



# ESCOLA NAVAL



*ta sainte & bief faire*

Tomás dos Santos Barata

**Localização e navegação em ambientes com  
disrupção de sinal GNSS usando unidades  
inerciais, odometria e outros sensores**

**Dissertação para obtenção do Grau de Mestre em  
Ciências Militares Navais, na especialidade de Marinha**



Alfeite


2024





# ESCOLA NAVAL

*talant de bi-faire*



Tomás dos Santos Barata

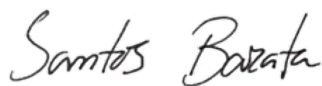
*Localização e navegação em ambientes com disrupção de sinal GNSS usando unidades inerciais, odometria e outros sensores*

Dissertação para obtenção do Grau de Mestre em Ciências Militares Navais, na especialidade de Marinha

Orientação de: Bruno Damas

Co-orientação de: Vítor Viegas e Vítor F. Plácido da Conceição

*O Aluno Mestrando,*



Tomás Barata

*O Orientador,*



Bruno Damas

Alfeite

2024



Dedico este trabalho à minha família.



# Agradecimentos

A conclusão desta dissertação assinala o término do meu percurso na Escola Naval. Percurso este que não teria chegado a bom porto sem o apoio e a ajuda das pessoas que me rodeiam, às quais estou profundamente grato.

Ao meu orientador, Sr. Professor Bruno Damas, pelas valiosas diretrizes fornecidas ao longo do trabalho, bem como pela sua supervisão atenta e disponibilidade constante no auxílio à resolução dos vários desafios encontrados.

Aos meus coorientadores, Sr. Professor Vítor Viegas e Sr. Comandante Plácido da Conceição, pelas perspectivas especializadas e pelo apoio e disponibilidade determinantes para o término deste trabalho.

Aos meus pais e à minha madrinha, pelo seu apoio incondicional e por me proporcionarem todas as condições necessárias para a realização deste trabalho.

À minha família e amigos mais próximos, pelo apoio e motivação nos momentos menos favoráveis.

À minha namorada Catarina, companheira fiel nesta caminhada, o meu especial agradecimento pelo carinho, auxílio e compreensão fundamentais para superar os momentos mais desafiantes.

À Denise, pelo apoio incansável e disponibilidade determinantes para a conclusão do percurso.

A todos os camaradas do curso Fernão de Magalhães, pelos momentos partilhados e pela camaradagem que desenvolvemos ao longo destes cinco anos.

Por último, mas não menos importante, gostaria de expressar a minha gratidão à Escola Naval pela formação proporcionada, que contribuiu não só para o meu desenvolvimento académico, mas também para o meu crescimento pessoal.

A todos, o meu mais sincero obrigado.



# Resumo

Os Sistemas Globais de Navegação por Satélite (*Global Navigation Satellite System*, GNSS) providenciaram um aumento significativo do rigor e disponibilidade de dados de Posicionamento, Navegação e Tempo (PNT), no entanto, esta vantagem expôs também vulnerabilidades nas infraestruturas críticas, pela dependência destes sistemas. A emergência dos veículos autônomos potencia ainda mais a criticidade desta dependência, em particular em cenários militares onde é fundamental dispor de dados de navegação e posição robustos e resilientes.

Este estudo apresenta uma via para aumentar a resiliência dos sistemas PNT, através da implementação de fusão sensorial utilizando um Filtro de Kalman Estendido (*Extended Kalman Filter*, EKF). Explora-se, também, a importância dos dados PNT em cenários de *Navigation Warfare* (NAVWAR). É apresentada uma visão abrangente dos sensores relevantes. Os princípios dos Filtros de Kalman são abordados com detalhe.

O trabalho desenvolvido na dissertação envolve a integração de um conjunto de sensores num veículo terrestre não tripulado (*Unmanned Ground Vehicle*, UGV) incorporando um receptor GNSS e um Sistema de Posicionamento *Indoor* (IPS) baseado em *beacons* para complementar os sensores já existentes, Unidade de Medida Inercial (*Inertial Measurement Unit*, IMU) e *encoders* para as rodas. São desenvolvidos modelos cinemáticos e dinâmicos, juntamente com modelos dos sensores para IMU, odometria, GNSS e IPS. O estudo centra-se na implementação de EKFs para fusão sensorial. Adquiriram-se múltiplos conjuntos de dados em ambiente interior e exterior, resultantes de diversos ensaios reais com o UGV. Subsequentemente, realizou-se uma análise qualitativa e crítica dos resultados obtidos.

Este trabalho, alinhado com um grupo de trabalho da NATO, contribui para o avanço de soluções PNT robustas e resilientes para sistemas autônomos que operam em ambientes de interrupção de sinal GNSS. As conclusões e os resultados do desempenho da fusão sensorial são apresentados nos capítulos finais da dissertação.

**Palavras-chave:** Filtro de Kalman, Fusão Sensorial, Navegação Inercial, Odometria, Resiliência PNT, Sistema Global de Navegação por Satélite



# Abstract

Global Navigation Satellite Systems (GNSS) have significantly improved the accuracy and availability of Positioning, Navigation, and Timing (PNT) data. However, this advantage has also exposed vulnerabilities in critical infrastructures due to their dependence on these systems. The emergence of autonomous vehicles further intensifies the criticality of this dependence, particularly in military scenarios where robust and resilient navigation and positioning data are essential.

This study presents an approach to enhance the resilience of PNT systems through the implementation of sensor fusion using an Extended Kalman Filter (EKF). The importance of PNT data in Navigation Warfare (NAVWAR) scenarios is also explored. A comprehensive overview of relevant sensors is presented. The principles of Kalman Filters are addressed in detail.

This research focuses on the integration of a sensor suite on an Unmanned Ground Vehicle (UGV), incorporating a GNSS receiver and an Indoor Positioning System (IPS) to complement existing Inertial Measurement Unit (IMU) and encoder systems for the wheels. Kinematic and dynamic models are developed, along with sensor models for IMU, odometry, GNSS, and IPS. The core of the study focuses on the implementation of EKF algorithms for sensor fusion. Multiple datasets were acquired from various trials conducted with the UGV. Subsequently, a qualitative and critical analysis of the obtained results was conducted.

This work, aligned with a NATO working group, contributes to the advancement of robust and resilient PNT solutions for autonomous systems operating in GNSS-denied environments. Conclusions and results of the sensor fusion performance are presented in the final chapters of the thesis.

**Keywords:** Global Navigation Satellite System, Inertial Navigation, Kalman Filter, Odometry, PNT Resilience, Sensor Fusion



# Índice

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Enquadramento Teórico</b>	<b>5</b>
2.1	PNT no Meio Militar - NAVWAR . . . . .	5
2.2	Sensores . . . . .	7
2.2.1	Recetores GNSS . . . . .	8
2.2.2	Unidades de Medida Inercial (IMUs) . . . . .	10
2.2.3	Odometria . . . . .	12
2.2.4	Sistemas Baseados em <i>Beacons</i> . . . . .	16
2.2.5	LiDAR . . . . .	17
2.3	Fusão de Dados . . . . .	18
2.3.1	Filtro de Kalman . . . . .	18
2.3.2	Outros Métodos de Fusão . . . . .	21
<b>3</b>	<b>Estado da Arte</b>	<b>23</b>
3.1	<i>Unmanned Aerial Vehicles</i> . . . . .	23
3.2	<i>Unmanned Ground Vehicles</i> . . . . .	24
<b>4</b>	<b>Modelação do Sistema</b>	<b>31</b>
4.1	Descrição Geral da Plataforma Leo Rover . . . . .	31
4.1.1	Características Físicas e <i>Hardware</i> . . . . .	32
4.1.2	<i>Software</i> . . . . .	34
4.1.3	Integração do Recetor GNSS - UBlox EVK-M8 . . . . .	35
4.1.4	Integração do IPS - Marvelmind <i>Indoor</i> GPS . . . . .	37
4.2	Ambiente Computacional . . . . .	39
4.3	Referenciais e Notação . . . . .	40
4.4	Modelo Cinemático e Dinâmico do Leo Rover . . . . .	43
4.4.1	Modelo Completo (3D) . . . . .	43
	Cinemática . . . . .	43
	Dinâmica . . . . .	44

4.4.2	Modelo Simplificado (2D) . . . . .	44
	Cinemática . . . . .	45
	Dinâmica . . . . .	46
4.5	Filtro de Kalman Estendido com Modelo Simplificado . . . . .	47
4.5.1	Modelo de Estado, Predição e Atualização . . . . .	47
4.5.2	IMU . . . . .	48
4.5.3	Odometria . . . . .	49
4.5.4	Compensação de <i>Bias</i> no IMU e Odometria . . . . .	51
	IMU . . . . .	51
	Odometria . . . . .	52
4.5.5	Recetor GNSS . . . . .	53
4.5.6	IPS baseado em <i>Beacons</i> . . . . .	54
4.6	Filtro de Kalman Estendido com Modelo Completo . . . . .	56
4.6.1	Cinemática, Dinâmica e Modelo de Estado . . . . .	58
4.6.2	IMU - insGyroscope / insAccelerometer . . . . .	59
	Giroscópio . . . . .	59
	Acelerómetro . . . . .	59
4.6.3	GNSS - insGPS . . . . .	59
4.6.4	Odometria - insOdometry . . . . .	60
<b>5</b>	<b>Ensaio Experimentais e Resultados</b>	<b>61</b>
5.1	Descrição do Processo de Aquisição de Dados . . . . .	61
5.2	<i>Datasets</i> . . . . .	61
5.2.1	Rover estático . . . . .	62
5.2.2	Quadrangular . . . . .	63
5.2.3	Parada EN . . . . .	64
5.2.4	Completo 3D . . . . .	64
5.3	Configuração Recetor GNSS . . . . .	65
5.4	Ensaio com UGV Estático . . . . .	69
5.4.1	Experiência 1 - Caracterização do IMU . . . . .	69
5.4.2	Experiência 2 - IMU com EKF . . . . .	71
5.4.3	Experiência 3 - IMU + Odometria com EKF . . . . .	72
5.5	Ensaio Trajetória Quadrangular . . . . .	73
5.5.1	Experiência 1 - IMU . . . . .	74
5.5.2	Experiência 2 - Odometria . . . . .	75
5.5.3	Experiência 3 - IMU + Odometria . . . . .	76
5.6	Ensaio Trajetória Parada EN . . . . .	77
5.6.1	Experiência 1 - IMU . . . . .	77

5.6.2	Experiência 2 - Odometria . . . . .	78
5.6.3	Experiência 3 - IMU + Odometria . . . . .	79
5.6.4	Experiência 4 - GNSS . . . . .	80
5.6.5	Experiência 5 - GNSS + Odometria + IMU . . . . .	81
5.6.6	Experiência 6 - GNSS Intermitente . . . . .	83
5.6.7	Experiência 7 - Odometria + IMU <i>insEKF</i> . . . . .	84
5.6.8	Experiência 8 - GNSS Intermitente <i>insEKF</i> . . . . .	85
5.7	Ensaio Trajetória Completa 3D . . . . .	85
5.7.1	Experiência 1 - GNSS . . . . .	86
5.7.2	Experiência 2 - Odometria + IMU . . . . .	87
5.7.3	Experiência 3 - GNSS + Odometria + IMU . . . . .	88
5.7.4	Experiência 4 - Odometria + IMU <i>insEKF</i> . . . . .	89
5.7.5	Experiência 5 - GNSS + Odometria + IMU <i>insEKF</i> . . . . .	90
5.8	Discussão de Resultados e Dificuldades Encontradas . . . . .	91
5.8.1	Calibração e <i>Bias</i> dos Sensores . . . . .	91
5.8.2	Superioridade do Giroscópio sobre o Acelerómetro . . . . .	91
5.8.3	Limitações da Estima do Estado com IMU Isolada . . . . .	91
5.8.4	Fusão Sensorial e Importância Relativa dos Sensores . . . . .	92
5.8.5	Desafios em Ambientes <i>Indoor</i> , Perda de Sinal GNSS e Resiliência . . . . .	92
5.8.6	Comparação entre EKF 2D e <i>insEKF</i> 3D . . . . .	92
5.8.7	Dificuldades do Processo de Afinação do Filtro . . . . .	93
<b>6</b>	<b>Conclusões e Trabalho Futuro</b>	<b>95</b>
6.1	Conclusão . . . . .	95
6.2	Trabalho Futuro . . . . .	96
	<b>Bibliografia</b>	<b>99</b>
	<b>Apêndices</b>	<b>105</b>
	<b>A Checklist Aquisição de Dados</b>	<b>105</b>
	<b>B Tópicos Publicados LeoRover</b>	<b>107</b>



# Lista de Figuras

2.1	Mapa GPSJAM, 23 Março 2024. . . . .	7
2.2	Trilateração - 3 satélites. . . . .	9
2.3	Trilateração - 4 satélites. . . . .	10
2.4	Princípio Funcionamento Giroscópio. . . . .	12
2.5	Princípio Funcionamento Acelerómetro. . . . .	12
2.6	Princípio Funcionamento Magnetómetro. . . . .	12
2.7	Cinemática Odometria - 1 eixo, 2 rodas. . . . .	13
2.8	Odómetro Eletromagnético. . . . .	15
2.9	<i>Doppler Velocity Log</i> . . . . .	15
2.10	Princípio Funcionamento LiDAR mecânico giratório. . . . .	18
2.11	Fluxo de informação Filtro de Kalman. . . . .	21
3.1	Ambiente e resultados experimentais de Kassas et al., 2022. . . . .	28
4.1	Leo Rover. . . . .	31
4.2	Dimensões Leo Rover. . . . .	32
4.3	Arquitetura <i>Hardware</i> Leo Rover. . . . .	33
4.4	IMU Leo Rover. . . . .	34
4.5	Estrutura <i>Software</i> Leo Rover. . . . .	34
4.6	Recetor GNSS - UBlox EVK-M8. . . . .	35
4.7	UBlox EVK-M8 integrado. . . . .	36
4.8	<i>Software</i> u-center. . . . .	36
4.9	Marvelmind <i>Indoor</i> GPS - Starter set Super-MP. . . . .	37
4.10	Marvelmind <i>Indoor</i> GPS - Dashboard. . . . .	37
4.11	IPS Marvelmind integrado. . . . .	38
4.12	Ligação entre sensores integrados e RPi. . . . .	39
4.13	Leo Rover após integrações. . . . .	39
4.14	Referencial Leo Rover, {B}. . . . .	40
4.15	Zona de Serviço e Referencial IPS. . . . .	41
4.16	Referencial do mundo {U}. . . . .	42
4.17	Roda Leo Rover. . . . .	50

4.18	<i>Indoor Positioning System</i> . . . . .	54
4.19	Estrutura do algoritmo <i>insEKF</i> . . . . .	57
5.1	Trajectoria Quadrangular. . . . .	63
5.2	Trajectoria Parada EN. . . . .	64
5.3	Trajectoria Completa 3D. . . . .	65
5.4	Satélites visíveis <i>Dataset3</i> . . . . .	66
5.5	Satélites visíveis <i>Dataset4</i> . . . . .	67
5.6	Satélites visíveis testes GNSS. . . . .	68
5.7	Trajectoria Testes GNSS. . . . .	68
5.8	Exp.1 - IMU [Estático]. . . . .	69
5.9	Exp.2 - IMU com EKF [Estático]. . . . .	71
5.10	Exp.3 - IMU + Odometria com EKF [Estático]. . . . .	73
5.11	Exp.1 - IMU com EKF [Quadrangular]. . . . .	74
5.12	Exp.2 - Odometria com EKF [Quadrangular]. . . . .	75
5.13	Exp.2 - Odometria (valores fabricante) com EKF [Quadrangular]. . . . .	76
5.14	Exp.3 - IMU + Odometria com EKF [Quadrangular]. . . . .	76
5.15	Exp.1 - IMU com EKF [Parada EN]. . . . .	78
5.16	Exp.2 - Odometria com EKF [Parada EN]. . . . .	78
5.17	Exp.3 - IMU + Odometria com EKF [Parada EN]. . . . .	79
5.18	Exp.4.1 - GNSS [Parada EN]. . . . .	80
5.19	Exp.4.2 - GNSS com EKF [Parada EN]. . . . .	81
5.20	Exp.5 - GNSS + Odometria + IMU [Parada EN]. . . . .	82
5.21	Exp.6 - GNSS intermitente com EKF [Parada EN]. . . . .	83
5.22	Exp.7 - Odometria + IMU <i>insEKF</i> [Parada EN]. . . . .	84
5.23	Exp.8 - GNSS intermitente <i>insEKF</i> [Parada EN]. . . . .	85
5.24	Exp.1 - GNSS [Full 3D]. . . . .	87
5.25	Exp.2 - Odometria + IMU [Full 3D]. . . . .	87
5.26	Exp.3 - GNSS + Odometria + IMU [Full 3D]. . . . .	88
5.27	Exp.4 - Odometria + IMU <i>insEKF</i> [Full 3D]. . . . .	89
5.28	Exp.5 - GNSS + Odometria + IMU <i>insEKF</i> [Full 3D]. . . . .	90

# Lista de Tabelas

2.1	Classificação de Sensores. . . . .	8
3.1	Resultados experimentais de Dissanayake et al., 2001. . . . .	27
4.1	Nomenclatura SNAME para veículos aquáticos. . . . .	42



# Lista de Acrónimos

2D	2 Dimensões.
3D	3 Dimensões.
ADS-B	<i>Automatic Dependent Surveillance-Broadcast.</i>
AIS	<i>Automatic Identification System.</i>
AMN	Autoridade Marítima Nacional.
AoA	<i>Angle of Arrival.</i>
BLE	<i>Bluetooth Low Energy.</i>
CCW	<i>Counterclockwise.</i>
CEOM	Centro de Experimentação Operacional da Marinha.
CEOV	Célula de Inovação e Experimentação Operacional de Sistemas Não Tripulados.
CINAV	Centro de Investigação Naval.
CW	<i>Clockwise.</i>
DC	<i>Direct Current.</i>
DEM	Diretiva Estratégica da Marinha.
DEMs	<i>Digital Elevation Models.</i>
DOF	<i>Degrees Of Freedom.</i>
DVL	<i>Doppler Velocity Log.</i>
EKF	<i>Extended Kalman Filter.</i>
eLORAN	<i>enhanced LORAN.</i>
ERPS	<i>Enhanced Radar Positioning System.</i>
GNSS	<i>Global Navigation Satellite System.</i>
GPS	<i>Global Positioning System.</i>
GT	<i>Ground Truth.</i>

IMU	<i>Inertial Measurement Unit.</i>
IP	<i>Índice de Proteção.</i>
IPS	<i>Indoor Positioning System.</i>
KF	<i>Kalman Filter.</i>
LiDAR	<i>Light Detection and Ranging.</i>
LORAN-C	<i>LONg RANge Navigation.</i>
LTE	<i>Long Term Evolution.</i>
MAV	<i>Micro Air Vehicle.</i>
MEMS	<i>Micro-Electro-Mechanical Systems.</i>
NATO	<i>North Atlantic Treaty Organization.</i>
NAVWAR	<i>Navigation Warfare.</i>
PF	<i>Particle Filter.</i>
PNT	<i>Posição, Navegação e Tempo.</i>
PPR	<i>Pulses Per Revolution.</i>
RADAR	<i>Radio Detection And Ranging.</i>
REP-MUS	<i>Robotic Experimentation and Prototyping augmented by Maritime Unmanned Systems.</i>
ROS	<i>Robotic Operating System.</i>
RSSI	<i>Received Signal Strength Indicator.</i>
SLAM	<i>Simultaneous Localization and Mapping.</i>
SOPs	<i>Signals of Opportunity.</i>
STO	<i>Science and Technology Organization.</i>
ToA	<i>Time of Arrival.</i>
UAVs	<i>Unmanned Aerial Vehicles.</i>
UGV	<i>Unmanned Ground Vehicle.</i>
UKF	<i>Unscented Kalman Filter.</i>
UTC	<i>Coordinated Universal Time.</i>

UWB      *Ultra-Wide-Band.*

VO        *Visual Odometry.*

WGS84    *World Geodesic System 1984.*



# Capítulo 1

## Introdução

O *Global Navigation Satellite System* (GNSS) é fulcral para conseguirmos obter, em tempo real, informação acerca da Posição, Navegação e Tempo (PNT). O termo geral GNSS descreve qualquer sistema de satélites que forneça globalmente dados PNT, incluindo o mais utilizado *Global Positioning System* (GPS) (com origem nos Estados Unidos da América), GLONASS (Rússia), Galileu (União Europeia) e BeiDou (China).

Atualmente, o sinal GNSS é utilizado em várias atividades importantes do quotidiano civil, tais como, transportes terrestres, marítimos e aéreos, agricultura, sistemas de telecomunicações, transações financeiras, monitorização meteorológica e serviços de segurança e emergência. No meio militar, as necessidades de posicionamento e referência no tempo, aliadas às necessidades operacionais de combate, tornam, também neste meio, o GNSS fundamental. A crescente utilização e importância dos sistemas GNSS está também associada a uma grande dependência, levantando assim o problema da sua vulnerabilidade e que mecanismos utilizar quando este sinal está ausente.

No contexto dos veículos autónomos e veículos não tripulados, a falta de um sinal de localização absoluta como o GNSS traz problemas adicionais. Os humanos conseguem, naturalmente e de uma forma mais ou menos precisa, orientar-se na falta desse sinal com recurso a pistas visuais e uma perceção inercial intrínseca. Os veículos autónomos e não tripulados não têm essa aptidão inata e, por isso, é necessário dotá-los dessa capacidade, recorrendo a outro tipo de sensores.

A evolução tecnológica tem impulsionado uma mudança de paradigma, na qual os sistemas autónomos e não tripulados assumem um papel cada vez mais relevante na sociedade, nas Forças Armadas e na Marinha. Estes sistemas, ao serem multiplicadores das capacidades operacionais, têm vindo a alterar consideravelmente a maneira como a Marinha e a Autoridade Marítima Nacional (AMN) conduzem

operações navais pois: reduzem o risco para a vida humana; têm um bom custo-benefício operacional; têm grande flexibilidade, versatilidade e interoperabilidade; possuem capacidade de operar em multi-domínio; e são uma projeção da força das unidades aumentando o alcance e autonomia (Estado-Maior da Armada, 2021).

O tema abordado baseia-se na estima de dados PNT de um veículo não tripulado em ambientes disruptivos, característico das operações militares. Por ser um tema novo e experimental, está alinhado com a perspectiva de desenvolvimento tecnológico da atual Diretiva Estratégica da Marinha (DEM). São exemplo da relevância destes temas inovadores e experimentais para a Marinha: o Centro de Experimentação Operacional da Marinha (CEOM), que apoia projetos de investigação, desenvolvimento, experimentação e inovação da Marinha e parceiros da Academia, Industria e Aliados; a Célula de Inovação e Experimentação Operacional de Sistemas Não Tripulados (CEOV), que tem como cerne o desenvolvimento e experimentação de sistemas não tripulados para apoio nas operações da Marinha; e o *Robotic Experimentation and Prototyping augmented by Maritime Unmanned Systems* (REP-MUS), um exercício que tem como objetivo permitir uma experimentação de larga escala, onde a Academia e a sociedade civil cooperam ativamente com a Marinha para testar conceitos operacionais; entre vários outros.

A presente dissertação enquadra-se no contexto do grupo de trabalho SET-309 da *Science and Technology Organization* (STO) da *North Atlantic Treaty Organization* (NATO). Este grupo parte do princípio que a NATO necessita de dados PNT robustos, resilientes e fidedignos em tempo real para realizar missões em ambientes com interrupção de sinal GNSS. De um modo geral, este grupo de investigação pretende, através de uma abordagem modular *plug-and-play*, desenvolver e integrar sensores e algoritmos em todo o género de veículos, tripulados e não tripulados (com principal foco experimental em veículos terrestres não tripulados), que forneçam informações precisas acerca da posição, velocidade e orientação do veículo.

Este estudo incide na navegação e localização em ambientes de interrupção do sinal GNSS, tendo como questão central de investigação: “Como assegurar informação PNT exata na ausência de dados provenientes do GNSS?”. Desta questão derivam-se outras como identificar os tipos de sensores necessários na ausência de sinal GNSS e como fundir eficazmente a informação desses sensores. O objetivo principal é projetar e analisar sistemas e algoritmos de localização e navegação baseados em filtros de Kalman, através de um veículo terrestre não tripulado (*Unmanned Ground Vehicle*, UGV) equipado com unidade de medida inercial, *encoders* e outros sensores. Pretende-se obter como produto final um sistema capaz de fornecer

localização exata em ambientes onde o sinal GNSS é inexistente ou pouco fiável.

A presente dissertação está estruturada da seguinte forma: no Capítulo 2 realiza-se o enquadramento teórico do tema abordado, descrevendo-se com detalhe os conceitos PNT no contexto militar, os sensores normalmente usados para localização e navegação, e os algoritmos de fusão sensorial. No Capítulo 3 é feita uma revisão do estado da arte em navegação e localização de veículos autónomos e veículos não tripulados aéreos e terrestres em ambientes de interrupção de sinal GNSS, através de métodos de fusão sensorial. O Capítulo 4 descreve detalhadamente a modelação do sistema, incluindo a apresentação do UGV utilizado, a integração e modelação de sensores, o desenvolvimento dos modelos cinemáticos e dinâmicos, e a descrição dos algoritmos de fusão sensorial baseados em EKF. O Capítulo 5 apresenta os resultados experimentais obtidos, descrevendo o processo e ambiente das aquisições de dados, analisando o desempenho dos sistemas em diversos cenários operacionais e discutindo os resultados obtidos e dificuldades encontradas. Por fim, o Capítulo 6 sumariza as principais conclusões da dissertação e propõe direções para investigação futura.



# Capítulo 2

## Enquadramento Teórico

O presente capítulo tem como objetivo apresentar e contextualizar os principais conceitos abordados nesta dissertação, nomeadamente, Posição, Navegação e Tempo (PNT) e *Navigation Warfare* (NAVWAR), sensores passíveis de integrar em UGVs e Filtros de Kalman, um método de fusão sensorial.

### 2.1 PNT no Meio Militar - NAVWAR

O conhecimento espacial, temporal e a escolha do percurso para chegar a um destino pretendido são três questões fundamentais no mundo civil e, principalmente, no meio militar. A NAVWAR é a guerra que se desenvolve em torno de negar essa informação de PNT aos inimigos, garantindo simultaneamente que as forças amigas a mantêm. De acordo com a NATO, “*NAVWAR is defined as preventing the hostile use of Positioning, Navigation and Timing information while protecting the unimpeded use of the information by NATO forces and preserving peaceful use of this information outside the area of operations*” (Saulay, 2002).

O termo PNT, é entendido pelo Departamento de Transportes dos Estados Unidos como uma combinação de três capacidades distintas mas interligadas entre si: Posicionamento, a capacidade de determinar com exatidão a própria localização e orientação tendo como referência um sistema geodésico padrão (como o Sistema Geodésico Mundial WGS84); Navegação, a capacidade de, para além de determinar a posição atual e a posição desejada (relativa ou absoluta), aplicar também correções à rota, orientação e velocidade de modo a atingir a posição desejada em qualquer lugar do mundo, desde a sub-superfície até à superfície e da superfície ao espaço; e, por fim, Tempo, a capacidade de adquirir e manter o tempo exato a partir de um padrão *Coordinated Universal Time* (UTC), em qualquer lugar do mundo e com precisão definida pelo utilizador (U.S Department of Transportation, 2017).

Ao abordar o conceito NAVWAR, é fundamental considerar o conceito mais abrangente da Electronic Warfare (EW). Enquanto a NAVWAR está especificamente associada à informação PNT, a EW abrange operações relacionadas com o espectro eletromagnético na sua totalidade. É relevante notar que todos os mecanismos utilizados para a disrupção do sinal GNSS no contexto da NAVWAR são, efetivamente, manifestações de guerra eletrónica. Existem dois tipos de disrupção: o *jamming* (bloqueio), que consiste em direcionar intencionalmente ondas eletromagnéticas potentes para um recetor alvo com o objetivo de impedir a sua localização; e o *spoofing* (falsificação), que consiste na transmissão de sinais falsos, semelhantes aos do GNSS, com a intenção de gerar uma posição falsa no recetor alvo sem interromper a normal operação dos equipamentos (Medina et al., 2019). Quando, ofensivamente, se nega a informação PNT ao inimigo através de *jamming* e *spoofing* do sinal GNSS e, defensivamente, se evita que o inimigo negue o nosso acesso a essa informação, estamos a falar de *Electronic Attacks* e *Electronic Protection*, respetivamente.

De acordo com Spezio, 2002, a EW envolve a utilização de sistemas para explorar e controlar o espectro eletromagnético de modo a alcançar objetivos militares, diplomáticos e económicos e, simultaneamente, negá-los aos adversários. A aplicação de várias técnicas e tecnologias da EW pode perturbar as comunicações, navegação, localização e radares do inimigo. Em operações militares, a guerra eletrónica interfere com as ações inimigas que envolvem o espectro eletromagnético em todas as fases do combate, desde a mobilização inicial até ao confronto final.

O correto funcionamento de muitos dos sistemas militares responsáveis pela localização, combate e comunicações dependem do sinal GNSS. É, então, essencial que estes sistemas consigam detetar a degradação ou ausência desse sinal e, ainda assim, manter as suas funcionalidades.

