideradas propriedades de textura na imagem. Para classificação, foi utilizada uma variação da técnica de classificação K-Vizinhos Mais Próximos (*K-Nearest Neighbors*, ou KNN). Para validar os resultados, foi realizada a comparação entre a abordagem proposta (*superpixel*) e uma abordagem clássica com segmentação da imagem em quadrantes de tamanho fixo, onde os autores obtiveram resultados significativos para maiores distâncias, conforme pode ser verificado na Figura 2.13.




Figura 2.13: Exemplos de classificação de traversabilidade usando *superpixel* e quadrantes de tamanho fixo [Kim et al., 2007].

Filitchkin & Byl [2012] propõem uma abordagem que funciona com uma câmera monocular, mantendo uma alta taxa de classificação mesmo com variação na iluminação. Para a classificação de terrenos é utilizada uma forma de representação, Saco de Palavras Visuais (*Bag of Visual Words*, ou BOVW), a partir do descritor de imagens local Características Robustas Aceleradas (*Speed Up Robust Features*, ou SURF), com o algoritmo de classificação SVM. Um método baseado na técnica de gradiente descendente é empregado para ajustar o limiar Hessiano do descritor SURF, juntamente com uma janela deslizante usada para identificar a troca de terreno.

Em Mongus & Jurič [2019] foi proposta uma abordagem para gerar mapas de traversabilidade a partir de nuvens de pontos capturadas por um *laser*. As nuvens de pontos são utilizadas para representar o nível de rugosidade e a inclinação do terreno. Para determinar se é possível trafegar por uma região, limiares foram definidos verificando se os níveis de rugosidade e inclinação da região são aceitáveis. Dentre os resultados obtidos destaca-se a média *f1-score* superior a 90%.

No trabalho de Lu et al. [2011], é apresentada uma estratégia para identificar tipos terrenos externos por meio de um *laser* e uma câmera infravermelho, ambos direcionados para a região imediatamente a frente do robô. A câmera infravermelho permite a captura de imagens durante a noite, ao contrário de abordagens clássicas baseadas em aparência que dependem de condições de luminosidade. As características consideradas na presente estratégia são: *i*) a distância provida pelo *laser*; e *ii*) a textura provida pela câmera. Foram utilizadas Redes Neurais para realizar a classificação dos diferentes tipos de terrenos.

Alguns trabalhos optaram por combinar diferentes tipos de sensores, visando tratar o problema com informações complementares e com isso aprimorar seus resultados. Como em Sock et al. [2016], onde os autores apresentam uma abordagem probabilística para criar mapas de traversabilidade por meio de um robô terrestre equipado com dispositivos *laser* 3D e câmeras RGB, conforme Figura 2.14. As regiões que compõem o

mapa são classificadas em navegáveis (sem obstáculos que impessam o deslocamento) ou não navegáveis (com obstáculos impedindo o deslocamento), após a fusão Bayesiana dos dados obtidos pelos diferentes sensores. Embora este método pareça mais robusto a falhas dos sensores, a classificação proposta não é suficiente para obter uma estratégia de tomada de decisão eficiente para o planejamento de caminhos.

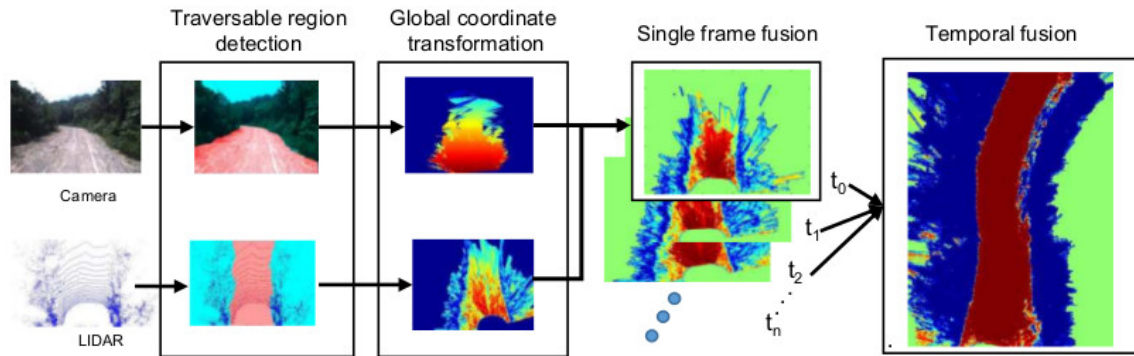


Figura 2.14: Esquemático da abordagem proposta em [Sock et al., 2016]. Para os mapas coloridos, as regiões navegáveis são representadas pela cor vermelha e as regiões não-navegáveis são representadas pela cor azul.

Alguns trabalhos buscaram realizar o mapeamento do ambiente externo levando em consideração as características do terreno. Foram avaliadas características associadas às superfícies do terreno, que colocavam em risco a viabilidade da tarefa a ser executada. Para isso, alguns trabalhos utilizaram sensores proprioceptivos, mensurando propriedades do terreno ao navegar por ele [Nardi & Stachniss, 2019].

No trabalho desenvolvido por Nardi & Stachniss [2019], foi utilizada uma IMU. Os autores propuseram uma estratégia para mapear o terreno considerando as propriedade de vibração coletadas. Para isso, foi capturado um conjunto de medições e suas respectivas posições, para realizar um agrupamento das medições de acordo com sua características. Dessa forma, para mapear o ambiente foi necessário proceder uma vasta coleta de dados, sendo executadas 25 repetições no terreno para obter o mapa resultante. Para fazer a predição das posições não visitadas do terreno foi proposto o modelo de Mistura Gaussiana.

Em Milella et al. [2018] foi proposta uma abordagem para mapeamento de ambientes externos não estruturados a partir de sensores visuais, termiais, hiperspectrais e inerciais. Os dados sensoriais foram integrados resultando em um mapa tridimensional do terreno. Além do mapeamento do terreno, os autores destacaram a detecção de mudança de superfície como resultado satisfatório do trabalho. A integração entre a nuvem de pontos e o nível de vibração do terreno ocorreu durante o deslocamento do

veículo, sendo definido um nível de vibração para todos os pontos correspondendo à região percorrida pelo veículo.

## 2.6 Contextualização do trabalho

Conforme apresentado nas seções anteriores, abordar separadamente cada uma das tarefas mencionadas (classificação dos níveis de rugosidade de terrenos, análise de dados inerciais invariantes a velocidade, estimação de custo de navegação, fusão entre múltiplos sensores e mapeamento de ambientes externos) já representa um grande desafio. Neste trabalho, além de serem apresentadas contribuições em algumas dessas etapas, será a primeira vez que todas elas são consideradas em conjunto como um único problema, o que aumenta sua dificuldade.

Os trabalhos relacionados mais próximos são [Guo et al., 2011], [Milella et al., 2018] e [Sebastian et al., 2019], onde são combinadas percepção proprioceptiva e exteroceptiva, assim como no presente trabalho. Em [Guo et al., 2011] foram utilizados câmera e IMU, em [Milella et al., 2018] foram utilizados câmera, câmera termal e IMU, em [Sebastian et al., 2019] foram utilizados câmera RGBD e IMU, enquanto no presente trabalho são utilizados *laser* 3D e IMU.

Considerando os três trabalhos mencionados, apenas [Guo et al., 2011] tratou a análise de superfícies em ambientes externos por meio da classificação de terrenos, de maneira similar ao presente trabalho. Quanto a combinação das características por meio de uma função de custo, [Guo et al., 2011] e [Milella et al., 2018] utilizaram representações semelhantes a esta tese, criando uma representação de alto nível do custo de navegação do ambiente. [Sebastian et al., 2019] e [Milella et al., 2018] combinaram informações geométricas e inerciais, assim como no presente trabalho. Para isso, [Sebastian et al., 2019] utilizou CNN para estimar os níveis de traversabilidade, enquanto [Milella et al., 2018] definiu limiares para determinar regiões navegáveis.

No trabalho de [Guo et al., 2011] a representação do terreno por meio de informação visual (textura), não permite a estimativa de irregularidade para diferentes tipos de terrenos, além de apresentar campo de visão limitado. Em [Milella et al., 2018] apenas um único tipo de dado inercial é considerado para determinar o custo de navegação da região percorrida. Além disso, o referido custo de navegação é atribuído à toda a região correspondendo ao tamanho do veículo, o que não é razoável tendo em vista que dentro dessa região há diferentes custos de navegação. No trabalho de [Sebastian et al., 2019] a representação do terreno é feita por imagem de profundidade, no entanto câmeras RGBD apresentam maior sensibilidade a raios ultravioleta, limitando

suas atividades em ambientes externos.

Dentre as contribuições da presente pesquisa, destacam-se as abordagens propostas para a classificação dos níveis de rugosidade de terrenos e o controle de velocidade adaptativo. Neste trabalho estão sendo utilizados dados inerciais providos por um acelerômetro, sumarizados por meio da técnica Erro Quadrático Médio (*Root Mean Square*, ou RMS) e classificados pelo algoritmo SVM com *kernel* Função de Base Radial (*Radial basis function*, ou RBF). No trabalho também foi proposto um modelo de transformação que permite a normalização de sinais de aceleração com invariância à alterações de velocidade [Oliveira et al., 2017].

Também foi proposta uma nova função de custo para estimar o custo de navegação em terrenos externos. Dados inerciais de tipos diferentes foram combinados no intuito de representar as irregularidades e inclinações presentes em diferentes superfícies. Adicionalmente, foi proposta uma estratégia de mapeamento de terrenos baseada em *vector fields* para apresentar o melhor fluxo de navegação pelo ambiente [Oliveira et al., 2019].

Por fim, foi proposta uma estratégia para combinar múltiplos sensores visando representar ambientes externos, desconhecidos e não estruturados. Para isso, foram considerados um *laser* e uma IMU. A partir do *laser* foram coletadas nuvens de pontos do ambiente. A partir da IMU foram coletados dados inerciais, de onde foram computados custos de navegação. Por meio de um modelo de Rede Neural Convolutiva, foi aprendida a relação entre os pontos tridimensionais, correspondentes ao terreno por onde o veículo está se deslocando, e os respectivos custos de navegação. Dessa forma, é possível estimar os custos de navegação para posições não visitadas pelo veículo. A representação proposta pode auxiliar significativamente o processo de planejamento de caminhos em ambientes externos [Oliveira et al., 2021].

A Tabela 2.1 apresenta um resumo dos principais trabalhos encontrados na literatura relacionados ao problema, destacando quais tarefas específicas abordam, e ao final contextualizando o problema abordado neste trabalho.



Tabela 2.1: Principais trabalhos encontrados na literatura e as tarefas por eles abordadas, contextualizando o problema proposto neste trabalho.

	Classificação de terrenos	Análise de dados inerciais invariantes a velocidade	Estimação de custo de navegação	Fusão entre múltiplos sensores	Mapeamento de ambientes externos
[Wang et al., 2017]	•				
[Bai et al., 2019]	•				
[Lv et al., 2018]	•	•			
[Krüsi et al., 2017]			•		•
[Otsu et al., 2016]	•				
[Nardi et al., 2019]					•
[Mongus and Jurić, 2019]			•		•
[Sebastian et al., 2019]				•	•
[Marella et al., 2018]			•	•	•
[Guo et al., 2011]	•		•	•	•
<b>Este Trabalho</b>	•	•	•	•	•

# Capítulo 3

## Fundamentação Teórica

Neste capítulo é apresentado um conjunto de conceitos e técnicas que compõem a fundamentação teórica necessária para que as técnicas de Aprendizado de Máquina aplicadas nesta tese sejam compreendidas. Para isso, serão apresentados os principais tipos de aprendizado, detalhando a técnica de classificação *Random Forest* e as técnicas de regressão Polinomial e Redes Convolucionais.

Nas seções seguintes, são definidos os tipos de aprendizado com foco nas aplicações de classificação e regressão. Posteriormente, são detalhadas as técnicas de Aprendizado de Máquina supracitadas.

### 3.1 Aprendizado de Máquina

O Aprendizado de Máquina é uma ramificação da Inteligência Artificial, que busca fornecer conhecimento aos computadores através de dados e experiências acumuladas a partir de observações do mundo. O referido conhecimento adquirido permite que computadores sejam capazes de generalizar corretamente eventos ainda não conhecidos [Ertel, 2017].

O aprendizado de máquina é baseado no comportamento de aprendizagem humano, cujo objetivo principal consiste em aprender automaticamente a reconhecer padrões e tomar decisões. A partir do processo de aprendizagem é possível analisar grandes volumes de dados com rapidez e eficiência, além de encontrar informações ocultas nos dados processados. [Kubat, 2017].

Diferentes formas de aprendizagem podem ser aplicadas no contexto de aprendizado de máquina, tais como: *i*) aprendizado supervisionado; *ii*) aprendizado não-supervisionado; *iii*) aprendizado semi-supervisionado; e *iv*) aprendizado por reforço.

- O *aprendizado supervisionado* consiste na utilização de dados de entrada e dos

respectivos dados de saída (rótulos previamente conhecidos), onde o objetivo é encontrar um modelo matemático que aprenda a mapear corretamente as entradas para as saídas, a partir de exemplos fornecidos.

- No *aprendizado não-supervisionado* não são utilizados dados de saída (rótulos previamente conhecidos), dessa forma o objetivo principal consiste em encontrar estrutura nos dados de entrada fornecidos, associando-os aos grupos de acordo com os padrões verificados.
- O *aprendizado semi-supervisionado* baseia-se na utilização de dados de entrada e dos respectivos dados de saída (rótulos previamente conhecidos), porém um conjunto dos dados de saída não é fornecido no intuito de intensificar o processo de aprendizagem.
- No *aprendizado por reforço* a aprendizagem ocorre por meio de tentativas e erros, onde a técnica estimula a realização determinadas ações através de recompensas e punições.

Neste trabalho são consideradas as técnicas de aprendizado supervisionado, as quais ainda podem ser subdivididas em técnicas de classificação e regressão.

### 3.1.1 Classificação

As técnicas de classificação consistem em encontrar a borda que divide o conjunto de dados em diferentes classes. Em outras palavras, consiste em encontrar uma função que mapeie um conjunto de dados nas classes correspondentes, considerando diferentes parâmetros. Dessa forma, é possível prever variáveis de saída discretas ( $y$ ), a partir de dados de entrada ( $x$ ).

Diversas técnicas são utilizadas para classificação, tais como Redes Neurais Artificiais, Redes Convolucionais, SVM, *Ada Boosting*, *Random Forest*, dentre outras técnicas [Forsyth, 2019]. Na subseção seguinte será apresentada a técnica de classificação *Random Forest*, utilizada para a classificação dos níveis de rugosidade.

#### 3.1.1.1 Random Forest

*Random Forest* é um algoritmo de aprendizagem flexível e que apresenta resultados precisos, mesmo sem a realização de ajuste de parâmetros. O algoritmo *Random Forest* é amplamente utilizado para tratar problemas de classificação. Neste trabalho o referido algoritmo é utilizado para classificar níveis de rugosidade, a partir de dados inerciais

coletados por um veículo terrestre durante seu deslocamento por ambientes externos, conforme apresentado na seção 6.3.

*Random Forest* cria um conjunto de árvores de decisão, aleatoriamente, e as combina para aumentar a eficácia do processo de classificação. Esse processo de combinação de diferentes técnicas de classificação, visando obter maior precisão no processo de classificação, é comumente conhecido como *ensemble* [Breiman, 2001].

Dentre as técnicas *ensemble*, *Random Forest* utiliza em seu processo de treinamento o método *bagging*. No método *bagging*, o aprendizado de cada classificador ocorre individualmente, onde os resultados dos classificadores são combinados, como por meio da técnica de análise de votos [Forsyth, 2019].

No algoritmo *Random Forest*, a aleatoriedade que ocorre durante o processo de criação das árvores de decisão, que compõem a floresta, permite uma busca pela melhor característica em um subconjunto aleatório. Dessa forma, é assegurada a diversidade e menor sobreajuste do modelo. Adicionalmente, a técnica de classificação *Random Forest* seleciona as características que mais contribuem para o processo de aprendizado e descarta as que não contribuem. Com isso, é possível criar modelos mais discriminativos para o processo de classificação. Além disso, o processo de treinamento do modelo *Random Forest* é significativamente mais rápido do que outras técnicas de classificação, como no caso da técnica de classificação SVM [Ono et al., 2015].

### 3.1.2 Regressão

As técnicas de regressão consistem em encontrar um modelo matemático que melhor explica a distribuição dos dados e que prediz as variáveis de saída com maior precisão. Em outras palavras, consiste em encontrar a correlação entre variáveis dependentes e independentes. Dessa forma, é possível prever variáveis de saída contínuas ( $y$ ), a partir de dados de entrada ( $x$ ).

Diversas técnicas são utilizadas para regressão, tais como Regressão Linear, Regressão Polinomial, Regressão Logística, Redes Neurais Artificiais, Redes Convolucionais, SVM, *Random Forest*, dentre outras técnicas [Harrell, 2015]. Nas subseções seguintes serão apresentadas: *i*) a técnica de regressão polinomial, utilizada para a transformação dos dados inerciais e como função de custo dos dados inerciais; e *ii*) a técnica de regressão usando redes convolucionais, para a estimação do custo de navegação a partir de nuvens de pontos de regiões não visitadas pelo veículo terrestre.

### 3.1.2.1 Regressão Polinomial

A regressão polinomial é utilizada em casos em que as variáveis interagem de forma não-linear, onde a distribuição dos dados pode ser aproximada por meio de polinômios, representados pela equação abaixo:

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \dots + \beta_n x_i^n + \varepsilon_i, \quad (3.1)$$

onde  $y$  corresponde a variável dependente, ou seja corresponde aos valores de saída do modelo de regressão.  $x$  é a variável independente, correspondendo aos dados de entrada do modelo de regressão.  $\beta$  é o conjunto de parâmetros do modelo regressão e  $\varepsilon$  corresponde ao erro do modelo de regressão, onde  $\varepsilon = y - \bar{y}$ .  $n$  corresponde ao  $n$ -ésimo grau do polinômio.  $i$  corresponde ao  $i$ -ésimo dado de entrada e  $m$  corresponde à quantidade total de dados de entrada [Jain, 1991].

O modelo de regressão polinomial pode ser escrito como o sistema de equações lineares abaixo:

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_m \end{bmatrix} = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^n \\ 1 & x_2 & x_2^2 & \dots & x_2^n \\ 1 & x_3 & x_3^2 & \dots & x_3^n \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_m & x_m^2 & \dots & x_m^n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \varepsilon_m \end{bmatrix}, \quad (3.2)$$

E sua representação matricial é dada por:

$$Y = X\beta + \varepsilon, \quad (3.3)$$

Para determinar os parâmetros do modelo de regressão é utilizado o método de Mínimos Quadrados, cujo objetivo é encontrar o vetor  $\bar{\beta}$  que minimiza o erro, conforme a equação abaixo:

$$\bar{\beta} = (X'X)^{-1}X'Y. \quad (3.4)$$

Portanto, o modelo de regressão polinomial ajustado é dado por:

$$\bar{Y} = X\bar{\beta}, \quad (3.5)$$

### Regressão polinomial de grau dois

Neste trabalho a regressão polinomial de grau dois ou quadrática é utilizada para estimar o fator de transformação de dados inerciais, conforme apresentado na seção 6.2. O modelo de regressão polinomial de grau dois com múltiplas variáveis proposto é definido como:

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{1i}^2 + \beta_4 x_{2i}^2 + \beta_5 x_{1i} x_{2i} + \varepsilon_i. \quad (3.6)$$

O modelo de regressão quadrático proposto pode ser escrito como o sistema de equações lineares abaixo:

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_m \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{21} & x_{11}^2 & x_{21}^2 & x_{11}x_{21} \\ 1 & x_{12} & x_{22} & x_{12}^2 & x_{22}^2 & x_{12}x_{22} \\ 1 & x_{13} & x_{23} & x_{13}^2 & x_{23}^2 & x_{13}x_{23} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1m} & x_{2m} & x_{1m}^2 & x_{2m}^2 & x_{1m}x_{2m} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \varepsilon_m \end{bmatrix}, \quad (3.7)$$

onde  $y$  corresponde a variável dependente, ou seja corresponde aos valores de saída do modelo de regressão.  $x$  corresponde às múltiplas variáveis independente, correspondendo aos dados de entrada do modelo de regressão.  $\beta$  é o conjunto de parâmetros do modelo regressão e  $\varepsilon$  corresponde ao erro do modelo de regressão, onde  $\varepsilon = y - \bar{y}$ .  $m$  corresponde à quantidade total de dados de entrada [Jain, 1991].

Para determinar os parâmetros do modelo de regressão é utilizado o método de Mínimos Quadrados, apresentado na equação 3.4, resultando no modelo de regressão quadrático ajustado dado por:

$$\bar{y}_i = \bar{\beta}_0 + \bar{\beta}_1 x_{1i} + \bar{\beta}_2 x_{2i} + \bar{\beta}_3 x_{1i}^2 + \bar{\beta}_4 x_{2i}^2 + \bar{\beta}_5 x_{1i} x_{2i}. \quad (3.8)$$

### Regressão polinomial de grau três

Neste trabalho a regressão polinomial de grau três ou cúbica é utilizada para computar o custo de navegação a partir das medições inerciais, conforme apresentado na seção 6.4. O modelo de regressão polinomial de grau três com múltiplas variáveis proposto é definido como:

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{1i} x_{2i} + \beta_4 x_{1i}^2 + \beta_5 x_{2i}^2 + \beta_6 x_{1i}^2 x_{2i} + \beta_7 x_{1i} x_{2i}^2 + \beta_8 x_{1i}^3 + \beta_9 x_{2i}^3 + \varepsilon_i. \quad (3.9)$$

O modelo de regressão cúbico proposto pode ser escrito como o sistema de equações lineares abaixo:

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_m \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{21} & x_{11}x_{21} & x_{11}^2 & x_{21}^2 & x_{11}^2x_{21} & x_{11}x_{21}^2 & x_{11}^3 & x_{21}^3 \\ 1 & x_{12} & x_{22} & x_{12}x_{22} & x_{12}^2 & x_{22}^2 & x_{12}^2x_{22} & x_{12}x_{22}^2 & x_{12}^3 & x_{22}^3 \\ 1 & x_{13} & x_{23} & x_{13}x_{23} & x_{13}^2 & x_{23}^2 & x_{13}^2x_{23} & x_{13}x_{23}^2 & x_{13}^3 & x_{23}^3 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1m} & x_{2m} & x_{1m}x_{2m} & x_{1m}^2 & x_{2m}^2 & x_{1m}^2x_{2m} & x_{1m}x_{2m}^2 & x_{1m}^3 & x_{2m}^3 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \vdots \\ \beta_9 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \varepsilon_m \end{bmatrix}, \quad (3.10)$$

onde  $y$  corresponde a variável dependente, ou seja corresponde aos valores de saída do modelo de regressão.  $x$  corresponde às múltiplas variáveis independente, correspondendo aos dados de entrada do modelo de regressão.  $\beta$  é o conjunto de parâmetros do modelo regressão e  $\varepsilon$  corresponde ao erro do modelo de regressão, onde  $\varepsilon = y - \bar{y}$ .  $m$  corresponde à quantidade total de dados de entrada [Jain, 1991].

Para determinar os parâmetros do modelo de regressão é utilizado o método de Mínimos Quadrados, apresentado na equação 3.4, resultando no modelo de regressão quadrático ajustado dado por:

$$\bar{y}_i = \bar{\beta}_0 + \bar{\beta}_1 x_{1i} + \bar{\beta}_2 x_{2i} + \bar{\beta}_3 x_{1i}x_{2i} + \bar{\beta}_4 x_{1i}^2 + \bar{\beta}_5 x_{2i}^2 + \bar{\beta}_6 x_{1i}^2 x_{2i} + \bar{\beta}_7 x_{1i} x_{2i}^2 + \bar{\beta}_8 x_{1i}^3 + \bar{\beta}_9 x_{2i}^3. \quad (3.11)$$

### 3.1.2.2 Redes Convolucionais

O Aprendizado Profundo é um ramo do Aprendizado de Máquina que utiliza redes neurais artificiais, com múltiplas camadas ocultas, para aprender representações de alto nível a partir de um grande volume de dados de entrada. Dentre as diversas arquiteturas de Aprendizado Profundo, destacam-se as CNN. As CNN são comumente utilizadas a partir de dados bidimensionais, como imagens, e aplicam sucessivas operações de convolução nos dados, aprendendo os filtros e características relacionados ao problema tratado [Aggarwal, 2018].

CNN são aplicadas tanto em problemas de classificação, quanto em regressão, sendo um método de aprendizado supervisionado. Neste trabalho, a fusão entre os múltiplos sensores ocorrerá por meio de uma CNN, em um processo de regressão. Dessa forma, será estimado o custo de navegação, a partir das representações geométricas das posições não visitadas, conforme apresentado na seção 7.3.

