

UNIVERSIDADE FEDERAL DE SÃO CARLOS–
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA–
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA–

Daniel Diegues

**Método automático de calibração de
IMU baseado no filtro de Kalman**

São Carlos
2021

Daniel Diegues

**Método automático de calibração de
IMU baseado no filtro de Kalman**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos e Eletrônicos

Orientador: Prof. Dr. Roberto Santos Inoue

São Carlos

2021



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Daniel Diegues, realizada em 17/12/2021.

Comissão Julgadora:

Prof. Dr. Roberto Santos Inoue (UFSCar)

Prof. Dr. Samuel Lourenço Nogueira (UFSCar)

Prof. Dr. Adriano Almeida Goncalves Siqueira (USP)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.

Agradecimentos

Agradeço primeiramente a Deus que sempre me fortaleceu e me iluminou em todos os momentos desse projeto e em toda minha vida, sem Ele nada poderia ter acontecido. Também agradeço a Nossa Senhora que intercede por nós abrindo os caminhos e passando na frente de todas as necessidades. Agradeço a minha esposa Janine que sempre me apoia em minhas decisões e projetos e assumiu esse desafio do mestrado junto comigo e teve muita paciência comigo em todo esse processo. Agradeço a minha família que sempre me apoiou em todas as necessidades possibilitando que pudesse desenvolver o projeto. Por fim agradeço ao professor Roberto Santos Inoue que com muita atenção e dedicação me direcionou e ajudou em todas as etapas do projeto e desenvolvimento do trabalho. Agradeço todos os colegas de turma e professores em especial professor Samuel Lourenço Nogueira pelo apoio e todas as contribuições dadas a esse trabalho.

Seja forte e corajoso! Não se apavore nem desanime, pois o Senhor, o seu Deus, estará com você por onde você andar. (Josué 1:9)

Resumo

As IMUs são largamente utilizadas em aplicações que exigem medidas de posição e atitude. E com a produção de IMUs de baixo custo, tem sido possível expandir essa utilização para além de aplicações militares e de alto custo, atingindo dispositivos de consumo como celulares, tecnologias vestíveis, equipamentos de exercícios físicos e reabilitação. Porém toda IMU precisa ser calibrada para o uso e, portanto, além do sensor, existe o custo de calibração. Os métodos de calibração existentes, ou são de propriedade dos fabricantes, ou são de alto custo e exigem equipamentos e laboratórios específicos, ou ainda utilizam métodos não ótimos de estimativa de parâmetros. Neste trabalho é proposto a sistematização de métodos de calibração de baixo custo, com execução simples realizada pelo usuário e que forneça resultados otimizados mais próximos dos alcançados por métodos de calibração de alto custo. O processo de captura dos dados é baseado em um método de multi-posição que para ser executado não exige equipamentos extras, além do próprio sensor e computador. Foram realizados experimentos com três IMUs comerciais, uma de alto custo calibrada pelo fabricante, utilizada como referência e duas de baixo custo, não calibradas. A leitura bruta do acelerômetro de cada IMU foi calibrada utilizando as quatro formas do filtro de Kalman desenvolvidos neste trabalho e avaliado os erros obtidos comparando, a IMU de alto custo e a calibração com os parâmetros estimados, mostrando o bom desempenho dos métodos.

Palavras-chave: IMU. Filtro de Kalman. Calibração.

Abstract

IMUs are widely used in applications that require position and attitude measurements. And with the production of low-cost IMUs, it has been possible to expand this use beyond military and high-cost applications, reaching consumer devices such as cell phones, wearable technologies, physical exercise and rehabilitation equipment. But every IMU needs to be calibrated for use and therefore, in addition to the sensor, there is the cost of calibration. Existing calibration methods are either proprietary to the manufacturers, or they are expensive and require specific equipment and laboratories, or they use non-optimal methods of parameter estimation. This work proposes the systematization of low cost calibration methods, with simple execution performed by the user and that provides optimized results closer to those achieved by high cost calibration methods. The data capture process is based on a multi-position method that does not require extra equipment, besides the sensor and computer itself. The experiments were executed with three commercial IMUs, one high-cost calibrated by the manufacturer, used as a reference, and two low-cost, uncalibrated. The raw accelerometer reading of each IMU was calibrated using the four forms of the Kalman filter developed in this work and the errors obtained were evaluated by comparing the high cost IMU and the calibration with the estimated parameters, showing the good performance of the methods.

Keywords: IMU. Kalman filter. Calibration.

Lista de ilustrações

Figura 1 – Fluxograma de erros dos sensores.(Adaptado de (AGGARWAL et al., 2010)).	22
Figura 2 – Representação gráfica dos erros nos sensores.	28
Figura 3 – Desalinhamento entre os eixos do acelerômetro.	29
Figura 4 – Diagrama de blocos do modelo de erro do acelerômetro.	29
Figura 5 – Esquema das 18 orientações da IMU com relação ao vetor gravidade.	40
Figura 6 – Fluxograma geral do processo de calibração.	42
Figura 7 – IMUs utilizadas nos testes.	43
Figura 8 – Capturas da aceleração bruta IMUs com marcação de períodos estáticos.	46
Figura 9 – Períodos estáticos das capturas de aceleração das IMUs.	47
Figura 10 – Repetições necessárias para convergência do BKF.	49
Figura 11 – MAE dos métodos para IMU myAHRS+.	50
Figura 12 – MAE dos métodos para IMU 9DoF Razor	51
Figura 13 – Capturas da aceleração bruta IMUs com marcação de períodos estáticos segunda captura.	68
Figura 14 – Períodos estáticos das capturas de aceleração das IMUs segunda captura.	69

Lista de tabelas

Tabela 1 – Valores de referência do vetor gravidade.	40
Tabela 2 – Comparação da média MAE normalizados em 1g dos métodos propostos com IMU de alto custo.	50
Tabela 3 – MAE para os três eixos dos sensores, normalizados em 1g	67

Lista de siglas

AHRS Attitude and Heading System
(Sistema de Atitude e Direção)

BKF Batch Kalman Filter
(Filtro de Kalman em Lote)

BEFK Batch Extended Kalman Filter
(Filtro de Kalman Estendido em Lote)

CEKF Cascated Extended Kalman Filter
(Filtro de Kalman Estendido em Cascata)

CBEKF Cascated Batch Extended Kalman Filter
(Filtro de Kalman Estendido Cascata em Lote)

DOF Degrees Of Freedom
(Graus de Liberdade)

DTG Dynamically Tuned Gyro
(Giroscópio Dinamicamente Ajustado)

EFK Extended Kalman Filter
(Filtro de Kalman Estendido)

IMU Inertial Measurement Unit
(Unidade de Medida Inercial)

INS Inertial Navigation System
(Sistema de Navegação Inercial)

KF Kalman Filter
(Filtro de Kalman)

MAE Mean Absolute Error
(Erro Absoluto Médio)

MEMS Micro Electrical Mechanical Systems
(Sistema Micro Eletromecânico)

RMSE Root Mean Squared Error
(Raiz Quadrada do Erro Médio)

Sumário

1	INTRODUÇÃO	21
1.1	Objetivos	25
1.2	Organização do Texto	25
2	SENSORES INERCIAIS	27
2.1	Acelerômetro Tri-Axial	28
3	CALIBRAÇÕES COM FILTRO DE KALMAN	31
3.1	Calibração do acelerômetro com filtro de Kalman	31
3.1.1	Observação baseada em cada elemento do lote de dados	32
3.1.2	Observação baseada no lote de dados	33
3.2	Calibração do acelerômetro com filtro de Kalman Estendido . .	34
3.2.1	Observação baseada em cada elemento do lote de dados	35
3.3	Calibração do acelerômetro com filtros de Kalman em cascata	37
4	MÉTODO CAPTURA AUTOMÁTICA	39
4.1	Método Multi-Posição e Captura dos Dados	39
4.2	Deteção automática da posição estática	41
4.3	Método e IMUs utilizadas nos testes	42
5	RESULTADOS E DISCUSSÕES	45
5.1	Captura e pré-processamento	45
5.2	Avaliação dos métodos de calibração implementados	48
6	PUBLICAÇÕES	53
7	CONCLUSÃO	55
	REFERÊNCIAS	57

APÊNDICES **61**

APÊNDICE A – DETALHES DOS ALGORITMOS 63

APÊNDICE B – RESULTADOS COMPLEMENTARES 67

Introdução

Uma Unidade de Medida Inercial (em inglês *Inertial Measurement Unit (IMU)*) é composta por acelerômetros e giroscópios, contudo, muitas IMUs possuem em suas placas magnetômetros já integrados. Assim, nesse trabalho iremos considerar IMUs com acelerômetros, giroscópios e magnetômetros, que retornam suas medidas para cada um dos eixos no espaço tridimensional. Estes dispositivos têm sido largamente utilizados para determinar a atitude de um corpo rígido, desde de aplicações de alto custo como militares, espaciais (MARTIN et al., 2004), veículos aéreos não tripulados e *drones* (PETER, 2011), tanto em aplicações de baixo custo como acessórios e peças de roupa também chamados vestíveis, auxílio a pessoas com deficiências (NOGUEIRA et al., 2017), e sistemas de medição de vibração para motores . Essas últimas aplicações têm sido viabilizadas e mais amplamente acessíveis, devido a diminuição drástica do custo desses dispositivos, passando de milhares de dólares para poucas dezenas de dólares, possibilitado principalmente pelos avanços dos sistemas microeletromecânicos (em inglês *Micro Electrical Mechanical Systems (MEMS)*) (BIJKER; STEYN, 2008).

Contudo, conforme discutido em (PETER, 2011), uma IMU tem que ser calibrada antes de ser colocada em operação. A calibração é necessária porque os eixos de sensibilidade do sensor não coincidem exatamente com os eixos do sistema de coordenadas do corpo rígido. Isso se deve aos defeitos de fabricação quando solda-se os sensores sobre a placa de circuito impresso e as próprias imperfeições dos sensores. Tais problemas, podem incluir não ortogonalidade aos eixos de sensibilidade e adição de desalinhamento, especialmente se o conjunto de sensores utilizados é de um eixo. Além disso, o fator de escala real e os valores de polarização geralmente são diferentes dos valores nominais, e devem ser determinados também.

Calibrar um sensor pode ser definido como o processo de determinação de parâmetros que aplicados aos sinais brutos dos sensores levam a valores comparáveis aos de uma referencia (AGGARWAL et al., 2008). Para a IMU, os parâmetros mais importantes a serem determinados são: a melhor correção para os fatores de escala e polarizações, a determinação dos ângulos de correção para o desalinhamento e as não ortogonalidades

dos eixos sensores. O diagrama da Figura 1 ilustra outros parâmetros e erros presentes nesses sensores e os blocos destacados são os que serão abordados nesse trabalho.

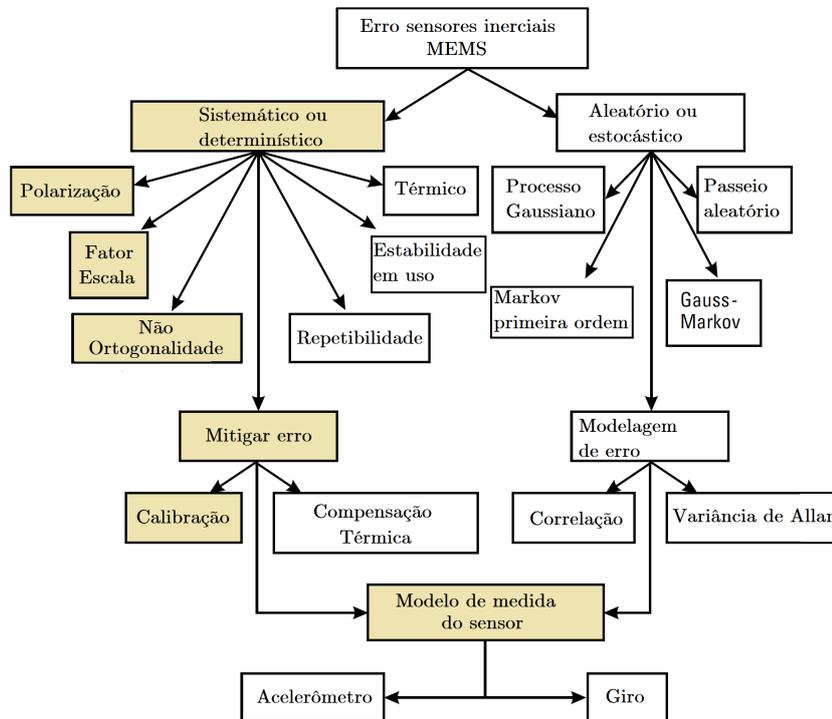


Figura 1 – Fluxograma de erros dos sensores.(Adaptado de (AGGARWAL et al., 2010)).