Atualmente, existem várias técnicas e novas tecnologias que aumentam a resiliência dos sistemas de modo a não perderem informação PNT fornecida através do sinal GNSS, como recetores redundantes, osciladores *holdover* (dispositivos que mantêm temporariamente a precisão temporal na ausência de sinal GNSS) ou recetores multibanda (Armstrong, 2023). Mas, por outro lado, novas tecnologias de *jamming* e *spoofing* mais avançadas estão continuamente a ser empregues em todo o mundo, colocando em risco a segurança e a fiabilidade (ver Figura 2.1).

O mapa apresentado na Figura 2.1 baseia-se em relatórios de precisão do GPS, ADS-B (*Automatic Dependent Surveillance-Broadcast*), de aeronaves, provenientes de mensagens transmitidas via rádio, ao longo de um período de 24 horas. Uma

vasta área (não colorida) do mapa não está coberta devido à ausência de relatórios ADS-B.

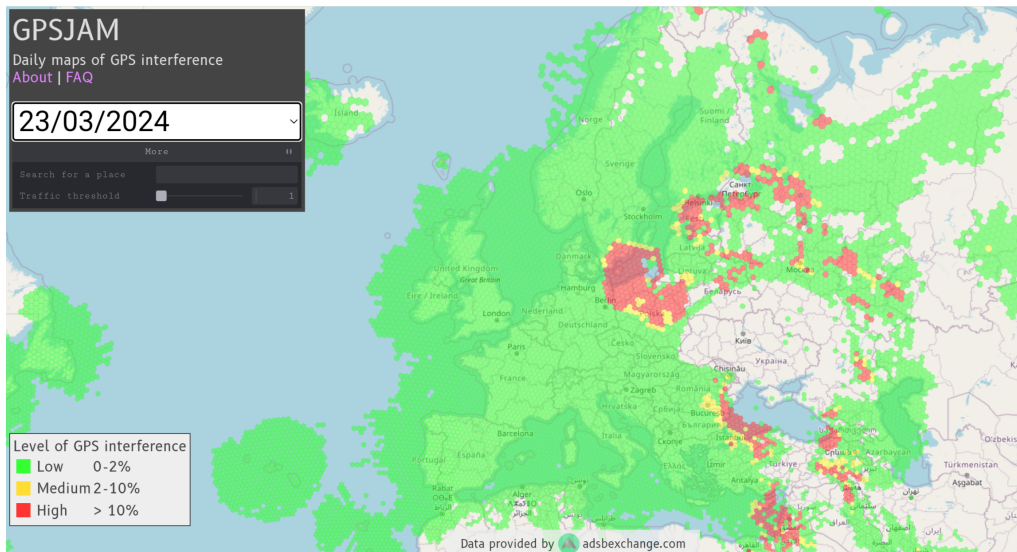


FIGURA 2.1: Mapa GPSJAM, 23 Março 2024.

Fonte: *GPS/GNSS Interference Map 2024*.

É, então, fulcral que existam métodos alternativos para obter dados PNT em ambientes onde ocorre a interrupção do sinal GNSS. Uma das principais alternativas para a obtenção destes dados é a fusão da informação proveniente de vários sensores juntamente com o sinal GNSS recorrendo a, por exemplo, filtros de Kalman.

## 2.2 Sensores

Atualmente existem várias fontes de dados disponíveis que permitem, isoladamente ou em conjunto, com menor ou maior exatidão, a localização e navegação na ausência de sinal GNSS. O objetivo desta secção é enumerar e descrever os princípios gerais de funcionamento, os fundamentos matemáticos e a informação que cada um destes sensores fornece.

No âmbito da robótica, os sensores são regularmente classificados de acordo com o que monitorizam, o objetivo da deteção (perceção interna (PI) ou perceção externa (PE)) e o método utilizado para a obter (ativo/passivo). Tendo como exemplo alguns sensores e dando ênfase aos que irão ser abordados durante o presente capítulo, segundo Siciliano e Khatib, 2016, os mesmos podem ser classificados de acordo com a Tabela 2.1.

Classificação Sensor	Tipo de Sensor (exemplo)	PE / PI
Táteis	Interruptores	PE
Hápticos	Resistivos	PE
	Força/Binário	PI/PE
Motor/Eixo	Encoders	PI
	Potenciômetros	PI
Direção/Orientação	Magnetómetro	PE
	Giroscópio	PI
	Inclinómetro	PE
Baseados em <i>Beacons</i>	GPS	PE
	Beacons Ultrasónicos	PE
	Beacons Rádio	PE
Medição de Distância	Sonar	PE
	Laser	PE
	Luz Estruturada	PE
Movimento/ Velocidade	Acelerómetro	PE
	Radar Doppler	PE
	Sonar Doppler	PE
Identificação	Câmara	PE
	Laser	PE

TABELA 2.1: Classificação de Sensores.

### 2.2.1 Recetores GNSS

O funcionamento de um sistema GNSS pode ser dividido em três partes: satélites, estações em terra e recetores de sinal. Os satélites fornecem informação acerca do seu posicionamento e o instante em que esta foi transmitida (proveniente do relógio atómico de cada satélite); as estações em terra verificam o desvio dos satélites em relação às órbitas ideais predefinidas, a sincronização do tempo e a qualidade dos sinais; e os recetores analisam os sinais rádio emitidos pelos satélites com o objetivo de determinar a que distância se encontram.

Para que um recetor GNSS calcule, uma boa estimativa tridimensional da posição em coordenadas absolutas (latitude, longitude e altitude), necessita conhecer a que distância se encontra de quatro ou mais satélites. Esta distância ( $d$ ) é calculada

com base numa relação entre o tempo ( $t$ ) que o sinal rádio demora a percorrer o caminho do satélite ao recetor, e a velocidade ( $c$ ) a que esta onda eletromagnética viaja (velocidade da luz,  $3.0 \times 10^8 km.s^{-1}$ ):

$$d = t \times c \quad (2.1)$$

O método que determina a posição com base na distância a várias estações localizadas em pontos conhecidos, em momentos definidos no tempo, chama-se trilateração (Thomas e Ros, 2005). Por sua vez, a triangulação (método mais utilizado em navegação) utiliza, ao invés de distâncias, a medição de ângulos entre dois ou mais pontos conhecidos para determinar a posição. Desta forma, é possível afirmar que o processo utilizado pelo sistema GNSS é uma trilateração em 3 Dimensões (3D), latitude, longitude e altitude; utilizando quatro ou mais pontos de referência.

Se houvesse apenas um ponto de referência, a possibilidade de localização do recetor seria uma esfera. Havendo dois satélites, essa possibilidade reduziria para um círculo. Se o recetor tiver acesso a três pontos de referência, a interseção dessas três esferas resultaria na possibilidade do recetor estar localizado em 2 pontos (Figura 2.2). Por fim, havendo quatro satélites como referência, a sua interseção resultará numa única posição possível e será possível sincronizar o relógio do recetor com os relógios dos satélites (Figura 2.3).

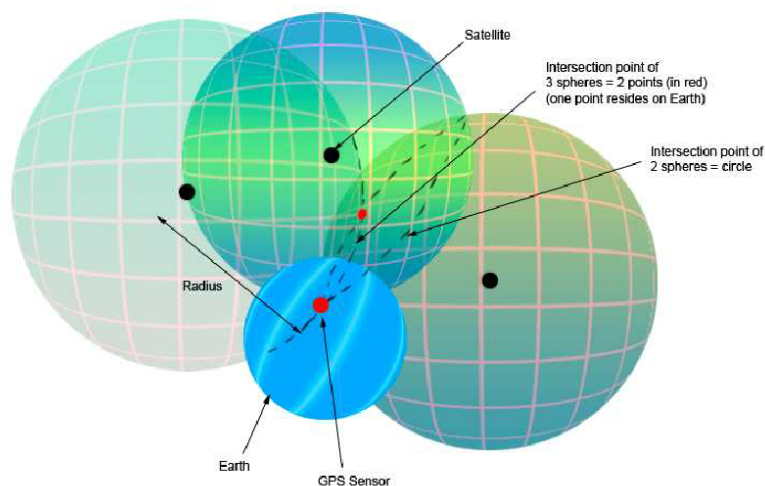


FIGURA 2.2: Trilateração - 3 satélites.

Fonte: Omar et al., 2004.

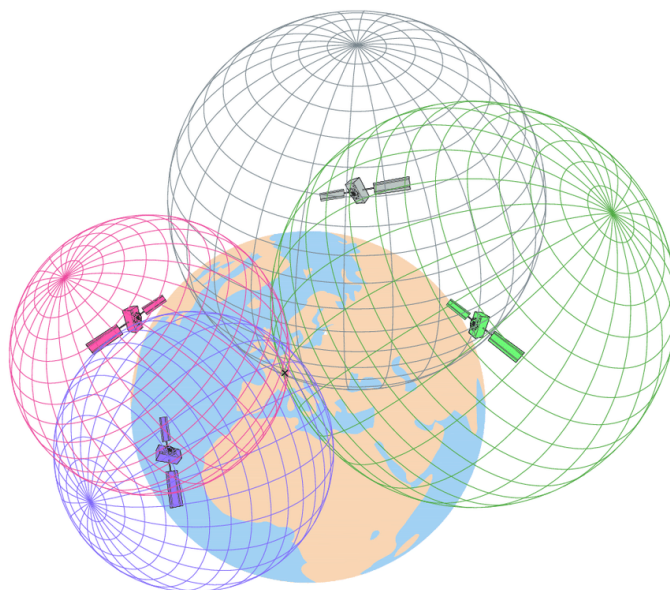


FIGURA 2.3: Trilateração - 4 satélites.

Fonte: Peyret et al., 2015.

Em termos de influências negativas no desempenho da computação da posição, existem fatores controláveis e incontroláveis. Os fatores que influenciam o desempenho dos satélites e as condições meteorológicas são os incontroláveis. Por outro lado, os fatores controláveis são: garantir que o nosso recetor tem uma linha de visão desobstruída para os satélites; efetuar uma análise das condições atmosféricas de modo a ter a perceção da sua influência na qualidade do sinal GNSS; e possuir um recetor que seja sensível e consiga captar sinais de fraca intensidade. O sinal GNSS, apesar de estar no espectro das microondas e atravessar, sem grandes alterações, plástico e vidro é absorvido na água e refletido em vários materiais (p.e. edifícios, árvores ou o solo), tornando-o pouco fiável em diversas situações (Siciliano e Khatib, 2016). Estas reflexões geram erros de multi-percurso, fazendo com que o recetor GNSS receba várias versões do mesmo sinal: uma que provem diretamente dos satélites e outras que percorrem trajetos mais longos devido às reflexões. Esses sinais refletidos adicionais podem causar erros no cálculo da posição e resultar em imprecisões.

## 2.2.2 Unidades de Medida Inercial (IMUs)

As Unidades de Medida Inercial ou, em inglês, *Inertial Measurement Unit* (IMU), são dispositivos normalmente compostos por um acelerómetro de 3 eixos, um giroscópio de 3 eixos e, opcionalmente, por um magnetómetro de 3 eixos. A fusão dos dados provenientes destes sensores, através de programação de baixo nível

na própria IMU, permite mitigar as limitações individuais de cada componente e fornecer dados abrangentes acerca da velocidade angular, aceleração linear e, em unidades com magnetômetro, intensidade do campo magnético.

Uma IMU pode ser de dois tipos, estabilizada ou integrada/fixa. Intuitivamente, as IMU estabilizadas, de modo a poderem fazer medições corretas, estão instaladas numa estrutura estabilizadora complexa e necessitam de ser regularmente calibradas de modo a manter o sistema de referência alinhado com o do veículo. As fixas estão diretamente integradas no sistema, sendo que todas as variações detetadas neste equipamento coincidem com as variações do veículo. Atualmente, os custos de produção e operação dos sistemas estabilizados comparados com o baixo custo e boa eficiência das IMU fixas/integradas torna a utilização destas últimas muito mais comum (Siciliano e Khatib, 2016).

Analisando separadamente, o objetivo de um giroscópio é medir a velocidade angular, tridimensionalmente, nos eixos x, y e z (ver Figura 2.4); a finalidade do acelerómetro é medir a aceleração linear nos três eixos referidos anteriormente (ver Figura 2.5); e o objetivo do magnetómetro é fornecer dados acerca do *heading* (azimute) com base na medição do campo magnético (ver Figura 2.6). De realçar que os magnetómetros, ao estarem integrados no veículo, estão sujeitos aos campos magnéticos parasitas induzidos pela maquinaria em redor que introduz erros nas suas medições. Por exemplo, uma IMU (com os 3 componentes) integrada num UGV está sujeita não só às interferências provenientes da estrutura metálica do veículo como também às variações no campo magnético produzidas pelos motores das rodas em movimento.

Em robótica, a utilização destes sensores baseia-se na tecnologia *Micro-Electro-Mechanical Systems* (MEMS), que permite a utilização destes componentes em escala microscópica, facilitando assim a sua aplicabilidade. Os MEMS são sistemas sofisticados que integram componentes elétricos e mecânicos, à escala microscópica, para desempenhar funções específicas. Inicialmente, estes sistemas foram projetados para incorporar apenas elementos elétricos e mecânicos, mas o seu âmbito expandiu-se desde então, passando também a incluir elementos óticos e de radiofrequência. A característica representativa da tecnologia MEMS é a acoplagem dos comportamentos elétricos e mecânicos, o que significa que o desempenho mecânico destes dispositivos está geralmente ligado às suas características elétricas (Lee, 2011).




FIGURA 2.4: Princípio Funcionamento Giroscópio.  
 Fonte: *MEMS Gyroscope Basics | MEMS Gyroscope Working Operation* 2012.

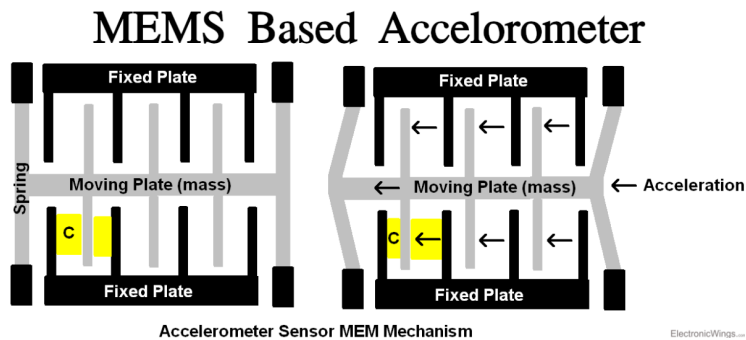


FIGURA 2.5: Princípio Funcionamento Acelerómetro.  
 Fonte: Amutham, 2020.




FIGURA 2.6: Princípio Funcionamento Magnetómetro.  
 Fonte: *What is a Magnetometer and How Does It Work?* 2021.

### 2.2.3 Odometria

A odometria aplica-se tanto no contexto de veículos terrestres como no de veículos marítimos. Apesar de fornecer, de um modo geral, os mesmos dados acerca do movimento do veículo, tem princípios de funcionamento bastante diferentes que irão ser descritos ao longo desta secção.

No âmbito de veículos terrestres, a odometria é a técnica que utiliza a medida de distância percorrida por cada uma das rodas, em conjunto com a sua velocidade de rotação, de modo a estimar o movimento do veículo. Essencialmente, incorpora um modelo matemático que calcula uma estimativa idealista da posição, orientação e velocidade de todo o veículo através da integração das variações individuais induzidas em cada junta/roda ao longo do tempo (Dudek e Jenkin, 2024). Este processo, que utiliza apenas sensores que fornecem dados acerca da perceção interna, para navegar e determinar o movimento de um veículo ao longo do tempo, é conhecido como *Dead Reckoning* (Siciliano e Khatib, 2016). A expressão “estimativa idealista” está associada ao facto de, num mundo ideal, conhecendo a posição inicial do veículo e conhecendo todas as variações induzidas em cada roda, seria possível calcular exatamente o movimento do veículo.

Considere-se o veículo simples, de 1 eixo e 2 rodas, representado na Figura 2.7. De modo a obter a velocidade linear e angular do veículo, a partir da informação dos *encoders* de cada roda, a odometria tem no cerne as leis da cinemática. Consequentemente, a orientação e posição são calculadas através de integração temporal destas velocidades.




FIGURA 2.7: Cinemática Odometria - 1 eixo, 2 rodas.

Fonte: Adaptado de Siciliano e Khatib, 2016.

Considerando a velocidade linear do veículo,  $v$ , e a velocidade linear de cada uma das rodas,  $v_R$  e  $v_L$ :

$$v = \frac{v_R + v_L}{2} \quad (2.2)$$

Considerando a velocidade angular do veículo,  $\omega$ , a velocidade linear de cada um das rodas,  $v_R$  e  $v_L$ , e a distância entre as rodas,  $D$ :

$$\omega = \frac{v_R - v_L}{D} \quad (2.3)$$

Na esfera dos veículos marítimos de superfície e subsuperfície, a odometria baseia-se não nas variações individuais de cada roda mas sim nas variações de velocidade. Existem dois tipos principais de equipamentos que fornecem informação acerca da odometria em veículos marítimos, os odómetros, que funcionam de forma passiva, e o *Doppler Velocity Log* (DVL), que, apesar de também se incluir no termo "odómetro", funciona de forma ativa.

Os odómetros passivos são utilizados para medir a velocidade em relação à coluna de água e por isso também permitem medir, por integração, a distância navegada. Existem várias classes de deste tipo de odómetros, que se diferenciam entre si através do seu modo de funcionamento: hélice propulsor-rebocado, eletromagnético, de pressão, e de resistência ao movimento do navio.

Atualmente, em muitos navios da Marinha Portuguesa utilizam-se odómetros de pressão e eletromagnéticos. Os odómetros de pressão medem diferenças de pressões entre uma tomada de água estática (voltada para baixo) e uma tomada dinâmica (voltada para a frente). Os odómetros eletromagnéticos (Figura 2.8) produzem um campo magnético constante e medem as variações da força eletromotriz (FEM) induzida. Detalhando, a existência de movimento de um condutor (neste caso, a água) em redor de um campo magnético constante produz uma FEM que é proporcional à velocidade do navio.





FIGURA 2.8: Odômetro Eletromagnético.

Fonte: Oways, 2021.

O DVL (Figura 2.9), principalmente usado para navegação e posicionamento de veículos subaquáticos, é também utilizado em veículos de superfície. Genericamente, baseia-se no efeito Doppler para medir a velocidade do veículo em relação ao fundo do mar ou à coluna de água. Em relação ao seu modo de funcionamento, inicialmente, são emitidos ecos acústicos em direção ao fundo do mar ou à coluna de água que por sua vez são refletidos de volta para os seus transdutores. Através da medição da mudança de frequência (efeito *Doppler*) entre os sinais emitidos e os recebidos é determinada a velocidade relativa do veículo. As velocidades medidas podem então ser integradas no tempo para calcular a distância percorrida pelo veículo (Rudolph e Wilson, 2012; Snyder, 2010).

FIGURA 2.9: *Doppler Velocity Log*.Fonte: *Doppler Log - principle, working, speed and errors* 2018.

## 2.2.4 Sistemas Baseados em *Beacons*

Os sistemas de posicionamento baseados em *beacons* são sistemas independentes do sinal GNSS que utilizam pontos de referência fixos para determinar a posição. Estes sistemas são frequentemente utilizados em ambientes *indoor* (por não haver linha de vista direta com os satélites GNSS), mas também podem ser aplicados em ambientes *outdoor* onde o sinal GNSS é fraco ou inexistente.

Em termos de tecnologia, os *beacons* podem ser classificados como acústicos (p.e., ultrassom), óticos (p.e., infravermelhos), rádio (p.e., WiFi e *Bluetooth Low Energy* (BLE)), entre outros. As várias tecnologias podem utilizar diferentes técnicas para calcular a posição, que se diferenciam entre si por processarem diferentes dados e medições. Estes dados e medições podem ser: a direção e ângulo do sinal recebido (*Angle of Arrival* (AoA)), o tempo entre a transmissão e receção do sinal (*Time of Arrival* (ToA) e variantes), a força do sinal recebido (*Received Signal Strength Indicator* (RSSI)), ou a força de vários sinais recebidos num recetor proveniente de múltiplos emissores na mesma estrutura (*fingerprint*), entre outros (Pascacio et al., 2021).

Para além da aplicação dos sistemas baseados em *beacons* como Sistemas de Posicionamento *Indoor* (*Indoor Positioning System*, IPS), existem sistemas semelhantes utilizados na navegação e radioposicionamento marítimos. Estes sistemas são o *LOng RAnge Navigation* (LORAN-C) (atualmente descontinuado nos Estados Unidos da América e na Europa) e, futuramente, o seu substituto atualizado e melhorado *enhanced LORAN* (eLORAN) e o conceito *Enhanced Radar Positioning System* (ERPS).

O *enhanced LORAN* é um sistema PNT padronizado globalmente, baseado em tecnologias tradicionais de baixa frequência e navegação de longo alcance (LORAN). Inclui uma infraestrutura modernizada e as suas transmissões estão sincronizadas com uma fonte UTC, através de um método independente do GNSS. A grande diferença em relação ao LORAN-C é a adição de um canal de dados no sinal transmitido, permitindo fornecer ao recetor correções, avisos e informações sobre a integridade do sinal (Helwig et al., 2011).

O ERPS utiliza *beacons* RADAR (*RAdio Detection And Ranging*) e radares especialmente modificados, *eRacons* e *eRadars* respetivamente, de modo a permitir que os *eRadars* calculem automaticamente posições absolutas. Neste sistema, os *beacons* radar transmitem a sua posição absoluta codificada nos sinais de resposta

para os radares que, por sua vez, utilizam esses sinais para calcular a posição absoluta do navio (IALA-AISM, 2021).

Outra opção é a utilização de *Signals of Opportunity* (SOPs), neste caso, sinais eletromagnéticos emitidos por infraestruturas rádio marítimas com uma distribuição considerável ao longo da costa, como *beacons* rádio e estações terrestres do *Automatic Identification System* (AIS) (Gewies et al., 2020).

### 2.2.5 LiDAR

*Light Detection and Ranging* (LiDAR) é uma tecnologia que utiliza impulsos de luz (laser) para medir distâncias e mapear o ambiente. Tal como os sistemas de posicionamento baseados em *beacons*, o LiDAR pode ser considerado IPS, mas também pode ser utilizado *outdoor*, dependendo das suas características.

O principal objetivo deste sensor é capturar informação espacial do meio envolvente, conseguindo criar modelos 3D precisos, auxiliando na navegação e prevenindo colisões. Em termos concretos de funcionamento, o sistema básico LiDAR efetua uma medição de tempo (ToA) entre a emissão e a receção do impulso laser para determinar distâncias aos objetos que formam o ambiente que o rodeia. Através desta medição de tempo ( $t$ ), e tendo em conta que o impulso laser viaja à velocidade da luz ( $c$ ), é possível obter a distância que o impulso laser percorreu. A equação 2.4 permite calcular a distância ( $d$ ) a que está o objeto que refletiu o impulso (Kim et al., 2021).

$$d = \frac{t \times c}{2} \quad (2.4)$$

Os sistemas LiDAR mais comuns baseiam-se nos seguintes métodos: varrimento macromecânico (motor e espelho giratório) (Figura 2.10); MEMS (*microscanner* integrado com atuadores); e *phased array* ótico (*array* de guias de ondas com atrasos de fase ajustáveis) (Kim et al., 2021).

A luz laser emitida pelos equipamentos LiDAR pode propagar-se por longas distâncias e não depende das condições meteorológicas, mantendo a sua precisão com, por exemplo, chuva intensa, neve ou nevoeiro.




FIGURA 2.10: Princípio Funcionamento LiDAR mecânico giratório.

Fonte: Islam et al., 2022.

## 2.3 Fusão de Dados

A fusão sensorial consiste em combinar os dados de vários sensores através de modelos matemáticos de modo a gerar um melhor conhecimento do sistema nos quais estes sensores estão inseridos, possibilitando a medição direta ou a estima de uma medição indireta. Com “melhor conhecimento do sistema” percebe-se: mais consistente, exato e fiável do que seria apenas com 1 fonte de dados.

Há vários métodos de fusão sensorial, diferentes entre si mas com o mesmo objetivo geral. Nesta secção descreve-se, com principal foco, o Filtro de Kalman, método de fusão sensorial escolhido para o presente estudo por, entre outros motivos, ter a vantagem de ser recursivo, não necessitando de manter em memória todas as observações (apenas a do estado imediatamente anterior), o que o torna ideal para aplicações em sistemas que estão em contínua mudança (problemas do mundo real) e em sistemas embebidos. Serão abordadas também as variantes *Extended* e *Unscented* deste filtro e o *Particle Filter*.

### 2.3.1 Filtro de Kalman

O Filtro de Kalman (*Kalman Filter*, KF) é um algoritmo utilizado para estimar o estado de um sistema que se baseia num processo de dois passos, predição e atualização. A combinação da previsão do modelo para a dinâmica do sistema (que descreve a evolução de determinadas variáveis ao longo do tempo) com medições ruidosas (com incerteza), diretas ou indiretas, dessas variáveis ao longo do tempo permite estimar o estado do veículo.

Existem, então, dois *stages* no Filtro de Kalman: equações de predição e equações de atualização. As equações de predição projetam (no tempo) a estima do

estado atual e da covariância do erro por forma a obter as estimativas *a priori* para a próxima predição. As equações de atualização incorporam medições provenientes dos sensores nas estimativas preditivas *a priori* de modo a obter estimativas *a posteriori*, atualizadas e mais exatas (Welch e Bishop, 2006).

De modo a clarificar a aplicabilidade e o funcionamento do KF, antes de serem apresentadas as equações que constituem o KF linear, considere-se que temos um UGV, equipado com recetor GNSS, que terá de fazer um percurso (que engloba a passagem dentro de um edifício) no qual é necessário saber a todo o momento a sua posição e velocidade, de modo a efetuar a navegação em segurança. Os dados GNSS não nos fornecem, diretamente, informação da velocidade e, apesar de termos o posicionamento em ambientes *outdoor*, assim que entrar no edifício ficaremos sem dados e a incerteza acerca da sua posição aumentará. Felizmente, também há informações sobre como se move o UGV: se souber informação acerca dos comandos enviados aos motores das rodas, e se a sua trajetória se mantiver a mesma sem que nada interfira com o seu movimento, provavelmente continuará nessa mesma direção no momento seguinte. No entanto, também não se conhece tudo sobre este movimento do UGV: as rodas podem deslizar ou passar por terrenos irregulares e pode, também, ser movimentado manualmente sem que as rodas se movam; assim, a quantidade de rotação das mesmas pode não representar exatamente a distância percorrida pelo veículo, e a previsão não será ideal. Sintetizando, o recetor GNSS fornece dados de posicionamento absoluto com incerteza, a que se soma a previsão feita a partir dos sensores do veículo com informação de como ele se está a movimentar. De modo a resolver problemas como este, o filtro de Kalman produz uma estima mais precisa e fidedigna fundindo toda a informação disponível (de todos sensores disponíveis e previsões do estado do veículo).

Importa referir que, se o modelo for linear e a incerteza na dinâmica do processo e o ruído da medição puderem ser modelados como uma distribuição Gaussiana, o KF proporcionará uma estimativa ótima do estado, não existindo nenhum outro algoritmo que forneça melhores resultados. Nesta situação, o Filtro de Kalman fornece a estimativa *a posteriori* para o estado do sistema, dadas todas as observações. A explicação que se segue parte deste pressuposto, o Filtro de Kalman linear.

De modo a avançar para o desenvolvimento das fases de predição e atualização, é necessário definir o modelo dinâmico e o modelo de observação subjacentes a estas fases do KF (equações 2.5 e 2.6, respetivamente). Considere-se  $x_k$  o estado atual,  $x_{k-1}$  o estado anterior,  $u_{k-1}$  a atuação no instante anterior,  $w_k$  as perturbações

externas,  $z_k$  a observação atual e  $v_k$  o ruído da observação, com  $w_k$  e  $v_k$  gaussianos.

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_k \quad (2.5)$$

$$\mathbf{z}_k = \mathbf{h}(\mathbf{x}_k) + \mathbf{v}_k \quad (2.6)$$

O Filtro de Kalman assume as funções  $f()$  e  $h()$  como lineares, o que permite que estas possam ser representadas por matrizes (equações 2.7 e 2.8). Estas são as matrizes que, juntamente com as matrizes de covariância (das perturbações externas e do ruído da observação), serão utilizadas nas fases de atualização e predição do KF.

$$\mathbf{x}_k = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{B}_k \mathbf{u}_{k-1} + \mathbf{w}_k \quad (2.7)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \quad (2.8)$$

A fase de predição do KF tem como base a equação 2.9, que permite calcular a previsão do estado no instante atual (com base no estado anterior e a atuação exercida no sistema no instante anterior),  $\hat{x}_k$ , e a equação 2.10, que calcula a nova incerteza associada a esta predição,  $P_k$ . Considere-se  $\hat{x}_{k-1}$  a estimativa da previsão do estado no instante anterior,  $P_{k-1}$  a incerteza associada à predição anterior,  $F_k$  a matriz do processo de predição,  $B_k$  a matriz de controlo das influencias externas,  $u_k$  a influência de perturbações ou fatores externos no sistema, e  $Q_k$  a covariância da incerteza adicional dos fatores externos.

$$\hat{\mathbf{x}}_k = \mathbf{F}_k \hat{\mathbf{x}}_{k-1} + \mathbf{B}_k \mathbf{u}_k \quad (2.9)$$

$$\mathbf{P}_k = \mathbf{F}_k \mathbf{P}_{k-1} \mathbf{F}_k^T + \mathbf{Q}_k \quad (2.10)$$

A fase de atualização do KF consiste nas equações 2.11 e 2.12, que permitem calcular, respetivamente, a nossa nova melhor estimativa do estado do veículo,  $\hat{x}'_k$ , e a incerteza associada a esta atualização,  $P'_k$ . Considere-se que  $Z_k$  reúne as observações adquiridas no instante  $k$  (observações que podem ser obtidas a partir de sensores ou de medições efetuadas manualmente), a expressão *Inovação* ( $Z_k - H_k \hat{x}_k$ ) mede a discrepância entre  $Z_k$  e  $H_k \hat{x}_k$  no espaço de observações, e o ganho de Kalman,  $K'$ , projeta esse erro para o espaço do estado, contendo o erro em função de  $R_k$  (covariância do erro da medição).

