



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE AUTOMAÇÃO E SISTEMAS
CURSO DE GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Henrique Daniel Hamisch

**Projeto de um Filtro de Kalman Estendido para Estimação da Localização
Geográfica de Pessoas em Ambientes Externos**

Florianópolis
2021

Henrique Daniel Hamisch

**Projeto de um Filtro de Kalman Estendido para Estimção da Localização
Geográfica de Pessoas em Ambientes Externos**

Relatório final da disciplina DAS5511 (Projeto de Fim de Curso) como Trabalho de Conclusão do Curso de Graduação em Engenharia de Controle e Automação da Universidade Federal de Santa Catarina em Florianópolis.

Orientador: Prof. Leandro Buss Becker, Dr.

Supervisor: Wilian Dal Castel Zanatta, Eng.

Florianópolis

2021

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Hamisch, Henrique Daniel

Projeto de um Filtro de Kalman Estendido para estimação da localização geográfica de pessoas em ambientes externos / Henrique Daniel Hamisch ; orientador, Leandro Buss Becker, 2021.

82 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Engenharia de Controle e Automação, Florianópolis, 2021.

Inclui referências.

1. Engenharia de Controle e Automação. 2. monitoramento de pessoas e ativos. 3. fusão de sensores. 4. Filtro de Kalman Estendido. 5. navegação de pedestres. I. Becker, Leandro Buss. II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Controle e Automação. III. Título.

Henrique Daniel Hamisch

Projeto de um Filtro de Kalman Estendido para Estimação da Localização Geográfica de Pessoas em Ambientes Externos

Esta monografia foi julgada no contexto da disciplina DAS5511 (Projeto de Fim de Curso) e aprovada em sua forma final pelo Curso de Graduação em Engenharia de Controle e Automação

Florianópolis, 10 de maio de 2021.

Prof. Hector Bessa Silveira, Dr.
Coordenador do Curso

Banca Examinadora:

Prof. Leandro Buss Becker, Dr.
Orientador
UFSC/CTC/DAS

Wilian Dal Castel Zanatta, Eng.
Supervisor
Khomp Indústria e Comércio Ltda

Prof. Gustavo Artur de Andrade, Dr.
Avaliador
UFSC/CTC/DAS

Prof. Fabio Luis Baldissera, Dr.
Presidente da Banca
UFSC/CTC/DAS

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus, pelo dom da vida, pelo (limitadíssimo) conhecimento e pela liberdade. Também por manifestar Sua indescritível beleza em todos os domínios da existência humana - inclusive nos filtros de estimação projetados por Kalman.

À minha família, pelo suporte de todos os tipos possíveis em todos os momentos em que eu precisei. Sem os tempos de aconchego e de convivência boa ao lado deles eu não teria a estrutura necessária para os desafios que surgem.

À Julia, minha amiga, namorada e pra sempre companheira, por ser a lembrança diária daquilo que mais importa dentre todas as coisas que importam. Sou grato e privilegiado pela companhia incomparável que se interessou genuinamente pelo meu projeto e pela minha sanidade mental. Também pela paciência e compreensão durante os tempos de correria e de ausência.

Ao meu orientador, Leandro Becker, pelas conversas cheias de bons conselhos e sábios direcionamentos ao longo da execução do projeto. Também ao professor Hector Silveira, pelas discussões produtivas a respeito do Filtro de Kalman, que certamente foram essenciais para o desenrolar do projeto. Ainda, estendo o agradecimento à Coordenação do PFC e a todos os professores que contribuíram para o meu desenvolvimento como estudante de Engenharia.

À Khomp e aos meus amigos de trabalho, pela oportunidade ímpar de crescer profissionalmente e pessoalmente dedicando-me em um projeto envolvente e desafiador e podendo contar sempre com o suporte e as risadas de um time único, humano e inspirador.

Ao Mateus, por toda a ajuda com acertadas dicas, discussões sobre o projeto e companhia para celebrar os momentos de conquista. Por último, mas certamente não menos importante, a todos os meus amigos que tornam a minha vida mais significativa. Sem vocês, muita coisa não faria sentido!

*“Não há um único centímetro quadrado,
em todos os domínios de nossa existência,
sobre os quais Cristo, que é soberano sobre tudo,
não clame: ‘É meu!’”
(Abraham Kuyper)*

RESUMO

O avançado crescimento das tecnologias para localização e posicionamento em tempo real tem permitido que esta funcionalidade seja empregada em aplicações de ramos variados da indústria. A Khomp, empresa onde este trabalho foi elaborado, tem se feito presente neste mercado de soluções e recentemente iniciou o desenvolvimento do *Smart Badge*, dispositivo portátil para monitorar a posição geográfica de colaboradores em ambientes externos de grandes empresas. A abordagem típica de utilização de módulos GNSS para desempenhar tal função não é suficiente ao se considerar a autonomia energética como um requisito, já que estes componentes tipicamente apresentam alto consumo energético. Neste Projeto de Fim de Curso (PFC), uma estratégia para estimação da localização dos pedestres foi então proposta com o objetivo de atender aos requisitos específicos de consumo, precisão e disponibilidade da solução. Uma arquitetura embarcada formada um receptor GNSS e uma IMU (*Inertial Measurement Unit*) foi proposta e um Filtro de Kalman Estendido foi projetado para a estimação das variáveis de navegação, combinando um modelo matemático derivado do processo real e os dados dos sensores. Além disso, um protótipo experimental foi construído, por meio do qual os dados dos sensores foram coletados em testes de movimentação de um pedestre. As simulações executadas em um ambiente de simulação desenvolvido pelo aluno na ferramenta MATLAB mostraram que a arquitetura proposta é capaz de manter uma estimativa de posição geográfica com precisão mesmo com o aumento da periodicidade de leitura do módulo GNSS. Esses resultados permitem uma melhor utilização da bateria e garantem robustez à solução em situações de indisponibilidade dos sinais dos satélites.

Palavras-chave: monitoramento de pessoas e ativos, fusão de sensores, Filtro de Kalman Estendido, navegação de pedestres.

ABSTRACT

The growing development of real-time navigation and positioning technologies has been promoting the presence of this feature in a myriad of industrial and commercial applications. Khomp - company in which this project was developed - recently started the conception and development of *Smart Badge*, an wearable device aimed at monitoring the geographic position of workers in outdoor facilities of big companies. The typical approach of using a single GNSS module for achieving this objective is not sufficient if low power consumption is an important requirement, as these components usually present a significant operating current. In this project, a strategy for estimating a pedestrian's position was proposed with the objective of satisfying the specific requirements of power consumption, position accuracy and solution availability. An embedded architecture composed by a GNSS receiver and an IMU (Inertial Measurement Unit) was proposed and a Extended Kalman Filter (EKF) was designed to estimate the navigation variables, combining a mathematical model of the real process and sensor data. Besides, an experimental prototype was built in order to collect sensor measurements during the walk of a pedestrian. Simulations performed in an MATLAB environment implemented by the student shown that the proposed architecture is capable of keeping an accurate position estimate even when the period of GNSS corrections is increased. These results allow for a better battery management and grant robustness to the solution in case of temporary GNSS signal unavailability.

Keywords: people and assets tracking, sensor fusion, Extended Kalman Filter, pedestrian navigation.

LISTA DE FIGURAS

Figura 1 – Topologia da solução <i>Smart Badge</i>	19
Figura 2 – Diagrama de blocos com os subsistemas que compõem o dispositivo <i>Smart Badge</i>	20
Figura 3 – Base instalada de receptores GNSS por tipo de dispositivo hospedeiro.	24
Figura 4 – Ilustração do princípio da trilateração no sistema GNSS.	26
Figura 5 – Diferentes soluções baseadas na tecnologia GNSS por nível de acurácia horizontal e disponibilidade geográfica.	29
Figura 6 – Aspecto construtivo de um giroscópio de massa vibrante.	30
Figura 7 – Problema genérico da estimação do estado de um sistema através do filtro de Kalman.	34
Figura 8 – Visão geral do modelo de mecanização clássica.	43
Figura 9 – Etapas do algoritmo PDR.	47
Figura 10 – Acelerações lineares lidas nos três eixos do acelerômetro durante um teste de caminhada com duração de 10 segundos.	47
Figura 11 – Sinal do acelerômetro durante um intervalo de 10 segundos.	48
Figura 12 – Posição reportada pelo módulo GNSS em teste estático de aproximadamente 3 minutos com amostragem de 1 Hz.	55
Figura 13 – Magnitude da aceleração linear e velocidade angular medidas pelos três eixos da IMU em teste estático de 10 segundos com amostragem de aproximadamente 100 Hz.	56
Figura 14 – Frequência de amostragem dos sensores inerciais durante um intervalo de 5 segundos.	59
Figura 15 – Frequência de passos detectados durante um intervalo de 30 segundos.	60
Figura 16 – Etapas desenvolvidas ao longo deste PFC.	62
Figura 17 – Componentes do protótipo desenvolvido para coleta de dados.	62
Figura 18 – Fluxo de execução do <i>software</i> de simulação desenvolvido.	70
Figura 19 – Registros de área residencial onde foram realizadas as coletas de dados.	71
Figura 20 – Resultado da posição estimada com mecanização clássica expressa no sistema de coordenadas NED.	71
Figura 21 – Trajetória para testes do modelo de passo.	72
Figura 22 – Resultado do algoritmo de detecção de passos para o passo curto.	72
Figura 23 – Resultado do algoritmo de detecção de passos para o passo médio.	73
Figura 24 – Resultado do algoritmo de detecção de passos para o passo longo.	73
Figura 25 – Representação da trajetória caminhada no mapa.	74
Figura 26 – Estimação do azimute.	75

Figura 27 – Estimação do bias de medição do eixo z (vertical) do giroscópio. . .	75
Figura 28 – Estimação das coordenadas norte e leste da posição geográfica. . .	76
Figura 29 – Resultado do filtro nas coordenadas geodésicas de posição. . . .	77

LISTA DE QUADROS

Quadro 1 – Comparação entre as características do sistema GNSS e dos sensores inerciais quanto à sua aplicação para localização.	40
--	----

LISTA DE TABELAS

Tabela 1 – Dados do ensaio do modelo de passos utilizados como referência.	66
Tabela 2 – Resultados do algoritmo de detecção de passos.	67
Tabela 3 – Valores ideais da constante K para três tamanhos de passo diferentes simulados na coleta de dados.	67
Tabela 4 – Resultados do modelo de tamanho de passo.	68

SUMÁRIO

1	INTRODUÇÃO	14
1.1	MOTIVAÇÃO	14
1.2	OBJETIVOS	15
1.3	METODOLOGIA	15
1.4	ESTRUTURA DO DOCUMENTO	16
2	CONTEXTO DO PROJETO	17
2.1	A EMPRESA	17
2.2	MONITORAMENTO DE PESSOAS E ATIVOS (MPA)	17
2.3	SMART BADGE	19
2.4	REQUISITOS DE PROJETO	21
3	TECNOLOGIAS RELACIONADAS	23
3.1	GEOLOCALIZAÇÃO EM APLICAÇÕES MÓVEIS	23
3.2	SISTEMA GLOBAL DE NAVEGAÇÃO POR SATÉLITE	25
3.3	SISTEMA DE NAVEGAÇÃO INERCIAL	28
3.4	FUSÃO DE SENSORES	32
3.5	FILTRO DE KALMAN	33
3.5.1	Filtro de Kalman Estendido	37
4	DEFINIÇÃO DA ARQUITETURA EMBARCADA	39
5	MODELAGEM MATEMÁTICA	41
5.1	SISTEMAS DE COORDENADAS	41
5.1.1	Sistemas de Coordenadas Geodésico	41
5.1.2	Sistemas de Coordenadas Local	42
5.1.3	Sistemas de Coordenadas do Corpo	42
5.2	MECANIZAÇÃO CLÁSSICA	43
5.2.1	Visão Intuitiva	43
5.2.2	Equação da atitude	44
5.2.3	Equação da velocidade	44
5.2.4	Equação da posição	45
5.2.5	Modelo completo	45
5.2.6	Características dos Erros	46
5.3	<i>PEDESTRIAN DEAD RECKONING</i>	46
5.3.1	Deteccção de Passos	46
5.3.2	Cálculo do Tamanho de Passo	49
5.3.3	Propagação do Azimute	50
5.3.4	Mecanização da Posição	51
5.3.5	Características dos Erros	51
5.4	CONSIDERAÇÕES FINAIS	51

6	PROJETO DO FILTRO	53
6.1	MODELO DE PREDIÇÃO	54
6.2	MODELO DE OBSERVAÇÃO	54
6.3	SINTONIA DO FILTRO	55
6.4	COVARIÂNCIA DO RUÍDO DE PROCESSO	56
6.5	COVARIÂNCIA DO RUÍDO DE MEDIÇÃO	57
6.6	COVARIÂNCIA INICIAL DO ERRO DE ESTIMAÇÃO	57
6.7	CONSIDERAÇÕES TEMPORAIS	57
7	SIMULAÇÃO E RESULTADOS	61
7.1	PROTÓTIPO PARA COLETA DE DADOS	61
7.2	AMBIENTE DE SIMULAÇÃO	64
7.3	CENÁRIOS DE TESTE	65
7.4	RESULTADOS	65
7.4.1	Mecanização Clássica	65
7.4.2	Detecção de Passos	66
7.4.3	Tamanho de Passo	67
7.4.4	Filtro de Estimação	68
8	CONCLUSÃO	78
8.1	TRABALHOS FUTUROS	79
	REFERÊNCIAS	80

1 INTRODUÇÃO

A navegação e posicionamento de pessoas, veículos ou objetos é um alvo nada recente da atividade científica: povos antigos já estudavam como se guiar através da posição de constelações estelares no céu. Naturalmente, com o passar dos séculos o desenvolvimento tecnológico possibilitou que a navegação dependesse cada vez menos da observação humana e mais de ferramentas, como a bússola.

Nas últimas décadas, as tecnologias voltadas para posicionamento tem sido fortemente impulsionadas pela fabricação de sensores inerciais de alta precisão e custo acessível, pelo estabelecimento de sistemas globais de infraestrutura - tendo como principal representante os sistemas GNSS - e pela exploração de redes de comunicação instaladas como uma alternativa para o monitoramento da posição.

Com isso, as perspectivas de utilização destas soluções foram significativamente ampliadas, contemplando diversas aplicações, que variam desde mapeamentos topográficos com precisão centimétrica até a sugestão de um restaurante novo na vizinhança através de um aplicativo de *smartphone*. Dispositivos capazes de se localizar espacialmente podem auxiliar na gestão inteligente de frotas e estoques, otimizar a utilização de recursos em cidades conectadas e inteligentes, aumentar os níveis de segurança em atividades desempenhadas em áreas remotas ou de acesso restrito, contribuir para a satisfação na realização de atividades físicas em ambientes externos, entre outros incontáveis benefícios ((GSA), 2020).

Dentro deste contexto de mercado, a Khomp - empresa onde este projeto de PFC foi desempenhado - se situa com uma linha de produtos com vista a diferentes cenários de aplicação. Um dos integrantes deste portfólio - atualmente em fase inicial de desenvolvimento - é o *Smart Badge*, dispositivo portátil com o objetivo de monitorar a posição geográfica de colaboradores de grandes companhias em amplos ambientes externos. O trabalho apresentado aqui consiste na especificação de uma arquitetura embarcada e um algoritmo para estimar a posição dos usuários do *Smart Badge*.

1.1 MOTIVAÇÃO

Os desafios de tornar o *Smart Badge* em um produto eficiente e competitivo, que atenda às necessidades de empresas no que se refere à localização de pessoas e ativos, dão-se principalmente pela necessidade de estabelecer uma solução robusta, energeticamente eficiente e com um aspecto construtivo de uso ergonômico e minimamente intrusivo. Tudo isso sem mencionar os custos de fabricação das placas de circuito impresso, que precisam ser minimizados.

Tradicionalmente, soluções robustas e com precisão satisfatória para a maioria das aplicações envolvem componentes de alto custo, que despendem uma potência relativamente alta em sua operação e que não se encaixam nas restrições de tamanho

pretendidos para o *Smart Badge*. Com isso, o trabalho aqui desenvolvido tem sua motivação em investigar alternativas de tecnologias disponíveis que possam ser integradas em um módulo de localização que atenda a essas necessidades de projeto.

1.2 OBJETIVOS

Do ponto de vista da participação do aluno nas atividades da empresa, o objetivo geral deste trabalho é contribuir para o desenvolvimento dos produtos da linha de MPA da Khomp, agindo diretamente na concepção, implementação e validação do produto *Smart Badge*. Considerando os desafios já apresentados acima, o objetivo - mais detalhadamente e tecnicamente apresentado - é o projeto de um sistema para estimação da posição geográfica dos usuários do dispositivo em tempo real. A partir desse alvo principal, derivam-se os seguintes objetivos específicos que compõem os escopo deste PFC:

- Definir uma arquitetura embarcada para o módulo de localização, incluindo a seleção das tecnologias que serão empregadas e o apontamento de componentes para compor o *hardware*;
- Projetar um algoritmo de estimação da posição geográfica do usuário em tempo real utilizando as tecnologias selecionadas;
- Elaborar um protótipo experimental para teste e avaliação do(s) algoritmo(s) projetado(s);
- Testar o(s) algoritmo(s) proposto(s) utilizando dados experimentais reais que representem com significativa fidelidade o cenário de operação real e identificar aquele com o melhor desempenho, considerando os requisitos especificados.

1.3 METODOLOGIA

Apesar de ter como objetivo último a longo prazo a integração de um dispositivo (produto), o trabalho desenvolvido dentro do escopo deste PFC concentra-se no estudo e avaliação de algoritmos para desempenhar uma das funcionalidades do produto final, que é a estimação da posição. Considerando isso, a metodologia construída para o desenvolvimento da solução é a seguinte:

- Estudo aprofundado das tecnologias disponíveis para estimação da posição geográfica em tempo real em termos de *hardware* (quais sensores são disponíveis) e algoritmos (quais modelos matemáticos serão usados e como os dados dos sensores serão integrados);

- Coleta de dados experimentais de sensores em um cenário de testes, buscando replicar o ambiente esperado na operação do futuro produto, através de um protótipo construído com *kits* de desenvolvimento - enquanto o protótipo de *hardware* é desenvolvido;
- Implementação de um ambiente de simulação em *software* para execução dos algoritmos propostos a partir dos dados experimentais coletados;
- Avaliação da performance dos algoritmos propostos baseado em métricas significativas da estimação de variáveis e norteado pelos requisitos especificados para o projeto.

Com esta abordagem, espera-se o desenvolvimento de um sistema maduro e confiável que poderá ser futuramente implementado em *software* embarcado, compondo parte do dispositivo *Smart Badge*.

1.4 ESTRUTURA DO DOCUMENTO

O presente documento está organizado conforme se indica na sequência. No Capítulo 2, são apresentados o contexto onde o projeto foi desenvolvido (a empresa Khomp) e para qual cenário foi projetado - que inclui os requisitos de projeto, a topologia geral desenhada para a solução e o cenário de operação esperado em campo.

Na sequência, no Capítulo 3, são descritas com detalhes as principais tecnologias e ferramentas empregadas para que se pudesse atender aos requisitos de projeto. Aqui são incluídos tanto elementos de *hardware* quanto algoritmos incluídos na elaboração da solução.

A partir disto, uma proposta de arquitetura embarcada é apresentada no Capítulo 4, com as devidas justificativas.

O Capítulo 5 define os modelos matemáticos escolhidos para representar o processo real de navegação de pedestres, enquanto que o Capítulo 6 explica como que estes modelos e as informações dos sensores/módulos selecionados foram integradas para se obter estimativas ótimas de posição geográfica.

Por último, o Capítulo 7 apresenta detalhadamente os resultados obtidos e a performance da solução proposta diante de diferentes cenários, seguido de uma breve conclusão do trabalho aqui realizado no Capítulo 8.

2 CONTEXTO DO PROJETO

2.1 A EMPRESA

A Khomp - empresa onde este PFC foi realizado - foi fundada na cidade de Florianópolis, SC, em 1996, tendo como objetivo a produção nacional de dispositivos voltados para a área de centrais de comutação telefônica pública e privada. A partir do conhecimento técnico em processamento digital de sinais e outras tecnologias relacionadas, com o passar dos anos a companhia se consolidou no mercado nacional e latino-americano com uma linha de produtos que passou a incluir dispositivos baseados em *Computer Telephony Integration* (CTI) e em *software* livre (mercado *Soft PBX*).

Recentemente, acompanhando o forte crescimento das tecnologias relacionadas ao mercado IoT (*Internet of Things*), a Khomp tem investido na pesquisa e desenvolvimento de produtos para sensoriamento e telemetria de grandezas variadas (energia, umidade, temperatura, nível, entre outros), controle de acesso e monitoramento de pessoas e ativos. Este último é de especial interesse para este documento, haja vista que o estudo desempenhado neste trabalho tem o objetivo de consolidar algumas tecnologias para o desenvolvimento de um produto para esta aplicação, e será abordada com maior profundidade na Seção 2.2.

A forma de trabalho da empresa abrange quase que completamente a cadeia produtiva de soluções, desde sua concepção até o suporte ao cliente. O projeto do *hardware* (seleção de componentes, *layout* das placas de circuito impresso) e do *software* embarcado são desempenhados inteiramente pelos colaboradores da empresa, que possuem competências complementares e aprofundadas. Testes de integração entre *hardware* e *software* são conduzidos durante todo o processo de implementação das funcionalidades de cada produto, e testes de campo são preparados e acompanhados pelos responsáveis em cenários reais de aplicação em clientes.