A calibração da IMU é geralmente feita através de uma plataforma mecânica que rotaciona o sensor com precisão em várias posições e velocidades. E no mínimo um grau de liberdade é necessário ser acionado para calibrar os giroscópios. Vários trabalhos têm utilizado esse tipo de sistema para a calibração de IMUs, em (SANTOS et al., 2010), por exemplo, foi construída uma bancada para calibração de giroscópios que realiza movimentos rotacionais em três eixos, aspectos relevantes do projeto mecânico e os principais parâmetros que compõem o sistema de acionamento são apresentados. Já em (PETER, 2011), um sistema baseado em um *gimbal* mecânico com três graus de liberdade atuados foi projetado e construído. O sistema possibilita calibrar a IMU sem nenhuma manipulação intermediária do usuário. Outras iniciativas para calibração de IMUs utilizando plataformas mecânicas podem ser vistas em (HALL; II, 2000; MADGWICK, 2010; PARK, 2004; VCELÁK et al., 2005; WEI et al., 2013). No entanto tal sistema requer extensiva e tediosa manipulação da IMU pelo usuário, como o reposicionamento da IMU várias vezes. Ademais, essas plataformas possuem alto custo de desenvolvimento, pois são compostas por estruturas mecânicas de três eixos, atuadores e *encoders* de precisão. E geralmente o custo delas excede o custo de desenvolvimento e construção de uma IMU baseada em MEMS.

Além das abordagens comentadas acima, existem iniciativas como a mostrada em (DONG et al., 2007), em que os dados de aceleração linear e posição espacial são ad-

quiridos através de rastreamento óptico, esses dados são então utilizados para calibrar a IMU. Já em (JENSEN; HAN; CHEN, 2009), a calibração foi feita através da comparação entre os dados da IMU e de imagens aéreas, onde alvos colocados em forma de quadrado são utilizados como referência para a coleta de dados. E em (LV et al., 2017) um sensor escaneamento laser foi utilizado para gerar a referência de deslocamento angular para a calibração de um giroscópio. Contudo, essas iniciativas ainda necessitam de um sensor externo a IMU de valor elevado para a calibração dos sensores.

Em virtude de reduzir os custos de calibração de uma IMU e reduzir o número de equipamentos externos usados nesse processo, em (LOTTERS et al., 1998) foi proposta uma técnica que calibra a polarização e o fator de escala do acelerômetro. A abordagem utiliza o fato do módulo do vetor de medida de um acelerômetro de três eixos ser igual a constante de gravidade em condições quase-estáticas, (SAXENA et al., 2005). O esquema não requer inclinações precisas e os parâmetros do modelo são ajustados utilizando métodos de estimativas robustas, (LIEBELT, 1967).

O esquema de calibração usado em (LOTTERS et al., 1998) foi estendido em (SKOG; HÄNDEL, 2006) para incluir o desalinhamento dos eixos dos sensores dos acelerômetros. Uma abordagem similar foi também proposta por (SKOG; HÄNDEL, 2006) para o giroscópio, porém uma mesa giratória com rotações de 0.1° por segundo foi necessária para a realização das calibrações. Ou seja, o método de calibração do giroscópio proposto não fica independente de equipamentos externos. Nessa técnica, a otimização de Newton, (BOYD; VANDENBERGHE, 2004), foi utilizada para ajustar os parâmetros de calibração do acelerômetro e do giroscópio.

Já em (SYED et al., 2007), foi obtido um esquema de calibração do acelerômetro e do giroscópio similar ao apresentado em (SKOG; HÄNDEL, 2006), porém foram propostas 26 posições diferentes da IMU para aquisição de dados a serem usados em uma otimização por mínimos quadrados ponderados para ajustar os parâmetros de calibração do giroscópio e do acelerômetro.

Diferentemente, em (FONG; ONG; NEE, 2008), foi utilizado o fato de que a medida do vetor de gravidade usando medidas estáticas de um acelerômetro de três eixos deve ser igual ao vetor de gravidade calculado usando as medidas de orientações obtidas através da integração das velocidades angulares fornecidas pelos giroscópios. O uso dessa proposição na calibração implica na eliminação de mesas giratórias ou qualquer equipamento especializado para a calibração do giroscópio. A minimização das funções custos para compensação dos erros de polarização, fator de escala, desalinhamento de eixo e sensibilidade eixos cruzados, foi realizada pelo método de otimização Downhill simplex, (PRESS et al., 1992).

Na última década, em (CHEUK et al., 2012), os autores estenderam a abordagem de calibração proposta por (FONG; ONG; NEE, 2008) para o magnetômetro, tornando possível, por meio da minimização das funções de custos, a correção dos erros de desali-

nhamento, fator de escala e polarização de todos os sensores da IMU (acelerômetro, magnetômetro e giroscópios) sem a utilização de equipamentos externos. Um algoritmo evolucionário diferencial, (STORN; PRICE, 1997; LAU; LIN, 2011), foi utilizado para ajustar os parâmetros de calibração da IMU. E em (TEDALDI; PRETTO; MENEGATTI, 2014), utilizou-se o método de multi-posição para captura manual dos dados, mantendo o sensor estático por um período, afim de utilizar esses dados estáticos na calibração do acelerômetro minimizando o erro da norma da aceleração com método de *Levenberg–Marquard*. Contudo, métodos baseados na minimização das funções custo dos erros dos sensores não convergem para os parâmetros calibrados, caso a escolha dos parâmetros iniciais não sejam adequados.

Recentemente, em (HAN et al., 2016; HAN et al., 2017) o deslocamento angular calculado por um giroscópio calibrado fixo em um eixo alinhado com o magnetômetro foi utilizado como sinal de comparação para a calibração de um magnetômetro através do uso de um filtro de Kalman. Esse método é interessante pois utiliza o giroscópio da própria IMU para calibrar o magnetômetro, desse modo não precisando de um outro sensor externo de valor mais elevado que a IMU. Uma abordagem inversa à proposta em (HAN et al., 2016; HAN et al., 2017) foi utilizada em (CHEUK et al., 2012), em que acelerômetros e magnetômetros calibrados eram usados para gerar medidas angulares de referência para a calibração do giroscópio.

Em sua maior parte, os trabalhos obtêm os parâmetros dos modelos dos sensores para calibração por meio do método de mínimos quadrados e algumas variações de funções custo sobre o modelo do sensor a ser calibrado. Porém a utilização do filtro de Kalman para estimativa de parâmetros de calibração vem tendo seu uso aumentando. (Grewal; Henderson; Miyasako, 1991) foi a primeira utilização do filtro de Kalman em calibração, depois em (LI et al., 2015) foi utilizada uma abordagem para calibração do giroscópio de um celular também utilizando o filtro, em (HAN et al., 2017) a abordagem com filtro de Kalman Estendido é realizada com a calibração do magnetômetro auxiliado pelos valores do giroscópio, também calibrado pelo método. E mais recentemente em (DAI; ZHANG; LU, 2019) o filtro de Kalman Unscented é utilizado, porém com uma IMU de alto custo do tipo Giroscópio Ajustado Dinamicamente (em inglês *Dynamically Tuned Gyro (DTG)*) e além disso as posições da IMU são realizadas em uma mesa de giro, para ajustar os ângulos de maneira precisa. Adicionalmente aos trabalhos citados, existem algumas patentes publicadas focadas nos métodos de calibração, como a patente registrada em nome da empresa *Intel Corporation* (HAN et al., 2016), que assim como abortado nesse trabalho utiliza o filtro de Kalman para estimar os parâmetros de calibração, porém com foco de calibrar o magnetômetro utilizando como referência o deslocamento angular calculado por um giroscópio fixo em um eixo alinhado com o magnetômetro e a patente registrada em nome da empresa *Leica Geosystems AG* (DAMIEN; AG., 2019), reivindica a utilização da calibração com correções dos efeitos da temperatura e identificando automaticamente e

calibrando de maneiras diferentes quando os sensores estão em movimento ou não.

1.1 Objetivos

Com a diminuição do custo das IMUs, o seu uso vem se estendendo para além das aplicações de alto valor agregado, como veículos autônomos, robôs e VANTs, chegando aos dispositivos de mais baixo custo como pulseiras FITNESS, dispositivos focados na avaliação e auxílio à reabilitação de pacientes com funções locomotoras limitadas, o que exige que os métodos de calibração, também sejam simples e de baixo custo.

Normalmente os métodos de calibração utilizam minimização do erro por meio dos mínimos quadrados ou método de newton. Neste trabalho estuda-se qual a eficácia do Filtro de Kalman na estimativa dos parâmetros utilizando o método multi-posição. Complementarmente será realizada a análise da minimização do erro da norma do vetor de aceleração para gerar uma melhora na estimativa dos parâmetros, com a utilização do Filtro de Kalman Estendido. A utilização dessas duas abordagens em cascata procura mitigar o efeito do erro no posicionamento manual, bem como possibilitar que o método convirja com uma condição inicial trivial.

Atualmente existem alguns métodos de calibração que estão em segredo industrial nos fabricantes de IMU, outros exigem dispositivos caros para serem executados. A proposta é disponibilizar, com base nos métodos de baixo custo disponíveis na bibliografia e no que será desenvolvido, um método simples para a comunidade científica a fim de reduzir as barreiras e com isso fomentar a pesquisa com IMU dentro da comunidade de pesquisadores em robótica, além disso expandir nas áreas correlatas que tenham como foco a aplicação da IMU diretamente sem ter vasto conhecimento de calibração ou estimativa de parâmetros.

Em suma o objetivo principal está em desenvolver um método de calibração de baixo custo para IMU focado no tipo MEMS, baseado no Filtro de Kalman, sem o uso de dispositivos de auxílio externos complexos ou caros, que possibilite a correção do desalinhamento dos eixos, o fator de escala, e o fator de polarização.

1.2 Organização do Texto

Este trabalho está organizado da seguinte maneira.

No Capítulo 2, são expressos os conceitos sobre a calibração e modelagem de erros dos sensores da IMU. No Capítulo 3 são apresentados os três métodos propostos de calibração com Filtro de Kalman. No Capítulo 4, estão contidos a metodologia de captura dos dados e as etapas de pré-processamento dos dados. O Capítulo 5 foi destinado para apresentação e discussão dos resultados preliminares alcançados até o momento. E nos Capítulos 6 e 7 apresentados, a publicação realizada até o momento e por fim as conclusões e possíveis trabalhos futuros.

Sensores Inerciais

Os sensores inerciais utilizados neste trabalho são de uma IMU com nove graus de liberdade (em inglês *Degrees Of Freedom (DOF)*) ou comumente chamada de IMU 9-DOF, com o conjunto formado por, um acelerômetro tri-axial para medidas de aceleração linear, um giroscópio tri-axial para medidas de velocidade angular e um magnetômetro tri-axial para medidas de atitude e orientação com referência no campo magnético da terra. O seu correto funcionamento é influenciado por diversos parâmetros que representam os erros presentes nesses sensores. Assim o processo de calibração busca estimar e corrigir esses parâmetros.

Em um funcionamento ideal, o valor de saída do sensor deveria refletir o valor da grandeza que se deseja medir, isso para cada eixo ortogonal entre si e alinhado aos eixos de um corpo rígido. Porém, devido as imperfeições no processo de fabricação tanto construtivos do sensor, como solda do chip, os valores medidos em um sensor real possuem os seguintes erros:

- ❑ **polarização:** parâmetro somado ao valor bruto para que o resultado seja zero quando nenhuma entrada está sendo aplicada ao sensor;
- ❑ **fator de escala:** parâmetro de proporção multiplicado pela leitura bruta em cada um dos eixos para se obter o valor real da grandeza;
- ❑ **não ortogonalidade e desalinhamento:** pequenos ângulos de desvio entre cada eixo sensível do sensor e o eixo do corpo que se deseja medir.