As principais arquiteturas de CNN encontradas na literatura, VGG-Net [Si-

monyan & Zisserman, 2015], AlexNet [Krizhevsky et al., 2012] e ResNet [He et al., 2015], são compostas pelas etapas: *i*) Convolucionais; *ii*) Funções de ativação; *iii*) Normalização; *iv*) Redução de dimensionalidade (*Pooling*); *v*) Redução da importância de conexões (*Dropout*); *vi*) Camadas completamente conectadas (*Fully Connected*); *vii*) Camada de ativação linear [Skansi, 2018]. É importante destacar que, cada arquitetura utiliza um conjunto diferente de parâmetros, ordem das etapas e quantidade de camadas, visando aumentar a eficiência da representação das características. Mais detalhes sobre cada etapa mencionada são apresentados abaixo:

- Camadas convolucionais: Aplicam filtros, que são convoluídos por toda a imagem de entrada. Esse processo identifica características presentes no conjunto de imagens de treino. As camadas convolucionais iniciais, tendem a identificar características de baixo nível, enquanto as camadas convolucionais finais, tendem a identificar características de alto nível.
- Função de ativação: Adiciona a não linearidade à rede convolucional. A função ReLU define como zero qualquer valor de entrada negativo. A função ReLU é definida como  $y = \max(0, x)$ , onde  $y$  é a saída da função e  $x$  é a entrada da função;
- Normalização: Normaliza os valores, após a aplicação da função de ativação. A normalização em lote, acelera o processo de aprendizagem da rede convolucional proposta;
- Redução de dimensionalidade (*Pooling*): Reduz a dimensionalidade dos mapas de características providos pelas camadas convolucionais, condensando-os em mapas de características reduzidos. Dessa forma, aumenta-se a invariância a pequenas alterações, tais como: translação e rotação. A operação *MaxPooling*, retira o maior elemento de uma região da matriz, para um dado tamanho da região.
- Redução de importância de conexões (*Dropout*): Evita que determinadas partes da rede convolucional tenham muita responsabilidade e conseqüentemente, possam ficar mais sensíveis a pequenas alterações. Adicionalmente, é utilizado para aumentar o aprendizado e capacidade de generalização da rede.
- Camadas completamente conectadas (*Fully Connected*): Nessa etapa, é aplicada a transformação da matriz da imagem, alterando seu formato para um vetor. Uma camada completamente conectada é uma forma de aprender combinações não lineares de características de alto nível.
- Camada de ativação linear: Utilizada para predição de valores, em problemas de regressão, em CNN.



# Capítulo 4

## Metodologia

Neste capítulo é apresentada uma abordagem de mapeamento do custo de navegação em ambientes externos a partir da combinação entre múltiplos sensores usando aprendizado profundo. Tal mapeamento permitirá uma representação dos níveis de dificuldade associados ao terreno, encontrados durante o deslocamento de veículos terrestres por ambientes externos, favorecendo técnicas de navegação autônoma. Para isso, será realizada a combinação entre múltiplos sensores, *laser* e IMU, no intuito de aprimorar o processo de construção dos mapas supracitados.

Inicialmente, será apresentada a definição do problema abordado nesta pesquisa e em seguida é apresentada uma visão geral sobre a abordagem proposta. Nos próximos capítulos serão apresentados os problemas e as descrições detalhadas de cada etapa do procedimento metodológico adotado.

### 4.1 Definição do problema geral

Considere um robô terrestre com rodas, com largura  $\lambda$  e comprimento  $\gamma$ , operando em um ambiente externo e livre de obstáculos. O robô é equipado com uma IMU, um *laser* e um conjunto de sensores provendo a localização do robô. A IMU captura um conjunto de dados inerciais  $\vec{\mathcal{I}}^k = \{i_1, i_2, \dots, i_\delta\}$ , onde para cada medição  $i_j$ ,  $1 \leq j \leq \delta$ , são adquiridos dados com diferentes características,  $i_j = \{\alpha^z, \omega^y, \rho^y, \pi^x\}$ , que correspondem às acelerações lineares no eixo  $z$ , às velocidades angulares no eixo  $y$  e os ângulos *roll* e *pitch*, respectivamente. Os dados são coletados considerando uma janela de medição deslizante, de tamanho  $k$ . O laser coleta um conjunto de nuvens de pontos  $\mathcal{P} = \langle p_1, p_2, \dots, p_\sigma \rangle$ , onde cada nuvem de pontos  $p_q$ ,  $1 \leq q \leq \sigma$ , é composta por pontos que são definidos por suas respectivas coordenadas nos eixos  $x$ ,  $y$  e  $z$  do ambiente. As nuvens de pontos coletadas podem representar as regiões visitadas ( $\mathcal{P}^v$ ) ou não

visitadas ( $\mathcal{P}^u$ ). O conjunto de sensores de localização, por exemplo a combinação entre um GPS e uma IMU, fornece um conjunto de coordenadas  $\mathcal{G}^v = \langle g_1^v, g_2^v, \dots, g_\phi^v \rangle$ , correspondendo às coordenadas das posições  $(x, y)$  visitadas pelo robô.

Os dados inerciais, geométricos e de localização são capturados durante o deslocamento do robô por um caminho previamente definido, seguindo as coordenadas  $\mathcal{G}^v$ . Para cada coordenada  $g_f^v$ ,  $1 \leq f \leq \phi$ , é realizado um conjunto de medições capturadas pelo sensor inercial. Adicionalmente, para cada coordenada  $g_f^v$ , é realizado um conjunto de medições capturadas pelo laser. Os dados coletados pelos diferentes sensores, são associados à coordenada  $g_f^v$  de tal modo que correspondem à região centrada na referida coordenada. Na Figura 4.1 é possível observar as coordenadas visitadas pelo robô ( $g_f^v$ ), definidas como ponto preto, e as regiões centradas nas coordenadas ( $r_f^v$ ), como retângulos azuis.




Figura 4.1: Esquemático para ilustrar a representação das coordenadas visitadas ( $g_f^v$ ) e as respectivas regiões visitadas ( $r_f^v$ ).

A dimensão da região ( $r_f^v$ ), ilustrada na Figura 4.1, é definida pelo tamanho do robô ( $\lambda \times \gamma$ ) utilizado nos experimentos. Dessa forma, é definido o conjunto de regiões visitadas  $\mathcal{R}^v = \langle r_1^v, r_2^v, \dots, r_\phi^v \rangle$ , de modo que para cada  $r_f^v$ ,  $1 \leq f \leq \phi$ , são determinados os dados inerciais  $i_f$  e geométricos  $p_f^v$ , que correspondem à região percorrida pelo robô ( $r_f^v$ ).

Para o mapeamento do custo de navegação proposto, considere o conjunto de regiões não visitadas  $\mathcal{R}^u = \langle r_1^u, r_2^u, \dots, r_\vartheta^u \rangle$ , onde cada região não visitada  $r_e^u$ ,  $1 \leq e \leq \vartheta$ , é centrada na coordenada não visitada  $g_e^u$ . Dessa forma, o objetivo principal é estimar os custos de navegação ( $\mathcal{C}$ ), baseados em dados inerciais ( $\vec{\mathcal{I}}$ ), para regiões não visitadas ( $\mathcal{R}^u$ ), a partir das representações geométricas ( $\mathcal{P}^u$ ) das regiões não visitadas.

## 4.2 Visão geral da metodologia proposta

Nesta seção é apresentada uma visão geral da metodologia proposta para tratar o problema de mapeamento do custo de navegação em ambientes externos a partir da combinação entre dados inerciais e geométricos. Serão discutidas, com brevidade, todas as etapas no intuito de ilustrar o funcionamento geral da abordagem completa, enquanto nos capítulos seguintes cada etapa será detalhada individualmente.

A estratégia proposta é dividida em três etapas principais, as quais podem ser separadas nas operações: *i*) Registro dos dados inerciais e geométricos; *ii*) Transformação dos dados inerciais; *iii*) Classificação do nível de rugosidade; *iv*) Estimação do custo de navegação; *v*) Fusão entre múltiplos sensores; e *vi*) Mapeamento do custo de navegação, que podem ser contempladas na Figura 4.2. As três etapas principais que compõem a metodologia são:

1. Mapeamento tridimensional e localização;
2. Estimação do custo de navegação usando dados inerciais;
3. Incremento do mapa tridimensional com custo de navegação usando aprendizado profundo.

Inicialmente, é abordado o problema de registro dos dados providos pela IMU e pelo *laser*. Os referidos dados, inerciais e geométricos, são coletados durante o deslocamento do robô. Porém, os dados coletados em cada coordenada percorrida pelo veículo não estão registrados, pois os mesmos não correspondem à mesma região, apenas foram coletados na mesma região. Para tratar esse problema, os dados inerciais e geométricos são associados à sua região correspondente. No primeiro momento, a partir das coordenadas do robô, são extraídas as medições geométricas que correspondem à região percorrida. Por fim, tendo em vista que, as medições geométricas já estão disponíveis, é possível encontrar quais medições inerciais foram realizadas na respectiva coordenada e associá-las.

Os dados inerciais são severamente impactados pela mudança de velocidade do veículo, durante a realização das medições. Nesse sentido, os dados supracitados são transformados, tornando-se invariantes a velocidade, passando a ser representados como se tivessem sido capturados em velocidade constante. Para isso, um modelo de predição é definido para aprender a relação entre os sinais inerciais e a velocidade aplicada, durante a captura dos dados. Dessa forma, é possível normalizar os dados inerciais, em tempo real, de acordo com a velocidade aplicada pelo robô.

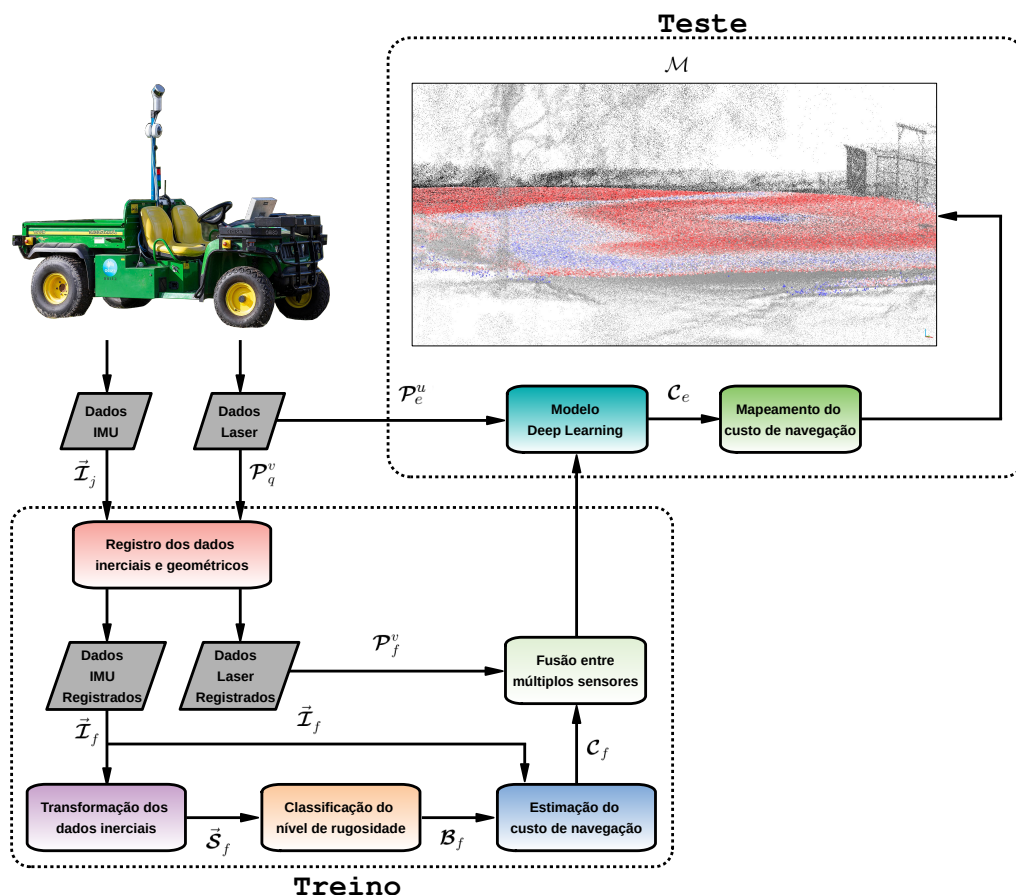


Figura 4.2: Esquemático da metodologia proposta. A metodologia consiste no mapeamento do custo de navegação em ambientes externos, a partir da combinação entre dados inerciais e geométricos, utilizando um veículo terrestre com rodas.

Em seguida, é abordado o problema de classificação dos níveis de rugosidade de terrenos. Nesse problema, um robô terrestre se desloca pelo terreno, coletando dados inerciais de aceleração e velocidade angular. A partir desses dados, é possível atribuir uma assinatura do terreno para cada posição. Dessa forma, é realizado o treinamento de um modelo de classificação, considerando os níveis de rugosidade como categorias de um classificador. Com isso, é possível obter, em tempo real, o nível de rugosidade do terreno para cada posição percorrida.

A representação de um terreno considerando apenas sua rugosidade não descreve todas as características da superfície. Nesse sentido, são combinados os níveis de rugosidade do terreno e a *attitude* do robô, representando a inclinação do terreno. Para isso, as características supracitadas são combinadas, provendo uma representação de alto nível do custo de se navegar por um terreno. A combinação entre os diferentes tipos de dados é realizada por meio de um modelo de predição, que apresenta o custo de navegação de uma região.

A estimação do custo de navegação, baseada em dados inerciais, proporciona uma estimativa local do custo de navegação, representando apenas as posições percorridas pelo veículo terrestre. No entanto, para realizar uma navegação eficiente é necessário inferir o custo de navegação para as demais regiões ao redor do robô. Para tratar esse problema, é treinado um modelo preditivo, baseado em Aprendizado Profundo, que aprende a relação entre a estrutura geométrica das superfícies de regiões e seus custos de navegação, computados localmente. Dessa forma, é possível inferir o custo de navegação de uma região a partir de sua representação geométrica, ou seja, permitindo estimar o custo de navegação para regiões não visitadas.

Por fim, a representação de terrenos em ambientes externos ocorre por meio de um mapa tridimensional, composto por coordenadas contínuas. Para isso, são consideradas as nuvens de pontos coletadas durante o deslocamento do robô terrestre. Em cada coordenada visitada, é coletada uma nuvem de pontos inicial que corresponde a região ocupada pelo robô. A partir de cada ponto capturado anteriormente, é extraída uma região não visitada de onde será estimado o custo de navegação. Com isso, é possível computar o custo de navegação, mesmo sem navegar pela referida região.

## Capítulo 5

# Mapeamento tridimensional e localização

Neste capítulo são apresentadas duas técnicas, utilizadas neste trabalho, para fornecer os dados de entrada necessários. A primeira técnica trata da construção de mapas tridimensionais, enquanto a segunda técnica computa a localização do veículo terrestre durante seu deslocamento. Para a construção dos mapas de custo de navegação propostos são considerados, como informação *a priori*, o mapa tridimensional do ambiente e o conjunto de coordenadas por onde o veículo se deslocou durante a captura de dados. Com isso, é possível combinar a representação tridimensional do ambiente com a informação do terreno provida pela abordagem proposta.

A técnica utilizada para criar mapas tridimensionais é chamada C-SLAM e foi apresentada pela primeira vez em [Bosse & Zlot, 2009]. Uma versão mais recente usando o *laser* 3D Velodyne VLP-16, em vez do *laser* 2D Hokuyo, foi apresentada em [Pfrunder et al., 2017]. O C-SLAM cria mapas 3D precisos a partir de um conjunto de nuvens de pontos, adquiridas durante o deslocamento do robô. Uma IMU com 6 Graus de liberdade (*Degrees of Freedom*, ou DOF) é utilizada para alinhar as nuvens de pontos com a trajetória. As nuvens de pontos são capturadas por um sensor *laser* giratório 3D, montado na parte superior do veículo terrestre. Na Figura 5.1 são apresentados a IMU, o *laser* 3D e a estrutura giratória do *laser*.

Para alinhar as nuvens de pontos coletadas durante a varredura do *laser*, os autores propuseram um algoritmo de casamento de nuvens de pontos, chamado *sweep-matching*. O referido algoritmo é baseado no consolidado algoritmo de casamento de nuvens de pontos Iterative Closest Point (ICP) [Besl & McKay, 1992], que é aplicado a regiões com características destacadas. O funcionamento do algoritmo consiste em, inicialmente, discretizar a nuvem de pontos em uma grade 3D, cujos pontos contidos





Figura 5.1: Arcabouço utilizado para realizar a captura de dados inerciais e geométricos, providos por uma IMU e um *laser*, respectivamente. Adicionalmente, é utilizado um servo motor para que o *laser* possa realizar suas medições girando continuamente.

em cada *voxel* são avaliados para verificar quão cilíndricos ou planares eles são. Com isso, é possível determinar a estrutura de uma superfície local. Em seguida, o algoritmo ICP é usado para comparar duas rotações do *laser* com varreduras consecutivas, nas quais as correspondências de *voxel* são verificadas para garantir que a estrutura local seja consistente. As correspondências de *voxel* são obtidas por meio de uma pesquisa em uma representação de árvore (*kd-tree*), no espaço 6D dos *voxels*. Para realizar a pesquisa na (*kd-tree*) foi utilizada a técnica KNN. Finalmente, a trajetória entre as duas varreduras é estimada, dada uma estimativa anterior. Assim, para cada unidade de tempo, a trajetória é corrigida, minimizando os erros de alinhamento entre as correspondências encontradas na etapa de correspondência do algoritmo ICP.

Assumimos que a localização do robô será fornecida como dado de entrada para a abordagem de mapeamento de terreno externo proposta. A técnica que usamos para fornecer localização precisa é chamada C-LOC [Pfrunder et al., 2017]. O algoritmo C-LOC é uma extensão do C-SLAM, fornecendo localização 3D em tempo real a partir de um mapa base *a priori*. Para isso, o C-SLAM mantém algumas visualizações dos *voxels* adquiridos nas coordenadas recentemente percorridas. Então, para reduzir a complexidade computacional, uma janela contínua é usada apenas nas visualizações adquiridas recentemente, chamadas visualizações fixas. Os *voxels* extraídos de visualizações fixas são usados para minimizar os erros de correspondência e reduzir o desvio acumulado. Os dados de posição, de baixa frequência, providos pelo C-LOC foram combinados com

a odometria da roda, de alta frequência, para obter uma posição precisa e em tempo real. Na Figura 5.2 são apresentados exemplos de mapa tridimensional e de localização providos pelas técnicas previamente apresentadas.



(a) Mapa tridimensional do ambiente externo. (b) Localização durante o deslocamento do veículo.

Figura 5.2: Resultados do processo de mapeamento tridimensional e computação da localização do veículo terrestre. Na Figura 5.2a, é apresentado um exemplo de mapa tridimensional computado para ambiente externo utilizando a técnica C-SLAM. Na Figura 5.2b, é apresentado um exemplo de localização computada durante o deslocamento do veículo terrestre utilizando a técnica C-LOC.



# Capítulo 6

## Estimação do custo de navegação usando dados inerciais

Neste capítulo é apresentada uma abordagem de estimação do custo de navegação em ambientes externos a partir de dados inerciais. O custo de navegação estimado permite representar uma região do terreno, determinando qual o nível de dificuldade ao trafegar pela referida região. Para isso, inicialmente, os dados inerciais são transformados, minimizando os impactos da velocidade sobre os dados inerciais capturados. Em seguida, os níveis de rugosidade do terreno são identificados. Por fim, o custo de navegar pelo ambiente externo é estimado.

Nas seções seguintes, serão apresentados os problemas relacionados a cada operação da etapa principal de estimação do custo navegação usando dados inerciais. Posteriormente, são apresentadas, em detalhes, cada uma das operações supracitadas.

### 6.1 Definição dos problemas

O problema principal abordado por este trabalho é dividido em 3 etapas fundamentais, como mencionado no Capítulo 4. Na etapa de estimação do custo de navegação usando dados inerciais são tratados 3 subproblemas que são definidos a seguir:

**Problema 1 (Transformação dos dados inerciais):** Seja  $\vec{\mathcal{I}} = \{i_1, i_2, \dots, i_\delta\}$  um conjunto de dados inerciais (acelerações lineares e velocidades angulares) fornecidos por uma IMU, capturados em cada coordenada visitada ( $g_f^v$ ). Dessa forma, o objetivo para este subproblema consiste em encontrar uma função de transformação do dado inercial ( $\Xi(\cdot)$ ), que mapeie  $\vec{\mathcal{I}}_f$ , adquirida em diferentes velocidades ( $\mathcal{V}$ ), em medições inerciais invariantes a velocidade  $\vec{\mathcal{S}}_f$ .

**Problema 2 (Classificação do nível de rugosidade):** Considere os dados inerciais transformados, invariantes a velocidade,  $\vec{\mathcal{S}}$ . Considere o conjunto de níveis de rugosidade (rótulos) previamente conhecidos,  $\mathcal{L} = \langle l_1, l_2, l_3, \dots, l_q \rangle$ . Dessa forma, o objetivo para este subproblema é associar o dado inercial ( $\vec{\mathcal{S}}$ ), correspondendo a região percorrida ( $\mathcal{R}^v$ ), a um dos níveis de rugosidade previamente conhecidos ( $\mathcal{L}$ ), obtendo o conjunto de níveis de rugosidade estimados para cada região percorrida,  $\mathcal{B} = \langle b_1, b_2, \dots, b_{\varpi} \rangle$ .

**Problema 3 (Estimação do custo de navegação):** Considere os níveis de rugosidade  $\mathcal{B}$ , estimados para cada região percorrida ( $r_f^v$ ). Considere os dados inerciais  $\vec{\mathcal{I}}$ , registrados. Dentre os diferentes tipos de dados inerciais em  $\vec{\mathcal{I}}$ , considere os ângulos *roll* ( $\rho_f^y$ ) e *pitch* ( $\pi_f^x$ ). Dessa forma, o objetivo para este subproblema é estimar o custo de navegação ( $\mathcal{C}$ ) para regiões visitadas ( $\mathcal{R}^v$ ), a partir dos níveis de rugosidade ( $\mathcal{B}$ ) e dos ângulos *roll* ( $\rho_f^y$ ) e *pitch* ( $\pi_f^x$ ), contidos em  $\vec{\mathcal{I}}$ .

## 6.2 Transformação dos dados inerciais

Nesta seção, é proposta uma abordagem para realizar a transformação do dado inercial, tornando-o invariante a velocidade. Durante a navegação do veículo terrestre são capturados dados inerciais a partir de uma IMU. Os dados inerciais são diretamente afetados pela velocidade aplicada pelo veículo, durante sua movimentação [Wang et al., 2017]. Por isso, a aplicação de dados inerciais para análise de terrenos torna-se vulnerável, caso a variação de velocidade não seja considerada na solução do problema.

A variação de velocidade do robô, durante a coleta de dados, resulta em uma alteração na magnitude dos sinais inerciais coletados. De modo que, para um mesmo terreno, altas velocidades resultam em alta magnitude do sinal inercial. Enquanto que baixas velocidades resultam em baixa magnitude do sinal inercial. Na Figura 6.1, é apresentado um exemplo de sinais inerciais coletados usando diferentes velocidades, para um mesmo terreno. Os sinais inerciais, na Figura 6.1, correspondendo às velocidades baixa, média e alta. Adicionalmente, é possível observar a variação na magnitude do sinal inercial, de acordo com a variação de velocidade do veículo.