2.2 MONITORAMENTO DE PESSOAS E ATIVOS (MPA)

Conforme indicado na seção anterior, a Khomp tem consistentemente desenvolvido, nos últimos anos, produtos voltados para o mercado de aplicações MPA, que são um desdobramento da emergência das tecnologias relacionadas a IoT: com dispositivos dotados de elementos sensoriais, capacidade computacional e conectividade à *internet*, apresentando tamanhos cada vez mais reduzidos e autonomia energética gradualmente mais expressiva, foi lógico utilizá-los para coletar dados de agentes de sistemas ou processos em tempo real. Estes agentes podem ser pessoas (colaboradores dentro de uma empresa, alunos de uma universidade, pacientes de um hospital) ou ativos (produtos, equipamentos, maquinário, veículos).

As motivações para que gestores de empresas e negócios invistam em soluções de monitoramento de destes elementos são muito variadas e se expandem acompanhando o ritmo do desenvolvimento tecnológico atual. Algumas das principais aplicações são elencadas abaixo:

- **Segurança do trabalho:** a circulação de pessoas em seus ambientes de trabalho pode, muitas vezes, representar riscos à integridade física, devido a fatores como operação de maquinário pesado, irregularidades no relevo, subestações de alta tensão, entre muitos outros. É importante monitorar a localização em tempo real para que ações rápidas possam ser tomadas em situações de emergência onde a segurança do trabalhador está comprometida;
- **Controle de acesso:** algumas instalações, ferramentas ou processos só podem ser acessados por pessoas específicas, que possuam a autorização e a capacitação para operá-los, controle que pode ser automatizado através de uma solução MPA com integração a dispositivos como porteiros eletrônicos ou travas digitais;
- **Contabilização de horas:** rastreando a posição de todos os colaboradores em seu ambiente de trabalho consiste também uma forma de controlar a jornada de trabalho, eventualmente possibilitando a automatização da utilização do ponto eletrônico;
- **Eficiência logística:** com informações estatísticas e visualização em mapa de como pessoas e ativos circulam dentro da operação de uma empresa/indústria, torna-se possível identificar gargalos logísticos e tomar ações para melhorar a eficiência na gestão da planta.

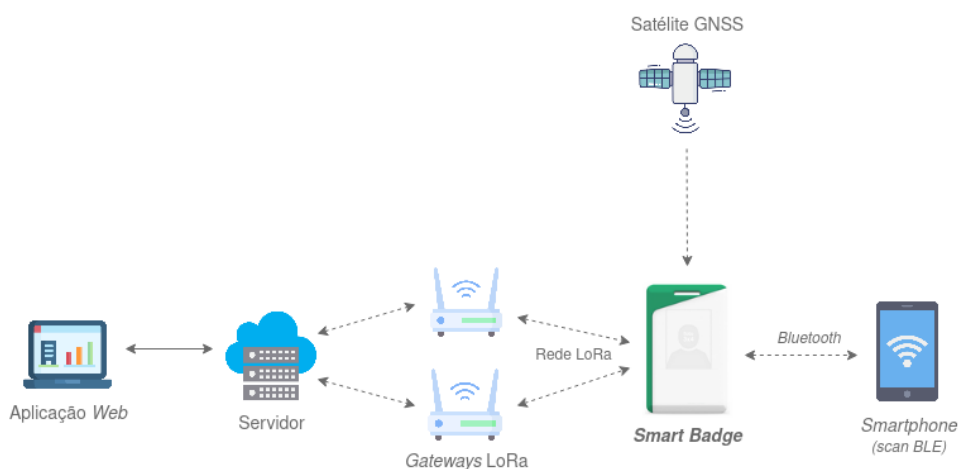
A forma como as soluções MPA são implementadas e utilizadas na prática tipicamente se dá através de um dispositivo (normalmente denominado de *endpoint*) que integra um ou mais sensores, um microcontrolador, uma fonte de alimentação (bateria ou alimentação externa, como o barramento de um veículo, por exemplo), um ou mais módulos para comunicação, eventualmente alguma interface homem-máquina, e uma circuitaria auxiliar para interconexão destes componentes. Este arranjo é desenhado e montado em uma ou mais placas de circuito impresso, que são então acondicionadas em um gabinete, cujas características mecânicas dependem muito do ambiente no qual o produto irá operar e onde ele será instalado. Para utilização em ambientes externos, por exemplo, é necessário se preocupar com o nível desejado de proteção IP (*Ingress Protection*) contra poeira, respingos de água, chuva, etc; já para um dispositivo que é carregado por uma pessoa durante suas atividades diárias (*wearable endpoint*), o peso e o tamanho precisam ser minimizados para evitar desconforto ou prejudicar a própria saúde do usuário.

2.3 SMART BADGE

Buscando propor uma ferramenta eficiente para o monitoramento de colaboradores em suas rotinas de trabalho em amplos espaços externos, o *Smart Badge* é apresentado como um dispositivo com capacidade computacional, sensorial e comunicativa, capaz de coletar dados sobre o usuário e enviá-los a um servidor integrado com uma aplicação *web*, equipando o gestor do sistema com as informações necessárias para a tomada de decisão rápida e eficiente sobre a operação da planta e seus colaboradores. A arquitetura planejada para o sistema é apresentada na Figura 1.

Os objetivos compreendidos pelo uso da solução irão depender fortemente dos problemas enfrentados pelos clientes e integradores em seus negócios, e poderão se modificar em virtude do potencial versátil de uso do *Smart Badge*. Ressalta-se, entretanto, que uma atenção especial será dada à segurança do trabalho e prevenção de acidentes (conforme elaborado na Seção 2.2) na especificação das funcionalidades do produto.

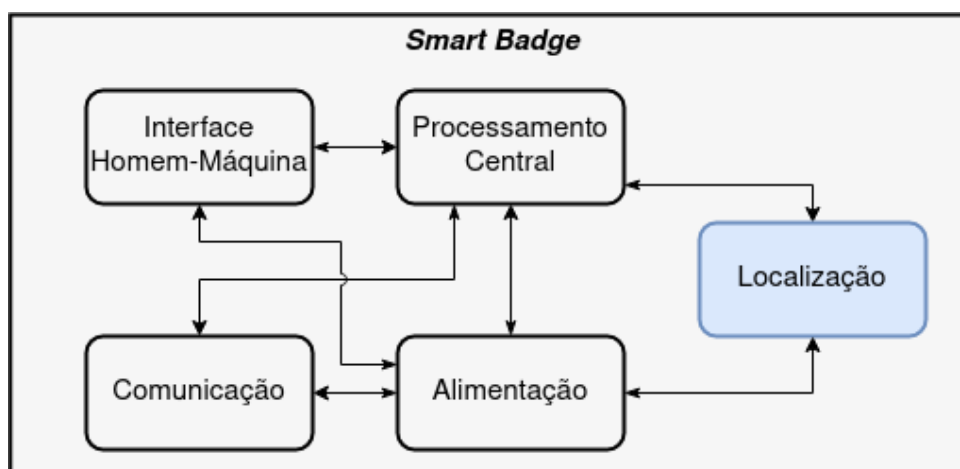
Figura 1 – Topologia da solução *Smart Badge*.



Fonte – O autor.

Destacando o dispositivo em si da infraestrutura completa da solução exibida na Figura 1 (que inclui os satélites GNSS, a rede de *gateways LoRa*, o aplicativo móvel para consulta local e a aplicação de gestão em nuvem), sua composição pode ser dividida em submódulos como na Figura 2, cujas funções são brevemente descritas na sequência.

- **Comunicação:** conectividade com os *gateways* da rede LoRa local para envio dos pacotes periódicos à aplicação em nuvem e com *smartphones* para consulta local via Bluetooth (mesma funcionalidade do ID-BLE apresentada na Seção 2.2).

Figura 2 – Diagrama de blocos com os subsistemas que compõem o dispositivo *Smart Badge*.

Fonte – O autor.

Para cada um dos dois canais de comunicação haverá um módulo e uma antena dedicados;

- **Localização:** estimação da posição geográfica do dispositivo em tempo real através do sistema GNSS e possivelmente de outras tecnologias avaliadas pelo aluno. O processamento dos sinais dos satélites GNSS será realizada com um módulo receptor e uma antena dedicada;
- **Interface Homem-Máquina:** interface composta de indicadores (LEDs e *display*) - através dos quais o dispositivo poderá comunicar e alertar ao usuário sobre seu próprio estado e também mensagens enviadas pela aplicação em nuvem - e de um botão de pânico, por meio do qual o usuário pode reportar uma situação de emergência à aplicação;
- **Alimentação:** módulo composto por uma bateria e um circuito para carregamento da bateria através de um conector USB, responsável por fornecer alimentação elétrica aos demais módulos;
- **Processamento Central:** composto essencialmente por um microcontrolador com o objetivo de integrar todos os módulos e executar o *software* embarcado implementado para o dispositivo.

Os dados coletados pelo dispositivo e enviados periodicamente à aplicação em nuvem através da rede LoRa local podem ser resumidos como: localização geográfica (latitude, longitude e altitude); estado do dispositivo (carga da bateria, versão de *hardware/firmware*, eventuais falhas detectadas); identificador único do dispositivo

(endereço MAC) e alarmes eventuais disparados pelo usuário em situações de emergência. Todas essas informações serão encapsuladas em um pacote com estrutura definida, contendo sempre uma marcação de data e horário. Entre todos os dados mencionados acima, o principal deles - especialmente no que se refere aos objetivos deste trabalho - é a localização geográfica, que permite o monitoramento em tempo real de toda a equipe de operação de uma empresa ou instalação. O dispositivo também será responsável por informar ao usuário, em tempo real, sobre situações de perigo ou emergência ao qual este pode estar exposto (como a entrada em uma área de risco, por exemplo), a partir de mensagens enviadas pela aplicação no servidor para os *endpoints* através dos *gateways* LoRa.

Considerando as funcionalidades acima introduzidas e detalhadas a seguir, o *Smart Badge* mostra-se como uma ferramenta essencial para a gestão de grandes grupos de colaboradores em ambientes externos de ampla cobertura, bem como para reduzir a exposição dos usuários a situações que possam trazer riscos à sua integridade física. Atualmente o produto se encontra em fase inicial de desenvolvimento, concentrado no projeto do *hardware* - mais especificamente no projeto das antenas de comunicação GNSS, LoRa e Bluetooth - e no estudo das tecnologias de comunicação e sensoriamento incluídas. O estudo de tais tecnologias tem sido feito com o auxílio de placas de desenvolvimento fornecidas pelas próprias fabricantes dos componentes, como uma alternativa enquanto os protótipos ainda não foram finalizados e fabricados.

Em relação à contribuição e áreas de envolvimento do aluno com o projeto, esclarece-se que, no momento em que este projeto de PFC teve início, algumas tecnologias integrantes do dispositivo já haviam sido definidas. Nenhuma indicação concreta de como essas tecnologias seriam aplicadas (módulos selecionados, protocolos utilizados, algoritmos para processamento dos sinais) tinha sido iniciada, porém. Ainda, sublinha-se que a contribuição do aluno se concentrou no módulo do produto responsável pela estimação da posição geográfica em tempo real, ficando as demais funcionalidades sob responsabilidade de outros integrantes da equipe.

2.4 REQUISITOS DE PROJETO

A partir da descrição geral do produto e do ambiente de operação, os requisitos para o projeto podem ser especificados. É muito importante aqui ressaltar que o objetivo deste trabalho é estudar formas de estimar especificamente a posição geográfica do usuário portador do *Smart Badge*. Em outras palavras, o trabalho aqui desempenhado se concentra em estudar tecnologias e algoritmos para que o módulo de localização do produto (vide Figura 2) seja capaz de estimar a posição geográfica do usuário com precisão, considerando as características típicas do cenário real. Logo, os requisitos aqui apresentados são voltados especificamente para o módulo de localização, e não visando o produto como um todo - o que resultaria em uma lista maior e

mais abrangente do que a mostrada abaixo.

- Estimar a posição geográfica do usuário em ambientes externos;
- Medir a posição geográfica horizontal (latitude e longitude) do usuário portando o dispositivo;
- Ser capaz de fornecer uma estimativa de posição com periodicidade mínima de 1 segundo;
- Manter a capacidade de estimar a posição geográfica temporariamente em situações de indisponibilidade total ou parcial dos sinais de satélites GNSS;
- Minimizar o consumo energético dispendido para estimação da posição geográfica;
- Minimizar a área ocupada na placa de circuito impresso (*hardware footprint*), haja vista que o dispositivo deve ter dimensões reduzidas para ser utilizado pelos colaboradores durante suas atividades diárias;
- Minimizar o tamanho dos dados de localização reportados à aplicação, considerando que a rede LoRa aceita uma baixa taxa de dados.

Como se pode perceber, o requisito de precisão de posicionamento não é elevadamente exigente e seria plenamente satisfeito com um módulo GNSS operando em condições normais, com uma visada contendo o número de satélites necessários. O objetivo, porém, deste trabalho, é investigar e propor alternativas para complementar este sistema, que pode facilmente se tornar indisponível - dependendo de condições atmosféricas e do ambiente - e que apresenta um expressivo consumo energético em seus componentes embarcados, que inviabiliza sua utilização constante para um dispositivo de baixo consumo e alimentado com bateria.

3 TECNOLOGIAS RELACIONADAS

A partir dos requisitos de projeto especificados no Capítulo 2, as tecnologias disponíveis para localização geográfica de pessoas e ativos foram atenciosamente investigados, buscando uma proposta viável para o problema que está sendo resolvido. Esta revisão é apresentada brevemente na Seção 3.1.


Como já foi indicado, o sistema GNSS já havia sido selecionado antes do início deste projeto de PFC, e é de fato uma escolha óbvia para que se possa obter uma posição absoluta e precisa durante longos períodos de utilização. No entanto, esta tecnologia é bastante complexa e apresenta várias arquiteturas de implementação possíveis, o que demandou um estudo aprofundado, que é resumido na Seção 3.2. Na sequência, na Seção 3.3, os Sistemas de Navegação Inercial (INS, do inglês *Inertial Navigation Systems*) são apresentados como uma alternativa ou complemento para o cálculo de posição - com uma amostragem mais rápida e maior disponibilidade, além de outras características. Finalmente, nas Seções 3.4 e 3.5 o filtro de Kalman é introduzido como uma ferramenta poderosa para integrar os dados obtidos destes diferentes sistemas.

3.1 GEOLOCALIZAÇÃO EM APLICAÇÕES MÓVEIS

Nenhum método ou tecnologia de geolocalização é tão versátil que sirva como solução para todos os cenários possíveis, ou, em outras palavras, toda ferramenta foi formulada e pertence a um determinado contexto e apresenta consideráveis limitações fora deste ((GSA), 2016). A qualidade de um produto com este objetivo depende diretamente da escolha de sensores e sistemas que tenham características de funcionamento que sejam compatíveis com o ambiente no qual estarão inseridas. Fatores como área de cobertura, densidade de área construída, ambiente interno ou externo, densidade de vegetação, entre outros, todos influenciam significativamente na disponibilidade e precisão das soluções calculadas e devem ser levados em conta durante o projeto. Por essas razões, diferentes possibilidades foram inicialmente investigadas.

Ao longo das últimas décadas, desde a operacionalização da primeira constelação de satélites com cobertura global no ano de 1995, os sistemas GNSS são a principal tecnologia utilizada para o cálculo da posição geográfica de objetos em ambientes externos, com uma base instalada de aproximadamente 6 bilhões de dispositivos em 2019 (GSA, 2019) distribuídos em diferentes dispositivos hospedeiros conforme mostra a Figura 3. Tal popularidade pode ser mais do que justificada pela infraestrutura com cobertura global já estabelecida através dos satélites em órbita, permitindo que uma precisão na ordem de metros seja possível com a utilização de apenas um receptor simples e uma antena equipados no dispositivo em questão (NOVATEL, 2015; (GSA), 2020).

Figura 3 – Base instalada de receptores GNSS por tipo de dispositivo hospedeiro.



Fonte – (GSA, 2019).

Outra possibilidade para cobertura de amplas áreas externas é a utilização de redes celulares instaladas, como GSM (*Global Standard for Mobile Telecommunications*) e UMTS (*Universal Mobile Telecommunication System*), que consistem basicamente em um conjunto de estações-base construídas na superfície terrestre. A posição absoluta do objeto móvel é derivada então a partir das localizações já conhecidas dessas bases através de abordagens utilizando RSSI (*Received Signal Strength Indication*), TDOA (*Time Difference of Arrival*) ou OTDOA (*Observed Time Difference of Arrival*) ((GSA), 2020). A precisão obtida nessas soluções é tipicamente na ordem de centenas ou milhares de metros, dada a grande distância pela qual estão usualmente separadas as estações-base ((GSA), 2020). Outra limitação desta opção é que a disponibilidade da solução desenvolvida fica condicionada à existência e operação de uma rede celular na região geográfica de interesse, condição que não se verifica no contexto do projeto aqui desenvolvido, como visto no Capítulo 2.

Expandindo ainda mais a análise, existem as redes sem fio de área local (WLAN, *Wireless Local Area Network*) ou de área pessoal (WPAN, *Wireless Personal Area Network*). Um exemplo clássico do primeiro grupo são as redes de acesso à *internet* tipicamente encontradas em instituições, universidades ou condomínios, enquanto que o segundo grupo pode ser muito bem representado pela rede Bluetooth. Todas estas soluções utilizam abordagens similares às apresentadas acima (TDOA, RSSI, OTDOA).

Já foram reportadas precisões de posicionamento menores que 30 metros para a rede Bluetooth e menores de 10 metros para redes WLAN, marcas muito mais satisfatórias que as percebidas em uma rede celular. Do outro lado da balança fica, porém, a área de cobertura, que enquanto pode ser global no caso da rede celular, fica limitada a centenas ou dezenas de metros para redes Bluetooth e WLAN (BILL *et al.*, 2004). Por essa última razão, estas soluções são tipicamente inviáveis para situações onde uma ampla região geográfica deve ser compreendida, o que exigiria a instalação de uma extensiva malha de pontos de acesso, elevando os custos de implementação drasticamente.

Por último, destaca-se os Sistemas de Navegação Inercial, que oferecem a capacidade de estimar posição e orientação em relação a um estado inicial conhecido a partir das acelerações lineares e velocidades angulares medidas por sensores inerciais - acelerômetros e giroscópios. Esta opção fornece bastante versatilidade por não depender de nenhum suporte externo para seu funcionamento - o que é denominado na literatura como sistemas autocontidos (*self-contained*), podendo operar tanto em áreas externas quanto internas. Estes apresentam alta precisão em curtos intervalos, que vai se degradando com o passar do tempo já que pequenos erros se tornam grandes desvios em virtude da acumulação da posição, como será visto mais adiante neste trabalho. Os sistemas INS costumam ser empregados em conjunto com outra tecnologia - que necessariamente forneça uma referência absoluta de posição, reiniciando os erros acumulados frequentemente - como uma forma de estender o desempenho da aplicação final.

Ponderando as vantagens oferecidas e limitações inerentes das tecnologias pesquisadas, os sistemas GNSS e INS foram selecionados para integrar o módulo de localização do *Smart Badge*, em razão das suas características naturalmente complementares que geram um alto potencial de integração. Esta decisão será reforçada e explicada mais profundamente especialmente no Capítulo 4.

3.2 SISTEMA GLOBAL DE NAVEGAÇÃO POR SATÉLITE

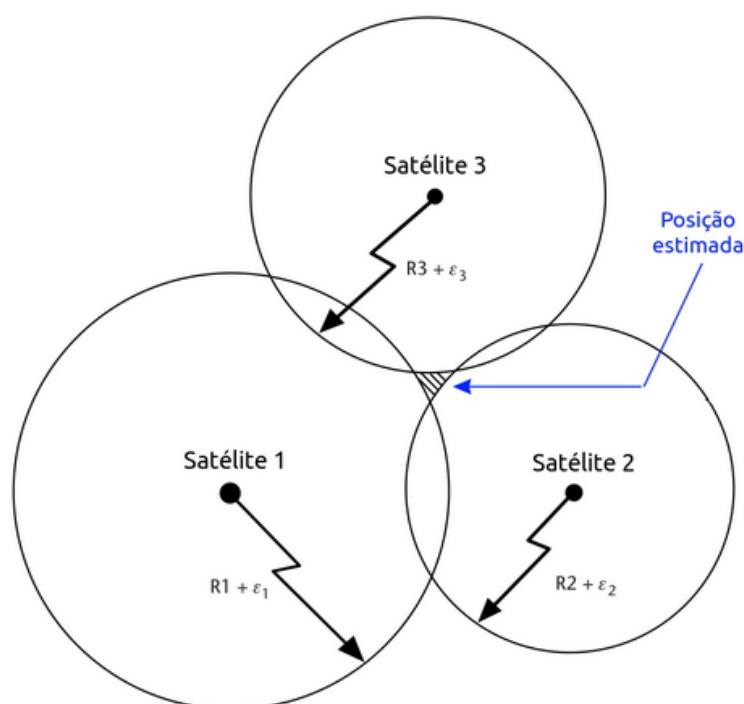
GNSS é o termo que abrange todo e qualquer sistema de navegação baseado em satélites capaz de equipar usuários com a capacidade de determinar sua posição geográfica de forma autônoma e com relativa precisão (OTHER. . . , 2020). Tais sistemas têm sido implantados desde o século passado e desenvolvidos continuamente por diferentes países e organizações, tendo como principais exemplos o GPS (Estados Unidos), GLONASS (Rússia), GALILEO (União Europeia) e BeiDou (China) (NOVATEL, 2015). As características principais destes sistemas são cobertura global, precisão na ordem de alguns metros (sem uso de tecnologias auxiliares), e certo grau de resistência à ação de interferências diversas.