O ganho de Kalman (equação 2.13) é a matriz do quociente entre a incerteza na previsão ( $P_k H_k^T$ ) e a incerteza no erro da medição ( $H_k P_k H_k^T + R_k$ ), para sistemas lineares (como o que estamos a analisar)  $K'$  irá produzir a estima com o menor erro quadrático.

$$\hat{\mathbf{x}}'_k = \hat{\mathbf{x}}_k + \mathbf{K}'(\mathbf{Z}_k - \mathbf{H}_k \hat{\mathbf{x}}_k) \quad (2.11)$$

$$\mathbf{P}'_k = \mathbf{P}_k - \mathbf{K}' \mathbf{H}_k \mathbf{P}_k \quad (2.12)$$

$$\mathbf{K}' = \mathbf{P}_k \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (2.13)$$

A figura 2.11 ilustra intuitivamente o funcionamento e o fluxo de informação por detrás do Filtro de Kalman.

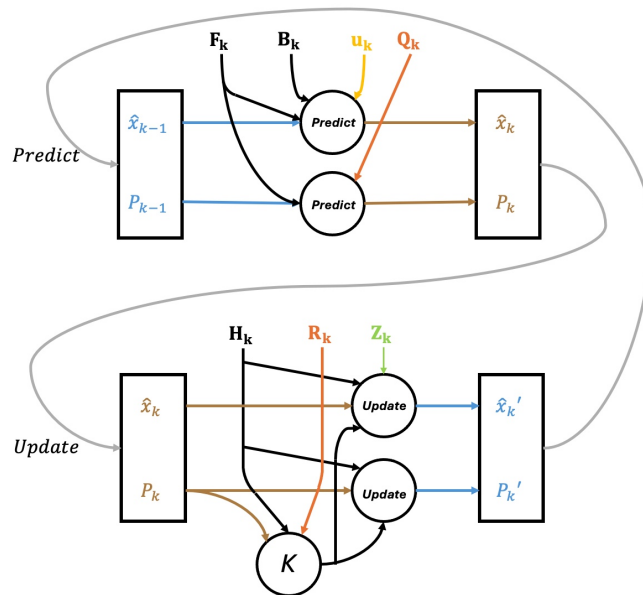


FIGURA 2.11: Fluxo de informação Filtro de Kalman.

Fonte: Adaptado de *How a Kalman filter works, in pictures* 2015.

### 2.3.2 Outros Métodos de Fusão

Geralmente, os modelos de dinâmica e observação não são lineares. Este é o princípio do qual partiu a necessidade de serem desenvolvidas variantes ao KF que conseguissem, baseadas em modos de funcionamento semelhantes, lidar com modelos não lineares. Estas variantes são o *Extended Kalman Filter* (EKF), o *Unscented*

*Kalman Filter* (UKF) e o *Particle Filter* (PF). A não linearidade implica que os resultados destas variantes do KF nunca sejam inteiramente ótimos para sistemas do mundo real. No entanto, o EKF, o UKF e o PF são muito usados na prática (em particular o EKF) devido ao carácter não linear da maior parte dos problemas de estimação.

O *Extended Kalman Filter* estende o KF de modo a lidar com as não linearidades e o problema do cálculo das matrizes  $F_k$  e  $H_k$ . Lineariza, para cada instante  $k$ , as funções  $f()$  e  $h()$  em torno da estimativa do estado atual  $\hat{x}_k$ . Na prática esta linearização é feita com o cálculo do Jacobiano. O Jacobiano é a matriz formada pelas derivadas parciais de primeira ordem de uma função. Por estarem a ser realizadas aproximações, através dos cálculos do Jacobiano, já não é possível assumir a otimização do EKF.

O *Unscented Kalman Filter*, por outro lado, processa as não linearidades com recurso aos designados *sigma-points*. Este filtro assume que a incerteza é uma distribuição normal e está centrada na estimativa mais recente. O UKF sonda a função não linear em pontos, *sigma-points*, que estão distribuídos pelos eixos principais da elipsoide formada pela incerteza (em volta da estima atual) e calcula uma aproximação linearizada com base nos resultados dessa sondagem (Thrun et al., 2005). Este calculo é feito através de uma média ponderada de todos os *sigma-points*.

O *Particle Filter* diferencia-se dos 3 filtros falados anteriormente devido ao seu estado estimado poder apresentar uma densidade de probabilidade multimodal (não Gaussiana). Consiste numa propagação irregular de partículas em que cada uma tem um funcionamento semelhante ao do Filtro de Kalman. Esta propagação é feita segundo o modelo dinâmico. Consoante a sua concordância ou discordância com as medições/observações vão sendo geradas novas partículas ou eliminadas, respetivamente, de forma a fazer convergir as partículas para a verdadeira distribuição de probabilidade do estado.

# Capítulo 3

## Estado da Arte

Nos últimos 20 anos tem havido uma grande incidência na investigação acerca de navegação e localização de veículos autónomos e veículos não tripulados, através de fusão sensorial, em ambientes de disrupção de sinal GNSS. A ideia de sistemas mais baratos e facilmente acessíveis abriu várias portas para o seu estudo e conseqüente desenvolvimento.

Os estudos acerca deste tema incidem maioritariamente em *Unmanned Aerial Vehicles* (UAVs), sendo esta a vertente mais desenvolvida, complexa e mais estudada atualmente. Por este motivo, durante o Estado da Arte que se segue existem, para além de várias referências a estudos de *Unmanned Ground Vehicles*, bastantes referências a estudos de veículos aéreos.

### 3.1 *Unmanned Aerial Vehicles*

Os estudos que se seguem apresentam várias propostas para colmatar a dificuldade em epígrafe, por exemplo, no estudo de Bachrach et al., 2010 é estudada a fusão de vários sensores (incluindo laser) e unidades inerciais a bordo de um *Micro Air Vehicle* (MAV), neste caso um helicóptero quadrotor, controlados de forma hierárquica, para explorar e mapear de forma autónoma mantendo a estabilização de voo.

No trabalho de Balamurugan et al., 2016 são estudadas várias técnicas já desenvolvidas, baseadas em sistemas visuais (p.e. odometria visual e *Simultaneous Localization and Mapping* (SLAM)), para a navegação em ambientes onde o sinal GNSS é inexistente. Este estudo conclui que uma abordagem baseada em odometria visual é mais rápida e requer menos memória e poder computacional comparado com uma baseada em SLAM.

Aumentando a escala para navegação e localização de longo alcance, Hermann et al., 2016, referem que uma primeira dificuldade é a navegação em missões de curto alcance e esta é colmatada através do uso de filtros de Kalman, e que a segunda e mais desafiante são as missões de longo alcance. Para esta segunda dificuldade apresentam uma solução que se apoia numa fusão de sensores LiDAR com *Digital Elevation Models* (DEMs) disponíveis (uma representação da superfície topográfica da região onde se pretende navegar). É também referido que incorporar sensores adicionais permite melhorar a robustez do sistema a fornecer uma posição correta ou então diminuir os requisitos técnicos da IMU. O método foi capaz de estimar com precisão o estado de uma aeronave ao longo de um voo de 218 km com um erro de posição final de 27 m.

Para resolver o problema da falta de sinal GNSS, através de uma abordagem completamente diferente, Russell et al., 2020, estudaram uma cooperação entre dois UAVs, onde um veículo A obtém a sua localização através de um sistema de navegação inercial e um veículo B, equipado com GPS, partilha a sua posição em vários instantes. O agente A mede a direção de chegada do sinal GNSS partilhado (em relação ao seu sistema de navegação inercial) e, através da compilação desta informação por um algoritmo, é obtida uma estimativa bastante rigorosa da posição real do veículo A. O algoritmo utilizado neste estudo é não iterativo, no sentido em que não ajusta continuamente os desvios ao longo do tempo, por ser uma situação onde os desvios entre atualizações de estado não são significativos.

No artigo de Gyagenda et al., 2022, é também feita uma revisão de técnicas de navegação de UAVs no ambiente em epígrafe. Foram tidos em conta estudos onde a navegação se baseava em módulos inerciais, visuais, rádio e LiDAR, tendo concluído que a navegação e localização baseada em sistemas inerciais fundidos com óticos é a chave para ultrapassar a dificuldade.

## 3.2 *Unmanned Ground Vehicles*

Leonard e Durrant-Whyte, 1991, desenvolveram um sistema de navegação e localização para um UGV que se move num ambiente conhecido. O algoritmo tem por base um EKF que processa dados da observação de *beacons* geométricos, detetados através de sonar, comparando-os com um mapa, definido previamente, da localização destes *beacons*. Este sistema de navegação é implementado, primeiramente, num veículo equipado com um sonar rotativo e, por fim, num veículo com

seis transdutores sonar fixos. A abordagem com o sonar instalado num servomotor diminui a ambiguidade da medida do azimute ao alvo e, apesar da rotação do sensor ser um processo demorado, a informação acerca do espaço circundante que esta sondagem fornece facilita a interpretação dos dados. O conjunto de sonares fixos, devido à sua rápida e simultânea obtenção de dados, permite uma estima da posição dinâmica em tempo real (de notar que com a medição de apenas um sonar fixo isolado esta afirmação não se aplica).

No artigo de Barshan e Durrant-Whyte, 1995 os autores descrevem o desenvolvimento e a avaliação experimental de um sistema de navegação inercial (*Inertial Navigation System*, INS) de baixo custo, especificamente concebido para UGVs. o INS proposto utiliza um giroscópio triaxial, um acelerómetro triaxial e dois sensores de inclinação. O principal foco deste estudo é a incorporação de modelos detalhados de erro dos sensores inerciais num EKF de modo a estimar a posição e orientação de um veículo em movimento. Esta modelação do erro tem em conta o ruído do sensores e o seu *bias*. Os resultados demonstram que, com a modelação adequada dos erros dos sensores, especialmente dos giroscópios, é possível obter melhorias substanciais no desempenho do sistema de navegação, tornando viável a utilização de INS de baixo custo em aplicações reais, particularmente em ambientes *outdoor*. De realçar que a incorporação destes erros no EKF melhora bastante o desempenho dos giroscópios, reduzindo os erros de orientação em até 5 vezes e tornando viável as estimativas por períodos acima de 10 minutos; no entanto, as estimativas de posição são apenas confiáveis por períodos até 10 segundos, devido aos erros acumulados no processo de dupla integração dos dados do acelerómetro.

Sukkarieh et al., 1999 elaboraram um artigo que aborda o desenvolvimento e implementação de um sistema de localização e navegação (baseado em EKF) de alta fiabilidade e robustez para UGVs, baseado na combinação de dados GPS com dados IMU de baixo custo. O foco principal do estudo é alcançar a integridade necessária do sistema de navegação para aplicações autónomas, através da deteção de possíveis falhas tanto antes como durante o processo de fusão de sensores. O sistema implementado considera falhas do IMU, causadas por *bias* do sensor e desalinhamento da unidade, bem como falhas no recetor GPS, devido a erros de multi-percurso. A implementação foi feita em veículos reais de média e grande escala, os resultados obtidos demonstram que este sistema de navegação e localização é um candidato ideal para aplicações em veículos terrestres, desde que implementadas no EKF as técnicas de deteção de falhas e erros (através das covariâncias das medições).

No âmbito da navegação autónoma de veículos terrestres não tripulados, o

estudo de Scheduling et al., 1999 focou-se no desenvolvimento teórico e teste experimental de um sistema de navegação robusto para caminhões de carga, transporte e descarga utilizados em minas, ambientes subterrâneos e acidentados. Esta investigação abordou um dos desafios mais significativos neste contexto: a derrapagem e deslizamento do veículo em terrenos irregulares e acidentados. O sistema de navegação proposto funde os dados provenientes de um IMU, odometria e um sensor laser através de um *Extended Kalman Filter*. Demonstrou-se que, neste terreno difícil e irregular, o deslizamento do veículo é significativo, especialmente durante as curvas, o que invalida os modelos convencionais que não consideram este fenómeno. Este trabalho sublinha a importância de uma modelação precisa dos sensores e do movimento do veículo para garantir uma navegação fiável.

O artigo de Dissanayake et al., 2001 descreve o desenvolvimento de um sistema de navegação para UGV's que implementa um algoritmo baseado num filtro de informação linear (estritamente relacionado com o filtro de Kalman, fornecem a mesma solução mas com técnicas computacionais diferentes). Esta implementação melhora a exatidão de IMU's de baixo custo e, conseqüentemente, o cálculo da velocidade do veículo e posição integrados neste tipo de veículos que, habitualmente, têm associado um rápido crescimento do erro. O foco principal está em melhorar esta exatidão exclusivamente através da introdução de restrições não holonómicas ao movimento do veículo, sem recurso a sensores e medições externas. O algoritmo apresentado neste artigo melhora a eficácia do IMU, estendendo significativamente o tempo que este pode ser confiável, como a única ferramenta de navegação. Esta eficácia é demonstrada através da comparação experimental entre os erros dos resultados da integração direta dos dados do IMU e os erros dos resultados do algoritmo que utiliza os dados do IMU com as restrições não holonómicas (baseado no filtro de informação); tendo como medições de referência os dados da fusão do IMU com o GPS (através do filtro de informação com as restrições), que também foram alvo de comparação posteriormente. Numa segunda fase, foi desenvolvida e testada uma implementação que funde a informação da posição e velocidade GPS, a velocidade das rodas (*encoder*) e a informação do IMU (com as restrições); estratégia que permite aumentar a resiliência do sistema de navegação na eventual falha do sinal GPS. O artigo apresenta um resumo dos resultados da primeira experiência, Tabela 3.1.

### 3.2. Unmanned Ground Vehicles

Method Implemented	Position Error (m)	Velocity Error (m/s)	Attitude Error (°)
Free Inertial	750N 300E	10N 5E	0.53 Roll 0.96 Pitch
Constrained Inertial	10N 5E	< 1 N,E	0.41 Roll 0.45 Pitch

TABELA 3.1: Comparação de resultados experimentais do algoritmo de Dissanayake et al., 2001 entre IMU e IMU com restrições não holonômicas.

Através da fusão sensorial do IMU, GPS, e bússola digital com *Unscented Kalman Filter*, Zhang et al., 2005 apresentam o seu método de navegação de um UGV. Este método consiste em dois passos, estabelecer primeiramente modelos dinâmicos que consideram a rotação da terra, o ruído do sistema e o erro das medições e, seguidamente, utilizar um UKF para a estima do estado do UGV. O modelo dinâmico consiste na transformação do referencial de referência do IMU e do referencial de referência do recetor GPS para o referencial fixo e local da navegação do UGV, de modo a poder comparar todos os dados de igual modo e introduzi-los nas equações do UKF, obtendo uma estima do estado global do sistema. Segundo os autores, a escolha do UKF em detrimento do EKF tem por base a sua maior exatidão de cálculo.

No estudo de Aqel et al., 2016, o principal foco reside em estimar com exatidão a *ego-motion* (translação e orientação de um veículo) através de uma ou múltiplas câmaras, um processo chamado odometria visual (*Visual Odometry*, VO). Afirma que esta é uma técnica robusta para navegação autónoma, posicionamento e deteção de obstáculos. Ao efetuar um estudo completo acerca da VO, e compará-la com os sensores e técnicas mais comuns de localização (odometria, IMUs, GPS e sensores laser), o estudo conclui que este processo é extremamente preciso para estimar a *ego-motion* de robôs e consegue evitar as desvantagens associadas aos restantes sensores. Comparando diretamente com a odometria, a VO é uma solução pouco dispendiosa que não é afetada pela grande desvantagem da odometria, desliz de rodas e terreno irregular. Por fim, conclui também que as principais desvantagens da VO estão associadas ao seu custo computacional e às condições de luz e imagem, condições que afetam principalmente os ambientes *outdoor*, onde existem sombras e luz solar direta.

No artigo de Nemeč et al., 2019 é testado um novo método de fusão sensorial e, posteriormente, comparado com o EKF. O método proposto de fusão sensorial entre odometria, giroscópio, acelerómetro, magnetómetro e pontos de referência visuais tem como objetivo estimar a posição de um UGV. As suas maiores vantagens são a simplicidade e a eficácia computacional; simplicidade que permite a implementação

em *hardware* de baixo custo e eficácia que se traduz num tempo de computação quatro vezes inferior ao EKF (aliado a um maior erro no posicionamento). Os resultados obtidos nas simulações revelam também que apenas com a odometria obtêm-se resultados bastante precisos em terrenos planos (inclinação zero), mas em terrenos irregulares o acelerómetro e o giroscópio são essenciais para uma boa estima.

Kassas et al., 2022, com base noutro método, conseguem colmatar a falta de sinal GNSS desde que existam SOPs para explorar no ambiente, isto é, sinais rádio ambiente que não se destinam à navegação, por exemplo, rádio AM/FM, WiFi, de rede, televisão digital e satélites em órbita terrestre baixa. Estes autores apresentaram uma abordagem SLAM via rádio (baseada em EKF), que permite a exploração de SOPs para navegação neste ambiente. Este artigo apresenta os primeiros resultados experimentais para a navegação com SOPs num ambiente onde não existe sinal GNSS. O artigo expõe, também, uma comparação com um sistema de navegação de um UGV baseado na fusão GPS-IMU, através de EKF. De acordo com a Figura 3.1, o veículo terrestre, ao percorrer uma trajetória de cerca de  $5\text{km}$  em 180 segundos, num ambiente onde existe disrupção de sinal GPS, utilizando este sistema GPS-IMU teve um desvio na posição de erro quadrático médio  $238\text{m}$  em relação à trajetória real do veículo. Em contraste, a abordagem SLAM, utilizando apenas uma fonte de sinal *Long Term Evolution (LTE) cellular*, cuja posição absoluta era vagamente conhecida (resultando numa incerteza inicial da posição na ordem de vários quilómetros), alcançou uma posição final com erro quadrático médio de apenas  $32\text{m}$ .

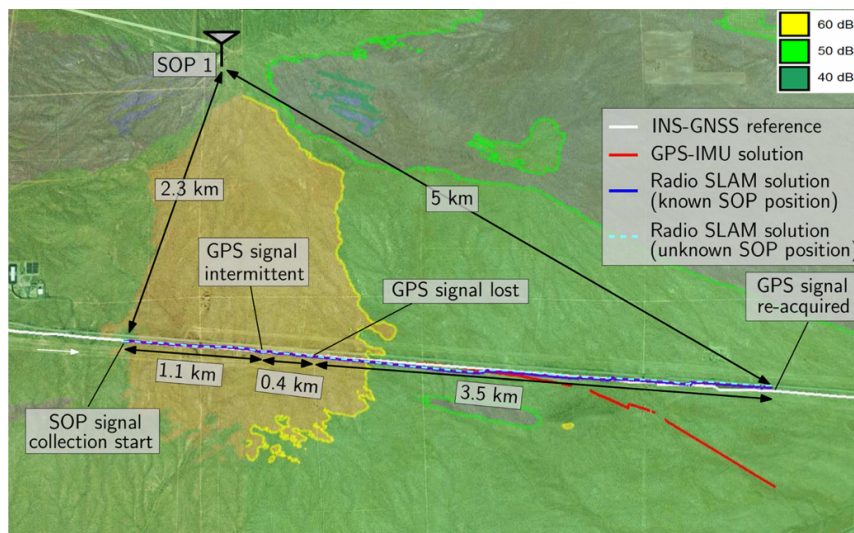


FIGURA 3.1: Ambiente e resultados experimentais de Kassas et al., 2022.

Por fim, Nguyen et al., 2022 afirmam que o sucesso da estima da posição é uma condição necessária para se poder desenvolver com sucesso um veículo autônomo terrestre *indoor*. O trabalho desenvolve-se em redor da investigação de um sistema de fusão sensorial *low-cost*, baseado em EKF, constituído por um sistema *Ultra-Wide-Band* (UWB) combinado com o IMU e a odometria. Através de simulações e resultados experimentais com sensores isolados e fusão sensorial, o estudo conclui que a aplicação do EKF na fusão sensorial entre UWB e IMU produz uma excelente estima do estado do veículo (posição e orientação), com pouco erro e uma taxa elevada de atualização.



# Capítulo 4

## Modelação do Sistema

Neste capítulo irá modelar-se o sistema, começando por se apresentar o UGV utilizado, o Leo Rover, e os sensores que lhe foram integrados.

Irão ser apresentadas duas abordagens para a modelação do veículo, uma a três dimensões (Modelo Completo) e outra a duas dimensões (Modelo Simplificado). Serão definidos os referenciais e a notação utilizada; os modelos da cinemática e da dinâmica para cada abordagem, os modelos dos sensores e as respetivas equações do Filtro de Kalman.

### 4.1 Descrição Geral da Plataforma Leo Rover

A presente secção introduz o UGV utilizado na dissertação e ilustrado na Figura 4.1, o Leo Rover. Este veículo terrestre não tripulado foi desenvolvido pela empresa *fictionlab* e adquirido pelo Centro de Investigação Naval (CINAV), órgão da Escola Naval responsável pelas atividades de Investigação e Desenvolvimento.




FIGURA 4.1: Leo Rover.

Fonte: *Leo Rover specification* 2024.

### 4.1.1 Características Físicas e *Hardware*

O Leo Rover é um UGV, com tração 4x4, adequado para uso *indoor* e *outdoor* devido à sua construção com classificação de proteção IP55. Um equipamento com este Índice de Proteção limita a entrada de pó e resíduos (5) e de jatos de água de alta pressão de qualquer direção (5).

As dimensões físicas do veículo estão representadas na Figura 4.2. Tem um peso de  $6.5\text{kg}$  e dimensões máximas  $425 \times 448 \times 305\text{ mm}$ . Pode atingir uma velocidade linear máxima de, aproximadamente,  $0.4\text{ m/s}$  e uma velocidade angular máxima de cerca de  $60\text{ graus/s}$ . Pode lidar com obstáculos até  $70\text{mm}$  de tamanho. Tem uma capacidade de carga de cerca de  $5\text{ kg}$  e possui uma plataforma de montagem superior que mede  $299 \times 183\text{ mm}$ , uma grelha que permite a instalação de componentes externos ao UGV.




FIGURA 4.2: Dimensões Leo Rover.

Fonte: *Leo Rover specification 2024*.

#### 4.1. Descrição Geral da Plataforma Leo Rover

Ao nível de interfaces de conexão, inclui uma entrada miniUSB à prova de água e um ponto de acesso WiFi de 2,4 ou 5 GHz com uma antena externa que permite um alcance de até 100m, com transmissão de vídeo.

Relativamente aos componentes: possui 4 rodas, cada uma alimentada por um motor interno *Direct Current* (DC); os pneus são feitos de borracha, preenchidos com espuma (não pneumáticos) e têm um diâmetro interno de 71mm, um diâmetro externo de, aproximadamente, 130mm e uma largura de cerca de 70mm; é alimentado por uma bateria Li-Ion com uma capacidade de 5800mAh e corrente máxima de 8A, que permite um tempo estimado de funcionamento de 4 horas; possui uma câmara que tem uma resolução de 5 Megapíxeis; relativamente a eletrónica, inclui um Raspberry Pi 4B como computador e o LeoCore como microcontrolador de baixo nível (com funções de: *drivers* de potência para os motores, leitura dos encoders das rodas, interface com o IMU, controlo do LED da bateria e fornecimento de energia ao RPi). Estes componentes estão associados entre si de acordo com a arquitetura de *Hardware* apresentada na Figura 4.3

Em relação a sensores, está equipado de fábrica com um IMU MEMS composto por acelerómetro e giroscópio soldado ao microcontrolador (Figura 4.4) e possui 4 *encoders* de 12 *Pulses Per Revolution* (PPR) associados ao motor de cada roda.

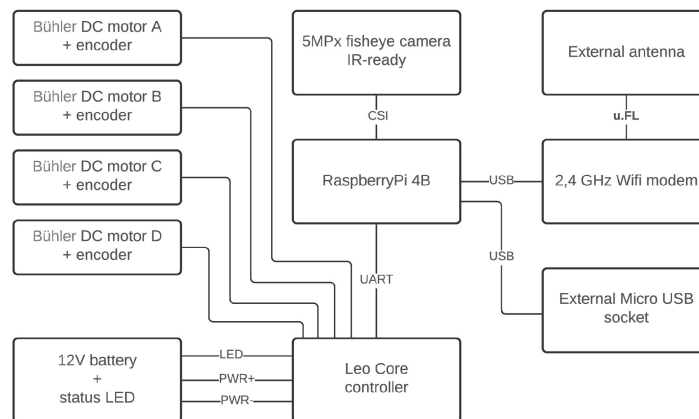


FIGURA 4.3: Arquitetura *Hardware* Leo Rover.

Fonte: Adaptado de *Leo Rover specification 2024*.




FIGURA 4.4: IMU Leo Rover.

Fonte: Adaptado de *Leo Rover specification* 2024.

### 4.1.2 Software

O Leo Rover opera em Ubuntu 20.04, sistema operativo linux, e, por sua vez, *Robotic Operating System* (ROS). O ROS tem uma estrutura modular e integrada de nós, tópicos, ferramentas de visualização e armazenamento de dados que facilita o desenvolvimento, teste e implementação de sistemas robóticos.

Em ROS os nós comunicam através de tópicos, cada nó pode publicar ou subscrever tópicos de modo a enviar e receber dados. A estrutura de Software do Leo Rover, baseada em ROS, está ilustrada na Figura 4.5.

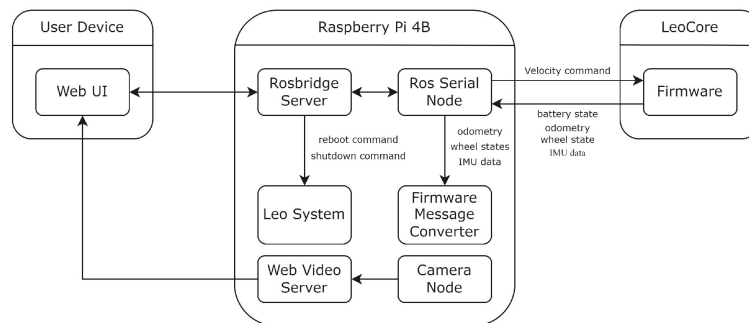


FIGURA 4.5: Estrutura *Software* Leo Rover.

Fonte: Adaptado de *Leo Rover specification* 2024.

Por exemplo, o nó *Ros Serial Node* (situado no Raspberry Pi) comunica com o nó do *Firmware* (situado no LeoCore) de modo a, por um lado, enviar dados acerca da velocidade (proveniente dos controlos) e, por outro lado, obter informação acerca do IMU, estado das rodas, odometria e bateria. Por sua vez, o nó *Ros Serial Node* comunica com o *Firmware Message Converter*, permitindo que este último nó

publique vários tópicos com informação normalizada do IMU, estado das rodas e odometria prontos para armazenamento e posterior processamento.

O *firmware* é um programa que opera diretamente no processador do Le-oCore, fornecendo várias funcionalidades ao Raspberry Pi através de uma ligação em série. Inclui funcionalidades de controlo diferencial de condução, monitorização dos estados das rodas, monitorização da tensão da bateria, cálculo da odometria das rodas e suporte ao IMU.

A interface de utilizador (*User Interface*, UI) é acessível através de um navegador web e interage com o servidor *Rosbridge* para obter e transmitir informação. A interface permite controlar o Rover através de um teclado ou joystick virtual, exibe um fluxo de vídeo da câmara transmitido pelo *Web Video Server*, exibe a leitura instantânea da tensão da bateria e incorpora controlos para reinicializar e desativar o sistema.

#### 4.1.3 Integração do Recetor GNSS - UBlox EVK-M8

O módulo UBlox EVK-M8N (Figura 4.6) é um recetor GNSS de alto desempenho e baixo consumo de energia, cerca de 20 mA. Este recetor suporta múltiplos sistemas globais de navegação por satélite: GPS/SBAS, GLONASS, Galileo e Bei-Dou, podendo ser configurado e testado através do software *u-center* desenvolvido pela UBlox (Figura 4.8).



FIGURA 4.6: Recetor GNSS - UBlox EVK-M8.

Fonte: *UBlox EVK-M8N GPS module 2024*.

Para integrar este módulo no Leo Rover, ao nível de *hardware*, foi apenas necessário conectar a interface USB integrada (alimentação e transferência de dados) ao RPi do UGV, ilustrado na Figura 4.12.

A integração ao nível de *software* é mais complexa e foi feita de acordo com as instruções dadas pela *fictionlab* (acessíveis na documentação do Leo Rover). Este processo foi moroso e foram encontradas várias dificuldades.

Após a integração deste módulo tanto ao nível de *hardware* como de *software* o Leo Rover ficou de acordo com a Figura 4.7.



FIGURA 4.7: UBlox EVK-M8 integrado.