Para tratar o problema de variação de velocidade em dados inerciais, foi proposta uma abordagem para transformar os referidos dados, coletados em diferentes velocidades. A transformação proposta considera os dados inerciais ( $\vec{\mathcal{I}}$ ) e a velocidade ( $\nu$ ) aplicada pelo veículo. Dentre o conjunto de dados inerciais mencionados no Capítulo 4, são transformadas: as acelerações lineares no eixo  $z$  ( $\alpha^z$ ) e as velocidades angulares no eixo  $y$  ( $\omega^y$ ). Para isso, são aplicadas duas funções transformação, uma para  $\alpha^z$  e

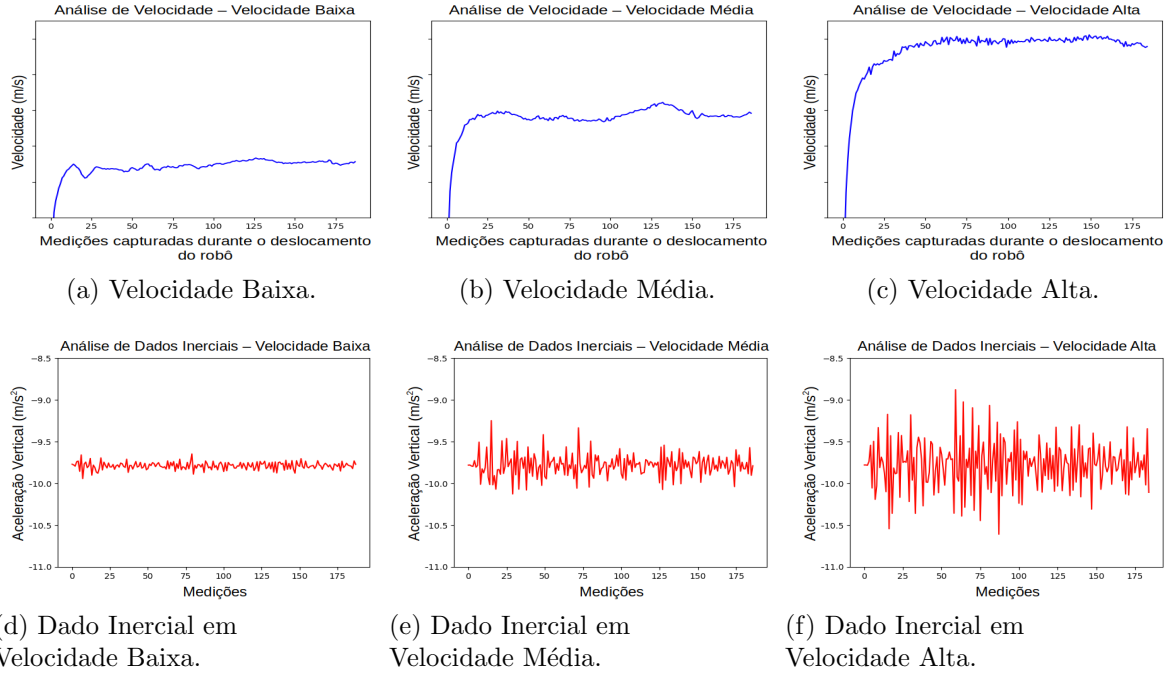


Figura 6.1: Impacto da variação de velocidade na aquisição de dados inerciais. Nas Figuras 6.1a e 6.1d são apresentadas as baixas velocidades aplicadas e o dado inercial correspondente, respectivamente. Nas Figuras 6.1b e 6.1e são apresentadas as médias velocidades aplicadas e o dado inercial correspondente, respectivamente. Nas Figuras 6.1c e 6.1f são apresentadas as altas velocidades aplicadas e o dado inercial correspondente, respectivamente.

outra para  $\omega^y$ , que compartilham o mesmo modelo preditivo. A equação:

$$\vec{\mathcal{S}}_f = \Xi(\vec{\mathcal{I}}_f, \nu_c, \nu_g) = \vec{\mathcal{I}}_f \times \eta(\nu_c, \nu_g), \quad (6.1)$$

define uma função que recebe como entrada o dado inercial ( $\vec{\mathcal{I}}_f$ ), a velocidade corrente do robô ( $\nu_c$ ) e a velocidade alvo ( $\nu_g$ ). Adicionalmente, a função aprende o fator de transformação  $\eta(\nu_c, \nu_g)$ , que mapeia  $\vec{\mathcal{I}}_f$ , adquirido em diferentes velocidades, em dados inerciais em velocidade constante  $\vec{\mathcal{S}}_f$ .

Para estimar o fator de transformação ( $\eta(\nu_c, \nu_g)$ ) é utilizado um modelo de regressão quadrático com múltiplas variáveis, definido na subseção 3.1.2.1. Tendo essa informação, o procedimento de transformação funciona como a seguir. Primeiro, o dado inercial capturado pelo robô é filtrado, por meio de um filtro passa-baixa. Em seguida, o fator de transformação, para normalizar o dado inercial filtrado, é computado a partir da velocidade aplicada pelo veículo. Por fim, é realizada a normalização entre o dado inercial filtrado e o fator de transformação de dados inerciais, resultando no dado inercial invariante a velocidade.

Para treinar o modelo de regressão quadrático múltiplo, em processo de aprendizado supervisionado, as seguintes informações são fornecidas: *i*)  $\nu_c$  e  $\nu_g$ , como dados de entrada do modelo; e *ii*) os fatores de normalização, como valores de referência. Os fatores de normalização utilizados na etapa de treino são encontrados como a seguir:  $\vec{\mathcal{I}}_f^{\nu_g} / \vec{\mathcal{I}}_f^{\nu_c}$ . Na etapa de treino, foram utilizados dados inerciais capturados em três diferentes velocidades, para o mesmo ambiente. Então, a partir do dado inercial conhecido, em diferentes velocidades, os fatores de normalização são computados como mencionado.

### 6.3 Classificação do nível de rugosidade de terrenos

Nesta seção, é proposta uma abordagem para realizar a classificação do nível de rugosidade de terrenos a partir de dados inerciais. Os dados inerciais são utilizados para representar as características das superfícies por onde o veículo se desloca. Dentre as características determinantes para definir o risco de navegação por uma região está o nível de rugosidade de um terreno [Dutta & Dasgupta, 2017].

Para realizar o processo de classificação dos níveis de rugosidade, é preciso, inicialmente, descrever a rugosidade do terreno a partir dos dados inerciais transformados ( $\vec{\mathcal{S}}_f$ ), ou seja, invariantes a velocidade. Os dados inerciais transformados considerados para corresponder à assinatura do terreno foram: *i*) a aceleração linear no eixo z ( $\alpha^z$ ); e *ii*) a velocidade angular no eixo y ( $\omega^y$ ).

Cada um dos dados inerciais supracitados correspondem a sinais unidimensionais, podendo os mesmos serem analisados de duas formas, no domínio do tempo ou no domínio da frequência. No domínio do tempo, os dados são representados por meio de uma relação entre a amplitude e o tempo. Já no domínio da frequência, os dados são representados por meio de uma relação entre a amplitude e a frequência, como pode ser observado na Figura 6.2.

Após a coleta e transformação dos dados inerciais, tornando-os invariantes a velocidade, ainda é possível observar uma das influências mais importantes da velocidade sobre o dado inercial. O número de medições de uma região, varia de acordo com a velocidade aplicada pelo veículo. De modo que, quanto mais rápido o robô se move, menor o número de amostras adquiridas em uma dada distância percorrida. Dessa forma, utilizar uma janela deslizante de tamanho fixo  $k$ , frente à variação de velocidade, pode promover medições inconsistentes, para um mesmo terreno.

Para um mesmo terreno, é esperado que as características que representam o ambiente sejam preservadas no dado inercial, especialmente para valores obtidos em baixas

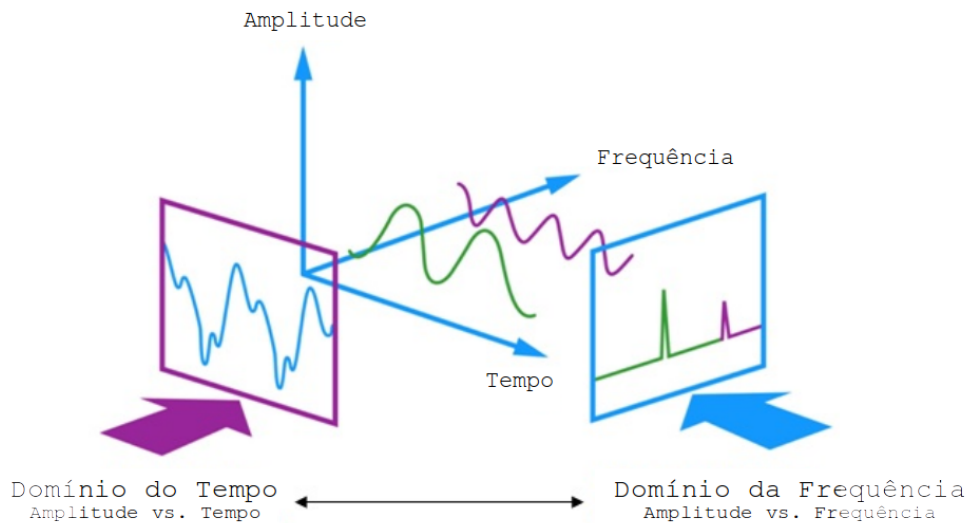


Figura 6.2: Representação de um dado inercial unidimensional, onde o mesmo sinal pode ser interpretado tanto no domínio do tempo, quanto no domínio da frequência.

velocidades. Nesse sentido, foi definida uma janela de medição deslizante variável para a classificação, baseada na distância percorrida e na velocidade aplicada. Considerando  $d$  como a distância usada para classificação,  $\nu$  a velocidade linear do robô e  $\Delta t$  o intervalo de medição, o tamanho da janela de medição  $k$  é definido como:

$$k = \frac{d}{\nu \Delta t}.$$

Neste trabalho, os dados inerciais são descritos no domínio da frequência e para isso será aplicado o algoritmo FFT. A Transformada de Fourier é uma técnica que converte um sinal no domínio do tempo em uma representação deste sinal no domínio da frequência, gerando uma descrição composta pelos componentes de frequência contidos no sinal [Rao et al., 2010].

Para utilizar o algoritmo FFT, o sinal a ser analisado deve ter tamanho  $T$  em potência de dois, resultando em um vetor contendo  $T$  elementos, correspondendo à  $T$  frequências. Considerando o teorema de *Nyquist*, sabe-se que o componente de frequência mais alta no sinal original deve ser a metade da frequência de amostragem, ou seja, a segunda metade do *spectrum* é uma imagem espelhada da primeira metade [Weik, 2001], conforme Figura 6.3.

Para descrever o nível de rugosidade dos terrenos, cada conjunto de dados inerciais ( $\alpha^z$  e  $\omega^y$ ), contido na janela deslizante de medição, foi transformado para o domínio da frequência ( $f\alpha^z$  e  $f\omega^y$ ). A partir das duas representações no domínio da frequência, observou-se que nem todas as frequências eram discriminantes o suficiente para pro-




Figura 6.3: Sinal transformado para o domínio da frequência por meio da FFT, evidenciando o teorema de *Nyquist* no espelhamento do vetor.

mover uma boa descrição do terreno. Com isso, uma análise de faixas de frequências foi realizada, conforme utilizado na literatura [DuPont et al., 2008]. Para tratar o problema de descrição, foram selecionadas algumas frequências mais significativas para representar as características fundamentais de cada tipo de informação [Otsu et al., 2016]. Dessa forma, para este trabalho, foram consideradas somente as 300 primeiras frequências (0-300 Hz) de  $f\alpha^z$  e  $f\omega^y$  e os resultados foram concatenados, formando a descrição de rugosidade para aquele terreno percorrido, conforme exemplo ilustrativo apresentado na Figura 6.4.

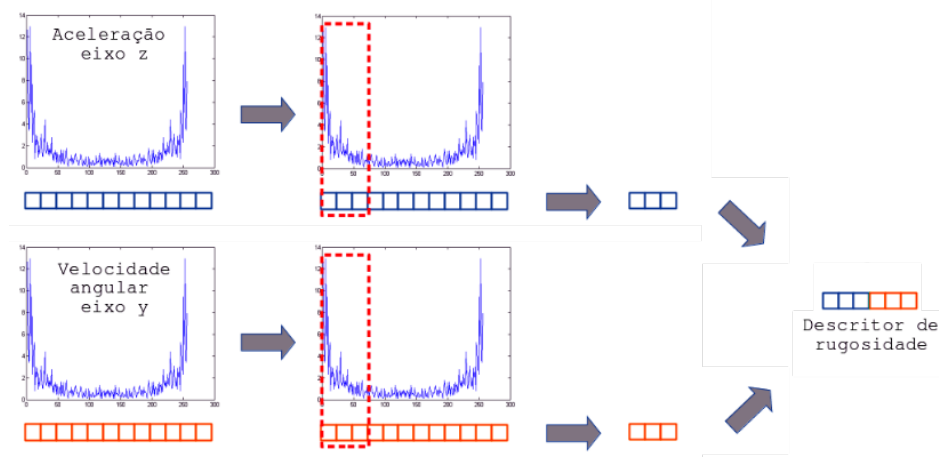


Figura 6.4: Ilustração do processo de formação da descrição de rugosidade. Inicialmente, os exemplos de dados inerciais  $\alpha^z$  e  $\omega^y$  foram transformados para o domínio da frequência obtendo  $f\alpha^z$  e  $f\omega^y$ . Em seguida, foram selecionadas somente as 300 primeiras frequências de cada vetor,  $f\alpha^z$  e  $f\omega^y$ . Por fim, os vetores resultantes da etapa anterior foram concatenados.

Com a definição do descritor de rugosidade, para cada coordenada percorrida, resta realizar a classificação do nível de rugosidade dos terrenos. Para isso, foi utilizado um modelo de classificação supervisionado. O modelo de classificação aplicado para identificar os níveis de rugosidades de terrenos foi o *Random Forest*, que é detalhado na subseção 3.1.1.1. As características mencionadas na referida subseção justificam a utilização do modelo *Random Forest* na presente pesquisa.

O procedimento de classificação dos níveis de rugosidade de terrenos funciona como a seguir. Inicialmente, os dados inerciais transformados ( $\vec{\mathcal{S}}$ :  $\alpha^z$  e  $\omega^y$ ), invariantes a velocidade, são representados por meio de janelas deslizantes. Em seguida, cada janela deslizante é transformada do domínio do tempo para o domínio da frequência. Posteriormente, para cada representação no domínio da frequência ( $f\alpha^z$  e  $f\omega^y$ ), são selecionadas apenas as 300 primeiras frequências e concatenadas, formando o descritor de rugosidade da região visitada. Por fim, o descritor de rugosidade é submetido ao modelo de classificação *Random Forest*, que irá associá-lo a um nível de rugosidade ( $\mathcal{B}$ ) adequado.

## 6.4 Estimação do custo de navegação

Para descrever uma região, representando o grau de dificuldade ao se deslocar por sua superfície, foi proposta uma abordagem para estimar o custo de navegação a partir de diferentes tipos de dados inerciais. Para isso foram combinados o nível de rugosidade e os ângulos do veículo, ao se deslocar pela superfície.

O nível de rugosidade de um terreno, computado na etapa de classificação (Seção 6.3), representa o grau de rugosidade da superfície. Ambientes externos apresentam grande variedade de tipos distintos de terrenos, onde os mesmos podem conter alto grau de rugosidade. Esses terrenos, possuem características que vão além do nível de rugosidade, podendo ser diretamente impactados por altos níveis de inclinação [Dubey et al., 2013].

Nesse contexto, a combinação entre o nível de rugosidade e a *attitude* do robô (*roll* e *pitch*) pode resultar em uma representação eficiente que corresponde ao custo de se navegar pelo terreno na coordenada corrente. Para isso, deve ser criada uma função que receba as informações supracitadas e as sintetize em um único valor que estima o custo de navegação.

A função de custo de navegação ( $\Lambda$ ) proposta neste trabalho, consiste, inicialmente, na aplicação de um modelo de regressão polinomial de terceira ordem ( $\Omega$ ), a partir dos ângulos do veículo (*roll* e *pitch*). O modelo  $\Omega$ , transforma os ângulos do

veículo (*roll* e *pitch*), que correspondem à *attitude* do robô, em uma saída com intervalo entre 0 e 1. A referida saída representa o grau de inclinação da região. Por fim, é aplicado outro modelo de regressão polinomial de terceira ordem ( $\Lambda$ ), a partir do nível de rugosidade e da *attitude* do robô. O modelo  $\Lambda$ , transforma as características extraídas da região (nível de rugosidade e da *attitude* do robô) em uma saída com intervalo entre 0 e 1. Para isso, são utilizados modelos de regressão treinados a partir de Tabela de consulta (*Lookup Table*, ou LUT) contendo saídas de referência conhecidas, para casos bem definidos. A referida saída compreende as características do terreno, reduzindo todos os custos à um único custo de navegação da região, conforme Figura 6.5.




Figura 6.5: Esquemático da função de custo proposta. A função de custo aplica, inicialmente, uma regressão polinomial de terceira ordem ( $\Omega$ ), combinando os ângulos do veículo, em uma representação da *attitude* do robô. Por fim, aplica-se outro modelo de regressão polinomial de terceira ordem ( $\Lambda$ ), para combinar os custos relacionados aos níveis de rugosidade e *attitude* do robô, em um único custo de navegação.

Para as funções  $\Omega$  e  $\Lambda$  foram empregados modelos de regressão polinomial de terceira ordem, definidos na subseção 3.1.2.1, onde há a relação entre a variável resposta e duas variáveis preditoras. O modelo de regressão polinomial de terceira ordem ( $\Omega$ ), representa o grau de inclinação das superfícies, a partir dos ângulos *roll* e *pitch*. Os ângulos *roll* e *pitch* compõem a *attitude* do robô, sendo o comportamento do modelo  $\Omega$ , apresentado na Figura 6.6.

Na Figura 6.6, é destacado que ângulos acentuados, tanto para *roll*, quanto para *pitch*, resultam em alto grau de *attitude*, impactando negativamente o custo de navegação da região. Considerando o ângulo *pitch*, destaca-se que declives, menos acentuados, impactam positivamente no custo de navegação. Ao contrário dos aclives, que impactam negativamente no custo de navegação.

O modelo de regressão polinomial de terceira ordem ( $\Lambda$ ), representa o custo de se navegar por uma superfície, a partir do nível de rugosidade e do custo de *attitude* do robô, computado em  $\Omega$ . O comportamento do modelo  $\Lambda$ , para estimação do custo de navegação de uma região em ambiente externo, pode ser visualizado Figura 6.7. Na



Figura 6.7, é destacado que as características de rugosidade e inclinação do terreno influenciam igualmente para a estimação do custo de navegação.

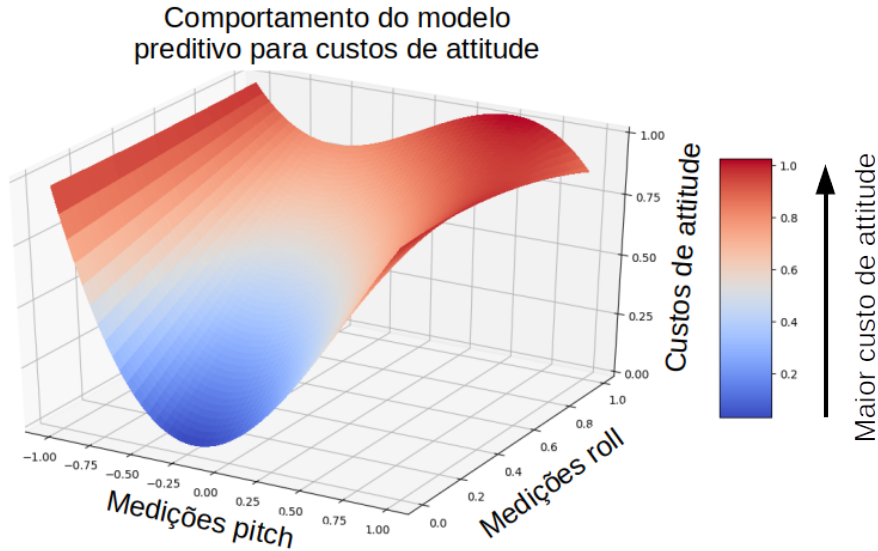


Figura 6.6: Modelo de regressão polinomial de terceira ordem ( $\Omega$ ), aplicado na combinação entre os ângulos *roll* e *pitch* do veículo, resultando no custo de *attitude* do robô. Para facilitar o entendimento, a cor azul representa baixo custo de *attitude*, enquanto a cor vermelha representa alto custo de *attitude*.

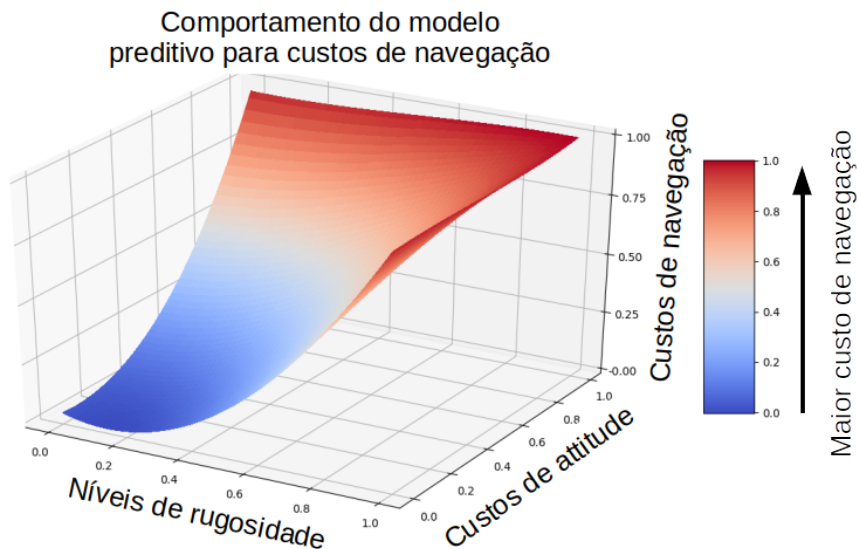


Figura 6.7: Modelo de regressão polinomial de terceira ordem ( $\Lambda$ ), aplicado na combinação entre o nível de rugosidade e o custo de *attitude* do robô, resultando no custo de navegação da região percorrida. Para facilitar o entendimento, a cor azul representa baixo custo de navegação, enquanto a cor vermelha representa alto custo de navegação.

O procedimento de estimação do custo de navegação de uma região funciona como a seguir. Primeiro, os dados inerciais ( $\vec{\mathcal{I}}$ ), *roll* e *pitch*, são submetidos ao modelo preditivo  $\Omega$ , que irá estimar o custo de *attitude* do robô, representando o grau de inclinação da superfície. Por fim, os dados: *i*) nível de rugosidade ( $\mathcal{B}$ ); e *ii*) custo de *attitude* do robô são combinados, pelo modelo preditivo  $\Lambda$ , resultando no custo de navegação ( $\mathcal{C}$ ) da região percorrida ( $\mathcal{R}^v$ ) pelo veículo terrestre.

# Capítulo 7

## Incremento do mapa tridimensional com custo de navegação usando aprendizado profundo

Neste capítulo é apresentada uma abordagem para construção de mapas de custo aumentados, representando ambientes externos. Adicionalmente, neste capítulo é apresentada a combinação entre os dados providos pelos diferentes sensores utilizados neste trabalho. Para isso, é aplicada uma técnica de Aprendizado Profundo para estimar o custo de navegação para regiões do terreno não visitadas pelo veículo terrestre. Com isso, técnicas de navegação em ambientes externos podem utilizar informações complementares sobre o terreno para aprimorar o deslocamento do robô.

Nas seções seguintes, serão apresentados os problemas relacionados a cada operação da etapa principal de incremento do mapa tridimensional com custo de navegação usando aprendizado profundo. Posteriormente, são apresentadas, em detalhes, cada uma das operações supracitadas.

### 7.1 Definição dos problemas

O problema principal abordado por este trabalho é dividido em 3 etapas fundamentais, como mencionado no Capítulo 4. Na etapa de incremento do mapa tridimensional com custo de navegação usando aprendizado profundo são tratados 3 subproblemas que são definidos a seguir:

**Problema 4 (Registro dos dados inerciais e geométricos):** Considere os dados inerciais ( $\vec{\mathcal{I}}$ ) e geométricos ( $\mathcal{P}^v$ ) providos pelos diferentes sensores, coletados

durante o deslocamento do robô, seguindo as coordenadas  $\mathcal{G}^v$ . Para cada coordenada  $g_f^v$ ,  $1 \leq f \leq \phi$ , é realizado um conjunto de medições ( $i_j$ ) capturadas pelo sensor inercial e um conjunto de medições ( $p_q^v$ ) capturadas pelo laser. Dessa forma, o objetivo para este subproblema é determinar os dados  $i_j$  e  $p_q^v$  que correspondem à mesma região visitada  $r_f^v$ , centrada na coordenada  $g_f^v$ . Dado que  $i_j$  e  $p_q^v$  correspondem à região visitada  $r_f^v$ , então os mesmos serão referenciados espacialmente como  $i_f$  e  $p_f^v$ .

**Problema 5 (Fusão entre múltiplos sensores):** Considere os custos de navegação  $\mathcal{C}$ , estimados para cada região percorrida ( $r_f^v$ ). Considere as nuvens de pontos  $\mathcal{P}^v$ , coletadas para cada região percorrida ( $r_f^v$ ). Considere que  $c_f$  e  $p_f^v$  representam a mesma região  $r_f^v$ , tendo em vista que os dados inerciais e geométricos foram registrados no Problema 4. Considere que  $p_f^v$  corresponde ao conjunto de pontos contidos na região  $r_f^v$  de tamanho previamente definido ( $\lambda \times \gamma$ ). Dessa forma, o objetivo para este subproblema é combinar os dados inerciais e geométricas, de tal forma que seja possível estimar o custo de navegação ( $\mathcal{C}$ ), para regiões não visitadas ( $\mathcal{R}^u$ ), a partir da representação geométrica ( $\mathcal{P}^u$ ) do terreno.