Os sistemas GNSS tem sua topologia organizada em três segmentos: 1) seg-

mento espacial, que consiste em uma constelação de satélites em órbita que transmitem sinais pseudo-aleatórios - utilizados para a estimação da posição - juntamente com dados de posição do satélite, órbita e informações do sistema; 2) segmento de controle, composto por estações terrestres responsáveis por monitorar o estado da constelação de satélites, enviar dados atualizados de órbita, relógio e almanaque e corrigir a posição de cada satélite através de comandos e 3) segmento de usuário, representado por receptores utilizados nas mais diversas aplicações (KAPLAN *et al.*, 2005).

O cálculo da posição geográfica - sintetizado nas variáveis latitude, longitude e altitude - a partir dos sinais enviados pelos satélites das constelações GNSS baseia-se no conceito de trilateração: conhecendo-se as distâncias de um objeto em relação a três ou mais satélites, cujas posições são precisamente conhecidas através de complexos modelos de órbita, é possível determinar com precisão a posição desse objeto. A Figura 4 representa o conceito de trilateração.

Figura 4 – Ilustração do princípio da trilateração no sistema GNSS.



Fonte – Adaptado de (KAPLAN *et al.*, 2005).

Para obter a distância em relação a cada satélite, os receptores GNSS utilizam uma técnica conhecida como Tempo de Chegada (TOA, do inglês *Time of Arrival*): medindo-se o intervalo de tempo decorrido entre a emissão de um sinal específico por um satélite e sua chegada no receptor, e multiplicando-o pela velocidade de propagação do sinal (velocidade da luz, neste caso), obtém-se a distância entre os dois

objetos. Essa computação é realizada para vários satélites que estejam na visada do dispositivo, e então a posição geográfica pode ser reportada (KAPLAN *et al.*, 2005).

Cada satélite GNSS em órbita transmite continuamente códigos pseudo-aleatórios (obtidos através técnicas de espalhamento de espectro) individuais, que modulam ondas portadoras de diferentes frequências localizadas na faixa conhecida como “Banda L” dentro do espectro de rádio (950 MHz a 2150 MHz), sendo as frequências L1 (1575,42 MHz) e L2 (1227,60 MHz) as mais conhecidas, com a adição mais recente da L5 (1176,45 MHz). Dados de navegação (informações de saúde do satélite do sistema, posição do satélite, desvio do relógio interno do satélite e outras informações auxiliares) também modulam as portadoras e fornecem informações para que correções nos módulos receptores possam ser efetuadas. Nessa configuração, os satélites compartilham o mesmo canal de comunicação, dividindo o acesso através do método de Acesso Múltiplo por Divisão de Código (CDMA, do inglês *Code Division Multiple Access*), onde seus sinais podem ser separados através de técnicas de correlação cruzada. Cada dispositivo receptor conhece e internamente compara o sinal recebido com sua réplica através de laços de controle (*delay locked loop, phase locked loop*), calculando a partir disso o tempo de propagação a partir do satélite (ENGE, 1994; PETERSON *et al.*, 1995; JUNQUEIRA, s.d.).

Em ambientes reais de operação, vários fatores - externos e internos ao sistema - influenciam em diferentes camadas do sistema GNSS, gerando erros no cálculo da posição geográfica. A Figura 4 leva em conta que as medidas de tempo de propagação do sinal calculadas são diferentes das reais, gerando uma região de confiança na qual a posição pode ser obtida. Uma breve descrição das fontes de erros é apresentada a seguir. Para cada fonte de erro existem diferentes e complementares alternativas de mitigação, que não serão abordadas em detalhes neste documento (NOVATEL, 2015) - já que normalmente envolvem a utilização de receptores com tecnologias mais avançadas que não são adequados aos requisitos deste projeto.

- **Relógios dos satélites:** apesar de muito precisos, os relógios internos dos satélites apresentam um pequeno desvio em relação ao horário universal (UTC), o que faz com que os períodos de transmissão sejam diferentes do considerado pelos receptores;
- **Erros de órbita:** mesmo que equipados com propulsores para efetuar correções de posição, a posição real dos satélites pode ser diferente da órbita prevista;
- **Atraso ionosférico de propagação:** a camada da atmosfera conhecida como ionosfera (entre 80 km e 600 km de altitude) é densa em partículas carregadas eletricamente que geram atrasos na propagação do sinal;

- **Atraso troposférico de propagação:** diferenças de pressão, umidade e temperatura em regiões próximas à superfície terrestre também geram atrasos na propagação dos sinais dos satélites. Os erros inseridos aqui são comuns a uma mesma região geográfica e portanto mais fáceis de corrigir do que aqueles inseridos pela ionosfera;
- **Multipercurso:** em ambientes com alta concentração de prédios, construções ou vegetação, os sinais transmitidos pelos satélites sofrem elevada reflexão e chegam aos receptores em diferentes momentos, gerando erros nos cálculos.

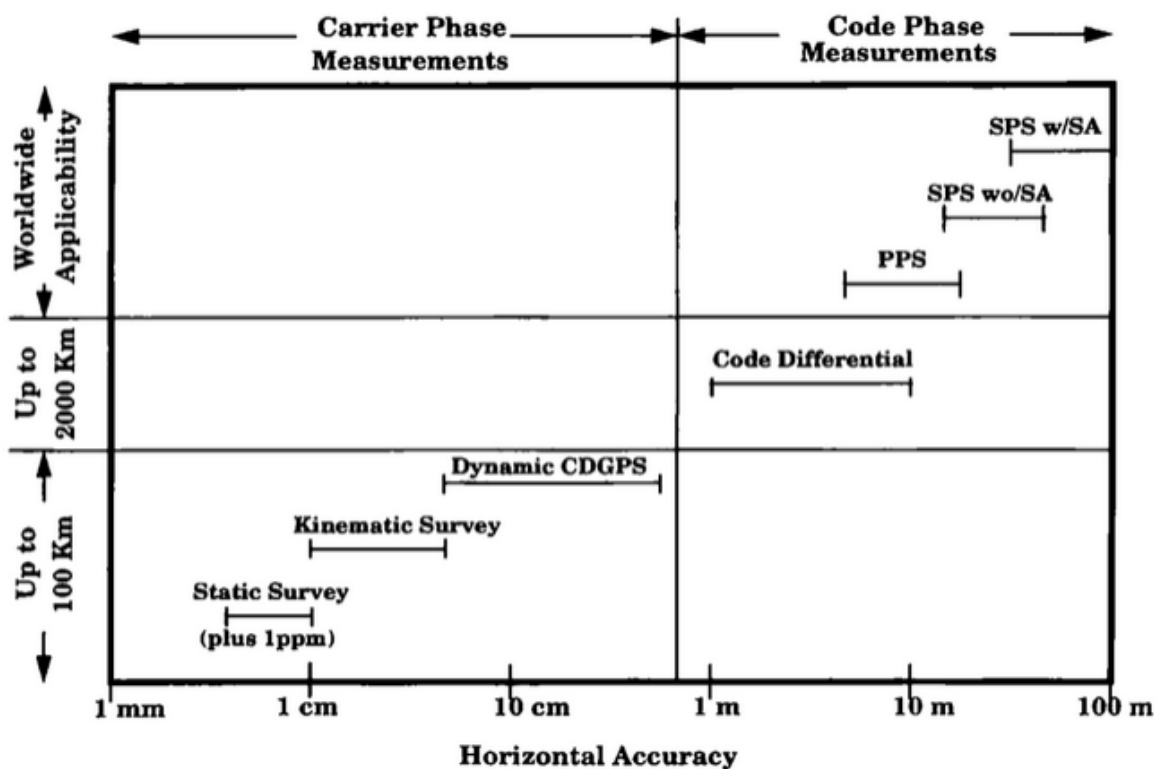
Considerando as características e limitações apresentadas até aqui, a tecnologia GNSS mostra-se muito apropriada para o desenvolvimento de soluções de navegação e geolocalização em ambientes externos, mencionando especialmente a independência de qualquer infraestrutura adicional instalada no ambiente de operação. A estrutura dos sistemas GNSS também permite grande flexibilidade para a implementação de soluções com diferentes arquiteturas, requisitos e especificações, que atendem a diferentes objetivos em variadas aplicações. A Figura 5 fornece uma visão geral de diferentes soluções baseadas em GNSS posicionadas de acordo com sua precisão de localização e aplicabilidade por região geográfica.

Como pode ser observado na Figura 5, à medida que a precisão requerida para a posição geográfica cresce, a disponibilidade da solução passa de global para regional, impactando em investimentos maiores para instalação de uma estrutura no ambiente de operação. No caso das soluções diferenciais, é necessário eliminar os erros comparando os sinais obtidos no receptor com os de outro dispositivo cuja posição é bem conhecida (estação-base), o que exige, além da estação-base com tecnologia para cálculo preciso da sua própria posição, um canal de comunicação com alta largura de banda - como uma rede móvel celular, por exemplo -, impossibilitando a utilização de redes privadas e que impactam em menor consumo para transmissão, como a rede LoRa, por exemplo. Para as propostas que fazem o uso das medidas de fase da portadora (metade à esquerda do gráfico), o custo dos receptores cresce consideravelmente quando comparado com aquelas que utilizam somente a fase do código pseudo-aleatório enviado pelos satélites. Estas indicações foram levadas em consideração para definir exatamente de que forma o sistema GNSS seria empregado no módulo de localização do *Smart Badge*, o que é apresentado no Capítulo 4.

3.3 SISTEMA DE NAVEGAÇÃO INERCIAL

Intuitivamente, em contraste à forma de se obter uma estimativa da posição geográfica de um corpo móvel apresentada na Seção 3.2, alguém pode sugerir que, a partir de um momento onde a posição desse objeto é conhecida, seu deslocamento linear a cada novo instante de tempo seja monitorado, acrescentando a informação nova

Figura 5 – Diferentes soluções baseadas na tecnologia GNSS por nível de acurácia horizontal e disponibilidade geográfica.



Fonte – (ENGE, 1994).

à estimativa anterior de posição. Com isso, é possível obter uma posição estimada absoluta a cada momento.


Esse é exatamente o princípio de funcionamento de um Sistema de Navegação Inercial (INS), que utiliza as informações advindas de sensores - *e.g.* acelerômetros, giroscópios - para estimar a orientação e posição de um corpo móvel em relação a um estado inicial conhecido (WOODMAN, 2007). Essa técnica de navegação é conhecida como “inercial” porque os sensores empregados utilizam leis *Newtonianas* de movimento para obter a variável de interesse (aceleração linear ou velocidade angular) (TORRES *et al.*, 2002). No caso dos giroscópios, o efeito Coriolis é empregado como princípio por trás da medição, que afirma que em um sistema de coordenadas de referência que esteja submetido a uma rotação de velocidade angular ω , uma massa m deslocando-se linearmente a uma velocidade v é submetida a uma força F_C - conhecida como força de Coriolis - conforme a equação abaixo (WOODMAN, 2007):

$$F_C = -2m(\omega \times v) \tag{1}$$

A força de Coriolis F_C produz um deslocamento na direção perpendicular ao

sentido de deslocamento dado por v , que, sendo medido, pode ser usado para calcular a velocidade angular ω . Em termos construtivos, o arranjo mais comum de giroscópio consiste em uma pequena massa conhecida que é submetida a uma vibração constante e com sentido alternante, com intensidade também conhecida, conforme ilustra a Figura 6.

Figura 6 – Aspecto construtivo de um giroscópio de massa vibrante.



Fonte – (WOODMAN, 2007).

Em relação aos acelerômetros, sua construção consiste basicamente em uma pequena massa, desta vez fixa a uma mola, ambos estando acoplados ao objeto que deseja-se obter a aceleração. Quando uma aceleração é imprimida no eixo de deslocamento da mola, a massa tende a permanecer estacionária, e por isso exerce uma força sobre a mola que pode ser medida através do deslocamento desta. A partir desse deslocamento medido é possível saber a aceleração (WOODMAN, 2007).

Tais aspectos construtivos são gerais e podem ser encapsulados em sensores de diferentes materiais, tamanhos e que geram medições com precisões diferentes. Com a evolução de técnicas de fabricação e engenharia de materiais ao longo dos anos, modelos tipicamente grandes e pesados para medições inerciais foram sendo miniaturizados até chegar em dispositivos atualmente conhecidos como sensores microeletromecânicos (MEMS, do inglês *Microelectromechanical Systems*). Como o próprio nome já indica, são construídos com uma composição de dispositivos mecânicos (normalmente responsáveis por “sentir” as variáveis de interesse) com elétricos (com a função de converter o estímulo percebido em uma grandeza mensurável computacionalmente, como tensão, por exemplo) com tamanho muito reduzido. Esses sensores

apresentam enormes vantagens para o desenvolvimento de aplicações embarcadas, já que são mais compactos, leves e baratos.

Os sistemas INS tipicamente permitem uma frequência de amostragem (comumente denominada como ODR, *Output Data Rate*) muito alta - superiores a 1 kHz -, o que equipa a aplicação a calcular e reportar posição a uma taxa muito superior àquela obtida somente com o uso de um sistema GNSS, que, como será abordado mais à frente, possui uma ODR muito menor (na ordem de 1 Hz) ou é periodicamente inativado para reduzir o alto consumo energético. Com essa capacidade de perceber incrementos de posição, velocidade e orientação em intervalos de tempo muito menores, os sistemas INS tornam possível a percepção de eventos que, dependendo da ODR, poderiam passar despercebidos por uma aplicação utilizando somente GNSS. Outra vantagem, ainda, é que o consumo energético de *chips* utilizados como sensores INS é significativamente menor que o de um módulo GNSS (dados e detalhes podem ser vistos no Capítulo 4), portanto os primeiros são mais adequados para aplicações de baixo consumo.

Assim como qualquer sensor, os acelerômetros e giroscópios que compõem qualquer sistema INS são sujeitos a diversas fontes de erros, sendo as principais apresentadas resumidamente a seguir (WOODMAN, 2007; AGGARWAL, 2010):

- **Bias ou zero offset:** consiste no valor que é reportado pelos sensores na ausência de qualquer aceleração linear resultante ou velocidade angular reais aplicadas no corpo, que é acumulado ao longo do tempo no cálculo da posição. Esse tipo de erro costuma ser elevado para sensores microeletromecânicos de baixo custo - como os utilizados neste projeto - e difícil de compensar, já que apresenta um componente estocástico que se modifica a cada vez que o dispositivo é inicializado (*turn-on bias*);
- **Fator de escala:** idealmente, a relação de ganho entre o elemento medido e o sinal elétrico correspondente deveria ser uma função linear e invariante no tempo, porém isto não é verdade. O fator de escala, na prática, pode variar com o tempo, com a temperatura e a partir de outros fatores;
- **Ruído térmico/mecânico:** os sinais reportados pelos sensores inerciais são corrompidos por ruído branco, que oscila em uma frequência muito maior do que a de amostragem. O ruído apresenta uma característica claramente gaussiana, com média igual a zero e sem correlação temporal.

Estratégias para calibrar os sensores inerciais e mitigar a influência destes erros no processo de cálculo da posição serão abordadas nos Capítulos 5 e 6.

3.4 FUSÃO DE SENSORES

De forma resumida, a melhor estratégia para uma solução de localização, em termos de aspectos como precisão, robustez e disponibilidade, é aquela que integra sensores com características diferentes, fazendo uso de informações que se somam para a obtenção de um resultado melhor do que o que seria obtido através de estratégias isoladas. Em outras palavras, os erros de estimação de posição decrescem quando sensores com características diferentes são empregados conjuntamente, com diferentes níveis de integração para o cálculo da solução (FALCO *et al.*, 2017).

Em conjunto com uma variedade nos elementos responsáveis pelo sensoria-mento das variáveis de interesse, um segundo componente que agrega maior precisão e confiabilidade nas estimativas de posição é um conhecimento matemático, na forma de um modelo que pode ser iterativamente calculado, do comportamento deste sistema, que possibilita prever a próxima posição antes que medidas sejam realizadas.

Em princípio, a fusão de sensores consiste essencialmente em agregar dados de sensores diferentes, em conjunto com um modelo matemático do sistema em ques-tão, de forma a produzir uma estimativa ótima do estado deste sistema. Intuitivamente, essa estratégia parece produzir resultados melhores que abordagens individuais (ou sem integração de sensores) à medida em que adiciona mais informações para a re-solução do problema. Diferentes tipos de algoritmos para fusão de sensores já foram formulados, sendo o Filtro de Kalman um dos mais comuns em aplicações de navega-ção (ANGRISANO *et al.*, 2010). A partir de uma formulação matemática da estratégia de integração, esta é transformada em sua versão discreta, a qual é implementada em uma arquitetura computacional para que possa ser executada em algum sistema embarcado - para aplicações de tempo real - ou computador fixo - em aplicações pós-processadas.

A fusão de sensores pode servir a diferentes propósitos, que são aqui breve-mente apresentados:

- **Redução de ruído em medições:** cruzar dados de sensores do mesmo tipo ou de tipos diferentes pode reduzir significativamente o ruído ao medir determinada grandeza física. Um exemplo dessa aplicação é a combinação de um magnetô-metro com um giroscópio para medir a intensidade do campo magnético agindo em um determinado objeto, como um *smartphone*, por exemplo, que permite distinguir se uma variação da intensidade do campo magnético foi originada por uma perturbação ou pela movimentação do dispositivo;
- **Estimar grandezas que não podem ser medidas diretamente:** em certas situ-ações, como no caso de um sensor óptico - uma câmera, por exemplo - medindo a distância em relação a um objeto, não é possível obter esta medida utilizando somente uma câmera. É necessário que duas câmeras, colocadas em posições

diferentes, sejam combinadas para extrair informação tridimensional e estimar a distância ao objeto;

- **Aumentar a área de cobertura de uma medição:** sensores do mesmo tipo podem ser alocados em posições diferentes e complementares de forma a criar um entendimento mais abrangente do estado de um objeto em termos de áreas ou componentes, como por exemplo quando vários sensores ultrassônicos são espalhados na extremidade de um carro para criar um mapa da área vizinha ao veículo;
- **Aumentar a confiabilidade de medições:** em sua forma mais básica, permite combinar informações de sensores do mesmo tipo medindo a mesma grandeza física, estabelecendo uma confiabilidade para situações onde um ou mais dos sensores falhe ou seja danificado. Essa técnica pode ser exemplificada pela instalação de vários Tubos de Pitot - sensores utilizados para medir a velocidade do ar em aeronaves - no bico de um avião, replicando suas medições.

Expandindo a exemplificação do último objetivo listado, pode-se considerar uma situação onde sensores de diferentes tipos, medindo grandezas físicas diferentes, são combinados para se obter uma melhor ideia do valor real de uma variável do que o que seria obtido se somente um dos tipos de sensores fosse empregado. O exemplo que talvez melhor represente isso é exatamente a aplicação desenvolvida neste PFC: a combinação de um módulo INS com um receptor GNSS para estimar a posição e velocidade de um pedestre. O primeiro conjunto de sensores mede velocidades angulares e acelerações lineares, enquanto que o segundo mede posição e velocidade diretamente.

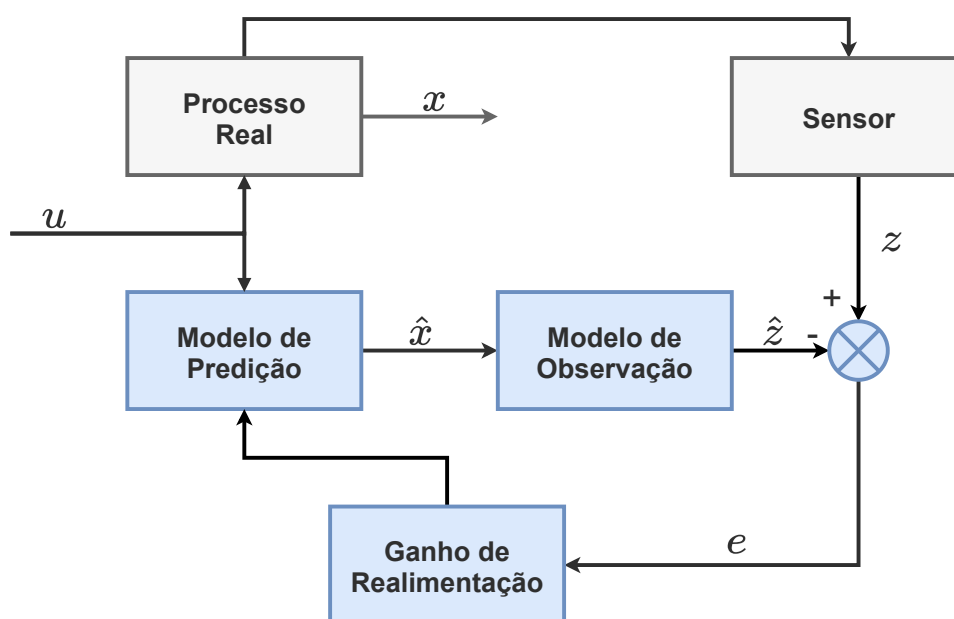
3.5 FILTRO DE KALMAN

Conhecido por sua versatilidade e robustez, o filtro de Kalman é um algoritmo amplamente empregado em aplicações de fusão de sensores, especialmente no campo de navegação e geolocalização. Trabalhos nesta direção de pesquisa podem ser encontrados ao longo deste documento inteiro. De maneira geral, o objetivo do filtro é produzir uma estimativa ótima do estado de um sistema linear a partir de uma série de medições ruidosas, que podem ser de diferentes sensores ou não.

