



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
DEPARTAMENTO DE ESTATÍSTICA E INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA APLICADA

Análise da aplicabilidade de sensores de baixo custo utilizando técnicas de reconstrução de trajetória de pedestres

Rodolfo Nicolás Rocha e Silva

Recife - PE, Fevereiro 2022

Rodolfo Nicolás Rocha e Silva

Análise da aplicabilidade de sensores de baixo custo utilizando técnicas de reconstrução de trajetória de pedestres

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Informática Aplicada do Departamento de Estatística e Informática - DEINFO - Universidade Federal Rural de Pernambuco, como parte dos requisitos necessários para obtenção do grau de Mestre.

Universidade Federal Rural de Pernambuco – UFPE

Departamento de Estatística e Informática

Programa de Pós-Graduação em Informática Aplicada

Orientador: Prof. Dr. Victor Wanderley Costa de Medeiros

Coorientador: Prof. Dr. Glauco Estácio Gonçalves

Recife - PE

Fevereiro 2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal Rural de Pernambuco
Sistema Integrado de Bibliotecas
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

S586a

Silva, Rodolfo Nicolás Rocha e

Análise da aplicabilidade de sensores de baixo custo utilizando técnicas de reconstrução de trajetória de pedestres / Rodolfo Nicolás Rocha e Silva. - 2022.
83 f. : il.

Orientador: Victor Wanderley Costa de Medeiros.

Coorientador: Glauco Estacio Goncalves.

Inclui referências.

Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Informática Aplicada, Recife, 2022.

1. Navegação inercial. 2. PDR. 3. Filtro de Kalman. 4. ZUPT. 5. Unidade de medição inercial. I. Medeiros, Victor Wanderley Costa de, orient. II. Goncalves, Glauco Estacio, coorient. III. Título

CDD 004

Rodolfo Nicolás Rocha e Silva

Análise da aplicabilidade de sensores de baixo custo utilizando técnicas de reconstrução de trajetória de pedestres

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Informática Aplicada do Departamento de Estatística e Informática - DEINFO - Universidade Federal Rural de Pernambuco, como parte dos requisitos necessários para obtenção do grau de Mestre.

Aprovada em Recife - PE, Fevereiro 25, 2022:

**Prof. Dr. Victor Wanderley Costa de
Medeiros** (Orientador)
Universidade Federal Rural de Pernambuco

**Prof. Dr. Tiago Alessandro Espínola
Ferreira**
Universidade Federal Rural de Pernambuco

**Prof. Dr. Edna Natividade da Silva
Barros**
Universidade Federal de Pernambuco

Recife - PE
Fevereiro 2022

Dedico a Marcela e Antônia

Agradecimentos

Gostaria de agradecer a todos os professores que conheci e tive contato na UFRPE, em especial aos meus dois professores Dr Victor Wanderley Costa de Medeiros e Dr Glaucio Estácio Gonçalves que durante todo esse tempo me acompanhando foram muito pacientes e atenciosos, tornando essa jornada uma experiência verdadeiramente engrandecedora.

Também gostaria de agradecer aos meus colegas de classe e de laboratório pelo apoio, suporte e companhia.

Por fim, gostaria de agradecer a Lourdinha, Marcela e Antônia por todo o apoio e amor.

“Os grandes navegadores devem sua reputação aos temporais e tempestades.”
(Epicuro)

Resumo

É possível estimar a posição e a trajetória de uma pessoa utilizando técnicas de navegação inercial e *dead-reckoning*, em estratégias conhecidas como *pedestrian dead-reckoning* (PDR). Um dos fatores de grande influência nesses sistemas é a qualidade dos sensores inerciais empregados para coletar os dados dos movimentos do pedestre. Sensores de alto desempenho, como os utilizados em aviação, por exemplo, são caros e às vezes grandes e pesados para serem transportados por uma pessoa enquanto caminha. Em aplicações de PDR, sensores mais baratos e, conseqüentemente, mais suscetíveis a erros de medição são geralmente a escolha mais comum. Existem diversos métodos e técnicas para reconstruir trajetória de pedestres baseando-se apenas nas medições de unidades de medição inercial fixadas em uma parte do corpo. Com os sensores fixados no pé é possível aliar a técnica ZUPT com um filtro de Kalman estendido para combater periodicamente os erros oriundos das medições e melhorar as estimativas de posição. Esta dissertação busca analisar a utilização de uma unidade de medição inercial de baixo custo, e a influência de suas configurações, na reconstrução de trajetória de pedestres. Para isso foi desenvolvido um dispositivo que coleta os dados dos sensores de uma MPU-6050 fixada no pé durante uma caminhada. As configurações dos sensores, relacionadas a sensibilidade de medição, foram então estudadas comparando os erros de posicionamento, distância acumulada, altitude e os tempos de execução, utilizando-se diferentes métodos de reconstrução de trajetória. Os resultados apontam a configuração do giroscópio como o parâmetro mais influente com relação aos erros estudados. Já a combinação entre a configuração dos sensores, acelerômetros em $\pm 16g$ e giroscópios em $\pm 2000^\circ/s$, e o algoritmo de reconstrução de trajetória 15IEZ+ZARU obteve o melhor desempenho com relação aos erros de posicionamento e distância acumulada. Os sensores com a configuração dos acelerômetros em $\pm 16g$ e dos giroscópios em $\pm 2000^\circ/s$ obteve o melhor desempenho com relação aos erros de posicionamento e distância acumulada utilizando o algoritmo de reconstrução de trajetória 15IEZ+ZARU.

Palavras-chaves: navegação inercial, unidade de medição inercial, filtro de kalman, PDR, ZUPT.

Abstract

It is possible to estimate the position and trajectory of a person using inertial navigation techniques and dead-reckoning, in strategies known as pedestrian dead-reckoning (PDR). One of the most influential factors in these systems is the quality of the inertial sensors used to collect pedestrian movements. High-performance sensors, such as those used in aviation, are expensive and sometimes even large and heavy to be carried by a person while walking. In PDR applications, cheaper sensors and, therefore, more susceptible to measurement errors are generally the most common choice. Several methods and techniques exist to reconstruct pedestrian paths based only on inertial measurement units fixed on some body parts. With the sensors mounted on foot, it is possible to combine the ZUPT technique with an extended Kalman filter to combat errors arising from measurements and improve position estimates periodically. This dissertation seeks to analyze the use of a low-cost inertial measurement unit and the influence of its configurations on pedestrians paths reconstruction. For this, we developed a device that collects data from an MPU-6050 sensor mounted on foot during a walk. The sensor configurations, related to sensitivity, were then studied comparing positioning errors, accumulated distance, altitude, and execution time using different trajectory reconstruction methods. The results point to the scale range of the gyroscope as the most influential parameter concerning the studied errors. Sensors with accelerometers configuration in $\pm 16g$ and gyroscopes in $\pm 2000^\circ/s$ had the best performance in relation to positioning errors and accumulated distance using 15IEZ+ZARU trajectory reconstruction algorithm.

Keywords: inertial navigation, inertial measurement unit, Kalman filter, PDR, ZUPT.

Lista de ilustrações

Figura 1 – INS e SHS. Adaptado de: (HARLE, 2013).	5
Figura 2 – Diagrama de um sistema de navegação inercial com filtro de Kalman estendido e ZUPT. Adaptado de: (FISCHER; SUKUMAR; HAZAS, 2012).	6
Figura 3 – <i>Roll</i> , <i>pitch</i> e <i>yaw</i> . Fonte: (Jahee Campbell-Brennan	11
Figura 4 – Sistemas de coordenadas e referenciais. Fonte: Elaborada pelo autor.	11
Figura 5 – Oscilador de feixe simples utilizado em giroscópio vibratório. Fonte: (TITTERTON; WESTON, 2004)	14
Figura 6 – Fases da caminhada. Adaptado de: (ZHANG et al., 2021)	15
Figura 7 – Resultado das condições C1, C2 e C3. Fonte: (FAN et al., 2018)	17
Figura 8 – Correção de posição utilizando filtro de Kalman estendido durante ZUPT. Adaptado de: (SUKUMAR, 2010)	17
Figura 9 – Algoritmo de navegação inercial <i>strapdown</i> . Adaptado de: (WOODMAN, 2007).	21
Figura 10 – A esquerda o caminho real percorrida e a direita a reconstrução ingênua dessa trajetória. Adaptado de: (STRAETEN, 2019).	23
Figura 11 – Diagrama do algoritmo do filtro de Kalman. Adaptado de: (WELCH; BISHOP et al., 1995).	24
Figura 12 – Diagrama do algoritmo do filtro de Kalman estendido. Adaptado de: (WELCH; BISHOP et al., 1995).	25
Figura 13 – Montagem do primeiro protótipo.	29
Figura 14 – Caixa do dispositivo de aquisição de dados e os sensores utilizados nas coletas.	30
Figura 15 – Tela do terminal serial <i>bluetooth</i> do celular.	31
Figura 16 – Diagrama da coleta de dados e do processamento.	32
Figura 17 – Protótipo amarrado ao pé pelos cadarços do sapato.	32
Figura 18 – Esquema do percurso fechado utilizado para coleta de dados. A linha tracejada indica o percurso contabilizado como a distância total percorrida e o ponto vermelho o local de partida.	33
Figura 19 – Diagramas de blocos dos algoritmos.	34
Figura 20 – Condições C1, C2 e C3 sobrepostas aos dados medidos pelos sensores.	36
Figura 21 – Resultados dos testes de detecção.	37
Figura 22 – Estimativa do ângulo <i>pitch</i> para sensores fixados no pé de uma caminhada em terreno plano. Os retângulos azuis mostram as regiões em que o pé está apoiado no chão.	37
Figura 23 – Resultado do teste de detecção de fase de apoio utilizando o ângulo <i>pitch</i> .	38

Figura 24 – Reconstrução das trajetórias para configuração C00	42
Figura 25 – Reconstrução das trajetórias para configuração C03	42
Figura 26 – Reconstrução das trajetórias para configuração C30	43
Figura 27 – Reconstrução das trajetórias para configuração C33	43
Figura 28 – Exemplo de gráfico quantil-quantil.	44
Figura 29 – Diagramas de caixas dos erros por algoritmo.	45
Figura 30 – Diagramas de caixas dos erros por configuração.	46
Figura 31 – Diagrama de caixas dos erros de posicionamento por algoritmo e configuração.	47
Figura 32 – Diagrama de caixas dos erros acumulados de distância por algoritmo e configuração.	47
Figura 33 – Diagrama de caixas dos erros de altitude por algoritmo e configuração.	48
Figura 34 – Diagrama de caixas dos tempos de execução por algoritmo e configuração.	48
Figura 35 – Reconstrução das trajetórias utilizando algoritmo 15IEZ+ZARU para configuração C33	50
Figura 36 – Comparação entre os detectores de fase de apoio baseados em C1&C2&C3 e <i>pitch</i> utilizando algoritmo 15IEZ+ZARU e a configuração C33.	51

Lista de tabelas

Tabela 1 – Tabela de preços de unidades de medição inercial com valores levantados em pesquisa realizada em dezembro de 2021	2
Tabela 2 – Categorias de unidade de medição inercial. Adaptado de: (CHAO et al., 2010)	13
Tabela 3 – Tabela dos algoritmos utilizados e suas diferenças	35
Tabela 4 – Combinações das configurações da unidade de medição inercial	35
Tabela 5 – Média de erros de posicionamento	48
Tabela 6 – Média de erros de distância acumulada	49
Tabela 7 – Média de erros de altitude	49
Tabela 8 – Média dos tempos de execução	49
Tabela 9 – Média dos erros e dos tempos de execução	50

Lista de abreviaturas e siglas

GPS	Global Positioning System
PDR	Pedestrian Dead-Reckoning
PINS	Pedestrian Inertial Navigation System
EKF	Extended Kalman Filter
KF	Kalman Filter
ZUPT	Zero-Velocity Update
INS	Inertial Navigation System
IEZ	INS-EKF-ZUPT
ZARU	Zero Angular Rate Update
HDR	Heuristic Heading Reduction
IMU	Inertial Measurement Unit
NED	North East Down
MEMS	Microeletromechanical Systems
DOF	Degrees Of Freedom
ZV	Zero Velocidade
MARG	Magnetic, Angular Rate and Gravity

Sumário

1	INTRODUÇÃO	1
1.1	Motivação	2
1.2	Objetivos	3
1.3	Organização do trabalho	3
2	TRABALHOS RELACIONADOS	5
3	REFERENCIAL TEÓRICO	9
3.1	Sistemas de Navegação Inercial	9
3.2	Sistemas de coordenadas e referenciais	10
3.3	Sensores Inerciais e Unidades de Medição Inerciais	12
3.3.1	Acelerômetros	13
3.3.2	Giroscópios	14
3.4	Análise de caminhada e detector de zero velocidade	15
3.4.1	ZUPT e ZARU	16
3.5	Representação da orientação	18
3.5.1	Ângulos de Euler	18
3.5.2	Quatérnios	19
3.6	Estimativa da orientação	20
3.6.1	Estimativa da orientação através do filtro de Madgwick	20
3.6.2	Estimativa da orientação através do filtro de Kalman	21
3.7	Mecanização de sistema de navegação inercial <i>strapdown</i>	21
3.8	Filtro de Kalman e Filtro de Kalman estendido (EKF)	24
3.8.1	Filtro de Kalman estendido e PDR	25
4	MATERIAIS E MÉTODOS	29
4.1	Dispositivo de aquisição de dados	29
4.2	Ambiente de experimentação	30
4.3	Algoritmos e configurações	32
4.4	Deteccção da fase de apoio da caminhada e deteccção da fase de apoio baseado no ângulo <i>pitch</i>	36
4.4.1	Deteccção da fase de apoio baseado no ângulo <i>pitch</i>	36
4.5	Métricas de avaliação	39
5	RESULTADOS E DISCUSSÃO	41
5.1	Reconstrução das trajetórias	41

5.2	Análise dos erros e tempo de execução	44
5.3	Comparação dos detectores de fase de apoio	50
6	CONCLUSÕES	53
6.1	Contribuições	54
6.2	Trabalhos futuros	55
	REFERÊNCIAS	57

1 Introdução

Estimar a posição de uma pessoa ou o caminho percorrido por ela é um problema de interesse em várias áreas, e um GPS é suficiente em vários casos, principalmente em locais amplos e abertos (*outdoor*). Porém existem situações em que esse dispositivo não funcionará corretamente em locais em que aconteça o bloqueio dos sinais dos satélites (WU et al., 2019), como locais fechados (*indoor*), dentro ou no entorno de densas construções, minas, estacionamentos subterrâneos, túneis, florestas ou até mesmo em ambientes nublados. Essas são grandes fontes de interferência na disponibilidade ou confiabilidade do sinal de um GPS.