**Problema 6 (Mapeamento do custo de navegação):** Considere que o veículo se desloca pelo ambiente seguindo as coordenadas  $\mathcal{G}^v$ . Considere as nuvens de pontos  $\mathcal{P}^u$ , coletadas para cada região não visitada ( $r_f^u$ ). Considere os custos de navegação  $\mathcal{C}$ , estimados para cada região não visitada ( $r_f^u$ ). Considere uma representação do terreno, definida por um sistema de coordenadas tridimensional  $\mathcal{M}$ , com coordenadas contínuas. Dessa forma, o objetivo para este subproblema é atribuir os custos de navegação ( $\mathcal{C}$ ) estimados, às coordenadas contínuas correspondentes ( $\mathcal{G}^u$ ), no mapa de custos de navegação ( $\mathcal{M}$ ) proposto.

## 7.2 Registro dos dados inerciais e geométricos

Nesta seção, é proposta uma abordagem para realizar o registro dos dados providos pelos sensores inercial e geométrico. Durante a navegação do veículo terrestre são capturados dados a partir de uma IMU e um *laser*. Os dados providos pelos diferentes sensores são capturados em uma mesma posição, porém não correspondem à mesma região visitada. Ou seja, em cada coordenada  $g_f^v$ , os dados capturados,  $i_j$  e  $p_q^v$ , correspondem a regiões distintas. Isso ocorre pois, o dado  $i_j$  é associado à coordenada atual do robô ( $g_f^v$ ), enquanto o dado  $p_q^v$  corresponde às posições ao redor do robô (por exemplo, a região frontal) e não à coordenada atual do robô, como pode ser observado na Figura 7.1.

Devido a diversidade de características encontradas em ambientes externos, o




Figura 7.1: Aquisição dos dados inerciais e geométricos. Apresentação da disparidade entre os dados coletados, enfatizando que os mesmos não correspondem à mesma região.

uso de múltiplos sensores tem se tornado uma estratégia amplamente utilizada para análise de terrenos. Na combinação entre diferentes sensores, são identificados alguns aspectos que impactam na fusão entre as informações. As características dos sensores e a frequência com que os dados são coletados são alguns dos fatores mais desafiadores, pois faz com que os dados sejam capturados em tempos de medição distintos.

A disparidade, supracitada, entre os dados ocorre pois determinados sensores realizam medições que correspondem à coordenada onde a medição foi realizada, como por exemplo, IMU. Enquanto que, para outros sensores, as medições correspondem às coordenadas ao redor do robô e não à posição onde foi coletada a medição, como por exemplo, *laser* e *radar*. A dificuldade mencionada ilustra a relação de registro entre sensores proprioceptivos e exteroceptivos.

Neste trabalho, são considerados dados sensoreados por uma IMU e um *laser*. Para todo o desenvolvimento do presente trabalho, assume-se que os dados inerciais e geométricos foram coletados previamente (*offline*), em uma rota pré-definida e com o veículo sendo dirigido por um operador humano. Adicionalmente, assume-se que os dados geométricos estão agrupados e registrados como uma única nuvem de pontos do ambiente a ser analisado.

Para proceder o registro dos dados inerciais e geométricos, inicialmente, foram consideradas as coordenadas ( $\mathcal{G}^v$ ), seguidas pelo veículo terrestre durante seu deslo-

camento. Para cada coordenada ( $g_f^v$ ) visitada, é extraída a representação geométrica ( $p_q^v$ ) (nuvem de pontos), que corresponde à região visitada  $r_f^v$ . A dimensão da referida região é baseada na dimensão do robô, ( $\lambda \times \gamma$ ).

A partir do conjunto de medidas geométricas ( $p_q^v$ ), que corresponde à região visitada  $r_f^v$ , são identificadas as medidas inerciais que correspondem à referida região, assumindo a sincronização dos relógios dos diferentes sensores. Para isso, é verificado o tempo de captura, dentre as medições inerciais, que mais se aproxima do tempo de captura da coordenada  $g_f^v$ . Dessa forma, as medições são referenciadas por meio da região por onde o veículo percorreu, ou seja, são referenciadas espacialmente. Com isso, as medições inerciais e geométricas passam a ser associadas à região visitada ( $r_f^v$ ), sendo representadas por  $i_f$  e  $p_f^v$ , respectivamente. Na Figura 7.2, é apresentado um exemplo do processo de identificação dos dados inerciais e geométricos que correspondem à mesma região.

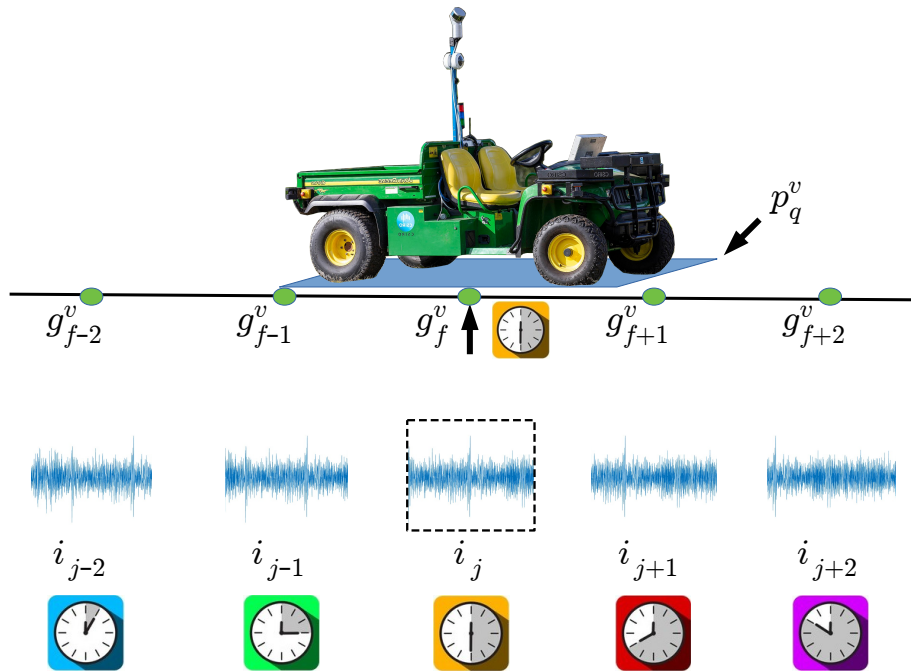


Figura 7.2: Identificação das medições inerciais e geométricas que correspondem à mesma região. A partir da representação geométrica ( $p_f^v$ ), extraída na coordenada atual ( $g_f^v$ ), é selecionada a medição inercial ( $i_f$ ) que apresenta o tempo de captura mais próximo do tempo de captura da referida coordenada.

### 7.3 Fusão entre múltiplos sensores

Nesta seção, é proposta uma abordagem para combinar diferentes tipos de dados, providos por diferentes sensores. Para representar características diversas, presentes em

terrenos, a utilização de múltiplos sensores é uma estratégia amplamente utilizada [Sock et al., 2016]. Isso ocorre pois diferentes sensores são capazes de descrever características complementares, aumentando a capacidade de representação da superfície. Para isso, foi proposta uma técnica de fusão sensorial entre dados inerciais e geométricos, por meio de uma abordagem de Aprendizado Profundo.

A combinação entre múltiplos sensores é essencial para navegação autônoma, devido a necessidade de redundância entre os dados, bem como a necessidade de prover dados com características complementares [Häselich et al., 2013]. Nesse sentido, diferentes estratégias têm sido exploradas para combinação dos dados providos por diferentes sensores, no contexto de análise de terrenos [Guo et al., 2011].

Diferentes técnicas de Aprendizado de Máquina foram utilizadas para análise de terrenos, tais como SVM, *Random Forest*, KNN, dentre outras [Dutta & Dasgupta, 2017][Wang et al., 2017][Oliveira et al., 2019][Martínez et al., 2020]. Técnicas de Aprendizado de Máquina, como as supracitadas, demandam de uma descrição do terreno para corresponder à assinatura da superfície. Diversas estratégias de descrição de terreno já foram aplicadas para descrever as características de uma região. Porém as referidas descrições são capazes de representar apenas uma quantidade limitada de características, como variação do sinal, textura, cor, dentre outras características.

Nesse contexto, destaca-se a aplicação recente de técnicas de Aprendizado Profundo na análise de terrenos. Dentre as diversas arquiteturas de Aprendizado Profundo, destacam-se as CNN, que são detalhadas na subseção 3.1.2.2. Neste trabalho, a fusão entre os múltiplos sensores ocorrerá por meio de uma CNN, em um processo de regressão. Dessa forma, será estimado o custo de navegação, a partir das representações geométricas das posições não visitadas.

As representações geométricas serão transformadas em estruturas bidimensionais. Tais estruturas bidimensionais correspondem à discretização dos pontos tridimensionais geométricos. Dessa forma, as referidas estruturas bidimensionais poderão ser submetidas como entrada da CNN proposta. Para isso, a região contínua será dividida em uma grade de células, com  $\chi$  linhas e  $\tau$  colunas. Cada célula apresenta um tamanho, definido por resolução, conforme pode ser observado na Figura 7.3.

Cada célula da grade bidimensional é composta por uma quantidade de pontos, com valores distintos correspondendo aos eixos  $x$ ,  $y$  e  $z$ , conforme Figura 7.3. Para estimar o valor no eixo  $z$  que representa a referida célula, assume-se que, embora exista variação entre os dados no eixo  $z$ , a variação entre eles é pequena, pois os mesmos correspondem à mesma célula, com baixa resolução. Dessa forma, foi utilizada a média aritmética como ferramenta para sumarizar as medições dos pontos no eixo  $z$ , para cada célula.

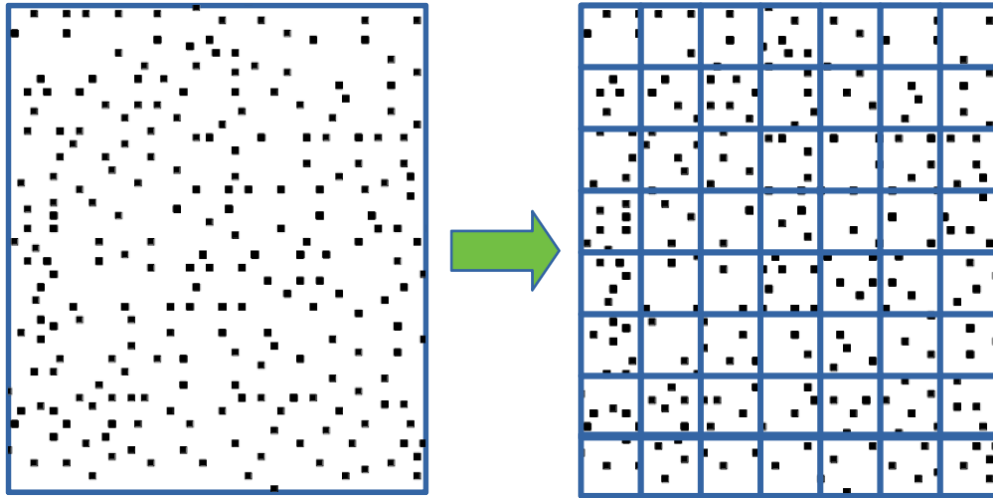


Figura 7.3: Discretização de regiões contendo medições geométricas. As regiões foram divididas em uma grade de células, com  $\chi$  linhas e  $\tau$  colunas. Cada célula apresenta um tamanho, definido por resolução.

Na etapa de treinamento do modelo convolucional proposto, os pesos e vieses das conexões entre as camadas foram aprendidos, a partir dos pares de dados: *i*) medições geométricas ( $p_f^v$ ) discretizadas; e *ii*) custos de navegação ( $c_f$ ). A saída da etapa de treinamento, é o modelo  $\Delta$  treinado. Dessa forma, na etapa de teste, é possível utilizar o modelo  $\Delta$  para prever os custos de navegação ( $c_e$ ), a partir de medições geométricas discretizadas, referentes às regiões não visitadas ( $r_e^u$ ).

A arquitetura da CNN proposta, mostrada na Figura 7.4, é composta por etapas: *i*) Convolucionais; *ii*) Funções de ativação; *iii*) Normalização; *iv*) Redução de dimensionalidade (*Pooling*); *v*) Redução da importância de conexões (*Dropout*); *vi*) Camadas completamente conectadas (*Fully Connected*); e *vii*) Camada de ativação linear [Skansi, 2018].




Figura 7.4: Arquitetura da CNN proposta para predição de custos de navegação, a partir da combinação entre medições geométricas e custos de navegação, baseados em medições inerciais.

Para a abordagem proposta, 4 unidades convolucionais foram aplicadas. Cada



unidade convolucional é composta por: Camada convolucional, Função de ativação (ReLU), Normalização em lote e Redução de dimensionalidade (*MaxPooling*). Os dados de entrada apresentam a dimensão 60x40. A primeira camada convolucional apresenta 300 filtros. A segunda camada convolucional apresenta 250 filtros. A terceira camada convolucional apresenta 200 filtros. A quarta camada convolucional apresenta 150 filtros. O tamanho dos filtros para todas as camadas convolucionais é 3x3. O tamanho da região para a operação *MaxPooling* é 2x2. O valor de *Dropout* aplicado é 0.90. As camadas completamente conectadas apresentam 500 e 250 neurônios, respectivamente. A última camada com ativação linear proporciona a estimação da regressão.

O procedimento de fusão entre os múltiplos sensores utilizados neste trabalho funciona como a seguir. Inicialmente, considera-se os dados geométricos e os custos de navegação, registrados. Os referidos dados correspondem às regiões percorridas pelo robô. A partir dos dados registrados, é realizada a discretização dos dados geométricos referentes às regiões visitadas. Em seguida, é treinado o modelo de predição baseado em Aprendizado Profundo. Por fim, dado que o modelo de predição está treinado, dados geométricos de regiões não visitadas são discretizados e então submetidos ao modelo preditivo, para estimar os custos de navegação para as coordenadas por onde o veículo terrestre não navegou.

## 7.4 Mapeamento do custo de navegação

Nesta seção é proposta uma abordagem para realizar o mapeamento tridimensional aumentado com custo de navegação do terreno. A estimação do custo de navegação, utilizando somente sensores inerciais, proporciona medições apenas para regiões visitadas pelo robô. Durante o desenvolvimento da fase inicial desta pesquisa, foi proposta uma técnica de mapeamento considerando apenas um sensor inercial. Para isso, os custos de navegação estimados foram modelados como *vector fields*, representando as relações espaciais entre cada posição visitada e suas posições adjacentes [Oliveira et al., 2019]. Mais detalhes sobre a técnica de mapeamento baseada em *vector fields* são apresentados no Apêndice A.

A computação de custos de navegação, a partir de dados inerciais, é uma operação que resulta em bons resultados, porém propagar custos de navegação para posições não visitadas é um grande desafio quando se utiliza somente uma única IMU. Considerando a limitação mencionada, observou-se que a combinação entre múltiplos sensores, para mapear ambientes externos, poderia promover a representação de toda a superfície do terreno. Com isso, seria possível determinar as regiões a serem navegadas, favorecendo

o processo de planejamento de caminhos [Guerrero et al., 2015].

Nas subseções seguintes são apresentadas a representação proposta para terrenos em ambientes externos e a estratégia de propagação do custo de navegação.

### 7.4.1 Representação de terrenos

O custo de navegação, computado na etapa de estimação do custo de navegação (Subseção 6.4) e estimado na fusão sensorial (Subseção 7.3), propicia a simplificação dos custos relacionados ao nível de rugosidade e grau de *attitude* do robô. Dessa forma, é possível mensurar o grau de dificuldade encontrado por um veículo terrestre ao se movimentar por um determinado ambiente [Dubey et al., 2013]. No entanto, a simples computação do custo permite apenas a verificação do esforço de se navegar na posição atual em que está sendo realizada a medição.

Nesse contexto, a aplicação de um mapa que contenha os custos de se navegar por cada região do ambiente pode promover grande eficiência e segurança ao processo de navegação de um veículo terrestre. Algumas formas de representação de terrenos externos se destacam na literatura, como as representações bidimensionais [Tanaka et al., 2015] e tridimensionais [Pfrunder et al., 2017].

Neste trabalho, é proposta uma representação tridimensional de terrenos, em ambientes externos, descrevendo continuamente cada ponto que compõe sua superfície, como pode ser visualizado na Figura 7.5. Adicionalmente, cada ponto do mapa tridimensional é associado a um custo de navegação, determinando o grau de dificuldade ao se deslocar por aquela coordenada.




Figura 7.5: Terreno em ambiente externo, representado em três dimensões, com coordenadas contínuas. Cada ponto é representado nos eixos  $x$ ,  $y$  e  $z$ , descrevendo as características das superfícies.

## 7.4.2 Propagação do custo de navegação

Após o processo de captura dos dados, inerciais e geométricos, os mesmos foram registrados. Então, os dados inerciais foram transformados, tornando-se invariantes a velocidade. Em seguida, a partir dos dados inerciais transformados, foram computados os níveis de rugosidade das regiões percorridas. Posteriormente, a partir dos níveis de rugosidade e dos ângulos do veículo, foram estimados os custos de navegação, para as regiões percorridas. Considerando que os custos de navegação, previamente computados, e os dados geométricos correspondem à mesma região, foi treinado um modelo para aprender a relação entre as características geométricas das regiões e seus respectivos custos de navegação. Dessa forma, é possível estimar o custo de navegação para regiões não visitadas, considerando apenas as características geométricas dessas regiões desconhecidas.

No entanto, para estimar os custos de navegação para regiões não visitadas, deve haver uma estratégia para: *i*) extrair as regiões para as quais serão estimados os custos de navegação; e por fim *ii*) associar os custos ao mapa tridimensional aumentado. Neste trabalho, para extrair os dados geométricos das regiões não visitadas foram consideradas como ponto de partida o conjunto de coordenadas  $\mathcal{G}^v$ , percorridas pelo veículo terrestre.

Para cada coordenada visitada ( $g_f^v$ ) (Figura 7.6(1)), é selecionado um conjunto de pontos ( $p_f^v$ ), correspondendo à região visitada ( $r_f^v$ ), de dimensão  $\lambda \times \gamma$ , centrada na respectiva coordenada, como pode ser observado na Figura 7.6(2).

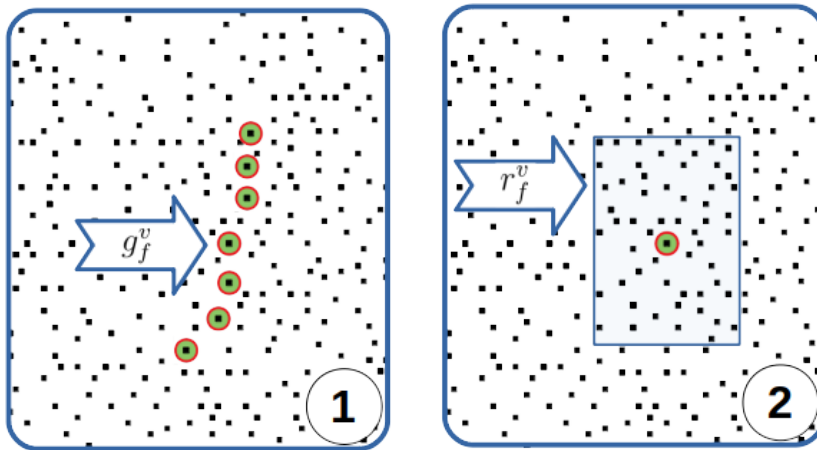


Figura 7.6: Etapas do processo de propagação de custos de navegação para regiões não visitadas. Na Figura 7.6(1), é selecionada cada coordenada visitada pelo veículo ( $g_f^v$ ). Na Figura 7.6(2), é selecionado o conjunto de pontos ( $p_f^v$ ), que corresponde à região visitada ( $r_f^v$ ).

A partir do conjunto de pontos  $p_f^v$ , é selecionada cada coordenada não visitada

$(g_e^u)$ , contida em  $r_f^v$ , conforme Figura 7.7(3). Para cada coordenada não visitada  $(g_e^u)$ , é extraída uma região centrada em  $g_e^u$ , conforme Figura 7.7(4). Essa região corresponde à uma área do terreno por onde o veículo não se deslocou e para a qual será realizada a estimação de custo de navegação.

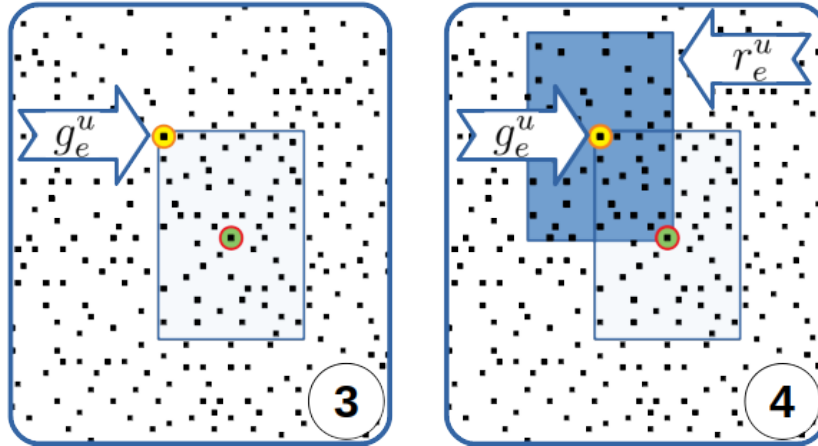


Figura 7.7: Etapas do processo de propagação de custos de navegação para regiões não visitadas. Na Figura 7.7(3), são selecionadas as coordenadas não visitadas  $(g_e^u)$ , contidas na região visitada  $(r_f^v)$ . Na Figura 7.7(4), é extraída a região não visitada  $(r_e^u)$ , centrada na coordenada não visitada  $(g_e^u)$ .

Outros exemplos de seleção de coordenadas não visitadas  $(g_{e+1}^u$  e  $g_{e+2}^u)$  e extração de regiões não visitadas  $(r_{e+1}^u$  e  $r_{e+2}^u)$ , são apresentados nas Figuras 7.8 (5 e 6), respectivamente.

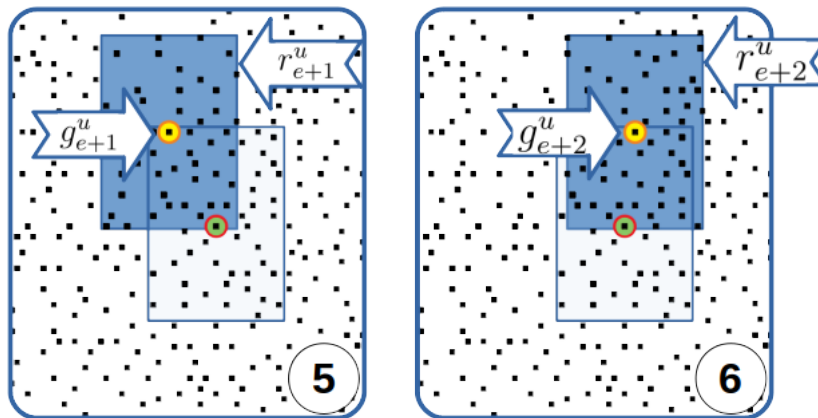


Figura 7.8: Etapas do processo de propagação de custos de navegação para regiões não visitadas. Nas Figura 7.8(5 e 6), são apresentados outros exemplos para a seleção de coordenadas não visitadas  $(g_{e+1}^u$  e  $g_{e+2}^u)$  e extração de regiões não visitadas  $(r_{e+1}^u$  e  $r_{e+2}^u)$ .

Dessa forma, para cada região não visitada  $(r_e^u)$ , é computado o seu custo de navegação, sendo o mesmo associado ao ponto central correspondente  $(g_e^u)$ . Isto é,

a cada coordenada visitada pelo veículo terrestre ( $g_f^v$ ), são selecionadas coordenadas adjacentes e não percorridas ( $g_e^u$ ). Posteriormente, são extraídas regiões não visitadas ( $r_e^u$ ), para as quais serão estimados custos de navegação ( $\mathcal{C}$ ). Por fim, os custos de navegação são associados às coordenadas não visitadas ( $g_e^u$ ).