Tipicamente, a variável de interesse do problema que está sendo resolvido não pode ser medida diretamente - ou sua medição apresenta precisão reduzida por aspectos como ruído, disponibilidade, baixa taxa de amostragem - e então é utilizada uma combinação de diferentes medições provindas de diferentes sensores, juntamente com um modelo matemático do sistema, para estimar seu valor real.

A Figura 7 mostra, de maneira simplificada, como o filtro de Kalman pode ser empregado em um problema genérico de estimação do estado de um sistema. O estado real do sistema (variável cujo valor deseja-se estimar com precisão) é representado pela letra x - que, para fins de generalização se considera como um vetor de dimensão n . O vetor genérico u engloba quaisquer entradas deste processo que podem ser diretamente conhecidas pelo algoritmo do filtro.

Figura 7 – Problema genérico da estimação do estado de um sistema através do filtro de Kalman.



Fonte – O autor.

A partir do conhecimento dos princípios naturais que regem esse sistema (características físicas, químicas, etc, dependendo do processo em questão), é possível elaborar, de maneira analítica, um modelo matemático que descreve a evolução deste sistema no tempo. A partir desse modelo, é possível então obter uma estimativa do estado real, \hat{x} . Caso o conhecimento sobre o processo real fosse suficientemente apurado, a estimativa \hat{x} mapearia perfeitamente sua correspondente real, e então o filtro de Kalman não seria necessário. Sabe-se porém que, na prática, por mais apurado e sofisticado que seja o modelo matemático, sempre existirão erros de modelagem pois o sistema real nunca se comporta da maneira ideal ou esperada. Em outras palavras, qualquer modelo matemático é essencialmente incompleto, e, por consequência, apresenta erros em sua modelagem. Estes erros são aqui denominados como ruídos de processo.

Além da informação fornecida pelo modelo, o filtro de Kalman faz uso de uma segunda fonte: medições diretas de grandezas reais relacionadas ao sistema, represen-

tadas nesse exemplo por z e obtidas a partir de sensores. Esta relação é estabelecida pelo modelo de observação: dependendo da natureza do sistema real e da tecnologia de sensoriamento disponível, as grandezas medidas podem corresponder ao próprio estado, ou a grandezas secundárias que se relacionam linearmente com o estado. Em ambos os casos, porém, está presente um ruído de medição - atribuído à limitação da precisão de medição dos sensores - que faz com que z também não possa ser utilizado isoladamente como uma estimativa confiável do estado x .

Em suma, existem então duas estimativas ruidosas de x : \hat{x} e z . A função do filtro é essencialmente combinar essas duas informações de forma a “obter o melhor dos dois mundos”. O erro e entre a medição do estado e a estimativa produzida pelo modelo é calculado e realimentado através de um ganho dentro do próprio filtro de Kalman.

Nos próximos parágrafos, as equações matemáticas que formulam o filtro de Kalman são exibidas, ressaltando alguns aspectos importantes para a compreensão de seu funcionamento dentro do contexto deste projeto. A formulação completa é omitida aqui e pode ser consultada em (SIMON, 2006) e (SILVEIRA, 2019). Optou-se pela exibição da versão discreta do filtro, considerando que sua implementação será dada em um algoritmo implementado em *software* embarcado e aplicado a um sistema que, apesar de naturalmente contínuo, é amostrado pelas medições dos sensores.

Considera-se como sistema cujo estado busca-se estimar aquele descrito pelo seguinte conjunto de equações:

$$\begin{aligned} x_k &= F_{k-1}x_{k-1} + G_{k-1}u_{k-1} + w_{k-1} \\ z_k &= H_k x_k + v_k. \end{aligned} \quad (2)$$

A primeira equação descreve a dinâmica temporal do estado do sistema, onde F é uma matriz $n \times n$ e G é uma matriz $n \times m$ que estabelece a relação entre o estado e a entrada u e w é o ruído de processo.

A conexão entre as variáveis medidas e o estado do sistema é realizada através da matriz $H_{k \times n}$, que corresponderá à matriz identidade ($I_{k \times n}$) caso o vetor de medição corresponda ao próprio estado. v_k representa o ruído associado à medição.

Os ruídos de processo/modelagem e medição, w e v , são modelados como processos gaussianos com média igual a zero, não correlacionados entre si, e cujas matrizes de covariância Q e R são conhecidas - tipicamente definidas e sintonizadas por quem está projetando o filtro.

$$\begin{aligned} w_k &\sim (0, Q_k) \\ v_k &\sim (0, R_k). \end{aligned} \quad (3)$$

A partir do modelo do sistema descrito na Equação (2), derivam-se equações que definem como a média (ou valor esperado) do estado e a covariância do estado

evoluem com o tempo, que formam o cerne do filtro de Kalman:

$$\begin{aligned}\bar{x}_k &= E(x_k) \\ &= F_{k-1}\bar{x}_{k-1} + G_{k-1}u_{k-1} \\ P_k &= E[(x_k - \bar{x}_k)(x_k - \bar{x}_k)^T] = F_{k-1}P_{k-1}F_{k-1}^T + Q_{k-1}\end{aligned}\quad (4)$$

Essas equações são apropriadas para o cálculo de uma estimativa do estado x porque 1) o valor esperado \bar{x} do estado x será definido como a própria estimativa \hat{x} (o que faz sentido intuitivamente, já que x é uma variável aleatória e há interesse em estimar a sua média) e 2) a covariância P do estado x permite monitorar o quão longe do valor real a estimativa do filtro está (informação que será utilizada para realimentar o filtro).

Como será visto nos próximos parágrafos, o filtro de Kalman consiste em um algoritmo que, a cada iteração, calcula duas estimativas diferentes e sequenciais do estado sendo observado: a primeira, conhecida como **predição** ou estimativa ***a priori***, é realizada antes que as medições são realizadas, ou seja, somente com a informação do estado e das entradas no passo anterior; a segunda, denominada **atualização** ou estimativa ***a posteriori***, corresponde a uma correção da estimativa *a priori* com a informação adicional provindo das medições. Daqui em diante, o símbolo sobrescrito “-” será utilizada para denotar as variáveis obtidas no passo de predição, enquanto que o símbolo “+” será empregado nas equações do passo de atualização.

- **Predição:**

$$\begin{aligned}\hat{x}_k^- &= F_{k-1}\hat{x}_{k-1}^+ + G_{k-1}u_{k-1} \\ P_k^- &= F_{k-1}P_{k-1}^+F_{k-1}^T + Q_{k-1}\end{aligned}\quad (5)$$

- **Atualização:**

$$\begin{aligned}K_k &= P_k^-H_k^T(HP_k^-H^T + R)^{-1} \\ \hat{x}_k^+ &= \hat{x}_k^- + K_k(z_k - H_k\hat{x}_k^-) \\ P_k^+ &= (I - K_kH_k)P_k^-\end{aligned}\quad (6)$$

A Equação (6) mostra que a implementação do filtro de Kalman possui uma forma nativa de calcular o ganho de realimentação baseado nas matrizes de covariância do ruído de processo e do ruído de medição definidas pelo usuário. Assim, é a escolha dessas matrizes que dá liberdade no projeto da resposta do filtro de estimação conforme o esperado.

Em relação aos ruídos de medição e processo/modelagem, algumas considerações são aqui importantes. Já se foi provado na literatura (SIMON, 2006) que, se w e v , ambos caracterizados como processos estocásticos, podem ser modelados como uma

distribuição de probabilidade *gaussiana* de média igual a zero e não correlacionados entre si, então o filtro de Kalman é o melhor filtro para o problema de estimação do estado x .

3.5.1 Filtro de Kalman Estendido

Nota-se nas equações da Seção 3.5 que, para que o filtro de Kalman possa ser utilizado como estratégia para estimação do estado, o sistema deve ser linear. Acontece que na maioria dos casos isto não é verdade: processos reais frequentemente apresentam dinâmicas não-lineares, a exemplificar pelo compreendido dentro deste trabalho, como pode ser visto no Capítulo 5. Em termos matemáticos, considera-se agora que o sistema real pode ser descrito pelo conjunto de equações

$$\begin{aligned}x_k &= f(x_{k-1}, u_{k-1}) + w_{k-1} \\z_k &= h(x_k) + v_k,\end{aligned}\tag{7}$$

onde f e h são funções não-lineares.

Portanto uma nova abordagem para a implementação do filtro deve ser adotada, permitindo que o mesmo algoritmo seja aplicado a um sistema cujas equações diferenciais não são lineares. Tipicamente, em outros problemas relacionados à teoria de controle, o modelo do processo é inicialmente linearizado nas proximidades de um ponto de operação de interesse, normalmente através do Teorema de Taylor.

Este mesmo caminho é adotado aqui para viabilizar o filtro de Kalman para sistemas não-lineares: a cada iteração do algoritmo do filtro o modelo é linearizado no ponto de operação correspondente ao último estado estimado. Esta abordagem é conhecida como Filtro de Kalman Estendido na literatura, e pode ser resumida nas seguintes equações:

- **Predição:**

$$\begin{aligned}F_{k-1} &= \left. \frac{\partial f_{k-1}}{\partial x} \right|_{\hat{x}_{k-1}^+} \\ \hat{x}_k^- &= f_{k-1}(\hat{x}_{k-1}^+, u_{k-1}) \\ P_k^- &= F_{k-1} P_{k-1}^+ F_{k-1}^T + Q_{k-1}\end{aligned}\tag{8}$$

- **Atualização:**

$$\begin{aligned} H_k &= \left. \frac{\partial h_k}{\partial x} \right|_{\hat{x}_k^-} \\ K_k &= P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1} \\ \hat{x}_k^+ &= \hat{x}_k^- + K_k (z_k - h_k(\hat{x}_k^-)) \\ P_k^+ &= (I - K_k H_k) P_k^- \end{aligned} \tag{9}$$

4 DEFINIÇÃO DA ARQUITETURA EMBARCADA

Como indicado no Capítulo 1, um dos objetivos deste trabalho é especificar uma arquitetura embarcada que possa ser utilizada para atingir os requisitos levantados para o módulo de localização do *Smart Badge* no Capítulo 2. Expondo de modo mais prático, busca-se responder quais tecnologias serão usadas no sensoriamento da posição.

A partir do detalhamento sobre o funcionamento do sistema GNSS dado no Capítulo 3, sabe-se que sua utilização isolada não é suficiente para satisfazer os requisitos de projeto, por algumas razões. A primeira delas é que os módulos receptores GNSS apresentam um consumo energético muito expressivo - no que se refere a dispositivos de baixa potência -, consequência de toda a circuitaria necessária para o recebimento e processamentos das ondas transmitidas pelos satélites em órbita.

A segunda razão que impede uma abordagem puramente baseada em GNSS é sua disponibilidade, que pode ser seriamente comprometida pela natureza do ambiente em que o módulo está localizado e pelas condições atmosféricas, como já foi visto anteriormente. Sem o número mínimo de satélites necessário para o cálculo da posição (três para uma solução bidimensional e quatro para tridimensional), o módulo GNSS perde sua utilidade e a funcionalidade do dispositivo seria comprometida por um período que pode variar de minutos até horas.

Observando o exposto no Capítulo 3 a respeito do princípio de funcionamento e das características individuais do sistema GNSS e dos sensores inerciais (acelerômetros e giroscópios), pode-se concluir que ambos possuem aspectos complementares. Esta ideia é sumarizada no Quadro 1.

É possível perceber que as vantagens de um sistema são as desvantagens do outro, o que leva à implicação lógica de que as duas alternativas podem ser combinadas para se obter um resultado melhor do que seria possível com ambas funcionando isoladamente. De fato, a complementariedade entre estes se manifesta tanto por apresentarem erros com dinâmicas diferentes quanto por medirem grandezas distintas (SCHMIDT *et al.*, 2010) - posição, velocidade e azimute pelo módulo GNSS, aceleração linear e velocidade angular pela IMU.

Levando em conta as limitações intrínsecas da tecnologia GNSS, as características complementares dos sistemas inerciais e os requisitos específicos deste projeto, decidiu-se por uma abordagem de integração entre as duas tecnologias. De forma superficial, os dados de ambos se tornarão entradas de um algoritmo de fusão de sensores que terá a função de extrair a melhor estimativa de ambos pesando suas peculiaridades. Dessa forma, os sensores inerciais podem ser usados para interpolar posições reportadas pelo módulo GNSS, ou, em outra perspectiva, as posições absolutas do GNSS podem ser usadas periodicamente para atualizar a estimativa relativa de

Quadro 1 – Comparação entre as características do sistema GNSS e dos sensores inerciais quanto à sua aplicação para localização.

	Vantagens	Desvantagens
GNSS	<ul style="list-style-type: none">• Fornece posição absoluta• Erros são limitados	<ul style="list-style-type: none">• Alto consumo energético• Depende de infraestrutura externa que pode apresentar indisponibilidade temporária ou interferência• Baixa taxa de atualização
IMU	<ul style="list-style-type: none">• Não depende de infraestrutura externa (é auto-contido)• Baixo consumo energético• Alta taxa de atualização	<ul style="list-style-type: none">• Fornece somente posição relativa• Erros são ilimitados e crescem com o tempo

Fonte – Baseado em (SCHMIDT *et al.*, 2010).

posição obtida a partir do processamento dos sensores inerciais. De fato, a integração será mais acoplada do que isso, como será visto no Capítulo 6.

5 MODELAGEM MATEMÁTICA

A estimação das variáveis de navegação - objetivo final da solução desenvolvida neste projeto - depende do estabelecimento de um modelo matemático que defina-as, a cada passo, com base no seu último valor e também eventualmente em algumas entradas, que neste caso podem ser consideradas como as leituras dos sensores inerciais. A função destes modelos é então converter dados crus do acelerômetro e giroscópio em uma estimativa de posição e orientação de um pedestre.

De forma geral, como reportado na literatura (ANGRISANO *et al.*, 2010; KUANG *et al.*, 2018; GABAGLIO, 2003), existem duas principais abordagens para construir modelos de navegação deste tipo: mecanização clássica e PDR (*Pedestrian Dead Reckoning*). Ambas foram inicialmente consideradas neste trabalho e serão apresentadas, respectivamente nas Seções 5.2 e 5.3. Além disso, uma breve definição dos sistemas de coordenadas de referência adotados é feita na Seção 5.1.

5.1 SISTEMAS DE COORDENADAS

As variáveis de navegação modeladas pelas equações apresentadas ao longo deste capítulo - posição, velocidade e atitude, mais especificamente - são por natureza sempre expressas em relação a um sistema de coordenadas de referência. Na sequência são definidos os sistemas utilizados nos modelos matemáticos empregados neste trabalho (GODHA, 2006; SHIN, 2005). As transformações entre um sistema e o outro já estão incluídas nas equações do modelo matemático e por isso não são repetidas nesta seção. Os índices sobrescritos na notação dos eixos nas seções abaixo são utilizados também em várias equações ao longo deste capítulo e servem para identificar a qual sistema de coordenadas uma determinada variável está referenciada. Ilustrações destes sistemas de coordenadas podem ser encontrados nas referências citadas e não são colocados aqui por questão de brevidade.

5.1.1 Sistemas de Coordenadas Geodésico

Este sistema tem seus eixos fixos ao elipsoide terrestre - *i.e.* os eixos acompanham a rotação da Terra - e é a ele que se referem as coordenadas geodésicas de posição (latitude, longitude e altitude). Sua definição é dada por:

- **Origem:** centro de massa da Terra;
- **Eixo x^e :** aponta na direção do meridiano de Greenwich;
- **Eixo y^e :** ortogonal aos eixos x^e e z^e completando um sistema dextrogiro;
- **Eixo z^e :** paralelo ao eixo de rotação médio da Terra.

A latitude representa a componente norte/sul de um ponto na superfície terrestre, sendo matematicamente expressa como o ângulo entre o vetor normal à superfície do elipsoide terrestre passando pelo determinado ponto e o plano equatorial. Analogamente, a longitude define-se pelo ângulo entre o mesmo vetor e o meridiano de Greenwich, quantificando a componente leste/oeste da posição. Ambos os valores são tipicamente expressos em graus.

5.1.2 Sistemas de Coordenadas Local

Também denominado por sistema de coordenadas de navegação ou “NED” (*North-East-Down*) ao longo deste documento, representa uma referência local cuja origem acompanha o corpo que está se movimentando (que neste caso é o pedestre) e cujos eixos têm sua definição alterada conforme a posição, como pode ser visto abaixo:

- **Origem:** centrado no objeto/corpo que está se movimentando (*i.e.* o pedestre), com o ponto exato coincidindo com a origem do sistema de coordenadas da IMU;
- **Eixo x^l :** aponta para a direção do norte geográfico (também conhecido como norte verdadeiro);
- **Eixo y^l :** completa o sistema dextrogiro com os eixos x^l e z^l , apontando na direção do leste geográfico;
- **Eixo z^l :** normal à superfície do elipsoide terrestre, direcionado para baixo.

As variáveis N e E da Equação (18) são expressas em relação à referência local (NED) cuja origem está localizada na posição inicial do pedestre.

5.1.3 Sistemas de Coordenadas do Corpo

Esse sistema representa tanto a referência de eixos do pedestre quanto a dos sensores inerciais (IMU), já que neste trabalho foi considerado que estes dois elementos estão alinhados (vide Seção 5.3.3).

- **Origem:** origem do sistema de coordenadas da IMU e do pedestre, que coincidem;
- **Eixo x^b :** paralelo à direção da caminhada. É referenciado nesse documento também como eixo frontal;
- **Eixo y^b :** novamente, completa o sistema dextrogiro juntamente com os eixos x^b e z^b , também chamado neste documento de eixo lateral;

- **Eixo z^b** : aponta para baixo na direção ortogonal ao plano normal da superfície do elipsoide terrestre.

O ângulo de azimute derivado na Seção 5.3.3, ψ , é definido como a rotação entre o eixo x^b e o eixo x^l do sistema NED cuja origem está centrada, a cada iteração, no pedestre/IMU. Em outras palavras, é o ângulo entre a direção de caminhada e o norte verdadeiro.

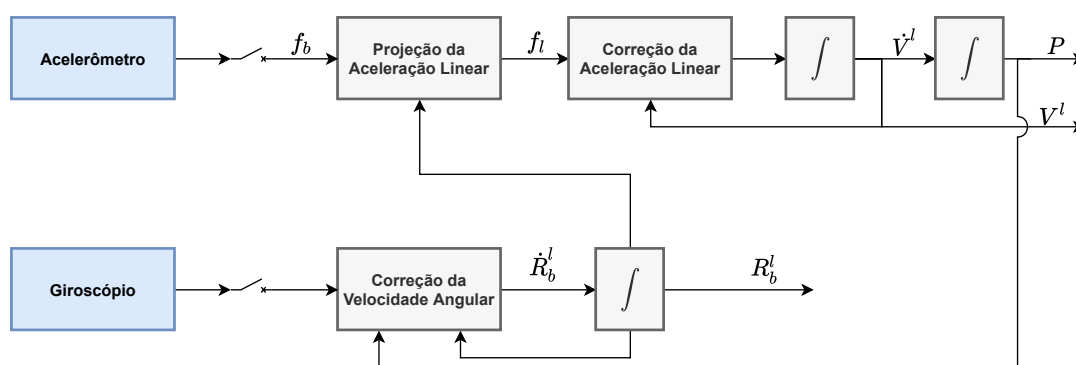
5.2 MECANIZAÇÃO CLÁSSICA

A mecanização clássica propaga a posição do usuário através do procedimento de dupla integração das acelerações lineares medidas pelos acelerômetros. Essa abordagem é a mais intuitiva em um primeiro olhar; no entanto, os resultados obtidos em outros trabalhos até aqui (PETOVELLO, 2003; GODHA, 2006; SHIN *et al.*, 2002) são tipicamente demonstrados para aplicações veiculares. Nestas aplicações, os sensores não são constantemente expostos a altas vibrações e impactos típicos da movimentação de um pedestre caminhando e usualmente são escolhidos componentes de alta qualidade - que apresentam densidade de ruído menor no sinal lido quando em comparação a sensores microeletromecânicos de baixo custo e baixo consumo. Essas duas condições contribuem expressivamente para que o modelo de mecanização clássica obtenha a performance reportada, porém não são verdadeiras para o projeto *Smart Badge*. Portanto, a validade dessa estratégia precisa ser avaliada inicialmente antes de se elaborar um filtro de estimação baseado neste modelo.

5.2.1 Visão Intuitiva

O diagrama da Figura 8 apresenta uma visão intuitiva do modelo de mecanização clássica.

Figura 8 – Visão geral do modelo de mecanização clássica.



Fonte – O autor.

Na extremidade direita da Figura 8 é possível visualizar as três variáveis de interesse do modelo de mecanização: P (posição geográfica), V^l (velocidade linear) e R_b^l (atitude ou desalinhamento entre os eixos do pedestre e os do sistema de coordenadas local, que é NED).

Começando pela atitude, as leituras do giroscópio - a saber as velocidades angulares dos três eixos do sensor - são inicialmente corrigidas de velocidades angulares externas e aparentes (causados pela redefinição dos eixos do sistema de coordenadas local com a movimentação do usuário) e então integradas para propagar a atitude do pedestre, considerando o intervalo de amostragem utilizado. A atitude calculada é, por sua vez, utilizada para projetar as acelerações lineares lidas pelo acelerômetro do sistema de coordenadas do sensor para o local (NED). Além da projeção, estas medidas precisam também ser corrigidas, desta vez por acelerações lineares aparentes - causadas especialmente pela rotação da Terra - e pelo vetor da gravidade. Após este passo, as acelerações lineares já corrigidas podem ser então integradas pela primeira vez - para obter velocidade - e pela segunda vez - tendo como resultado a posição. Fechando o esquema, a posição é empregada para recalcular o vetor normal da gravidade e para estimar as velocidades angulares aparentes utilizadas na correção dos dados dos giroscópios (ANGRISANO *et al.*, 2010).