Segundo (AHMED et al., 2019) sistemas para a localização de pedestres são uma área de constante crescimento em diversas aplicações, como por exemplo rastrear a posição de um bombeiro em um prédio colapsando ou como médicos podem utilizar as informações da trajetória diária percorrida por um paciente para compreender seu estágio de recuperação. Ainda são colocadas por (HARLE, 2013) uma outra gama de oportunidades para localização de pedestres em lugares fechados, como por exemplo em prédios inteligentes que poderiam otimizar a climatização e iluminação de acordo com a localização das pessoas, auxílio na navegação de visitantes em prédios que eles desconhecem e a disponibilização de serviços de emergência com uma visualização imediata da localização dos usuários nas construções.

Em (ZHENG et al., 2016) e (WU et al., 2019) as tecnologias de posicionamento de pedestres *indoor* podem ser divididas em duas, as que utilizam infraestrutura (*infrastructure-based*) e as que não utilizam infraestrutura (*infrastructure-free*). As que utilizam infraestrutura se valem informações externas, sejam de equipamentos ou redes, como *WiFi*, *Bluetooth*, *GNSS* (*global navigation satellite system*), câmeras de vídeo e *UWB* (*ultra wide band*, por exemplo, para estimar a localização. Para (WU et al., 2019) e (HOU; BERGMANN, 2020) os métodos que não se utilizam de infraestrutura são aqueles autocontidos, geralmente baseados em sensores inerciais que são fixados em alguma parte do corpo e, baseado-se nas informações desses sensores estimam a posição do corpo em relação a sua posição inicial.

A posição de um pedestre pode ser estimada a partir de sensores inerciais fixados a eles, utilizando técnicas de navegação inercial e *dead-reckoning*, não sendo necessários sinais externos ou uma infraestrutura pré-estabelecida. Essas estratégias são geralmente chamadas de *pedestrian dead-reckoning* (PDR), ou *pedestrian inertial navigation system* (PINS). Nelas os sinais dos acelerômetros são integrados duas vezes para estimar velocidade e posição, já os sinais dos giroscópios são integrados para estimar a orientação do pedestre.

Sensores inerciais estão sujeitos a erros, que se acumulam e propagam rapidamente

devido as sucessivas integrações e as próprias características dos sensores. Mesmo a utilização de sensores de alto desempenho, como os utilizados em aviões, ainda trariam problemas para utilização com pedestres, devido ao seu tamanho e principalmente, ao custo elevado na ordem de milhares de dólares. Alternativas de baixo custo são ainda mais suscetíveis a esses erros, tornando necessárias estratégias de controle e o entendimento das influências destes erros nos resultados dos sistemas que os utilizam.

1.1 Motivação

Navegação inercial na forma de PDR pode ser utilizada para estimar a trajetória de pedestres sem a utilização de infraestrutura externa, porém os resultados são muito afetados pela qualidade dos sensores utilizados. Sensores utilizados em PDR são em geral mais baratos que sensores utilizados em aviação ou navegação não tripulada, mas ainda assim podem ter um custo elevado. A Tabela 1 apresenta os valores, em Real (R\$), das unidades de medição inercial (*inertial measurement unit* - IMU) utilizadas em alguns trabalhos sobre PDR, para comparação com o valor da MPU-6050, sensor utilizado neste trabalho.

Tabela 1 – Tabela de preços de unidades de medição inercial com valores levantados em pesquisa realizada em dezembro de 2021

IMU	Preço R\$	Trabalho
MPU-6050 InvenSense Inc.	17,90	(ROCHA et al., 2021)
MPU-9150 InvenSense Inc.	79,92	(JI et al., 2020)
MPU-9250 InvenSense Inc.	89,00	(MA et al., 2018)
3DM-GX3 Microstrain Inc.	1.588,61	(ILYAS et al., 2016)
Xsens MTI-10-2A5G4-DK	2.040,30	(ZHU et al., 2020)
Xsens MTw Awinda	2.573,04	(ZHANG; LIU; SUN, 2021), (DIAZ; KAISER; AHMED, 2018), (ZHANG; WEI; YUAN, 2020)
Xsens MTI-G-700	12.824,55	(TIAN et al., 2016)
Xsens MTI-G-710	25.487,30	(WU et al., 2021), (DENG et al., 2018)

A tabela foi construída após pesquisa em sites nacionais e internacionais de venda de eletrônicos no mês de dezembro de 2021. Uma das dificuldades para construir essa tabela foi que alguns trabalhos não colocam nenhuma informação sobre a referência da IMU e, dispositivos de trabalhos relativamente recentes já saíram da linha do fabricante e não foram encontrados preços para eles.

Investigar o desempenho de sensores de baixo custo se tornou uma oportunidade no desenvolvimento de soluções baratas para o problema de estimar a posição e a trajetória de pedestres, pois saber os limites desses dispositivos também ajuda a definir onde e como

essas soluções podem ser aplicadas. Outra possibilidade é adaptar as técnicas de PDR para o contexto animal a fim de viabilizar sistemas baratos de monitoramento de animais na pecuária de precisão, por exemplo.

1.2 Objetivos

O principal objetivo deste trabalho é estudar a aplicabilidade da unidade de medição inercial de baixo custo MPU-6050 na reconstrução de trajetória de caminhada utilizando técnicas de PDR.

E ainda como objetivos específicos, pretende-se:

- Desenvolver um dispositivo de baixo custo para coletar os dados de medição da MPU-6050;
- Avaliar o impacto das configurações da MPU-6050 no desempenho da reconstrução de trajetória de pedestres;
- Avaliar o desempenho dos algoritmos estudados na utilização em conjunto com a MPU-6050;
- Construir um detector de zero velocidade utilizando a estimativa do ângulo *pitch* do pé, e compará-lo com um detector tradicional encontrado na literatura.

1.3 Organização do trabalho

Este trabalho está organizado em sete capítulos, sendo o primeiro de introdução e o segundo sobre os trabalhos relacionados. O capítulo 3 apresenta o referencial teórico sobre sistemas de navegação, filtro de Kalman, representação e estimativa de orientação, e, análise de caminhada. O capítulo 4 descreve os materiais utilizados no desenvolvimento do dispositivo de coleta de dados da IMU e os métodos utilizados para realização e avaliação dos experimentos, além de apresentar um método de detecção da fase estacionária do pé, baseando-se no ângulo *pitch*. O capítulo 5 apresenta e discute os resultados obtidos. No capítulo 6 tem-se as conclusões e considerações finais sobre este trabalho, e também são apresentadas ideias para trabalhos futuros.

2 Trabalhos Relacionados

Para (HOU; BERGMANN, 2020) e (HARLE, 2013) pode-se dividir os PDR's em dois tipos: INS (*inertial navigation system*) e SHS (*step-and-heading system*). No INS a trajetória é estimada em 3D durante todos os intervalos de tempo, sendo a teoria básica por trás desses sistemas a de que os valores da posição podem ser calculados após duas integrações sucessivas das acelerações. No SHS, que é um sistema específico para pedestres, a posição em 2D é obtida após as somas acumuladas das estimativas dos vetores de orientação e tamanho do passo do indivíduo. A Figura 1 exemplifica como se dá essa reconstrução para cada tipo sistema.




Figura 1 – INS e SHS. Adaptado de: (HARLE, 2013).

Um PDR com sensores fixados no pé foi proposto por (FOXLIN, 2005), onde a mecânica da caminhada humana foi utilizada na estratégia de controle dos erros do sistema. O sistema infere zero velocidade cada vez que o pé está apoiado no chão durante a caminhada, e alimenta um filtro de Kalman estendido (EKF) que estima os erros a cada passo para corrigir posição e velocidade, impedindo o crescimento descontrolado dos erros que inviabilizariam o sistema. A estratégia de zero velocidade ficou conhecida como *zero velocity update* (ZUPT). Segundo (WU et al., 2019), após (FOXLIN, 2005) diversos trabalhos propuseram algoritmos para sistemas com a IMU fixada no pé.

O diagrama de um PDR utilizando EKF e ZUPT, apresentado por (FISCHER;

(SUKUMAR; HAZAS, 2012), pode ser visto na Figura 2. Nesse diagrama é possível visualizar as diversas etapas necessárias para estimar a trajetória, como o sistema de navegação inercial (*inertial navigation system* - INS), o filtro de Kalman, a detecção de estacionariedade dos sensores e o ZUPT. Um PDR foi detalhado por (NILSSON et al., 2012), num sistema similar a (FISCHER; SUKUMAR; HAZAS, 2012), porém utilizando quatérnios para representação da orientação do sistema ao invés dos ângulos de Euler. Outros trabalhos como (ZHOU et al., 2014), (QIU et al., 2018) e (ZHANG; LIU; SUN, 2021) também utilizaram o quatérnio para representar a orientação.




Figura 2 – Diagrama de um sistema de navegação inercial com filtro de Kalman estendido e ZUPT. Adaptado de: (FISCHER; SUKUMAR; HAZAS, 2012).

Um *framework* chamado INS-EKF-ZUPT (IEZ) foi apresentado por (JIMÉNEZ et al., 2010), onde foram integrados diversos métodos para reduzir erros na orientação,

principalmente com relação a *yaw* que é a direção que o pé aponta quando está apoiado no solo. Alguns desses métodos de correção utilizados foram o *zero angular rate update* (ZARU), *heuristic heading reduction* (HDR) e magnetômetros.

Em (HOU; BERGMANN, 2020) 145 artigos sobre PDR foram avaliados. A IMU foi o sensor mais utilizado, estando presente em 81 trabalhos, sendo que destes, apenas 32 utilizaram magnetômetros para estimar *yaw*. Dos trabalhos avaliados que utilizavam apenas uma IMU, o estudo apontou que o ponto de fixação mais comum é o pé, seguido da fixação na cintura. Uma das vantagens desses sistemas, como colocado por (WU et al., 2019), é que ao descrever a trajetória do pé, também se está descrevendo a trajetória do corpo. Outro aspecto importante de fixar os sensores no pé são os pontos claramente próximos a zero, quando se analisa os valores das medições, diferente do que acontece quando a fixação se dá na perna, canela ou cintura, por exemplo.

Determinar as fases da caminhada, que pode ser dividida em fase de apoio e balanço, é importante para identificar quando os sensores estão estacionários. Em (WU et al., 2019) é dito que existem diversas formas de inferir as fases da caminhada, como comparando os valores obtidos a partir das medições dos acelerômetros e giroscópios com faixas de valores fixos (*thresholds*), *thresholds* adaptativos, utilizando um modelo oculto de Markov (*hidden Markov model* - HMM), etc. São apresentados em (JIMÉNEZ et al., 2010) detalhes sobre a detecção da estacionariedade dos sensores fixados no pé, baseando-se em 3 condições simultâneas para inferir a zero velocidade. A múltipla condição para determinação da fase de apoio também pode ser vista em diversos trabalhos como (ZHENG et al., 2016), (ZHANG; LIU; SUN, 2021) e (LI et al., 2021).

Os filtros são utilizados nos PDR's para integrar as observações oriundas dos sensores no sistema (HOU; BERGMANN, 2020). Segundo (WU et al., 2019) o filtro mais utilizado em PDR's é o EKF, porém vários outros como o *unscented Kalman filter* (UKF) e o *cubature Kalman filter* (CKF), por exemplo, também podem ser encontrados, bem como filtros complementares.

Em (LI; WANG, 2019) a abordagem tradicional de PDRs, com integração das velocidades angulares para estimativa das orientações, foi comparada com estimativas oriundas de filtros complementares como Madgwick (MADGWICK; HARRISON; VAIDYANATHAN, 2011) e Mahony (MAHONY; HAMEL; PFLIMLIN, 2008), analisando graficamente a reconstrução das trajetórias, os ângulos e as altitudes estimadas.

3 Referencial Teórico

Neste capítulo serão apresentados conceitos gerais necessários ao entendimento dessa dissertação.

3.1 Sistemas de Navegação Inercial

Encontrar o caminho de um lugar a outro é uma das definições de navegação, e é possível fazer isso de diversas formas, tais como seguindo instruções e utilizando um mapa, se guiando por marcos geográficos ou estrelas, etc ([TITTERTON; WESTON, 2004](#)).

Existem basicamente 5 formas de navegação ([GREWAL; WEILL; ANDREWS, 2007](#)), que podem ser combinadas entre si, descritas resumidamente abaixo:

- **Pilotagem**, que diz respeito a se guiar pelo reconhecimento de marcos;
- ***Dead reckoning***, onde a posição atual é calculada a partir da posição anterior e de informações relativas a velocidade e orientação;
- **Astronavegação**, onde os guias e marcos de navegação são os corpos celestes;
- **Radio navegação**, onde fontes de rádio frequência, fixas e de localização conhecidas, são usados como referenciais de navegação;
- **Navegação inercial**, utiliza a posição, velocidade e direção inicial, bem como a medição das taxas de rotação e aceleração, para navegar.