A Figura 2 exemplifica graficamente os erros que esses parâmetros exercem.

Nesse sentido, para que a calibração seja realizada e os parâmetros de erro sejam determinados, se faz necessário um modelo matemático para cada um desses sensores, sendo que esse processo de modelagem passa pela elucidação de quais são os erros que afetam as medidas e como os valores obtidos nas saídas dos sensores representam os valores das grandezas que se deseja medir (SKOG; HÄNDEL, 2006)(LV et al., 2017).

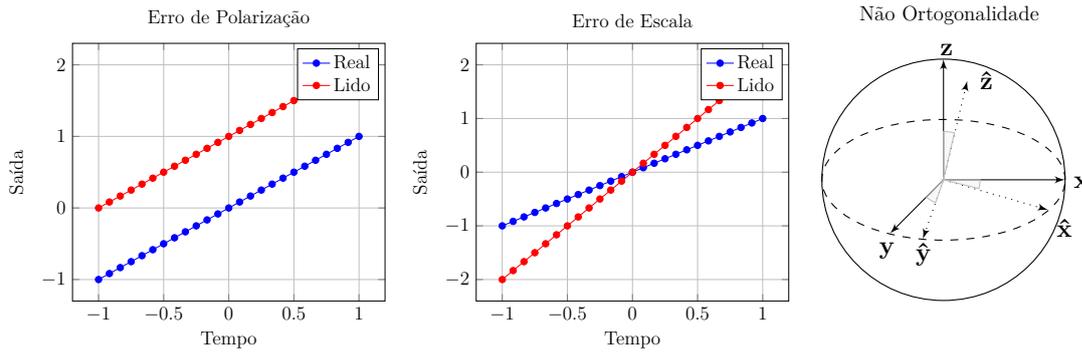


Figura 2 – Representação gráfica dos erros nos sensores.

2.1 Acelerômetro Tri-Axial

Um sensor ideal realiza somente a medida da aceleração dinâmica de um corpo rígido, contudo, neste trabalho o acelerômetro é modelado com sensibilidade para aceleração dinâmica e estática (gravidade). Assim, a medida do acelerômetro \mathbf{a}_a é dada por:

$$\mathbf{a}_a = {}^{\mathcal{L}}R^{\mathcal{G}} (\mathbf{f} - \mathbf{g}_e) + \mathbf{b}_a + \mathbf{w}_a, \quad (1)$$

sendo ${}^{\mathcal{L}}R^{\mathcal{G}}$ a matriz de rotação do sistema de coordenadas Global $\{\mathcal{G}\}$ para o sistema de coordenadas Local $\{\mathcal{L}\}$, ${}^{\mathcal{G}}\mathbf{g}_e$ o vetor de gravidade da Terra, \mathbf{b}_a o vetor coluna de polarização e \mathbf{w}_a o ruído Gaussiano branco.

Para propósitos da calibração, está-se interessado na medida da gravidade no sistema de coordenadas Local $\{\mathcal{L}\}$. Isto é possível quando a aceleração dinâmica é nula, ou seja ${}^{\mathcal{G}}\mathbf{f} = 0$. Portanto, a Equação (1) é reescrita para esta situação de medida do acelerômetro como:

$$\mathbf{g}_a = -{}^{\mathcal{L}}R^{\mathcal{G}} \mathbf{g}_e + \mathbf{b}_a + \mathbf{w}_a, \quad (2)$$

sendo \mathbf{g}_a a medida de gravidade.

A matriz de correção T_a realiza a correção do sistema não-ortogonal para o sistema ortogonal, veja (SKOG; HÄNDEL, 2006)(CHEUK et al., 2012)(QURESHI; GOLNARAGHI, 2017).

$$T_a = \begin{bmatrix} 1 & -\alpha_{yz} & \alpha_{zy} \\ \alpha_{xz} & 1 & -\alpha_{zx} \\ -\alpha_{xy} & \alpha_{yx} & 1 \end{bmatrix}, \quad (3)$$

sendo α_{ij} o pequeno ângulo de desvio do eixo i entorno do eixo j , como mostrado na Figura 3. Outros fatores que devem ser determinados para que se possa obter a medida de aceleração da plataforma, dado o valor bruto do sensor da IMU, são os fatores de escala,

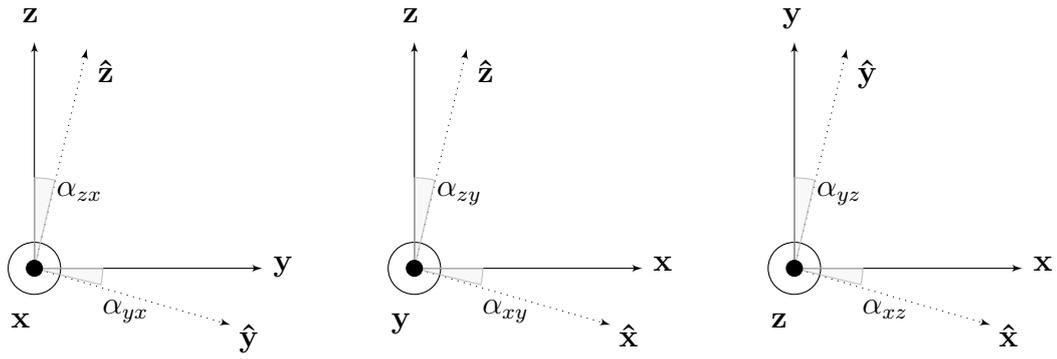


Figura 3 – Desalinhamento entre os eixos do acelerômetro.

representados pela matriz diagonal 3×3

$$K_a = \begin{bmatrix} K_{ax} & 0 & 0 \\ 0 & K_{ay} & 0 \\ 0 & 0 & K_{az} \end{bmatrix}. \quad (4)$$

Modificando a Equação (2) para incluir a matriz para calibração do sensor em relação ao alinhamento dos eixos e ao fator de escala, define-se o modelo de calibração do acelerômetro baseado na medida da aceleração da gravidade como:

$$\mathbf{g} = \Theta_a \mathbf{g}_a - \mathbf{b}_a, \quad (5)$$

sendo

$$\Theta_a = \begin{bmatrix} \theta_{00} & \theta_{01} & \theta_{02} \\ \theta_{10} & \theta_{11} & \theta_{12} \\ \theta_{20} & \theta_{21} & \theta_{22} \end{bmatrix}, \quad \mathbf{b}_a = \begin{bmatrix} b_{ax} \\ b_{ay} \\ b_{az} \end{bmatrix} \quad (6)$$

$\Theta_a = T_a K_a$ a multiplicação da matriz de rotação com a matriz dos fatores de escala, e $\mathbf{g} = -\frac{c}{g} R^g \mathbf{g}_e$.

Portanto, serão necessários a identificação de doze parâmetros, nove elementos da matriz Θ_a e três elementos do vetor \mathbf{b}_a .

A Figura 4, mostra uma representação em diagrama de blocos do modelo dado pela Equação 5.

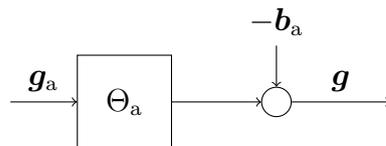


Figura 4 – Diagrama de blocos do modelo de erro do acelerômetro.

Calibrações com Filtro de Kalman

Neste capítulo serão apresentados os métodos propostos para realizar a calibração dos sensores inerciais baseados no filtro de Kalman como estimador de parâmetros. Para isto, defini-se os vetores dos lotes de dados de calibração como

$$\bar{\mathbf{g}}_{\mathbf{a}} = [\mathbf{g}_{\mathbf{a},1}, \mathbf{g}_{\mathbf{a},2}, \dots, \mathbf{g}_{\mathbf{a},l}, \dots, \mathbf{g}_{\mathbf{a},N}]^T, \quad (7)$$

$$\bar{\mathbf{g}}_{\mathbf{a}}^e = [\mathbf{g}_{\mathbf{a},1}^e, \mathbf{g}_{\mathbf{a},2}^e, \dots, \mathbf{g}_{\mathbf{a},l}^e, \dots, \mathbf{g}_{\mathbf{a},N}^e]^T, \quad (8)$$

para $l = \{1, \dots, N\}$, sendo N a quantidade de dados do lote, $\mathbf{g}_{\mathbf{a},l}$ e $\mathbf{g}_{\mathbf{a},l}^e$ o valor medido e esperado do acelerômetro, respectivamente. Esses valores são obtidos em uma determinada posição da sequência de posicionamentos especificadas para coleta dos dados do lote de dados de calibração. Vale lembrar que esses dados são obtidos manualmente sem o auxílio de equipamentos. Mais detalhes da aquisição dos dados de calibração do acelerômetro são discutidas no Capítulo 4.

Nas próximas seções, serão definidas as equações do filtro e suas relações com os modelos dos sensores, evidenciando as referências e a forma de cálculo dos erros, bem como os algoritmos utilizados nas abordagens.

3.1 Calibração do acelerômetro com filtro de Kalman

Nesta seção, pretende-se utilizar o filtro de Kalman para realizar a estimativa dos doze parâmetros do modelo do acelerômetro apresentado na Equação (5). O modelo do sistema para estimativa de parâmetros pode ser descrito como

$$\mathbf{x}_{k+1} = \mathbf{x}_k, \quad (9)$$

$$\mathbf{z}_k = H_k \mathbf{x}_k + \mathbf{v}_k, \quad (10)$$

sendo \mathbf{x}_k o vetor de parâmetros, H_k o modelo de medição e \mathbf{v}_k o ruído branco de média zero com matriz de covariância R_k . Para maiores detalhes do uso de filtro de Kalman para o problema de estimativa de parâmetros veja (HAYKIN, 2004; WALKER, 2006).

A estimativa de parâmetros pelo filtro de Kalman assemelha-se a um algoritmo preditor-corretor para a solução de problemas numéricos, assim podemos classificar suas equações como preditoras e corretoras. As equações preditoras são responsáveis por projetar futuramente as estimativas do estado atual, $\hat{\mathbf{x}}_{k|k}$, e a covariância do erro, $P_{k|k}$, para obter as estimativas *a priori*, $\hat{\mathbf{x}}_{k+1|k}$ e $P_{k+1|k}$, para o próximo passo de iteração. As equações corretoras são responsáveis por incorporar uma nova medida, \mathbf{z}_{k+1} , na estimativa *a priori*, $\hat{\mathbf{x}}_{k+1|k}$, para obter uma estimativa *a posteriori*, $\hat{\mathbf{x}}_{k+1|k+1}$, melhorada.

Dessa forma, para o nosso problema de calibração, define-se o vetor de parâmetros do nosso sistema de estimativa de parâmetros como

$$\mathbf{x}_k = [\theta_{00} \ \theta_{01} \ \theta_{02} \ \theta_{10} \ \theta_{11} \ \theta_{12} \ \theta_{20} \ \theta_{21} \ \theta_{22} \ b_{ax} \ b_{ay} \ b_{az}]^T, \quad (11)$$

sendo θ_{ij} elementos da matriz Θ_a de fatores de escala e não ortogonalidade, e b_{ax} , b_{ay} e b_{az} os elementos do vetor de polarização \mathbf{b}_a , ambos apresentados em (6).

O vetor de medidas \mathbf{z}_k pode utilizar a medida de cada elemento do lote de dados (Seção 3.1.1), ou o lote inteiro de dados (Seção 3.1.2), conforme descrito nas seções abaixo. Com a observação dos dados definido dessa forma, a qualidade da estimativa dos parâmetros do modelo de calibração vai depender da qualidade do posicionamento do sensor no momento da coleta dos dados do acelerômetro, visto que o sensor são posicionados manualmente, sem auxílio de equipamento.

3.1.1 Observação baseada em cada elemento do lote de dados

Para a observação baseada em cada elemento do lote de dados, é definido $\mathbf{z}_k = \mathbf{g}_{a,l}^e$. Desse modo, utilizando o modelo de medida de gravidade pelo acelerômetro, definido em (5), é calculada a matriz de observação da seguinte forma

$$H_k = \frac{\partial \mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l})}{\partial \mathbf{x}_k} \quad (12)$$

$$= \begin{bmatrix} \mathbf{g}_{ax,l} & \mathbf{g}_{ay,l} & \mathbf{g}_{az,l} & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & \mathbf{g}_{ax,l} & \mathbf{g}_{ay,l} & \mathbf{g}_{az,l} & 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \mathbf{g}_{ax,l} & \mathbf{g}_{ay,l} & \mathbf{g}_{az,l} & 0 & 0 & -1 \end{bmatrix}, \quad (13)$$

sendo $\mathbf{g}_{ax,l}$, $\mathbf{g}_{ay,l}$, e $\mathbf{g}_{az,l}$ os elementos do vetor de medidas brutas do acelerômetro $\mathbf{g}_{a,l}$ para cada eixo.