As equações detalhadas são apresentadas na sequência divididas em três partes - atitude, velocidade e posição - e foram baseadas em (AGGARWAL, 2010; SHIN *et al.*, 2002; PETOVELLO, 2003).

5.2.2 Equação da atitude

O primeiro passo deste modelo consiste em estimar a atitude - ou orientação espacial - que o pedestre apresenta em relação a um sistema de coordenadas de referência (que neste caso corresponde ao NED, já apresentado no Capítulo 3), que é representado pela matriz de rotação R_b^l . Sua evolução é dada de acordo com a equação

$$\dot{R}_b^l = R_b^l(\Omega_{ib}^b - \Omega_{il}^b), \quad (10)$$

onde Ω_{ib}^b é a velocidade angular medida pelo giroscópio (em sua forma matricial) e Ω_{il}^b é um termo que contempla a taxa de rotação da Terra e a velocidade angular aparente gerada pela redefinição dos eixos do sistema NED com a mudança de posição, também em forma de matriz.

5.2.3 Equação da velocidade

A velocidade expressa no sistema de coordenadas local (V^l) é calculada a partir das medidas obtidas do acelerômetro, conforme mostra a Equação (11). O acelerô-

metro mede não diretamente a aceleração resultante sobre o corpo, mas sim a força específica (f^b , expressa no sistema de coordenadas do pedestre) percebida em cada um dos eixos, o que inclui a aceleração gravitacional e outros termos que precisam ser corrigidos.

$$\dot{V}^l = R_b^l f^b - (2\Omega_{ie}^l + \Omega_{el}^l) V^l + g^l \quad (11)$$

Na Equação (11), o primeiro termo corresponde à transformação de sistema de coordenadas, onde R_b^l é a matriz de rotação entre as coordenadas do pedestre e o sistema de referência NED; o segundo incorpora a correção de acelerações aparentes causadas pela variação da posição (o que faz com que a própria definição dos eixos do sistema local seja alterada) e pela rotação da Terra; e o terceiro elimina a aceleração gravitacional g^l , já com suas coordenadas transformadas.

5.2.4 Equação da posição

Na sequência, a Equação (12) relaciona as velocidades calculadas no sistema de coordenadas local com as variáveis de posição geodésicas (latitude, longitude e altitude). As letras M e N representam, respectivamente, o raio de curvatura da Terra nas direções meridiana e vertical, e suas expressões, que dependem essencialmente da latitude, podem ser encontradas em (SHIN *et al.*, 2002).

$$\dot{P} = \begin{bmatrix} \dot{\alpha} \\ \dot{\theta} \\ \dot{h} \end{bmatrix} = \begin{bmatrix} \frac{1}{M+h} & 0 & 0 \\ 0 & \frac{1}{(N+h)\cos\alpha} & 0 \\ 0 & 0 & -1 \end{bmatrix} \begin{bmatrix} v^n \\ v^e \\ v^d \end{bmatrix} = DV^l \quad (12)$$

5.2.5 Modelo completo

Finalmente, as Equações 10, 11 e 12 podem ser condensadas em sua notação matricial resultando na Equação (13):

$$\begin{bmatrix} \dot{P} \\ \dot{V}^l \\ \dot{R}_b^l \end{bmatrix} = \begin{bmatrix} DV^l \\ R_b^l f^b - (2\Omega_{ie}^l + \Omega_{el}^l) V^l + g^l \\ R_b^l (\Omega_{ib}^b - \Omega_{il}^b) \end{bmatrix}. \quad (13)$$

As equações derivadas acima são equações contínuas, e para que possam ser implementadas em um algoritmo que obtém dados amostrados dos sensores, uma versão discreta precisa ser obtida e resolvida iterativamente em uma arquitetura computacional. O procedimento adotado para isso neste projeto, considerando que o intervalo de amostragem dos sensores é muito pequeno (0,01s para os testes executados), foi uma simples aproximação numérica conforme reportado em (SHIN *et al.*, 2002).

5.2.6 Características dos Erros

O grande fator complicador da abordagem de mecanização clássica é que junto com a aceleração linear real, são integrados também os bias (ou *offsets*) das medições realizadas pelo acelerômetro. Tipicamente, o desvio na posição se torna rapidamente elevado por causa deste aspecto (KUANG *et al.*, 2018). De forma mais detalhada, o erro inserido pelo bias, quando integrado pela primeira vez para se obter velocidade, produz um erro linear; na segunda vez, para obter posição, insere um desvio de comportamento quadrático (ANGRISANO *et al.*, 2010).

Agravando ainda mais estes resultados, sabe-se que a expressividade de ruídos e incerteza na medição dos acelerômetros é mais comum em sensores de baixo custo e tamanho reduzido (JIMENEZ *et al.*, 2009), características principais dos sensores microeletromecânicos escolhidos neste projeto considerando os requisitos e limitações do Capítulo 2. Estes sensores tipicamente são mais afetados por pequenos impactos e mais sensíveis a perturbações, podendo gerar erros que chegam à proporção de centenas de metros durante curtos períodos em que operam em malha aberta (sem atualização do GNSS, por exemplo) (AGGARWAL, 2010).

5.3 PEDESTRIAN DEAD RECKONING

O termo “*dead reckoning*” faz alusão à característica de que essa metodologia - assim como a primeira - obtém as variáveis de navegação de forma relativa, ou seja, propaga a posição adiante a partir de uma posição anterior previamente conhecida. Este conceito é mais difundido em aplicações marítimas ou veiculares - onde a velocidade angular e o ângulo de direção das rodas são medidos e, a partir do conhecimento do raio da roda é possível propagar a posição adiante - e foi adaptado também para navegação de pedestres.

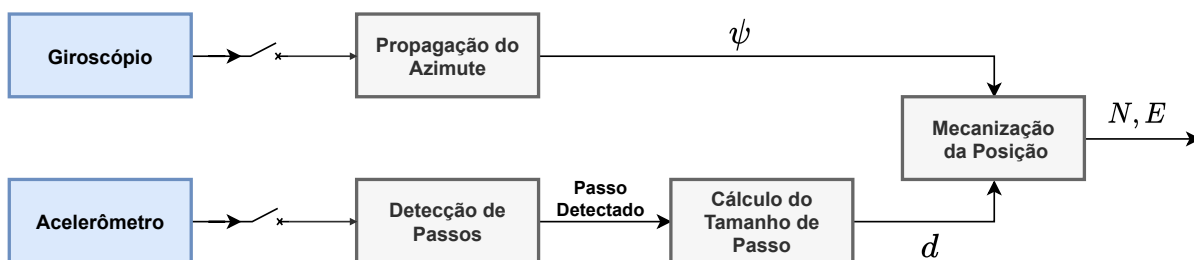
O princípio de funcionamento deste modelo consiste em combinar dados dos sensores inerciais com o conhecimento de certos padrões e aspectos da movimentação de caminhada de um ser humano obtido a partir de estudos fisiológicos conduzidos na área da biomecânica.

A estratégia PDR pode ser dividida em quatro etapas principais (KUANG *et al.*, 2018; JIMENEZ *et al.*, 2009), que são representadas no diagrama da Figura 9 e explicados com maior profundidade nas próximas seções.

5.3.1 Detecção de Passos

Diferentes algoritmos para detectar passos de um pedestre já foram discutidos (KIM *et al.*, 2004), sendo que a maioria deles utiliza análises de variância do sinal dos sensores inerciais em uma janela local de avaliação, variando majoritariamente

Figura 9 – Etapas do algoritmo PDR.

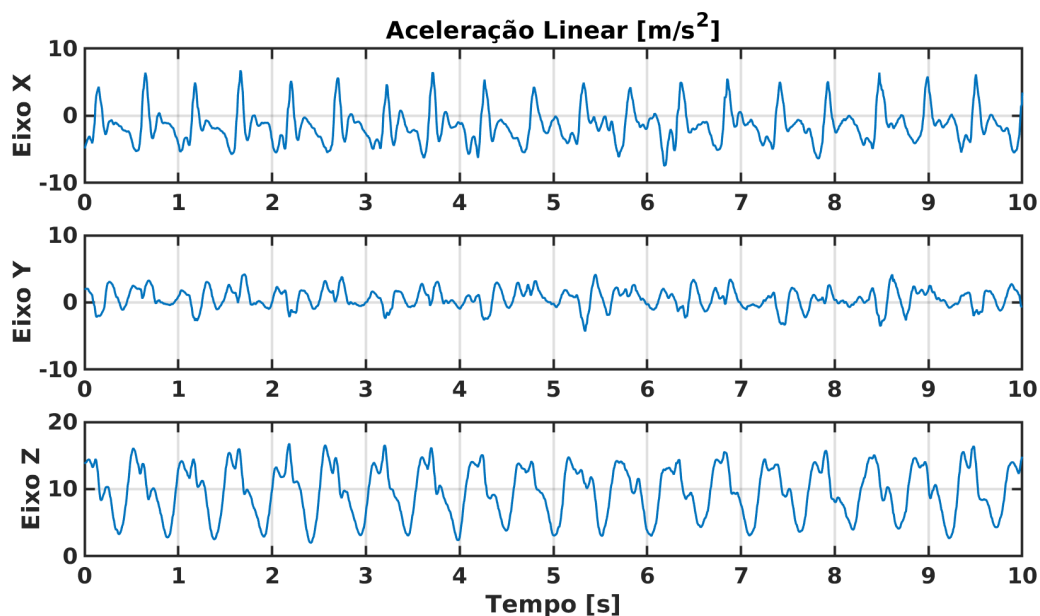


Fonte – O autor.

na escolha do sensor e do(s) eixo(s) considerados e nos parâmetros que indicam a ocorrência de um passo.

O sinal dos acelerômetros já foi reportado como mais robusto para detecção de passos (JIMENEZ *et al.*, 2009) e sua capacidade de evidenciar o padrão cíclico da movimentação humana é evidenciado pela Figura 10, onde os sinais dos três eixos são exibidos para um teste curto de caminhada com uma IMU sendo carregada em um protótipo na altura do tórax.

Figura 10 – Acelerações lineares lidas nos três eixos do acelerômetro durante um teste de caminhada com duração de 10 segundos.




Fonte – O autor.

O sinal de aceleração do eixo z do sensor correspondente ao intervalo de tempo de um passo é destacado na Figura 11 para uma análise mais detalhada. Nesta se

verificam dois picos locais consecutivos, que podem ser respectivamente interpretados como o momento de impacto do calcanhar e depois da ponta do pé com o chão. Alguns autores já afirmaram que o segundo pico pode também ser causado por um efeito de reação ao impacto sofrido pelo acelerômetro. De qualquer maneira, o objetivo do algoritmo de detecção de passos é identificar o maior número possível de ocorrências deste padrão de sinal. Após analisar os três gráficos da Figura 10, optou-se por utilizar o eixo x do acelerômetro como entrada, no qual o padrão está mais visível e definido. O eixo z também apresenta a periodicidade dos passos com bastante clareza, mas nele não se verifica com definição um momento de baixa variância na aceleração - que corresponde ao intervalo entre dois passos consecutivos -, o que será essencial para o algoritmo.

Figura 11 – Sinal do acelerômetro durante um intervalo de 10 segundos.



Fonte – O autor.

Os principais métodos reportados e já testados para detecção de passos podem ser resumidos como:

- **Detecção de picos:** busca identificar a ocorrência repetitiva do padrão de caminhada exibido acima, monitorando a variância do sinal e aplicando limiares para detecção;
- **Passagem por zero (zero-crossing):** identifica um passo toda vez que a magnitude da aceleração troca de sinal, o que pode ser seriamente afetado por ruídos na medição, e por isso é necessário saber *a priori* se o indivíduo está se movendo ou parado;

- **Análise de Fourier:** utiliza-se a decomposição de *Fourier* para analisar o padrão do sinal no domínio da frequência. Requer alta capacidade computacional.

A abordagem escolhida neste projeto foi a primeira, que já foi afirmada na literatura como a solução mais robusta dentre as mencionadas acima (BRAJDIC *et al.*, 2013) e apresenta capacidade computacional condizente com as limitações do projeto. O algoritmo foi baseado em (JIMENEZ *et al.*, 2009):

5.3.2 Cálculo do Tamanho de Passo

Toda vez que um passo é detectado, o modelo PDR deve atualizar (propagar) a posição do usuário, o que implica no conhecimento de qual foi a distância percorrida durante o intervalo de um passo. Este valor não pode ser considerado constante, como é feito com o raio da roda de um carro nas aplicações de odômetro, por exemplo. Pessoas mudam constantemente o tamanho de seus passos, seja devido a mudanças de velocidade, obstáculos no caminho, modificações no relevo e outros fatores externos. Além disso, pessoas diferentes apresentam comprimentos de passo diferentes por possuem estaturas e características biofísicas variadas. Portanto, uma forma de estimar a distância percorrida a cada passo deve ser derivada (KIM *et al.*, 2004).

Um modelo apropriado para tal tarefa foi inicialmente proposto em (WEINBERG, 2002) e aplicado com sucesso em (JIMENEZ *et al.*, 2009; ZHUANG *et al.*, 2013; KUANG *et al.*, 2018). A intuição por trás deste modelo é a seguinte: passos maiores obrigam a pessoa a projetar seu corpo mais adiante, o que faz com que sua amplitude de movimento vertical durante a execução do passo seja maior - caso contrário não seria possível para a perna alcançar a distância planejada. O contrário vale para passos menores. Esta intensidade de movimento vertical pode ser transcrita para valores de aceleração vertical, que por sua vez podem ser medidos. Assim, estabelece-se uma relação entre uma variável medida (aceleração linear vertical) e o tamanho do passo. A equação que define essa relação é conhecida como modelo de Weinberg e é dada por

$$d = K(a_{z,max} - a_{z,min})^{\frac{1}{4}}, \quad (14)$$

onde d é o tamanho do passo (ou distância percorrida), $a_{z,max}$ e $a_{z,min}$ são respectivamente os valores locais máximo e mínimo da aceleração medida no eixo z (vertical), e K é uma constante de calibração do modelo.

A determinação de K é a parte mais complicada desta equação, já que este parâmetro busca aproximar características fisiológicas que variam de pessoa para pessoa e também temporalmente e que não podem ser calculadas nem obtidos através das medidas dos acelerômetros. Assim, um fator de correção (δK) é adicionado ao

modelo da Equação (14) para contemplar erros na determinação desta constante, de acordo com a Equação (15).

$$d = (K - \delta K)(a_{z,max} - a_{z,min})^{\frac{1}{4}} \quad (15)$$

Esta equação também é calculada considerando uma janela de amostras, e o tamanho utilizado é o mesmo da detecção de passos, N .

5.3.3 Propagação do Azimute

Diferentemente de outras aplicações de navegação, aqui não é estritamente necessário obter a informação completa de atitude (ângulos *roll*, *pitch* e *yaw* ou azimute), como foi visto na Seção 5.2. A justificativa para isto é que como o que está sendo monitorado é a posição geográfica e o deslocamento se dá no plano da superfície terrestre, o eixo vertical do sistema de coordenadas do pedestre se mantém sempre aproximadamente alinhado com a direção normal da superfície (e portanto com o eixo vertical do frame NED). Em uma perspectiva mais prática, a postura natural de uma pessoa durante o ato de caminhar faz com que a rotação nos eixos frontal e lateral permaneçam muito próximos a zero (vide Seção 5.1).

Sendo assim, é suficiente para propagar a posição geográfica conhecer a direção na qual o pedestre está se movimentando sob a superfície terrestre, que é conhecida em aplicações de navegação como **azimute**. Formalmente falando, o azimute é o ângulo entre a direção de caminhada (ou direção do eixo frontal do sistema de coordenadas do pedestre) e o norte geográfico.

A partir de um valor inicial conhecido de azimute, os incrementos deste ângulo podem ser medidos através das leituras de velocidade angular no eixo vertical (eixo z) do giroscópio contido dentro da IMU, o que é expresso na equação

$$\psi_{k+1} = \psi_k + \omega_{z,k} \Delta t, \quad (16)$$

sendo que ψ é o ângulo de azimute, $\omega_{z,k}$ é a velocidade angular no eixo z lida pelo giroscópio e Δt é o intervalo de tempo entre amostras subsequentes da IMU. Como já visto no Capítulo 3, giroscópios microeletromecânicos tipicamente apresentam bias significativos em suas medições, e para que a estimação do azimute tenha uma boa precisão no filtro projetado, faz-se necessário considerá-lo no modelo:

$$\psi_{k+1} = \psi_k + (\omega_{z,k} - b_{z,k}) \Delta t, \quad (17)$$

onde $b_{z,k}$ é o *bias* de velocidade angular no eixo z .

Destaca-se aqui que a desconsideração dos ângulos de *roll* e *pitch* neste modelo, introduzida no início desta seção, somente é válida se 1) houver algum eixo do

sensor alinhado com o eixo vertical do sistema de coordenadas do pedestre e 2) o alinhamento relativo entre o sensor e o corpo do pedestre for aproximadamente mantido durante a movimentação. Caso alguma dessas condições não for satisfeita, será necessário monitorar os ângulos de *roll* e *pitch* e utilizá-los para projetar as velocidades angulares e acelerações lineares lidas no sistema de coordenadas do corpo para o sistema de coordenadas no pedestre.

5.3.4 Mecanização da Posição

Tendo a distância percorrida (d) e a direção do movimento (ψ) devidamente calculados, o último passo restante no algoritmo PDR é a projeção da posição adiante:

$$\begin{aligned} N_{k+1} &= N_k + d \cos \psi_k \\ E_{k+1} &= E_k + d \sin \psi_k. \end{aligned} \tag{18}$$

As variáveis N e E representam, respectivamente, a posição do pedestre nas direções norte e leste, considerando o sistema de referência NED com origem na posição inicial. A posição geográfica global pode ser obtida a partir destas duas variáveis através de uma simples transformação de coordenadas (vide Capítulo 7).

5.3.5 Características dos Erros

Em relação à distância percorrida, os erros podem ser originados tanto na etapa de detecção de passos (passos inexistentes detectados ou passos perdidos) quanto na Equação (15). Como será visto mais adiante no Capítulo 7, a detecção de passos apresenta alta robustez e ótimo desempenho. Os desvios da posição se concentram em torno do modelo de Weinberg, que mesmo utilizando a aceleração vertical a cada momento não é capaz de calcular com exatidão a distância percorrida.

Quanto ao azimute, é praticamente consenso que este permanece sendo a maior causa dos erros na estimativa de posição (KUANG *et al.*, 2018; LAN *et al.*, 2015). A razão disto se deve principalmente à baixa acurácia dos giroscópios microeletromecânicos, que apresentam alta densidade de ruído e bias significativos. Portanto, especial atenção deve ser dada à esta parte do algoritmo.

5.4 CONSIDERAÇÕES FINAIS

Modelos que integram inteligência artificial já foram propostos amplamente na literatura, tanto para a abordagem de mecanização clássica (AGGARWAL, 2010; EL-SHEIMY *et al.*, 2006; BEAUREGARD *et al.*, 2006) quanto para PDR (BEAUREGARD *et al.*, 2006; FELIZ ALONSO *et al.*, 2009). Um exemplo comum é utilizar redes neurais para estimar o tamanho de passo adaptativamente para cada pessoa: após algum

tempo de utilização e eventualmente alguns testes que o usuário precisaria executar, o modelo obteria uma boa estimativa das características da caminhada daquela pessoa específica, como é visto em (BEAUREGARD *et al.*, 2006). Apesar de promissores do ponto de vista de robustez da solução - os modelos seriam mais tolerantes a características fisiológicas que diferem entre pessoas e podem afetar o modelo genérico de detecção de passos e cálculo da distância percorrida apresentado aqui neste relatório -, o emprego de tal tecnologia implica em alguns requisitos que estão distantes do cenário de operação do *Smart Badge*. Destaca-se aqui que o processamento necessário para treinar os modelos baseados em inteligência artificial (como redes neurais, por exemplo) é muito maior que para executar o filtro de Kalman iterativamente, e necessitaria de um processador embarcado dedicado - o que significa, em última instância, maior custo de *hardware* e maior potência dissipada, recursos extremamente caros para um dispositivo portátil como este. Considerando isto, esta linha de pesquisa não foi aprofundada neste trabalho.

6 PROJETO DO FILTRO

No Capítulo 5, dois modelos matemáticos para estimar a posição geográfica de um pedestre a partir de uma posição inicial e das medidas dos sensores inerciais foram estabelecidos, e neste capítulo estes modelos são combinados com observações das variáveis de navegação obtidas a partir de um módulo GNSS em um filtro de Kalman estendido. O objetivo é propor um algoritmo que combine as duas informações e consiga através disso obter uma estimativa do estado de navegação com uma confiabilidade maior do que aquela que seria possível com os modelos matemáticos isoladamente. Ao longo de todo este Capítulo, algumas equações e modelos foram omitidos por questões de confidencialidade do trabalho desenvolvido junto à empresa parceira.