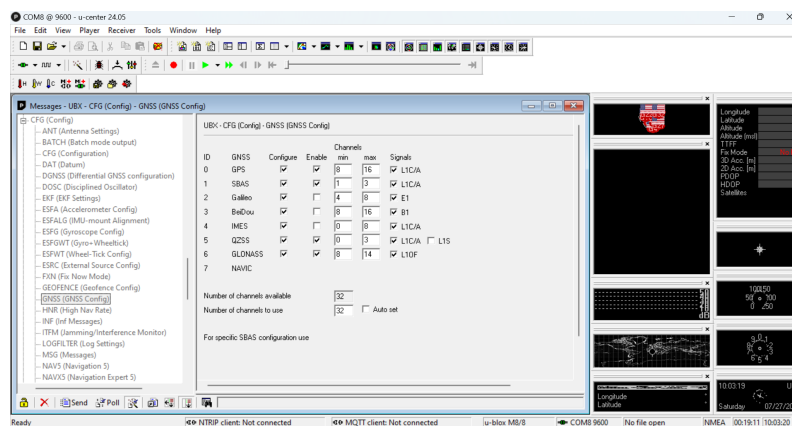


FIGURA 4.8: Software u-center.

### 4.1.4 Integração do IPS - Marvelmind Indoor GPS

O Indoor GPS da Marvelmind é um IPS projetado para fornecer dados de localização (2D ou 3D) precisos ( $\pm 2$  cm) a veículos autônomos ou não tripulados. Podendo ser utilizado para localizar qualquer objeto em movimento através de *beacons* móveis acoplados. O conjunto de equipamentos utilizado foi o Starter set Super-MP, consistindo em, de acordo com a Figura 4.9, 1 modem com capacidade para 250 beacons e 250 submapas e 5 *beacons* com capacidade de transmissão e recepção. Este IPS funciona através de ultrassons o que, segundo o fabricante, traz grandes vantagens para todo o sistema.



FIGURA 4.9: Marvelmind Indoor GPS - Starter set Super-MP.

Fonte: *Marvelmind Indoor Navigation System 2024.*

O fabricante desenvolveu também um *software* que permite configurar, estabelecer e gerir todo o IPS. Este *software* é o *Dashboard* apresentado na Figura 4.10.

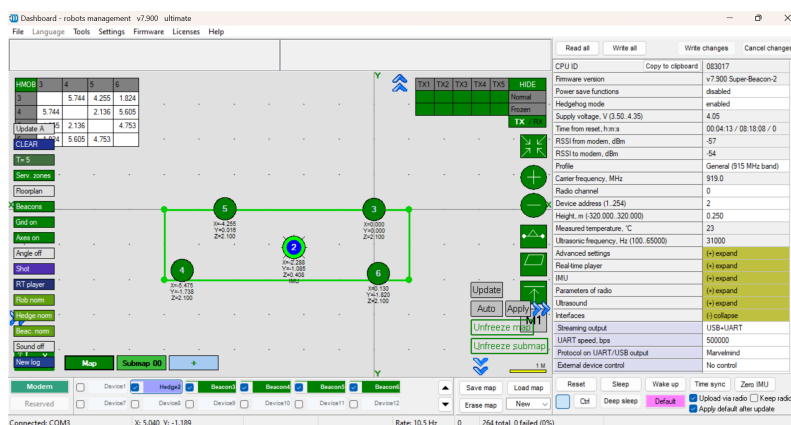


FIGURA 4.10: Marvelmind Indoor GPS - Dashboard.

De um modo geral e tendo como referência o Starter set, o sistema funciona da seguinte maneira: posicionam-se os beacons que irão estar estáticos; liga-se o

modem a um computador e através do *Dashboard* estabelece-se a zona de serviço; o último *beacon* será móvel (*hedge*) e ao passar na zona de serviço coberta pelo alcance dos *beacons* estáticos irá ser atribuída uma posição a este *hedge*, com base na distância a cada *beacon* estático.

Ao nível de arquiteturas básicas de sistema, pode optar-se por *Non-Inverse Architecture* e *Inverse Architecture*, sendo que a diferença está em qual dos grupos de *beacons* emite e qual recebe os ultrassons. Na primeira arquitetura quem emite os ultrassons é o *hedge* e quem os recebe são os *beacons* estáticos; na segunda arquitetura é o inverso.

Em relação à integração *hardware* ilustrada na Figura 4.12, a ligação é feita através do interface USB do *hedge* conectado diretamente ao RPi do Leo Rover, permitindo a transmissão de informação. Ao instalar o *beacon* móvel na estrutura física do Leo Rover considerou-se, do modo a minimizar os erros de posicionamento, elevar este componente acima de possíveis obstáculos que pudessem interferir com a transmissão/receção de ultrassons (Figura 4.11).

Relativamente à integração do *software* do sistema de navegação *indoor* da Marvelmind, o pacote *leo\_marvelmind* da *ficitonlab* já se encontrava programado e preparado para utilização mas, devido a um problema no desenvolvimento deste pacote, foi necessário recorrer a uma abordagem mais complexa.



FIGURA 4.11: IPS Marvelmind integrado.



FIGURA 4.12: Ligação entre sensores integrados e RPi.

Após todas as integrações, o Leo Rover mudou a sua silhueta, ficando de acordo com a Figura 4.13.



FIGURA 4.13: Leo Rover após integrações.

## 4.2 Ambiente Computacional

Relativamente ao ambiente computacional da operação com os sensores (receptor GNSS e IPS), todo o controlo foi feito através dos respetivos softwares em sistema operativo Windows.

Em relação à ligação com o Leo Rover, foi feita sempre através do sistema operativo Linux (Ubuntu 20.04) a correr em simultâneo com o Windows (onde se controlava a operação dos sensores) através de uma máquina virtual.

O ambiente computacional próprio do Leo Rover foi definido durante a Subsecção 4.1.2.

### 4.3 Referenciais e Notação

Para obter o modelo do veículo é necessário, primeiramente, definir os referenciais e a notação utilizada. Existem quatro referenciais distintos no âmbito do UGV e sensores utilizados: o referencial solidário com o UGV  $\{B\}$ , o referencial GNSS, o referencial do sistema de posicionamento *indoor* e o referencial do mundo (fixo)  $\{U\}$ .

O referencial solidário com o Leo Rover,  $\{B\}$ , (Figura 4.14) é utilizado como referência para o IMU (acelerómetro e giroscópio) e para a odometria. Este sistema de coordenadas, baseado no REP 103 (ROS (*Robotic Operating System*) *Enhancement Proposal*) de Foote e Purvis, 2000, define que em relação ao UGV o eixo dos  $xx$  aumenta para a frente, o eixo dos  $yy$  aumenta para a esquerda, o eixo dos  $zz$  aumenta para cima e define também que as rotações sobre os três eixos ( $x$  - balanço (*roll*),  $y$  - arfagem (*pitch*) e  $z$  - cabeceio (*yaw*)) aumentam no sentido anti-horário de 0 a  $2\pi$ . No caso específico do *yaw*, este é zero quando aponta para Este. A origem deste referencial é o centro de massa do UGV.

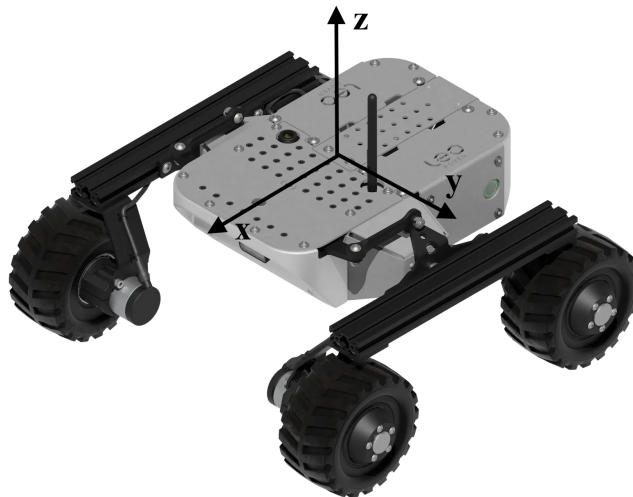


FIGURA 4.14: Referencial Leo Rover,  $\{B\}$ .

Fonte: Adaptado de *Leo Rover specification* 2024.

O referencial WGS84, referencial do recetor GNSS integrado no Leo Rover, tem como referência geral a origem das coordenadas de latitude, longitude e altitude. A origem deste referencial é o local onde os valores da latitude e longitude são nulos (interseção entre o meridiano de Greenwich e o equador) e a altitude é considerada zero (superfície do elipsoide de referência, aproximando-se ao nível médio das águas do mar).

O referencial do IPS está centrado em um dos quatro *beacons* estáticos, definido previamente, que compõem a zona de serviço. De acordo com a Figura 4.15, que corresponde à zona de serviço, o *beacon* número 3 foi definido como a origem do referencial e os eixos estão definidos da seguinte maneira (considerando uma trajetória de acordo com a seta da imagem):  $x$  positivo para trás,  $y$  positivo para a direita e  $z$  positivo para cima. De acordo com este referencial, os valores que iremos obter durante a trajetória serão negativos para o eixo dos  $xx$  e dos  $yy$ . De notar que, ao criar a zona de serviço, é possível introduzir a altura dos *beacons* tornando possível que a origem do eixo dos  $zz$  seja no solo, sendo de esperar que durante a trajetória os valores de  $zz$  sejam positivos.

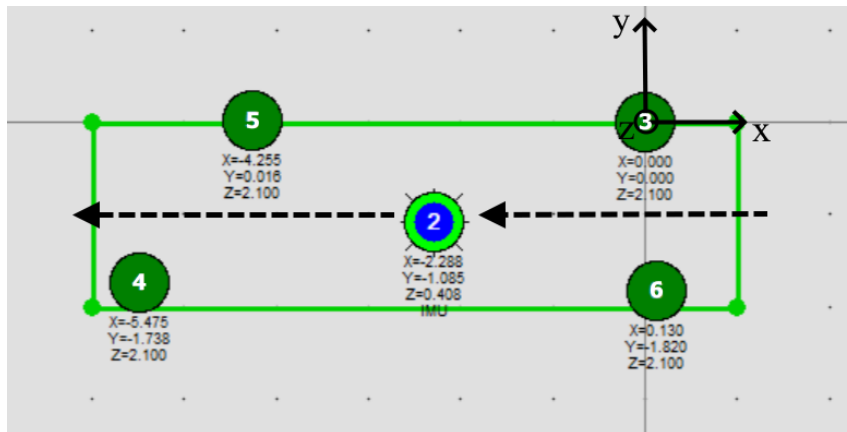


FIGURA 4.15: Zona de Serviço e Referencial IPS.

De modo a haver um referencial comum, fixo, que pudesse ser utilizado como referência tanto para as medições dos sensores como para os movimentos do Leo Rover, definiu-se o referencial do mundo  $\{U\}$ . Este referencial está fixado num ponto fixo dentro da Escola Naval (local onde foram efetuadas as aquisições de dados), com coordenada GPS conhecida, diferente para cada uma das aquisições de dados. Ao definir este referencial e a sua origem assume-se que as alterações de um ponto na superfície terrestre podem ser desprezadas. Esta assunção é válida uma vez que o movimento de rotação da terra não tem efeito relevante sobre UGVs de baixa velocidade e escala quando comparado com a escala global. Os eixos do referencial

seguem a convenção *East-North-Up* (ENU), como apresentado na Figura 4.16, o eixo dos  $xx$  direcionado para Este, o eixo dos  $yy$  direcionado para Norte e o eixo dos  $zz$  direcionado verticalmente para cima a partir da superfície da Terra. Os valores das rotações sobre os eixos aumentam no sentido anti-horário (counterclockwise, CCW).

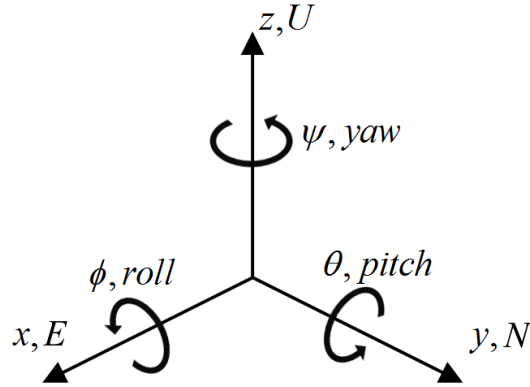


FIGURA 4.16: Referencial do mundo  $\{U\}$ .  
 Fonte: Adaptado de Bieda e Jaskot, 2016.

De modo a padronizar a notação e facilitar a leitura e o estudo entre trabalhos, utiliza-se a nomenclatura de posição e ângulos definida pela SNAME (1950) (Tabela 4.1) para descrever o movimento de veículos marítimos.

DOF*	Descrição	Posição e Ângulos
1	Movimento na direção do eixo $x$ ( <i>surge</i> )	$x$
2	Movimento na direção do eixo $y$ ( <i>sway</i> )	$y$
3	Movimento na direção do eixo $z$ ( <i>heave</i> )	$z$
4	Rotação sobre eixo $x$ ( <i>roll</i> )	$\phi$
5	Rotação sobre eixo $y$ ( <i>pitch</i> )	$\theta$
6	Rotação sobre eixo $z$ ( <i>yaw</i> )	$\psi$

\*Graus de Liberdade (*Degrees Of Freedom*, DOF)

TABELA 4.1: Nomenclatura SNAME para veículos aquáticos.

Fonte: Adaptado de Fossen, 2011.

Considere-se: a rotação do referencial  $\{B\}$  em relação a  $\{U\}$  (*roll*, *pitch*, *yaw*) designada por  $\eta$  e definida pela matriz coluna  $\eta = [\phi \ \theta \ \psi]^T$ ; a posição de origem de  $\{B\}$ , expressa no referencial  $\{U\}$ , designada por  $p$  também definida pela matriz coluna  $p = [p_x \ p_y \ p_z]^T$ ;  $Uv/Bv$  a velocidade linear do veículo, expressa no

referencial  $\{U\}/\{B\}$ ;  ${}^U a/{}^B a$  a aceleração linear do veículo, expressa no referencial  $\{U\}/\{B\}$ ;  ${}^U \omega/{}^B \omega$  a velocidade angular do veículo, expressa no referencial  $\{U\}/\{B\}$ . Definem-se  $v$ ,  $a$  e  $\omega$  como vetores 3D.

## 4.4 Modelo Cinemático e Dinâmico do Leo Rover

Para descrever e controlar eficazmente o movimento de veículos não tripulados, os modelos cinemáticos e dinâmicos têm de ser personalizados e adaptados. No entanto, é importante destacar que a abordagem descrita é versátil e pode ser usada em qualquer veículo terrestre não tripulado numa situação 3D ou 2D, respetivamente.

O objetivo do modelo cinemático é descrever o movimento e a orientação do centro de massa do veículo com base em conceitos geométricos, relacionando as velocidades lineares e angulares com a posição e a orientação.

O objetivo do modelo dinâmico é descrever como as forças aplicadas no veículo afetam o seu movimento.

### 4.4.1 Modelo Completo (3D)

O Modelo Completo irá ser aplicado numa trajetória a três dimensões e considera as acelerações/velocidades/posições 3D do veículo, bem como a orientação/velocidade angular 3D.

#### Cinemática

Para descrever o movimento do veículo Leo Rover utilizam-se os referenciais definidos acima e define-se o modelo cinemático do veículo que pode ser descrito por:

$${}^U v = J_1(\eta) {}^B v \quad (4.1)$$

$${}^U \omega = J_2(\eta) {}^B \omega \quad (4.2)$$

$J_1$  é a matriz de rotação, definida em Fossen, 2011, que converte velocidades e acelerações lineares expressas no referencial  $\{B\}$  para o referencial  $\{U\}$ :

$$J_1(\eta) = {}^U R_B(\eta) = \begin{bmatrix} c\psi c\theta & -s\psi c\phi + c\psi s\theta s\phi & s\psi s\phi + c\psi s\theta c\phi \\ s\psi c\theta & c\psi c\phi + s\psi s\theta s\phi & -c\psi s\phi + s\psi s\theta c\phi \\ -s\theta & c\theta s\phi & c\theta c\phi \end{bmatrix} \quad (4.3)$$

onde  $c$  representa a função  $\cos()$  e  $s$  representa a função  $\sin()$ .  $J_2(\eta)$  é a matriz de transformação, definida em Fossen, 2011, que converte velocidades angulares expressas em  $\{B\}$  para  $\{U\}$ :

$$J_2(\eta) = \begin{bmatrix} 1 & s\phi t\theta & c\phi t\theta \\ 0 & c\phi & -s\phi \\ 0 & s\phi/c\theta & c\phi/c\theta \end{bmatrix} \quad (4.4)$$

onde  $t$  representa a função trigonométrica  $\tan()$ .

### Dinâmica

O modelo dinâmico do UGV, a três dimensões, é descrito pelo seguinte sistema de equações:

$$\begin{cases} \dot{\eta} = {}^U \omega \\ \dot{p} = {}^U v \\ {}^U \dot{v} = {}^U a \end{cases} \quad (4.5)$$

Para analisar e estudar a dinâmica do veículo definiu-se o modelo como sendo de velocidade angular e aceleração linear constantes. Tem-se, então, também que:

$$\begin{cases} {}^U \dot{\omega} = 0 \\ {}^U \dot{a} = 0 \end{cases} \quad (4.6)$$

#### 4.4.2 Modelo Simplificado (2D)

O Modelo Simplificado irá ser utilizado para uma trajetória a duas dimensões. Este modelo tem como cerne a restrição do movimento a um plano horizontal, daí a especificação 2D. Desta restrição resulta que a posição no eixo  $z$  é sempre nula e a rotação sobre o eixo  $x$  e sobre o eixo  $y$  é, também, nula:

$$\begin{aligned}
 p_z &= 0 \\
 \phi &= 0 \\
 \theta &= 0
 \end{aligned} \tag{4.7}$$

De 4.7 aplicado em 4.3, 4.4, 4.5 advém que:

$$\begin{aligned}
 {}^U v_z &= {}^B v_z = 0 \\
 {}^U \omega_x &= {}^B \omega_x = 0 \\
 {}^U \omega_y &= {}^B \omega_y = 0
 \end{aligned} \tag{4.8}$$

### Cinemática

Para obter as equações que descrevem o modelo cinemático do UGV foi feita a transformação das velocidades lineares e angulares em {B} para {U}, através das matrizes de rotação 4.3 e 4.4 simplificadas pela restrição do movimento a um plano horizontal:

$$\begin{bmatrix} {}^U v_x \\ {}^U v_y \\ 0 \end{bmatrix} = \begin{bmatrix} \cos(\psi) & -\sin(\psi) & 0 \\ \sin(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} {}^B v_x \\ {}^B v_y \\ 0 \end{bmatrix} \tag{4.9}$$

$$\begin{bmatrix} 0 \\ 0 \\ {}^U \omega_z \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ {}^B \omega_z \end{bmatrix} \tag{4.10}$$

e conseqüentemente conclui-se que,

$$\begin{cases} {}^U v_x = {}^B v_x \cos(\psi) - {}^B v_y \sin(\psi) \\ {}^U v_y = {}^B v_x \sin(\psi) + {}^B v_y \cos(\psi) \\ {}^U \omega_z = {}^B \omega_z \end{cases} \tag{4.11}$$

De modo a simplificar a nomenclatura definiu-se, a partir de 4.11 :

$$\begin{aligned}
 v_x &\equiv {}^U v_x \\
 v_y &\equiv {}^U v_y \\
 \omega &\equiv {}^B \omega_z
 \end{aligned}$$

Para este modelo impôs-se uma restrição não holonómica, considerou-se que o veículo durante a sua trajetória não "derrapa". Ao ter em conta esta restrição, a velocidade no referencial {B} passa a ter apenas componente no eixo  $x$  e  ${}^B v_y = 0$ .

As equações da cinemática que descrevem o movimento e a orientação do centro de massa do veículo para o modelo simplificado são:

$$\begin{cases} v_x = v \cos(\psi) \\ v_y = v \sin(\psi) \\ {}^U \omega_z = \omega \end{cases} \quad (4.12)$$

onde se definiu  $v \equiv {}^B v_x$ .

### Dinâmica

A duas dimensões, aplicando as restrições descritas ao movimento do Leo Rover, obtém-se o seguinte modelo dinâmico:

$$\begin{cases} \dot{\psi} = \omega \\ \dot{p}_x = v_x = v \cos(\psi) \\ \dot{p}_y = v_y = v \sin(\psi) \end{cases} \quad (4.13)$$

e para a aceleração temos que:

$$\begin{cases} \dot{v}_x = {}^U a_x \\ \dot{v}_y = {}^U a_y \end{cases} \quad (4.14)$$

onde, por derivação temporal de  $v_x$  e  $v_y$  em 4.14, se obtém

$$\begin{cases} \dot{v}_x = \dot{v} \cos(\psi) - v \omega \sin(\psi) \\ \dot{v}_y = \dot{v} \sin(\psi) + v \omega \cos(\psi) \end{cases} \quad (4.15)$$

Repare-se que o sistema de equações 4.15 é o resultado da transformação da aceleração em {B} para {U}, e a equação matricial é definida por:

$$\begin{bmatrix} \dot{v}_x \\ \dot{v}_y \end{bmatrix} = \begin{bmatrix} \cos(\psi) & -\sin(\psi) \\ \sin(\psi) & \cos(\psi) \end{bmatrix} \begin{bmatrix} a \\ v\omega \end{bmatrix} \quad (4.16)$$

onde  $a \equiv {}^B a_x$  é a aceleração tangencial e  $v\omega$  é a aceleração centrípeta do veículo. Desta forma, tem-se para a aceleração no referencial do veículo:

$${}^B a = \begin{bmatrix} a \\ v\omega \end{bmatrix} \quad (4.17)$$

## 4.5 Filtro de Kalman Estendido com Modelo Simplificado

Na presente secção apresenta-se o *Extended Kalman Filter* desenvolvido, método escolhido para fazer a fusão de dados. Apresentam-se também os modelos matemáticos dos sensores utilizados na aquisição de dados, integrados no Leo Rover, que serão posteriormente utilizados no EKF desenvolvido para o Modelo Simplificado.

### 4.5.1 Modelo de Estado, Predição e Atualização

Para o EKF do Modelo Simplificado (trajetória 2D restringida a um plano horizontal, veículo não holonómico, aceleração linear e velocidade angular constantes) definiu-se o modelo de estado 4.18; o modelo de predição geral 4.19 (correspondente à fase de predição) e específico para cada dimensão do estado 4.20; e o modelo de observação geral 4.21 (correspondente à fase de atualização).

Assim, o modelo de estado é o vetor:

$$X \equiv [\omega \quad a \quad v \quad \psi \quad p_x \quad p_y]^T \quad (4.18)$$

Tem-se então a equação matricial para o modelo de predição:

$$X(k+1) = f(X(k)) + W_k, \quad \text{com } W_k \sim \mathcal{N}(0, Q_k). \quad (4.19)$$

onde  $f()$  é o modelo não linear da predição e  $W_k$  é o ruído, de covariância  $Q_k$ .  $W_k$  segue uma distribuição Normal de média nula e desvio padrão igual à covariância  $Q_k$ . Explicitamente, para cada componente do modelo de estado:

$$\begin{cases} \omega(k+1) = \omega(k) \\ a(k+1) = a(k) \\ v(k+1) = v(k) + T_k a(k) \\ \psi(k+1) = \psi(k) + T_k \omega(k) \\ p_x(k+1) = p_x(k) + T_k v(k) \cos(\psi(k)) \\ p_y(k+1) = p_y(k) + T_k v(k) \sin(\psi(k)) \end{cases} \quad (4.20)$$

com  $T_k$  o período entre o instante atual  $t_{k+1}$  e o instante anterior  $t_k$ . Note-se também que  $\omega(k+1) = \omega(k)$  e  $a(k+1) = a(k)$  uma vez que se assumiu um modelo de velocidade angular e a aceleração linear constantes.

O modelo geral das observações, equação 4.21, é o ponto de partida para criar os modelos de observação de cada um dos sensores que irão ser apresentados nas subsecções seguintes.

$$Z(k) = h(X(k)) + V_k, \quad \text{com } V_k \sim \mathcal{N}(0, R_k). \quad (4.21)$$

onde  $h()$  é o modelo não linear da observação e  $V_k$  é o ruído do sensor, de covariância  $R_k$ .  $V_k$  segue uma distribuição Normal de média nula e desvio padrão igual à covariância  $R_k$ .

## 4.5.2 IMU

A unidade de medida inercial utilizada, composta por acelerómetro e giroscópio, pode ser caracterizada pelo modelo de observação que se apresenta abaixo:

$${}^{IMU}Z(k) = {}^{IMU}h(X(k)) + {}^{IMU}V_k \quad (4.22)$$

Considerando que o movimento do UGV está restrito a um plano horizontal, 2D, o foco da análise recai sobre medidas específicas provenientes deste sensor. São de interesse apenas as componentes  $a_x$  e  $a_y$  da aceleração linear, e a componente  $\omega_z$  da velocidade angular:

$${}^{IMU}Z \equiv \begin{bmatrix} {}^{IMU}a_x \\ {}^{IMU}a_y \\ {}^{IMU}\omega_z \end{bmatrix} \quad (4.23)$$

ou seja,

$$\begin{cases} {}^{IMU}a_x(k) = a(k) \\ {}^{IMU}a_y(k) = v(k) \omega(k) \\ {}^{IMU}\omega_z(k) = \omega(k) \end{cases} \quad (4.24)$$

Para o Jacobiano do modelo do IMU, necessário para o EKF, temos:

$${}^{IMU}H_k = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ v(k) & 0 & \omega(k) & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (4.25)$$

### 4.5.3 Odometria

O modelo de observação da odometria é dado pela seguinte equação:

$${}^{ODO}Z(k) = {}^{ODO}h(X(k)) + {}^{ODO}V_k \quad (4.26)$$

$${}^{ODO}Z \equiv \begin{bmatrix} \omega_{FR} \\ \omega_{RR} \\ \omega_{FL} \\ \omega_{RL} \end{bmatrix} \quad (4.27)$$

onde,

$\omega_{FR} \equiv$  velocidade angular roda *Front Right*

$\omega_{RR} \equiv$  velocidade angular roda *Rear Right*

$\omega_{FL} \equiv$  velocidade angular roda *Front Left*

$\omega_{RL} \equiv$  velocidade angular roda *Rear Left*

Para desenvolver o modelo da odometria é necessário ter em conta as equações 2.2 e 2.3 do Capítulo 2 (Enquadramento Teórico):

$$\begin{cases} v = \frac{v_R + v_L}{2} \\ \omega = \frac{v_R - v_L}{D} \end{cases} \quad (4.28)$$

Destas equações obtemos as velocidades lineares das rodas direita,  $v_R$ , e esquerda,  $v_L$ , respetivamente

$$v_R = v + \frac{D}{2} \omega \quad (4.29)$$

$$v_L = v - \frac{D}{2} \omega \quad (4.30)$$

Tendo em conta que, de acordo com a Figura 4.17

$$\omega_{\text{RODA}} = \frac{v_{\text{RODA}}}{R} \quad (4.31)$$

ao substituir  $v_{\text{RODA}}$  por 4.29, para as rodas da direita (R, *Right*), e por 4.30, para as rodas da esquerda (L, *Left*), obtemos o seguinte modelo da odometria:

$$\begin{cases} \omega_{FR}(k) = \frac{1}{R} v(k) + \frac{D}{2R} \omega(k) \\ \omega_{RR}(k) = \frac{1}{R} v(k) + \frac{D}{2R} \omega(k) \\ \omega_{FL}(k) = \frac{1}{R} v(k) - \frac{D}{2R} \omega(k) \\ \omega_{RL}(k) = \frac{1}{R} v(k) - \frac{D}{2R} \omega(k) \end{cases} \quad (4.32)$$




FIGURA 4.17: Roda Leo Rover.

Para o Jacobiano do modelo da odometria, necessário para o EKF, temos:

$${}^{ODO}H_k = \begin{bmatrix} \frac{D}{2R} & 0 & \frac{1}{R} & 0 & 0 & 0 \\ \frac{D}{2R} & 0 & \frac{1}{R} & 0 & 0 & 0 \\ -\frac{D}{2R} & 0 & \frac{1}{R} & 0 & 0 & 0 \\ -\frac{D}{2R} & 0 & \frac{1}{R} & 0 & 0 & 0 \end{bmatrix} \quad (4.33)$$

#### 4.5.4 Compensação de *Bias* no IMU e Odometria

O IMU e a odometria têm *bias*, desvios, que estão associados a erros constantes que podem ser medidos. No caso do IMU este *bias* está associado a *drifts* na medição da gravidade por parte do acelerómetro ou a *drifts* no giroscópio. No caso da odometria este erro constante e previsível está associado à medida introduzida do raio das rodas que, naturalmente, pode ter pequenas variações de roda para roda.

De modo a melhorar o modelo de observação do IMU e da odometria, estes *bias* podem ser analisados e determinados através de testes com o UGV. Para o IMU, uma aquisição de dados com o veículo imóvel numa superfície plana e para a odometria uma aquisição de dados com velocidade constante no eixo dos  $xx$ , por exemplo.

Para introduzir o modelo constante destes desvios no *Extended Kalman Filter* é necessário alterar o modelo de estado do veículo e o modelo de observação dos sensores (e, como consequência, o seu Jacobiano).