Os princípios básicos da mecânica clássica são a base para a navegação inercial. Esses princípios dizem que um corpo em repouso ou em movimento retilíneo uniforme tende a manter seu estado enquanto não é perturbado por uma força externa. Existindo esta força, ela produzirá no corpo uma aceleração proporcional a sua magnitude. Sendo possível medir essa aceleração, pode-se calcular as mudanças na velocidade e posição do corpo após sucessivas integrações no tempo ([TITTERTON; WESTON, 2004](#)).

Os sistemas de navegação inercial (*inertial navigation system* - INS), em geral, se valem de 3 acelerômetros e 3 giroscópios montados em direções perpendiculares entre si para estimar posição, velocidade e orientação de um corpo. Para ser possível navegar com relação a um referencial inercial, é preciso saber a direção de deslocamento do acelerômetro, o que pode ser feito medindo a rotação (giro) do corpo com giroscópios ([TITTERTON; WESTON, 2004](#)). Esse agrupamento de acelerômetros e giroscópios, dispositivos que medem aceleração e velocidade angular, respectivamente, é comumente chamado de unidade de

medição inercial (*inertial measurement unit* - IMU) (WOODMAN, 2007) (KOK; HOL; SCHÖN, 2017) (LAWRENCE, 2012).

Assim, a navegação inercial é uma técnica de navegação que se vale de acelerômetros e giroscópios para definir a posição e orientação de um objeto, corpo ou veículo, com relação a sua já conhecida posição, velocidade e orientação inicial (TITTERTON; WESTON, 2004). Outra definição para Navegação Inercial é o processo de computar a posição integrando-se a velocidade, e calcular a velocidade integrando-se a aceleração (SAVAGE, 1998).

Nos INS *strapdown*, os sensores são fixados rigidamente ao corpo, tornando as medições referentes a ele e não ao referencial de navegação. Assim, algumas dessas grandezas precisam ser transformadas do referencial do corpo para o referencial de navegação (WOODMAN, 2007). Um exemplo são os valores dos acelerômetros, que precisam ser transformados do referencial do corpo para o de navegação antes de serem integrados para obtenção da velocidade.

Uma das principais vantagens dos INS é sua autonomia, já que não dependem de referências ou infraestruturas externas ou, por exemplo, condições de visibilidade para navegar (GREWAL; WEILL; ANDREWS, 2007). Por outro lado, uma das principais desvantagens são os erros a que são suscetíveis, que sem nenhum controle tornariam os sistemas inúteis rapidamente (TITTERTON; WESTON, 2004) (FOXLIN, 2005). Esses erros, em geral, são relacionados às medições das IMUs e aos processos de integrações sucessivas dessas medições.

3.2 Sistemas de coordenadas e referenciais

Para melhor entender sobre navegação inercial e as grandezas medidas por acelerômetros e giroscópios é preciso definir certos sistemas de coordenadas com relação aos referenciais.

O referencial do corpo (referencial b ou b -frame), pode em geral, ser definido como o sistema de coordenadas dos sensores que estão se movimentando, tendo sua origem como a mesma dos sistema triaxial formado pelos sensores. É o sistema de coordenadas alinhado com os eixos onde os sensores estão fixados. Todas as medições dos sensores inerciais são relativas a esse referencial.

Com relação ao referencial do corpo, cabe acrescentar que as rotações ao longo de seus eixos x , y e z são chamadas *roll* (ϕ), *pitch* (θ) e *yaw* (ψ), e podem ser vistos na Figura 3.

O referencial de navegação (referencial n ou n -frame) é o referencial onde se deseja navegar, ou seja, é com relação a esse referencial que se deseja obter a posição e orientação do corpo. Neste trabalho ele é considerado estacionário com relação ao referencial da Terra e




Figura 3 – *Roll*, *pitch* e *yaw*. Fonte: (Jahee Campbell-Brennan¹).

está na superfície desta, coincidindo com o sistema de coordenadas NED (*North-East-Down*, norte-leste-baixo) e por vezes chamado de plano tangente (*t-frame*).

O referencial inercial (referencial *i* ou *i-frame*) é o referencial estacionário. Tem origem no centro da terra, sendo os eixos estacionários com relação as estrelas fixas.

O referencial da Terra (referencial *e* ou *e-frame*) tem a origem do seu sistema de coordenadas coincidindo com o centro da Terra. Este referencial é fixo com relação a Terra, porém gira em relação ao referencial inercial.

Na Figura 4 é possível ver os sistemas de coordenadas dos referenciais do corpo e de navegação.




Figura 4 – Sistemas de coordenadas e referenciais. Fonte: Elaborada pelo autor.

Neste trabalho o referencial de uma grandeza será representado por uma letra

¹ <https://www.racecar-engineering.com/tech-explained/racecar-vehicle-dynamics-explained/>

sobrescrita. Por exemplo, A^b representa a grandeza A no referencial b .

3.3 Sensores Inerciais e Unidades de Medição Inerciais

Sensores que medem forças inerciais para determinar o comportamento dinâmico de um corpo com relação a um referencial inercial são chamados sensores inerciais (KEMPE, 2011). Os sensores inerciais são os acelerômetros e giroscópios, pois medem os parâmetros dinâmicos básicos (KOK; HOL; SCHÖN, 2017) (GROVES, 2015) (GREWAL; WEILL; ANDREWS, 2007).

INS's onde custo, tamanho e consumo de energia eram fatores limitantes, puderam ser viabilizados com a utilização de sistemas microeletromecânicos (*microelectromechanical systems* - MEMS) (TITTERTON; WESTON, 2004). MEMS são dispositivos miniaturizados que combinam componentes mecânicos e elétricos utilizando técnicas de microfabricação como as utilizadas para fabricar circuitos integrados. Sensores tradicionais, comumente de construção eletromecânica, geralmente têm melhores características de sensibilidade e fundo de escala, por exemplo, se comparados a sensores MEMS (HAK, 2001). Assim, acelerômetros e giroscópios MEMS podem ser produzidos em larga escala, se tornando uma alternativa de qualidade inferior, porém mais barata a sensores convencionais (GROVES, 2015).

Em geral, IMUs possuem 3 acelerômetros e 3 giroscópios triaxiais e, nessa configuração é dito que possuem 6 graus de liberdade (*six degrees of freedom* - 6-DOF), porém também é comum encontrar alguns dispositivos que possuem 3 magnetômetros triaxiais adicionais (9-DOF) e até barômetros.

Segundo (GROVES, 2015) não existe um consenso sobre o que seriam sensores de alto, médio e baixo grau de desempenho, sendo o grau de mais elevado reservado a aplicações militares, como navios de guerra, mísseis intercontinentais e submarinos, podendo o preço desses dispositivos alcançar 1 milhão de dólares. Outros autores como (CHAO et al., 2010) e (ZHOU et al., 2020) categorizam as IMUs com relação a seu grau de desempenho e precisão dividindo-as em:

- **Navegação:** é o grau com maior desempenho, utilizada em aeronaves, navios e espaçonaves. A diferença entre o valor medido e real do giroscópio aumenta $0.1\text{grau}/h$;
- **Tático:** utilizada em navegação aérea com veículos não tripulados. A diferença entre o valor medido e real do giroscópio aumenta entre 0.1 e $10\text{graus}/h$;
- **Industrial:** aplicada em robôs e máquinas industriais. A diferença entre o valor medido e real do giroscópio aumenta $1\text{grau}/s$;

- **Hobista:** também conhecido como grau de consumidor ou automotivo, comumente encontradas em *wearables*, jogos, realidade virtual e brinquedos. A diferença entre o valor medido e real do giroscópio aumenta $1\text{grau}/s$.

Na Tabela 2 é feita uma relação entre o grau de desempenho das IMUs e seu custo. A maioria dos sensores industriais e *hobbistas* são baseados em dispositivos MEMS, e esse é um dos motivos da faixa de preço inferior com relação a IMUs táticas de navegação.

Tabela 2 – Categorias de unidade de medição inercial. Adaptado de: (CHAO et al., 2010)

Grau de desempenho	Custo (USD)
Navegação	$> 50.000,00$
Tático	$10.000,00 - 20.000,00$
Industrial	$500,00 - 3.000,00$
Hobista	$< 500,00$

3.3.1 Acelerômetros

Acelerômetros são dispositivos que convertem a aceleração de um corpo em deflexão ou tensão, que são posteriormente utilizadas para estimar aceleração (KEMPE, 2011). A maioria dos acelerômetros mede a força específica atuando no corpo (e não a aceleração da gravidade), e a relação entre estas se dá conforme a Equação 3.1 (TITTERTON; WESTON, 2004) (GREWAL; WEILL; ANDREWS, 2007) (AGGARWAL, 2010). Onde f é a força específica; g é a aceleração da gravidade; e a é a aceleração em relação ao referencial inercial.

$$F = ma = mf + mg \quad (3.1)$$

Pode-se dividir os acelerômetros em mecânicos e de estado sólido. A forma mais simples de um acelerômetro mecânico é um sistema massa-mola, onde aplicando a segunda lei de newton é possível calcular a aceleração do conjunto (TITTERTON; WESTON, 2004)(WOODMAN, 2007). Acelerômetros de estado sólido podem ser construídos com cristais de quartzo, e a vibração desses cristais é utilizada para medir as acelerações. Também existem acelerômetros baseados em silício, onda acústica de superfície (*surface acoustic wave* - SAW), e outras tecnologias (TITTERTON; WESTON, 2004).

As faixas de operação desses dispositivos geralmente são dadas em relação a aceleração da gravidade g , onde $1g = 9,80665m/s^2$ (GROVES, 2015), mas também é possível encontrar dispositivos que utilizam a própria unidade de aceleração m/s^2 (AGGARWAL, 2010).

3.4 Análise de caminhada e detector de zero velocidade

A mecânica da caminhada humana (as vezes chamada marcha humana) pode ser dividida nas fases de apoio e balanço (*stance phase* e *swing phase*), como mostra a Figura 6. Na fase de apoio o pé está em contato com o solo, sustentando o peso do corpo e na fase de balanço ele se move pelo ar sobre o solo (YAMAUCHI; BHANU; SAITO, 2009) (DIAZ; KAISER; AHMED, 2018). Desta forma é possível inferir que durante a fase de apoio ele está parado, e assim é possível aproximar o modelo de caminhada humana entre momentos em que o pé está parado (fase de apoio) ou em movimento (fase de balanço).




Figura 6 – Fases da caminhada. Adaptado de: (ZHANG et al., 2021)

É possível identificar a zero velocidade (ZV) do pé, e consequentemente a fase de apoio, se valendo apenas dos dados obtidos pelos sensores inerciais. A forma mais comum de detectar ZV é comparando os dados medidos pelos sensores com faixas de valores fixos (*thresholds*).

Em (FISCHER; SUKUMAR; HAZAS, 2012) foi utilizado um detector baseado apenas na comparação do módulo da velocidade angular (ω^b) com um valor de referência e (SKOG et al., 2010) apresentou que para caminhadas, detectores de ZV baseados apenas nos dados dos giroscópios funcionam tão bem quanto aqueles baseados nos dados dos acelerômetros e giroscópios.

Segundo (JIMÉNEZ et al., 2010) o processo de detecção de ZV se torna mais robusto se for necessária a simultaneidade de várias condições, baseadas nos dados dos acelerômetros e giroscópios, com posterior filtragem dos resultados.

Abaixo são descritas três condições para a detecção da fase de apoio da caminhada, sendo que cada uma capaz de identificar ZV independentemente. Nas condições, o 1 representa que a detecção da fase de apoio é verdadeira.

A condição C1 (3.2) compara o módulo das medições dos acelerômetros (f^b) com os limites $9m/s^2$ e $11m/s^2$, faixa de valores referentes a aceleração da gravidade que, quando o sensor estiver apoiado no chão (parado com relação ao referencial de navegação) seria a única força agindo nele (SKOG et al., 2010).

$$C1 = \begin{cases} \text{se } 9m/s^2 < \|f^b\| < 11m/s^2, & 1 \\ \text{senão,} & 0 \end{cases} \quad (3.2)$$

A condição C2 (3.3) compara a variância de f^b em uma janela móvel n com um valor de referência, sendo $\bar{f}_j^b$ é a média de n amostras (SKOG et al., 2010). Os estudos de (RAJAGOPAL, 2008) apontam que para caminhadas, valores entre 5 e 10 são apropriados para as janelas móveis n . Como valor de referência (JIMÉNEZ et al., 2010) utilizou $3m^2/s^4$, enquanto (RAJAGOPAL, 2008) utilizou $20m^2/s^4$ e (SUKUMAR, 2010) utilizou $15m^2/s^4$. Esses valores devem ser definidos ajustados de acordo com o experimento que está sendo realizado.

$$C2 = \begin{cases} \text{se } \frac{1}{n} \sum_{i=1}^{i=j+n} (f_i^b - \bar{f}_j^b)^2 < 3m^2/s^4, & 1 \\ \text{senão,} & 0 \end{cases} \quad (3.3)$$

A condição C3 (3.4) compara o módulo de ω^b com um valor de referência para detectar ZV (SKOG et al., 2010). Em (FISCHER; SUKUMAR; HAZAS, 2012) $0.6rad/s$ é utilizado como valor de referência.

$$C3 = \begin{cases} \text{se } \|\omega^b\| < 0.6rad/s, & 1 \\ \text{senão} & 0 \end{cases} \quad (3.4)$$

É possível ver os resultados individuais das condições C1, C2 e C3, bem como a detecção de apoio apenas com a simultaneidade de todas as condições (operação lógica $C1 \& C2 \& C3$) na Figura 7.