O passo inicial no projeto do filtro de Kalman é a definição do vetor de estado. A escolha destas variáveis depende fortemente dos objetivos de quem desenha o filtro e também dos modelos matemáticos formulados. Para este projeto, o vetor de estado foi baseado em parte no trabalho de (MEZENTSEV, 2005) e (GABAGLIO, 2003):

$$x = \begin{bmatrix} N & E & \psi & b_z & \delta K \end{bmatrix}^T. \quad (19)$$

As três primeiras variáveis - N , E e ψ - correspondem, respectivamente, à posição na direção norte, posição na direção leste (lembra-se que o sistema de coordenadas de referência é o NED) e azimute. A inclusão destas três é um tanto quanto óbvia, considerando que estão diretamente relacionadas à saída de interesse da aplicação, que é a posição horizontal - a altitude não é considerada porque tem uma variação temporal muito pequena e pode ser obtida diretamente do pacote GNSS quando necessária.

Além destas, inclui-se também as variáveis b_z - bias ou *offset* de velocidade angular do giroscópio no eixo vertical - e δK - um erro de aproximação da constante do modelo de passo de Weinberg, introduzido no Capítulo 5.

Com o fundamento estabelecido, montam-se dois modelos: o de predição e o de observação. O primeiro será utilizado para prever as variáveis de navegação (estimativa *a priori*) na próxima iteração a partir dos dados coletados do acelerômetro e do giroscópio no instante corrente, ao passo em que o segundo é aplicado a partir das medidas reportadas pelo módulo GNSS quando disponíveis para atualizar o estado (estimativa *a posteriori*).

6.1 MODELO DE PREDIÇÃO

$$\begin{aligned} N_{k+1} &= N_k + d \cos \psi_k + w_{n,k} \\ E_{k+1} &= E_k + d \sin \psi_k + w_{e,k} \\ \psi_{k+1} &= \psi_k + w_z \Delta t + w_{\psi,k} \end{aligned} \quad (20)$$

As variáveis $w_{i,k}$ representam ruídos de processo e são considerados como gaussianos. b_z e δK quantificam erros do giroscópio e de aproximação do modelo de passos, sendo portanto modeladas estocasticamente. Diferentes modelos estocásticos já foram discutidos e aplicados (MEZENTSEV, 2005; GABAGLIO, 2003), dos quais o representante mais comum é o ruído gaussiano.

6.2 MODELO DE OBSERVAÇÃO

Na arquitetura da solução de localização geográfica desenvolvida neste trabalho, o sistema GNSS foi selecionado para servir como atualização periódica das variáveis de navegação, corrigindo o desvio que cresce com o tempo da estimativa obtida com a mecanização PDR.

As três variáveis observadas a partir dos sinais de satélites processados pelo módulo GNSS compõem o vetor de observação

$$z = \begin{bmatrix} N_{GNSS} & E_{GNSS} & \psi_{GNSS} \end{bmatrix}^T, \quad (21)$$

onde as duas primeiras correspondem respectivamente às coordenadas norte e leste da posição e ψ_{GNSS} é o ângulo de azimute medido. Em termos práticos, a posição é reportada pelo módulo GNSS em coordenadas geodésicas (latitude, longitude e altitude) e a conversão para o sistema de referência local (NED) é feita com o auxílio da função *geodetic2ned* da biblioteca *Mapping Toolbox* do MATLAB, adotando como origem o mesmo ponto usado na mecanização PDR - que é o ponto de inicialização do algoritmo.

O modelo de observação conecta as variáveis medidas pelo receptor GNSS com o estado, através da relação $z_k = h(x_k) + w_{z,k}$, que neste caso é dada por

$$z = \begin{bmatrix} N_{GNSS} \\ E_{GNSS} \\ \psi_{GNSS} \end{bmatrix} = \begin{bmatrix} N \\ E \\ \psi \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \quad (22)$$

e $w_{z,k}$ é o ruído de medição. A matriz jacobiana utilizada internamente pelo filtro

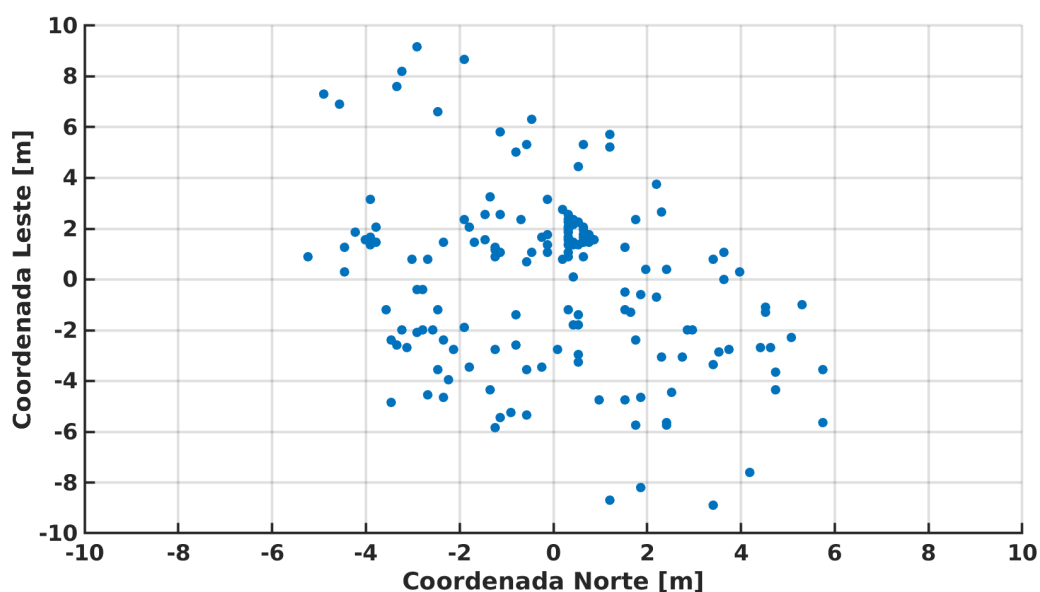
é facilmente derivada, já que o modelo de observação é linear:

$$z = Hx = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix} x. \quad (23)$$

6.3 SINTONIA DO FILTRO

Os modelos matemáticos utilizados no algoritmo de fusão de sensores contém variáveis ruidosas. Para as grandezas observadas pelo módulo GNSS, esse ruído é inerente do cálculo das variáveis de navegação, que é realizado a partir de outras medidas indiretas que também contém incertezas - como a frequência do relógio do receptor e a posição dos satélites em órbita, por exemplo. Essa característica pode ser visualizada pela oscilação da posição em um teste estático realizado com o módulo GNSS definido para este projeto, representada na Figura 12.

Figura 12 – Posição reportada pelo módulo GNSS em teste estático de aproximadamente 3 minutos com amostragem de 1 Hz.




Fonte – O autor.

Para o modelo de predição, o ruído contempla principalmente o ruído de medição dos sensores inerciais - que são utilizados como entradas no modelo matemático - e erros de modelagem, a qual naturalmente não consegue captar com exatidão o processo real ao qual se refere. Somente para exemplificar, pode-se destacar o tamanho do passo, que não é exatamente descrito pela Equação (15), que é somente uma

aproximação. A Figura 13 deixa evidente o aspecto ruidoso dos sinais dos sensores inerciais.

Figura 13 – Magnitude da aceleração linear e velocidade angular medidas pelos três eixos da IMU em teste estático de 10 segundos com amostragem de aproximadamente 100 Hz.



Fonte – O autor.

Os ruídos de processo e de medição (observação) são quantificados no arranjo do filtro de Kalman a partir das matrizes de covariância dos ruídos. De fato, definidos os modelos de predição e observação, a configuração do filtro de Kalman estendido se resume a três parâmetros (matrizes) principais: covariância dos ruídos de processo (Q), covariâncias dos ruídos de medição (R) e covariância inicial do erro de estimação (P_0) (SILVEIRA, 2019).

Como apresentado no Capítulo 3 a respeito do filtro de Kalman, os dois primeiros quantificam a confiança que o sistema tem no modelo matemático e nas medidas obtidas dos sensores, respectivamente. Estes parâmetros são usados internamente e autonomamente pelo filtro para pesar entre as estimativas *a priori* e *a posteriori* na aplicação da realimentação a partir do erro de estimação.

6.4 COVARIÂNCIA DO RUÍDO DE PROCESSO

A sintonia do ruído de processo é delicada, já que estes contemplam não só erros provindos dos sensores inerciais, mas também de aproximações da própria modelagem matemática. Tipicamente, valores iniciais são estipulados baseados na ordem de grandeza de cada uma das variáveis - a posição, por exemplo, tem uma

ordem de grandeza maior que o *bias* do giroscópio -, e a partir daí são feitas mudanças seguidas de simulação até se encontrar um ponto ótimo.

Esta abordagem foi utilizada neste trabalho - feita possível pela implementação do ambiente de simulação que é descrita no Capítulo 7. A matriz assume o formato digonal porque se assume que os ruídos não tem correlação entre si.

6.5 COVARIÂNCIA DO RUÍDO DE MEDIÇÃO

O módulo GNSS selecionado para o projeto já implementa em seu *firmware* o cálculo do desvio padrão das variáveis reportadas, a saber posição horizontal (σ_p) e azimute (σ_ψ). Estes valores são expressos como o desvio padrão correspondente a 1-sigma (aproximadamente 69% das medições tem precisão igual ou menor a este valor) e são tipicamente usados para qualificar os dados reportados pelo GNSS. No nosso caso, sua utilidade é especificamente para determinar a matriz de covariância do ruído de medição, que fica então dada por

$$R = \begin{bmatrix} \sigma_p^2 & 0 & 0 \\ 0 & \sigma_p^2 & 0 \\ 0 & 0 & \sigma_\psi^2 \end{bmatrix}. \quad (24)$$

6.6 COVARIÂNCIA INICIAL DO ERRO DE ESTIMAÇÃO

O mesmo princípio de sintonia por tentativa e erro através de simulação utilizado para sintonizar a covariância do ruído de processo também vale para a determinação da covariância inicial do erro de estimação. De forma geral, esta matriz define quão grande é a incerteza inicial para variável de estado. Esse parâmetro é essencial para que o filtro apresente convergência na estimação e tem grande contribuição para determinar a dinâmica com que isso acontece - normalmente valores altos são escolhidos para uma rápida convergência e valores menores para uma dinâmica mais suavizada e estável.

6.7 CONSIDERAÇÕES TEMPORAIS

Geralmente os passos de predição e atualização do filtro acontecem com a mesma frequência, ou seja, a cada iteração do filtro o modelo matemático é utilizado para prever o estado e logo em sequência as medições são realizadas para corrigir a estimativa predita. Esse arranjo, no entanto, parte do princípio que as medições estão disponíveis com a mesma frequência que se deseja obter uma nova estimativa do estado, o que não é verdade para este projeto. Aqui, um dos objetivos é, inclusive, maximizar o intervalo de tempo em que novas medições GNSS são utilizadas, o que

em última análise representa redução de consumo energético. Faz-se necessário, portanto, elaborar um pouco melhor a temporização do filtro de Kalman.


São definidos então três dinâmicas temporais diferentes que constituem o filtro projetado:

- **Predição:** acompanhando o período de amostragem dos sensores inerciais (IMU), determina as iterações onde o modelo de predição é calculado. Esse período propaga sempre o azimute e aplica a detecção de passos. A propagação das variáveis de posição é controlada por uma variável que indica se um passo foi ou não detectado naquela iteração. Para os testes reportados no Capítulo 7, a frequência utilizada foi de aproximadamente 100 Hz, valor típico em outros trabalhos similares - o que permite a comparação mais direta dos resultados;
- **Atualização:** é determinado pela frequência de amostragem do módulo GNSS, que foi fixado em 1 Hz na coleta dos dados e variado via *software* nas simulações executadas, buscando avaliar a robustez do filtro perante a indisponibilidade das observações;
- **Passos:** rotina que é disparada sempre que um passo é detectado, determina quando a posição será propagada adiante no modelo de predição. Tipicamente, para uma pessoa de estatura média e caminhada em ritmo normal, a frequência de passos se aproxima de 2 Hz (vide Figura 10).

Os gráficos das Figuras 14 e 15 mostram, nesta ordem, a variação da frequência de predição do modelo - cujo ruído verificado é causado pela dinâmica do tratamento das interrupções que indicam atualização dos registradores dos sensores e também por limitações da interface serial entre o protótipo e o computador - e da frequência de passos detectados - que é ditada pelo ritmo de caminhada do usuário e contém erros devido a falhas no algoritmo de detecção de passos.

Em alguns estudos há uma preocupação em sincronizar exatamente o instante de tempo em que as observações GNSS foram calculadas e em que o último passo foi detectado (MEZENTSEV, 2005; GABAGLIO, 2003), o que é feito normalmente extrapolando-se a posição PDR a partir do último passo detectado e da velocidade média calculada durante os últimos passos. O argumento para tal implementação é que se este procedimento não for realizado, então a comparação entre as medições e o modelo predito na etapa de atualização do filtro torna-se inconsistente, já que os dados se referem a momentos diferentes. No entanto, como a frequência de amostragem da IMU é alta (aproximadamente 100 Hz nos testes realizados, com perspectiva de ser significativamente aumentada para a solução implementada no *hardware* do produto) e a velocidade de movimentação de um pedestre é baixa, este procedimento pode significativamente aumentar o custo computacional trazendo benefícios pouco


Figura 14 – Frequência de amostragem dos sensores inerciais durante um intervalo de 5 segundos.



Fonte – O autor.

perceptíveis na solução final. Na prática, a diferença na comparação da posição GNSS com a obtida pela mecanização PDR em virtude do intervalo de tempo entre o último passo detectado e a aquisição de dados GNSS mais recente se localiza dentro do tamanho de um passo, o que é menor que 1 metro e é inferior à acurácia máxima do módulo GNSS (que pode chegar a 2,5 metros para o critério de 50% das medições). Considerando isso, esse procedimento de sincronização não foi implementado neste projeto.

Figura 15 – Frequência de passos detectados durante um intervalo de 30 segundos.



Fonte – O autor.

7 SIMULAÇÃO E RESULTADOS

Para avaliar a performance da estratégia de fusão de sensores para estimação de variáveis neste trabalho, propôs-se a elaboração de um ambiente de simulação.

No início do planejamento do projeto, uma abordagem puramente baseada em simulação foi considerada e avaliada, que inclui, além do algoritmo do filtro, um módulo para geração de trajetórias e modelos de sensores inerciais e do receptor GNSS que reproduzem virtualmente os sinais ruidosos a partir da trajetória gerada de acordo com parâmetros configurados pelo desenvolvedor. Ferramentas incluídas dentro do próprio MATLAB foram avaliadas para estas tarefas e não mostraram a capacidade necessária de reproduzir com fidelidade os dados dos sensores para o cenário de uma pessoa caminhando. O grande problema encontrado foi a geração de trajetórias, que foi de fato pensado para emular cenários típicos de aplicações veiculares, sem oferecer a capacidade de reproduzir os padrões típicos do caminhar de uma pessoa. Obviamente tais características poderiam ser implementadas, mas decidiu-se por concentrar esforços em desenvolver uma ferramenta para coletar os dados reais de testes com um pedestre, que foram então usados como entrada para simulação.

A metodologia de trabalho introduzida no Capítulo 1 é aprofundada aqui e representada pelo diagrama da Figura 16.

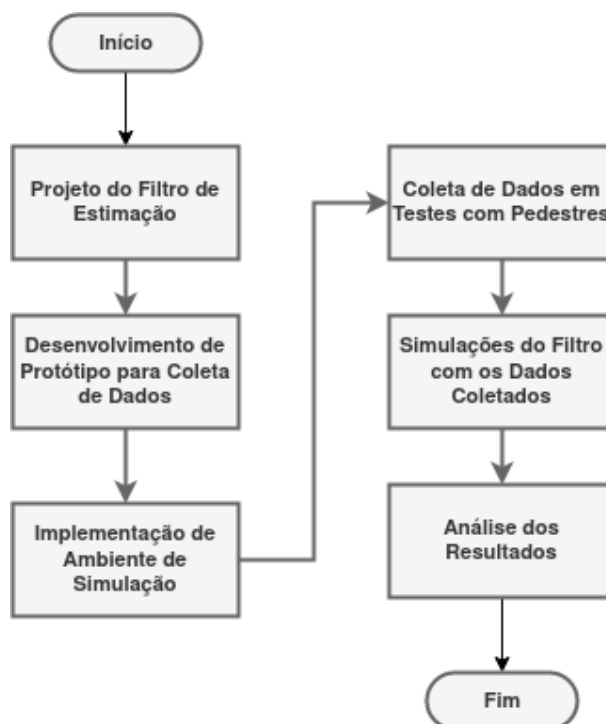
O projeto do filtro foi detalhado no Capítulo 6, e aqui são descritos a construção do protótipo experimental para coleta de dados (Seção 7.1), a implementação do *software* para simulação (Seção 7.2), os cenários selecionados para as coletas de dados (Seção 7.3) e os resultados obtidos (Seção 7.4).

7.1 PROTÓTIPO PARA COLETA DE DADOS

O protótipo desenvolvido pelo aluno teve papel fundamental na avaliação dos algoritmos de estimação projetados enquanto o projeto do *hardware* do *Smart Badge* está em andamento e ainda não há protótipos do produto disponíveis, equipando a simulação com dados sensoriais próximos daqueles que são esperados em um ambiente real de operação da solução. Os componentes envolvidos na medição e registro dos dados em tempo real, bem como suas interfaces de comunicação, são apresentados na Figura 17.

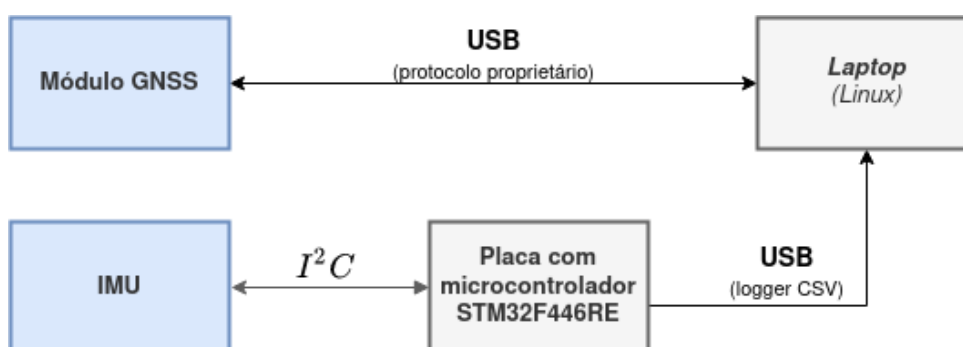
Para a comunicação com a IMU, um simples código foi implementado e embarcado em uma placa de desenvolvimento contendo o microcontrolador STM32F446RE da fabricante STMicroelectronics, que serve como ponte entre a IMU e o *laptop*. O código foi desenvolvido com o auxílio de uma API (*Application Programming Interface*) disponibilizada abertamente pela própria fabricante da IMU, e é responsável por configurar os sensores no modo e taxa de atualização desejados, fazer a leitura periódica

Figura 16 – Etapas desenvolvidas ao longo deste PFC.



Fonte – O autor.

Figura 17 – Componentes do protótipo desenvolvido para coleta de dados.



Fonte – O autor.

dos registradores contendo as medidas de aceleração e velocidade angular (uma interrupção de pino é disparada quando os registradores são atualizados) e enviar os dados em formato CSV (*Comma-Separated Values*) por uma porta de comunicação serial com o *laptop* através de um cabo USB. O protocolo selecionado para interfaceamento do microcontrolador com a IMU foi o I^2C , considerando que este exige um menor número de pinos (quando comparado à SPI, por exemplo) e apresenta taxa de dados (*data throughput*) suficiente para a quantidade de dados trocada. A frequência

de amostragem da IMU foi determinada como aproximadamente 100 Hz para os testes, por ser um valor comumente usado em outros trabalhos - permitindo uma comparação mais direta - e por impactar em um consumo energético menor quando comparado a frequências mais altas disponíveis (chegando a mais de 1 kHz para o *chip* utilizado). A tendência é que frequências mais altas reduzam o ruído de medição e tragam maior precisão à estimativa de azimute, mas neste primeiro momento resolveu-se avaliar o desempenho num caso mais conservador.

A integração com o *kit* de desenvolvimento do módulo GNSS foi mais simples e não exigiu o desenvolvimento de nenhuma interface intermediária com o computador. A frequência com que uma nova posição é calculada foi definida para 1 Hz - frequências menores são simuladas via *software* como descrito na Seção 7.2. A configuração foi salva em uma memória não-volátil presente no *kit* de integração, sendo válida para todos os testes executados sem necessidade de reaplicação. A partir disto, o módulo reporta periodicamente os dados, que foram captados através de uma comunicação serial por meio de um cabo USB conectado ao *laptop*.

Encerrando a cadeia de aquisição e registro dos dados, um código em linguagem C foi elaborado para ser executado no *laptop* em tempo real durante os testes. Essencialmente, este programa abre duas interfaces seriais - uma vinculada à placa contendo o microcontrolador STM32F446RE e outra à placa de integração do receptor GNSS -, processa os dados recebidos periodicamente em cada uma delas e registra cada amostra em uma nova linha de um arquivo de saída em formato CSV - que é utilizado posteriormente pelo *script* de simulação em MATLAB.

Os componentes foram fixados em um gabinete de plástico reaproveitado de outro produto da empresa, permitindo que o protótipo seja carregado em uma altura próxima ao tórax, buscando reproduzir o posicionamento do dispositivo em operação. O *notebook* é carregado pela pessoa executando o teste dentro de uma mochila.