#### IMU

Ao introduzir o modelo constante do *bias* do IMU, o modelo de estado fica a seguinte matriz coluna

$$X \equiv \left[ \omega \quad a \quad v \quad \psi \quad p_x \quad p_y \quad \Delta a_x(k) \quad \Delta a_y(k) \quad \Delta \omega_z(k) \right]^T \quad (4.34)$$

onde,

$$\begin{cases} \Delta a_x(k+1) = \Delta a_x(k) \\ \Delta a_y(k+1) = \Delta a_y(k) \\ \Delta \omega_z(k+1) = \Delta \omega_z(k) \end{cases} \quad (4.35)$$

O modelo de observação do sensor sofre a seguinte alteração:

$$\begin{cases} {}^{IMU}a_x(k) = a(k) + \Delta a_x(k) \\ {}^{IMU}a_y(k) = v(k)\omega(k) + \Delta a_y(k) \\ {}^{IMU}\omega_z(k) = \omega(k) + \Delta\omega_z(k) \end{cases} \quad (4.36)$$

e o Jacobiano fica definido por:

$${}^{IMU}H_k = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ v(k) & 0 & \omega(k) & 0 & 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.37)$$

### Odometria

De modo a introduzir o *bias* no raio das rodas, o modelo de estado estende-se para a seguinte matriz coluna:

$$X \equiv [\omega \quad a \quad v \quad \psi \quad p_x \quad p_y \quad \Delta R_{FR} \quad \Delta R_{RR} \quad \Delta R_{FL} \quad \Delta R_{RL}]^T \quad (4.38)$$

onde,

$$\begin{cases} \Delta R_{FR}(k+1) = \Delta R_{FR}(k) \\ \Delta R_{RR}(k+1) = \Delta R_{RR}(k) \\ \Delta R_{FL}(k+1) = \Delta R_{FL}(k) \\ \Delta R_{RL}(k+1) = \Delta R_{RL}(k) \end{cases} \quad (4.39)$$

O modelo de observação do sensor sofre a seguinte alteração:

$$\begin{cases} \omega_{FR}(k) = \frac{1}{R+\Delta R_{FR}(K)} v(k) + \frac{D}{2(R+\Delta R_{FR}(K))} \omega(k) \\ \omega_{RR}(k) = \frac{1}{R+\Delta R_{RR}(K)} v(k) + \frac{D}{2(R+\Delta R_{RR}(K))} \omega(k) \\ \omega_{FL}(k) = \frac{1}{R+\Delta R_{FL}(K)} v(k) + \frac{D}{2(R+\Delta R_{FL}(K))} \omega(k) \\ \omega_{RL}(k) = \frac{1}{R+\Delta R_{RL}(K)} v(k) + \frac{D}{2(R+\Delta R_{RL}(K))} \omega(k) \end{cases} \quad (4.40)$$

Repare-se que o cálculo da velocidade da roda sofreu a seguinte alteração:

$$v_{\text{RODA}} = (R + \Delta R_{FR}) \omega_{\text{RODA}} \quad (4.41)$$

O Jacobiano é então,

$$\begin{aligned} & ODO H_k = \quad (4.42) \\ = & \begin{bmatrix} \frac{D}{2(R+\Delta R_{FR})} & 0 & \frac{1}{R+\Delta R_{FR}} & 0 & 0 & 0 & -\frac{v+D\omega/2}{(R+\Delta R_{FR})^2} & 0 & 0 & 0 \\ \frac{D}{2(R+\Delta R_{RR})} & 0 & \frac{1}{R+\Delta R_{RR}} & 0 & 0 & 0 & 0 & -\frac{v+D\omega/2}{(R+\Delta R_{RR})^2} & 0 & 0 \\ \frac{D}{2(R+\Delta R_{FL})} & 0 & \frac{1}{R+\Delta R_{FL}} & 0 & 0 & 0 & 0 & 0 & -\frac{v+D\omega/2}{(R+\Delta R_{FL})^2} & 0 \\ \frac{D}{2(R+\Delta R_{RL})} & 0 & \frac{1}{R+\Delta R_{RL}} & 0 & 0 & 0 & 0 & 0 & 0 & -\frac{v+D\omega/2}{(R+\Delta R_{RL})^2} \end{bmatrix} \end{aligned}$$

### 4.5.5 Recetor GNSS

O modelo de observação do recetor GNSS é dado pela seguinte equação:

$$^{GNSS}Z(k) = ^{GNSS}h(X(k)) + ^{GNSS}V_k \quad (4.43)$$

$$^{GNSS}Z \equiv \begin{bmatrix} \text{lat} \\ \text{long} \end{bmatrix} \quad (4.44)$$

Para tornar a leitura do sensor adequada para a fusão sensorial foi necessário transformar a posição em graus, proveniente do recetor GNSS, para uma posição em metros, no referencial {U}. Para este fim, começou por associar-se a origem da posição do UGV,  $p_0$ , a uma coordenada GNSS,  $^{GNSS}Z_0$ :

$$p_0 = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \Rightarrow ^{GNSS}Z_0 = \begin{bmatrix} \text{lat}_0 \\ \text{long}_0 \end{bmatrix} \quad (4.45)$$

Tendo a origem definida e constantes multiplicativas que façam a conversão de metros para graus é possível obter a posição proveniente do recetor GNSS no referencial {U}:

$$\begin{cases} \text{lat} = \text{lat}_0 + K_{\text{lat}} p_y \\ \text{long} = \text{long}_0 + K_{\text{long}} p_x \end{cases} \quad (4.46)$$

Tenha-se em consideração que o referencial  $\{U\}$  foi definido como ENU, daí as coordenadas da latitude estarem associadas a  $p_y$  (componente Norte) e as coordenadas de longitude a  $p_x$  (componente Este).

As constantes multiplicativas referidas acima, que convertem coordenadas do referencial do mundo, ENU, para WGS84, podem obter-se, de forma prática, a partir de *toolboxes* do Matlab. Outra forma de as obter é através de ferramentas de conversão, como a disponibilizada pelo Centro de Informação Geospacial do Exército.

Para o Jacobiano do modelo do recetor GNSS, necessário para o EKF, temos:

$${}^{GNSS}H_k = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & K_{lat} \\ 0 & 0 & 0 & 0 & K_{long} & 0 \end{bmatrix} \quad (4.47)$$

#### 4.5.6 IPS baseado em *Beacons*

Antes de avançar para o modelo de observação e para o Jacobiano é necessário compreender a nomenclatura associada ao *Indoor Positioning System* e aos beacons que o compõem.




FIGURA 4.18: *Indoor Positioning System*.

A numeração dos *beacons* na Figura 4.18,  $B_n$ , e as respectivas distâncias  $d_n$  estão direcionadas para a aquisição de dados, para tornar mais intuitiva esta subsecção consideremos:

$$\begin{aligned} \text{Posição de } B_3 &\equiv b_1, & d_3 &\equiv d_1 \\ \text{Posição de } B_6 &\equiv b_2, & d_6 &\equiv d_2 \\ \text{Posição de } B_5 &\equiv b_3, & d_5 &\equiv d_3 \\ \text{Posição de } B_4 &\equiv b_4, & d_4 &\equiv d_4 \end{aligned}$$

$$b_1 = \begin{bmatrix} b_{x1} \\ b_{y1} \\ b_{z1} \end{bmatrix} \quad b_2 = \begin{bmatrix} b_{x2} \\ b_{y2} \\ b_{z2} \end{bmatrix} \quad b_3 = \begin{bmatrix} b_{x3} \\ b_{y3} \\ b_{z3} \end{bmatrix} \quad b_4 = \begin{bmatrix} b_{x4} \\ b_{y4} \\ b_{z4} \end{bmatrix} \quad (4.48)$$

onde a posição do *beacon*  $n$ ,  $b_n$ , é dada pela sua posição no eixo x ( $b_{xn}$ ), y ( $b_{yn}$ ) e z ( $b_{zn}$ ).

Posto isto, o modelo de observação do IPS é o seguinte:

$${}^{BEAC}Z(k) = {}^{BEAC}h(X(k)) + {}^{BEAC}V_k \quad (4.49)$$

$${}^{BEAC}Z \equiv \begin{bmatrix} d_1 \\ d_2 \\ d_3 \\ d_4 \end{bmatrix} \quad (4.50)$$

com,

$$\begin{cases} d_1 = \sqrt{(p_x - b_{x1})^2 + (p_y - b_{y1})^2 + (p_z - b_{z1})^2} \\ d_2 = \sqrt{(p_x - b_{x2})^2 + (p_y - b_{y2})^2 + (p_z - b_{z2})^2} \\ d_3 = \sqrt{(p_x - b_{x3})^2 + (p_y - b_{y3})^2 + (p_z - b_{z3})^2} \\ d_4 = \sqrt{(p_x - b_{x4})^2 + (p_y - b_{y4})^2 + (p_z - b_{z4})^2} \end{cases} \quad (4.51)$$

Ao analisar o modelo de observação do IPS, é importante notar algumas considerações. Primeiramente, o  $p_z$  utilizado neste modelo não consta no modelo de estado atual, tendo sido assumido como 0 na equação 4.7. Esta simplificação, embora funcional para o modelo 2D, apresenta limitações para este cenário. Para

a utilização deste sensor seria necessário estender o vetor de estado para incluir a componente  $p_z$ , permitindo assim o cálculo preciso das distâncias aos beacons. Em relação aos referenciais, o modelo de observação (equação 4.51) requer que a posição dos beacons seja expressa no referencial do mundo, o que implica que seja feita uma conversão do referencial do IPS para  $\{U\}$ , um processo que, na prática, equivale a uma calibração do IPS. Para realizar esta calibração, seria necessário medir com precisão a distância entre a origem do referencial  $\{U\}$  e o *beacon* de referência, origem do referencial IPS. Esta medição permitiria, subsequentemente, determinar as coordenadas de todos os outros *beacons* no referencial do mundo.

Para o Jacobiano do modelo do IPS, considerando um modelo de estado com 7 dimensões, sendo a última  $p_z$ , temos:

$${}^{BEAC}H_k = \begin{bmatrix} 0 & 0 & 0 & 0 & \frac{p_x - b_{x1}}{d1} & \frac{p_y - b_{y1}}{d1} & \frac{p_z - b_{z1}}{d1} \\ 0 & 0 & 0 & 0 & \frac{p_x - b_{x2}}{d2} & \frac{p_y - b_{y2}}{d2} & \frac{p_z - b_{z2}}{d2} \\ 0 & 0 & 0 & 0 & \frac{p_x - b_{x3}}{d3} & \frac{p_y - b_{y3}}{d3} & \frac{p_z - b_{z3}}{d3} \\ 0 & 0 & 0 & 0 & \frac{p_x - b_{x4}}{d4} & \frac{p_y - b_{y4}}{d4} & \frac{p_z - b_{z4}}{d4} \end{bmatrix} \quad (4.52)$$

Com a particularidade de que os valores de  $d$ , na matriz do Jacobiano, são os valores calculados através da fórmula 4.51 e não as medidas dadas pelos *beacons*.

## 4.6 Filtro de Kalman Estendido com Modelo Completo

Para analisar uma trajetória real e sem restrições planares, com obstáculos e mudanças de elevação, foi utilizado um algoritmo desenvolvido pela MathWorks que consiste na fusão sensorial entre dados do IMU, GNSS e, mais tarde desenvolvido, odometria de modo a estimar o estado do UGV. O algoritmo é o *insEKF*, *Inertial Extended Kalman Filter*, e a sua estrutura está representada na Figura 4.19.

O *insEKF* cria um EKF com dois métodos, o *pedrict* e o *fuse*, que correspondem respetivamente à fase de predição e de atualização do filtro de Kalman. Para o primeiro é necessário especificar o período,  $dT$ , que representa o avanço temporal para o qual as estimativas do estado devem ser projetadas; para o segundo, além da observação, é necessário especificar a respetiva incerteza/ruído.

#### 4.6. Filtro de Kalman Estendido com Modelo Completo

De acordo com o indicado no parágrafo anterior, esta *toolbox* fornece os modelos de vários sensores: acelerómetro (*insAccelerometer*), giroscópio (*insGyroscope*), recetor GNSS (*insGPS*) e magnetómetro (*insMagnetometer*), este último modelo não foi utilizado por não haver este sensor integrado no Leo Rover. O modelo da odometria utilizado foi desenvolvido posteriormente (*insOdometry*). A *toolbox* também disponibiliza modelos para a fase de predição, onde o *insMotionPose* foi o escolhido entre as opções disponíveis; este modelo assume velocidade angular constante e aceleração linear constante,  ${}^U\dot{\omega} = 0 / {}^U\dot{a} = 0$ . O *insEKF*, na sua versão padrão, não considera as restrições não holonómicas tidas em conta no desenvolvimento do Modelo 2D ( ${}^Bv_y \neq 0 / {}^Bv_z \neq 0$ ). Esta ausência poderia resultar na perceção de movimentos fisicamente irrealistas e, conseqüentemente, introduzir erros nas estimativas de estado. De modo a colmatar esta limitação foi desenvolvido um modelo que introduz restrições não holonómicas no *insEKF*. Esta adaptação permite assegurar que, à semelhança do Modelo 2D, as componentes da velocidade  ${}^Bv_y$  e  ${}^Bv_z$  no referencial do veículo são consideradas nulas.

A utilização de um algoritmo pré desenvolvido para analisar o Modelo Completo 3D deve-se ao facto do desenvolvimento deste modelo ser bastante mais complexo e com um grau de dificuldade bastante elevado devido à grande dimensão dos modelos de estado e de observação (bem como os respetivos Jacobianos)

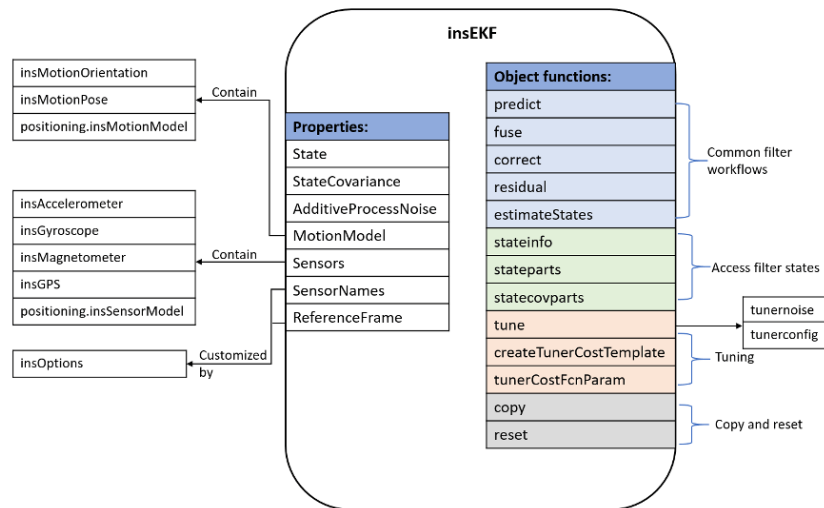


FIGURA 4.19: Estrutura do algoritmo *insEKF*.

Fonte: *Fuse inertial sensor data using INSEKF-Based Flexible Fusion Framework 2024*.

Os modelos de estado e de observação que irão ser apresentados abaixo foram adaptados de *Fuse inertial sensor data using INSEKF-Based Flexible Fusion Framework* 2024.

### 4.6.1 Cinemática, Dinâmica e Modelo de Estado

A cinemática e dinâmica do insEKF estão de acordo com o desenvolvido na Subsecção 4.4.1.

Concretamente:

$$\begin{cases} \dot{\eta} = J_2(\eta)^B \omega \\ {}^U \dot{p} = {}^U v \\ {}^U \dot{v} = {}^U a \\ {}^B \omega = 0 \\ {}^U a = 0 \end{cases} \quad (4.53)$$

De realçar que o processamento efetuado pelo algoritmo desenvolvido pela *MathWorks* considera a orientação acima expressa como  $\eta$ , em quaterniões,  $q$ . Apesar de serem semelhantes e representarem a mesma variável de estado, a primeira através de ângulos de Euler e a segunda através de quaterniões,  $\eta$  tem 3 DOF  $(\phi, \theta, \psi)$  e  $q$  tem 4 DOF  $(q_0, q_1, q_2, q_3)$ .

O modelo de estado, representado pela matriz coluna abaixo, fica agora com 16 dimensões.

$$X \equiv [q \ \omega \ p \ v \ a]^T \quad (4.54)$$

onde  $\omega \equiv {}^B \omega$ ;  $p \equiv {}^U p$ ;  $v \equiv {}^U v$ ;  $a \equiv {}^U a$  são vetores com 3 DOF e  $q$  é um vetor com 4 DOF.

## 4.6.2 IMU - insGyroscope / insAccelerometer

### Giroscópio

O modelo de observação do giroscópio, *insGyroscope*, é dado pela seguinte equação:

$$\begin{aligned} {}^{\text{GYRO}}Z(k) &= {}^B\omega + \Delta_{\text{GYRO}} \\ &= J_2(\eta)^{-1} {}^U\omega + \Delta_{\text{GYRO}} \end{aligned} \quad (4.55)$$

onde,  ${}^{\text{GYRO}}Z(k)$  é a observação tridimensional do sensor,  ${}^B\omega$  é velocidade angular no referencial {B} e  $\Delta_{\text{GYRO}}$  é o *bias* tridimensional (modelado como constante).

Devido a este *bias* tridimensional do giroscópio o modelo de estado fica agora com 19 dimensões.

O Jacobiano do modelo de observação do giroscópio é calculado internamente pelo algoritmo *insEKF*.

### Acelerómetro

O modelo de observação do acelerómetro, *insAccelerometer*, é dado pela seguinte equação:

$$\begin{aligned} {}^{\text{ACC}}Z(k) &= {}^B g + {}^B a + \Delta_{\text{ACC}} \\ &= J_1(\eta)^{-1} ({}^U g + {}^U a) + \Delta_{\text{ACC}} \end{aligned} \quad (4.56)$$

onde,  $J_1(\eta)^{-1} = J_1(\eta)^T$ ,  ${}^{\text{ACC}}Z(k)$  é a observação tridimensional do sensor,  ${}^B g$  é a aceleração gravítica no referencial {B},  ${}^B a$  é a aceleração (excluindo a aceleração gravítica) no referencial {B} e  $\Delta_{\text{ACC}}$  é o *bias* tridimensional (modelado como constante).

Devido a este *bias* tridimensional do acelerómetro o modelo de estado fica, por fim, com 22 dimensões.

O Jacobiano do modelo de observação do acelerómetro, para o EKF, é calculado internamente pelo algoritmo *insEKF*

## 4.6.3 GNSS - insGPS

O modelo de observação do recetor GNSS, *insGPS*, tem uma estrutura semelhante à definida na Subsecção 4.5.5, com a particularidade de considerar também a altitude.

Por sua vez, o Jacobiano do modelo de observação dos dados de posicionamento GNSS, para o EKF, é calculado internamente pelo algoritmo *insEKF*.

Este algoritmo dá também a possibilidade de utilizar dados da velocidade linear fornecidos pelo recetor GNSS. Estes dados são convertidos internamente para o referencial  $\{U\}$ , sendo necessário definir a sua localização de referência e a convenção dos eixos do referencial (p.e. ENU).

#### 4.6.4 Odometria - *insOdometry*

O modelo de observação da odometria, *insOdometry*, e o respetivo Jacobiano, desenvolvidos *a posteriori*, estão de acordo com o definido na Subsecção 4.5.3. Particularmente no *insEKF*, de modo a calcular a velocidade esperada de cada roda é necessária a estimativa da velocidade linear tangencial,  $v$ , e da rotação em torno de  $z$ ,  $\omega_z$ , expressos no referencial do veículo. Para isso, tal como para o acelerómetro, é necessário converter a velocidade linear de  $\{U\}$  para  $\{B\}$  usando  $J_1(\eta)^T$ .

# Capítulo 5

## Ensaio Experimentais e Resultados

### 5.1 Descrição do Processo de Aquisição de Dados

O processo de aquisição de dados seguiu uma estrutura consistente para todos os *datasets*. No entanto, para as aquisições mais simples, alguns passos foram omitidos por não serem necessários. A lista de verificação (*checklist*) completa, que detalha todos os procedimentos a serem executados antes, durante e após a aquisição, encontra-se no Apêndice A.

### 5.2 *Datasets*

Os dados constituintes de todos os conjuntos de dados (*datasets*) apresentados nesta secção foram adquiridos experimentalmente através do Leo Rover. As aquisições foram realizadas *in situ*, empregando os sensores integrados no veículo, garantindo assim a autenticidade e a relevância dos *datasets* para a presente e futuras investigações.

Tal como apresentado nas secções anteriores, os sensores disponíveis para as aquisições de dados são os seguintes:

- Recetor GNSS;
- IMU;
- *Encoders* das rodas (odometria);
- IPS baseado em *beacons* ultrassónicos.

O ambiente computacional da aquisição de dados foi o ROS, que implementa uma arquitetura de comunicação baseada em nós e tópicos. Nesta estrutura, cada sensor está associado a um nó específico, responsável pela publicação de informação através de tópicos. A especificação detalhada dos tópicos (dados) publicados por cada um dos nós (associados aos sensores) pode ser consultada no Apêndice B.

Foram realizadas 5 aquisições de dados com esta estrutura, tornando possível a criação dos seguintes *datasets*:

- Rover Estático (*Dataset1\_RoverStill.bag*);
- Trajetória Quadrangular 2D (*Dataset2\_SmallSquare.bag*);
- Trajetória Retangular Parada EN 2D (*Dataset3\_ParadaEN.bag*);
- Trajetória Completa 3D (*Dataset4\_Full3D.bag*).

Todas as aquisições de dados, feitas através do ambiente computacional ROS, estão organizadas através de *timestamps*, ponto crucial no processamento e análise dos dados. São utilizados *timestamps* Unix, que representam instantes temporais como segundos desde 01/01/1970 00:00:00 UTC. Fornecem uma precisão na ordem dos nanosegundos, facilitando cálculos e comparações temporais em sistemas computacionais. Estes valores temporais são convertidos em formatos legíveis adicionando-se o valor do *timestamp* à época Unix e ajustando o valor final ao fuso horário do local da aquisição de dados.

As horas representadas nos ensaios são referentes ao fuso horário UTC + 1.

Os *datasets*, guardados no formato *.bag*, podem ser consultados e descarregados através dos links indicados na nota de rodapé.<sup>1</sup>

Nas subsecções seguintes descrevem-se as aquisições de dados referidas em epígrafe. Todas as figuras representativas das trajetórias das aquisições de dados foram obtidas através do *GoogleEarth*.

### 5.2.1 Rover estático

O primeiro *dataset*, *Dataset1\_RoverStill.bag*, consiste numa aquisição de dados, durante um período de 45 segundos, feita com o Leo Rover parado (estático). Foram guardados dados provenientes do IMU e da Odometria (*encoders* de cada roda).

---

<sup>1</sup><https://drive.google.com/drive/folders/1X55A7qfDfStnU6AJDxHXZDdqrTjP4qSm?usp=sharing> (Google Drive) | <https://www.kaggle.com/datasets/tomasbarata/ugv-sensor-data-2d-and-3d-trajectories> (Kaggle)

A aquisição ocorreu a 26 julho de 2024 com início às 16:56:55 e fim às 16:57:40.

O principal objetivo desta aquisição foi a calibração do IMU e a visualização de resultados com EKF 2D.

### 5.2.2 Quadrangular

O segundo *dataset*, *Dataset2\_SmallSquare.bag*, consiste numa aquisição de dados de 2 minutos e 28 segundos, onde o Leo Rover percorreu uma trajetória quadrangular,  $4 \times 4 \text{ m}$ , de acordo com a Figura 5.1. Em todas as alterações consideráveis de orientação o Leo Rover parou e rodou sobre o próprio eixo. No final da aquisição de dados orientou-se o UGV de acordo com a sua orientação inicial.

Foram guardados dados provenientes de IMU, Odometria, GNSS e comandos fornecidos ao UGV. Foram utilizados dados do IMU e odometria durante o processamento e análise do *dataset*. Os dados GNSS não foram incorporados na análise devido à reduzida extensão da trajetória.

A aquisição ocorreu a 21 de maio de 2024 com início às 22:22:35 e fim às 22:25:03.

O principal objetivo desta aquisição foi testar as calibrações do IMU e odometria em ambiente real de pequena escala (aplicando EKF 2D).



FIGURA 5.1: Trajetória Quadrangular.

### 5.2.3 Parada EN

O terceiro *dataset*, *Dataset3\_ParadaEN.bag*, consiste numa aquisição de dados durante 8 minutos e 11 segundos onde o Leo Rover percorreu uma trajetória retangular na Parada da EN, de acordo com a Figura 5.2. Em todas as alterações consideráveis de orientação o Leo Rover parou e rodou sobre o próprio eixo. No final da aquisição de dados orientou-se o UGV de acordo com a sua orientação inicial. O ícone azul representa o ponto de referência GNSS e o laranja representa um ponto de *Ground Truth* (GT).

Foram guardados dados provenientes de IMU, Odometria e GNSS.

A aquisição ocorreu a 21 julho de 2024 com início às 20:29:56 e fim às 20:38:07.

O principal objetivo desta aquisição foi obter resultados experimentais em maior escala e incorporar dados GNSS (aplicando EKF 2D e insEKF).

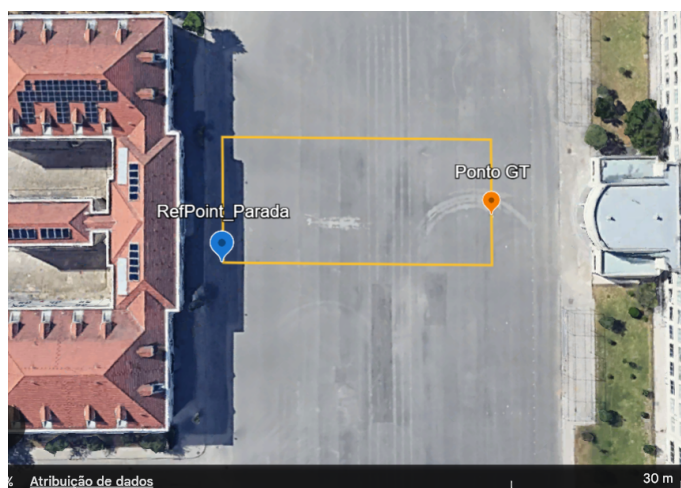


FIGURA 5.2: Trajetória Parada EN.

### 5.2.4 Completo 3D

O quarto *dataset*, *Dataset4\_Full3D.bag*, consiste numa aquisição de dados durante 15 minutos e 24 segundos onde o Leo Rover percorreu uma trajetória a simular um ambiente real, com mudanças de elevação e segmentos do percurso em ambiente *indoor*, de acordo com a Figura 5.3. As principais alterações de elevação ocorreram no início e no final do percurso, correspondendo à subida e descida do piso do Departamento de Ciências e Tecnologias da Escola Naval. Em todas as alterações consideráveis de orientação o Leo Rover parou e rodou sobre o próprio eixo. No final da aquisição de dados orientou-se o UGV de acordo com a sua orientação inicial.

### 5.3. Configuração Recetor GNSS

---

Na figura, o ícone azul indica o ponto de referência GNSS, enquanto os ícones laranja representam os pontos de GT. O percurso do UGV iniciou-se com o deslocamento para o ponto GT identificado como 1. Subsequentemente, o UGV subiu pela estrada até entrar no Departamento de Ciências e Tecnologias. Após sair do edifício pela parte posterior, o veículo dirigiu-se novamente para a estrada. Prosseguindo ao longo desta via, efetuou um ajuste de trajetória antes de descer por uma área relvada, concluindo assim o seu percurso.

Foram guardados dados provenientes de IMU, Odometria, GNSS e toda a informação proveniente do nó do IPS.

A aquisição ocorreu a 15 agosto de 2024 com início às 10:12:10 e fim às 10:27:34.

O principal objetivo desta aquisição foi replicar um cenário real com variações de altitude e segmentos em ambiente *indoor* (aplicando EKF 2D e insEKF).




FIGURA 5.3: Trajetória Completa 3D.

## 5.3 Configuração Recetor GNSS

Esta secção especifica o tipo de dados GNSS utilizados durante a aquisição do *Dataset3\_ParadaEN* e do *Dataset4\_Full3D*.

Na aquisição do primeiro *dataset* acima referido foram adquiridos dados GNSS provenientes de constelações de satélites GPS/SBAS, Galileu e GLONASS, que é a configuração predefinida do recetor GNSS UBlox EVK-M8. A Figura 5.4 mostra o número de satélites visíveis durante a aquisição.

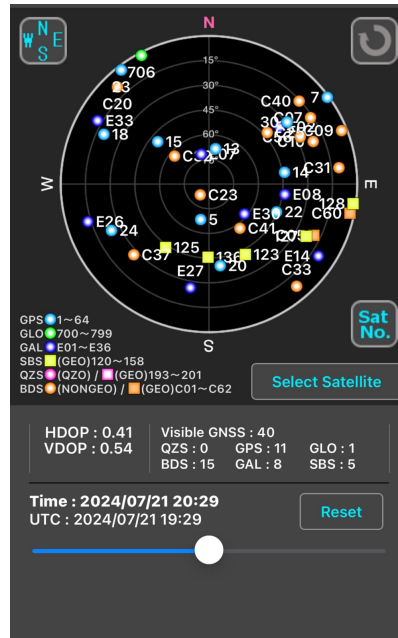


FIGURA 5.4: Satélites visíveis *Dataset3*.

Fonte: Aplicação *GNSSView*.

Durante a aquisição do segundo *dataset* seguindo o objetivo de simular um cenário em ambiente real, determinou-se que se utilizaria apenas dados provenientes de GNSS aliados, nomeadamente GPS/SBAS e Galileu. A Figura 5.5 apresenta a panorama da constelação de satélites visíveis durante a aquisição de dados.

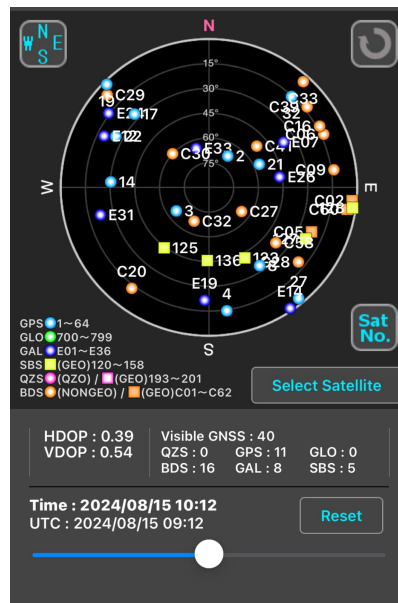


FIGURA 5.5: Satélites visíveis *Dataset4*.