3.4.1 ZUPT e ZARU

É possível inferir que a velocidade do pé é zero quando este está totalmente apoiado no chão durante a caminhada, em contato direto com o solo. Isso torna possível estimar o erro correspondente à velocidade naquele instante (m_k), que é a diferença entre a velocidade estimada pelo INS (v_k) e um vetor de valor zero ($[0, 0, 0]$) referente a pseudo-medição de ZV, como mostra a Equação (3.5).

$$m_k = v_k - [0, 0, 0]^T \quad (3.5)$$




Figura 7 – Resultado das condições C1, C2 e C3. Fonte: (FAN et al., 2018)

Assim, é possível alimentar o EKF com esse erro e atualizar os estados do sistema, na técnica conhecida como ZUPT. A Figura 8 traz um exemplo de como é corrigida a posição em duas dimensões utilizando EKF durante o ZUPT.




Figura 8 – Correção de posição utilizando filtro de Kalman estendido durante ZUPT. Adaptado de: (SUKUMAR, 2010)

De forma similar a descrita anteriormente é possível inferir que a velocidade angular nesse mesmo momento também é zero e compará-la com os valores do sistema para alimentar o EKF e corrigir as medições dos giroscópios. Essa técnica é conhecida como ZARU e tem o mesmo princípio básico utilizado no ZUPT. A técnica ZARU pode

ser aplicada independentemente da ZUPT ou em conjunto com a mesma, sempre que detectado que o pé está apoiado no chão.

3.5 Representação da orientação

A representação da orientação é um importante ponto na navegação inercial, pois a orientação é necessária para transformações vetoriais dos referenciais b para o n , além do que cada uma das diversas representações possui vantagens e desvantagens. As representações mais comuns são os ângulos de Euler, quatérnios e cossenos diretores (WOODMAN, 2007).

Essas representações são utilizadas para construção de matrizes de transformação, utilizadas para transformar uma grandeza vetorial de um referencial para outro (GROVES, 2015). Na Equação (3.6), x^i é um vetor no referencial i e x^b um vetor no referencial b , sendo C_b^i a matriz de transformação do referencial b para o i .

$$x^i = C_b^i x^b \quad (3.6)$$

Uma propriedade importante das matrizes de transformação para a navegação inercial é a da Equação (3.7). Onde a transformação inversa de um referencial para outro é dada pela transposta dessa matriz.

$$C_b^i = C_i^{bT} \quad (3.7)$$

3.5.1 Ângulos de Euler

A orientação de um corpo rígido em um espaço 3D pode ser descrita pelos 3 ângulos de Euler, *roll* (ϕ), *pitch* (θ) e *yaw* (ψ), que representam rotações sucessivas ao longo dos 3 eixos ortogonais, x , y e z . Essas rotações podem ser representadas por matrizes de rotação independentes, sendo C_1 uma rotação de ψ sobre o eixo z , C_2 uma rotação de θ sobre o eixo y e C_3 a rotação de ϕ sobre o eixo x . Assim as Equações (3.8), (3.9) e (3.10) definem as rotações em torno dos eixos e a Equação (3.11) define a transformação C_n^b e (3.12) define C_b^n (TITTERTON; WESTON, 2004).

$$C_1 = \begin{bmatrix} \cos\psi & \sin\psi & 0 \\ -\sin\psi & \cos\psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.8)$$

$$C_2 = \begin{bmatrix} \cos\theta & 0 & -\sin\theta \\ 0 & 1 & 0 \\ \sin\theta & 0 & \cos\theta \end{bmatrix} \quad (3.9)$$

$$C_3 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\phi & \sin\phi \\ 0 & -\sin\phi & \cos\phi \end{bmatrix} \quad (3.10)$$

$$C_n^b = C_3 C_2 C_1 = C_b^{nT} \quad (3.11)$$

$$C_b^n = \begin{bmatrix} \cos\theta\cos\psi & \sin\theta\sin\phi\cos\psi - \cos\phi\sin\psi & \sin\theta\cos\phi\cos\psi + \sin\phi\sin\psi \\ \cos\theta\sin\psi & \sin\theta\sin\phi\sin\psi + \cos\phi\cos\psi & \sin\theta\cos\phi\sin\psi - \sin\phi\cos\psi \\ -\sin\theta & \cos\theta\sin\phi & \cos\theta\cos\phi \end{bmatrix} \quad (3.12)$$

Uma das vantagens dos ângulos de Euler para representar a orientação de um corpo é que essa é uma representação intuitiva, onde é possível imaginar e visualizar as sucessivas rotações do corpo ao redor dos eixos. Essa representação também é bastante utilizada nas indústrias aeronáutica e aeroespacial.

A principal desvantagem dos ângulos de Euler é a singularidade conhecida por *gimbal lock* que se dá quando dois eixos de rotação ficam paralelos e um grau de liberdade é perdido. Uma forma de visualizar o *gimbal lock* é quando na sequência (ψ, θ, ϕ) , θ está em 90° e o corpo aponta para cima, não é possível distinguir entre ψ e ϕ (DIEBEL, 2006).

3.5.2 Quatérnios

A rotação de um corpo rígido ou um referencial de coordenadas tridimensional podem ser representados por um número complexo de quatro dimensões, uma real (q_0) e três complexas (q_1, q_2 e q_3), chamado quatérnio (3.13) (MADGWICK, 2010).

$$q = [q_0 \quad q_1 \quad q_2 \quad q_3] \quad (3.13)$$

A partir de um quatérnio é possível realizar a rotação de um vetor tridimensional v de duas formas. A primeira é considerando o vetor um quatérnio de parte real nula e realizando as operações da Equação (3.14), onde $\otimes$ representa o produto entre dois quatérnios definida pela regra de Hamilton na Equação (3.15), e q^* é o conjugado do quatérnio q , como na Equação (3.16).

$$v^n = q \otimes v^b \otimes q^* \quad (3.14)$$

$$q \otimes p = \begin{bmatrix} q_1 p_1 - q_2 p_2 - q_3 p_3 - q_4 p_4 \\ q_1 p_2 + q_2 p_1 + q_3 p_4 - q_4 p_3 \\ q_1 p_3 - q_2 p_4 + q_3 p_1 + q_4 p_2 \\ q_1 p_4 + q_2 p_3 - q_3 p_2 + q_4 p_1 \end{bmatrix} \quad (3.15)$$

$$q^* = \begin{bmatrix} q_0 & -q_1 & -q_2 & -q_3 \end{bmatrix} \quad (3.16)$$

A segunda forma é convertendo o quatérnio em uma matriz de transformação, como mostra a Equação (3.17) e depois seguindo da mesma forma que (3.6).

$$C_n^b = \begin{bmatrix} q_0^2 + q_1^2 - q_2^2 - q_3^2 & 2(q_1 q_2 - q_0 q_3) & 2(q_1 q_3 + q_0 q_2) \\ 2(q_1 q_2 + q_0 q_3) & q_0^2 - q_1^2 + q_2^2 - q_3^2 & 2(q_2 q_3 - q_0 q_1) \\ 2(q_1 q_3 - q_0 q_2) & 2(q_2 q_3 + q_0 q_1) & q_0^2 - q_1^2 - q_2^2 + q_3^2 \end{bmatrix} \quad (3.17)$$

Uma das principais vantagens de se utilizar quatérnio na representação da orientação é não precisar lidar com *gimbal lock*, já que ele está livre dessa singularidade (DIEBEL, 2006).

3.6 Estimativa da orientação

Quando se deseja acompanhar a posição de um corpo, é preciso constantemente estimar sua orientação no espaço. É possível obter essa orientação utilizando dados dos acelerômetros e giroscópios separadamente, ou utilizando técnicas como o filtro de Madgwick e filtro de Kalman para utilizar as informações dos dois sensores em conjunto.

3.6.1 Estimativa da orientação através do filtro de Madgwick

Em (MADGWICK; HARRISON; VAIDYANATHAN, 2011) foi apresentado de forma detalhada um algoritmo capaz de fornecer a estimativa de orientação baseado nas medições de IMUs e MARGs (*magnetic, angular rate and gravity*) que ficou comumente conhecido como filtro de Madgwick.

No caso de IMUs a orientação inicial é calculada pela integração do quatérnio obtido das medições dos giroscópios, que depois é corrigida a partir da comparação com a medição do vetor gravidade pelos acelerômetros, onde se obtêm a estimativa final do quatérnio que representa a orientação, computado pela Equação (3.18).

$$q_{t+1} = q_t + 0.5 q_t \otimes \omega_t \Delta t - \beta \frac{\nabla f}{\|\nabla f\|} \Delta t \quad (3.18)$$

Onde o termo $0.5q_t \otimes \omega_t \Delta t$ é referente a atualização da orientação baseada na integração das velocidades angulares e $\frac{\nabla f}{\|\nabla f\|} \Delta t$ é o termo relacionado a correção com base nos dados dos acelerômetros e β o peso atribuído a ele.

3.6.2 Estimativa da orientação através do filtro de Kalman

O filtro de Kalman é uma das ferramentas mais usadas para estimar a orientação a partir de sensores inerciais. Geralmente se busca estimar *roll*, *pitch*, *yaw* e os vieses de medição (*bias*) das medições dos giroscópios e acelerômetros. Na etapa de predição é feita uma estimativa da orientação baseada na integração das velocidades angulares, e, na etapa de atualização essa estimativa é corrigida utilizando-se as medições dos acelerômetros, atualizações de zero velocidade angular (ZARU), medições de bússolas digitais, etc. Esse filtro de Kalman e alguns desses métodos de correção são descritos por (DIAZ; AHMED; KAISER, 2019).

3.7 Mecanização de sistema de navegação inercial *strapdown*

Com uma IMU fixada a um corpo é possível estimar sua posição (p), velocidade (v) e orientação (θ) aplicando um algoritmo de navegação inercial *strapdown*, como o da Figura 9. Velocidade e posição são obtidas após duas integrações sucessivas dos valores fornecidos pelos acelerômetros (f^b), e a orientação é obtida a partir da integração dos valores fornecidos pelos giroscópios (ω^b). Ao conjunto IMU, corpo e algoritmo é dado o nome de sistema de navegação inercial.




Figura 9 – Algoritmo de navegação inercial *strapdown*. Adaptado de: (WOODMAN, 2007).

As Equações de navegação do sistema são dadas pela propagação da orientação do corpo no espaço (3.19), a aceleração calculada pela derivada da velocidade (3.20) e, por

fim a velocidade computada pela derivada da posição (3.21). Estas Equações relacionam posição, velocidade e orientação.

$$\dot{C}_b^n = C_b^n \Omega \quad (3.19)$$

$$\dot{v}^n = C_b^n f^b + g^n \quad (3.20)$$

$$\dot{p}^n = v^n \quad (3.21)$$

Sendo que b e n representam o referencial do corpo (*body-frame* ou *sensor-frame*) e o referencial de navegação (*navigation-frame* ou *global-frame*) respectivamente, C_b^n é uma matriz 3×3 que define a orientação do referencial b com relação ao referencial de navegação n , f^b é o vetor que contém a força específica no referencial do corpo, ω^b é o vetor que contém a velocidade angular no referencial do corpo, g^n é o vetor gravidade no referencial de navegação, e, Ω representa a matriz antissimétrica das velocidades angulares, dada por (3.22).

$$\Omega = \begin{bmatrix} 0 & -\omega_z^b & \omega_y^b \\ \omega_z^b & 0 & -\omega_x^b \\ -\omega_y^b & \omega_x^b & 0 \end{bmatrix} \quad (3.22)$$

Pode-se dividir o algoritmo da Figura 9 em 4 etapas principais:

1. Integração das velocidades angulares para estimar a orientação;
2. Transformação da força específica do referencial b para o referencial n e remoção da aceleração da gravidade no componente vertical;
3. Integração da aceleração para estimar a velocidade;
4. Integração da velocidade para estimar a posição.

A discretização de (3.19), (3.20) e (3.21), para intervalos de tempo Δ_t entre as amostras k e $k + 1$, é dada por (3.23), (3.24), (3.25) e (3.26).

$$C_{b_{k+1}}^n = C_{b_k}^n \left(\frac{2I_{3 \times 3} + \delta\Omega_{k+1}\Delta_t}{2I_{3 \times 3} - \delta\Omega_{k+1}\Delta_t} \right) \quad (3.23)$$

$$f_{k+1}^n = C_{b_{k+1}}^n f_{k+1}^b + g^n \quad (3.24)$$

$$v_{k+1}^n = v_k^n + f_{k+1}^n \Delta_t \quad (3.25)$$

$$p_{k+1}^n = p_k^n + v_{k+1}^n \Delta t \quad (3.26)$$

É importante pontuar que a Equação que atualiza no tempo as orientações com base nos dados dos sensores é dada pela exponencial matricial (3.27), que é discretizada para (3.23) utilizando uma aproximação de *Padé*, como colocado por (SKOG; HÄNDEL, 2005) e (JIMÉNEZ et al., 2010).

$$C_{b_{k+1}}^n = C_{b_k}^n \cdot e^{\Omega_{k+1} \Delta t} \quad (3.27)$$

Devido aos erros a que sensores de baixo custo estão sujeitos, se torna praticamente impossível a construção de um sistema de navegação inercial tradicional para estimativa de posição. Os erros nas medições dos giroscópios vão se acumulando gradativamente na estimativa de orientação. Da mesma forma, os erros nas medições dos acelerômetros serão integrados seguidamente, inviabilizando qualquer estimativa de posição confiável. Uma forma de combater esses erros que dominam o sistema é aplicar um filtro, como por exemplo o Filtro de Kalman, para aumentar a precisão da estimativa das posições.

A Figura 10 apresenta uma reconstrução de uma caminhada em circuito fechado retangular utilizando as Equações relacionadas ao algoritmo apresentado na Figura 9, sem nenhuma estratégia de controle dos erros. Observando a figura, fica claro que não é possível identificar nenhuma informação útil sobre posição, devido aos erros que dominam o sistema rapidamente. Esse tipo de implementação é geralmente chamada de *ingênua* ou *naïve*.