Uma última consideração é feita a respeito da orientação da IMU em relação à pessoa portando o protótipo: como os eixos de medição do acelerômetro e do giroscópio não são os mesmos do sistema NED de coordenadas local (definido na Seção 5.1), um alinhamento relativo entre estas duas referências foi estabelecido (AGGARWAL, 2010). Durante a leitura dos registradores da IMU no *software* que foi embarcado no microcontrolador STM32F446RE, as medições são reorientadas de tal forma que os eixos x^s , y^s e z^s da IMU coincidam com as direções x^b , y^b e z^b do sistema de coordenadas local. Essa conversão é válida somente se for considerado que o dispositivo manterá sua orientação fixa em relação à orientação da do usuário, que é uma suposição válida conforme visto no Capítulo 6.

7.2 AMBIENTE DE SIMULAÇÃO

O *software* para simulação do filtro projetado foi desenvolvido utilizando a linguagem *MATLAB*, com suporte direto da ferramenta *Control Systems Toolbox*, que fornece um objeto que implementa um filtro de Kalman estendido, o qual foi utilizado para iterativamente executar as rotinas de predição e atualização do estado.

O fluxo de execução do *software* de simulação é apresentado no diagrama da Figura 18 e foi desenvolvido para reproduzir ao máximo possível o que será futuramente implementado em tempo real no produto final. O arquivo CSV gerado na coleta de dados é tomado como entrada e lido amostra por amostra, coordenando a execução das etapas do filtro de acordo com o módulo de origem da (IMU ou GNSS). A frequência de atualização do filtro - que tem o objetivo de ser minimizada neste trabalho para reduzir a utilização do módulo GNSS - é variada definindo-se um intervalo de atualização que é checado toda vez que uma amostra GNSS é lida, e caso ainda não tenha se completado, a leitura é então desconsiderada e o filtro não é atualizado.

Os blocos de pré-processamento de dados adequam os dados crus registrados no arquivo CSV de acordo com o esperado pelo filtro. No caso das amostras GNSS, essa etapa consiste em uma simples conversão de unidades e transformação de coordenadas de posição - do sistema geodésico (latitude e longitude) para a referência NED (norte e leste). Para o caso da IMU, além da conversão de unidades, existe também uma filtragem passa-baixa dos sinais do giroscópio para redução de componentes de alta frequência no ângulo de azimute estimado em malha aberta, implementada através de uma simples suavização exponencial (*exponential smoothing*).

Ao final de cada simulação, além dos gráficos gerados dentro do *MATLAB*, as séries de dados contendo as posições geográficas são escritas em arquivos CSV. Estes resultados são então lidos por um simples *script* escrito em linguagem *JavaScript* que exhibe os pontos geográficos em um mapa carregado numa página HTML com o suporte da biblioteca *Leaflet*.

Um ponto importante da simulação é a inicialização do filtro. Como os modelos são puramente relativos, ou seja, obtém a posição e o azimute propagados a partir de uma estimativa inicial conhecida, é necessário utilizar o GNSS para essa inicialização. Assim, a partir do momento em que a primeira posição válida for reportada pelo GNSS, a variável de azimute no vetor de estado assume o valor fornecido pelo GNSS, enquanto que a posição lida é utilizada como origem do sistema de coordenadas local - origem para qual as coordenadas *N* e *E* se referem. Para as variáveis que modelam o *bias* do giroscópio e o fator de correção da constante do modelo de passo, como estas são inicialmente desconhecidas, são inicializadas com zero. O vetor de estado

no momento inicial é então determinado como

$$x_0 = \begin{bmatrix} N \\ E \\ \psi \\ b_z \\ \delta K \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \psi_{GNSS} \\ 0 \\ 0 \end{bmatrix}. \quad (25)$$

Em suma, o ambiente desenvolvido permitiu testar a performance do(s) filtro(s) proposto(s) de forma ágil e com repetibilidade, sendo possível variar os parâmetros de sintonia buscando um resultado satisfatório entre velocidade de convergência e estabilidade da resposta.

7.3 CENÁRIOS DE TESTE

A seleção dos locais para execução dos experimentos de coleta de dados dos sensores tem um papel importante na validade da análise dos resultados obtidos perante às condições reais esperadas de operação do produto em campo. Infelizmente, devido à especificidade dos cenários reais esperados e às limitações de deslocamento, não foi possível encontrar uma localidade que os representasse com alto grau de similaridade.

Os testes foram conduzidos em áreas residenciais com baixa densidade de prédios, conforme registrado na Figura 19, especialmente considerando o fácil acesso e proximidade.

As condições atmosféricas durante as coletas variaram de céu limpo a algumas nuvens. Durante todos os experimentos, o protótipo foi carregado pelo aluno na altura do tórax conforme descrito anteriormente. Diferentes percursos foram realizados para testar diferentes aspectos dos modelos e do filtro de estimação, que são exibidos ao longo da Seção 7.4.

7.4 RESULTADOS

No Capítulo 5, duas propostas de modelos matemáticos para prever a posição geográfica de um pedestre com base na posição anterior e nos dados obtidos da IMU foram apresentados: a mecanização clássica e o PDR.

Aqui são então exibidos os resultados da mecanização clássica na Seção 7.4.1, do modelo PDR nas Seções 7.4.2 e 7.4.3 e do filtro de estimação na Seção 7.4.4.

7.4.1 Mecanização Clássica

A simulação deste modelo de predição do estado foi realizada com os dados coletados na trajetória exibida no mapa da Figura 25. A comparação entre as posições

(norte e leste) estimadas através das equações da mecanização clássica e aquelas reportadas pelo GNSS (que é tomado como referência aqui) são apresentadas na Figura 20.

7.4.2 Detecção de Passos

Para os testes do algoritmo de detecção de passos, a trajetória escolhida é uma linha reta de aproximadamente 129 metros, percorrida pelo aluno na calçada, e está representada no mapa da Figura 21, onde os pontos inicial e final são indicados.

O percurso foi repetido três vezes, onde o aluno intencionalmente variou o tamanho de passo entre patamares que são aqui definidos como **curto**, **médio** e **longo**. A intenção é a de simular variações reais no tamanho de passo típico que acontece entre pessoas e avaliar a robustez do modelo perante essas modificações.

As posições iniciais e final são determinadas com o auxílio da ferramenta de visualização e interação de mapas *Google Maps*, e a partir delas é possível definir a distância real percorrida, que foi de 129 metros para esse teste. Aqui há de fato um pequeno erro causado pela diferença entre os pontos considerados na ferramenta e os reais, no entanto esta é a melhor referência possível, haja vista que não se dispunha de um receptor GNSS de alta qualidade para calcular a posição com precisão submétrica. O número de passos reais praticados em cada uma das três repetições do percurso foi registrado pelo aluno através de um aplicativo de *smartphone*. Os dados estão sumarizados na Tabela 1.

Tabela 1 – Dados do ensaio do modelo de passos utilizados como referência.

Tamanho do passo	Número de passos	Tempo total [s]
Curto	178	113,2
Médio	157	104,3
Longo	139	86,5

Fonte – O autor.

O resultado do algoritmo de detecção de passos para os três tamanhos de passos é exibido nas Figuras 22, 23 e 24, onde um intervalo de 10 segundos é destacado para permitir a visualização. As variáveis intermediárias definidas na Seção 5.3.1 são também apresentadas nos gráficos.

O número de passos detectados em cada um dos três casos é então colocado lado a lado com o valor real na Tabela 2. Ressalta-se aqui que os três parâmetros de sintonia do modelo permaneceram o mesmo para os três testes.

O resultado acima é muito interessante e relevante porque tradicionalmente o desempenho de estratégias para detectar passos funciona melhor com os sensores

Tabela 2 – Resultados do algoritmo de detecção de passos.

Tamanho do passo	Número real de passos	Número de passos detectados
Curto	139	139
Médio	157	158
Longo	178	180

Fonte – O autor.

posicionados em regiões de maior impacto no corpo humano durante a caminhada, como nos pés (STIRLING *et al.*, 2003) ou próximo à cintura (BEAUREGARD *et al.*, 2006). Aqui foi demonstrada a eficiência deste algoritmo também para um posicionamento na região do tórax e sem que houvesse uma fixação forte do protótipo ao corpo para evitar deslocamentos.

7.4.3 Tamanho de Passo

Avalia-se agora a performance do modelo de Weinberg (vide Equação (15)) no cálculo do tamanho de passo. Para cada um dos três testes de detecção de passos realizado, o valor da constante K foi ajustado (com resolução de duas casas decimais) em simulação de tal forma que o resultado de distância percorrida ao final do percurso estivesse o mais próximo possível do valor de referência de 129 metros. Os resultados são sumarizados na Tabela 3.

Tabela 3 – Valores ideais da constante K para três tamanhos de passo diferentes simulados na coleta de dados.

Tamanho do passo	Distância calculada [m]	Constante K
Curto	130,34	0,45
Médio	129,88	0,49
Longo	129,60	0,56

Fonte – O autor.

Um valor que representa a média igualmente ponderada entre os três valores ideais para cada tamanho de passo, $K = 0.5$, foi definido, e as três simulações foram refeitas agora utilizando esta constante para avaliar o erro na distância percorrida, cujos resultados são sintetizados na Tabela 4.

Investigações ainda precisam ser conduzidas para avaliar com mais fidelidade a influência de diferenças reais nos aspectos fisiológicos, ou seja, executando testes com pessoas diferentes.

Tabela 4 – Resultados do modelo de tamanho de passo.

Tamanho do passo	Distância real [m]	Distância calculada [m]	Erro absoluto [m]	Erro relativo [%]
Curto	129	145	16	12,40
Médio	129	132	3	2,32
Longo	129	116	13	10,10

Fonte – O autor.

7.4.4 Filtro de Estimação

Finalmente, a execução do filtro de estimação é simulada a partir dos dados coletados na trajetória apresentada na Figura 25, que durou aproximadamente 500 segundos. Com esse teste, pode-se avaliar se o filtro proposto, tanto em termos de estrutura (modelo de predição, modelo de observação e vetor de estado), quanto em relação à sua sintonia, apresenta um resultado suficiente para estimar a posição geográfica de um pedestre e para cumprir os requisitos especificados.

Aqui, as medidas fornecidas pelo módulo GNSS são inicialmente utilizadas a uma frequência de 1 Hz durante um período de 120 segundos. Depois disso a taxa de atualização é alterada para 1/240 Hz (período de 240 segundos). Essa dinâmica é exibida nas imagens e gráficos a seguir de forma clara, onde são marcados os momentos em que as medidas do GNSS são utilizadas para correção da estimativa do filtro.

O gráfico da Figura 26 mostra os valores de azimute fornecidos pelo GNSS, pelo modelo de predição em malha aberta e pelo filtro de estimação, e indicam claramente que o filtro foi capaz de atingir seus objetivos, já que o desvio de azimute em comparação ao valor fornecido pelo GNSS é significativamente menor. A estimação do bias é apresentada na Figura 27.

A estimação das variáveis de posição é exibida na Figura 28, onde se verifica uma variação brusca nos valores quando a correção final é realizada.

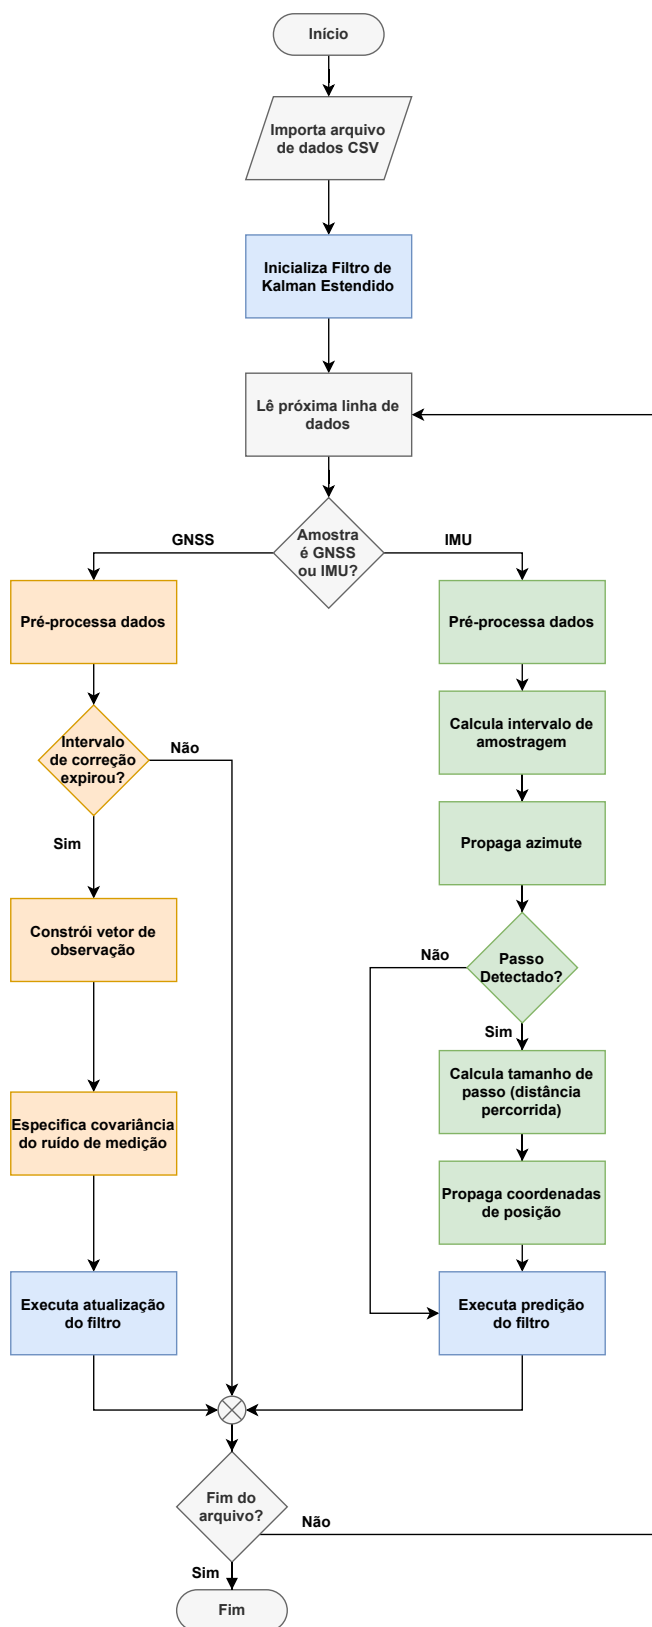
Por último, o resultado é exibido no mapa da Figura 29 - as coordenadas de posição estimadas no filtro e no modelo PDR em malha aberta são convertidas para coordenadas geodésicas com o auxílio da ferramenta *Mapping Toolbox* do MATLAB.

Verifica-se na imagem que a posição fornecida pelo módulo GNSS mostra uma trajetória muito próxima à real, validando a qualidade do módulo GNSS selecionado. Em contraste, a estimativa obtida pelo modelo PDR em malha aberta apresenta um desvio que cresce com o tempo e se manifesta especialmente no ângulo de azimute - o que se pode visualizar considerando que é possível projetar, com alguma diferença, a trajetória vermelha sobre a azul ajustando sua rotação.

A trajetória correspondente ao filtro de Kalman, em verde, mostra que a performance da estimação atingiu resultados excelentes. Durante os primeiros 120 segundos, quando o GNSS é amostrado a cada segundo, a posição resultante fica praticamente idêntica à medida GNSS, como já era de se esperar. Após esse momento, quando o GNSS passa a ser amostrado somente a cada 4 minutos, somente mais uma medida é realizada. Durante todo esse período, até o fim da trajetória, pode-se ver que o percurso estimado pelo filtro é muito próximo daquele projetado pelo GNSS e, conseqüentemente, do percurso real.

Uma atenção especial é dada à segunda curva de 90 graus realizada na caminhada, onde claramente a ação do bias do giroscópio afeta a projeção do azimute em malha aberta, ao mesmo passo em que é compensada pelo filtro de estimação.

Figura 18 – Fluxo de execução do *software* de simulação desenvolvido.




Fonte – O autor.

Figura 19 – Registros de área residencial onde foram realizadas as coletas de dados.



Fonte – O autor.

Figura 20 – Resultado da posição estimada com mecanização clássica expressa no sistema de coordenadas NED.



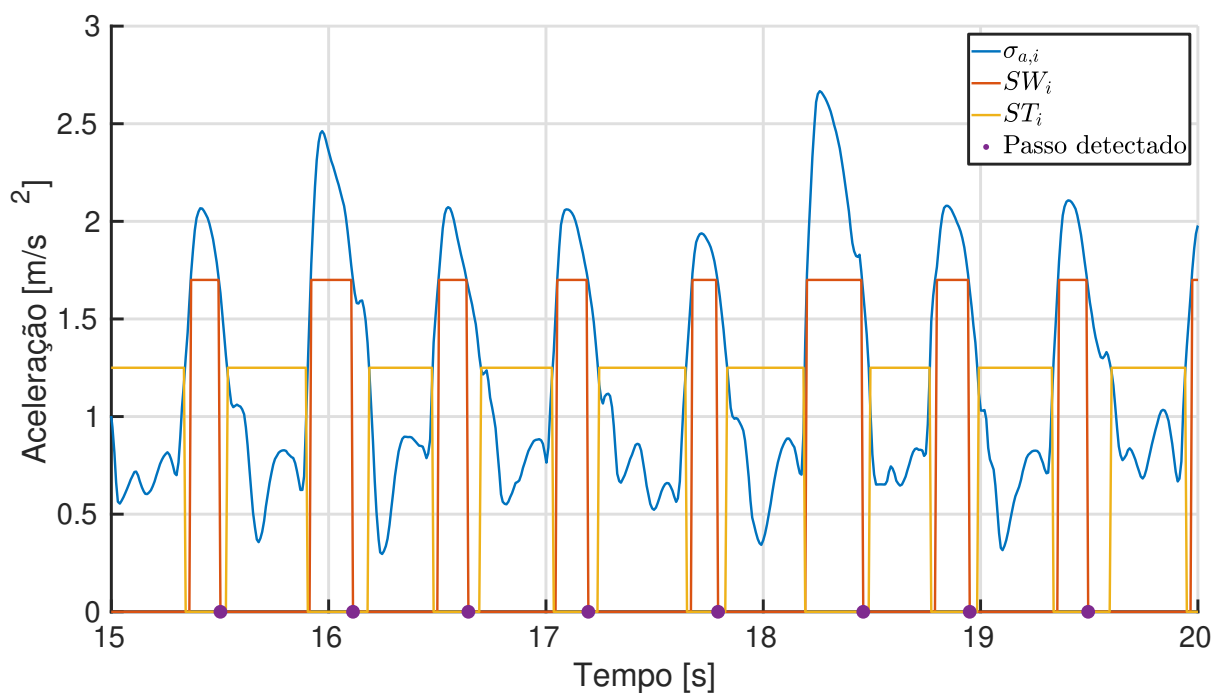
Fonte – O autor.

Figura 21 – Trajetória para testes do modelo de passo.



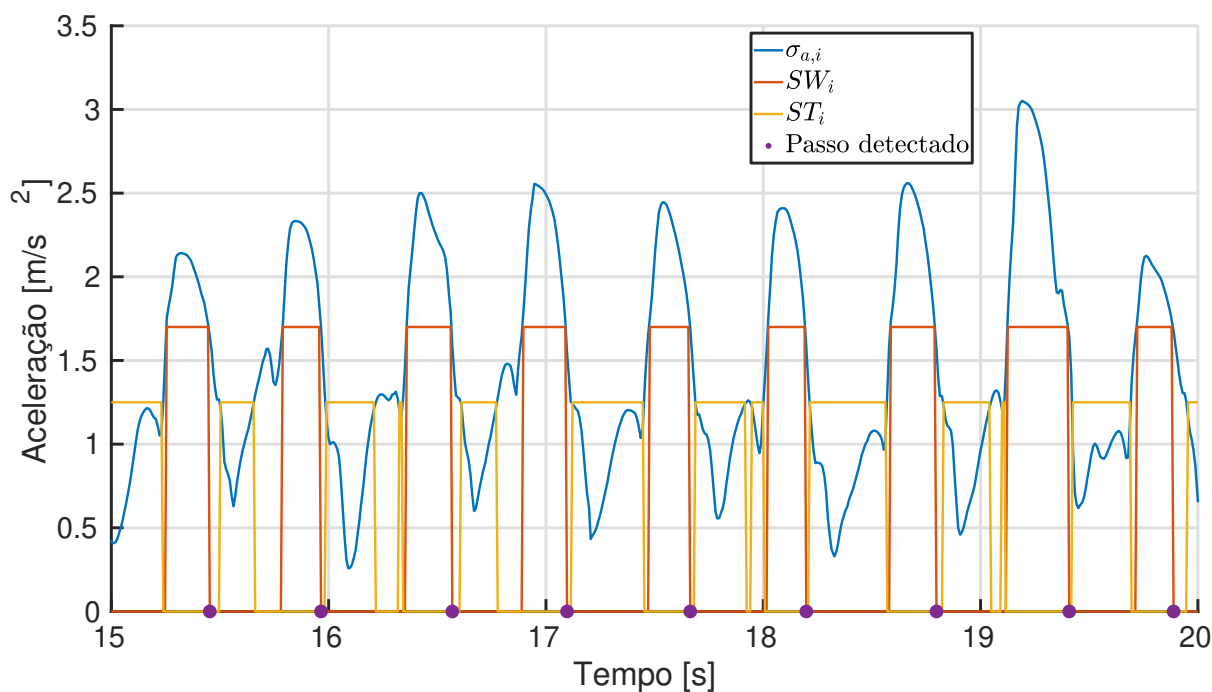
Fonte – Google Maps, com marcações do autor.