Com isso é possível mapear terrenos, em ambientes externos, mesmo sem visitá-los completamente. Como resultado são obtidos mapas tridimensionais aumentados com o custo de navegação, representando o ambiente externo. Dessa forma, o processo de navegação poderá agregar a informação relacionada ao terreno à representação dos obstáculos e selecionar caminhos mais seguros e eficientes para o deslocamento de veículos terrestres.

Para melhor compreensão do processo de mapeamento do custo de navegação proposto, é apresentado abaixo o Algoritmo 1.

---

**Algoritmo 1** Mapeamento do Custo de Navegação

---

1:	<b>procedure</b> MCN( $\mathcal{M}, \mathcal{G}$ )	▷ Recebe o mapa e o conjunto de coordenadas
2:	<b>for</b> $g_f^v \in \mathcal{G}$ <b>do</b>	▷ Percorre cada coordenada visitada
3:	$p_f = \text{mediçãoGeométrica}(g_f^v)$	▷ Extrai medição geométrica
4:	$r_f^v = \text{extraiRegião}(g_f^v, p_f)$	▷ Extrai pontos da região visitada
5:	<b>for</b> $g_e^u \in r_f^v$ <b>do</b>	▷ Percorre cada coordenada não visitada
6:	$r_e^u = \text{extraiRegião}(g_e^u, p_f)$	▷ Extrai pontos da região não visitada
7:	$c_e = \text{estimaCustoNavegação}(r_e^u)$	▷ Estima o custo de navegação
8:	$\text{preencheMapa}(\mathcal{M}, g_e^u, c_e)$	▷ Preenche o mapa do terreno
9:	<b>return</b> $\mathcal{M}$	▷ Mapa final

---

# Capítulo 8

## Experimentos

Neste capítulo é apresentado todo o processo experimental realizado para validar as etapas propostas na metodologia, mostradas nos Capítulos 4, 5, 6 e 7. Os experimentos foram conduzidos em ambientes externos com o uso de robôs terrestres reais. Para cada tipo de experimento foram considerados um par composto por: *i*) robô; e *ii*) ambiente externo, onde o experimento foi conduzido. Dessa forma, é possível verificar a capacidade de generalização das técnicas propostas.

O procedimento experimental tem como objetivo principal a validação da metodologia proposta, ou seja, determinar a qualidade dos mapas tridimensionais aumentados com custo de navegação, assim como a eficiência das principais etapas intermediárias. Para isso, os experimentos foram separados em cinco etapas principais: *i*) a análise de comportamento dos dados inerciais com variação de velocidade *ii*) a avaliação do processo de transformação dos dados inerciais, em dados inerciais invariantes a velocidade; *iii*) a avaliação do processo de classificação do nível de rugosidade do terreno; *iv*) a avaliação da qualidade dos mapas de custo de navegação criados; e *v*) a avaliação da efetividade dos mapas de custo de navegação criados.

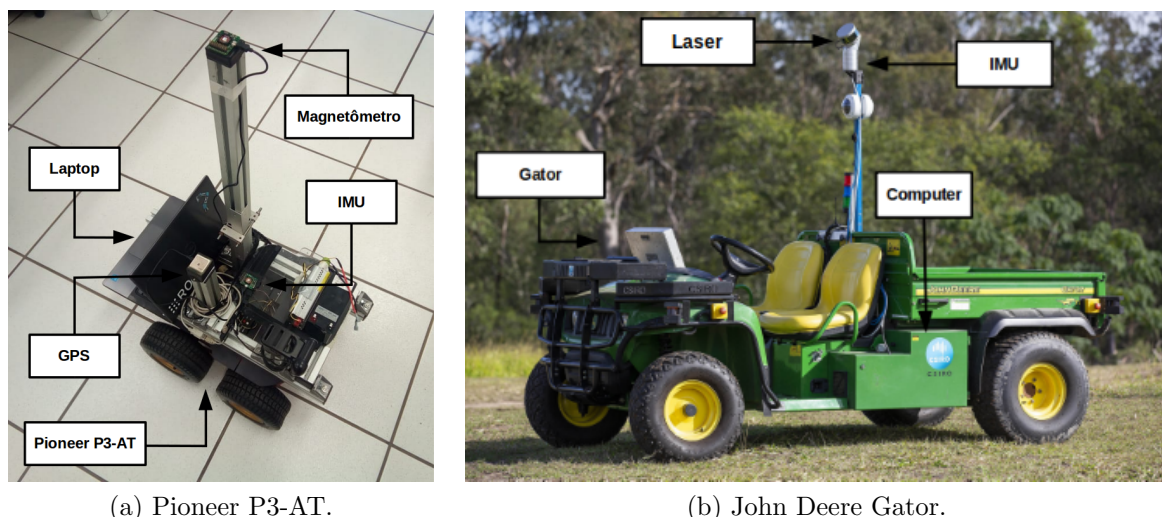
Nas seções seguintes serão apresentados: o processo de aquisição de dados, o ambiente experimental e a avaliação dos resultados obtidos nas principais etapas da metodologia proposta.

### 8.1 Aquisição de dados

Os dados sensoriais foram coletados usando: *i*) um Pioneer 3-AT, uma plataforma de robótica móvel para aplicações em ambientes externos. O robô estava equipado com uma IMU Xsens MTi, um GPS, um magnetômetro e um *laptop* Dell com processador Intel i5-4200U e 8 GB de memória; e *ii*) um John Deere Gator, equipado com uma

IMU MicroStrain 3DM-CV5-25, um Velodyne VLP-16 e um computador com processador Intel i7-6500U e 16 GB de memória, como pode ser observado na Figura 8.1. A velocidade aplicada pelo robô Pioneer P3-AT estava limitada ao intervalo de 0 à 1.2 m/s, onde 0 representa velocidade nula e 1.2 representa sua velocidade máxima. A velocidade aplicada pelo robô Gator estava limitada ao intervalo de 0 à 8.88 m/s, onde 0 representa velocidade nula e 8.88 representa sua velocidade máxima.

Os dados coletados pelos sensores inerciais foram transmitidos para o computador à 100 Hz, enquanto a taxa de rotação do *laser* está entre 5 e 20 Hz. A navegação do robô Pioneer P3-AT, durante a aquisição de dados, foi realizada em modo teleoperado, por meio de um *joystick*. A navegação do veículo Gator, durante a aquisição de dados, foi realizada por um operador humano, dirigindo manualmente.



(a) Pioneer P3-AT.

(b) John Deere Gator.

Figura 8.1: Plataformas de robótica móvel. Na Figura 8.1a, é apresentado o robô Pioneer P3-AT, equipado com um GPS, uma IMU, um magnetômetro e um *laptop*, para aquisição de dados. Na Figura 8.1b, é apresentado o robô John Deere Gator equipado com uma IMU MicroStrain 3DM-CV5-25, um Velodyne VLP-16 e um computador, para aquisição de dados.

IMUs podem ser utilizadas de duas formas, com sistema *gimbaled* ou com sistema *strap-down*. Sistemas *gimbaled* consideram que a IMU é montada em um *gimbal*, que proporcione estabilidade no processo de medição. Sistemas *strap-down* consideram que a IMU é rigidamente conectada ao robô, de forma que não é necessária nenhuma transformação, pois assume-se que o referencial da IMU corresponde ao referencial do veículo [Siciliano & Khatib, 2007]. Neste trabalho foi utilizado o sistema *strap-down*, assumindo que não há deformação nas rodas ou na suspensão do robô.

O magnetômetro é um dispositivo que fornece valores absolutos com relação à orientação do veículo, considerando o norte magnético da terra como referência. Para

o bom funcionamento do dispositivo o mesmo foi montado em uma estrutura acima do robô, no intuito de minimizar as influências magnéticas provenientes do robô.

O GPS é o mecanismo de estimação de localização mais utilizado. Ele provê uma posição tridimensional estimada em coordenadas absolutas, ou seja, a posição geográfica do veículo. As coordenadas absolutas fornecidas pelo GPS são representadas no sistema de coordenadas *Universal Tranverse Mercator* (UTM), no formato *East-North-Up* (ENU), com medição em metros.

O sensor Velodyne VLP-16 é um *laser* 3D que utiliza a tecnologia LiDAR para estimar a distância entre o sensor e os objetos que estão ao seu redor. Com isso é possível mapear, tridimensionalmente, o ambiente. O Velodyne VLP-16 dispõe de 16 canais, com 360° de campo de visão na horizontal, com 30° de campo de visão na vertical, com sensoreamento de aproximadamente 300000 pontos por segundo e alcance de aproximadamente 100 metros.

## 8.2 Ambiente experimental

Para a realização dos experimentos foram selecionados diferentes tipos de terrenos que correspondem a cenários externos reais, para navegação de veículos. Os experimentos foram realizados em dois ambientes externos, com diferentes níveis de rugosidade e inclinação. O primeiro ambiente externo é composto por áreas que estão localizadas: *i*) no Monumento ao Aleijadinho, em frente à Reitoria da Universidade Federal de Minas Gerais (UFMG), em Belo Horizonte - MG - Brasil; e *ii*) no Departamento de Ciência da Computação, da UFMG. Adicionalmente, o primeiro ambiente externo é composto por cinco níveis diferentes de rugosidade (NR). Os níveis de rugosidade são:

- NR1 - nível baixo de rugosidade;
- NR2 - nível intermediário-baixo de rugosidade;
- NR3 - nível intermediário de rugosidade;
- NR4 - nível intermediário-alto de rugosidade;
- NR5 - nível alto de rugosidade.

A Figura 8.2 mostra todos os diferentes tipos de terrenos contidos no primeiro ambiente externo. As Figuras 8.2b, 8.2c e 8.2d mostram terrenos com níveis de rugosidade intermediários, enquanto as Figuras 8.2a e 8.2e mostram superfícies com os níveis de rugosidade mais baixo e mais alto, respectivamente.



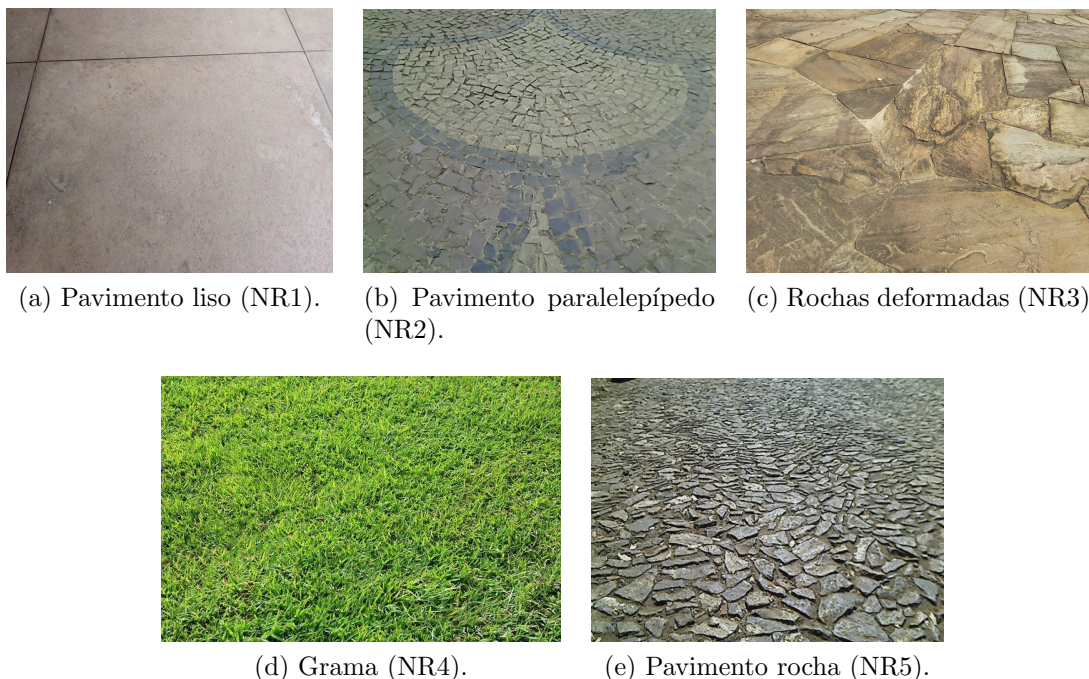


Figura 8.2: Diferentes tipos de terrenos encontrados no primeiro ambiente.

O segundo ambiente externo também é composto por áreas que contém diferentes níveis de rugosidade e inclinação, incluindo regiões como estacionamento, áreas de construção e áreas com vegetação. O segundo ambiente externo está localizado no Queensland Centre for Advanced Technologies (QCAT), do Commonwealth Scientific and Industrial Research Organisation (CSIRO), em Pullenvale - Queensland - Austrália. A Figura 8.3 apresenta os diferentes tipos de terrenos contidos no segundo ambiente externo. As Figuras 8.3a, 8.3b, 8.3c e 8.3d, consistem em regiões com diferentes níveis de rugosidade e inclinação, onde frequentemente ocorre a navegação de veículos. As Figuras 8.3e e 8.3f, representam regiões com altos níveis de rugosidade e inclinação. Os robôs Pioneer P3-AT e Gator foram usados no primeiro e no segundo ambiente externo, respectivamente.

### 8.3 Análise de comportamento dos dados inerciais com variação de velocidade

Neste experimento, foram considerados o primeiro e o segundo ambiente externo. Para cada ambiente, foram coletados dados inerciais com diferentes velocidades aplicadas pelos veículos. No primeiro ambiente foram adquiridos dados inerciais com as velocidades 0.25, 0.3, 0.4, 0.5 e 0.6 m/s, aplicadas pelo robô Pioneer P3-AT. Para o segundo



Figura 8.3: Diferentes tipos de terrenos encontrados no segundo ambiente.

ambiente, foram consideradas três áreas distintas, onde em cada área foram coletados dados inerciais em velocidades diferentes, aplicadas pelo robô Gator. Na Figura 8.4, é apresentado o segundo ambiente externo e suas áreas, bem como os trajetos percorridos.


Considerando a área 1, do segundo ambiente, os dados inerciais foram adquiridos com velocidades 1.0, 2.0, 4.0 e 6.0 m/s. Para a área 2, do segundo ambiente, os dados inerciais foram capturados com velocidades 1.0, 2.0, 3.0 e 4.0 m/s. Finalmente, os dados inerciais foram adquiridos na área 3 com velocidades 3.0, 4.0 e 5.0 m/s. No primeiro ambiente, usando o robô Pioneer P3-AT, as velocidades aplicadas na aquisição de dados foram previamente definidas. No segundo ambiente, o robô Gator foi operado manualmente e as velocidades aplicadas não são constantes. Além disso, as velocidades aplicadas podem variar devido a velocidade máxima permitida para cada robô.

O objetivo deste experimento consiste em avaliar o impacto da variação de velocidade na aquisição de dados inerciais. A partir dessa avaliação, o comportamento dos dados inerciais é definido e pode ser usado para fornecer um modelo preditivo adequado, representando os dados inerciais adquiridos em diferentes velocidades (Figura 8.5).

Para cada ambiente e para cada velocidade diferente, a variação dos dados inerciais é calculada, ou seja é computada a dispersão dos dados a medida que a velocidade

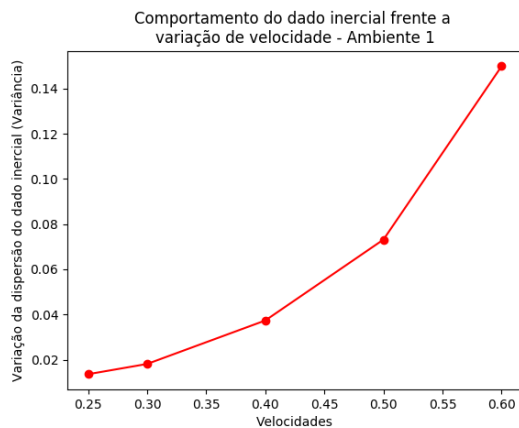


(a) Segundo ambiente com destaque nas áreas 1, 2 e 3. (b) Trajetória do veículo ao percorrer a área 1.

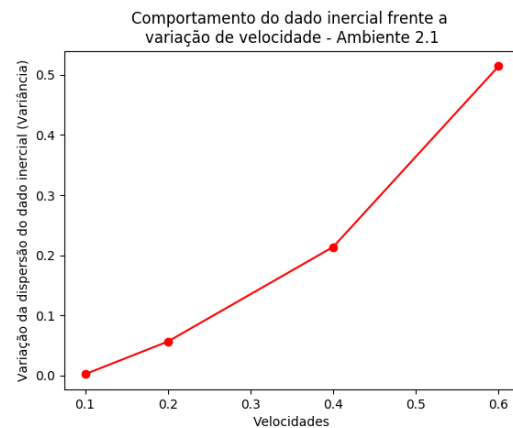


(c) Trajetória do veículo ao percorrer a área 2. (d) Trajetória do veículo ao percorrer a área 3.


Figura 8.4: Segundo ambiente e as áreas que o compõe. A Figura 8.4a, apresenta todo o segundo ambiente, com destaque para as áreas 1, 2 e 3. Na Figura 8.4b é apresentado o trajeto percorrido na área 1 do segundo ambiente. Na Figura 8.4c é apresentado o trajeto percorrido na área 2 do segundo ambiente. Na Figura 8.4d é apresentado o trajeto percorrido na área 3 do segundo ambiente.




(a) Primeiro ambiente.



(b) Ambiente 2 - Área 1.



(c) Ambiente 2 - Área 2.



(d) Ambiente 2 - Área 3.

Figura 8.5: Avaliação do impacto da variação de velocidade no dado inercial. Na Figura 8.5a é apresentado o comportamento do dado inercial em diferentes velocidades, para o primeiro ambiente. Nas Figuras 8.5b, 8.5c e 8.5d são apresentados os comportamentos do dado inercial em diferentes velocidades, no segundo ambiente, para diferentes áreas.

varia. Como visto na Figura 8.5, o aumento da velocidade durante a aquisição de dados faz com que o sinal inercial se comporte de maneira similar a uma função quadrática. Isso sugere que um modelo preditivo quadrático é adequado para a transformação inercial invariante à velocidade, apresentada na Subseção 6.2.

## 8.4 Avaliação da transformação de dados inerciais invariantes a velocidade

Para validar a etapa de transformação de dados inerciais invariantes a velocidade, serão realizados alguns experimentos no intuito de avaliar a qualidade da transformação dos

dados. Para isso os experimentos serão divididos em duas partes. A primeira parte irá avaliar a transformação dos dados qualitativamente, enquanto a segunda parte irá avaliar a transformação dos dados quantitativamente.


Neste experimento, foram consideradas as três áreas contidas no segundo ambiente externo, previamente definidas na Figura 8.4. Para cada área, os dados inerciais foram adquiridos em 2,5 (velocidade baixa), 3,8 (velocidade média) e 6,0 (velocidade alta) m/s. Para reduzir as frequências ruidosas contidas no dado inercial, foi aplicado um filtro passa-baixa *Butterworth*, com frequência de amostragem igual a 100 e frequência de corte igual a 15. A localização do robô, durante seu deslocamento, foi computada para todos os processos de captura de dados inerciais.

### 8.4.1 Análise qualitativa


Este experimento avalia a qualidade da transformação inercial invariante a velocidade proposta (Transformação de Dados Inerciais Invariantes a Velocidade (*Inertial Speed-Invariant Transformation*, ou ISIT)). Para isso, as medições inerciais adquiridas em diferentes velocidades foram transformadas em sinais inerciais correspondentes a uma única velocidade constante. Para a avaliação, as áreas utilizadas no experimento são divididas em Treino e Teste, de modo que os dados adquiridos em uma área sejam utilizados para treinar o modelo de transformação e os dados adquiridos nas outras duas áreas sejam utilizados para teste. Por exemplo, os dados inerciais capturados em diferentes velocidades (baixa, média e alta), na área 1, são utilizados para treinar o modelo de transformação. Enquanto, os dados inerciais capturados em diferentes velocidades (baixa, média e alta), nas áreas 2 e 3, são utilizados para testar a transformação dos sinais inerciais invariantes a velocidade.

A avaliação qualitativa das transformações obtidas pode ser realizada por meio da comparação visual entre os dados inerciais reais, capturados pela IMU em diferentes velocidades, e os dados inerciais transformados, invariantes a velocidade. Na Figura 8.6 são apresentadas as acelerações lineares no eixo Z, reais e transformadas, para cada área do segundo ambiente externo.


Na Figura 8.6, a primeira coluna (Figuras 8.6a, 8.6d e 8.6g) corresponde ao sinal inercial real, capturado pelo veículo, enquanto as demais colunas correspondem aos dados inerciais transformados. Na primeira linha, os sinais inerciais correspondem à área 1, onde na Figura 8.6b o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 2 e na Figura 8.6c o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 3. Na segunda linha, os sinais inerciais correspondem à área 2, onde na Figura 8.6e o modelo de transformação foi




(a) Dado inercial real da Área 1.




(b) Dado inercial da Área 1 transformado a partir da Área 2.




(c) Dado inercial da Área 1 transformado a partir da Área 3.




(d) Dado inercial real da Área 2.




(e) Dado inercial da Área 2 transformado a partir da Área 1.




(f) Dado inercial da Área 2 transformado a partir da Área 3.



(g) Dado inercial real da Área 3.



(h) Dado inercial da Área 3 transformado a partir da Área 1.



(i) Dado inercial da Área 3 transformado a partir da Área 2.

Figura 8.6: Dados inerciais (acelerações lineares no eixo Z), reais e transformados, capturados em diferentes áreas e velocidades. Nas Figuras 8.6a, 8.6d e 8.6g podem ser visualizados os dados inerciais reais, para as áreas 1, 2 e 3, respectivamente. Nas Figuras 8.6b, 8.6c, 8.6e, 8.6f, 8.6h e 8.6i, são mostrados os dados inerciais transformados, ou seja invariantes a velocidade.

treinado a partir dos dados inerciais capturados na área 1 e na Figura 8.6f o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 3. Na terceira linha, os sinais inerciais correspondem à área 3, onde na Figura 8.6h o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 1 e na Figura 8.6i o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 2. Adicionalmente, os dados inerciais representados na cor vermelha foram capturados aplicando velocidade baixa. Os dados inerciais representados na cor verde foram capturados aplicando velocidade intermediária. Por fim, os dados inerciais representados na cor azul foram capturados aplicando velocidade alta.

Ao observar os sinais inerciais reais (Figuras 8.6a, 8.6d e 8.6g), é possível verificar que, a medida que a velocidade aplicada pelo veículo aumenta, a variação entre as magnitudes dos dados inerciais também aumenta. Observando os sinais inerciais transformados é possível verificar que a dispersão entre as diferentes velocidades foi minimizada, reduzindo o impacto da velocidade sobre os dados inerciais. É importante destacar que a mesma abordagem ISIT, também foi aplicada à velocidade angular no eixo Y, cujos dados inerciais reais e transformados podem ser visualizados no Apêndice B.

### 8.4.2 Análise quantitativa

Neste experimento é avaliada a qualidade da abordagem ISIT proposta, quantitativamente. Para isso, é calculada a variação da magnitude (desvio da média) para cada conjunto de dados inerciais (área 1, área 2 e área 3) e para cada velocidade (baixa, média e alta). Por exemplo, na área 1 foram adquiridos dados inerciais utilizando três diferentes velocidades (baixa, média e alta). Com isso, é computada a variação da magnitude do sinal inercial para as velocidades baixa, média e alta, resultando em três medidas de variação de magnitude por área.

Posteriormente, uma medida de dispersão é então aplicada para quantificar a diferença entre as variações de magnitudes nas diferentes velocidades. Com isso, é possível medir quão similar são os dados inerciais reais, coletados em diferentes velocidades, e os dados inerciais transformados, em velocidade constante. Dessa forma, a dispersão das magnitudes inerciais deve ser compreendida como uma medida que computa o grau de similaridade entre dados inerciais adquiridos em diferentes velocidades (reais) e os dados inerciais transformados.

A Tabela 8.1 apresenta a dispersão das magnitudes inerciais, para acelerações lineares no eixo Z, capturadas pela IMU, e a Tabela 8.2 apresenta a dispersão das magnitudes inerciais, para velocidades angulares no eixo Y, capturadas pela IMU. Nas

Tabelas 8.1 e 8.2, as referidas dispersões das magnitudes inerciais são calculadas a partir de sinais inerciais reais, onde quanto menor for o valor de dispersão, menor o impacto da velocidade sobre os diferentes dados inerciais. Observando as Tabelas 8.1 e 8.2, é possível verificar que para os sinais reais, em cada área, foram obtidas altas dispersões de magnitude, indicando que ao aumentar a velocidade do veículo, maior será a diferença entre as magnitudes.

Tabela 8.1: Dispersão das magnitudes de dados inerciais reais, para acelerações lineares no eixo Z, capturados em diferentes áreas e aplicando diferentes velocidades.