Figura 10 – A esquerda o caminho real percorrida e a direita a reconstrução ingênua dessa trajetória. Adaptado de: (STRAETEN, 2019).

3.8 Filtro de Kalman e Filtro de Kalman estendido (EKF)

O filtro de Kalman (Kalman *filter* - KF) é uma ferramenta matemática desenvolvida por Rudolf Kalman em 1960. Este filtro recursivo é capaz de estimar os estados de sistemas lineares discretos no tempo mesmo quando a modelagem do sistema não é totalmente conhecida (WELCH; BISHOP et al., 1995). Neste caso, o termo estado é usado para identificar a informação que se deseja estimar, como: posição, velocidade, temperatura ou uma combinação entre elas, por exemplo. O filtro combina medições (ou observações) ruidosas e imprecisas com os resultados esperados da modelagem matemática do sistema para obter resultados melhores e mais próximos dos reais do que aqueles que seriam obtidos apenas pelas medições ou pelos modelos. A Figura 11 apresenta o algoritmo do filtro de Kalman e suas duas etapas principais: predição (*predictor* ou *time update*) e correção (*corrector* ou *measurement update*).

Na etapa de predição o estado estimado na etapa anterior é utilizado para obter uma estimativa do estado atual. Essa estimativa é chamada estado *a priori* (*a priori state*). Durante a etapa de correção, a medição do sistema é incorporada ao estado *a priori* para obter o estado estimado *a posteriori* (*a posteriori state*). Durante esta etapa, o ganho de Kalman é responsável por regular quem terá mais importância no estado estimado, se o estado *a priori* ou a medição, combinando os dois de forma a obter estimativas melhores dos que as que seriam obtidas a partir de apenas um deles.




Figura 11 – Diagrama do algoritmo do filtro de Kalman. Adaptado de: (WELCH; BISHOP et al., 1995).

No filtro de Kalman tradicional os modelos do sistema e de medição são lineares, sendo necessário aplicar outras técnicas quando não existem essas condições. O filtro de

Kalman estendido (*extended Kalman filter* - EKF) é uma das técnicas desenvolvidas a partir do filtro tradicional que pode ser utilizada para estimar os estados de um sistema não linear.

Em um EKF o sistema não linear deve ser linearizado em torno de um ponto de interesse, e isso geralmente é feito utilizando uma aproximação de Taylor de primeira ordem, obtida pelas Jacobianas dos modelos do sistema e da medição, isto é, as derivadas parciais desses modelos. Após a linearização, as etapas do algoritmo continuam as mesmas, predição e correção. A Figura 12 apresenta um diagrama do EKF.




Figura 12 – Diagrama do algoritmo do filtro de Kalman estendido. Adaptado de: (WELCH; BISHOP et al., 1995).

3.8.1 Filtro de Kalman estendido e PDR

Em (FOXLIN, 2005) foi proposto um PDR com filtro de Kalman estendido que, utilizando pseudo medições de zero velocidade, estima e corrige os erros a cada passo, impedindo o crescimento descontrolado dos erros do sistema de navegação tradicional. A inferência de velocidade zero do sensor é feita com base na mecânica da caminhada humana, onde o pé - local de fixação do sensor - alterna momentos em que está parado com momentos em que está em movimento. O ZUPT (*zero velocity update*) é, então, aplicado apenas quando é detectado que o pé, e consequentemente o sensor, está estacionário.

Esse tipo de EKF trabalha no espaço dos erros e, após cada atualização, realimenta o INS com a estimativa dos erros computados. Já em (FISCHER; SUKUMAR; HAZAS, 2012) foi apresentado um PDR com um EKF de 9 estados para estimar a trajetória de um pedestre utilizando uma IMU montada no pé.

O vetor de estados δx , que representa as estimativas dos erros do sistema é dado por

(3.28). Sendo que δ representa o erro de um estado e, portanto, $\delta\phi$ os erros de orientação, δp os erros de posição no referencial de navegação e δv os erros de velocidade no referencial de navegação, cada um sendo um estado representado por um vetor com 3 elementos.

$$\delta x = [\delta\phi \quad \delta p \quad \delta v]^T \quad (3.28)$$

A partir dos dados do acelerômetro estacionário é possível estimar *roll* e *pitch* iniciais, enquanto se assume o valor zero para *yaw* pois não é possível estimar seu valor inicial apenas utilizando acelerômetros e giroscópios. A partir de (3.29) é possível construir a matriz de orientação (3.12).

$$\delta\phi = \begin{bmatrix} \arctan\left(\frac{f_y^n}{f_z^n}\right) \\ \arcsin\left(\frac{f_x^n}{g}\right) \\ 0 \end{bmatrix} \quad (3.29)$$

Como o modelo não é linear, a Equação (3.30) apresenta o modelo de transição linearizado. Onde δx_{k+1} são as estimativas dos erros dos estados, δx_k são as últimas estimativas dos erros dos estados calculadas em k , ω_k é o ruído de processo (de covariância $Q_{k+1} = E(\omega_{k+1}\omega_{k+1}^T)$) e F_{k+1} é a matriz de transição de estados dada por (3.31).

$$\delta x_{k+1} = F_{k+1}\delta x_k + \omega_k \quad (3.30)$$

$$F_{k+1} = \begin{bmatrix} I_{3x3} & 0_{3x3} & 0_{3x3} \\ 0_{3x3} & I_{3x3} & I_{3x3}\Delta t \\ -S_{k+1}\Delta t & 0_{3x3} & I_{3x3} \end{bmatrix} \quad (3.31)$$

Em F_{k+1} o termo S_{k+1} é uma matriz antissimétrica (3.32) construída a partir f_{k+1}^n , que relaciona a estimativa de erros de orientação a partir das forças específicas com a estimativa de erros velocidade.

$$S_{k+1} = \begin{bmatrix} 0 & -f_z^n & f_y^n \\ f_z^n & 0 & -f_x^n \\ -f_y^n & f_x^n & 0 \end{bmatrix} \quad (3.32)$$

O modelo de medição z_{k+1} aplicado quando a condição de ZUPT é verdadeira é dado por (3.33). Sendo H a matriz de medição dada por (3.34), e n_{k+1} é o ruído de medição (de covariância $R_{k+1} = E(n_{k+1}n_{k+1}^T)$).

$$z_{k+1} = H\delta x_{k+1} + n_{k+1} \quad (3.33)$$

$$H = \begin{bmatrix} 0_{3 \times 3} & 0_{3 \times 3} & I_{3 \times 3} \end{bmatrix} \quad (3.34)$$

A estimativa dos erros é computada para o estado $k + 1$, pela Equação (3.35), quando a medição para esse intervalo estiver disponível. Onde z_k é a medição e K é o ganho de Kalman, calculado por (3.36), P_k é a estimativa da matriz de covariância do erro, calculada por (3.37), R é a matriz de covariância do ruído de medição, e Q é a matriz de covariância do ruído de processo.

$$\delta x_{k+1} = K z_k \quad (3.35)$$

$$K = P_k H^T (H P_k H^T - R_{k+1})^{-1} \quad (3.36)$$

$$P_k = F_k P_{k-1} F_k^T - Q_k \quad (3.37)$$

Baseando-se em (FISCHER; SUKUMAR; HAZAS, 2012) pode-se inicializar Q como uma matriz diagonal 9×9 com os seguintes valores $[10_{1x3}^{-2} \text{rad/s}, 0_{1x3}, 10_{1x3}^{-2} \text{m/s}^2]$; P pode ser inicializada como uma matriz nula 9×9 ; e R como uma matriz diagonal 3×3 com os seguintes valores $[10_{1x3}^{-2} \text{m/s}]$. Uma relação importante ocorre entre Q e R , pois quanto menor o valor de Q com relação a R , maior é a confiança no modelo do sistema. De forma análoga, quanto menor o valor de R com relação a Q maior é a confiança nas medições.

Após o calculo do ganho de Kalman, P_k deve ser atualizada para P_{k+1} por (3.38).

$$P_{k+1} = (I - KH)P_k \quad (3.38)$$

Por fim os erros dos estados calculados por (3.35) podem ser utilizados para corrigir os estados. As correções de δv e δp podem ser vistas em (3.39) e (3.40), e a correção da orientação $\delta \phi$ em (3.41).

$$p_{k+1}^n = p_k^n - \delta p_{k+1}^n \quad (3.39)$$

$$v_{k+1}^n = v_k^n - \delta v_{k+1}^n \quad (3.40)$$

$$C_{b_{k+1}}^n = \left(\frac{2I_{3 \times 3} + \delta \Theta_{k+1} \Delta_t}{2I_{3 \times 3} - \delta \Theta_{k+1} \Delta_t} \right) C_{b_k}^n \quad (3.41)$$

Onde $\delta\Theta$ é a matriz antissimétrica para pequenos ângulos construída a partir dos erros estimados de *roll*, *pitch* e *yaw*, como pode ser visto na Equação (3.42).

$$\delta\Theta_{k+1} = \begin{bmatrix} 0 & -\phi_z & \phi_y \\ \phi_z & 0 & -\phi_x \\ -\phi_y & \phi_x & 0 \end{bmatrix} \quad (3.42)$$

Para um EKF de 15 estados, os mesmos princípios apresentados anteriormente podem ser seguidos, com o vetor de estados dado por (3.43) e matriz de transição por (3.44). Sendo $\delta\phi$, δp e δv estados já descritos, e $\delta\omega^b$, δa^b erros relacionados ao viés de medição (*bias*) dos giroscópios e acelerômetros, respectivamente.

$$\delta x = [\delta\phi \quad \delta\omega^b \quad \delta p \quad \delta v \quad \delta a^b] \quad (3.43)$$

$$F_{k+1} = \begin{bmatrix} I_{3x3} & C_{b_k}^n \Delta t & 0_{3x3} & 0_{3x3} & 0_{3x3} \\ 0_{3x3} & I_{3x3} & 0_{3x3} & 0_{3x3} & 0_{3x3} \\ 0_{3x3} & 0_{3x3} & I_{3x3} & I_{3x3} \Delta t & 0_{3x3} \\ -S_{k+1} \Delta t & 0_{3x3} & 0_{3x3} & I_{3x3} & C_{b_k}^n \Delta t \\ 0_{3x3} & 0_{3x3} & 0_{3x3} & 0_{3x3} & I_{3x3} \end{bmatrix} \quad (3.44)$$

4 Materiais e métodos

Neste capítulo serão apresentados os materiais utilizados na confecção do dispositivo de aquisição de dados e processamento dos dados, bem como os métodos e métricas de avaliação utilizados nas experiências e estudos dessa dissertação.

4.1 Dispositivo de aquisição de dados

Os primeiros protótipos do dispositivo de aquisição de dados buscaram uma forma prática de salvar os dados da IMU, assim foi decidido transferir via *bluetooth* as medições da IMU para um telefone celular onde eles seriam salvos para processamento posterior das trajetória no computador. Para a realização de testes, foi montado em uma *protoboard* um circuito contendo uma placa microcontrolada (baseada em Arduino¹), a IMU e um módulo *bluetooth*, que pode ser visto na Figura 13. Como os testes apresentaram bons resultados, se iniciou a confecção de um dispositivo de aquisição de dados.




Figura 13 – Montagem do primeiro protótipo.

O dispositivo de aquisição de dados foi construído utilizando uma caixa plástica compacta contendo a placa microcontrolada, as IMUs e uma bateria, Figura 14. Podendo a caixa ser facilmente acoplada ou desacoplada magneticamente a base amarrada ao tênis.

A placa microcontrolada utilizada no protótipo foi a ESP-32². Um dos motivos dessa escolha, além do baixo custo, foi a disponibilidade do *bluetooth* nativo integrado que permite a fácil transmissão dos dados coletados a qualquer outro dispositivo próximo com *bluetooth* pareado, como um telefone celular ou computador, facilitando as coletas e criação dos *datasets*.

A ESP-32 também possui interfaces de comunicação I^2C de fácil configuração e que foram utilizadas para comunicação com a IMU.

¹ <<https://www.arduino.cc/>>

² <https://www.espressif.com/sites/default/files/documentation/esp32_datasheet_en.pdf>




Figura 14 – Caixa do dispositivo de aquisição de dados e os sensores utilizados nas coletas.

A IMU utilizada foi a MPU-6050 da InvenSense³, que possui 3 acelerômetros e 3 giroscópios triaxiais, escolhida pelo seu baixo custo e facilidade de compra. Os fundos de escala, que são os maiores valores que os sensores podem medir, do acelerômetro pode ser ajustado para $\pm 2g$, $\pm 4g$, $\pm 8g$ e $\pm 16g$ e dos giroscópios para $\pm 250^\circ/s$, $\pm 500^\circ/s$, $\pm 1000^\circ/s$ e $\pm 2000^\circ/s$.

O dispositivo coleta os dados a uma taxa de 100 Hz e os transmite via *bluetooth* para o celular, onde são salvos como arquivos de texto utilizando um aplicativo de serial *bluetooth*⁴. Esse processo facilitou muito o trabalho de coleta, pois permitiu realizar diversas caminhadas seguidas e a reconfiguração dos fundos de escala dos sensores do dispositivo, Figura 15, sem a necessidade de reprogramação da placa microcontrolada.

Os dados salvos foram posteriormente processados pelos algoritmos, escritos em Python⁵, utilizando um computador Samsung Intel(R) Core(TM) i5-7200U CPU 2.50GHz 8GB. Um diagrama geral do processo de coleta dos dados, transmissão via *bluetooth* para o celular e o processamento no computador pode ser visto na Figura 16.


4.2 Ambiente de experimentação

O experimento foi realizado por homem de 37 anos, saudável, 1,70 m e 96 kg, utilizando tênis onde o protótipo foi amarrado rigidamente a face ventral do pé pelos cadarços, como pode ser visto na figura Figura 17. Esse local foi escolhido para a fixação da IMU pois segundo (WU et al., 2019), quando a IMU está fixada no pé, devido ao movimento periódico da caminhada, é possível considerar iguais a zero o deslocamento e a velocidade do pé quando ele estiver apoiado no solo, e assim o erro estimado a cada passo pode ser corrigido para atingir melhores resultados na estimativa da trajetória.