Uma vez definido todos os elementos do nosso modelo de estimativa de parâmetros para calibração do acelerômetro, é apresentado o Algoritmo 1 para estimativa do parâmetros de calibração. O Algoritmo 1 deve ser executado até que a matriz $P_{k+1|k+1}$ convirja para valores fixos.

Algoritmo 1 Calibração utilizando elementos dos dados do lote com o filtro de Kalman.

Predição:

- 1: $\hat{\mathbf{x}}_{k+1|k} = \hat{\mathbf{x}}_{k|k}$
- 2: $P_{k+1|k} = P_{k|k}$

Correção:

- 1: Obtenha os dados de $\mathbf{g}_{a,l}$ e $\mathbf{g}_{a,l}^e$
- 2: Calcule a matriz H_{k+1} utilizando os valores de $\mathbf{g}_{a,l}$
- 3: Atribua $\mathbf{z}_{k+1} = \mathbf{g}_{a,l}^e$
- 4: $K_{k+1} = P_{k+1|k} H_k^T (H_{k+1} P_{k+1|k} H_k^T + R_k)^{-1}$
- 5: $\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + K_{k+1} (\mathbf{z}_{k+1} - H_{k+1} \hat{\mathbf{x}}_{k+1|k})$
- 6: $P_{k+1|k+1} = (I - K_{k+1} H_{k+1}) P_{k|k-1}$

Saída:

- 1: Atualize a matriz Θ_a e o vetor \mathbf{b}_a com o valores de $\hat{\mathbf{x}}_{k+1|k+1}$
-

3.1.2 Observação baseada no lote de dados

Para a observação baseada no lote de dados, definimos $\mathbf{z}_k = \bar{\mathbf{g}}_a^e$. Desse modo, utilizando o modelo de medida de gravidade pelo acelerômetro definido em (5), podemos calcular a matriz de observação da seguinte forma

$$H_k = \begin{bmatrix} H_{1k}^T & \dots & H_{lk}^T & \dots & H_{Nk}^T \end{bmatrix}^T, \quad (14)$$

sendo

$$H_{lk} = \frac{\partial \mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l})}{\partial \mathbf{x}_k}, \quad (15)$$

$$= \begin{bmatrix} \mathbf{g}_{ax,l} & \mathbf{g}_{ay,l} & \mathbf{g}_{az,l} & 0 & 0 & 0 & 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & \mathbf{g}_{ax,l} & \mathbf{g}_{ay,l} & \mathbf{g}_{az,l} & 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \mathbf{g}_{ax,l} & \mathbf{g}_{ay,l} & \mathbf{g}_{az,l} & 0 & 0 & -1 \end{bmatrix}, \quad (16)$$

$\mathbf{g}_{ax,l}$, $\mathbf{g}_{ay,l}$, e $\mathbf{g}_{az,l}$ os elementos do vetor de medidas brutas do acelerômetro $\mathbf{g}_{a,l}$ para cada eixo.

Uma vez que definimos todos os elementos do nosso modelo de estimativa de parâmetros para calibração do acelerômetro, podemos apresentar o Algoritmo 2 para estimativa do parâmetros de calibração. O Algoritmo 2 deve ser executado até que a matriz $P_{k+1|k+1}$ convirja para valores fixos.

Algoritmo 2 Calibração utilizando elementos dos dados do lote com o filtro de Kalman.

Predição:

- 1: $\hat{\mathbf{x}}_{k+1|k} = \hat{\mathbf{x}}_{k|k}$
- 2: $P_{k+1|k} = P_{k|k}$

Correção:

- 1: Obtenha os dados de $\bar{\mathbf{g}}_a$ e $\bar{\mathbf{g}}_a^e$
- 2: Calcule a matriz H_{k+1} utilizando os valores de \mathbf{g}_a
- 3: Atribua $\mathbf{z}_{k+1} = \bar{\mathbf{g}}_a^e$
- 4: $K_{k+1} = P_{k+1|k} H_k^T (H_{k+1} P_{k+1|k} H_k^T + R_k)^{-1}$
- 5: $\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + K_{k+1} (\mathbf{z}_{k+1} - H_{k+1} \hat{\mathbf{x}}_{k+1|k})$
- 6: $P_{k+1|k+1} = (I - K_{k+1} H_{k+1}) P_{k|k-1}$

Saída:

- 1: Atualize a matriz Θ_a e o vetor \mathbf{b}_a com o valores de $\hat{\mathbf{x}}_{k+1|k+1}$
-

3.2 Calibração do acelerômetro com filtro de Kalman Estendido

Utilizando-se o modelo de calibração do acelerômetro através das medidas da aceleração da gravidade (5), pode-se definir o seguinte problema de otimização para estimar os parâmetros $\Theta_{\mathbf{a}}$ e $\mathbf{b}_{\mathbf{a}}$

$$[\Theta_{\mathbf{a}}, \mathbf{b}_{\mathbf{a}}] = \arg \min_{\Theta_{\mathbf{a}}, \mathbf{b}_{\mathbf{a}}} \sum_{n=1}^N \left(1 - \mathcal{L}^2(\mathbf{g})\right)^2, \quad (17)$$

sendo $\mathcal{L}^2(\mathbf{g})$ a norma L^2 . O problema de otimização (17) foi proposto em (CHEUK et al., 2012) para calibração de um acelerômetro sem a utilização de equipamento fixo ao sensor, para este método utiliza-se o fato que a magnitude do vetor da aceleração da gravidade é $1g^e$, sendo $g^e \approx 9,81 \frac{\text{m}}{\text{s}^2}$. Ou seja, quando a norma $\mathcal{L}^2(\mathbf{g})$ for igual a 1, os parâmetros $\Theta_{\mathbf{a}}$ e $\mathbf{b}_{\mathbf{a}}$ teram sido encontrados. Algoritmos de busca diretas evolucionários (STORN; PRICE, 1997; LAU; LIN, 2011) foram utilizados para obter a solução de (17) em (CHEUK et al., 2012).

A norma $\mathcal{L}^2(\mathbf{g})$ pode ser calculada como

$$\mathcal{L}^2(\mathbf{g}) = \|\mathbf{g}\|_2 = (g_1^2 + g_2^2 + \dots + g_j^2 + \dots + g_n^2)^{\frac{1}{2}}, \quad (18)$$

para $j = 1, \dots, n$, sendo g_j os elementos do vetor \mathbf{g} e n a quantidade de elementos do vetor. E a derivada de (18) é dada por

$$\frac{\partial}{\partial g_i} \mathcal{L}^2(\mathbf{g}) = (g_1^2 + g_2^2 + \dots + g_j^2 + \dots + g_n^2)^{-\frac{1}{2}} g_j = \frac{g_j}{(\sum_{j=1}^n g_j^2)^{\frac{1}{2}}}. \quad (19)$$

Nesta seção, pretende-se utilizar o filtro de Kalman Estendido com restrição para realizar a estimativa dos 12 parâmetros do modelo do acelerômetro apresentada na Equação (5). O modelo do sistema para estimativa de parâmetros pode ser descrito como

$$\mathbf{x}_{k+1} = \mathbf{x}_k, \quad (20)$$

$$\mathbf{0} = \mathbf{z}_k - h(\mathbf{x}_k, \mathbf{y}_k) + \mathbf{v}_k, \quad (21)$$

sendo \mathbf{x}_k o vetor de parâmetros, h_k o modelo de medição não linear, \mathbf{y}_k o vetor de medidas e \mathbf{v}_k o ruído branco de média zero com matriz de covariância R_k . Para maiores detalhes do uso de filtro de Kalman Estendido com restrição para o problema de estimativa de parâmetros veja (WALKER, 2006).

Dessa forma, para o nosso problema de calibração, define-se o vetor de parâmetros do nosso sistema de estimativa de parâmetros como

$$\mathbf{x}_k = [\theta_{00} \theta_{01} \theta_{02} \theta_{10} \theta_{11} \theta_{12} \theta_{20} \theta_{21} \theta_{22} b_{ax} b_{ay} b_{az}]^T, \quad (22)$$

sendo θ_{ij} elementos da matriz $\Theta_{\mathbf{a}}$ de fatores de escala e não ortogonalidade e b_{ax} , b_{ay} e b_{az} os elementos do vetor de polarização $\mathbf{b}_{\mathbf{a}}$, ambos apresentados em (6).

O vetor de medidas \mathbf{z}_k pode utilizar a medida de cada elemento do lote de dados (Seção 3.2.1), ou o lote inteiro de dados (Seção 3.2.1.1), conforme descrito nas seções abaixo. Observe que para este método a qualidade da estimativa dos parâmetros do modelo de calibração não depende da qualidade do posicionamento do sensor no momento da coleta dos dados do acelerômetro, visto que para este método a norma L^2 sempre tem ser unitária para que o sensor esteja calibrado. E consequentemente só utilizamos os dados do lote $\bar{\mathbf{g}}_a$ uma vez que estaremos comparando com a norma a norma L^2 . Desse modo, a coleta de dados pode ser feita sem o auxílio de equipamentos, e a mesma não prejudica a qualidade da calibração.

3.2.1 Observação baseada em cada elemento do lote de dados

Para a observação baseada em cada elemento do lote de dados, definimos $\mathbf{z}_k = 1$, uma vez que esse será o valor esperado da norma $\mathcal{L}^2(\mathbf{g})$ para quando o sensor estiver calibrado. E o modelo de medida como $h(\mathbf{x}_k, \mathbf{y}_k) = \mathcal{L}^2(\mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l}))$, sendo $\mathbf{y}_k = \mathbf{g}_{a,l}$.

A matriz H_k de observação pode ser obtida através da linearização de $\mathcal{L}^2(\mathbf{g})$ pelo estado \mathbf{x}_k , ou seja

$$H_k = \frac{\partial \mathcal{L}^2(\mathbf{g})}{\partial \mathbf{x}_k} = \frac{\partial \mathcal{L}^2(\mathbf{g})}{\partial \mathbf{g}} \frac{\partial \mathbf{g}}{\partial \mathbf{x}_k}. \quad (23)$$

Os elementos de $\frac{\partial \mathcal{L}^2(\mathbf{g})}{\partial \mathbf{g}}$ podem ser calculados por (19). Já os elementos de $\frac{\partial \mathbf{g}}{\partial \mathbf{x}_k}$ podem ser calculados por $\frac{\partial g_j}{\partial x_{ik}}$, sendo $i = \{1, \dots, m\}$, e m o número de elementos do vetor \mathbf{x}_k .

Uma vez que definimos todos os elementos do nosso sistema em espaço de estado para a calibração do acelerômetro, podemos apresentar o Algoritmo 3 para estimativa dos parâmetros de calibração. O Algoritmo 3 deve ser executado até que a matriz $P_{k+1|k+1}$ convirja para valores fixos.

Algoritmo 3 Calibração utilizando elementos dos dados do lote com o filtro de Kalman Estendido.

Predição:

- 1: $\hat{\mathbf{x}}_{k+1|k} = \hat{\mathbf{x}}_{k|k}$
- 2: $P_{k+1|k} = P_{k|k}$

Correção:

- 1: Obtenha os dados de $\mathbf{g}_{a,l}$
- 2: Calcule \mathbf{g} , Equação (5), utilizando os dados de $\mathbf{g}_{a,l}$, Θ_a e \mathbf{b}_a
- 3: Calcule a matriz H_{k+1} utilizando os valores de $\mathbf{g}_{a,l}$ conforme mostrado em (23)
- 4: Calcule $h(\hat{\mathbf{x}}_{k+1|k}) = \mathcal{L}^2(\mathbf{g}(\hat{\mathbf{x}}_{k+1|k}, \mathbf{g}_{a,l}))$
- 5: Atribua $\mathbf{z}_{k+1} = 1$
- 6: $K_{k+1} = P_{k+1|k} H_{k+1}^T (H_{k+1} P_{k+1|k} H_{k+1}^T + R_k)^{-1}$
- 7: $\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + K_{k+1} (\mathbf{z}_{k+1} - h(\hat{\mathbf{x}}_{k+1|k}))$
- 8: $P_{k+1|k+1} = (I - K_{k+1} H_{k+1}) P_{k|k-1}$

Saída:

- 1: Atualize a matriz Θ_a e o vetor \mathbf{b}_a com os valores de $\hat{\mathbf{x}}_{k+1|k+1}$
-

Contudo, a abordagem que proposta no o Algoritmo 3 necessita que a condição inicial esteja próxima da solução, caso contrário os parâmetros de calibração não irão convergir para uma solução adequada de calibração.