Fonte: Aplicação *GNSSView*.

De modo a perceber que influência teria a utilização de diferentes GNSS nos dados obtidos, foram realizadas quatro experiências (enumeradas subsequentemente) com diferentes combinações GNSS no trajeto ilustrado na Figura 5.7. Os dados foram analisados através da comparação das covariâncias médias (erros) da posição.

Os satélites visíveis durante as quatro aquisições de dados estão ilustrados na Figura 5.6

- GPS/SBAS;
- GPS/SBAS + Galileu;
- GPS/SBAS + Galileu + GLONASS;
- GPS/SBAS + Galileu + BeiDou.

As aquisições de dados ocorreram a 15 agosto de 2024, entre as 14:55:00 e as 15:50:00. Cada aquisição de dados teve a duração de aproximadamente 3 minutos.

Os resultados obtidos nas aquisições de dados foram esclarecedores, as diferenças entre as covariâncias médias foi menor que 0.6. Todos os valores estão compreendidos entre 0.6 e 1.2.

Os resultados, da menor para a maior incerteza, foram os seguintes:

- GPS/SBAS + Galileu + BeiDou (covariância média = 0.62);

- GPS/SBAS + Galileu + GLONASS (covariância média = 0.71);
- GPS/SBAS + Galileu (covariância média = 0.96);
- GPS/SBAS (covariância média = 1.20).

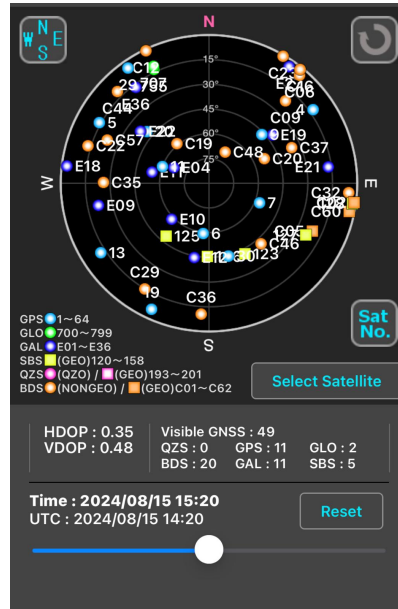


FIGURA 5.6: Satélites visíveis testes GNSS.

Fonte: Aplicação *GNSSView*.




FIGURA 5.7: Trajetória Testes GNSS.

## 5.4 Ensaio com UGV Estático

A presente secção apresenta e descreve o ponto de partida dos ensaios experimentais, utilizado para fazer ajustes e visualizar, numa primeira fase, o desempenho e os resultados do IMU (giroscópio e acelerómetro), da odometria e do EKF desenvolvido.

Foram realizadas três experiências, descritas nas subsecções que se seguem.

### 5.4.1 Experiência 1 - Caracterização do IMU

A Figura 5.8 consiste na visualização dos dados do IMU, sem qualquer pré ou pós processamento. O principal objetivo nesta primeira experiência foi caracterizar o acelerómetro e o giroscópio, em particular os respetivos erros sistemáticos (*bias*) associado a cada um.

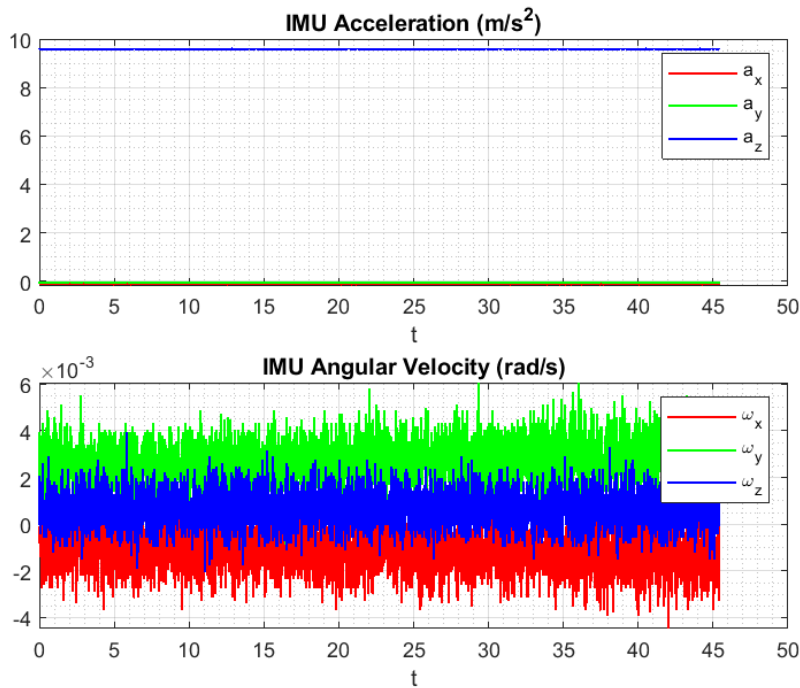


FIGURA 5.8: Exp.1 - IMU [Estático].

Os valores das covariâncias associadas à aceleração linear e velocidade angular (erro do acelerómetro e giroscópio, respetivamente) são dados fornecidos pelo ficheiro .bag obtido em ambiente ROS. Os valores predefinidos para o acelerómetro são erros na ordem de  $1 \times 10^{-3} (m/s^2)^2$  e para o giroscópio na ordem de  $1 \times 10^{-6} (rad/s)^2$ , em  $\omega_x$  e  $\omega_y$ , e  $1 \times 10^{-5} (rad/s)^2$  em  $\omega_z$ .

Apesar de haver este valor de referência dos erros associados ao IMU, decidiu-se quantificá-los concretamente através da análise da variância das medições obtidas. Este método permitiu uma avaliação precisa da dispersão dos dados em torno da média para cada eixo dos sensores  $(x, y, z)$ , fornecendo assim uma estimativa robusta do erro de medição.

Para o acelerómetro, a análise revelou erros na ordem de  $1 \times 10^{-4} (m/s^2)^2$  (tendo este valor sido definido como erro aproximado do acelerómetro). Especificamente, os valores de variância obtidos para cada eixo foram:  $(0.6732 \times 10^{-4}, 0.5670 \times 10^{-4}, 0.6272 \times 10^{-4}) (m/s^2)^2$ .

No que diz respeito ao giroscópio, os erros observados foram significativamente menores, na ordem de  $1 \times 10^{-6} (rad/s)^2$  (definiu-se este valor como erro aproximado do giroscópio). Os valores específicos de variância para cada eixo do giroscópio foram:  $(0.8466 \times 10^{-6}, 0.7975 \times 10^{-6}, 0.5511 \times 10^{-6}) (rad/s)^2$ .

Comparando os valores obtidos com os valores predefinidos nos respetivos tópicos ROS, verifica-se que os valores para a incerteza do acelerómetro são, na verdade, 10 vezes inferiores. Em relação ao giroscópio, a covariância que estava a ser publicada para a velocidade angular em  $z$ ,  $\omega_z$ , dada pelo giroscópio, era 10 vezes superior a  $\omega_x$  e  $\omega_y$ , algo que nos dados observados não se verifica.

De modo a determinar o *bias* do giroscópio determinou-se a média dos sinais (em cada eixo) fornecidos pelo sensor. Sendo a aquisição de dados feita com o UGV parado, a média dos dados deveria ser, num cenário ideal, nula. Os resultados obtidos demonstram o seguinte *bias*:  $(-0.0011, 0.0027, 0.0007) rad/s$ . Estes valores irão ser utilizados para melhorar ligeiramente o modelo de observação do IMU através da adição do *bias* de  $\omega_z$  à estimativa atual de  $\omega$  para obter o valor esperado para a observação do giroscópio, a implementar no EKF 2D desenvolvido.

É importante salientar que este *bias* consiste em valores que podem variar entre diferentes inicializações do UGV e também em função da temperatura do próprio sensor. A abordagem mais rigorosa para esta determinação seria implementar um algoritmo que, a cada inicialização do Leo Rover, aguardasse um período predefinido e efetuasse este cálculo automaticamente. Esta metodologia asseguraria uma calibração adaptativa às condições específicas de cada aquisição de dados.

A determinação precisa do *bias* do acelerómetro apresenta desafios significativos em comparação com o giroscópio, principalmente devido à influência omnipresente da gravidade e à sensibilidade do sensor a variações mínimas na orientação

do veículo. A aceleração gravítica, de aproximadamente  $9,8 \text{ m/s}^2$ , distribui-se pelos três eixos do sensor  $(x, y, z)$  de acordo com a orientação do veículo, tornando extremamente difícil distinguir entre o verdadeiro *bias* do sensor e os efeitos de ligeiras inclinações da superfície. Para uma calibração rigorosa do acelerómetro, seria necessário garantir condições controladas, como uma superfície perfeitamente nivelada, ou realizar medições em múltiplas orientações conhecidas para isolar o efeito da gravidade.

### 5.4.2 Experiência 2 - IMU com EKF

A Experiência 2 apresenta resultados que, embora pouco promissores, não são imprevisíveis.

Esta aquisição de dados foi realizada com o Leo Rover parado, no entanto, ao analisar a Figura 5.9 constata-se que a perceção do EKF é que a velocidade do UGV aumenta linearmente, fazendo divergir a posição e orientação.

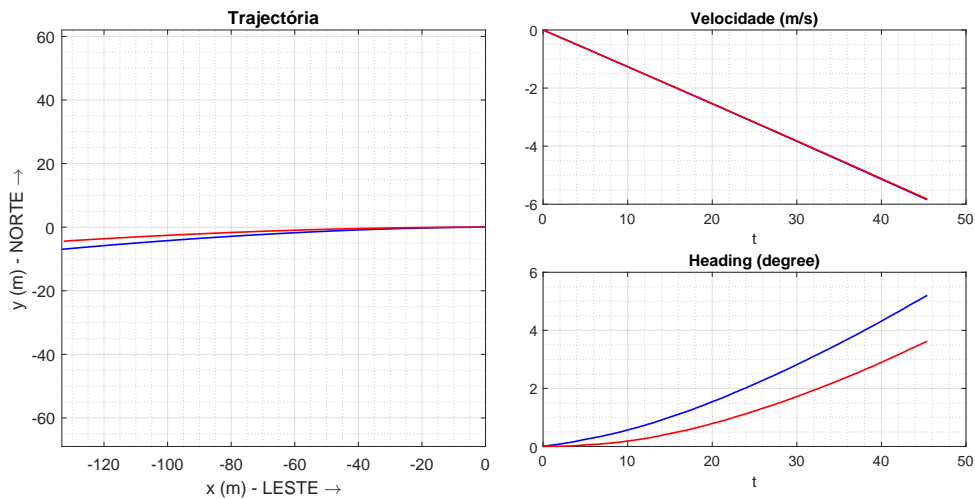


FIGURA 5.9: Exp.2 - IMU com EKF [Estático].

Legenda:

- Azul - Resultados sem compensação de *bias*
- Vermelho - Resultados com compensação de *bias*

Analisando primeiramente a velocidade, e considerando o modelo de observação do IMU desenvolvido para o EKF 2D (4.24), observa-se que, dada a componente não nula e constante da aceleração no eixo  $x$ , existe um aumento progressivo da velocidade ao longo do tempo. O valor negativo observado é atribuível à aceleração constante com valor negativo medida pelo IMU.

Ao interpretar os dados da trajetória verifica-se que a componente não nula da aceleração, através da dupla integração, manifesta-se na variação da trajetória. Devido a erros, esta trajetória apresenta um ligeiro desvio curvilíneo. Esta curvatura está diretamente associada aos dados de orientação (*heading*) obtidos. O EKF, ao considerar as restrições não holonómicas impostas (velocidade possui componente apenas no eixo  $x$  no referencial do UGV), é compelido a ajustar a orientação de modo a acompanhar o movimento observado pelo acelerómetro. Estes ajustes, combinados com os erros inerentes ao giroscópio, resultam numa estimativa de orientação variável, quando, na realidade, deveria permanecer constante.

A comparação entre os resultados com compensação do *bias* do giroscópio (representadas a vermelho) e sem esta compensação (representadas a azul) revela diferenças subtis, mas notáveis: relativamente à trajetória, observa-se uma ligeira divergência entre as duas, com a trajetória compensada (vermelha) apresentando um desvio ligeiramente menor em relação ao ponto de origem; os resultados da velocidade são praticamente idênticos, evidenciando que a compensação do *bias* do giroscópio tem pouco impacto neste parâmetro, como seria expectável; os dados da orientação (*heading*) são onde a implementação do *bias* tem mais impacto, com a orientação compensada (vermelha) a mostrar uma taxa de orientação menor em comparação com a não compensada (azul).

Estas observações indicam que a compensação do *bias* do giroscópio tem um efeito mais pronunciado na estimativa da orientação do UGV, resultando numa ligeira melhoria nos resultados obtidos. No entanto, a melhoria global da estima do estado é reduzida.

Os resultados obtidos demonstram que, para a presente implementação, o EKF apenas com observações de um IMU de baixo custo não constitui uma abordagem eficaz, devido à significativa propagação de erros inerentes a este sensor.

### 5.4.3 Experiência 3 - IMU + Odometria com EKF

A presente subsecção explora uma metodologia de fusão sensorial, incorporando dados de odometria, com o objetivo de melhorar o desempenho do EKF em comparação aos resultados anteriores.

Os resultados obtidos a partir desta fusão sensorial (Figura 5.10) evidenciam uma melhoria significativa em relação à experiência anterior. A trajetória estimada aproxima-se consideravelmente do cenário real, apresentando uma variação

de 0.06 m. Os valores da velocidade e orientação, embora aparentemente oscilatórios, apresentam variações limitadas a aproximadamente 0.01 m/s e 0.15 graus, respectivamente.

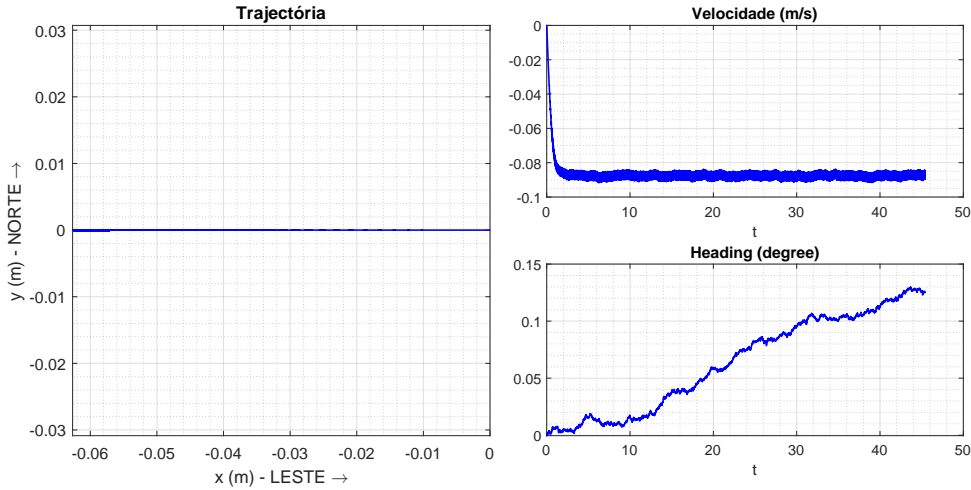


FIGURA 5.10: Exp.3 - IMU + Odometria com EKF [Estático].

Os valores positivos observados na velocidade e orientação resultam da fusão entre a odometria (rodas paradas) e a IMU. Estes valores refletem a influência da informação proveniente da IMU no processo de fusão, cujos valores foram analisados na experiência anterior.

Na implementação de fusões sensoriais, a importância relativa entre sensores constitui um aspecto crítico. Os valores utilizados para o erro e *bias* da IMU foram os determinados na Experiência 1 (Subsecção 5.4.1). Para o erro da odometria, os valores adotados resultaram de múltiplos testes com diferentes valores de erro induzido nas observações do sensor. O erro escolhido, na ordem de  $1 \times 10^{-4} (m/s)^2$ , é semelhante ao erro predefinido para a odometria no tópico ROS.

## 5.5 Ensaios Trajetória Quadrangular

A presente secção apresenta o primeiro ensaio com uma trajetória real, de pequena escala.

Foram realizadas três experiências, descritas nas subsecções que se seguem.

### 5.5.1 Experiência 1 - IMU

A experiência, utilizando exclusivamente dados do IMU como fonte de observações para o EKF, resultou em estimativas de posicionamento inadequadas para aplicações práticas. Os resultados estão esquematizados na Figura 5.11.

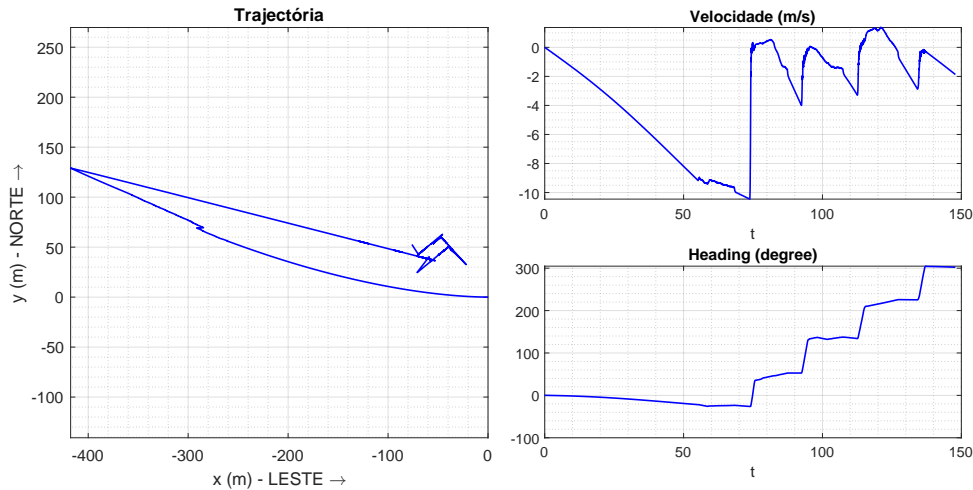


FIGURA 5.11: Exp.1 - IMU com EKF [Quadrangular].

No que diz respeito à velocidade, os dados obtidos revelam-se inconclusivos. A análise do gráfico da velocidade não permite extrair informações fiáveis ou padrões consistentes sobre o movimento do veículo. Esta natureza errática dos dados da trajetória e da velocidade sugere uma acumulação de erros na integração da aceleração, evidenciando, mais uma vez, a baixa qualidade da IMU.

Em relação à orientação, é possível identificar quatro períodos distintos de orientação constante durante a aquisição de dados. Cada um destes períodos é seguido por alterações de aproximadamente  $90^\circ$ , indicando as viragens do Leo Rover. Teoricamente, a soma de todas as variações de orientação, partindo de  $0^\circ$  e reposicionando (no final da aquisição) o UGV na sua orientação inicial, deveria totalizar  $360^\circ$ . Embora este valor exato não seja observado, a soma total aproxima-se deste valor.

É possível inferir que os dados provenientes do giroscópio apresentam uma qualidade superior em comparação com os do acelerómetro. Esta discrepância torna-se particularmente evidente considerando que os dados do acelerómetro são submetidos a uma dupla integração para obtenção da velocidade e da trajetória, amplificando assim os erros presentes.

A inconsistência destes dados sublinha a necessidade de incorporar fontes adicionais de informação para melhorar a exatidão e a fiabilidade da estima do estado do veículo, realizada pelo EKF.

### 5.5.2 Experiência 2 - Odometria

A utilização dos dados da odometria como fonte das observações do EKF produziu resultados bastante promissores, como evidenciado na Figura 5.12.

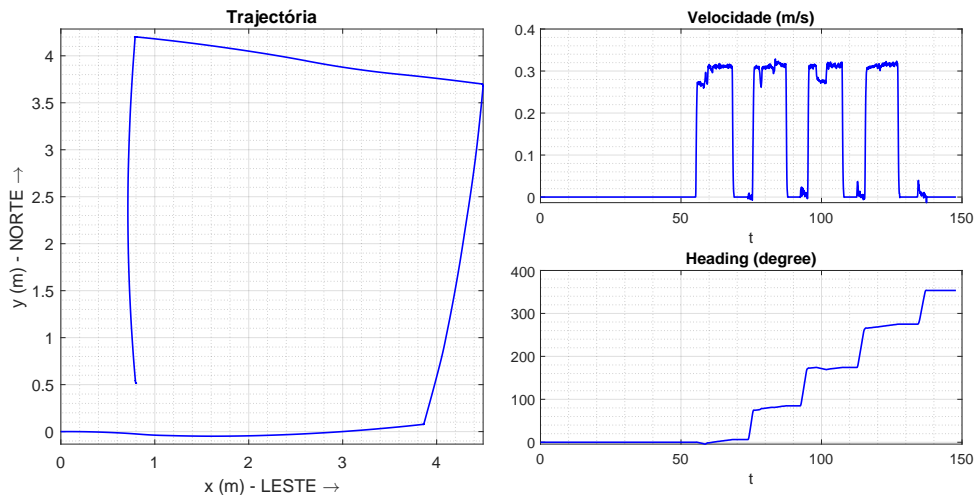


FIGURA 5.12: Exp.2 - Odometria com EKF [Quadrangular].

As estimativas da trajetória, velocidade e orientação obtidas nesta experiência correspondem, de modo geral e aproximado, à realidade da aquisição de dados, não apresentando discrepâncias substanciais. É importante notar, contudo, que a acumulação de erros ao longo do tempo é perceptível na trajetória estimada que, idealmente, deveria terminar no ponto de origem.

As variações presentes nos dados da velocidade, que rondam os  $0.3 \text{ m/s}$ , podem ser atribuídas a pequenos ajustes de velocidade implementados para corrigir a trajetória. As oscilações registadas nos instantes 75, 95, 115 e 135 segundos são a consequência da derrapagem das rodas durante as rotações do Leo Rover sobre o seu eixo.

Os parâmetros fundamentais para a odometria, nomeadamente a distância entre rodas ( $D$ ) e o raio das rodas ( $R$ ), foram determinados empiricamente através de equações aplicadas aos dados provenientes do tópico ROS do estado das rodas. Esta análise resultou nos seguintes valores:  $D = 0,630080027175821 \text{ m}$  e  $R = 0,0625 \text{ m}$ . É importante salientar que estes valores obtidos experimentalmente apresentam discrepâncias significativas em relação às especificações fornecidas pelo fabricante,

que define  $D = 0,359 \text{ m}$  e  $R = 0,065 \text{ m}$ . A aplicação destes valores pré-definidos pelo fabricante resulta numa degradação considerável da precisão na estima da trajetória e da orientação (que totaliza cerca de  $650^\circ$  em vez dos  $360^\circ$  esperados), como demonstrado na Figura 5.13.

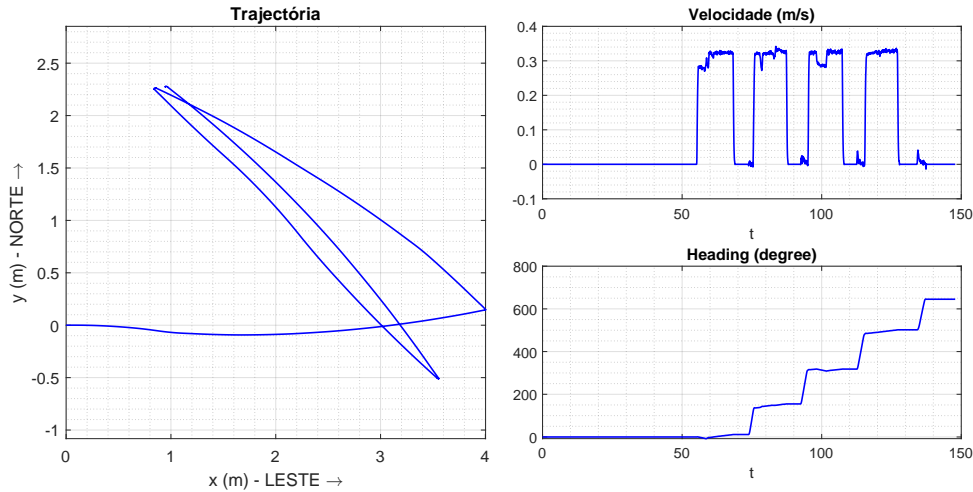


FIGURA 5.13: Exp.2 - Odometria (valores fabricante) com EKF [Quadrangular].

### 5.5.3 Experiência 3 - IMU + Odometria

Na terceira experiência, implementou-se a fusão sensorial entre a unidade de medida inercial e a odometria (Figura 5.14). Conforme esperado, esta abordagem produziu resultados melhores, em comparação com a experiência anterior. A estimativa da trajetória demonstrou uma exatidão notável, com uma diferença inferior a  $0,2 \text{ m}$  entre a posição inicial e final do veículo.

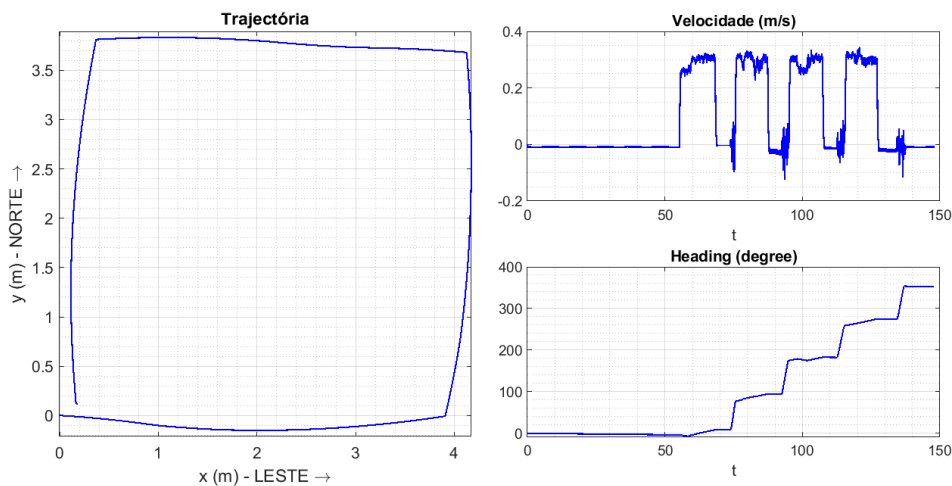


FIGURA 5.14: Exp.3 - IMU + Odometria com EKF [Quadrangular].

Relativamente à velocidade, observa-se uma maior evidência das oscilações nos dados, atribuível à IMU. Este fenómeno manifesta-se de duas formas: nas medições que oscilam em torno de  $0,3 \text{ m/s}$ , as flutuações apresentam-se mais pronunciadas; nos instantes específicos de 75, 95, 115 e 135 segundos, registam-se também oscilações mais acentuadas resultantes da derrapagem das rodas, que induz variações nos dados da odometria e da vibração do UGV durante as rotações sobre o seu próprio eixo, que amplifica o ruído captado pela IMU.

Esta melhoria na exatidão evidencia as vantagens da fusão sensorial, que permite mitigar as limitações individuais de cada sensor, resultando numa estimativa mais robusta e fiável do estado do UGV.

## 5.6 Ensaio Trajetória Parada EN

A análise de resultados desta secção compreende oito experiências distintas, cujos resultados são detalhados nas subsecções que se seguem.

Os primeiros seis ensaios demonstram os resultados do EKF desenvolvido, aplicado a uma escala maior. Neste contexto, são introduzidos e analisados, pela primeira vez, resultados que incorporam dados do recetor GNSS.

Nos dois últimos ensaios, procedeu-se a uma comparação entre o EKF 2D desenvolvido pelo autor e o EKF da *toolbox insEKF* da *MathWorks*. Para estes ensaios, à semelhança de todos os ensaios com o EKF desenvolvido, foram utilizados os valores definidos na Subsecção 5.4.1 para o erro do acelerómetro e para o erro e *bias* do giroscópio.

### 5.6.1 Experiência 1 - IMU

A experiência, ao utilizar exclusivamente dados da IMU como fonte de observações para o EKF, de forma análoga ao observado na experiência 1 dos ensaios com trajetória quadrangular, resultou em estimativas de posicionamento e velocidade imprecisas e inadequadas para aplicações práticas. Os resultados estão ilustrados na Figura 5.15.

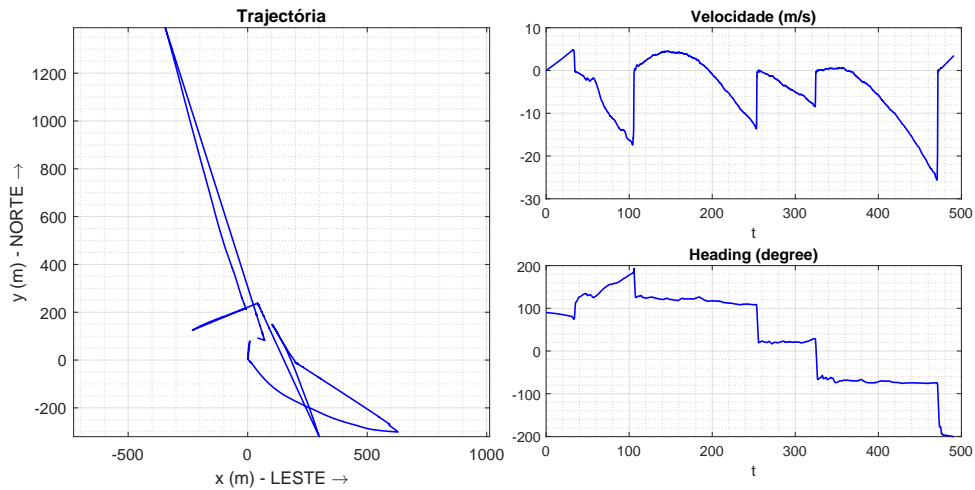


FIGURA 5.15: Exp.1 - IMU com EKF [Parada EN].