³ <<https://invensense.tdk.com/products/motion-tracking/6-axis/mpu-6050/>>

⁴ <https://play.google.com/store/apps/details?id=de.kai_morich.serial_bluetooth_terminal&hl=pt_BR&gl=US>

⁵ <<https://www.python.org>>

Figura 15 – Tela do terminal serial *bluetooth* do celular.

Para cada configuração do protótipo a ser estudada, foram realizadas 30 caminhadas, no sentido horário, em um circuito plano retangular fechado de percurso útil total 22,1 m, delimitado por duas linhas laterais distantes aproximadamente 0,4 m uma da outra, como pode ser visto na Figura 18. O plano foi escolhido devido a dificuldade de se realizar as medições em lugares inclinados e, como coloca (HARLE, 2013) a maioria dos testes de PDR são feitos em lugares planos por esta ser parte da configuração da maioria das construções. O início das caminhadas se dava no vértice superior esquerdo da figura, sempre com os pés alinhados e imóveis, e terminava com o retorno ao ponto de origem. A cobaia manteve os passos dentro dos limites das faixas, sem que isso afetasse o movimento natural da caminhada. No início de cada coleta os pés ficavam entre 2 e 5 segundos imóveis antes do início da caminhada, para inicialização dos estados do sistema.




Figura 16 – Diagrama da coleta de dados e do processamento.



Figura 17 – Protótipo amarrado ao pé pelos cadarços do sapato.

4.3 Algoritmos e configurações

Para reconstrução da trajetória foram utilizados 4 algoritmos baseados em um sistema de navegação inercial (INS) que utiliza um filtro de Kalman estendido (EKF) para estimar os erros dos estados do sistema e corrigi-los em uma atualização de zero velocidade (ZUPT), apresentado no diagrama de blocos da Figura 19a como IEZ. Todos os códigos gerados podem ser encontrados no link a seguir <<https://github.com/pajaraca/IEZ>>.

Variações do algoritmo se dão nas técnicas de correção de erro, quantidade de estados estimados do sistema e na estimativa de orientação, onde no primeiro e quarto métodos a orientação é atualizada pela integração das velocidades angulares, dada por (3.23); no segundo método onde a orientação é dada pelo filtro de Madgwick (abreviado para MAD) a estimativa é calculada por (3.18), e pode ser visto um diagrama desse processo na Figura 19b; e no terceiro método a orientação é estimada por outro filtro




Figura 18 – Esquema do percurso fechado utilizado para coleta de dados. A linha tracejada indica o percurso contabilizado como a distância total percorrida e o ponto vermelho o local de partida.

de Kalman, como mostra a Figura 19c. O quarto método utiliza um diagrama de blocos praticamente igual ao primeiro, sendo a quantidade de estados estimados é igual a 15 ao invés de 9, e que além do ZUPT utiliza também o ZARU como método de correção. A Tabela 3 detalha esses pontos.

Como é possível ver na Tabela 3 a principal diferença entre os algoritmos estudados se dá na estimativa de orientação do sistema. Como coloca (LI; WANG, 2019) em seu trabalho, a precisão da trajetória está ligada a orientação. Assim buscou-se nesse trabalho 3 formas de estimativa de orientação com distinções claras em algum aspecto para se conduzir os estudos de comparação entre as combinações algoritmo e configuração da IMU.




Figura 19 – Diagramas de blocos dos algoritmos.

Tabela 3 – Tabela dos algoritmos utilizados e suas diferenças

Algoritmos	Estados	Correção	Orientação
9IEZ	9	ZUPT	Equação (3.23)
9IEZ+MAD	9	ZUPT	Equação (3.18)
9IEZ+KF	9	ZUPT	Subseção 3.6.2
15IEZ+ZARU	15	ZUPT+ZARU	Equação (3.23)

As configurações definidas para o estudo foram os menores e maiores fundos de escala dos sensores, sendo $\pm 2g$ e $\pm 16g$ para os acelerômetros e $\pm 250^\circ/s$ e $\pm 2000^\circ/s$ para os giroscópios, combinadas conforme a Tabela 4. Não foram utilizadas todas as configurações devido a necessidade de limitar o escopo do trabalho, pois com mais 2 configurações para cada sensor o número de combinações entre eles passaria de 4 para 16 e as combinações entre algoritmos e configurações passaria de 16 para 64.

Tabela 4 – Combinações das configurações da unidade de medição inercial

Configuração	Acelerômetro	Giroscópio
C00	$\pm 2g$	$\pm 250^\circ/s$
C03	$\pm 2g$	$\pm 2000^\circ/s$
C30	$\pm 16g$	$\pm 250^\circ/s$
C33	$\pm 16g$	$\pm 2000^\circ/s$

4.4 Detecção da fase de apoio da caminhada e detecção da fase de apoio baseado no ângulo *pitch*

Foram utilizadas para detecção da fase de apoio, necessária para aplicar as técnicas ZUPT e ZARU, as condições C1 (magnitude da aceleração), C2 (variância da aceleração) e C3 (magnitude da velocidade angular) descritas na Seção 3.4. Para (HARLE, 2013), essas condições baseadas em faixas de valores fixos (*thresholds*) são uma forma típica de detecção da fase de apoio, sendo que a magnitude da aceleração e da velocidade angular são muito utilizadas. Nos estudos de (HOU; BERGMANN, 2020), ele indica que a utilização de *thresholds* facilita a detecção da fase de apoio, e apontou trabalhos que utilizaram simultaneamente a magnitude da aceleração, a variância da aceleração e a magnitude da velocidade angular para realizar essa tarefa.

Na Figura 20 é possível ver as condições C1, C2 e C3 aplicadas a uma caminhada com 7 passos. A condição de apoio é detectada quando as três condições são satisfeitas simultaneamente e o resultado é depois filtrado utilizando uma janela móvel de 10 medições para deixar o processo de detecção mais robusto. Em (JIMÉNEZ et al., 2010) uma janela de 11 medições foi utilizada, mas nesse estudo uma janela de apenas 10 medições foi utilizada. A Figura 21 apresenta os testes das condições e o resultado final.




Figura 20 – Condições C1, C2 e C3 sobrepostas aos dados medidos pelos sensores.

4.4.1 Detecção da fase de apoio baseado no ângulo *pitch*

O trabalho também propõe e analisa um método de detecção da fase de apoio utilizando o ângulo *pitch* do pé durante a caminhada. Analisando o ângulo é possível observar um movimento periódico que corresponde as fases de apoio e balanço do pé




Figura 21 – Resultados dos testes de detecção.

durante a caminhada. A Figura 22 mostra o gráfico do ângulo *pitch*, sendo que as regiões onde o pé está apoiado no chão estão contidas nas áreas limitadas pelas caixas azuis.

Para identificar se o pé está apoiado no chão o detector compara as estimativas de *pitch* com duas condições que devem ser satisfeitas simultaneamente.




Figura 22 – Estimativa do ângulo *pitch* para sensores fixados no pé de uma caminhada em terreno plano. Os retângulos azuis mostram as regiões em que o pé está apoiado no chão.

A condição $C1_{pitch}$ (4.1) compara o valor estimado de *pitch* (θ) com um valor de referência (θ_{ref}) obtido na inicialização do código, momento em que o pé está apoiado no chão durante alguns segundos e o valor de *pitch* pode ser estimado com boa precisão baseando-se nos dados dos acelerômetros. A faixa de valores de $\pm 6^\circ$ foi definida observando-

se a curva do ângulo *pitch*, de forma a diminuir falhas nas detecções (falsas detecções ou falta de detecção) no entorno do valor de referência calculado no início da caminhada.

$$C1_{pitch} = \begin{cases} \text{se } \theta_{ref} - 6^\circ < \theta_k < \theta_{ref} + 6^\circ, & 1 \\ \text{senão,} & 0 \end{cases} \quad (4.1)$$

A condição $C2_{pitch}$ (4.2) compara a variância de *pitch* em uma janela móvel n com o valor de referência de 6° . Esse valor foi obtido a partir da observação da variância no entorno dos pontos em que o pé está apoiado, que é uma região que tem variância menor que o restante da curva. Onde $\bar{\theta}_j$ é a média de n amostras. Para os dois casos, o valor de n utilizado no trabalho foi igual a 20.

$$C2_{pitch} = \begin{cases} \text{se } \frac{1}{n} \sum_{i=1}^{i=j+n} (\theta_i - \bar{\theta}_j)^2 < 6^\circ, & 1 \\ \text{senão,} & 0 \end{cases} \quad (4.2)$$

A detecção da fase de apoio do pé é então calculada para cada intervalo de tempo $k, k + 1$, pois cada estimativa de *pitch* (exceto na inicialização) só é calculada após o início do sistema de navegação inercial. A Figura 23 apresenta os resultados da detecção de fase apoio para uma caminhada com 7 passos.




Figura 23 – Resultado do teste de detecção de fase de apoio utilizando o ângulo *pitch*.

Para avaliação do detector proposto, os resultados das reconstruções de trajetória utilizando as condições $C1$ & $C2$ & $C3$ foram então comparadas aos resultados obtidos utilizando o detector baseado no ângulo *pitch* do pé para verificar a aplicabilidade do mesmo. Esse estudo pode ser visto na Seção 5.3.

4.5 Métricas de avaliação

Em (HOU; BERGMANN, 2020) é dito que não existe uma padronização para computar os erros de PDR's, com alguns trabalhos utilizando erros de posicionamento, erros de estimativa da distância percorrida, *root mean square* para cada eixo, etc.

Neste trabalho, para avaliar o desempenho das combinações entre as configurações das IMUs e os algoritmos, foram analisados os erros de posicionamento (4.3), o erro acumulado de distância (4.4) e os erros de altitude (4.5). O erro de posicionamento foi utilizado em (JIMÉNEZ et al., 2010) e (ZHANG; LIU; SUN, 2021) e o erro acumulado de distância em (ZHOU et al., 2014) e (POTTER et al., 2019). Como as coletas foram realizadas em terreno plano, o erro de altitude é o módulo da diferença entre 0 e altura final estimada pelo código. Vale ressaltar que o sistema não foi planejado e nem foram avaliados cenários com planos inclinados, escadas, escadas rolantes e elevadores.

$$EP = \frac{D_{if}}{D_T} \quad (4.3)$$

$$ED = \frac{D_E - D_T}{D_T} \quad (4.4)$$

$$EA = ||0 - Pz_{final}|| \quad (4.5)$$

Onde D_{if} representa a distância euclidiana entre a posição inicial e final, D_T é a distância total percorrida, D_E é a distância total estimada e Pz_{final} é a altitude final estimada. Todas as distâncias são dadas em metros.

Também foram analisados os tempos de execução de cada experimento, isto é, o tempo total em segundos que foi utilizado pelo laço principal de cada algoritmo para estimar todas as posições de uma caminhada.

Cada coleta foi processada pelos 4 algoritmos para se obter trajetórias, erros e tempo de execução, que foram então analisados.

5 Resultados e discussão

Neste capítulo serão apresentados os resultados obtidos utilizando os métodos apresentados na Tabela 3 em conjunto com as combinações de configurações da MPU-6050 listados na Tabela 4. Será feita a reconstrução das trajetórias das caminhadas realizadas, E posteriormente serão analisados os erros para comparação das combinações entre métodos e configurações.

Para a avaliação do detector da fase de apoio do pé baseado no ângulo *pitch*, proposto neste trabalho, apresentado na Subseção 4.4.1, foi feita uma análise a partir dos erros e tempo de execução obtidos utilizando o algoritmo 15IEZ+ZARU e a configuração $\pm 16g$ e $\pm 2000^\circ/s$ buscando verificar o desempenho deste detector em comparação ao detector apresentado na Seção 3.4.

5.1 Reconstrução das trajetórias

Todas as trajetórias reconstruídas em duas dimensões (2D), divididas por configuração, são apresentadas nas Figuras 24, 25, 26 e 27. Cada figura contém o processamento das 30 coletas realizadas por configuração, divididas pelos métodos estudados. As trajetórias estão sobrepostas e cada uma é representada por uma cor.

Visualmente verificando as Figuras 24b e 26b é possível visualizar que o giroscópio configurado em $\pm 250^\circ/s$ e a orientação estimada pelo filtro de Madgwick afetaram negativamente a reconstrução das trajetórias. Nessas mesmas figuras, as reconstruções oriundas dos outros algoritmos apresentam trajetórias condizentes com o percurso realizado, mesmo tendo um aspecto mais serrilhado. Esse comportamento serrilhado é referente as correções feitas pelo EKF durante os períodos estacionários, quanto mais acentuado ele for maior foi a correção necessária.

Nas Figuras 25 e 27, onde o giroscópio está configurado em $\pm 2000^\circ/s$, é possível visualizar trajetórias mais estáveis e com menos serrilhados, mesmo com algumas sendo anômalas.




Figura 24 – Reconstrução das trajetórias para configuração C00







Figura 25 – Reconstrução das trajetórias para configuração C03




(a) 9IEZ



(b) 9IEZ+MAD




(c) 9IEZ+KF




(d) 15IEZ+ZARU


Figura 26 – Reconstrução das trajetórias para configuração C30




(a) 9IEZ



(b) 9IEZ+MAD



(c) 9IEZ+KF



(d) 15IEZ+ZARU

Figura 27 – Reconstrução das trajetórias para configuração C33

5.2 Análise dos erros e tempo de execução

A normalidade dos valores dos erros foi verificada utilizando gráficos quantil-quantil, Figura 28, e o teste de Shapiro-Wilk. Os gráficos quantil-quantil além de efetivos são as ferramentas mais utilizadas para verificar a normalidade de dados, porém é recomendado que algum teste de normalidade mais formal e numérico seja utilizado em conjunto com eles (RAZALI; WAH et al., 2011). Um teste de normalidade é o de Shapiro-Wilk (RAZALI; WAH et al., 2011) (HANUSZ; TARASINSKA; ZIELINSKI, 2016). Os testes de Shapiro-Wilk foram realizados com uma confiança de 95%. Para reduzir distorções causadas por falhas nas coletas e medições, foram desconsiderados valores fora dos limites de 3 desvios padrão.