3.2.1.1 Observação baseada no lote de dados

Para a observação baseada no lote de dados, define-se

$$\mathbf{z}_k = [z_{1k} \ \dots \ z_{lk} \ \dots \ z_{Nk}] \quad (24)$$

sendo $z_{lk} = 1$, uma vez que esse será o valor esperado da norma $\mathcal{L}^2(\mathbf{g})$ para quando o sensor estiver calibrado. E o modelo de medida como

$$h(\mathbf{x}_k, \mathbf{y}_k) = [h_{1k} \ \dots \ h_{lk} \ \dots \ h_{Nk}] \quad (25)$$

sendo $h_{lk} = \mathcal{L}^2(\mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l}))$ e $\mathbf{y}_k = \bar{\mathbf{g}}_a$.

A matriz H_k pode ser obtida através da linearização de $\mathcal{L}^2(\mathbf{g})$ pelo estado \mathbf{x}_k , ou seja

$$H_k = [H_{1k}^T \ \dots \ H_{lk}^T \ \dots \ H_{Nk}^T]^T, \quad (26)$$

sendo

$$H_{lk} = \frac{\partial \mathcal{L}^2(\mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l}))}{\partial \mathbf{x}_k} = \frac{\partial \mathcal{L}^2(\mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l}))}{\partial \mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l})} \frac{\partial \mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l})}{\partial \mathbf{x}_k}. \quad (27)$$

Os elementos de $\frac{\partial \mathcal{L}^2(\mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l}))}{\partial \mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l})}$ podem ser calculados por (19). Já os elementos de $\frac{\partial \mathbf{g}(\mathbf{x}_k, \mathbf{g}_{a,l})}{\partial \mathbf{x}_k}$ podem ser calculados por $\frac{\partial g_j}{\partial x_{ik}}$, sendo $i = \{1, \dots, m\}$, e m o número de elementos do vetor \mathbf{x}_k .

Uma vez que definido todos os elementos do nosso sistema em espaço de estado para a calibração do acelerômetro, pode-se apresentar o Algoritmo 4 para estimativa dos parâmetros de calibração. O Algoritmo 4 deve ser executado até que a matriz $P_{k+1|k+1}$ convirja para valores fixos.

Algoritmo 4 Calibração utilizando os dados do lote com o filtro de Kalman Estendido.

Predição:

- 1: $\hat{\mathbf{x}}_{k+1|k} = \hat{\mathbf{x}}_{k|k}$
- 2: $P_{k+1|k} = P_{k|k}$

Correção:

- 1: Obtenha os dados de $\bar{\mathbf{g}}_a$
- 2: Calcule a matriz H_{k+1} utilizando os valores de $\bar{\mathbf{g}}_a$ e \mathbf{x}_k conforme mostrado em (26)
- 3: Calcule $h(\hat{\mathbf{x}}_{k+1|k}, \bar{\mathbf{g}}_a)$ conforme mostrado em (25)
- 4: Faça as atribuições de \mathbf{z}_{k+1} conforme mostrado em (24)
- 5: $K_{k+1} = P_{k+1|k} H_k^T (H_{k+1} P_{k+1|k} H_{k+1}^T + R_k)^{-1}$
- 6: $\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + K_{k+1} (\mathbf{z}_{k+1} - h(\hat{\mathbf{x}}_{k+1|k}))$
- 7: $P_{k+1|k+1} = (I - K_{k+1} H_{k+1}) P_{k|k-1}$

Saída:

- 1: Atualize a matriz Θ_a e o vetor \mathbf{b}_a com os valores de $\hat{\mathbf{x}}_{k+1|k+1}$
-

Contudo, a abordagem que proposta no o Algoritmo 4 necessita que a condição inicial esteja próxima da solução, caso contrário os parâmetros de calibração não irão convergir para uma solução adequada de calibração.

3.3 Calibração do acelerômetro com filtros de Kalman em cascata

Como descrito na Seção 3.2, a abordagem proposta no Algoritmo 3 necessita de uma boa condição inicial para que o método tenha sucesso. Dessa forma, este trabalho propõe a utilização dos Algoritmos 1 ou 2 apresentados na Seção 3.1 para obter os parâmetros de calibração inicial para serem utilizados pelos Algoritmos 3 ou 4 apresentados na Seção 3.2. Uma vez que a qualidade da estimativa dos parâmetros utilizando os Algoritmos da Seção 3.1 dependem da qualidade do posicionamento no momento da coleta dos dados do sensor, assim pode-se adquirir os dados com o posicionamento manual do acelerômetro, o que proporcionaria parâmetros próximos da solução de calibração ótima, e refinaria-se esses parâmetros através da abordagem dos Algoritmos da Seção 3.2. Desse modo, teríamos um método em cascata de filtros de Kalman, algoritmos 1 ou 2 e 3 ou 4 em cascata.

Método Captura Automática

As IMUs de alto custo são calibradas individualmente pelo fabricante e possuem seus parâmetros adequados para aquela peça em específico. Porém as IMUs de baixo custo normalmente são fornecidas com parâmetros de calibração padrões ou até sem qualquer calibração (SYED et al., 2007). Porém, para qualquer aplicação que se destine o uso desses sensores a calibração é essencial, principalmente em aplicações com fusão de sensores, como Sistema de Atitude e Orientação (em inglês *Attitude and Heading System (Attitude and Heading System (AHRS))*) e Sistema de Navegação Inercial (em inglês *Inertial Navigation System (INS)*). Com isso o processo de calibração deve ser de baixo custo e de fácil execução, sendo assim, dois principais fatores influenciam nessas características, a captura dos dados e o custo computacional dos algoritmos de calibração.

Para a definição do método de captura de dados foram levados em consideração as seguintes premissas:

- ❑ utilização dos dados apenas nos momentos estáticos;
- ❑ varrer de maneira suficiente as orientações para o vetor gravidade e campo magnético;
- ❑ não utilizar nenhum outro dispositivo além do sensor, sistema de captura e computador;
- ❑ ser automático ao ponto que o usuário precisa apenas indicar o início do processo, executar o posicionamento manual do dispositivo e indicar o fim da captura.

4.1 Método Multi-Posição e Captura dos Dados

Em (SYED et al., 2007), foi descrito um procedimento em que são utilizadas 18 posições de orientação na IMU com relação ao vetor gravidade, neste trabalho foi utilizada a sequência de posicionamento apresentada na Figura 5 para fornecer os dados brutos aos algoritmos de pré-processamento e calibração.

A convenção para orientação dos eixos utilizada foi a Norte Leste Baixo (em inglês *North East Down (NED)*) assim pode-se observar que as posições são alternadas entre as seis posições de alinhamento dos eixos sensores com o vetor gravidade (-x, x, -y, y, -z e z) e as outras doze posições com a aresta da IMU posicionada a aproximadamente 45 graus com a horizontal, na qual a notação para essas posições o eixo perpendicular a gravidade é omitido e o sinal negativo indica o eixo que tem um ângulo maior que 180 graus com a horizontal (-x+y, +x+y, +x-y, -x-y, +x+z, +x-z, -x-z, -x+z, +y+z, +y-z, -y-z e -y+z)

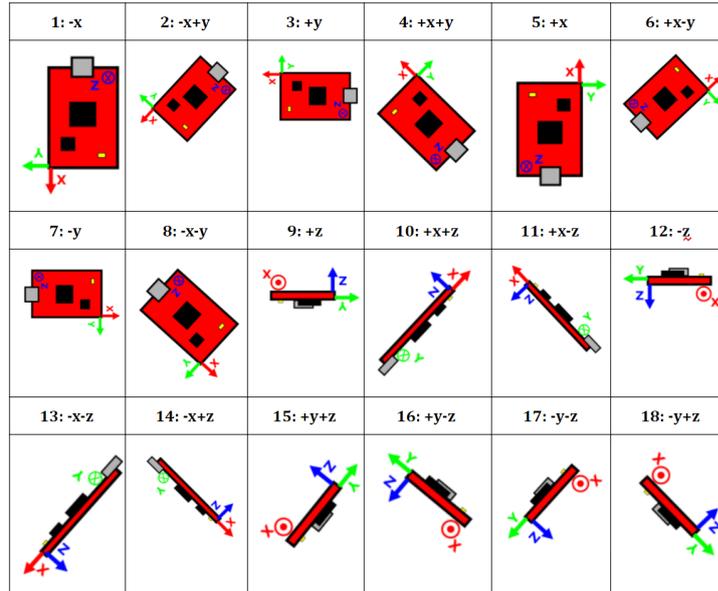


Figura 5 – Esquema das 18 orientações da IMU com relação ao vetor gravidade.

Assim se a IMU estivesse com uma calibração ideal, cada uma dessas posições deveria retornar uma soma vetorial do vetor gravidade em cada eixo, na Tabela 1 está descrito o valor de referência para as 6 primeiras posições, que pode ser facilmente estendido para as demais posições, sendo ${}^G g_e$ o vetor gravidade.

Tabela 1 – Valores de referência do vetor gravidade.

l	$g_{a,l}^e$		
	x	y	z
1	${}^G g_e$	0	0
2	$-{}^G g_e \sqrt{2}/2$	${}^G g_e \sqrt{2}/2$	0
3	0	${}^G g_e$	0
4	${}^G g_e \sqrt{2}/2$	${}^G g_e \sqrt{2}/2$	0
5	${}^G g_e$	0	0
6	${}^G g_e \sqrt{2}/2$	$-{}^G g_e \sqrt{2}/2$	0

Para que a captura seja executada de maneira automática, é necessário encontrar nos dados os instantes em que a IMU estava medindo somente aceleração estática para assim utilizar apenas esses valores para a calibração do acelerômetro.

4.2 Detecção automática da posição estática

A aceleração da gravidade é a referencia para calibração do acelerômetro e para que isso seja possível, não devem existir outras forças atuando sobre a IMU, o que geraria medidas de aceleração dinâmicas que se somariam ao vetor gravidade modificando a referência.

Contudo os movimentos são realizados manualmente e por isso os momentos que a IMU permanece estática não são muito bem definidos, já que o usuário pode fazer pequenos movimentos que sejam suficientes para gerar interferências muito grandes na referência.

Desse modo, propõe-se utilizar o Algoritmo 5, baseado em (TEDALDI; PRETTO; MENEGATTI, 2014), para realizar a detecção dos instantes de tempo em que o acelerômetro está com baixa interferência de forças extras à gravidade.

Esse algoritmo considera que a IMU está estática nos intervalos em que a norma da variância da medida do acelerômetro é menor que um determinado limiar. No Algoritmo 5, γ_a é o parâmetro que deve ser ajustado como limite para a norma da variância que acima deste, o estado do sensor não é mais considerado estático. No Algoritmo 7, presente no Apêndice A, estão explícitos outros parâmetros que podem ser ajustados para refinar a detecção sendo, t_{per} o período de cálculo da variância e n_a o tamanho do vetor de dados capturado pelo acelerômetro, estes parâmetros foram determinados experimentalmente com base nos dados capturados.

Algoritmo 5 Detecção da posição estática

- 1: Calcule a variância $\sigma_{a_a}^2$ de a_a
 - 2: Se $\sigma_{a_a}^2 > \gamma_a$ a aceleração não é estática.
 - 3: Caso contrário, a aceleração é estática, portanto $g_a = a_a$
-

Das 18 posições executadas pelo usuário, o sensor foi mantido um certo intervalo de tempo em cada uma, e por isso foi gerada uma série de dados para aquela posição em específico. O algoritmo de calibração necessita apenas de um ponto observável para cada posição de referência na obtenção dos parâmetros de calibração.