	Área 1	Área 2	Área 3
<b>Dispersão das magnitudes de dados inerciais</b>	210.982	279.043	78.664

Tabela 8.2: Dispersão das magnitudes de dados inerciais reais, para velocidades angulares no eixo Y, capturados em diferentes áreas e aplicando diferentes velocidades.

	Área 1	Área 2	Área 3
<b>Dispersão das magnitudes de dados inerciais</b>	0.88163	1.43025	0.36796

Para dados inerciais transformados, espera-se que a dispersão das magnitudes de dados inerciais seja menor do que para dados inerciais reais, uma vez que as magnitudes transformadas são normalizadas para uma velocidade constante.

Três modelos de regressão são utilizados para avaliar o desempenho da abordagem ISIT. O modelo preditivo proposto (regressão polinomial de 2<sup>a</sup> ordem) e os outros dois modelos de *baseline* (regressão polinomial de 3<sup>o</sup> grau e regressão *Random Forest*) são usados para treinar o modelo ISIT. Cada modelo de predição é treinado a partir dos dados inerciais reais, correspondendo a uma área (por exemplo, área 1). Em seguida, o modelo preditivo treinado é usado para transformar os dados inerciais reais correspondendo às outras duas áreas (por exemplo, área 2 e área 3).

As Tabelas 8.3 e 8.4 apresentam as dispersões das magnitudes inerciais transformadas, considerando acelerações lineares no eixo Z e velocidades angulares no eixo Y, respectivamente. Observando as tabelas referentes aos dados inerciais reais (Tabelas 8.1 e 8.2) e as tabelas referentes aos dados inerciais transformados (Tabelas 8.3 e 8.4), é possível verificar que os dados inerciais transformados, para todos os modelos preditivos, apresentaram menor dispersão de magnitudes do que os dados inerciais reais. Em outras palavras, após a transformação invariante a velocidade, os diferentes dados inerciais se tornaram mais semelhantes em relação à variação de magnitude, independente da velocidade inicial aplicada. A Tabela 8.3 mostra que o modelo ISIT proposto (regressão polinomial de 2<sup>o</sup> grau) apresenta medidas de dispersão mais baixas em sete



dos nove cenários. Enquanto a Tabela 8.4 mostra que o modelo ISIT proposto (regressão polinomial de 2<sup>o</sup> grau) apresenta medidas de dispersão mais baixas em seis dos nove cenários.

Tabela 8.3: Dispersão das magnitudes de dados inerciais transformados, considerando acelerações lineares no eixo Z, capturados em diferentes áreas e aplicando diferentes velocidades.

		Teste			
		Área 1	Área 2	Área 3	
Polinomial de 2 <sup>a</sup> ordem	Treino	Área 1	2.022	28.394	2.425
		Área 2	2.294	32.847	1.853
		Área 3	2.181	28.572	2.277
Polinomial de 3 <sup>a</sup> ordem	Treino	Área 1	2.024	28.909	2.232
		Área 2	2.338	34.345	2.897
		Área 3	2.540	30.748	2.432
Random Forest	Treino	Área 1	2.187	31.673	2.108
		Área 2	2.622	37.129	0.922
		Área 3	2.318	32.049	2.789

Tabela 8.4: Dispersão das magnitudes de dados inerciais transformados, considerando velocidades angulares no eixo Y, capturados em diferentes áreas e aplicando diferentes velocidades.

		Teste			
		Área 1	Área 2	Área 3	
Polinomial de 2 <sup>a</sup> ordem	Treino	Área 1	0.00140	0.00085	0.02226
		Área 2	0.00131	0.00649	0.02071
		Área 3	0.00114	0.00107	0.02266
Polinomial de 3 <sup>a</sup> ordem	Treino	Área 1	0.00136	0.00156	0.02292
		Área 2	0.00451	0.00572	0.02090
		Área 3	0.00349	0.00010	0.02311
Random Forest	Treino	Área 1	0.00183	0.00116	0.01582
		Área 2	0.00141	0.00605	0.01941
		Área 3	0.00118	0.00325	0.02297

## 8.5 Avaliação da classificação do nível de rugosidade

Para validar o processo de classificação do nível de rugosidade de terrenos em ambientes externos foram consideradas duas avaliações. A primeira avaliação irá verificar as taxas de acerto para velocidades individuais. Enquanto a segunda avaliação irá apresentar

e discutir as matrizes de confusão referentes ao processo de classificação do nível de rugosidade.

### 8.5.1 Acurácia da classificação com velocidades individuais

Neste experimento, consideramos o primeiro ambiente externo. Dados inerciais correspondentes a cinco terrenos diferentes foram coletados com os respectivos níveis de rugosidade (NR), mostrados na Figura 8.2. Para este experimento foram realizadas três execuções, cada exec. utilizando três velocidades (aproximadamente 0.4, 0.6 e 0.8 m/s), resultando em nove conjuntos de dados inerciais.

Cada terreno representa um nível de rugosidade pré-definido, correspondendo aos rótulos do processo de classificação, utilizados para treinar o classificador de nível de rugosidade. Este experimento avalia a precisão do processo de classificação do nível de rugosidade proposto. Nesta avaliação, para um mesmo ambiente e uma mesma velocidade, um conjunto de dados inerciais (por exemplo: exec. 1) é usado para treinar o modelo de classificação do nível de rugosidade. Os outros dois conjuntos de dados inerciais (por exemplo: exec. 2 e exec. 3) são utilizados para testar o modelo. Além disso, três diferentes modelos de classificação são avaliados: *i*) *Random Forest*; *ii*) *Ada Boosting*; e *iii*) *SVM*. Esses modelos de classificação foram utilizados devido aos bons resultados obtidos no contexto de classificação de terrenos externos [Otte et al., 2015] [Dutta & Dasgupta, 2017] [Wang et al., 2017].

A Tabela 3 mostra os resultados da classificação do nível de rugosidade. Os resultados mostram que o modelo proposto de classificação usando *Random Forest* supera os demais classificadores, para velocidades de 0.4 e 0.6 m/s. Para a velocidade de 0.8 m/s, o modelo proposto supera os demais classificadores em 8 cenários, enquanto o *SVM* apresenta melhor resultado em um único cenário. O modelo de classificação proposto, aplicando velocidade de 0.4 m/s, atinge uma precisão média de 93.9%, com um desvio padrão de 0.020. Para a velocidade de 0.6 m/s, a precisão média é de 95.4%, com um desvio padrão de 0.006. Finalmente, para 0.8 m/s, a precisão média é de 84.1%, com um desvio padrão de 0.063. Dentre os classificadores apresentados como *baseline*, o modelo *SVM* obteve os resultados mais próximos. O *SVM*, aplicando velocidade de 0.4 m/s, atingiu precisão média de 89.4%, com um desvio padrão de 0.020. Para a velocidade de 0.6 m/s, a precisão média foi de 86.9%, com um desvio padrão de 0.013. Por fim, para 0.8 m/s, a precisão média obtida foi de 79.6%, com um desvio padrão de 0.042.

Tabela 8.5: Resultados da classificação do nível de rugosidade em terrenos externos. Neste experimento é apresentada a acurácia dos classificadores Random Forest, Ada Boosting e SVM, em relação a três velocidades diferentes, para cada execução.

		<b>Veloc.</b>		<b>Teste</b>			
<b>Random Forest</b>	<b>0.4 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
			<b>exec. 1</b>	1.000	0.946	0.908	
			<b>exec. 2</b>	0.954	1.000	0.913	
				<b>exec. 3</b>	0.960	0.955	1.000
	<b>0.6 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
			<b>exec. 1</b>	1.000	0.953	0.949	
			<b>exec. 2</b>	0.961	1.000	0.946	
				<b>exec. 3</b>	0.964	0.953	1.000
	<b>0.8 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
<b>exec. 1</b>			1.000	0.816	0.933		
<b>exec. 2</b>			0.784	1.000	0.777		
			<b>exec. 3</b>	0.923	0.812	1.000	
<b>Ada Boosting</b>	<b>0.4 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
			<b>exec. 1</b>	0.859	0.837	0.786	
			<b>exec. 2</b>	0.888	0.913	0.849	
				<b>exec. 3</b>	0.519	0.503	0.538
	<b>0.6 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
			<b>exec. 1</b>	0.844	0.839	0.802	
			<b>exec. 2</b>	0.886	0.891	0.869	
				<b>exec. 3</b>	0.782	0.793	0.789
	<b>0.8 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
<b>exec. 1</b>			0.792	0.712	0.772		
<b>exec. 2</b>			0.619	0.684	0.638		
			<b>exec. 3</b>	0.802	0.782	0.836	
<b>SVM</b>	<b>0.4 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
			<b>exec. 1</b>	0.999	0.933	0.891	
			<b>exec. 2</b>	0.903	0.999	0.870	
				<b>exec. 3</b>	0.878	0.889	0.999
	<b>0.6 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
			<b>exec. 1</b>	1.000	0.893	0.848	
			<b>exec. 2</b>	0.871	1.000	0.866	
				<b>exec. 3</b>	0.864	0.873	1.000
	<b>0.8 m/s</b>	<b>Treino</b>		<b>exec. 1</b>	<b>exec. 2</b>	<b>exec. 3</b>	
<b>exec. 1</b>			1.000	0.751	0.843		
<b>exec. 2</b>			0.779	0.999	0.779		
			<b>exec. 3</b>	0.863	0.758	1.000	

### 8.5.2 Matrizes de confusão

Para avaliar o processo de classificação do nível de rugosidade, ainda considerando velocidades individuais, também foram utilizadas matrizes de confusão. As matrizes de confusão propiciam a visualização completa da distribuição de respostas do classificador, sendo possível identificar os falso-positivos e em quais classes os mesmos ocorreram.

Neste experimento foram computadas as matrizes de confusão para todos os modelos de classificação utilizados, em cada conjunto de velocidades. Na Tabela 8.6 são apresentadas somente as matrizes de confusão obtidas pelo melhor modelo de classificação, com o classificador proposto *Random Forest*. As matrizes de confusão computadas para os demais modelos de classificação podem ser visualizadas no Apêndice C.

Tabela 8.6: Matrizes de confusão computadas pelo classificador *Random Forest* (RF), com variação de velocidade. Neste experimento, os modelos de classificação treinados consideram 5 níveis de rugosidade, porém os dados de teste consideram apenas 3 níveis de rugosidade (NR), em 3 velocidades distintas (0.4, 0.6 e 0.8 m/s).

		Estimado						
Esperado	Classificador	Níveis de Rugosidade	NR 1	NR 2	NR 3	NR 4	NR 5	
		0.4 m/s	RF	NR 1	0	0	0	0
NR 2			0	20401	220	97	0	
NR 3			0	262	36702	0	0	
NR 4			0	2468	207	5170	0	
NR 5			0	0	0	0	0	
0.6 m/s		RF	NR 1	0	0	0	0	0
		NR 2	0	13820	61	100	0	
		NR 3	0	471	24376	1	0	
		NR 4	0	962	273	3862	0	
		NR 5	0	0	0	0	0	
0.8 m/s		RF	NR 1	0	0	0	0	0
		NR 2	0	10599	407	186	0	
		NR 3	0	177	20098	3	0	
		NR 4	0	1372	120	2926	0	
		NR 5	0	0	0	0	0	

Observando as matrizes de confusão expostas na Tabela 8.6, é possível verificar erros de classificação. Para este experimento foram considerados três níveis de rugosidade (NR2, NR3 e NR4) para teste, onde em alguns trechos os níveis de rugosidade são classificados incorretamente. Um dos principais motivos para os erros mencionados consiste na presença de irregularidades (cavidades ou elevações) no terreno. Dessa

forma, quando o veículo navega sobre essa irregularidade causa uma grande oscilação na aceleração vertical, que é classificada como um nível de rugosidade que não corresponde ao terreno percorrido.

A Figura 8.7, mostra o problema supracitado, onde para um mesmo terreno há uma grande irregularidade, que impacta significativamente o dado inercial capturado. A Figura 8.7a apresenta uma cavidade acentuada, enquanto a Figura 8.7b mostra uma elevação proeminente.



(a) Exemplo de cavidade no terreno.



(b) Exemplo de elevação no terreno.

Figura 8.7: Diferentes tipos de irregularidades (cavidades e elevações) encontradas nos terrenos durante a navegação.

## 8.6 Avaliação do mapeamento do custo de navegação

Para validar a etapa de mapeamento do custo de navegação em ambientes externos, serão realizados alguns experimentos no intuito de avaliar a qualidade dos mapas tridimensionais incrementados com custo de navegação do terreno. Para isso, os experimentos serão divididos em duas partes. A primeira parte irá avaliar os mapas tridimensionais incrementados com custo de navegação qualitativamente, enquanto a segunda parte irá avaliar os referidos mapas quantitativamente.

Neste experimento, foram coletados dados providos por um *laser* e uma IMU, considerando o segundo ambiente externo. Além disso, a localização do robô foi computada durante toda a movimentação do veículo. A Figura 8.8 mostra as áreas utilizadas neste experimento e apresenta as trajetórias percorridas em cada cenário. A Figura 8.8a corresponde a todo o segundo ambiente, exceto a área 2. Para este experimento as áreas contempladas na Figura 8.8a serão chamadas de Área 4. A Figura 8.8b corresponde à

área 2, contida no segundo ambiente externo. As Figuras 8.8c e 8.8d correspondem às trajetórias percorridas pelo robô nas áreas 4 e 2, respectivamente.



Figura 8.8: Ambientes utilizados neste experimento, com diferentes níveis de rugosidade e inclinação. As Figuras 8.8a e 8.8b apresentam as áreas 4 e 2, utilizadas neste experimento, respectivamente. As Figuras 8.8c e 8.8d apresentam as trajetórias percorridas pelo robô durante a navegação pelas áreas 4 e 2, respectivamente.

### 8.6.1 Análise qualitativa

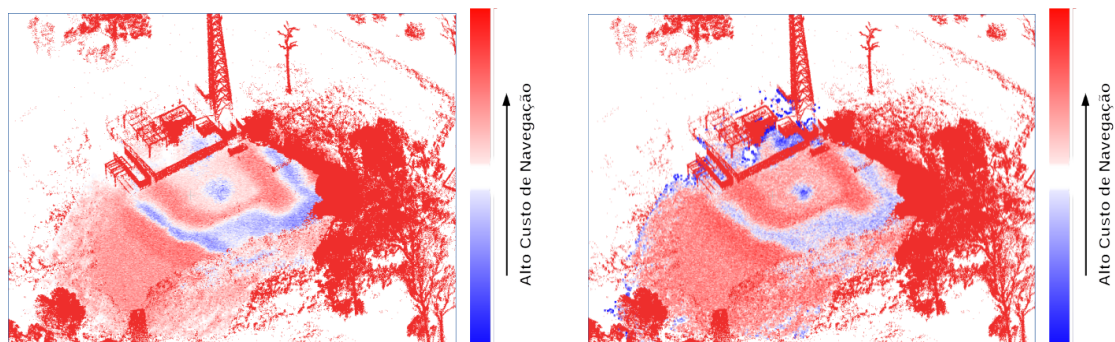
Neste experimento foram avaliados os mapas tridimensionais incrementados com o custo de navegação estimados, realizando a verificação visual dos mapas obtidos. Para isso, foram computados mapas de custo de terrenos externos considerando a técnica de predição de custo de navegação proposta (modelo preditivo baseado em CNN) e a técnica de predição *baseline* (modelo preditivo baseado em *Random Forest*). A técnica *baseline* foi utilizada devido aos bons resultados obtidos no contexto de predição em análise de terrenos externos [Ono et al., 2015].

A partir dos resultados apresentados na Figura 8.9, é possível verificar a qualidade do mapa de custo de navegação gerado pela abordagem proposta usando o modelo preditivo baseado em CNN. Os resultados alcançados ocorreram, pois a arquitetura

de aprendizado profundo proposta apresenta grande capacidade de aprender diferentes tipos de filtros. Os filtros aprendidos são combinados para detectar padrões como bordas, cores, grau de desfocagem e etc. Por fim, os filtros mencionados são usados para ajustar um modelo preditivo eficiente, a partir do conjunto de representações bidimensionais do terreno, fornecido como entrada.



(a) Principais características do terreno.



(b) Mapa aumentado com custo de navegação, computado a partir do modelo preditivo proposto.

(c) Mapa aumentado com custo de navegação, computado a partir do modelo preditivo *baseline*.

Figura 8.9: Apresentação das principais características do terreno, contidas na área 2, do segundo ambiente. Adicionalmente, são apresentados os mapas tridimensionais aumentados com custo de navegação, criados a partir de diferentes modelos preditivos. A Figura 8.9a apresenta as características de rugosidade e inclinação presentes na área 2. Na Figura 8.9b é apresentado o mapa aumentado com custo de navegação, computado a partir do modelo preditivo proposto, baseado em aprendizado profundo. Enquanto a Figura 8.9c apresenta o mapa aumentado com custo de navegação, computado a partir do modelo preditivo *baseline*.

A Figura 8.9a apresenta as regiões contendo as principais características do terreno, tais como rugosidade e inclinação. Considerando as características apresentadas, é possível verificar se os mapas criados representam adequadamente o terreno ou não. Na Figura 8.9b é apresentado o mapa aumentado com custo de navegação, estimado a partir do modelo preditivo proposto, para a área 2. Na Figura 8.9c é apresentado o mapa aumentado com custo de navegação, estimado a partir do modelo *baseline* utilizado, também para a área 2. Nos referidos mapas (Figuras 8.9b e 8.9c), quanto mais vermelha for a região, maior o custo de navegação da mesma. Quanto mais azul for a região, menor o custo de navegação da mesma.

Confrontando a Figura 8.9c com a Figura 8.9a, é possível verificar que: *i*) em algumas regiões nas extremidades do terreno foram estimados baixo custo de navegação, de maneira incorreta; *ii*) a região plana, apresentada na Figura 8.9a, não foi devidamente representada no mapa computado; e *iii*) as transições entre baixo custo de navegação e alto custo de navegação foram abruptas, resultando em um mapa que não representa a superfície a ser mapeada, com qualidade. Enquanto isso, confrontando o resultado obtido e apresentado na Figura 8.9b com a Figura 8.9a, é possível verificar que: *i*) a região plana, destacada na Figura 8.9a, foi representada de maneira mais homogênea, se aproximando do resultado esperado; *ii*) os custos de navegação intermediários demonstram maior suavidade na transição entre os custos de navegação extremos. Principalmente, considerando as inclinações presentes no terreno; e *iii*) além de representar corretamente as regiões com características de rugosidade presentes no terreno, resultando em uma representação do terreno, de qualidade.

## 8.6.2 Análise quantitativa

Para avaliar quantitativamente os mapas de terreno incrementados com custo de navegação, foram analisados os custos dos caminhos planejados, a partir de mapas criados por meio da técnica de predição proposta e da técnica de predição *baseline*. Para realizar o planejamento de caminho foi utilizado o algoritmo Dijkstra, representando as coordenadas do mapa tridimensional aumentado com custo de navegação, como um grafo. Para reduzir a quantidade total de arestas do grafo do terreno, a vizinhança de cada ponto é limitada por uma distância máxima entre vizinhos.

A avaliação neste experimento verifica a capacidade de criação de mapas de custo, que permitam uma navegação eficiente pelo ambiente externo, ou seja permitindo encontrar os caminhos mais eficientes. Para isso, foram definidos dez pares de pontos que representam a origem e o destino de cada caminho, cinco pares de pontos para área 4 e cinco pares de pontos para área 2. A Tabela 8.7 mostra os custos dos cami-



nhos obtidos, considerando os cinco caminhos de cada área, tanto para a abordagem de predição proposta, quanto para a abordagem de predição *baseline*. Observando a referida tabela é possível verificar que os custos dos caminhos calculados a partir da abordagem proposta, usando CNN, são inferiores aos custos dos caminhos calculados a partir da abordagem *baseline*.

Isso ocorre porque os mapas incrementados com custo de navegação propostos apresentam uma representação do ambiente mais acurada do que a abordagem *baseline*. Com isso, promove uma análise mais eficiente do terreno para aplicações envolvendo navegação de veículos terrestres.

Tabela 8.7: Custos dos caminhos gerados pelo algoritmo de planejamento de caminho (Dijkstra), considerando diferentes modelos preditivos em diferentes cenários.

Custos dos caminhos				
Caminhos	Baseline		Abordagem proposta	
	Área 4	Área 2	Área 4	Área 2
<b>1</b>	0.41	0.19	0.40	0.13
<b>2</b>	1.00	0.89	0.58	1.00
<b>3</b>	0.64	1.00	0.35	0.82
<b>4</b>	0.67	0.76	0.33	0.49
<b>5</b>	0.96	0.46	1.00	0.22

## 8.7 Avaliação da efetividade do mapeamento de terrenos externos

Para complementar a validação da etapa de mapeamento do custo de navegação em ambientes externos, será realizado um experimento no intuito de avaliar a efetividade dos mapas tridimensionais incrementados com custo de navegação do terreno. Este experimento se concentra em avaliar a eficácia da abordagem de mapeamento de terrenos proposta, no contexto de navegação em ambientes externos. Para isso, é avaliado o uso dos mapas de custo de navegação obtidos para o processo de planejamento de caminhos em ambientes externos. Dessa forma, são comparados os custos dos caminhos considerando apenas a distância e os custos dos caminhos considerando as características do terreno. Para a realização deste experimento foram considerados os mesmos ambientes, dados adquiridos e condições definidas na Seção 8.6.

Para este experimento foram definidos cinco pares de pontos representando a origem e o destino de cada caminho, com dois pares de pontos para a área 4 e três pares

de pontos para a área 2. Para a operação de planejamento de caminho foi utilizado o algoritmo Dijkstra. Duas versões do referido algoritmo foram adaptadas para: *i*) tomar decisões baseadas na distância até o ponto de destino, porém computando o custo final do caminho baseado no custo de navegação do terreno; e *ii*) tomar decisões baseadas no custo de navegação do terreno, computando o custo final do caminho baseado no próprio custo de navegação do terreno.

A partir das duas abordagens propostas para planejamento de caminho, são comparados os custos de navegação de cada trajeto. Na Figura 8.10, é apresentado o mapa tridimensional incrementado com custo de navegação, referente à área 4. Considerando o mapa de custo de navegação da área 4, foram computados dois trajetos: *i*) um baseado em distância (cor verde); e *ii*) um baseado no custo de navegação (cor laranja). O comprimento do caminho considerando apenas a distância é de 407.08 metros, enquanto o comprimento do caminho considerando apenas o custo de navegação é de 425.72 metros. O custo final do caminho, baseado no custo de navegação do terreno, considerando apenas a distância é 488.15, enquanto o custo final do caminho considerando apenas o custo da navegação é 5.81.

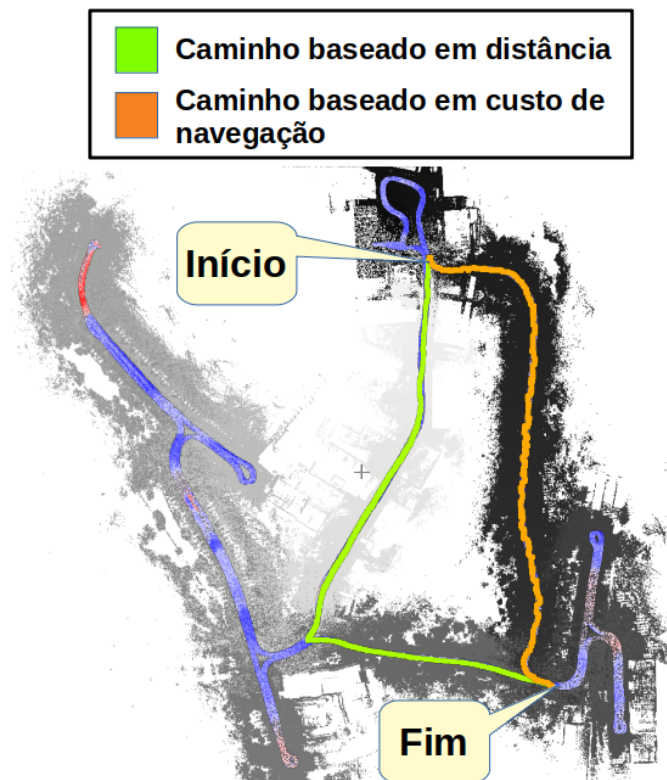


Figura 8.10: Caminhos computados a partir do mapa tridimensional incrementado com custo de navegação proposto. Para o par de pontos de origem e destino, destacados na imagem, são computados: *i*) um caminho baseado em distância (cor verde); e *ii*) um caminho baseado no custo de navegação do terreno (cor laranja).