Figura 28 – Exemplo de gráfico quantil-quantil.

Na Figura 29 temos os diagramas de caixas dos erros estimados e os tempos de execução divididos por algoritmo e utilizando todas as medições realizadas. Nas Figuras 29a, 29b e 29c é possível verificar que o método que utiliza o filtro de Madgwick para estimar a orientação possui intervalos interquartis que apontam variabilidade e mediana mais elevados em comparação com os outros métodos. Com relação aos tempos de execução, a Figura 29d mostra que o algoritmo 9IEZ apresenta menor mediana que os outros.

Na Figura 30 são apresentados os diagramas de caixas de todos os erros estimados e os tempos de execução por configurações dos sensores. Nas Figuras 30a, 30b e 30c possível verificar que a configuração de $\pm 250^\circ/s$ do giroscópio, influencia no aumento das variabilidades dos erros e com diversos pontos fora dos intervalos interquartis, enquanto as configurações com o giroscópio em $\pm 2000^\circ/s$ tem menor variabilidade. Já a Figura 30d aponta que as configurações não tem grande influência nos tempos de execução.

Nas Figuras 31, 32 e 33 é possível ver uma discrepância nas variâncias e medianas dos intervalos interquartis que combinam o filtro de Madgwick com as configurações dos




Figura 29 – Diagramas de caixas dos erros por algoritmo.

giroscópios em $\pm 250^\circ/s$. Para os erros de posicionamento as maiores médias ocorreram o algoritmo 9IEZ+MAD, sendo 0.12573 e 0.18287 para as configurações $\pm 2g$ e $\pm 250^\circ/s$ e, $\pm 16g$ e $\pm 250^\circ/s$. O mesmo 9IEZ+MAD aliado as configurações $\pm 2g$ e $\pm 250^\circ/s$ e, $\pm 16g$ e $\pm 250^\circ/s$ apresentam também o pior desempenho para os erros de distância acumulada, sendo 1.56511 e 1.73145 as médias dos erros, e também para os erros de altitude, com 1.76186 e 1.44616 de médias de erro. Com relação aos tempos de execução o 9IEZ demonstrou ser a menos custosa para todas as configurações, conforme a Figura 34.

Para distinguir quais combinações entre método e configurações tem melhor desempenho que as outras foi conduzido um teste t de Welch para verificar a hipótese das médias dos erros serem iguais e identificar o desempenho dos algoritmos e configurações. O teste t de Welch é utilizado para comparar a médias entre duas populações, testando a hipótese de que elas possuem a mesma média (WINTER, 2013). Este teste pode ser utilizado mesmo quando as amostras tem tamanhos e/ou variâncias diferentes (AHAD; YAHAYA, 2014). Como o teste também funciona com amostras de tamanhos diferentes, não foi um problema a exclusão de pontos discrepantes. Os testes t de Welch foram realizados com




Figura 30 – Diagramas de caixas dos erros por configuração.

uma confiança de 95%.

As duas menores médias, para o erro de posicionamento e distância acumulada, ocorreram com o algoritmo 15IEZ+ZARU e as configurações $\pm 2g$ e $\pm 2000^\circ/s$, e $\pm 16g$ e $\pm 2000^\circ/s$, e o teste apontou que elas podem ser consideradas iguais. As médias foram de 0.01342 e 0.00982 para os erro de posição e 0.09579 e 0.09566 para o erro de distância acumulada.

Para os erros de altitude as menores médias ocorreram para a configuração de $\pm 2g$ e $\pm 250^\circ/s$ e os algoritmos 9IEZ e 9IEZ+KF, sendo elas 0.18426 e 0.20033 respectivamente. O teste apontou que essas duas combinações podem ser consideradas iguais.

O algoritmo 9IEZ teve os menores tempos de execução em todos os grupos de algoritmo e configuração. Comparando todas as combinações, a menor média para o tempo de execução se deu com a combinação 9IEZ e as configurações $\pm 2g$ e $\pm 2000^\circ/s$, sendo ela 1.08599. O teste apontou que essa combinação pode ser considerada igual a combinação entre o algoritmo 9IEZ e a configuração $\pm 16g$ e $\pm 2000^\circ/s$, que teve média de 1.11654.




Figura 31 – Diagrama de caixas dos erros de posicionamento por algoritmo e configuração.




Figura 32 – Diagrama de caixas dos erros acumulados de distância por algoritmo e configuração.

Todas as médias dos erros de posicionamento, por algoritmo e combinação, podem ser vistas na Tabela 5, dos erros de distância acumulada na Tabela 6 e dos erros de altitude na Tabela 7. A Tabela 8 apresenta as médias dos tempos de execução.




Figura 33 – Diagrama de caixas dos erros de altitude por algoritmo e configuração.




Figura 34 – Diagrama de caixas dos tempos de execução por algoritmo e configuração.

Tabela 5 – Média de erros de posicionamento

Algoritmos	Configurações			
	<i>C00</i>	<i>C03</i>	<i>C30</i>	<i>C33</i>
9IEZ	0.02477	0.02484	0.04433	0.02263
9IEZ+MAD	0.12573	0.04233	0.18287	0.04506
9IEZ+KF	0.02253	0.02232	0.04442	0.02018
15IEZ+ZARU	0.01471	0.01342	0.03561	0.00982

Tabela 6 – Média de erros de distância acumulada

Algoritmos	Configurações			
	<i>C00</i>	<i>C03</i>	<i>C30</i>	<i>C33</i>
9IEZ	0.21927	0.22546	0.18443	0.18053
9IEZ+MAD	1.56811	0.23870	1.73145	0.23147
9IEZ+KF	0.21826	0.24288	0.17872	0.20097
15IEZ+ZARU	0.20237	0.09579	0.21085	0.09566

Tabela 7 – Média de erros de altitude

Algoritmos	Configurações			
	<i>C00</i>	<i>C03</i>	<i>C30</i>	<i>C33</i>
9IEZ	0.18426	0.77960	1.06814	0.58955
9IEZ+MAD	1.76186	0.61892	1.44616	0.40434
9IEZ+KF	0.20033	0.78824	1.07481	0.59684
15IEZ+ZARU	0.40666	0.83520	1.02897	0.64060

Tabela 8 – Média dos tempos de execução

Algoritmos	Configurações			
	<i>C00</i>	<i>C03</i>	<i>C30</i>	<i>C33</i>
9IEZ	1.24708	1.11387	1.08599	1.11654
9IEZ+MAD	1.43080	1.38165	1.26690	1.30850
9IEZ+KF	1.49051	1.35805	1.30649	1.37733
15IEZ+ZARU	1.36397	1.25783	1.19851	1.23642

5.3 Comparação dos detectores de fase de apoio

A Figura 35 apresenta as reconstruções das trajetórias da configuração $\pm 16g$ e $\pm 2000^\circ/s$ utilizando o algoritmo 15IEZ+ZARU, sendo que a Figura 35a utiliza as condições C1, C2 e C3 para detecção da fase de apoio, enquanto a Figura 35b utiliza as condições baseadas no ângulo *pitch*.




Figura 35 – Reconstrução das trajetórias utilizando algoritmo 15IEZ+ZARU para configuração C33

A Figura 36 apresenta os diagramas de caixas dos erros de posicionamento, distância acumulada e altitude e também o tempo de execução. Analisando os diagramas não é possível visualizar grandes diferenças nas variâncias e as medianas parecem muito próximas, exceto pelos erros de altitude que aparentou uma redução no valor da mediana.

Para verificar se existem diferenças nas médias foi conduzido um teste t de Welch, realizados com uma confiança de 95%, que apontou que as médias podem ser consideradas iguais para todos os erros e também para o tempo de execução. A Tabela 9 apresenta as médias dos erros e dos tempos de execução.

Tabela 9 – Média dos erros e dos tempos de execução

	Detector			
	<i>C1&C2&C3</i>		<i>Pitch</i>	
	Média	Desvio padrão	Média	desvio padrão
Erros de posicionamento	0.00402	0.00092	0.00864	0.00227
Erros de distância acumulada	0.10393	0.01503	0.11238	0.01097
Erros de altitude	0.43265	0.14002	0.35009	0.19183
Tempo de execução	1.76007	0.55837	1.91496	0.92625




Figura 36 – Comparação entre os detectores de fase de apoio baseados em C1&C2&C3 e *pitch* utilizando algoritmo 15IEZ+ZARU e a configuração C33.

6 Conclusões

Este trabalho apresentou um estudo sobre as configurações da IMU MPU-6050 utilizando técnicas de PDR baseadas em EKF. Foram implementados sistemas de navegação que se valeram apenas dos acelerômetros e giroscópios da IMU, sem auxílio de infraestrutura externa ou outros sensores e aplicando as técnicas de correção de erro ZUPT e também ZUPT+ZARU. Essas técnicas, da forma que foram implementadas precisam que os sensores estejam fixados no pé devido a mecânica da caminhada humana.

A reconstrução das trajetórias em $2D$ aponta que mesmo os resultados mais ruidosos ainda apresentam um formato retangular parecido com o caminho real percorrido. As reconstruções em que a estimativa de orientação pelo filtro de Madgwick foram realizadas com o giroscópio configurado em $\pm 250^\circ/s$ tiveram os resultados afetados negativamente.

Os resultados das análises dos erros de posicionamento e distância acumulada apontam que na utilização da MPU-6050 deve-se evitar a configuração do giroscópio em $\pm 250^\circ/s$ aliada a estimativa de orientação do INS sendo dada pelo filtro de Madgwick. A configuração com melhores resultados nas reconstruções de trajetória em $2D$ foi a dos maiores fundos de escala, $\pm 16g$ e $\pm 2000^\circ/s$, aliada ao algoritmo 15IEZ+ZARU, com uma média de erros de posicionamento de 0.98% da distância total percorrida, e erros de distância acumulada de 9.5% da distância total percorrida.

Em (WU et al., 2019) é dito que alguns erros de distância acumulada excedem 15% para IEZ e 8% para IEZ+ZARU, enquanto um sistema que utilize um IEZ+ZARU aliado ainda a outros métodos de correção como HDR (*heuristic heading reduction*) e bússolas digitais pode apresentar erros entre 0.38% e 1.5%. Como não existe um método padrão para comparar os erros dos sistemas de PDR, (HOU; BERGMANN, 2020) ao analisar diversos estudos calculou um erro percentual para melhorar a compreensão dos resultados dos trabalhos que seu estudo analisou, e esse erro percentual variou entre 0.07% e 10.07%. Os erros de distância acumulada do sistema apresentado neste trabalho se mostram condizentes com os de outros sistemas apresentados na literatura, porém apontam a possibilidade de melhoria nos filtros para melhoria dos resultados.

Em (ZHOU et al., 2014) uma média de erro de posicionamento de 0.825% da distância total percorrida, foi apresentada para um PDR baseado em EKF, ZUPT e uma IMU contendo bússola digital para estimar a orientação do sistema. Já em (DENG et al., 2018) os erros de posicionamento quando utilizado um PDR baseado em IEZ ficaram entre 2.3% e 2.8% da distância total percorrida em um dos testes realizados para avaliação do sistema, já quando foi utilizada a técnica de correção IHDE (*improved heuristic drift elimination*) apresentada no trabalho, os erros ficaram entre 0.4% e 0.7%. Esses erros

apresentados mostram que o erro de posicionamento de 0.98% apresentado pelo sistema estão condizente com outros trabalhos da literatura.

A configuração que obteve a menor média de erros de altitude foi a $\pm 2g$ e $\pm 250^\circ/s$, apontando que quando a altitude for o parâmetro de maior importância, deve esta configuração ser utilizada em conjunto com o algoritmo 9IEZ, pois essa combinação obteve uma média de erro de altitude de 0.18426m.

O algoritmo com menor tempo de execução é o 9IEZ. Essa diferença se dá pelos algoritmos 9IEZ+MAD e 9IEZ+KF estimarem a orientação com processos auxiliares que demandam mais tempo na execução, enquanto o algoritmo 15IEZ+ZARU apesar de utilizar o mesmo método de estimativa de orientação que o 9IEZ, precisa processar matrizes de dimensões maiores devido a quantidade de estados estimados.

O detector de fase de apoio baseado no ângulo *pitch* do pé, proposto neste trabalho, se mostrou equiparável ao detector baseado em múltiplas condições. Ele conseguiu satisfatoriamente detectar a velocidade zero do pé para que o EKF pudesse corrigir os erros de posição.

6.1 Contribuições

A proposta principal deste trabalho, de analisar a aplicabilidade da IMU de baixo custo MPU-6050 na reconstrução de trajetória de caminhada utilizando técnicas de PDR foi verificada e, se demonstrou que é possível aplicar essa solução no contexto apresentado.

Outras contribuições dessa dissertação são:

- Desenvolvimento de um sistema para coleta de dados de uma IMU de baixo custo, apresentado na Seção 4.1, que pode ser utilizado em experimentos e aplicações semelhantes (repositório com mais informações e detalhes <<https://github.com/pajaraca/IEZ>>);
- Avaliação dos impactos das configurações da IMU na reconstrução das trajetórias;
- Avaliação dos algoritmos com relação ao tempo de execução, o que pode direcionar trabalhos que pretendem executá-los em tempo real e no próprio dispositivo (*edge computing*);
- Apresentação de um detector de zero velocidade baseado no ângulo *pitch* do pé, descrito na Subseção 4.4.1, que pode ser uma alternativa para aplicações em tempo real;
- Artigo publicado com resultados preliminares da dissertação no XI Simpósio Brasileiro de Engenharia de Sistemas Computacionais (ROCHA et al., 2021).