Figura 22 – Resultado do algoritmo de detecção de passos para o passo curto.



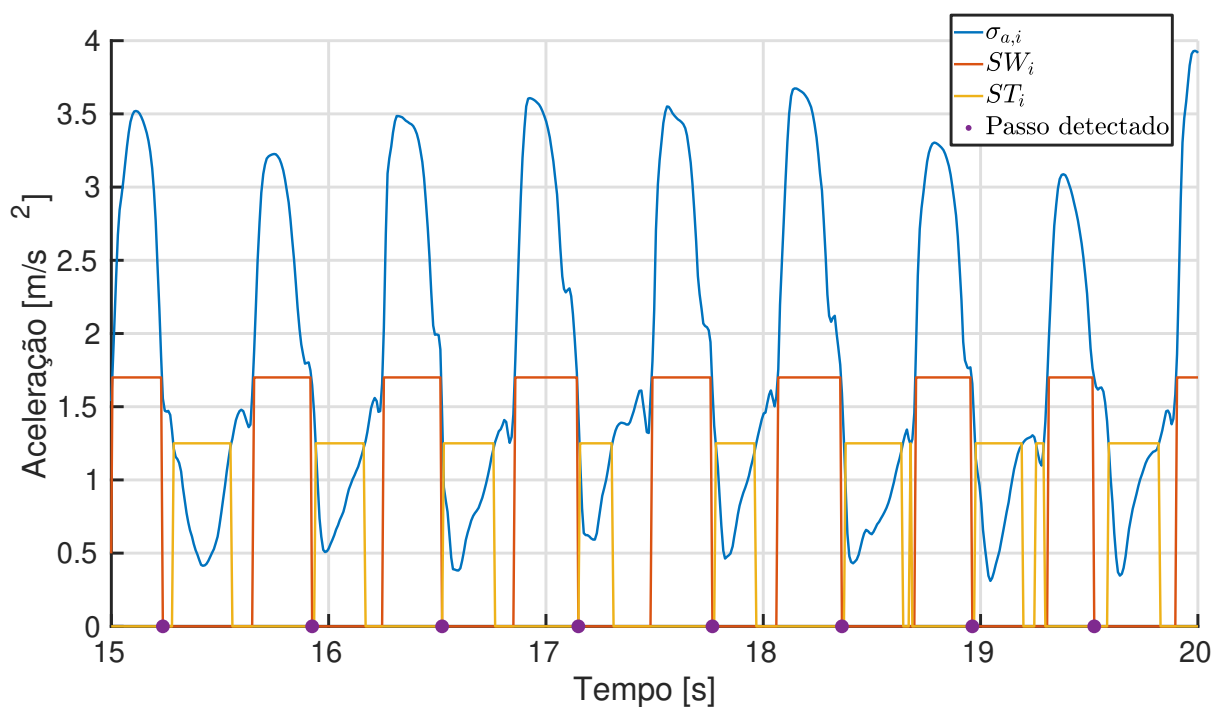
Fonte – O autor.

Figura 23 – Resultado do algoritmo de detecção de passos para o passo médio.




Fonte – O autor.

Figura 24 – Resultado do algoritmo de detecção de passos para o passo longo.



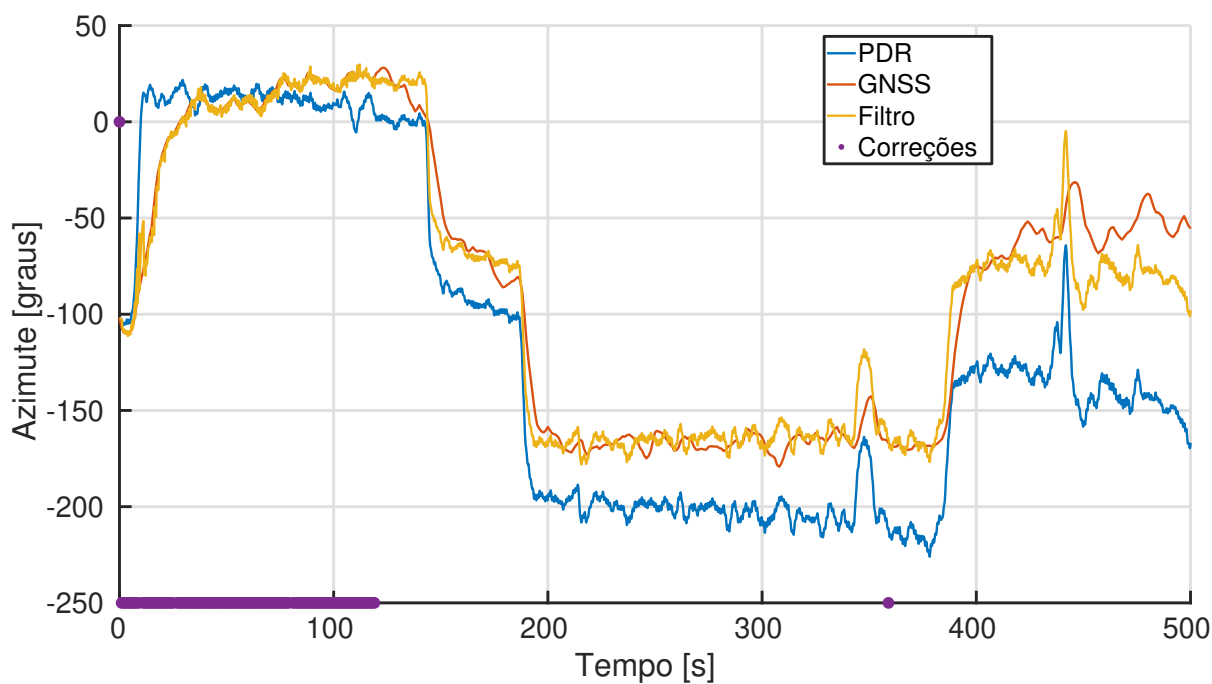
Fonte – O autor.

Figura 25 – Representação da trajetória caminhada no mapa.



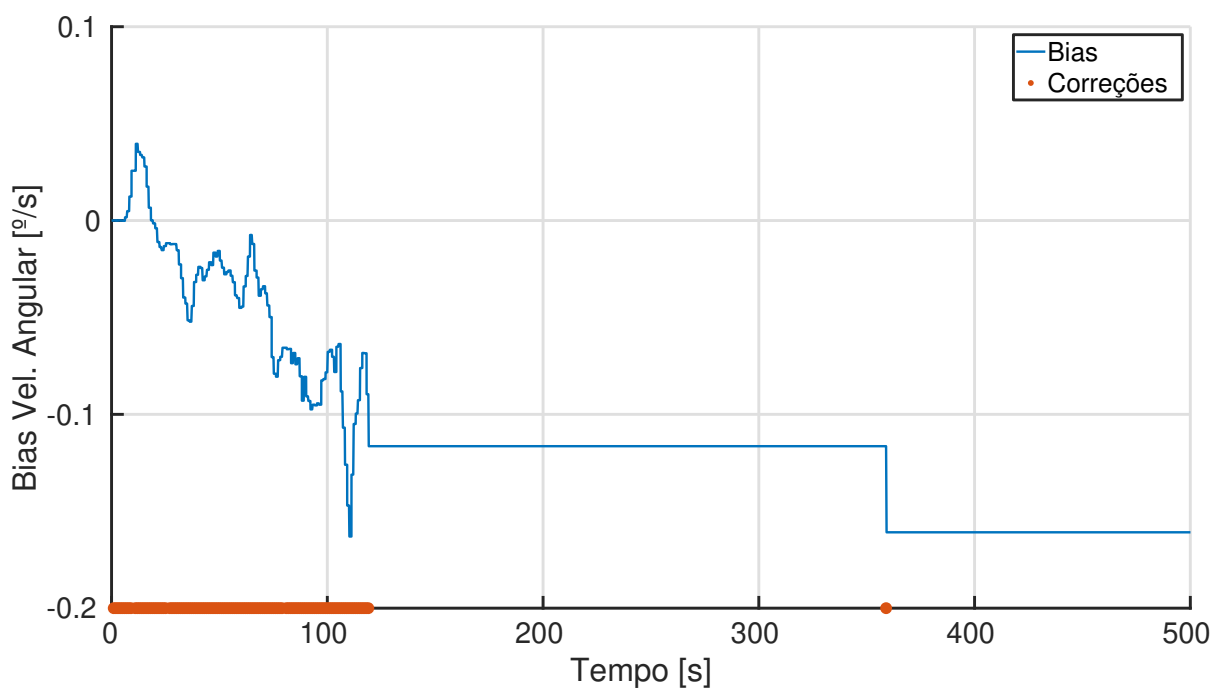
Fonte – *Google Maps*, com marcações do autor.

Figura 26 – Estimação do azimute.




Fonte – O autor.

Figura 27 – Estimação do bias de medição do eixo z (vertical) do giroscópio.



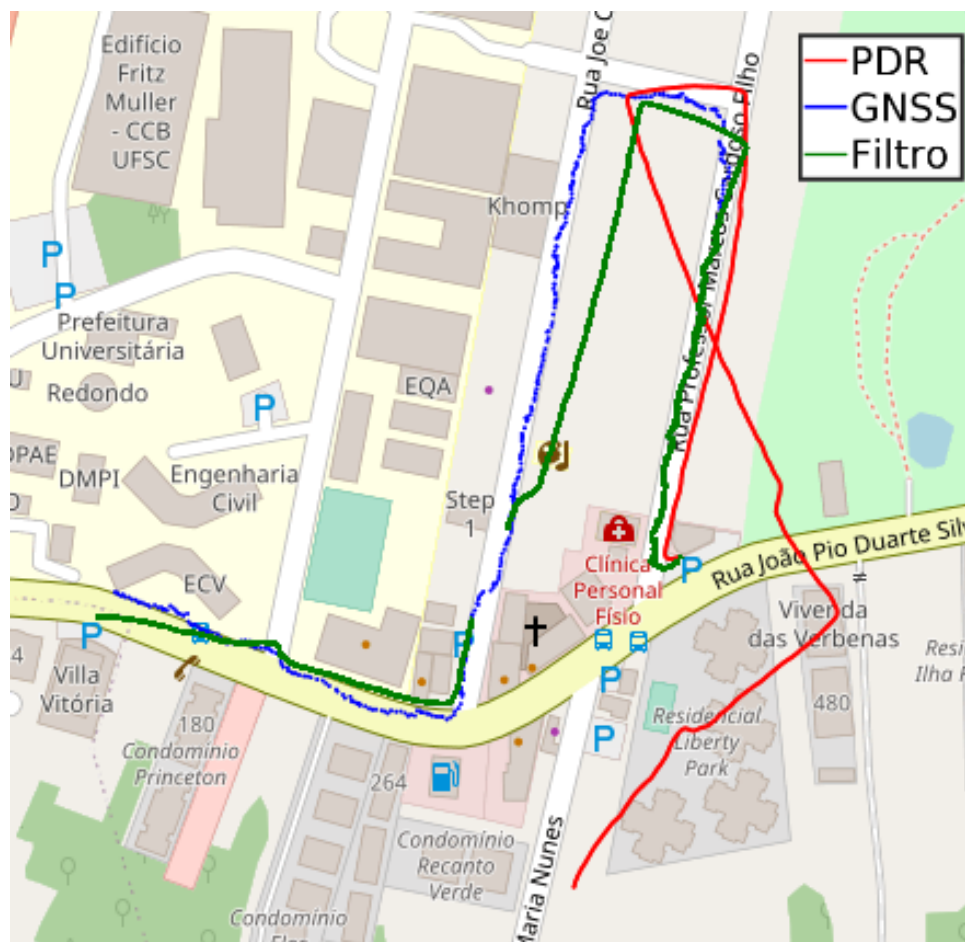
Fonte – O autor.

Figura 28 – Estimação das coordenadas norte e leste da posição geográfica.



Fonte – O autor.

Figura 29 – Resultado do filtro nas coordenadas geodésicas de posição.



Fonte – Leaflet, com marcações do autor.

8 CONCLUSÃO

Neste projeto de PFC, uma solução para o problema da localização geográfica de pessoas em ambientes externos foi proposta, incluindo a definição de uma arquitetura embarcada e o projeto de um filtro de Kalman estendido para estimação das variáveis de navegação. Dados obtidos de uma reprodução do cenário real previsto para a operação da solução foram coletados e utilizados como entrada em um ambiente de simulação desenvolvido para avaliar a performance do filtro projetado.

De maneira geral, o resultado apresentado na Figura 29 mostra que o filtro projetado atendeu os requisitos especificados, combinando os dados do módulo GNSS com os sensores inerciais para derivar uma estimativa precisa de posição. Conforme indicado no Capítulo 2, um dos principais objetivos do trabalho é conferir ao dispositivo uma maior autonomia em relação à frequência de utilização do módulo GNSS, o que impacta em uma redução significativa no consumo energético total e permite que a posição continue sendo estimada com qualidade mesmo em momentos de indisponibilidade na recepção dos sinais dos satélites. Claramente, nos testes realizados, após um período de inicialização para estimação dos erros do modelo e dos bias dos sensores, tal autonomia foi atingida, permitindo uma periodicidade de minutos na leitura da posição reportada pelo módulo GNSS.

Enquanto outros trabalhos similares referenciados ao longo de toda esta monografia se preocupam com manter uma estimativa precisa de posição em períodos eventuais de indisponibilidade do sistema GNSS, o projeto de filtro de estimação aqui desenvolvido se destaca por ter como objetivo reduzir sua frequência de utilização mesmo em condições de operação normais, consistindo portanto em um desafio ainda maior. Vários pontos ainda podem e serão explorados pelo aluno na continuação do projeto, mas os resultados já estão dentro daquilo que foi especificado.

Do ponto de vista da experiência do aluno, comenta-se ainda que o trabalho desenvolvido durante o período de execução deste PFC foi uma oportunidade única para seu desenvolvimento profissional e pessoal. O problema abordado é desafiador e permitiu a aplicação de conhecimentos e ferramentas apresentadas durante a graduação, como o filtro de Kalman, a implementação de ambientes de simulação, a instrumentação de sistemas embarcados e a modelagem matemática de processos reais, apenas para citar alguns exemplos principais.

Finalmente, destaca-se que o filtro de estimação projetado, bem como a arquitetura embarcada proposta pelo aluno serão elementos integrantes, em um futuro próximo, de um dispositivo de fabricação e tecnologia nacionais voltado para o monitoramento de pessoas e ativos. Tal contribuição soma à linha de produtos MPA da Khomp e constitui a base para que esta solução seja implementada agora em um *software* embarcado.

8.1 TRABALHOS FUTUROS

Perspectivas futuras de continuação e aprofundamento da solução desenvolvida durante este PFC são apresentadas abaixo:

- Implementar o filtro de Kalman estendido projetado em linguagem C para ser executado em tempo real no microcontrolador que fará parte do dispositivo *Smart Badge* e medir o custo computacional exigido, propondo alternativas caso seja necessário;
- Testar e avaliar a performance da solução proposta no próprio *hardware* do *Smart Badge* assim que este estiver disponível, como forma de verificar a robustez da estimação diante de novas condições de acomodação dos sensores;
- Expandir os cenários de teste compreendidos neste trabalho, incluindo ambientes que tenham maior proximidade com o ambiente típico esperado em campo e com o dispositivo sendo portado por pessoas com características fisiológicas distintas;
- Expandir o comportamento de movimentação do pedestre durante os testes executados - inserindo elementos como corridas, longas pausas, degraus/escadas - e verificar se o algoritmo de detecção de passos consegue operar com assertividade nessas ocasiões.

REFERÊNCIAS

(GSA), European GNSS Agency. **GNSS User Technology Report**. Issue 1. [S./], 2016. Disponível em: <https://www.gsa.europa.eu/european-gnss/gnss-market/gnss-user-technology-report>.

(GSA), European GNSS Agency. **Power-efficient positioning for the Internet of Things**. [S./], 2020.

AGGARWAL, Priyanka. **MEMS-based integrated navigation**. [S./]: Artech House, 2010.

ANGRISANO, Antonio *et al.* GNSS/INS integration methods. **Dottorato di ricerca (PhD) in Scienze Geodetiche e Topografiche Thesis, Università degli Studi di Napoli PARTHENOPE, Naples**, v. 21, 2010.

BEAUREGARD, Stephane *et al.* Pedestrian dead reckoning: A basis for personal positioning. *In*: PROCEEDINGS of the 3rd Workshop on Positioning, Navigation and Communication. [S./: s.n.], 2006. P. 27–35.

BILL, Ralf *et al.* Indoor and outdoor positioning in mobile environments a review and some investigations on wlan positioning. **Geographic Information Sciences**, v. 10, n. 2, p. 91–98, 2004.

BRAJDIC, Agata *et al.* Walk detection and step counting on unconstrained smartphones. *In*: PROCEEDINGS of the 2013 ACM international joint conference on Pervasive and ubiquitous computing. [S./: s.n.], 2013. P. 225–234.

ENGE, Per K. The global positioning system: Signals, measurements, and performance. **International Journal of Wireless Information Networks**, Springer, v. 1, n. 2, p. 83–105, 1994.

FALCO, Gianluca *et al.* Loose and tight GNSS/INS integrations: Comparison of performance assessed in real urban scenarios. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 17, n. 2, p. 255, 2017.

FELIZ ALONSO, Raúl *et al.* Pedestrian tracking using inertial sensors. *Red de Agentes Fisicos*, 2009.

GABAGLIO, Vincent. **GPS/INS integration for pedestrian navigation**. [S.l.], 2003.

GODHA, Saurabh. **Performance evaluation of low cost MEMS-based IMU integrated with GPS for land vehicle navigation application**. [S.l.: s.n.], 2006.

GSA. **GNSS Market Report**. Issue 6. [S.l.], 2019. Disponível em:
<https://www.gsa.europa.eu/2019-gsa-gnss-market-report>.

JIMENEZ, Antonio R *et al.* A comparison of pedestrian dead-reckoning algorithms using a low-cost MEMS IMU. *In: IEEE. 2009 IEEE International Symposium on Intelligent Signal Processing*. [S.l.: s.n.], 2009. P. 37–42.

JUNQUEIRA, Flavio Paiva. **CDMA - Code Division Multiple Access**. Disponível em:
<https://www.gta.ufrj.br/~flavio/commovel/CDMA.htm>. Acessado em 26/04/2021.

KAPLAN, Elliott *et al.* **Understanding GPS: principles and applications**. [S.l.]: Artech house, 2005.

KIM, J Won *et al.* A step, stride and heading determination for the pedestrian navigation system. **Journal of Global Positioning Systems**, v. 3, n. 1-2, p. 273–279, 2004.

KUANG, Jian *et al.* Robust pedestrian dead reckoning based on MEMS-IMU for smartphones. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 18, n. 5, p. 1391, 2018.

LAN, Haiyu *et al.* An integrated PDR/GNSS pedestrian navigation system. *In: SPRINGER. CHINA Satellite Navigation Conference (CSNC) 2015 Proceedings: Volume III*. [S.l.: s.n.], 2015. P. 677–690.

MEZENTSEV, Oleg A. **Sensor aiding of HSGPS pedestrian navigation**. 2005.

NOVATEL. **An Introduction to GNSS**. [S.l.]: NovAtel, 2015.

OTHER Global Navigation Satellite Systems (GNSS). 2020. Disponível em:
<https://www.gps.gov/systems/gnss/>. Acessado em 25/04/2021.

PETERSON, Roger L *et al.* **An introduction to spread-spectrum communications**. [S.l.]: Prentice-Hall, Inc., 1995.

PETOVELLO, Mark G. **Real-time integration of a tactical-grade IMU and GPS for high-accuracy positioning and navigation**. 2003.

SCHMIDT, George T *et al.* **INS/GPS integration architectures**. [S.l.], 2010.

EL-SHEIMY, Naser *et al.* The utilization of artificial neural networks for multisensor system integration in navigation and positioning instruments. **IEEE Transactions on instrumentation and measurement**, IEEE, v. 55, n. 5, p. 1606–1615, 2006.

SHIN, Eun-Hwan. **Estimation techniques for low-cost inertial navigation**. v. 20219. [S.l.: s.n.], 2005.

SHIN, Eun-Hwan *et al.* **Accuracy improvement of low cost INS/GPS for land applications**. [S.l.: s.n.], 2002. P. 146–157.

SILVEIRA, Hector Bessa. **Notas de Aula: DAS 5131 - Controle Multivariável**. [S.l.]: Universidade Federal de Santa Catarina, 2019.

SIMON, Dan. **Optimal state estimation: Kalman, H infinity, and nonlinear approaches**. [S.l.]: John Wiley & Sons, 2006.

STIRLING, Ross *et al.* An innovative shoe-mounted pedestrian navigation system. *In*: 5. PROCEEDINGS of European navigation conference GNSS. [S.l.: s.n.], 2003.

TORRES, JMC *et al.* Caracterização de Sensor Inercial e Aplicação em Barco Autônomo. **Instituto Tecnológico de Aeronautica (ITA)**, 2002.

WEINBERG, Harvey. Using the ADXL202 in pedometer and personal navigation applications. **Analog Devices AN-602 application note**, v. 2, n. 2, p. 1–6, 2002.

WOODMAN, Oliver J. **An introduction to inertial navigation**. [S.l.], 2007.

ZHUANG, Yuan *et al.* A MEMS multi-sensors system for pedestrian navigation. *In*: SPRINGER. CHINA satellite navigation conference (CSNC) 2013 proceedings. [S.l.: s.n.], 2013. P. 651–660.