Considerando o exposto (Figura 8.10) é possível verificar que, embora o trajeto baseado no custo de navegação (cor laranja) apresente maior comprimento, é trivial constatar que seu custo de navegação é significativamente mais baixo do que o custo de navegação do trajeto baseado em distância (cor verde). Em uma análise mais simplista, observa-se que o menor caminho não resultou em um trajeto mais seguro para o veículo ou para a tarefa, indicando que a combinação de ambas as informações pode fornecer uma representação mais acurada para ambientes externos.

Adicionalmente, na Figura 8.11 são observadas as medidas de custo de navegação durante o movimento do robô, em relação a diferentes aspectos do planejamento de trajetória. Na Figura 8.11 é demonstrado que levar em consideração apenas a distância para navegar em um ambiente não estruturado não é razoável.

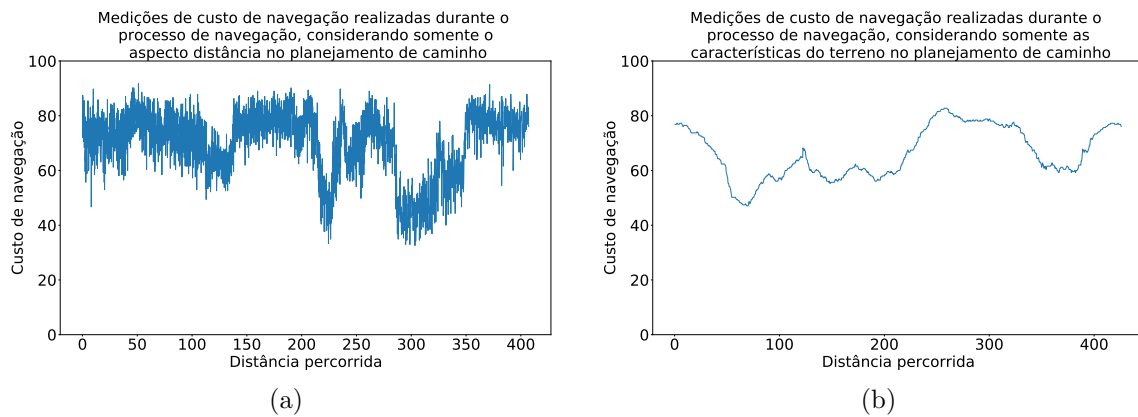


Figura 8.11: Custos de navegação computados durante a navegação do robô, em processo de planejamento de caminho, considerando somente o aspecto distância (a) e considerando somente características do terreno (b).

Para uma análise quantitativa deste experimento, a Tabela 8.8 apresenta os custos dos caminhos, baseados em distância e baseados no custo de navegação do terreno. Observando a Tabela 8.8, é possível verificar que os caminhos planejados considerando apenas a informação de distância, apresentaram os maiores custos finais. Nesse sentido, considerando os experimentos realizados e os resultados obtidos, podemos afirmar que a utilização de mapas tridimensionais aumentados com custo de navegação aumenta a eficiência e a segurança da navegação de robôs terrestres em ambientes externos.

Tabela 8.8: Custos dos caminhos gerados pelo algoritmo de planejamento de caminho (Dijkstra), considerando diferentes métricas (distância e custo de navegação) para tomada de decisão, em diferentes cenários.

Custos dos caminhos			
	Área	Distância	Custo de navegação
	4	488.15	5.81
	4	74.35	2.31
<b>Caminhos</b>	<b>2</b>	91.91	8.42
	<b>2</b>	35.23	5.72
	<b>2</b>	51.85	4.20

# Capítulo 9

## Conclusões e Trabalhos Futuros

### 9.1 Conclusões

Este trabalho aborda o problema de mapeamento tridimensional aumentado com custo de navegação através de aprendizado profundo. Para isso, foram tratados diferentes subproblemas relacionados, que ao serem combinados permitem a resolução do problema principal. Os subproblemas são: *i*) transformação dos dados inerciais tornando-os invariantes a velocidade; *ii*) classificação dos níveis de rugosidade de ambientes externos; *iii*) estimação do custo de navegação a partir de dados inerciais; *iv*) fusão entre múltiplos sensores usando aprendizado profundo; e *v*) mapeamento tridimensional do custo de navegação.

Para cada subproblema mencionado foram propostas diferentes metodologias. Para a transformação dos dados inerciais, foi proposta uma abordagem que transforma os dados inerciais, coletados em diferentes velocidades, em dados inerciais como se tivessem sido coletados em velocidade constante. Para a classificação dos níveis de rugosidade, foi proposta uma estratégia que representa o sinal inercial, no domínio da frequência, e o classifica em um nível de rugosidade conhecido. A estimação do custo de navegação proposta é baseada em uma função de custo que combina o nível de rugosidade e as orientações do veículo (*roll* e *pitch*), em uma representação de alto nível do custo de navegar pelo ambiente externo. A combinação entre múltiplos sensores (*laser* e IMU) é realizada para estimar o custo de navegação de regiões não visitadas pelo veículo terrestre. Para isso, foi proposta uma metodologia baseada em aprendizado profundo, que aprende a relação entre a representação geométrica e o custo de navegação de terrenos, a partir de dados inerciais. Por fim, foi proposta a estratégia de mapeamento tridimensional do ambiente externo, aumentado com o custo de navegação do terreno.

A partir de uma detalhada análise experimental foi possível verificar que: *i*) a transformação dos dados inerciais reduziu o impacto da velocidade sobre os dados inerciais. Adicionalmente, foi possível verificar que, mesmo os dados de treino e teste pertencendo a domínios diferentes, a transformação dos dados ainda apresenta desempenho significativo; *ii*) a classificação dos níveis de rugosidade proposta mostrou-se eficiente para diferentes níveis de rugosidade, apresentando a melhor acurácia média de 95.4%, com desvio padrão de 0.006, ao aplicar a velocidade 0.6 m/s; *iii*) os mapas tridimensionais aumentados com custo de navegação apresentaram boa representação do ambiente externo, resultando em custos de caminhos menores do que os custos de caminhos obtidos a partir de mapas gerados pela técnica *baseline*; e *iv*) os mapas de terrenos com custo de navegação agregaram informação complementar e útil para a navegação. Com isso, permitem que o processo de tomada de decisão de técnicas de planejamento de caminho levem em consideração as características do terreno e não apenas obstáculos. Também foi possível observar que durante a navegação, considerar apenas obstáculos não resulta em uma navegação segura para o veículo ou até mesmo viável.

Dentre as principais desvantagens da metodologia proposta estão: *i*) o mapeamento tridimensional aumentado com custo de navegação de ambientes externos é *offline*. Embora todo o processo de estimação do custo de navegação a partir de dados inerciais seja *online*; *ii*) a abordagem proposta não tratou o problema de variação do tamanho do veículo e seus impactos na análise de dados inerciais; *iii*) a classificação dos níveis de rugosidade é limitada à quantidade de classes definidas no processo de treinamento do classificador; e *iv*) a função de transformação dos dados inerciais deve ser treinada para cada veículo utilizado.

Considerando o exposto, é possível concluir que a abordagem proposta para mapear terrenos em ambientes externos apresenta boa representação dos custos de navegação do ambiente, permitindo sua aplicação em cenários reais. Adicionalmente, a técnica de mapeamento proposta resulta em significativa melhoria ao processo de navegação autônoma em ambientes externos. Isso ocorre pois, a partir dos mapas propostos é possível determinar caminhos que considerem tanto os obstáculos presentes na cena, quanto as características dos terrenos contidos na cena. A qualidade dos mapas obtidos, foi resultado da combinação entre diferentes sensores (*laser* e IMU), que proveram informações complementares de qualidade. Com isso, a aplicação de uma CNN para prever os custos de navegação, mesmo para regiões não visitadas pelo veículo, permitiram a criação de mapas com ampla cobertura do ambiente.

## 9.2 Trabalhos Futuros

A abordagem proposta neste trabalho é composta por alguns subproblemas relevantes e que ainda podem ser explorados, permitindo diversas possíveis extensões e melhorias futuras.

A primeira extensão para este trabalho seria a análise do impacto da variação do tamanho, massa e torque de veículos terrestres na captura de dados inerciais. Com isso, seria possível avaliar a relação entre os dados inerciais e os fatores relacionados às características dos veículos utilizados, para criar uma estratégia que torne os dados inerciais invariantes às propriedades do veículo. Até o presente momento, não foram encontrados trabalhos na literatura que tratem o referido problema. Uma possível solução para este problema consiste na captura de dados inerciais utilizando veículos com diferentes características, em um mesmo ambiente e aplicando a mesma velocidade, para investigar o modelo matemático que melhor representa o comportamento entre as diferentes propriedades de veículos.

Outra possível extensão para o presente trabalho consiste em incorporar mais sensores ao processo de mapeamento, por exemplo: câmeras. A adição de câmeras ao processo de mapeamento proposto agregaria mais uma informação complementar, contribuindo na melhor representação das características dos terrenos explorados. A partir da informação visual dos terrenos, tanto características geométricas quanto características visuais (textura, cor, forma, dentre outras características) poderiam ser utilizadas para aumentar a confiança do modelo de predição dos custos de navegação do ambiente externo mapeado.

Uma extensão deste trabalho que traria grande benefício ao processo de mapeamento de terrenos, seria a transformação da abordagem *offline* proposta em uma abordagem de mapeamento *online*. Adicionalmente, seria realizada uma análise sobre os impactos ao utilizar as abordagens *offline* e *online*, tendo em vista que a abordagem *online* apresenta uma limitação crítica de processamento das nuvens de pontos coletadas durante a movimentação do robô. Uma possível solução para este problema deve investigar os impactos da redução de pontos, coletados pelo *laser*, na qualidade dos mapas de custo de navegação propostos.

Por fim, outra extensão interessante seria tornar o processo de mapeamento proposto autônomo. Para isso, seria realizada a investigação de técnicas de exploração autônoma para ambientes externos. Com isso, seria possível definir um conjunto de pontos de referência a serem seguidos pelo veículo ou pontos de referência definindo a extensão da área a ser mapeada. Assim, o veículo poderia navegar de maneira autônoma pelo ambiente realizando o mapeamento dos custos de navegação.

# Referências Bibliográficas

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Springer, Cham. ISBN 978-3-319-94462-3.
- Bai, C.; Guo, J. & Zheng, H. (2019). Three-dimensional vibration-based terrain classification for mobile robots. *IEEE Access*, 7:63485–63492.
- Ben-Ari, M. & Mondada, F. (2017). *Elements of Robotics*. Springer International Publishing. ISBN 9783319625331.
- Besl, P. J. & McKay, N. D. (1992). A method for registration of 3-d shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2):239–256.
- Bosse, M. & Zlot, R. (2009). Continuous 3d scan-matching with a spinning 2d laser. Em *IEEE Int. Conf. on Robotics and Automation*, pp. 4312–4319.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- Brooks, C. A. & Iagnemma, K. D. (2007). Self-supervised classification for planetary rover terrain sensing. Em *2007 IEEE Aerospace Conference*, pp. 1–9. ISSN 1095-323X.
- C. Ward, C. & Iagnemma, K. (2009). Speed-independent vibration-based terrain classification for passenger vehicles. 47:1095–1113.
- Castelнови, M.; Arkin, R. & Collins, T. R. (2005). Reactive speed control system based on terrain roughness detection. Em *Proceedings of the 2005 IEEE International Conference on Robotics and Automation*, pp. 891–896. ISSN 1050-4729.
- Cunningham, C.; Nesnas, I. & Whittaker, W. L. (2015). Terrain traversability prediction by imaging thermal transients. Em *2015 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 3947–3952. ISSN 1050-4729.



- Dubey, G.; Korupolu, P. V. N.; Kapuria, A. & Vijay, R. (2013). Shock reduction for autonomous navigation on rough terrain: A difference of normals approach. Em *Proceedings of Conference on Advances In Robotics*, AIR '13, pp. 76:1--76:6, New York, NY, USA. ACM.
- DuPont, E. M.; Moore, C. A.; Collins, E. G. & Coyle, E. (2008). Frequency response method for terrain classification in autonomous ground vehicles. *Autonomous Robots*, 24(4):337--347. ISSN 1573-7527.
- Dutta, A. & Dasgupta, P. (2017). Ensemble learning with weak classifiers for fast and reliable unknown terrain classification using mobile robots. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(11):2933-2944. ISSN 2168-2216.
- Ertel, W. (2017). *Introduction to Artificial Intelligence*. Springer International Publishing.
- Filitchkin, P. & Byl, K. (2012). Feature-based terrain classification for littledog. Em *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 1387-1392. ISSN 2153-0858.
- Forster, C.; Pizzoli, M. & Scaramuzza, D. (2013). Air-ground localization and map augmentation using monocular dense reconstruction. Em *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3971-3978. ISSN 2153-0858.
- Forsyth, D. (2019). *Applied Machine Learning*. Springer International Publishing.
- Fujita, K. & Ichimura, N. (2015). Classifying terrain properties for planetary exploration rovers based on a combined distance measure with dynamic texture model. *Robotics and Autonomous Systems*, 70:156 - 165. ISSN 0921-8890.
- Guerrero, J. A.; Jaud, M.; Lenain, R.; Rouveure, R. & Faure, P. (2015). Towards lidar-radar based terrain mapping. Em *2015 IEEE International Workshop on Advanced Robotics and its Social Impacts (ARSO)*, pp. 1-6. ISSN .
- Guo, Y.; Song, A.; Bao, J. & Zhang, H. (2011). Optimal path planning in field based on traversability prediction for mobile robot. Em *2011 International Conference on Electric Information and Control Engineering*, pp. 563-566. ISSN .
- Harrell, F. E. (2015). *Regression Modeling Strategies*. Springer International Publishing.

- He, K.; Zhang, X.; Ren, S. & Sun, J. (2015). Deep residual learning for image recognition.
- Helmick, D.; Angelova, A. & Matthies, L. (2009). Terrain adaptive navigation for planetary rovers. *Journal of Field Robotics*, 26(4):391--410. ISSN 1556-4967.
- Häselich, M.; Arends, M.; Wojke, N.; Neuhaus, F. & Paulus, D. (2013). Probabilistic terrain classification in unstructured environments. *Robotics and Autonomous Systems*, 61(10):1051 – 1059. ISSN 0921-8890. Selected Papers from the 5th European Conference on Mobile Robots (ECMR 2011).
- Iwaszczuk, D.; Koppányi, Z.; Pfrang, J. & Toth, C. (2019). Evaluation of a mobile multi-sensor system for seamless outdoor and indoor mapping. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-1/W2:31--35.
- Jain, R. (1991). *The art of computer systems performance analysis - techniques for experimental design, measurement, simulation, and modeling*. Wiley professional computing. Wiley. ISBN 978-0-471-50336-1.
- Kim, D.; Oh, S. M. & Rehg, J. M. (2007). Traversability classification for ugv navigation: a comparison of patch and superpixel representations. Em *2007 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3166–3173. ISSN 2153-0858.
- Krizhevsky, A.; Sutskever, I. & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Em *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, NIPS'12*, p. 1097–1105, Red Hook, NY, USA. Curran Associates Inc.
- Krüsi, P.; Furgale, P.; Bosse, M. & Siegwart, R. (2017). Driving on point clouds: Motion planning, trajectory optimization, and terrain assessment in generic nonplanar environments. *J. of Field Robotics*, 34(5):940–984. ISSN 1556-4959.
- Kubat, M. (2017). *An Introduction to Machine Learning*. Springer International Publishing.
- Larson, J.; Trivedi, M. & Bruch, M. (2011). Off-road terrain traversability analysis and hazard avoidance for ugvs. *IEEE Vehicular Technology Magazine*.

- Liu, G. & Chai, S. (2019). Optimizing open-pit truck route based on minimization of time-varying transport energy consumption. *Mathematical Problems in Engineering*, 2019:1--12.
- Lu, L.; Ordonez, C.; Collins, E. G.; Coyle, E. & Palejiya, D. (2011). Terrain surface classification with a control mode update rule using a 2d laser stripe-based structured light sensor. *Robotics and Autonomous Systems*, 59(11):954 – 965. ISSN 0921-8890.
- Lv, F.; Gao, H.; Bai, Y.; Li, N.; Ding, L.; Zhou, R.; Deng, Z. & Liu, G. (2018). Extraction of speed-independent vibration features for terrain classification in lugged-wheel rovers. Em *2018 IEEE International Conference on Robotics and Biomimetics (RO-BIO)*, pp. 1580–1585.
- Lynch, K. & Park, F. (2017). *Modern Robotics: Mechanics, Planning, and Control*. Cambridge University Press. ISBN 9781316609842.
- Manduchi, R.; Castano, A.; Talukder, A. & Matthies, L. (2005). Obstacle detection and terrain classification for autonomous off-road navigation. *Autonomous Robots*, 18(1):81--102. ISSN 1573-7527.
- Martínez, J. L.; Morán, M.; Morales, J.; Robles, A. & Sánchez, M. (2020). Supervised learning of natural-terrain traversability with synthetic 3d laser scans. *Applied Sciences*, 10(3):1140.
- Milella, A.; Reina, G. & Nielsen, M. (2018). A multi-sensor robotic platform for ground mapping and estimation beyond the visible spectrum. *Precision Agriculture*, 20(2):423--444.
- Mongus, D. & Jurič, S. (2019). Generation of traversability maps based on 3d point-clouds. Em *2019 Conference on Next Generation Computing Applications (Next-Comp)*, pp. 1–5.
- Nardi, L. & Stachniss, C. (2019). Actively improving robot navigation on different terrains using gaussian process mixture models. Em *IEEE ICRA*.
- Oliveira, F. G.; Neto, A. A.; Borges, P.; Campos, M. F. M. & Macharet, D. G. (2019). Augmented vector field navigation cost mapping using inertial sensors. Em *19th Int. Conf. on Advanced Robotics (ICAR)*, pp. 388–393. ISSN null.
- Oliveira, F. G.; Neto, A. A.; Howard, D.; Borges, P.; Campos, M. F. M. & Macharet, D. G. (2021). Three-dimensional mapping with augmented navigation cost through deep learning. *Journal of Intelligent & Robotic Systems*, 101(3).

- Oliveira, F. G.; Santos, E. R. S.; Neto, A. A.; Campos, M. F. M. & Macharet, D. G. (2017). Speed-invariant terrain roughness classification and control based on inertial sensors. Em *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, pp. 1–6. ISSN .
- Ono, M.; Fuchs, T. J.; Steffy, A.; Maimone, M. & Yen, J. (2015). Risk-aware planetary rover operation: Autonomous terrain classification and path planning. Em *2015 IEEE Aerospace Conference*, pp. 1–10. ISSN 1095-323X.
- Otsu, K.; Ono, M.; Fuchs, T. J.; Baldwin, I. & Kubota, T. (2016). Autonomous terrain classification with co- and self-training approach. *IEEE Robotics and Automation Letters*, 1(2):814–819. ISSN 2377-3766.
- Otte, S.; Laible, S.; Hanten, R. & Zell, A. (2015). Robust visual terrain classification with recurrent neural networks. *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*.
- Otte, S.; Weiss, C.; Scherer, T. & Zell, A. (2016). Recurrent neural networks for fast and robust vibration-based ground classification on mobile robots. Em *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 5603–5608. ISSN .
- Papadakis, P. (2013). Terrain traversability analysis methods for unmanned ground vehicles: A survey. *Engineering Applications of Artificial Intelligence*, 26(4):1373 – 1385. ISSN 0952-1976.
- Pereira, G. A. S.; Pimenta, L. C. A.; Fonseca, A. R.; de Q. Corrêa, L.; Mesquita, R. C.; Chaimowicz, L.; de Almeida, D. S. C. & Campos, M. F. M. (2009). Robot Navigation in Multi-terrain Outdoor Environments. *The International Journal of Robotics Research*, 28(6):685–700.
- Pfrunder, A.; Borges, P. V. K.; Romero, A. R.; Catt, G. & Elfes, A. (2017). Real-time autonomous ground vehicle navigation in heterogeneous environments using a 3d LiDAR. Em *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE.
- Rao, K. R.; Kim, D. N. & Hwang, J.-J. (2010). *Fast Fourier Transform - Algorithms and Applications*. Springer Publishing Company, Incorporated, 1st edição. ISBN 1402066287, 9781402066283.

- Riopelle, N.; Caspers, P. & Sofge, D. (2018). Terrain classification for autonomous vehicles using bat-inspired echolocation. Em *2018 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–6.
- Sebastian, B.; Ren, H. & Ben-Tzvi, P. (2019). Neural network based heterogeneous sensor fusion for robot motion planning. Em *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE.
- Siciliano, B. & Khatib, O. (2007). *Springer Handbook of Robotics*. Springer-Verlag, Berlin, Heidelberg. ISBN 354023957X.
- Simonyan, K. & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition.
- Skansi, S. (2018). Introduction to deep learning: From logical calculus to artificial intelligence.
- Sock, J.; Kim, J.; Min, J. & Kwak, K. (2016). Probabilistic traversability map generation using 3d-lidar and camera. Em *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 5631–5637. ISSN .
- Souza, J. R.; Marchant, R.; Ott, L.; Wolf, D. F. & Ramos, F. (2014). Bayesian optimisation for active perception and smooth navigation. Em *2014 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 4081–4087. ISSN 1050-4729.
- Stavens, D.; Hoffmann, G. & Thrun, S. (2007). Online speed adaptation using supervised learning for high-speed, off-road autonomous driving. Em *Proceedings of the 20th International Joint Conference on Artificial Intelligence, IJCAI'07*, pp. 2218–2224, San Francisco, CA, USA. Morgan Kaufmann Publishers Inc.
- Suger, B.; Steder, B. & Burgard, W. (2015). Traversability analysis for mobile robots in outdoor environments: A semi-supervised learning approach based on 3d-lidar data. Em *2015 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 3941–3946. ISSN 1050-4729.
- Tanaka, Y.; Ji, Y.; Yamashita, A. & Asama, H. (2015). Fuzzy based traversability analysis for a mobile robot on rough terrain. Em *2015 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 3965–3970. ISSN 1050-4729.
- Thorpe, C. E. & Durrant-Whyte, H. F. (2001). Field robots. Em *ISRR*.

- Thrun, S.; Montemerlo, M.; Dahlkamp, H.; Stavens, D.; Aron, A.; Diebel, J.; Fong, P.; Gale, J.; Halpenny, M.; Hoffmann, G.; Lau, K.; Oakley, C.; Palatucci, M.; Pratt, V.; Stang, P.; Strohband, S.; Dupont, C.; Jendrossek, L.-E.; Koelen, C.; Markey, C.; Rummel, C.; van Niekerk, J.; Jensen, E.; Alessandrini, P.; Bradski, G.; Davies, B.; Ettinger, S.; Kaehler, A.; Nefian, A. & Mahoney, P. (2006). Stanley: The robot that won the darpa grand challenge: Research articles. *J. Robot. Syst.*, 23(9):661–692. ISSN 0741-2223.
- Wang, S.; Kodagoda, S.; Shi, L. & Wang, H. (2017). Road-terrain classification for land vehicles: Employing an acceleration-based approach. *IEEE Vehicular Technology Magazine*, 12(3):34–41. ISSN 1556-6072.
- Weik, M. H. (2001). *Nyquist theorem*, pp. 1127--1127. Springer US, Boston, MA.
- Zhang, H.; Dai, X.; Sun, F. & Yuan, J. (2016). Terrain classification in field environment based on random forest for the mobile robot. Em *2016 35th Chinese Control Conference (CCC)*, pp. 6074–6079. ISSN .

# Apêndice A

## Mapeamento de ambientes externos baseado em vector fields usando sensores inerciais

Neste Apêndice, é apresentada uma abordagem para a criação de mapas de custos de navegação usando apenas dados inerciais. Os mapas representam os terrenos em ambientes externos e fornecem informações complementares para melhorar as técnicas de navegação autônoma baseadas apenas em sensores exteroceptivos. Foi proposta uma representação do ambiente externo aumentada com *vector fields*, chamada Augmented Vector Field (AVF), por meio da estimativa de rugosidade do terreno e das informações de *attitude* do robô. Também foi introduzida uma estratégia de propagação baseada na técnica de Processo Gaussiano (*Gaussian Process*, ou GP), para obter uma estimativa mais eficiente do mapa para áreas maiores. Experimentos em cenários reais e simulações mostram que os mapas obtidos são precisos e aplicáveis no processo de navegação.

### A.1 Metodologia

A técnica proposta de mapeamento AVF tem o objetivo de mapear o custo de navegação, a partir de dados inerciais, representando as características contidas em terrenos desconhecidos e não estruturados. Para atingir esse objetivo, foram criados mapas cujos custos de navegação são modelados como vetores (*vector fields*), representando a relação espacial entre regiões com diferentes níveis de rugosidade e inclinação. Adicionalmente, foram estimadas as magnitudes dos *vector fields*, para regiões não visitadas.