6.2 Trabalhos futuros

Para trabalhos futuros, deverão ser investigados o comportamento dos erros em outros cenários como longas caminhadas de vários minutos, circuitos assimétricos e locais com desnível conhecido, de forma a identificar variadas limitações do sistema e formas de combatê-las.

Utilizar outros filtros como o UKF (*unscented Kalman filter*) para estimativa dos erros e outras formas de correção baseadas em métodos que não necessariamente precisem de infraestrutura externa ou sensores adicionais deverão ser exploradas, como por exemplo o HUPT (*height update algorithm*) um método que força a altitude para 0 quando se tem certeza que o movimento se dá em um plano.

Investigar outros cenários para aplicação de técnicas de PDR e sistemas de navegação inercial de baixo custo, como por exemplo, monitoramento de animais criados a pasto ou aplicações em tempo real.

Por fim, a análise dos erros, das estimativas de posição e trajetória em 3 dimensões, com a utilização de fusão de outros sensores, assim como outros métodos de correção dos erros baseados nesses dispositivos como, por exemplo, a estimativa do ângulo *yaw* por magnetômetros e/ou a estimativa da altura do pé durante a caminhada utilizando barômetros.

Referências

AGGARWAL, P. *MEMS-based integrated navigation*. [S.l.]: Artech House, 2010. Citado na página [13](#).

AHAD, N. A.; YAHAYA, S. S. S. Sensitivity analysis of welch'st-test. In: AMERICAN INSTITUTE OF PHYSICS. *AIP Conference proceedings*. [S.l.], 2014. v. 1605, n. 1, p. 888–893. Citado na página [45](#).

AHMED, D. B. et al. A survey on test and evaluation methodologies of pedestrian localization systems. *IEEE Sensors Journal*, IEEE, v. 20, n. 1, p. 479–491, 2019. Citado na página [1](#).

CHAO, H. et al. A comparative evaluation of low-cost imus for unmanned autonomous systems. In: IEEE. *2010 IEEE Conference on Multisensor Fusion and Integration*. [S.l.], 2010. p. 211–216. Citado 3 vezes nas páginas [15](#), [12](#) e [13](#).

DENG, Z. et al. An improved heuristic drift elimination method for indoor pedestrian positioning. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 6, p. 1874, 2018. Citado 2 vezes nas páginas [2](#) e [53](#).

DIAZ, E. M.; AHMED, D. B.; KAISER, S. A review of indoor localization methods based on inertial sensors. *Geographical and Fingerprinting Data to Create Systems for Indoor Positioning and Indoor/Outdoor Navigation*, Elsevier, p. 311–333, 2019. Citado na página [21](#).

DIAZ, E. M.; KAISER, S.; AHMED, D. B. Height error correction for shoe-mounted inertial sensors exploiting foot dynamics. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 3, p. 888, 2018. Citado 2 vezes nas páginas [2](#) e [15](#).

DIEBEL, J. Representing attitude: Euler angles, unit quaternions, and rotation vectors. *Matrix*, v. 58, n. 15-16, p. 1–35, 2006. Citado 2 vezes nas páginas [19](#) e [20](#).

FAN, Q. et al. An optimal enhanced kalman filter for a zupt-aided pedestrian positioning coupling model. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 5, p. 1404, 2018. Citado 2 vezes nas páginas [13](#) e [17](#).

FISCHER, C.; SUKUMAR, P. T.; HAZAS, M. Tutorial: Implementing a pedestrian tracker using inertial sensors. *IEEE pervasive computing*, IEEE, v. 12, n. 2, p. 17–27, 2012. Citado 6 vezes nas páginas [13](#), [6](#), [15](#), [16](#), [25](#) e [27](#).

FOXLIN, E. Pedestrian tracking with shoe-mounted inertial sensors. *IEEE Computer graphics and applications*, IEEE, v. 25, n. 6, p. 38–46, 2005. Citado 3 vezes nas páginas [5](#), [10](#) e [25](#).

GREWAL, M. S.; WEILL, L. R.; ANDREWS, A. P. *Global positioning systems, inertial navigation, and integration*. [S.l.]: John Wiley & Sons, 2007. Citado 4 vezes nas páginas [9](#), [10](#), [12](#) e [13](#).

- GROVES, P. D. Navigation using inertial sensors [tutorial]. *IEEE Aerospace and Electronic Systems Magazine*, IEEE, v. 30, n. 2, p. 42–69, 2015. Citado 4 vezes nas páginas 12, 13, 14 e 18.
- HAK, M. Gad-el. *The MEMS handbook*. [S.l.]: CRC press, 2001. Citado na página 12.
- HANUSZ, Z.; TARASINSKA, J.; ZIELINSKI, W. Shapiro-wilk test with known mean. *REVSTAT-Statistical Journal*, Instituto Nacional de Estatística, v. 14, n. 1, p. 89–100, 2016. Citado na página 44.
- HARLE, R. A survey of indoor inertial positioning systems for pedestrians. *IEEE Communications Surveys & Tutorials*, Ieee, v. 15, n. 3, p. 1281–1293, 2013. Citado 5 vezes nas páginas 13, 1, 5, 31 e 36.
- HOU, X.; BERGMANN, J. Pedestrian dead reckoning with wearable sensors: A systematic review. *IEEE Sensors Journal*, IEEE, v. 21, n. 1, p. 143–152, 2020. Citado 6 vezes nas páginas 1, 5, 7, 36, 39 e 53.
- ILYAS, M. et al. Drift reduction in pedestrian navigation system by exploiting motion constraints and magnetic field. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 16, n. 9, p. 1455, 2016. Citado na página 2.
- JI, M. et al. Improved pedestrian positioning with inertial sensor based on adaptive gradient descent and double-constrained extended kalman filter. *Complexity*, Hindawi, v. 2020, 2020. Citado na página 2.
- JIMÉNEZ, A. R. et al. Indoor pedestrian navigation using an ins/ekf framework for yaw drift reduction and a foot-mounted imu. In: IEEE. *2010 7th Workshop on Positioning, Navigation and Communication*. [S.l.], 2010. p. 135–143. Citado 7 vezes nas páginas 6, 7, 15, 16, 23, 36 e 39.
- KEMPE, V. *Inertial MEMS: principles and practice*. [S.l.]: Cambridge University Press, 2011. Citado 2 vezes nas páginas 12 e 13.
- KOK, M.; HOL, J. D.; SCHÖN, T. B. Using inertial sensors for position and orientation estimation. *arXiv preprint arXiv:1704.06053*, 2017. Citado 2 vezes nas páginas 10 e 12.
- LAWRENCE, A. *Modern inertial technology: navigation, guidance, and control*. [S.l.]: Springer Science & Business Media, 2012. Citado na página 10.
- LI, H. et al. Research on multi-sensor pedestrian dead reckoning method with ukf algorithm. *Measurement*, Elsevier, v. 169, p. 108524, 2021. Citado na página 7.
- LI, X.; WANG, Y. Evaluation of ahrs algorithms for foot-mounted inertial-based indoor navigation systems. *Open Geosciences*, De Gruyter, v. 11, n. 1, p. 48–63, 2019. Citado 2 vezes nas páginas 7 e 33.
- MA, M. et al. An adaptive zero velocity detection algorithm based on multi-sensor fusion for a pedestrian navigation system. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 10, p. 3261, 2018. Citado na página 2.
- MADGWICK, S. An efficient orientation filter for inertial and inertial/magnetic sensor arrays. *Report x-io and University of Bristol (UK)*, v. 25, p. 113–118, 2010. Citado na página 19.

MADGWICK, S. O.; HARRISON, A. J.; VAIDYANATHAN, R. Estimation of imu and marg orientation using a gradient descent algorithm. In: IEEE. *2011 IEEE international conference on rehabilitation robotics*. [S.l.], 2011. p. 1–7. Citado 2 vezes nas páginas 7 e 20.

MAHONY, R.; HAMEL, T.; PFLIMLIN, J.-M. Nonlinear complementary filters on the special orthogonal group. *IEEE Transactions on automatic control*, IEEE, v. 53, n. 5, p. 1203–1218, 2008. Citado na página 7.

NILSSON, J.-O. et al. Foot-mounted ins for everybody-an open-source embedded implementation. In: *Proceedings of IEEE/ION PLANS 2012*. [S.l.: s.n.], 2012. p. 140–145. Citado na página 6.

POTTER, M. V. et al. Effect of imu design on imu-derived stride metrics for running. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 19, n. 11, p. 2601, 2019. Citado na página 39.

QIU, S. et al. Inertial/magnetic sensors based pedestrian dead reckoning by means of multi-sensor fusion. *Information Fusion*, Elsevier, v. 39, p. 108–119, 2018. Citado na página 6.

RAJAGOPAL, S. Personal dead reckoning system with shoe mounted inertial sensors. *Master's Degree Project, Stockholm, Sweden*, Citeseer, 2008. Citado na página 16.

RAZALI, N. M.; WAH, Y. B. et al. Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. *Journal of statistical modeling and analytics*, v. 2, n. 1, p. 21–33, 2011. Citado na página 44.

ROCHA, R. N. et al. Avaliação de unidade de medição inercial utilizando técnicas de reconstrução de trajetória de pedestres. In: SBC. *Anais Estendidos do XI Simpósio Brasileiro de Engenharia de Sistemas Computacionais*. [S.l.], 2021. p. 24–31. Citado 2 vezes nas páginas 2 e 54.

SAVAGE, P. G. Strapdown inertial navigation integration algorithm design part 1: Attitude algorithms. *Journal of guidance, control, and dynamics*, v. 21, n. 1, p. 19–28, 1998. Citado na página 10.

SKOG, I.; HÄNDEL, P. A low-cost gps aided inertial navigation system for vehicle applications. In: IEEE. *2005 13th European Signal Processing Conference*. [S.l.], 2005. p. 1–4. Citado na página 23.

SKOG, I. et al. Zero-velocity detection—an algorithm evaluation. *IEEE transactions on biomedical engineering*, IEEE, v. 57, n. 11, p. 2657–2666, 2010. Citado 2 vezes nas páginas 15 e 16.

STRAETEN, M. Development of a standalone pedestrian navigation system utilizing sensor fusion strategies. University of Windsor, 2019. Citado 2 vezes nas páginas 13 e 23.

SUKUMAR, P. T. Enhanced stance phase detection and extended kalman filtering for strapdown pedestrian dead reckoning msc in mobile and ubiquitous computing. 2010. Citado 3 vezes nas páginas 13, 16 e 17.

- TIAN, X. et al. A novel zero velocity interval detection algorithm for self-contained pedestrian navigation system with inertial sensors. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 16, n. 10, p. 1578, 2016. Citado na página 2.
- TITTERTON, D.; WESTON, J. L. *Strapdown inertial navigation technology*. [S.l.]: IET, 2004. v. 17. Citado 6 vezes nas páginas 13, 9, 10, 12, 14 e 18.
- WELCH, G.; BISHOP, G. et al. An introduction to the kalman filter. Chapel Hill, NC, USA, 1995. Citado 3 vezes nas páginas 13, 24 e 25.
- WINTER, J. C. D. Using the student's t-test with extremely small sample sizes. *Practical Assessment, Research, and Evaluation*, v. 18, n. 1, p. 10, 2013. Citado na página 45.
- WOODMAN, O. J. *An introduction to inertial navigation*. [S.l.], 2007. Citado 5 vezes nas páginas 13, 10, 14, 18 e 21.
- WU, X. et al. Pedestrian inertial navigation based on cnn-svm gait recognition algorithm. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2021. v. 1903, n. 1, p. 012043. Citado na página 2.
- WU, Y. et al. A survey of the research status of pedestrian dead reckoning systems based on inertial sensors. *International Journal of Automation and Computing*, Springer, v. 16, n. 1, p. 65–83, 2019. Citado 5 vezes nas páginas 1, 5, 7, 30 e 53.
- YAMAUCHI, K.; BHANU, B.; SAITO, H. Recognition of walking humans in 3d: Initial results. In: IEEE. *2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.], 2009. p. 45–52. Citado na página 15.
- ZHANG, L.; LIU, Y.; SUN, J. A hybrid framework for mitigating heading drift for a wearable pedestrian navigation system through adaptive fusion of inertial and magnetic measurements. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 11, n. 4, p. 1902, 2021. Citado 4 vezes nas páginas 2, 6, 7 e 39.
- ZHANG, W.; WEI, D.; YUAN, H. The improved constraint methods for foot-mounted pdr system. *Ieee Access*, IEEE, v. 8, p. 31764–31779, 2020. Citado na página 2.
- ZHANG, Y. et al. An indoor localization method based on the combination of indoor map information and inertial navigation with cascade filter. *Journal of Sensors*, Hindawi, v. 2021, 2021. Citado 2 vezes nas páginas 13 e 15.
- ZHENG, L. et al. A 3d indoor positioning system based on low-cost mems sensors. *Simulation Modelling Practice and Theory*, Elsevier, v. 65, p. 45–56, 2016. Citado 2 vezes nas páginas 1 e 7.
- ZHOU, L. et al. How we found our imu: Guidelines to imu selection and a comparison of seven imus for pervasive healthcare applications. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 15, p. 4090, 2020. Citado na página 12.
- ZHOU, X.-c. et al. Pedestrian navigation with foot-mounted inertial sensors in wearable body area networks. In: IEEE. *Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2014 Asia-Pacific*. [S.l.], 2014. p. 1–7. Citado 3 vezes nas páginas 6, 39 e 53.

ZHU, R. et al. Enhanced heuristic drift elimination with adaptive zero-velocity detection and heading correction algorithms for pedestrian navigation. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 4, p. 951, 2020. Citado na página [2](#).