Considerando que este trajeto é de maior extensão, os efeitos da propagação do erro do acelerómetro, decorrentes da dupla integração da aceleração, são significativamente amplificados.

Embora seja possível extrair algumas informações relevantes da orientação, os resultados obtidos demonstram que a utilização exclusiva de uma IMU como única fonte sensorial é insuficiente para uma estimativa fiável do estado do UGV.

### 5.6.2 Experiência 2 - Odometria

Os resultados desta experiência são apresentados na Figura 5.16.




FIGURA 5.16: Exp.2 - Odometria com EKF [Parada EN].

A análise dos resultados da velocidade e orientação coincide com aquilo que foi analisado durante a Subsecção 5.5.2, dado que se trata de uma trajetória semelhante, mas em maior escala.

É importante salientar que os dados da orientação permitem identificar de forma bastante clara a trajetória retangular deste dataset. Outro aspeto notável nos dados da orientação é a diminuição progressiva dos seus valores, muitos deles negativos. Esta observação alinha-se com a convenção adotada para a rotação, na qual valores positivos correspondem a rotações no sentido CCW. Os valores negativos registados são, portanto, consistentes com as quatro rotações consecutivas executadas pelo Leo Rover no sentido horário (clockwise, CW).

É importante notar que a estimativa da trajetória nesta experiência apresenta menor exatidão e qualidade em comparação com a obtida em 5.5.2. Esta redução na precisão deve-se à maior acumulação de erros nos dados da odometria, resultante da trajetória mais longa.

### 5.6.3 Experiência 3 - IMU + Odometria

Os resultados da fusão sensorial entre dados do IMU e odometria são apresentados na Figura 5.17.




FIGURA 5.17: Exp.3 - IMU + Odometria com EKF [Parada EN].

Conforme explicado na Subsecção anterior, dada a semelhança nos percursos dos *datasets*, a análise dos dados da velocidade e orientação é análoga à efetuada na Subsecção 5.5.3.

No caso específico da orientação, observa-se também que a fusão dos dados da IMU com os da odometria resulta em estimativas melhores, quando comparadas com a experiência anterior. As mudanças significativas na orientação são registradas apenas quando o UGV efetivamente altera o seu rumo, culminando num valor absoluto final de aproximadamente  $360^\circ$ , consistente com o retorno à orientação inicial.

Observa-se que devido à acumulação de erros durante este percurso mais longo, a estimativa da trajetória apresenta imprecisões, particularmente evidentes na parte final do percurso.

#### 5.6.4 Experiência 4 - GNSS

Na Figura 5.18 estão representados os dados GNSS sem pós processamento. Por outro lado, a Figura 5.19 apresenta os resultados das estimativas do EKF com base nas observações dos dados GNSS.



FIGURA 5.18: Exp.4.1 - GNSS [Parada EN].




FIGURA 5.19: Exp.4.2 - GNSS com EKF [Parada EN].

Ao comparar a trajetória estimada do EKF com os dados brutos da posição GNSS, é possível verificar que a informação da posição proveniente do recetor GNSS é bastante rigorosa.

Relativamente à estima da velocidade e orientação do EKF (Figura 5.19), os dados contêm informação bastante fidedigna, coincidindo com aquilo que foi o movimento do veículo. É possível identificar alterações significativas na orientação coincidentes com as rotações do UGV sobre o seu eixo, correspondentes a cada vértice da trajetória retangular. Observam-se também dois períodos curtos e dois longos de orientação constante, correspondentes às arestas menores e maiores do retângulo que compõe a trajetória. A alternância entre velocidades positivas e negativas reflete o processo do EKF de estimar o movimento do veículo com base nos dados da posição do recetor GNSS.

### 5.6.5 Experiência 5 - GNSS + Odometria + IMU

A fusão dos dados da IMU e odometria com os dados GNSS resulta em estimativas bastante exatas para todos os parâmetros analisados, conforme ilustrado na Figura 5.20.

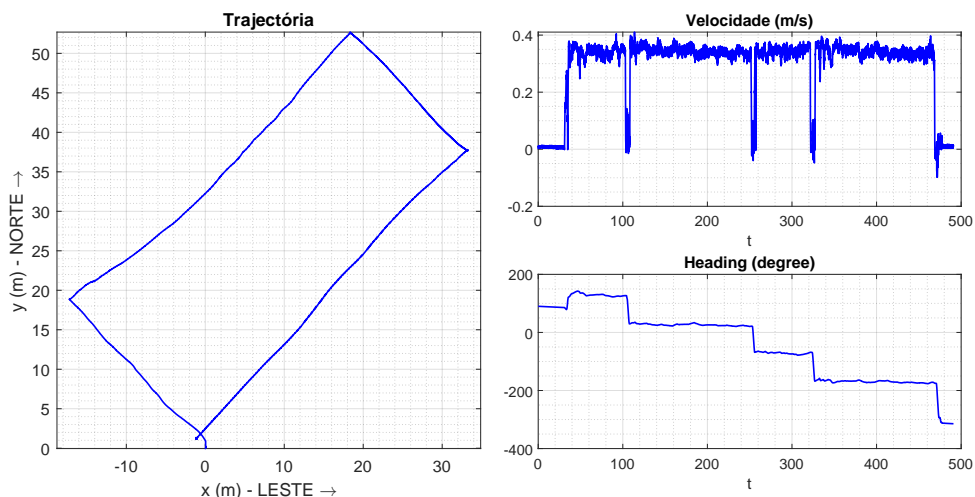


FIGURA 5.20: Exp.5 - GNSS + Odometria + IMU [Parada EN].

Em comparação com a experiência em epígrafe, que utiliza apenas os dados GNSS como observações do EKF, a estimativa da trajetória mantém um nível de exatidão equivalente, enquanto as estimativas de velocidade e orientação apresentam melhorias significativas.

Quando comparados com os resultados da Experiência 3 (Subsecção 5.6.3), observa-se uma melhoria considerável na estimativa da trajetória, a manutenção de níveis similares de exatidão na estimativa da velocidade e um ligeiro aprimoramento na estimativa da orientação.

### 5.6.6 Experiência 6 - GNSS Intermitente

Os resultados obtidos na Experiência 6 estão representados na Figura 5.21. Considere-se que a linha a tracejado cinzenta corresponde ao resultado da Experiência 5, servindo como referência, e a linha azul ilustra a trajetória estimada com perda de sinal GNSS.

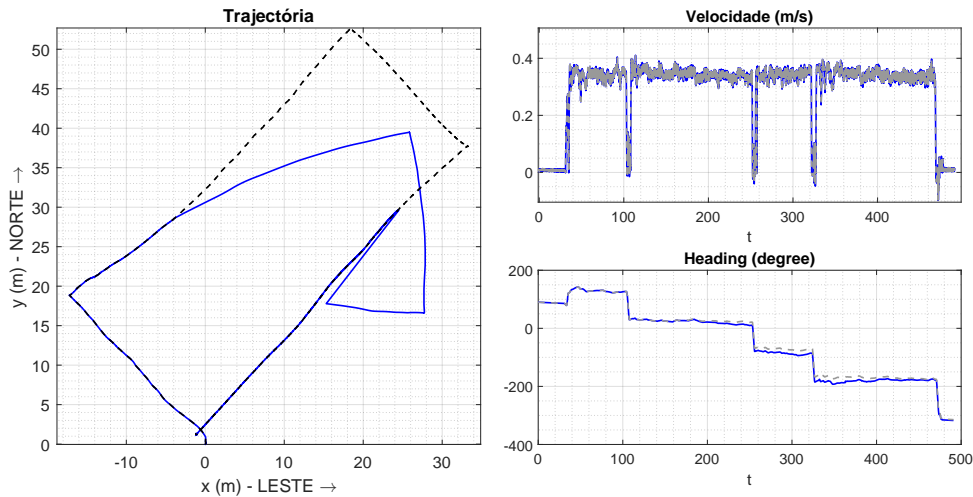


FIGURA 5.21: Exp.6 - GNSS intermitente com EKF [Parada EN].

Legenda:

Azul - Resultados com perda sinal GNSS

Tracejado - Resultados sem perda sinal GNSS

O objetivo desta experiência é avaliar a resiliência do EKF desenvolvido pelo autor em situações de perda completa do sinal GNSS. Em relação ao estado estimado do UGV, a velocidade e orientação não sofrem grande alteração; por outro lado, é bastante visível o momento de perda e retoma do sinal GNSS.

Note-se que durante os períodos sem sinal GNSS, a trajetória estimada desvia-se da real, mas retorna à trajetória correta quando o sinal é recuperado.

O gráfico de velocidade mostra pouca variação durante os períodos de perda de sinal, mantendo um padrão consistente ao longo do tempo e o gráfico de orientação apresenta mudanças graduais e consistentes, mesmo durante os períodos de perda de sinal GNSS.

Em termos globais, o EKF demonstra uma resiliência significativa, embora não ideal, face à perda intermitente do sinal GNSS. A manutenção de estimativas estáveis de velocidade e orientação durante estes períodos sugere que o filtro está a utilizar eficazmente os dados da IMU e odometria para compensar a falta de informação do GNSS. No entanto, a acumulação de erros na estimativa da posição

durante os períodos sem GNSS é evidente, conforme observado nos desvios da trajetória. A rápida convergência para a posição correta após a recuperação do sinal GNSS indica uma boa capacidade de correção do filtro.

### 5.6.7 Experiência 7 - Odometria + IMU *insEKF*

A análise desta experiência permite concluir que o *insEKF* (linha azul) fornece estimativas com qualidade bastante semelhante ao EKF 2D desenvolvido (linha a tracejado), no contexto de fusão sensorial entre odometria e IMU (Figura 5.23). A diferença entre a posição final das trajetórias estimadas é inferior a 5 metros.

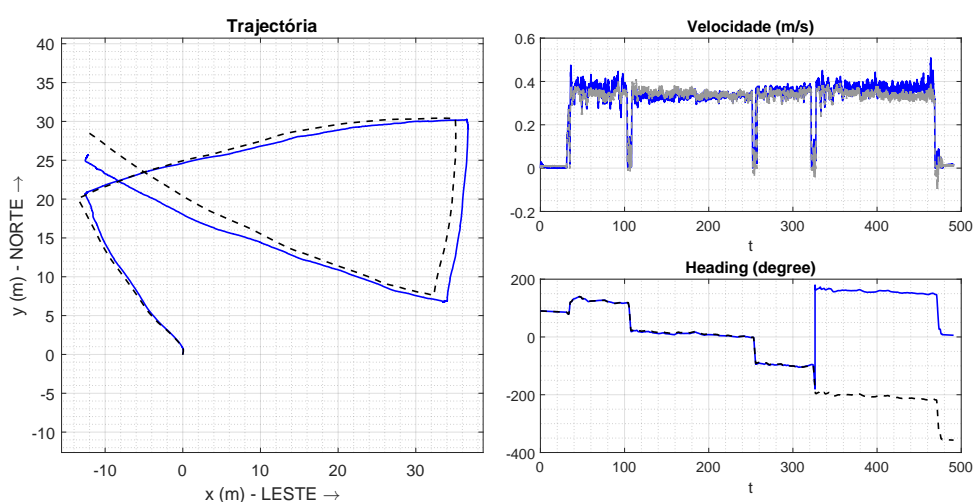


FIGURA 5.22: Exp.7 - Odometria + IMU *insEKF* [Parada EN].

Legenda:

Azul - Resultados *insEKF*

Tracejado - Resultados EKF 2D

A estimativa da velocidade por parte do *insEKF* revela-se menos ruidosa, fenómeno associado ao facto deste algoritmo ter a capacidade de determinar e ajustar, ao longo do seu processamento, o *bias* do acelerómetro.

Relativamente à orientação, no instante  $t = 320$  s observa-se um salto abrupto de 360 graus na estimativa do *insEKF*. Este acontecimento sugere que o algoritmo implementa uma limitação no intervalo angular, restringindo-o a  $[-180, +180]$  graus.

### 5.6.8 Experiência 8 - GNSS Intermitente *insEKF*

A Figura 5.23 apresenta os resultados da Experiência 8, que compara o desempenho do *insEKF* com o EKF desenvolvido, em condições de sinal GNSS intermitente.

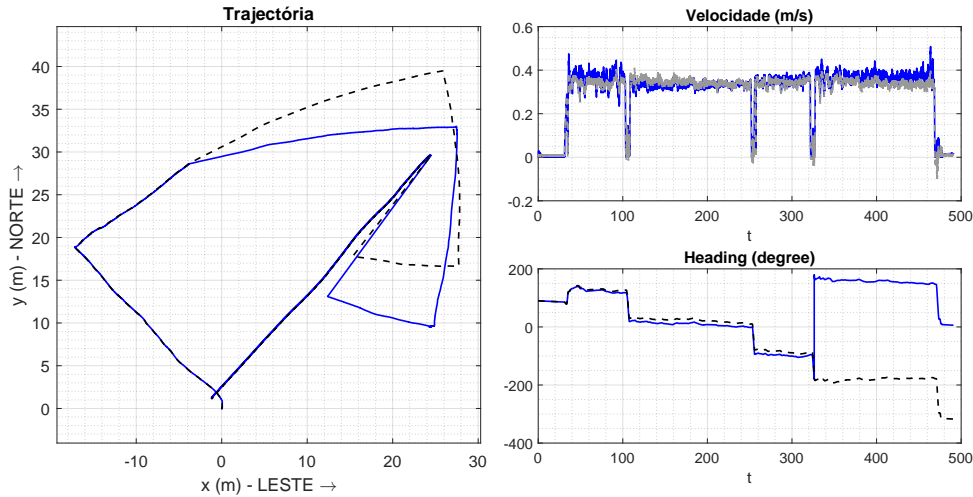


FIGURA 5.23: Exp.8 - GNSS intermitente *insEKF* [Parada EN].

Legenda:

Azul - Resultados *insEKF*

Tracejado - Resultados EKF 2D

Relativamente à velocidade e orientação, a análise é semelhante à da subsecção anterior.

Em relação à trajetória, com base nos dados GNSS da figura 5.18 observa-se que a estimativa do *insEKF* (representada pela linha azul) apresenta um desempenho inferior quando comparada com a do EKF desenvolvido (linha a tracejado). A redução na exatidão desta estima pode ser explicada pela maior complexidade do processo de estimação de estado do *insEKF*. Este algoritmo incorpora um número significativamente maior de variáveis de estado, uma característica necessária para abordagens 3D, mas que introduz desafios adicionais num cenário 2D. Esta complexidade pode conduzir a problemas de convergência.

## 5.7 Ensaios Trajetória Completa 3D

A análise do *dataset4\_Full3D.bag* compreende oito experiências distintas, cujos resultados são detalhados nas subsecções que se seguem. É importante salientar que, devido à inclusão de um segmento de percurso *indoor*, todas as experiências

que incorporam dados GNSS contemplarão cenários de interrupção deste sinal.

Os primeiros três ensaios apresentados nesta secção demonstram os resultados do EKF desenvolvido, aplicado a uma trajetória 3D.

As duas experiências finais, em conformidade com a abordagem adotada na subsecção precedente, visam estabelecer uma análise comparativa entre o EKF 2D desenvolvido e o EKF disponibilizado pela *toolbox insEKF* da *MathWorks*. Na parametrização destes ensaios, e em consonância com todos os ensaios previamente analisados, recorreu-se aos valores do erro do acelerómetro e do erro e *bias* do giroscópio previamente estabelecidos na Subsecção 5.4.1.

De relatar que, nas experiências onde são analisados dados da fusão GNSS, IMU e odometria, os algoritmos necessitaram de adaptações significativas. Observou-se que tanto o EKF desenvolvido como o *insEKF* apresentaram limitações na interpretação da informação GNSS em ambiente *indoor*, o que inviabilizou a análise da navegação inercial nesse contexto. Como era expectável, verificou-se uma degradação considerável do sinal GNSS, resultando em valores erráticos e num aumento substancial da covariância associada às medições. Contudo, mesmo com o aumento da covariância, seja por consequência direta da degradação do sinal ou por aumentos manuais adicionais, os filtros não processaram adequadamente esta informação. Consequentemente, a estima do estado do UGV durante a permanência no interior do edifício tornou-se errática, levando a uma divergência significativa dos filtros. Como resultado destas limitações, a estimativa do estado do UGV ficou com problemas de convergência, tornando-se errática e inconsistente.

Para ultrapassar este obstáculo e permitir uma análise eficaz da fusão sensorial, foi necessário implementar uma estratégia de exclusão manual das observações GNSS nos períodos *indoor*, aplicada a ambos os filtros durante a permanência do UGV no interior do edifício. Esta abordagem garantiu o funcionamento adequado dos EKF, evitando que dados GNSS inconsistentes comprometessem a estima do estado do Leo Rover.

### 5.7.1 Experiência 1 - GNSS

Na Figura 5.24 encontram-se ilustrados os dados GNSS sem pós-processamento. A imagem à esquerda apresenta uma visão geral dos dados com erros associados à entrada no edifício, enquanto a imagem à direita oferece uma aproximação no local da aquisição dos mesmos. Observa-se claramente o momento em que o Leo Rover

## 5.7. Ensaios Trajetória Completa 3D

entrou no edifício, evidenciado por uma grande deriva do sinal, seguido de uma fase de convergência após a sua saída.




FIGURA 5.24: Exp.1 - GNSS [Full 3D].

### 5.7.2 Experiência 2 - Odometria + IMU

Os resultados da Experiência 2 estão ilustrados na Figura 5.25.




FIGURA 5.25: Exp.2 - Odometria + IMU [Full 3D].

Relativamente aos dados da velocidade, embora apresentem um nível considerável de ruído, é possível identificar períodos distintos: intervalos com velocidade constante de 0,4 m/s, correspondentes aos segmentos retilíneos do percurso, e períodos de velocidade nula, coincidentes com as paragens e mudanças de direção do Leo Rover.

A estima da orientação consegue refletir os momentos de mudança de direção do veículo. A orientação final registada, de aproximadamente 280 graus, revela uma discrepância em relação ao valor ideal de 360 graus - que representaria o retorno à orientação inicial. Esta diferença indica uma acumulação gradual de erros ao longo do percurso.

Os resultados da estima da trajetória, apesar de ilustrarem vagamente o percurso efetuado pelo UGV, são pouco exatos. A divergência significativa entre as posições inicial e final, de cerca de 70 metros, é particularmente notável.

Esta análise dos resultados permite concluir que, embora o filtro 2D não seja completamente ineficaz, revela-se inadequado para uma estima precisa do estado do UGV num percurso tridimensional.

### 5.7.3 Experiência 3 - GNSS + Odometria + IMU

Esta experiência, apresentada na Figura 5.26, visa avaliar a resiliência do EKF 2D desenvolvido em cenários de disrupção de sinal GNSS. A laranja está indicada a entrada no edifício e a verde a saída.

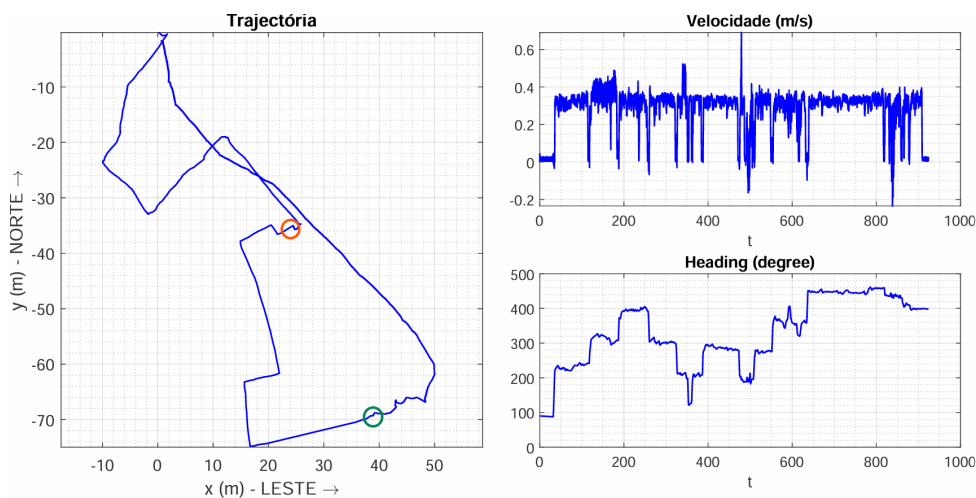


FIGURA 5.26: Exp.3 - GNSS + Odometria + IMU [Full 3D].

Como seria expectável, a estimativa da trajetória melhora significativamente em comparação com a experiência anterior, uma vez que a perda do sinal GNSS ocorre apenas na fase intermédia da aquisição, estando presente no início e no fim do percurso. Esta configuração resulta numa precisão notável, com as posições inicial e final a coincidirem. No segmento *indoor* do percurso, que, à semelhança do *outdoor*, também apresenta variações de altitude (ainda que pequenas, provocadas por escadas), observa-se uma deriva considerável na trajetória estimada.

É importante salientar que a estima da orientação apresenta uma melhoria, totalizando aproximadamente 300 graus. A estimativa da velocidade mantém-se consistente com os resultados anteriores.

A análise destes resultados reforça a conclusão previamente observada: o filtro 2D, apesar de oferecer alguma utilidade, demonstra claras limitações na estimativa precisa do estado do UGV em percursos com características tridimensionais. Estas limitações evidenciam a necessidade de uma abordagem mais robusta para lidar com a complexidade do ambiente.

Considerando as limitações observadas no filtro 2D para percursos com características tridimensionais, a aplicação de um EKF 3D, como o *insEKF*, apresenta-se como uma alternativa mais adequada e será analisada nas subsecções seguintes.

#### 5.7.4 Experiência 4 - Odometria + IMU *insEKF*

A Figura 5.27 apresenta os resultados da estimação do estado do UGV baseada na fusão entre odometria e IMU através do *insEKF*. Os resultados do *insEKF* estão representados a azul e os resultados do EKF 2D pela linha tracejada.

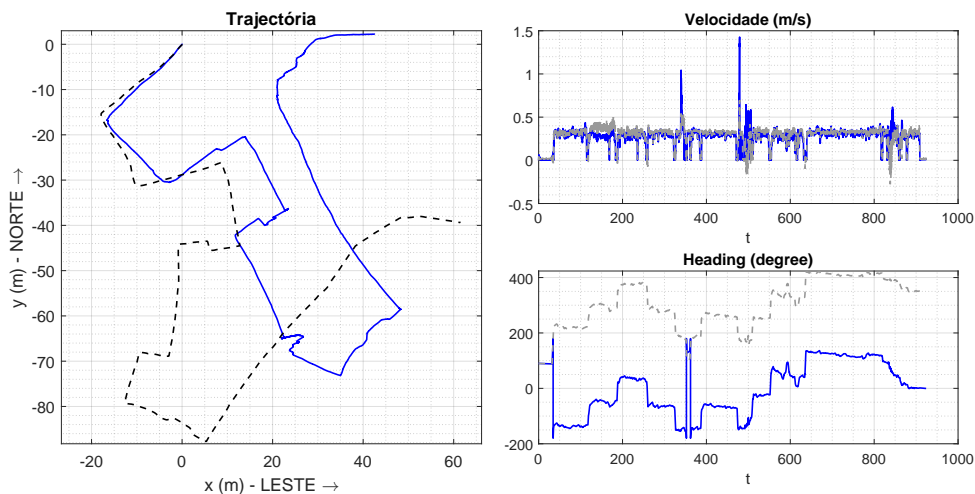


FIGURA 5.27: Exp.4 - Odometria + IMU *insEKF* [Full 3D].

Legenda:

Azul - Resultados *insEKF*

Tracejado - Resultados EKF 2D

A análise dos dados da trajetória revela que, no final do percurso, o *insEKF* não processou adequadamente os dados disponíveis. A descida acentuada até ao ponto de inicial/final foi interpretada pelo filtro como uma curva gradual à direita, resultando numa discrepância de aproximadamente 40 metros em relação à posição

final real (coincidente com a posição inicial). Não obstante, quando comparada com a estimativa de posição do EKF 2D, observa-se uma melhoria significativa.

Nos dados da velocidade destacam-se dois aumentos rápidos para 1 m/s e 1,5 m/s, correspondentes à subida e descida das rampas na entrada e saída do edifício. Estas variações de altitude contribuíram possivelmente para o incremento do erro, refletindo-se na estima da velocidade.

De realçar as variações abruptas da orientação perto do instante  $t = 350$  segundos, associada às mudanças curtas de direção do UGV, de modo a entrar pela porta do edifício. O valor final é nulo coincidindo com o Norte. A diferença entre as perceções da orientação entre os dois filtros foi abordada na Subsecção 5.6.7.

### 5.7.5 Experiência 5 - GNSS + Odometria + IMU *insEKF*

Os resultados da Experiência 5 estão ilustrados na Figura 5.28. O círculo laranja indica o momento de entrada em ambiente *indoor* e o círculo verde indica a saída.

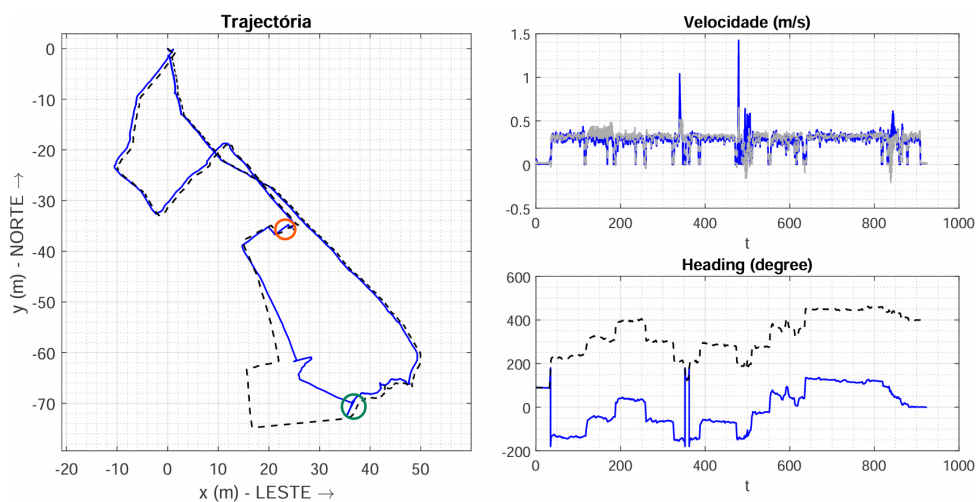


FIGURA 5.28: Exp.5 - GNSS + Odometria + IMU *insEKF* [Full 3D].

Legenda:

Azul - Resultados *insEKF*

Tracejado - Resultados EKF 2D

Esta experiência evidencia principalmente as diferenças na estima da trajetória entre o *insEKF* e o EKF 2D. Observa-se que, durante o período de navegação exclusivamente inercial (na ausência de sinal GNSS dentro do edifício), o *insEKF* demonstra maior exatidão e estabilidade. Em contrapartida, o EKF 2D apresenta uma

deriva mais acentuada e menor exatidão. Nos segmentos do trajeto com cobertura de sinal GNSS, as estimativas de ambos os filtros são praticamente coincidentes.

## 5.8 Discussão de Resultados e Dificuldades Encontradas

### 5.8.1 Calibração e *Bias* dos Sensores

Um desafio importante foi a calibração dos sensores inerciais, particularmente o acelerómetro (*bias* não foi determinado manualmente) e o giroscópio (*bias* determinado manualmente). O facto do *bias* destes sensores ser variável entre inicializações e sensível a mudanças de temperatura sublinha a necessidade de uma metodologia de calibração mais robusta e adaptativa. A calibração do acelerómetro revelou-se especialmente desafiante devido à influência omnipresente da gravidade e à sensibilidade a pequenas variações na orientação do veículo. Uma forma de melhorar os resultados obtidos seria através de um algoritmo que realize calibrações automáticas de parâmetros como o ruído dos sensores e os seus *bias* a cada inicialização do UGV. Num cenário de fusão sensorial com odometria, a aprendizagem automática de parâmetros como as dimensões exatas das rodas seria também uma grande mais valia para melhorar os resultados.

### 5.8.2 Superioridade do Giroscópio sobre o Acelerómetro

Os dados do giroscópio demonstraram consistentemente uma qualidade superior em comparação com os do acelerómetro, fenómeno comum em IMUs de baixo custo. Esta discrepância é particularmente relevante considerando que para obter a estima da posição, os dados do acelerómetro são submetidos a uma dupla integração, amplificando quaisquer erros presentes. Duas possíveis formas de colmatar este problema do IMU são, através da fusão sensorial, atribuir maior peso aos dados do giroscópio ou a aquisição e integração de uma unidade de medida inercial mais precisa.

### 5.8.3 Limitações da Estima do Estado com IMU Isolada

Os resultados demonstraram que a utilização exclusiva de uma IMU de baixo custo como fonte de observações para o EKF não é uma abordagem eficaz. A propagação significativa de erros inerentes aos sensores, leva a estimativas erradas de velocidade e posição, especialmente em trajetórias mais longas onde os erros

acumulam. Esta constatação enfatiza a necessidade crítica de fusão sensorial para aplicações em navegação e localização inercial robusta.