Porém ao invés de escolher um ponto desse período estático filtrado, optou-se por desenvolver o Algoritmo 6 capaz de detectar a transição de cada posição por meio da derivada numérica dos vetores assim calcular a média da aceleração de cada eixo para cada posição, procurando assim minimizar os efeito de ruído e pequenas movimentações do usuário.

Algoritmo 6 Média das regiões estáticas

- 1: Calcule a derivada de g_a , $\dot{g}_a = \frac{dg_a}{dt}$
 - 2: Se $\|\dot{g}_a(j)\| > dif_{lim}$, realize a somatória de g_a , \sum_a
 - 3: Caso contrário, calcule a média de \bar{g}_a a partir da \sum_a , e zere a variável \sum_a
-

O Algoritmo 6 também possui parâmetro ajuste de limiar dif_{lim} a afim de melhorar a detecção da transição entre os períodos estático e os de movimento.

4.3 Método e IMUs utilizadas nos testes

Para avaliação e testes dos algoritmos propostos, foi estabelecido o fluxograma da Figura 6 que mostra uma visão geral do método executado neste trabalho, com detalhes para os dados de entrada e saída de cada fase do processo. No fluxograma está descrito apenas o passo a passo com o filtro aplicado a cada item do lote, porém o processo é análogo para o caso da utilização do lote completo de dados apenas substituindo os Algoritmos 1 e 3 pelos Algoritmos 2 e 4, respectivamente.

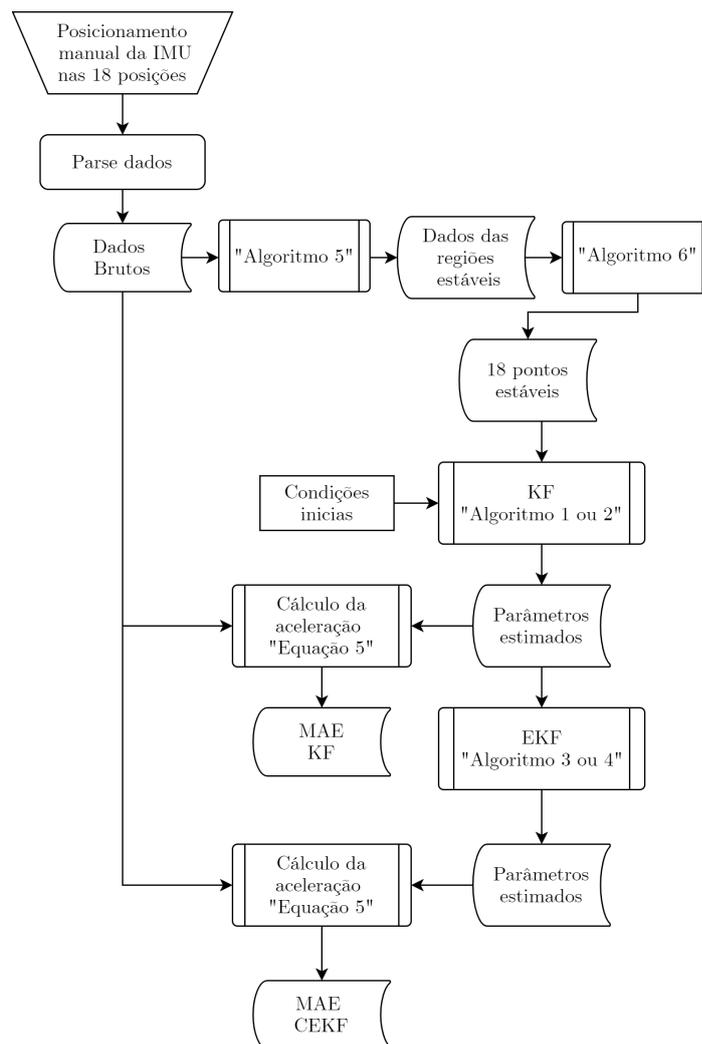
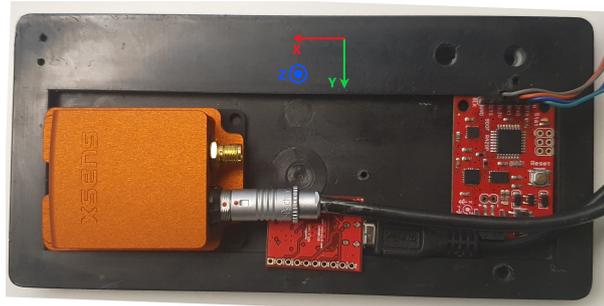


Figura 6 – Fluxograma geral do processo de calibração.

Vale ressaltar que neste fluxograma fica simples observar a proposta do trabalho de comparar os resultados de calibração obtida pelos filtros individualmente e o efeito cascata, aplicando o estendido com a norma na sequência do linear. Outro ponto de destaque é a utilização dos dados brutos obtidos na captura para o cálculo da aceleração utilizando os parâmetros obtidos e calculando o Erro Absoluto Médio (em inglês *Mean Absolute Error (MAE)*), dado pela Equação (28), escolhido por retornar o erro absoluto o que é importante já que os erros positivos e negativos poderiam se



(a) IMU baixo custo e alto custo utilizadas



(b) Montagem das IMUs

Figura 7 – IMUs utilizadas nos testes.

anular causando uma distorção nos resultados, além disso como os dados possuem pontos discrepantes por conta da captura manual, a utilização da Raiz Quadrada do Erro Médio (em inglês *Root Mean Squared Error (Root Mean Squared Error (RMSE))*) não é indicada, já que são atribuídos pesos maiores para erros maiores.

$$\mathbf{MAE} = \frac{1}{N} \sum_{i=1}^N |\mathbf{g}_{\text{ref},i} - \mathbf{g}_i|, \quad (28)$$

sendo N a quantidade de dados capturados, $\mathbf{g}_{\text{ref},i}$ os valores calibrados lidos da IMU de alto custo e \mathbf{g}_i os valores calculados utilizando os dados brutos das IMUs de baixo custo e os parâmetros estimados pelos métodos.

Para executar todas as medidas brutas foram realizadas as capturas para três modelos distintos de IMUs, o modelo *myAHRs+* da *WITHROBOTIC Inc.* de baixo custo (\$75,00), a *9DoF Razor* da *SparkFun* também de baixo custo (\$25,00), o modelo *MTi-G-700* da *XSENS* de mais alto custo (\$4263,75). A Figura 7(b), mostra as duas IMUs respectivamente. Mais informações sobre as características técnicas podem ser obtidas do manual dos seus fabricantes (*WITHROBOT Inc.*, 2014)(*XSENS*, 2015).

É importante salientar que a IMU de mais alto custo possui um certificado de calibração do fabricante, o que fortalece a ideia de utiliza-la como a referencia na avaliação de desempenho do método de calibração proposto.

Para realizar essa comparação as três IMUs foram montadas como mostra a Figura 7(b), com isso as 18 posições foram capturadas simultaneamente para as três IMUs, com

isso o mesmo erro de posição causado pelo posicionamento manual foi carregado para as três IMUs, destacando que para as IMUs de baixo custo foram armazenados os dados brutos (sem calibração) e para a IMU de alto custo os dados da aceleração já calculados com os parâmetros do fabricante.

Resultados e Discussões

Neste capítulo serão apresentados os resultados obtidos, com a captura dos dados, pré-processamento e o processo de calibração por meio do filtro de Kalman, comparando os dados calibrados com os da IMU de alto custo, calibrada pelo fabricante. Foram realizadas duas capturas completas das três IMUs, sendo que a segunda captura foi realizada provocando erros intencionais no momento do posicionamento manual, procurando inserir erros que a execução manual do processo pode gerar. Os dados brutos da segunda captura são apresentados no Apêndice B.

5.1 Captura e pré-processamento

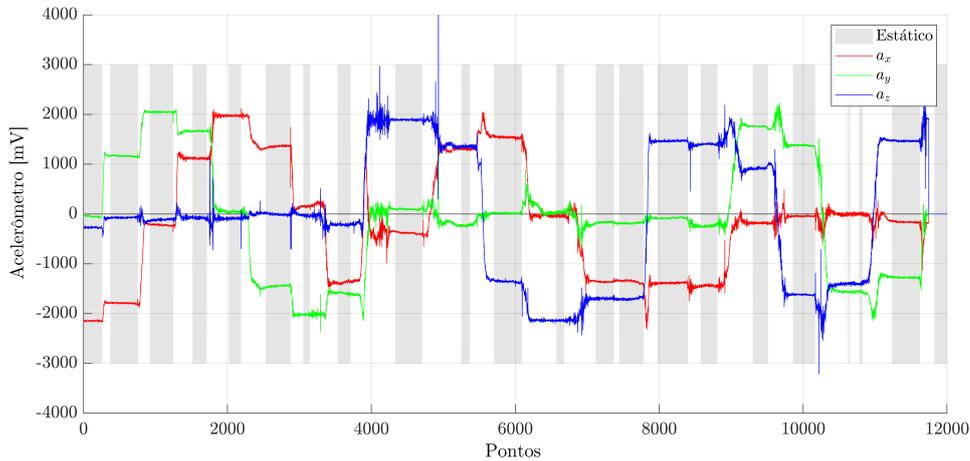
Para a captura manual seguindo o método de multi-posição descrito na Seção 4.1, a frequência de atualização dos dados foi configurada para 50 Hz nas três IMUs, respeitando o limite máximo da IMU de baixo custo, visando sincronizar a captura.

Outro ponto importante a ser ressaltado, é que tendo em vista o desenvolvimento de um método de simples execução, não foi marcada a transição das posições por nenhuma interface extra, como por exemplo, o pressionar de um botão pelo usuário a cada mudança, sendo que a detecção dos pontos estáticos foi obtida automaticamente pelo algoritmo, o que permitiu utilizar a média de vários pontos brutos na determinação de cada ponto de calibração.

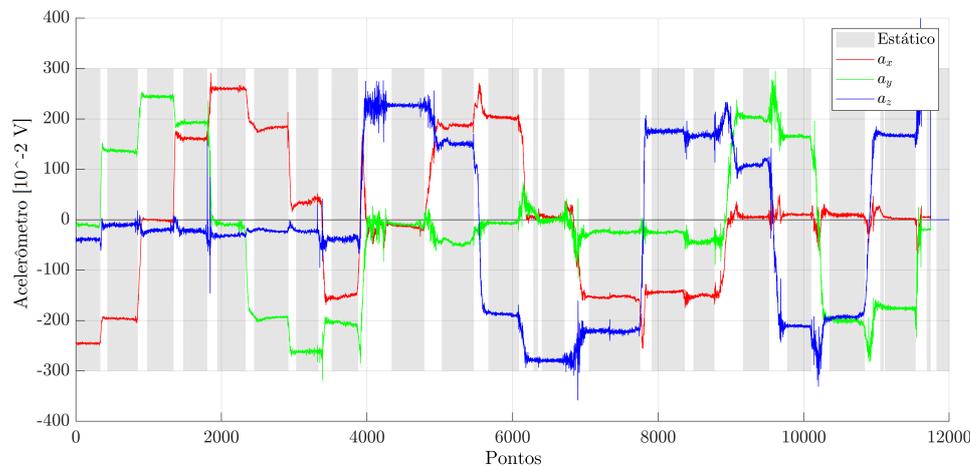
Na Figura 8, são apresentados os dados brutos do acelerômetro em cada um dos três eixos para cada IMU, podendo ser observados altos níveis de ruído e oscilações causadas pelo sensor e pela movimentação manual. Além desses dados, tem-se em destaque, o resultado da primeira etapa de pré-processamento, saída do Algoritmo 5, que marcou todos os pontos dentro da margem de limiar estabelecida como estática, criando assim os períodos de interesse, de onde serão extraídos os valores de aceleração que serão a entrada para os algoritmos de calibração.

Na utilização do Algoritmo 5, para obtenção dos resultados das regiões estáticas, foi necessário ajustar o período de cálculo da variância t_{per} para 1.6 segundos e do limiar da

variância, \mathbf{var}_{lim} para, 600 na IMU *myAHRs+* e 60 na IMU *9 DoF Razor*, sem unidade já que os dados da aceleração nesta etapa são brutos. Esses valores foram determinados experimentalmente ajustando-os até que o método fosse capaz de extrair dezoito pontos, com valores próximos aos de referência, indicando que foram extraídos das posições estáticas.