A metodologia proposta, apresentada na Figura A.1, pode ser dividida nas três

etapas principais abaixo:

1. Função do custo de navegação;
2. Representação AVF;
3. Propagação das magnitudes dos vetores.

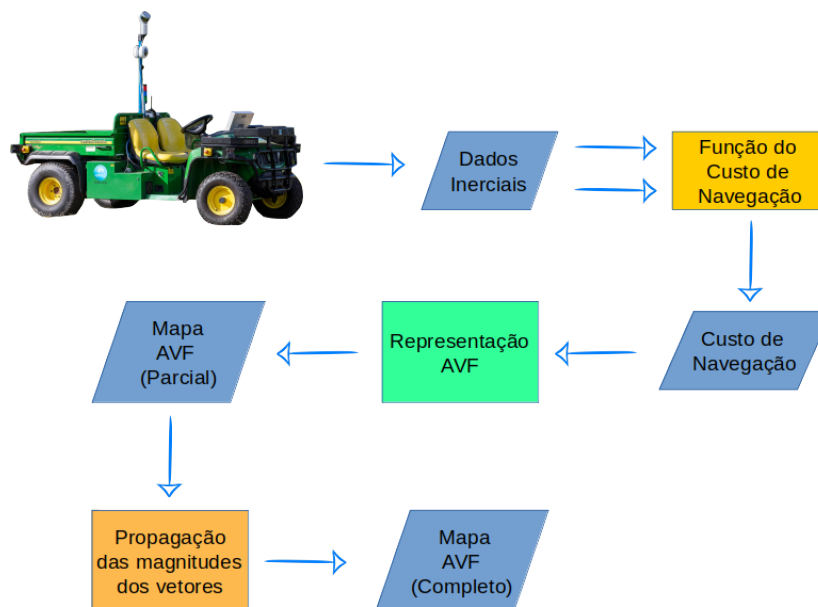


Figura A.1: Esquemático da metodologia proposta para o mapeamento AVF. A metodologia consiste no mapeamento baseado em *vector fields*, do custo de navegação em ambientes externos, a partir de dados inerciais capturados por um veículo terrestre.

### A.1.1 Função do custo de navegação

Inicialmente, dados inerciais providos por uma IMU são coletados, durante a navegação do veículo terrestre. Sensores inerciais são utilizados para capturar dados que representem as características de rugosidade e inclinação do terreno. Neste trabalho, os dados inerciais são utilizados para quantificar o custo de navegar sobre as coordenadas percorridas pelo robô. A abordagem de estimação do custo de navegação utilizada, a partir de dados inerciais, é apresentada detalhadamente na Subseção 3.1.2.1.



### A.1.2 Representação AVF

Como mencionado anteriormente, os custos de navegação computados são estimativas locais, definindo os graus de dificuldade ao se deslocar por coordenadas específicas. Para uma navegação autônoma eficiente é necessário o conhecimento prévio da região, que pode ser representada como um mapa. Os mapas utilizados para descrever terrenos externos na abordagem AVF, são modelados como grades bidimensionais que indicam o fluxo de deslocamento com menor custo de navegação. Cada célula é representada por um vetor 8-conectado, isto é, 8 setas vetoriais em diferentes direções associadas à referida célula, como pode ser visualizado na Figura A.2.




Figura A.2: Exemplos da representação AVF. Na Figura A.2a, são apresentadas células contendo 8 vetores em direções distintas. Na Figura A.2b, são associados os vetores às respectivas funções *vector field*.

Um *vector field* é uma função  $\vec{F}$  que atribui a cada ponto  $(x, y)$  um vetor dado por  $\vec{F}(x, y)$ . Isso significa que, todo ponto tem um vetor associado com magnitude e direção. A função  $\vec{F}$  é uma função multivariável, cujos espaços de entrada e saída tem a mesma dimensão. Na representação AVF proposta, a orientação de cada vetor é fixa, e relacionada à posição das células vizinhas. Assim, cada vetor tem sua respectiva função *vector field*, conforme Figura A.2b, definida anteriormente como  $\vec{F}$ , e calculada, como abaixo:

$$f_1(x, y) = (\Lambda(x, y + 1), 0), \quad (\text{A.1a})$$

$$f_2(x, y) = (\Lambda(x - 1, y + 1), \Lambda(x - 1, y + 1)), \quad (\text{A.1b})$$

$$f_3(x, y) = (0, \Lambda(x - 1, y)), \quad (\text{A.1c})$$

$$f_4(x, y) = (-\Lambda(x - 1, y - 1), \Lambda(x - 1, y - 1)), \quad (\text{A.1d})$$

$$f_5(x, y) = (-\Lambda(x, y - 1), 0), \quad (\text{A.1e})$$

$$f_6(x, y) = (-\Lambda(x + 1, y - 1), -\Lambda(x + 1, y - 1)), \quad (\text{A.1f})$$

$$f_7(x, y) = (0, -\Lambda(x + 1, y)), \quad (\text{A.1g})$$

$$f_8(x, y) = (\Lambda(x + 1, y + 1), -\Lambda(x + 1, y + 1)). \quad (\text{A.1h})$$

Na representação AVF, a magnitude dos vetores é calculada a partir da função de custo de navegação ( $\Lambda(\cdot)$ ), definida na Subseção 6.4, considerando os dados inerciais capturados (acelerações lineares, velocidades angulares e os ângulos *roll* e *pitch*). Para superfícies planas e homogêneas, ou seja, com custos de navegação similares, a magnitude dos vetores será quase a mesma em todas as direções. Assim, se a superfície tiver baixo custo de navegação, os vetores serão menores, como na Figura A.3a. Se a superfície tiver alto custo de navegação, os vetores serão maiores, como na Figura A.3b. Para superfícies inclinadas, com rugosidade ou não, um aclive representa um custo de navegação mais alto, definindo um vetor maior. Enquanto um declive representa um custo de navegação mais baixo, definindo um vetor menor, como observado na Figura A.3c. Aclives e declives apresentam diferentes custos de navegação, dependendo da inclinação da superfície. Declives suaves, por exemplo, exigem menos esforço do robô durante a navegação (por exemplo, energia), resultando em um deslocamento eficiente.

### A.1.3 Propagação das magnitudes dos vetores

Na Subseção anterior, a partir da representação AVF, foi computado o mapa AVF parcial, contendo somente as estimativas das posições percorridas pelo robô. Mapas AVF parciais não podem ser utilizados para planejamento de caminho, já que não cobrem uma área significativa do terreno. Para minimizar esse problema, foi proposta uma estratégia para propagar a magnitude de vetores para posições não visitadas pelo robô, a partir das magnitudes de vetores computadas, em posições previamente visitadas, resultando em mapas AVF completos. Para isso, foi aplicada uma técnica eficiente de aprendizado supervisionado, denominada regressão GP, para prever quantidades contínuas, como magnitudes vetoriais. A função GP é definida por:

$$g(\mathbf{z}) = GP(\text{mean}(\mathbf{z}), \text{cov}(\mathbf{z}, \mathbf{z}')), \quad (\text{A.2})$$

onde  $\text{mean}(z)$  é a função média e  $\text{cov}(\mathbf{z}, \mathbf{z}')$  é a função covariância, definidas abaixo:

$$\text{mean}(z) = E[g(z)], \quad (\text{A.3})$$

$$\text{cov}(z, z') = E [(g(z) - \text{mean}(z))(g(z') - \text{mean}(z'))^T]. \quad (\text{A.4})$$

Na abordagem de propagação proposta foram definidos, para o processo de treina-




Figura A.3: Exemplos de representações AVF em ambientes externos. As Figuras A.3a e A.3b, correspondem a representações AVF de terrenos planos. A Figura A.3c, corresponde a representação AVF de terrenos inclinados.

mento, um conjunto de informações conhecidas, compostas por: *i*) coordenadas  $(x, y)$ ; e *ii*) magnitudes de vetores, como dados de treinamento. As magnitudes dos vetores são definidas como alvo do processo de treinamento. Assim, para cada vetor em diferentes direções, é treinado um modelo de aprendizado para prever as magnitudes dos vetores em posições desconhecidas, ou seja, em cada posição adjacente, uma estimativa é realizada.

## A.2 Experimentos

Nesta Seção, são apresentados os resultados experimentais obtidos. Adicionalmente, são comparados os desempenhos da abordagem proposta e da abordagem *baseline*. Para a realização dos experimentos, as mesmas plataformas robóticas apresentadas na Seção 8.1 foram utilizadas. Os ambientes experimentais utilizados nos experimentos

foram os mesmos definidos na Seção 8.2.

### A.2.1 Avaliação da propagação das magnitudes dos vetores

Após a realização do mapeamento AVF parcial, foi aplicado um método de propagação das magnitudes dos vetores, para posições não visitadas pelo veículo terrestre. Com isso, o objetivo deste experimento é validar a técnica de propagação das magnitudes dos vetores. Em todas as etapas do experimento, o melhor conjunto de parâmetros para o *kernel* utilizado (exponencial quadrado) foi encontrado através da otimização do gradiente descendente.

Para medir a precisão da estratégia de propagação, foi proposta uma análise quantitativa. Na análise quantitativa, foram avaliados os custos de navegação dos caminhos planejados a partir dos mapas AVF, usando propagação *baseline* (Regressão polinomial de 3ª ordem) e a propagação proposta (Regressão GP), referentes ao primeiro e segundo ambiente. Para isso, foram definidos 10 pares de pontos correspondendo ao início e fim de cada trajeto. Finalmente, os custos de navegação computados, a partir dos pares de pontos, são comparados na Tabela A.1. Este trabalho utiliza o algoritmo Dijkstra, para planejamento de caminho entre dois pontos. Para isso, cada célula da grade bidimensional (mapa AVF) é considerada como vértice de um grafo e as arestas são definidas considerando uma distância máxima entre as células vizinhas.

Tabela A.1: Custos dos caminhos gerados pelo planejador de caminho, de acordo com diferentes estratégias de propagação, em diferentes terrenos.

Custos dos caminhos				
Caminho	Propagação baseline		Propagação proposta	
	Ambiente 1	Ambiente 2	Ambiente 1	Ambiente 2
1	18.8666	29.1078	12.3000	28.4686
2	18.9607	29.1000	12.3000	28.4843
3	30.8460	36.0558	20.9578	32.4264
4	30.7127	35.8009	20.8441	31.9676
5	25.5647	14.5333	16.7098	11.0803
6	26.0039	14.4039	17.2509	10.6686
7	20.1941	33.6656	13.4705	30.7794
8	20.5823	33.5715	13.9058	30.8382
9	23.7666	32.2098	14.8901	28.8215
10	23.8058	32.3901	15.0000	28.8490

Observando a Tabela A.1, é possível verificar que o mapa AVF completo, criado utilizando a propagação proposta é mais preciso do que o mapa AVF com propagação *baseline*, pois minimiza o custo de navegação para todos os caminhos, mesmo em di-

ferentes cenários. Isso ocorre porque o GP aprende, com eficiência, um modelo de inferência baseado em vetores conhecidos, fornecendo estimativas confiáveis.

## A.2.2 Avaliação da efetividade dos mapas AVF

Este experimento avalia a efetividade dos mapas AVF, analisando o uso dos mapas propostos como uma métrica para o processo de planejamento de caminho em ambientes externos. Para a análise qualitativa e uma melhor visualização dos mapas AVF, a Figura A.4 apresenta os caminhos obtidos empregando diferentes métricas (distância e custo de navegação), para os mesmos pares de pontos, usando o algoritmo Dijkstra, em diferentes terrenos.

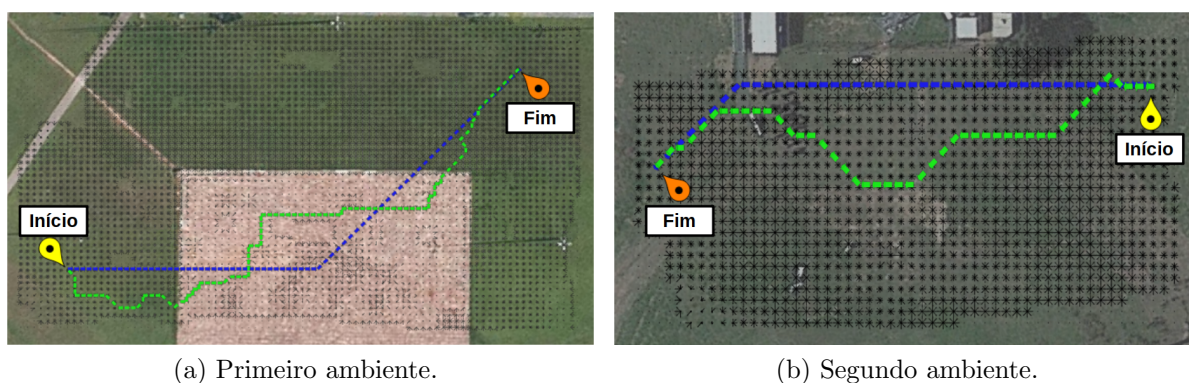


Figura A.4: Diferentes caminhos obtidos através dos mapas AVF propostos, considerando diferentes métricas (distância e custo de navegação). Nas Figuras A.4a e A.4b, são apresentados os caminhos computados considerando a distância (setas azuis) e o custo de navegação (setas verdes) para o primeiro e segundo ambiente, respectivamente.

No primeiro cenário, é apresentado um mapa AVF, representando o primeiro ambiente, com um caminho baseado apenas em informações de distância (setas azuis) e um caminho baseado apenas no custo de navegação (setas verde), conforme Figura A.4a. No segundo cenário, é apresentado um mapa AVF, representando o segundo ambiente, com um caminho baseado somente informações de distância (setas azuis) e um caminho baseado somente no custo de navegação (setas verdes), conforme Figura A.4b.

Para análise quantitativa, os custos dos caminhos planejados nos cenários mencionados acima são avaliados. Para isso, são considerados os mesmos 10 pares de pontos utilizados no experimento anterior, para cada terreno. Em seguida, a técnica Dijkstra encontra caminhos considerando distância e custo de navegação, respectivamente. Por fim, os custos de navegação obtidos são comparados na Tabela A.2.

Tabela A.2: Custos dos caminhos gerados a partir do mapeamento AVF proposto, de acordo com diferentes métricas (distância ou custo de navegação), em diferentes terrenos.

Caminho	Custos dos caminhos			
	Distância		Custo de navegação	
	Ambiente 1	Ambiente 2	Ambiente 1	Ambiente 2
1	25.9960	34.1019	12.3000	28.4686
2	25.9960	31.4235	12.3000	28.4843
3	31.4264	35.6852	20.9578	32.4264
4	51.5127	36.8186	20.8441	31.9676
5	39.1588	11.3725	16.7098	11.0803
6	33.6882	10.9607	17.2509	10.6686
7	18.0509	35.7009	13.4705	30.7794
8	18.4862	37.0774	13.9058	30.8382
9	58.5294	34.3490	14.8901	28.8215
10	58.6392	38.9490	15.0000	28.8490

Observando a Tabela A.2, é possível verificar que os custos dos caminhos, considerando apenas a distância, são maiores do que os custos dos caminhos que consideram características do terreno. Isso indica que, para uma navegação segura e eficiente, somente a informação de distância não é suficiente para o uso em aplicações que envolvam ambientes reais, desconhecidos e não estruturados.

### A.2.3 Avaliação da precisão dos mapas AVF

Neste experimento é avaliada a precisão dos mapas AVF propostos, a partir de terrenos externos simulados. Para medir a taxa de precisão da técnica de mapeamento AVF proposta, foram criados terrenos simulados com as respectivas representações de referência (*ground-truths*). Assim, é possível aplicar a estratégia proposta e a estratégia *baseline* para criar representações AVF completas e compará-las com a referência correta (*ground-truth*).

Para isso, uma trajetória, simulando a navegação do robô durante o processo de mapeamento, foi definida e as técnicas proposta e *baseline* são comparadas com o *ground-truth*. É importante mencionar que: *i*) a trajetória simulada não cobre todo o terreno; *ii*) a trajetória foi definida manualmente, tentando representar um caminho real; e *iii*) o número de coordenadas no caminho pré-definido corresponde a 1/7 da quantidade total de posições. Assim, a trajetória proposta deixa regiões sem estimativas de *vector fields*, demandando a aplicação das técnicas de propagação das magnitudes dos vetores.

Por fim, através da medida Raiz do Erro Quadrático Médio (*Root Mean Square Error*, ou RMSE), foram mensurados os graus de similaridade entre: *i*) o mapa proposto e o *ground-truth*; e *ii*) o mapa *baseline* e o *ground-truth*. Dessa forma, considerando 10 diferentes terrenos simulados é possível validar a qualidade do mapa AVF computado. Para isso, foram calculados o RMSE entre: *i*) os mapas AVF estimados e o *ground-truth*, com propagação por GP; e *ii*) os mapas AVF estimados e o *ground-truth*, com propagação *baseline*. Os valores de RMSE obtidos são comparados na Tabela A.3.

Tabela A.3: Medidas RMSE entre: *i*) mapa AVF + propagação *baseline* e o *ground-truth*; e *ii*) mapa AVF + propagação proposta e o *ground-truth*, para ambientes simulados.

Caminho	Medidas RMSE	
	Propagação proposta Ground-truth	Propagação baseline Ground-truth
1	2.45489	4.04071
2	3.35003	3.46936
3	3.39574	4.79947
4	5.19529	5.52715
5	3.29156	4.96672
6	1.79262	3.53951
7	1.94923	2.16800
8	7.14107	7.89581
9	0.71182	2.31680
10	1.78550	3.19240

É importante mencionar que quanto mais próximo de zero for o valor RMSE, maior a precisão. Portanto, os resultados mostram que a abordagem AVF proposta apresenta mapas precisos, mesmo para posições não visitadas, resultando em uma boa alternativa para o mapeamento de terrenos.

## Apêndice B


# Resultados da transformação de dados inerciais invariantes à velocidade

Este anexo continua a avaliação de qualidade da transformação inercial invariante à velocidade proposta (ISIT). Para isso, as medições inerciais adquiridas em diferentes velocidades foram transformadas em sinais inerciais correspondentes a uma única velocidade constante. A avaliação qualitativa das transformações obtidas pode ser realizada por meio da comparação visual entre os dados inerciais reais, capturados pela IMU em diferentes velocidades, e os dados inerciais transformados, invariantes a velocidade. Na Figura B.1 são apresentadas as velocidades angulares no eixo Y, reais e transformadas, para cada área do segundo ambiente externo.


Na Figura B.1, a primeira coluna (Figuras B.1a, B.1d e B.1g) corresponde ao sinal inercial real, capturado pelo veículo, enquanto as demais colunas correspondem aos dados inerciais transformados. Na primeira linha, os sinais inerciais correspondem à área 1, onde na Figura B.1b o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 2 e na Figura B.1c o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 3. Na segunda linha, os sinais inerciais correspondem à área 2, onde na Figura B.1e o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 1 e na Figura B.1f o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 3. Na terceira linha, os sinais inerciais correspondem à área 3, onde na Figura B.1h o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 1 e na Figura B.1i o modelo de transformação foi treinado a partir dos dados inerciais capturados na área 2. Adicionalmente, os dados inerciais representados nas cores vermelha, verde e azul, foram capturados nas velocidades baixa, média e alta, respectivamente.




Assim como na transformação das acelerações lineares no eixo Z, é possível observar que, a medida que a velocidade aplicada pelo veículo aumenta, a variação entre as magnitudes dos dados inerciais também aumenta. Com isso, é possível verificar que a dispersão nos sinais inerciais transformados, inicialmente capturados em diferentes velocidades foi minimizada, reduzindo o impacto da velocidade sobre os dados inerciais.



(a) Dado inercial real da Área 1. (b) Dado inercial da Área 1 transformado a partir da Área 2. (c) Dado inercial da Área 1 transformado a partir da Área 3.



(d) Dado inercial real da Área 2. (e) Dado inercial da Área 2 transformado a partir da Área 1. (f) Dado inercial da Área 2 transformado a partir da Área 3.



(g) Dado inercial real da Área 3. (h) Dado inercial da Área 3 transformado a partir da Área 1. (i) Dado inercial da Área 3 transformado a partir da Área 2.

Figura B.1: Dados inerciais (velocidades angulares no eixo Y), reais e transformados, capturados em diferentes áreas e velocidades. Nas Figuras B.1a, B.1d e B.1g podem ser visualizados os dados inerciais reais, para as áreas 1, 2 e 3, respectivamente. Nas Figuras B.1b, B.1c, B.1e, B.1f, B.1h e B.1i, são mostrados os dados inerciais transformados, ou seja invariantes a velocidade.

## Apêndice C

### Resultados das matrizes de confusão

Este anexo continua a avaliação do processo de classificação, considerando velocidades individuais, utilizando matrizes de confusão. As matrizes de confusão propiciam a visualização completa da distribuição de respostas do classificador, sendo possível identificar os falso-positivos e em quais classes os mesmos ocorreram.

Na Subseção 8.5.2 foram apresentadas as matrizes de confusão computadas pelo classificador *Random Forest* em três velocidades distintas, 0.4, 0.6 e 0.8 m/s. Neste apêndice são apresentadas as matrizes de confusão computadas pelos classificadores SVM e *Ada Boosting*, para as velocidades supracitadas. A Tabela C.1 apresenta a matriz de confusão obtida pelo classificador SVM. Enquanto a Tabela C.2 apresenta a matriz de confusão obtida pelo classificador *Ada Boosting*.

Observando as matrizes de confusão expostas nas Tabelas C.1 e C.2, foi possível verificar o mesmo padrão nas ocorrências de erros de classificação, já destacados na Subseção 8.5.2. Para este experimento foram considerados três níveis de rugosidade (NR2, NR3 e NR4) para teste, onde em alguns trechos os níveis de rugosidade são classificados incorretamente. Um dos principais motivos para os erros mencionados consiste na presença de irregularidades (cavidades ou elevações) no terreno. Dessa forma, quando o veículo navega sobre essa irregularidade, causa uma grande oscilação na aceleração vertical, que é classificada como um nível de rugosidade que não corresponde ao terreno percorrido.

Além disso, destaca-se o aumento na taxa de erros de classificação de níveis de rugosidade, onde alguns níveis de rugosidade são, incorretamente, classificados como níveis de rugosidade próximos. Esses problemas adicionais podem ser atribuídos ao modelo de classificação, uma vez que, o classificador *Random Forest* minimizou uma taxa significativa desses erros de classificação.

Tabela C.1: Matrizes de confusão computadas pelo classificador SVM, com variação de velocidade. Neste experimento, os classificadores treinados consideram 5 níveis de rugosidade, porém os dados de teste consideram apenas 3 níveis de rugosidade (NR), em 3 velocidades distintas (0.4, 0.6 e 0.8 m/s)

		<b>Estimado</b>					
<b>Esperado</b>	Classificador	Níveis de Rugosidade	NR 1	NR 2	NR 3	NR 4	NR 5
		SVM	NR 1	0	0	0	0
	NR 2		0	18540	394	1245	539
	NR 3		0	189	36588	187	0
	NR 4		0	1562	36	6245	0
	NR 5		0	0	0	0	0
	SVM	NR 1	0	0	0	0	0
		NR 2	0	10943	298	2193	547
		NR 3	0	58	24567	98	125
		NR 4	0	1156	19	3878	44
		NR 5	0	0	0	0	0
	SVM	NR 1	0	0	0	0	0
		NR 2	0	7916	613	2048	615
		NR 3	0	342	19767	169	0
		NR 4	0	1656	62	2695	5
		NR 5	0	0	0	0	0

Tabela C.2: Matrizes de confusão computadas pelo classificador *Ada Boosting* (AB), com variação de velocidade. Neste experimento, os classificadores treinados consideram 5 níveis de rugosidade, porém os dados de teste consideram apenas 3 níveis de rugosidade (NR), em 3 velocidades distintas (0.4, 0.6 e 0.8 m/s).

		<b>Estimado</b>									
<b>Esperado</b>	Classificador	Níveis de Rugosidade	NR 1	NR 2	NR 3	NR 4	NR 5				
		0.4 m/s	AB	NR 1	0	0	0	0	0		
0.6 m/s			AB	NR 2	0	14355	1028	5335	0		
			0.8 m/s	AB	NR 3	0	682	33918	2364	0	
					AB	NR 4	0	782	216	6847	0
					AB	NR 5	0	0	0	0	0
					AB	NR 1	0	0	0	0	0
					AB	NR 2	0	9008	1593	3360	0
					AB	NR 3	0	646	24103	99	0
					AB	NR 4	0	881	290	3926	0
					AB	NR 5	0	0	0	0	0
					AB	NR 1	0	0	0	0	0
					AB	NR 2	0	8413	2738	41	0
					AB	NR 3	0	873	19405	0	0
					AB	NR 4	0	1974	2444	0	0
					AB	NR 5	0	0	0	0	0