#### 5.8.4 Fusão Sensorial e Importância Relativa dos Sensores

A implementação de fusão sensorial provou ser crucial para melhorar a qualidade da estima do estado do UGV. A combinação de dados da IMU com odometria e GNSS resultou em estimas bastante robustas. A determinação da importância relativa entre os sensores emergiu como um aspeto crítico, com a escolha dos parâmetros de erro a influenciar significativamente o desempenho do sistema.

#### 5.8.5 Desafios em Ambientes *Indoor*, Perda de Sinal GNSS e Resiliência

Outro desafio importante foi identificado na navegação em ambientes *indoor*, onde o sinal GNSS se degrada consideravelmente. Tanto o EKF desenvolvido pelo autor como o *insEKF* demonstraram limitações na interpretação das informações GNSS incorretas nestes ambientes. A estratégia de exclusão manual das observações GNSS durante os períodos *indoor* provou ser necessária para manter a estabilidade das estimativas, bem como para permitir a análise completa dos dados.

Esta estratégia permitiu concluir que ambos os filtros de Kalman estendidos demonstraram, no contexto dimensional para o qual foram concebidos, uma resiliência significativa, embora não ideal, face a perdas intermitentes de sinal GNSS. A capacidade de manter estimas estáveis de velocidade e orientação durante estes períodos sugere uma fusão eficaz dos dados da IMU e odometria. No entanto, durante períodos prolongados sem GNSS, observa-se uma acumulação considerável de erros na estima da posição. Este fenómeno deve-se, mais uma vez, à natureza ruidosa dos dados de aceleração que são submetidos a uma dupla integração.

Para mitigar estes erros na estima da posição e aumentar a resiliência na perda de sinal GNSS podem considerar-se duas abordagens: a implementação de fusão sensorial com um maior número de sensores e/ou o investimento numa IMU de maior qualidade.

#### 5.8.6 Comparação entre EKF 2D e *insEKF* 3D

A comparação entre o EKF 2D desenvolvido pelo autor e o *insEKF* permitiu retirar conclusões significativas. Apesar de mais complexo, o *insEKF* demonstrou maior exatidão e estabilidade apenas em percursos 3D. O EKF 2D obteve resultados

melhores em cenários 2D devido a uma maior simplicidade ao nível das dimensões do estado do UGV (7 dimensões) e especificidade a duas dimensões. A complexidade da estimação do estado por parte do *insEKF*, associada a todas as variáveis necessárias para fazer a estimação do estado a três dimensões (totalizando um modelo de estado de 22 dimensões), cria problemas de convergência que interferem com os resultados em cenários 2D. Isto sugere que a escolha entre abordagens com EKF a 2D e 3D deve ser cuidadosamente considerada com base nas características específicas do ambiente de operação.

### 5.8.7 Dificuldades do Processo de Ajuste do Filtro

A utilização de um número reduzido de sensores resulta num problema de escassez de observações. Por exemplo, ao empregar exclusivamente o IMU, não é possível corrigir, através de observações diretas, a velocidade ou a posição. Consequentemente, a incerteza associada a estas variáveis tende a crescer exponencialmente com o tempo, originando problemas numéricos à medida que estas incertezas aumentam.

Relativamente aos dados GNSS, identificou-se um problema relacionado com as restrições não holonómicas do sistema. Com a incerteza de transição definida como nula em  $p_x$  e  $p_y$ , o filtro tentava corrigir o estado de acordo com o modelo, iniciando uma viragem para a posição proveniente dos dados GNSS. Esta abordagem, além de ser lenta na sua atuação, entrava em contradição com as informações provenientes da odometria, que corretamente indicavam que o UGV não estava a efetuar qualquer viragem. A introdução de incerteza em  $p_x$  e  $p_y$  permitiu ao filtro, do ponto de vista matemático, sobrepor-se a estas restrições não holonómicas e realizar ajustes da posição de forma mais eficaz.

A sintonia de todas estas incertezas, aliada aos problemas de escassez de observações sensoriais que originam instabilidades numéricas e às restrições não holonómicas, constitui provavelmente o maior desafio no processo de ajuste do filtro.



# Capítulo 6

## Conclusões e Trabalho Futuro

### 6.1 Conclusão

No decorrer da presente dissertação abordou-se a navegação e localização de veículos terrestres não tripulados (UGVs) em ambientes caracterizados pela interrupção do sinal GNSS, um desafio crescente tanto em aplicações civis como militares. A investigação foi motivada pela importância crítica dos dados PNT e pela vulnerabilidade inerente dos sistemas dependentes de GNSS em cenários de Navigation Warfare (NAVWAR). A questão central que norteou esta investigação foi: “Como assegurar informação PNT exata na ausência de dados provenientes do GNSS?” Para abordar esta questão, bem como as questões derivadas sobre os tipos de sensores necessários e as metodologias de fusão de dados, foram realizados diversos ensaios e análises recorrendo a um UGV, no qual se integraram vários sensores.

Os resultados obtidos a partir das quatro aquisições de dados realizadas, bem como do desenvolvimento e implementação de filtros de Kalman estendidos para a fusão de dados sensoriais provenientes de IMU, odometria e GNSS, demonstraram uma resiliência significativa na manutenção de uma estima razoavelmente exata do estado do UGV, mesmo durante períodos de perda de sinal GNSS. No entanto, esta capacidade revela-se limitada, observando-se uma acumulação gradual de erros na estimativa da posição ao longo do tempo.

A calibração dos sensores inerciais emergiu como um desafio significativo, particularmente devido à possível variabilidade do *bias* e à complexidade do seu cálculo para IMU e odometria. Esta observação enfatiza a necessidade de desenvolver metodologias de calibração mais robustas e adaptativas que permitam ao máximo diminuir as incertezas associadas ao IMU de baixo custo.

Um desafio adicional foi identificado na navegação em ambientes *indoor*, onde o sinal GNSS está degradado ou é inexistente. A necessidade de excluir manualmente as observações GNSS durante estes períodos para manter a estabilidade das estimativas indica que são necessários sistemas mais robustos para lidar eficazmente com transições entre ambientes *indoor* e *outdoor*.

O processo de afinação do filtro, especialmente a definição das incertezas de transição, revelou-se complexo. Adicionalmente, a falta de observações (de outros sensores) pode levar as incertezas a crescer exponencialmente no tempo, com os problemas numéricos que daí advém.

A comparação entre as abordagens com EKF 2D e 3D (*insEKF*) revelou que cada uma tem o seu domínio de eficácia. Nas experiências realizadas, o EKF 2D desenvolvido demonstrou ser melhor em cenários bidimensionais, enquanto o *insEKF* apresentou vantagens em trajetórias tridimensionais mais complexas. Esta constatação ressalta a importância de adaptar a abordagem ao ambiente operacional específico.

No contexto de NAVWAR, estas conclusões sugerem que, embora seja possível manter uma navegação razoavelmente exata por períodos de tempo limitados sem sinal GNSS fiável, ainda existem desafios significativos para garantir uma navegação robusta e de longo período em ambientes de interrupção deste sinal e de variabilidade do contexto operacional. Estes desafios poderão ditar a escolha criteriosa da panóplia de sensores de navegação passíveis de integrar.

Apesar dos fatores anteriormente mencionados poderem contribuir para alguma incerteza nos resultados obtidos, a fusão sensorial através do EKF desenvolvido pelo autor e os estudos efetuados podem, no futuro, após os devidos ajustes, ser utilizados como base de um sistema de navegação e localização de um veículo autónomo não tripulado em ambientes de interrupção de sinal GNSS.

## 6.2 Trabalho Futuro

Os resultados e desafios identificados nesta investigação abrem várias linhas de investigação futura promissoras. A incorporação dos dados do Sistema de Posicionamento Indoor (IPS), que não foi possível incluir no EKF, é uma das principais linhas de investigação futura, estando já integrado e modulado tem o potencial de melhorar significativamente a robustez e precisão da navegação, especialmente em ambientes *indoor* ou, por outro lado, permitir fazer uma avaliação quantitativa dos

resultados através do GT fornecido. Outra direção possível é a expansão da fusão sensorial para incluir sensores adicionais, como, por exemplo, LiDAR.

O desenvolvimento de algoritmos adaptativos para calibração automática de parâmetros, como o ruído dos sensores e os seus *bias* a cada inicialização do UGV, bem como a identificação automática de *outliers* é outra área de interesse. Estes algoritmos poderiam melhorar substancialmente a adaptabilidade do sistema a diferentes condições ambientais. Deveria também ser feita, para futuras implementações, uma análise comparativa do desempenho e custo-benefício de IMUs de maior precisão de modo a solucionar o problema da incerteza associada ao IMU de baixo custo.

É fundamental aperfeiçoar o processamento automático da perda de sinal GNSS por parte do EKF. Ao nível experimental esta melhoria eliminaria a necessidade de intervenção manual para simular ambientes de disrupção, proporcionando assim uma representação mais fiel de cenários reais. Em aplicações práticas, tal aperfeiçoamento aumentaria consideravelmente a robustez e a aplicabilidade do sistema em ambientes operacionais caracterizados por instabilidade ou ausência de sinal GNSS.

A otimização do sistema para cenários específicos de NAVWAR, incluindo o desenvolvimento de técnicas para detetar e mitigar *jammimg* e *spoofing* do sinal GNSS, é uma área de investigação que merece atenção especial.

A investigação contínua nesta área é crucial para o desenvolvimento de veículos não tripulados capazes de operar eficazmente numa variedade de cenários, incluindo aqueles caracterizados por disrupção de sinal GNSS, contribuindo assim para avanços significativos tanto em aplicações civis quanto militares.



# Bibliografia

- Amutham V, Kadal (jul. de 2020). *MEMS based accelerometer*. Acedido: 2024-06-15. URL: <https://www.linkedin.com/pulse/mems-based-accelerometer-v-kadal-amutham>.
- Aqel, Mohammad OA, Mohammad H Marhaban, M Iqbal Saripan e Napsiah Bt Ismail (2016). «Review of visual odometry: types, approaches, challenges, and applications». Em: *SpringerPlus* 5, pp. 1–26. DOI: 10.1186/s40064-016-3573-7.
- Armada, Estado-Maior da, ed. (ago. de 2021). *IOA 115 – Conceito de Emprego do Centro de Experimentação Operacional da Marinha*. Marinha, Ministério da Defesa Nacional.
- Armstrong, Allan (set. de 2023). *GNSS Vulnerabilities Common-Sense Solutions*. Meinberg. Acedido: 2024-06-16. URL: [https://www.naspi.org/sites/default/files/2023-10/D2\\_S09\\_01\\_Armstrong\\_Meinberg\\_20230927.pdf](https://www.naspi.org/sites/default/files/2023-10/D2_S09_01_Armstrong_Meinberg_20230927.pdf).
- Bachrach, Abraham, Anton de Winter, Ruijie He, Garrett Hemann, Samuel Prentice e Nicholas Roy (mai. de 2010). «RANGE - robust autonomous navigation in GPS-denied environments». Em: *2010 IEEE International Conference on Robotics and Automation*, pp. 1096–1097. DOI: 10.1109/ROBOT.2010.5509990.
- Balamurugan, G, J Valarmathi e V P S Naidu (out. de 2016). «Survey on UAV navigation in GPS denied environments». Em: *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES)*, pp. 198–204. ISBN: 978-1-5090-4620-1. DOI: 10.1109/SCOPES.2016.7955787.
- Barshan, B. e H.F. Durrant-Whyte (1995). «Inertial navigation systems for mobile robots». Em: *IEEE Transactions on Robotics and Automation* 11.3, pp. 328–342. DOI: 10.1109/70.388775.
- Bieda, Robert e Krzysztof Jaskot (jun. de 2016). «Determining of an object orientation in 3D space using direction cosine matrix and non-stationary Kalman filter». Em: *Archives of Control Sciences* 26, pp. 147–168. DOI: 10.1515/acsc-2016-0013.

- Dissanayake, G., S. Sukkarieh, E. Nebot e H. Durrant-Whyte (2001). «The aiding of a low-cost strapdown inertial measurement unit using vehicle model constraints for land vehicle applications». Em: *IEEE Transactions on Robotics and Automation* 17.5, pp. 731–747. DOI: 10.1109/70.964672.
- Doppler Log - principle, working, speed and errors (jun. de 2018). Cult Of Sea. Acedido: 2024-06-15. URL: <https://cultofsea.com/bridge-equipment/1229/>.
- Dudek, Gregory e Michael Jenkin, eds. (2024). *Computational principles of mobile robotics*. 3<sup>a</sup> ed. Cambridge University Press. ISBN: 978-1-108-73638-1. DOI: 10.1017/9781108682404.
- Foot, Tully e Mike Purvis (2000). *REP 103 - Standard Units of Measure and Coordinate Conventions*. ROS.org. Acedido: 2024-04-25. URL: <https://www.ros.org/reps/rep-0103.html>.
- Fossen, Thor (2011). *Handbook of Marine Craft Hydrodynamics and Motion Control*. John Wiley e Sons, Ltd. ISBN: 9781119991496. DOI: 10.1002/9781119994138.
- Fuse inertial sensor data using INSEKF-Based Flexible Fusion Framework (2024). MATLAB and Simulink. MathWorks. Acedido: 2024-07-20. URL: <https://www.mathworks.com/help/fusion/ug/fuse-inertial-sensor-data-using-insekf-based-flexible-fusion-framework.html>.
- Gewies, Stefan, Lars Grundhöfer e Niklas Hehenkamp (mar. de 2020). «Availability of Maritime Radio Beacon Signals for R-Mode in the Southern Baltic Sea». Em: *TransNav, the International Journal on Marine Navigation and Safety of Sea Transportation* 14, pp. 173–178. DOI: 10.12716/1001.14.01.21.
- GPS/GNSS Interference Map (2024). GPSJAM.org. Acedido: 2024-06-13. URL: <https://gpsjam.org/?lat=54.39560&lon=9.37553&z=2.7&date=2024-03-23>.
- Gyagenda, Nasser, Jasper Hatilima, H. Roth e Vadim Zhmud (fev. de 2022). «A review of GNSS-independent UAV navigation techniques». Em: *Robotics and Autonomous Systems* 152, p. 104069. ISSN: 0921-8890. DOI: 10.1016/j.robot.2022.104069.
- Helwig, A, G Offermans, C Stout e C Schue (2011). *eLoran System Definition and Signal Specification Tutorial*. UrsaNav. Acedido: 2024-06-16. URL: <http://www.ursanav.com/wp-content/uploads/UrsaNav-ILA-40-eLoran-Signal-Specification-Tutorial.pdf>.
- Hemann, Garrett, Sanjiv Singh e Michael Kaess (out. de 2016). «Long-range GPS-denied aerial inertial navigation with LIDAR localization». Em: *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 1659–1666. DOI: 10.1109/IROS.2016.7759267.

- How a Kalman filter works, in pictures* (ago. de 2015). Bzarg. Acedido: 2024-06-19. URL: <https://www.bzarg.com/p/how-a-kalman-filter-works-in-pictures/#mjax-eqn-kalupdatefull>.
- IALA-AISM (dez. de 2021). *Workshop on Enhanced Radar Positioning System*. Acedido: 2024-06-16. URL: <https://www.iala-aism.org/e-bulletin/enhanced-radar-positioning-system/>.
- Islam, Saiful, Md Shahnewaz Tanvir, Md Habib, Tahsina Tashrif, Md Apu Ahmed, Tafannum Ferdous, Md Arefin e Sanim Alam (fev. de 2022). «Autonomous Driving Vehicle System Using LiDAR Sensor». Em: pp. 345–358. ISBN: 978-981-16-7609-3. DOI: 10.1007/978-981-16-7610-9\_25.
- Kassas, Zaher M., Joe Khalife, Ali A. Abdallah e Chiawei Lee (jul. de 2022). «I Am Not Afraid of the GPS Jammer: Resilient Navigation Via Signals of Opportunity in GPS-Denied Environments». Em: *IEEE Aerospace and Electronic Systems Magazine* 37.7, pp. 4–19. ISSN: 1557-959X. DOI: 10.1109/MAES.2022.3154110.
- Kim, Inki, Renato Juliano Martins, Jaehyuck Jang, Trevon Badloe, Samira Khadir, Ho-Youl Jung, Hyeongdo Kim, Jongun Kim, Patrice Genevet e Junsuk Rho (mai. de 2021). «Nanophotonics for light detection and ranging technology». Em: *Nature Nanotechnology* 16, pp. 1–17. DOI: 10.1038/s41565-021-00895-3.
- Lee, Ki (jan. de 2011). *Principles of Microelectromechanical Systems*. ISBN: 9780470466346. DOI: 10.1002/9780470649671.ch7.
- Leo Rover specification* (jun. de 2024). Fictionlab Documentation. Acedido: 2024-07-02. URL: <https://docs.fictionlab.pl/leo-rover/documentation/specification>.
- Leonard, J.J. e H.F. Durrant-Whyte (1991). «Mobile robot localization by tracking geometric beacons». Em: *IEEE Transactions on Robotics and Automation* 7.3, pp. 376–382. DOI: 10.1109/70.88147.
- Marvelmind Indoor Navigation System* (2024). Fictionlab Documentation. Acedido: 2024-04-21. URL: <https://docs.fictionlab.pl/leo-rover/integrations/positioning-systems/marvelmind-rtls>.
- Medina, Daniel, Christoph Lass, Emilio Pérez Marcos, Ralf Ziebold, Pau Closas e Jesús García (2019). «On GNSS Jamming Threat from the Maritime Navigation Perspective». Em: *2019 22th International Conference on Information Fusion*, pp. 1–7. DOI: 10.23919/FUSION43075.2019.9011348.

- MEMS Gyroscope Basics / MEMS Gyroscope Working Operation* (2012). RF Wireless World. Acedido: 2024-06-14. URL: <https://www.rfwireless-world.com/Terminology/MEMS-Gyroscope.html>.
- Nemec, Dušan, Vojtech Šimák, Aleš Janota, Marián Hruboš e Emília Bubeníková (2019). «Precise localization of the mobile wheeled robot using sensor fusion of odometry, visual artificial landmarks and inertial sensors». Em: *Robotics and Autonomous Systems* 112, pp. 168–177. ISSN: 0921-8890. DOI: <https://doi.org/10.1016/j.robot.2018.11.019>.
- Nguyen, Trong Tai, Dang Hien Ngo, Quoc Truong Nguyen, Duc Thien Tran e Xuan Ba Dang (2022). «Indoor Mobile Robot Positioning using Sensor Fusion». Em: *2022 6th International Conference on Green Technology and Sustainable Development (GTSD)*, pp. 884–890. DOI: [10.1109/GTSD54989.2022.9989084](https://doi.org/10.1109/GTSD54989.2022.9989084).
- Omar, Samir, Y Mar, B Lee e Quan Pham (jan. de 2004). «GPS Oriented Re-Locatable Internet Kiosk with Wireless Technology for Remote Computer-Based Administration». Em: p. 13.
- Oways (fev. de 2021). *Electromagnetic Speed Log - Explanation with Diagrams*. Acedido: 2024-06-15. URL: <https://owaysonline.com/electromagnetic-speed-log-on-ships/>.
- Pascacio, Pavel, Sven Casteleyn, Joaquín Torres-Sospedra, Elena Simona Lohan e Jari Nurmi (2021). «Collaborative Indoor Positioning Systems: A Systematic Review». Em: *Sensors* 21.3. ISSN: 1424-8220. DOI: [10.3390/s21031002](https://doi.org/10.3390/s21031002).
- Peyret, François, Pierre-Yves Gilliéron, Laura Ruotsalainen e Jesper Engdahl (jan. de 2015). *SaPPART White paper : Better use of Global Navigation Satellite Systems for safer and greener transport*.
- Rudolph, Dylan e Timothy A. Wilson (mar. de 2012). «Doppler Velocity Log theory and preliminary considerations for design and construction». Em: pp. 1–7. ISSN: 1558-058X. DOI: [10.1109/SECon.2012.6196918](https://doi.org/10.1109/SECon.2012.6196918).
- Russell, James S., Mengbin Ye, Brian D. O. Anderson, Hatem Hmam e Peter Sarunic (jun. de 2020). «Cooperative Localization of a GPS-Denied UAV Using Direction-of-Arrival Measurements». Em: *IEEE Transactions on Aerospace and Electronic Systems* 56.3, pp. 1966–1978. ISSN: 1557-9603. DOI: [10.1109/TAES.2019.2942704](https://doi.org/10.1109/TAES.2019.2942704).
- Saulay, Jean-Philippe (2002). *Satellite Navigation as seen by NATO*. Civil GPS Service Interface Committee. GPS.gov. Acedido: 2024-05-28. URL: <https://www.gps.gov/cgsic/international/2002/brussels/saulay.ppt>.

- Scheding, S., G. Dissanayake, E.M. Nebot e H. Durrant-Whyte (1999). «An experiment in autonomous navigation of an underground mining vehicle». Em: *IEEE Transactions on Robotics and Automation* 15.1, pp. 85–95. DOI: 10.1109/70.744605.
- Siciliano, Bruno e Oussama Khatib, eds. (2016). *Springer Handbook of Robotics*. Springer Handbooks. Springer. ISBN: 978-3-319-32550-7. DOI: 10.1007/978-3-319-32552-1.
- Snyder, Jeff (set. de 2010). «Doppler Velocity Log (DVL) navigation for observation-class ROVs». Em: pp. 1–9. ISSN: 0197-7385. DOI: 10.1109/OCEANS.2010.5664561.
- Spezio, A.E. (2002). «Electronic warfare systems». Em: *IEEE Transactions on Microwave Theory and Techniques* 50.3, pp. 633–644. DOI: 10.1109/22.989948.
- Sukkarieh, S., E.M. Nebot e H.F. Durrant-Whyte (1999). «A high integrity IMU/GPS navigation loop for autonomous land vehicle applications». Em: *IEEE Transactions on Robotics and Automation* 15.3, pp. 572–578. DOI: 10.1109/70.768189.
- Thomas, F. e L. Ros (fev. de 2005). «Revisiting trilateration for robot localization». Em: *IEEE Transactions on Robotics* 21.1, pp. 93–101. ISSN: 1941-0468. DOI: 10.1109/TR0.2004.833793.
- Thrun, Sebastian, Wolfram Burgard e Dieter Fox (2005). *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*. The MIT Press. ISBN: 0262201623.
- Transportation, U.S. Department of (jun. de 2017). *What is Positioning, Navigation and Timing (PNT)?* Acedido: 2024-05-28. URL: <https://www.transportation.gov/pnt/what-positioning-navigation-and-timing-pnt>.
- UBlox EVK-M8N GPS module (2024). Leo Rover shop. Fictionlab. Acedido: 2024-04-12. URL: <https://www.leorover.tech/shop/gps-module>.
- Welch, Greg e Gary Bishop (jan. de 2006). *An Introduction to the Kalman Filter*. Rel. téc. Department of Computer Science, University of North Carolina at Chapel Hill.
- What is a Magnetometer and How Does It Work?* (Fev. de 2021). YoungWonks. Acedido: 2024-06-15. URL: <https://www.youngwonks.com/blog/what-is-a-magnetometer-and-how-does-it-work>.
- Zhang, P., J. Gu, E.E. Milios e P. Huynh (2005). «Navigation with IMU/GPS/digital compass with unscented Kalman filter». Em: *IEEE International*

*Conference Mechatronics and Automation*. Vol. 3, pp. 1497–1502. DOI: 10.1109/ICMA.2005.1626777.

# Apêndice A - *Checklist* Aquisição de Dados

## **Checklist** **Aquisição de Dados**

- Carregar completamente a bateria do Leo Rover e *beacons*;
- Carregar a bateria do PC e telemóvel usado para guiar o Leo Rover;
- Montar as rampas;
- Abrir porta das traseiras do DCT;
- Anotar a data e a hora da experiência;
- Setup do IPS e respetiva calibração [*Windows*];
- Medição da localização do *beacon* de referência (0,0,0);
- Identificar rigorosamente o percurso a seguir pelo Rover;
- Sincronizar relógios do Leo Rover e PC com servers do NTP Portugal [*RPi / Windows*];
- Colocar o Leo Rover na posição inicial da trajetória;
- Lançar o script para dar *reset* os valores do odómetro do Leo Rover [*RPi*];
- Lançar o script para iniciar o nó do IPS [*RPi*];
- Verificar ligações do recetor GNSS, *beacon* móvel e modem do IPS [*RPi*];
- Lançar os scripts no Leo Rover para a aquisição de dados [*RPi*];
- Finalizar a gravação de dados no fim da experiência [*RPi*];
- Converter ficheiros *.bag* para *.yaml* [*RPi*];
- Transferir ambos os ficheiros do RPi do Leo Rover para o Linux (VM) [*Linux*];
- Passar os ficheiros do Linux para o Windows [*Windows*];
- Fechar a porta das traseiras do DCT;
- Desmontar as rampas utilizadas;
- Desmontar os *beacons*.



# Apêndice B - Tópicos Publicados LeoRover

Origem	Tópicos Relevantes Publicados	Descrição	Pós processamento	Tipo de Informação	Unidades	Incerteza (convencional)	Frequência Atualização	Sistema de Coordenadas	
Leo Rover	Firmware [LeRCore]	/firmware/mhvel_odom	Orientação calculada através da leitura de dois sensores de cada roda	Velocidade angular do Rover Velocidade linear do Rover Posição do Rover (ref. posição inicial) (X,Y,W)	rad/s m/s m [0-20]	- - - -	20Hz	X - Fronte Y - Esquerda Z - Centro	
		/firmware/mhvel_status	Estado das rodas (FL, RL, FR, RR)	Posição das rodas Velocidade das rodas Balanço aplicado nas rodas PWM DutyCycle	rad/s rad/s Nm %	- - - -	20Hz		
		/firmware/imu	Dados provenientes do IMU	Temperatura Giro (velocidade rotacional X,Y,Z) Aceleração (aceleração linear X,Y,Z)	rad/s rad/s m/s <sup>2</sup>	- - -	100Hz		
		/cmd_vel (velocidade/rotacao)	Velocidade angular do Rover (X,Y,Z) /rotacao (comandos dados ao Rover)	Velocidade linear Velocidade angular	m/s rad/s	- -	10 Hz (valor máximo em 100Hz)		
		/port_status	Dados para descrever o estado das joints controladas pelo bitario	Posição das joints Velocidade das joints Estado das joints	rad/s rad/s Nm	- - -	20Hz		
		/mhvel_odom_with_covariance	Estimativa da posição, velocidade do rover baseada na odometria, com covariância	Posição do Rover (X,Y,X) Orientação do Rover (X,Y,Z,W) Velocidade linear do Rover (X,Y) Velocidade angular do Rover (X,Y)	m - m/s rad/s	(0, 0, 0) (0, 0, 0) (0,0001, 0, 0) (0, 0, 0,0001)	20Hz		
		/imu/data_raw	Velocidade angular e aceleração linear provenientes do IMU com covariância	Orientação (o IMU não fornece estes dados) Velocidade angular (X,Y,Z) Aceleração linear (X,Y,Z)	- rad/s m/s <sup>2</sup>	- (1e-6, 1e-6, 1e-6) (0,001, 0,001, 0,001)	100Hz		
		/ublox_gps_node/fix_velocity	Informação da velocidade com base nos dados GPS	Velocidade linear (X,Y,Z)	m/s	VARIA	4Hz		WGS84
		/ublox_gps_node/fix	Informação acerca da localização do Rover	Latitude Longitude Altitude	graus graus m	VARIA VARIA VARIA	4Hz		
		/ublox_gps_node/fix_velocity	Informação da velocidade com base nos dados GPS	Velocidade linear (X,Y,Z)	m/s	VARIA	4Hz		
Marvelmind Indoor GPS	Hedgehog (Beacon mlevel)	/hedgehog_imu_raw	Posição do hedge com base no referencial pré estabelecido	Endereço do Hedge [Z] Coordenadas da posição Aceleração (X,Y,Z) Giro (X,Y,Z)	m [1000, 1000] dps	Depende da imprecisão da posição dos beacons estáticos 1 mg/LSB 0,075dps/LSB	1 - 100Hz	Hedge - Sistema de coordenadas semelhante ao Rover (se a antena alinhada com o eixo superior (direito do mesmo) <b>Mhvel Indoor GPS</b> - Definido previamente no modém através do <b>disthorver</b> da <b>Marvelmind</b> , normalmente todos beacons estáticos e o origem e o mapa desmorve-se e torna dessa origem	
		/hedge_imu_odom	Resultado de todos os dados do IMU	Coordenadas da posição através fusão IMU (X,Y,Z) Orientação (X,Y,Z) Velocidade (X,Y,Z) Aceleração linear (X,Y,Z)	m - m/s m/s <sup>2</sup>	- - - -	1 - 100Hz		
		/hedge_quality	Qualidade da localização do hedge	Qualidade da localização	%	-	-		0,05 - 19Hz (utilizado 18Hz)
		/beacon_pos_a	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da temperatura, pressão e humidade	VARIA		VARIA
		/beacon_pos_b	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da imprecisão da posição dos beacons estáticos	VARIA		24 - 28Hz
		/beacon_pos_c	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da imprecisão da posição dos beacons estáticos	VARIA		24 - 28Hz
		/beacon_pos_d	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da imprecisão da posição dos beacons estáticos	VARIA		24 - 28Hz
		/beacon_pos_e	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da imprecisão da posição dos beacons estáticos	VARIA		24 - 28Hz
		/beacon_pos_f	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da imprecisão da posição dos beacons estáticos	VARIA		24 - 28Hz
		/beacon_pos_g	Posição dos beacons estáticos em relação a origem do beacons estáticos	Endereço do Beacon [Z] Posição (X,Y)	m	Depende da imprecisão da posição dos beacons estáticos	VARIA		24 - 28Hz