(a) myAHRs+



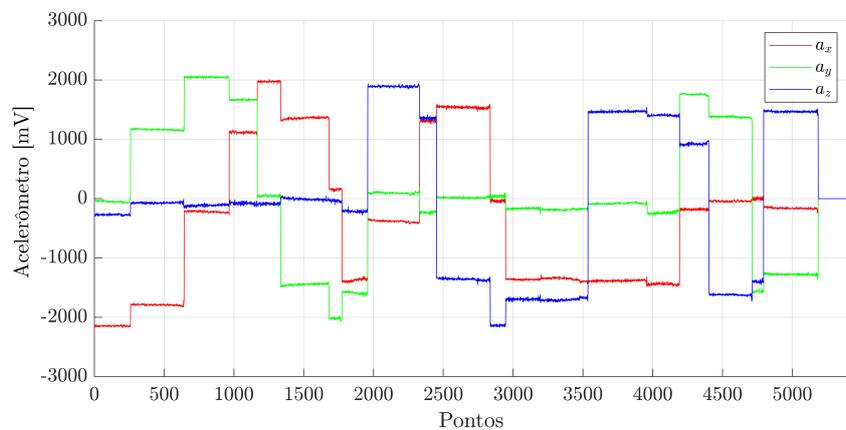
(b) 9DOF Razor

Figura 8 – Capturas da aceleração bruta IMUs com marcação de períodos estáticos.

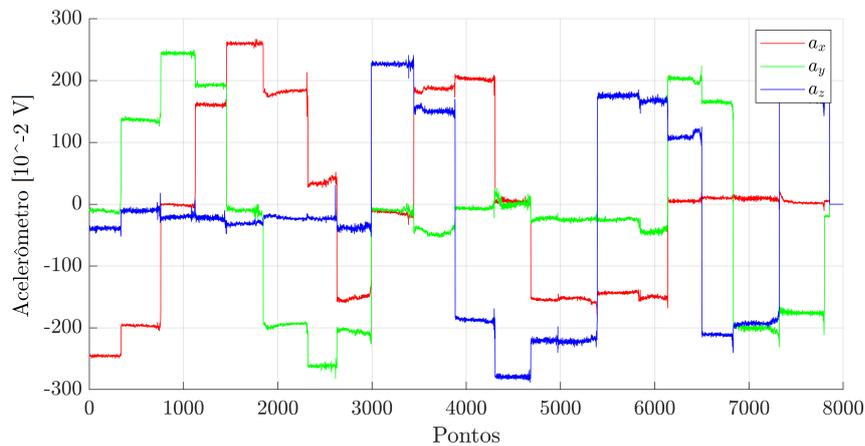
Nos dados brutos de cada eixo da Figura 8, é possível observar os dezoito patamares formados pelos instantes do ensaio em que o usuário manteve a IMU idealmente sem movimento, nas posições pré-estabelecidas, apresentadas na Figura 5 da Seção 4.1. Assim, analisando o resultado das regiões estáticas que foram retornadas pelo Algoritmo 5, em destaque cinza na Figura 8, observa-se que os momentos detectados como estáticos estão dentro das regiões esperadas. Portanto, demonstrando um bom desempenho do algoritmo.

Os resultados das regiões estáticas obtidos pelo Algoritmo 5, são utilizados com entrada para o Algoritmo 6, que foi capaz de detectar a transição de cada posição por meio da derivada numérica dos vetores de períodos estáticos mostrados na Figura 9. Por fim,

calculando a média da aceleração normalizada de cada eixo para cada patamar estático, obteve-se assim um ponto para cada uma das dezoito posições. Esse é um importante processo para utilização do filtro de Kalman, já que apenas um ponto observável, de cada posição estática, referente a cada patamar da Figura 9, é suficiente para obtenção dos parâmetros de calibração, uma vez que somente estão disponíveis os valores das componentes do vetor gravidade para cada uma das dezoito posições como medida de referência, como definidas na Tabela 1 da Seção 4.1.



(a) myAHRs+



(b) 9DOF Razor

Figura 9 – Períodos estáticos das capturas de aceleração das IMUs.

Adicionalmente, pode-se observar na Figura 9 que, por meio do Algoritmo 6 para detecção de estático, as oscilações causadas pela movimentação manual foram totalmente mitigadas, isso porque foram mantidos apenas os dados referentes aos períodos apontados como estáticos.

5.2 Avaliação dos métodos de calibração implementados

Os resultados apresentados a seguir buscam avaliar e comparar os métodos de calibração desenvolvidos nesse trabalho, utilizando o *MAE* da aceleração normalizada, de cada método como justificado na Seção 4.3. Adicionalmente, por meio da Equação (29), foi calculada a melhoria percentual da média do *MAE* de cada método, considerando o filtro de Kalman com o modelo linear a base de comparação para os demais métodos, para assim ser possível evidenciar a evolução atingida com a utilização de cada método.

$$I\% = 100\left(1 - \frac{\bar{E}_m}{\bar{E}_{KF}}\right), \quad (29)$$

sendo \bar{E}_m a média do *MAE* para os métodos de calibração propostos no trabalho.

No decorrer dessa seção são apresentados os dados obtidos e a discussão sobre os resultados. Nessas seções os resultados serão denotados pelos sufixos, "*My*" para os relacionados à IMU *myAHRs+* e "*Rz*" para os relacionados à IMU *9 DoF Razor*. E os prefixos serão apresentados como *Kalman Filter (KF)* para os filtros de Kalman linear para cada item do lote, *Extended Kalman Filter (EFK)* para os filtro de Kalman Estendidos para cada item do lote e *Cascated Extended Kalman Filter (CEKF)*, quando o resultado foi obtido por meio da cascata do filtro *KF* e o *EFK*. Além destes, também tem-se os prefixos, *Batch Kalman Filter (BKF)* para os filtros de Kalman linear em lote, *Batch Extended Kalman Filter (BEFK)* para os filtro de Kalman Estendidos em lote e *Cascated Batch Extended Kalman Filter (CBEKF)* quando o resultado foi obtido por meio da cascata dos filtros *BKF* e o *BEFK*.

A abordagem em lotes, utilizada nos métodos *BKF*, *BEFK* e *CBEKF*, pode ser repetida de maneira recursiva utilizando os parâmetros obtidos na iteração anterior como entrada para o próximo laço, sendo assim foi realizado um teste calculando o *MAE* em cada laço para determinar a quantidade de repetições utilizadas. A Figura 10 mostra o resultado dessa análise, o que mostrou ser um processo convergente com tendência de estabilidade após a oitava repetição. Sendo assim, foi definido a utilização de dez repetições dos Algoritmos 2 e 4 para cada lote.

Os *MAE* obtidos a partir da diferença entre, os valores do vetor calibrado pelo fabricante da IMU de alto custo e os valores do vetor de dados brutos calibrados com os parâmetros obtidos na aplicação de cada método de calibração apresentado no trabalho, foram compilados nos gráficos da Figura 11 para a IMU *myAHRs+* e na Figura 12 para a IMU *9 DoF Razor*, e nas Tabela 2 desta seção e Tabela 3 do Apêndice B das duas capturas realizadas. Vale ressaltar ainda que na segunda captura foram inseridos erros deliberados nos posicionamentos manuais, para que fosse possível comparar os métodos em uma situação adversa. Além disso, a utilização das duas IMUs de baixo custo, para

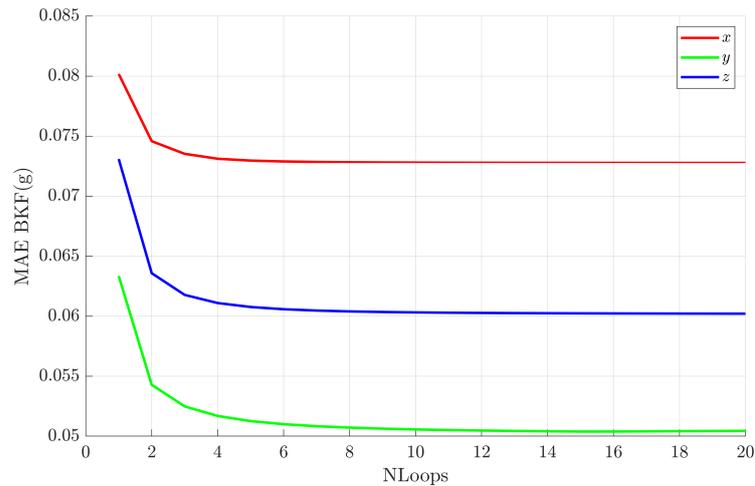


Figura 10 – Repetições necessárias para convergência do BKF.

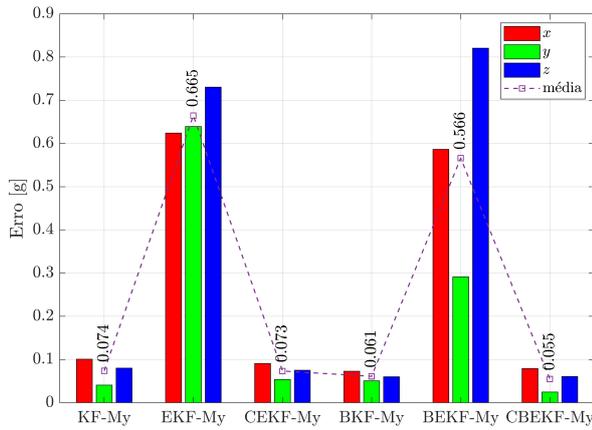
avaliar se mesmo para uma IMU de menor custo, *9 DoF Razor*, os métodos se mostraram robustos.

Nestes gráficos é importante notar que cada barra representa o MAE da aceleração de cada eixo, e o ponto acima, representa o valor da média dos erros para três eixos de cada método. Além disso, destaca-se os gráficos intitulados de Comparativo e Cascata, que foram construídos para evidenciar a vantagem do método em cascata. No primeiro caso figuras 11(a) e 12(a), foram apresentados os erros obtidos utilizando os parâmetros estimados com os filtros de Kalman Estendido, de prefixos *EKF* e *BEKF*, com valores iniciais triviais, ou seja, sem inicia-los com os valores do filtro linear.

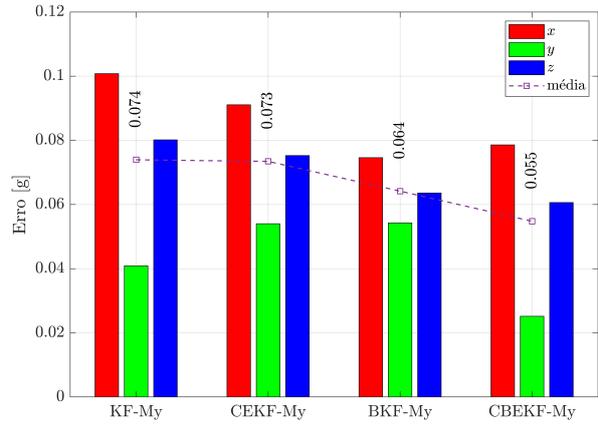
Pode-se notar que estes apresentaram erros altos se comparados aos outros métodos, sendo assim, as abordagens *EFK* e *BEKF*, ou seja, os filtros de Kalman Estendido sem cascata, foram descartadas como métodos de calibração viáveis. Com isso, foram geradas as Figuras 11(b) e 12(b), em que esses casos sem cascata foram omitidos, possibilitando a visualização dos resultados finais dos demais métodos e a concluir uma clara tendência de menores erros para os métodos em cascata e com uma melhora mais significativa nos métodos em lotes, indicando assim que entre os métodos desenvolvidos a Cascata do Filtro de Kalman Estendido em Lote *CBEFK* apresenta o melhor desempenho.

Os dados numéricos de cada eixo bem como a média de cada método apresentado nas Figuras 11 e 12, podem ser consultados na Tabela 3 no Apêndice B.

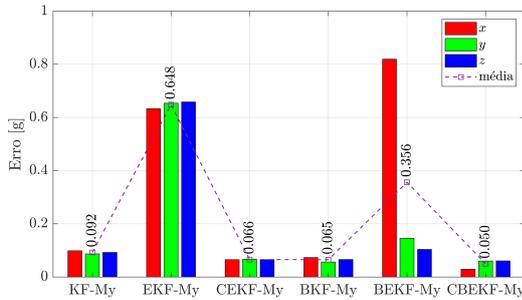
A Tabela 2 mostra a média do MAE, obtida com a calibração utilizando os parâmetros resultados de cada método proposto, aplicado em cada IMU e a porcentagem de quanto o MAE de cada método é maior que a média do MAE da IMU de alto custo calibrada pelo fabricante. Podemos observar pela porcentagem de erro, que os métodos obtiveram um bom desempenho, já que todos tiveram o MAE menor que dobro do MAE da IMU calibrada pelo fabricante. Destacando o desempenho do método *CBEKF*, que chegou a apresentar erros menores que 3%.



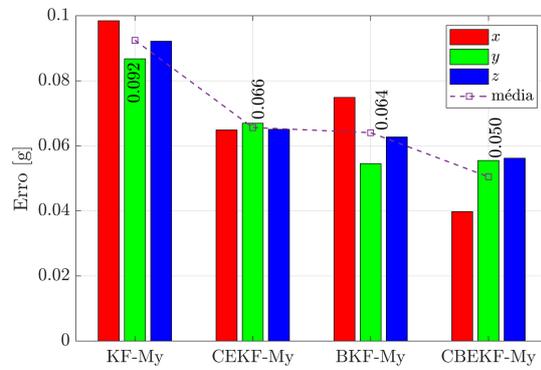
(a) Comparativo (primeira captura).



(b) Cascata (primeira captura).



(c) Comparativo (segunda captura).

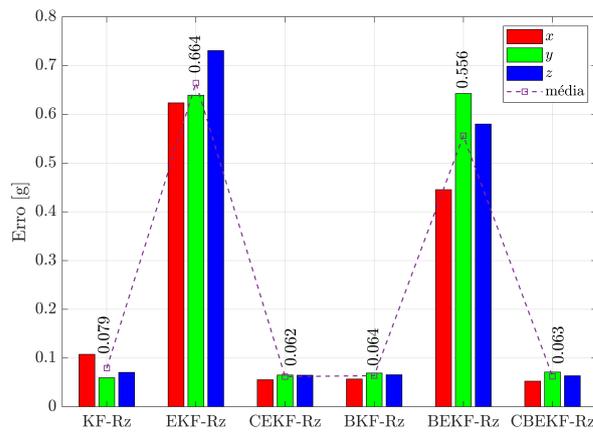


(d) Cascata (segunda captura).

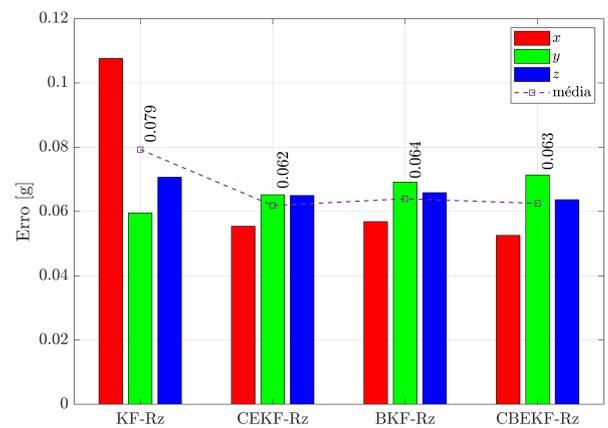
Figura 11 – MAE dos métodos para IMU myAHRs+.

Tabela 2 – Comparação da média MAE normalizados em 1g dos métodos propostos com IMU de alto custo.

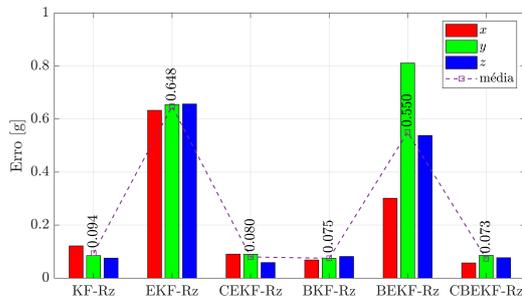
	<i>myAHRs+</i>		<i>9 DoF Razor</i>	
	média	I%	média	I%
<i>primeira captura</i>				
KF	0.074	0	0.079	0
CEKF	0.074	0	0.062	21
BKF	0.065	12	0.064	17
CBEKF	0.055	25	0.063	25
<i>segunda captura</i>				
KF	0.092	0	0.094	0
CEKF	0.066	28	0.080	15
BKF	0.064	31	0.075	21
CBEKF	0.050	45	0.073	26



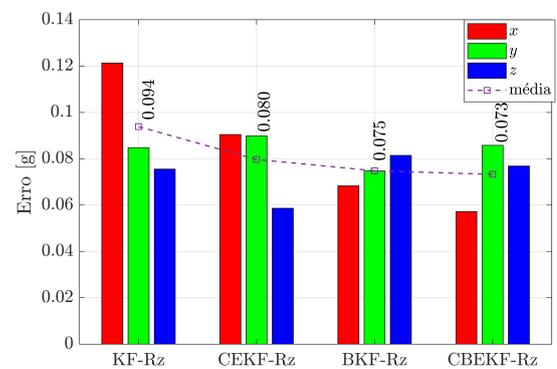
(a) Comparativo (primeira captura).



(b) Cascata (primeira captura).



(c) Comparativo (segunda captura).



(d) Cascata (segunda captura).

Figura 12 – MAE dos métodos para IMU 9DoF Razor

Publicações

Até o momento desta qualificação de mestrado o seguinte artigo foi publicado:

- DIEGUES, D.; INOUE, R. S.; NOGUEIRA, S. L. Método Automático de Calibração de Acelerômetro Baseado no Filtro de Kalman. In: **XIV Conferência Brasileira de Dinâmica, Controle e Aplicações (DINCON)**. [S.l.: s.n.], 2019.

Conclusão

Com a análise dos dados apresentados, foi possível identificar que o método de multi-posição proposto, aliado aos algoritmos de identificação de posições estáticas cumprem o objetivo de um método de baixo custo e de simples execução, já que nenhuma outra ação, além do posicionamento manual da IMU se faz necessário ao usuário. Além disso, conclui-se que os métodos de estimativa de parâmetros propostos, oferecem bom desempenho, uma vez que as calibrações do sensor utilizando os parâmetros estimados, resultaram em MAE entre 0.05g, para o $CBEKF$, e 0.094g, para o KF , comparado com o sensor calibrado pelo fabricante, em condições de laboratório da IMU de alto custo utilizada nos testes, e observando uma melhora de até 45% do filtro KF para o filtro $CBEKF$ nas mesmas condições de captura. Destaca-se também que a estratégia de utilizar o filtro de Kalman estendido para realizar um ajuste fino procurando mitigar os efeitos dos erros que o posicionamento manual insere, foram bastante satisfatórios. Além disso, a utilização em cascata se mostrou necessária, já que ao aplicar a estimativa apenas com a norma, nos filtros de Kalman Estendido, apresentaram erros muito superiores aos demais o que inviabiliza a utilização desses métodos isolados, uma vez que foi observado erros menores para os métodos em cascata, sendo está uma melhora significativa quando comparamos com os métodos estendidos sem cascata e lineares. Adicionalmente, a estratégia de estimativa dos parâmetros, com a utilização de todo o lote de dados mostrou-se bastante efetiva para a IMU, tendo em vista que nos quatro ensaios (dois com cada IMU), foi possível observar uma tendência do método em cascata apresentar melhores resultados quando combinado com o método em lote, em comparação com os demais métodos utilizados, levando a conclusão de que a combinação do método em cascata do filtro de Kalman e a abordagem de aplicação com o lote completo dos dados, apresenta o melhor método desenvolvido. Essas constatações são bastante interessantes, pois vão de encontro com o que se esperava, já que a estratégia de cascata procura aproveitar o melhor de cada filtro, ou seja, a não dependência dos valores iniciais do filtro de Kalman e a robustez quanto a erros de posicionamento do estendido, além da abordagem em lotes ponderar todos os dados de uma vez para a estimativa dos parâmetros, o que tende a ser mais abrangente

do ponto de vista do conjunto de dados como um todo e portanto levar a erros menores. Por fim, com este trabalho foi possível validar que a utilização dessas estratégias de estimativas de parâmetros para o problema de calibração são viáveis e apresentaram bons resultados, e em trabalhos futuros, extrapolar esses conceitos para os demais sensores da IMU devem apresentar resultados bastante promissores.

Referências

- AGGARWAL, P. et al. A Standard Testing and Calibration Procedure for Low Cost MEMS Inertial Sensors and Units. **Journal of Navigation**, n. 2, p. 323–336, 2008.
- _____. **MEMS-Based Integrated Navigation**. [S.l.]: Artech House Publishers, 2010. (GNSS Technology and Applications). ISBN 1608070433,9781608070435.
- BIJKER, J.; STEYN, W. Kalman filter configurations for a low-cost loosely integrated inertial navigation system on an airship. **Control Engineering Practice**, 2008.
- BOYD, S.; VANDENBERGHE, L. **Convex Optimization**. New York, USA: Cambridge University Press, 2004.
- CHEUK, C. M. et al. Automatic calibration for inertial measurement unit. In: **IEEE International Conference on Control Automation Robotics Vision**. Guangzhou, China: [s.n.], 2012.
- DAI, M.; ZHANG, C.; LU, J. In-field calibration method for DTG IMU including g-sensitivity biases. **IEEE Sensors Journal**, IEEE, 2019.
- DAMIEN, D.; AG., L. G. Método de Calibração de Sensores de Inércia. **Instituto Nacional da Propriedade Industrial do Brasil**, 2019.
- DONG, Z. et al. A calibration method for mems inertial sensors based on optical tracking. In: **IEEE International Conference on Nano/Micro Engineered and Molecular Systems**. [S.l.: s.n.], 2007.
- FONG, M. T.; ONG, S. K.; NEE, A. Y. C. Method for in-field user calibration of an inertial measurement unit with external equipment. **Measurement Science and Technology**, 2008.
- Grewal, M. S.; Henderson, V. D.; Miyasako, R. S. Application of kalman filtering to the calibration and alignment of inertial navigation systems. **IEEE Transactions on Automatic Control**, 1991.
- HALL, J. J.; II, R. L. W. Case study: Inertial measurement unit calibration platform. **Journal of Robotic Systems**, v. 17, n. 11, p. 623–632, 2000.
- HAN, K. et al. Extended Kalman Filter Based Autonomous Magnetometer Calibration - WO 2016/074153 A1. **World Intellectual Property Organization**, 2016.

_____. Extended Kalman Filter-Based Gyroscope-Aided Magnetometer Calibration for Consumer Electronic Devices. **IEEE Sensors Journal**, IEEE, 2017.

HAYKIN, S. **Kalman Filtering and Neural Networks**. John Wiley & Sons, 2004. ISBN 978-0-471-46421-1. Disponível em: <https://www.ebook.de/de/product/21148311/simon_haykin_kalman_filtering_and_neural_networks.html>.

JENSEN, A. M.; HAN, Y.; CHEN, Y. Q. Using aerial images to calibrate the inertial sensors of a low-cost multispectral autonomous remote sensing platform (aggieair). In: **IEEE International Geoscience and Remote Sensing Symposium**. Cape Town, South Africa: [s.n.], 2009.

LAU, T. K.; LIN, K. wun. Evolutionary tuning of sigma-point kalman filters. In: **IEEE International Conference on Robotics and Automation**. Shanghai, China: [s.n.], 2011.

LI, Y. et al. Autonomous calibration of MEMS gyros in consumer portable devices. **IEEE Sensors Journal**, IEEE, 2015.

LIEBELT, P. B. **Introduction to Optimal Estimation**. [S.l.]: Addison-Wesley, 1967.

LOTTERS, J. C. et al. Procedure for in-use calibration of triaxial accelerometers in medical application. **Sensors and Actuators, A: Physical**, 1998.

LV, J. et al. A method of low-cost IMU calibration and alignment. **SII 2016 - 2016 IEEE/SICE International Symposium on System Integration**, 2017.

MADGWICK, S. O. H. **Automated calibration of an accelerometers, magnetometers and gyroscopes - A feasibility study**. [S.l.], 2010.

MARTIN, M. et al. The Mars exploration rovers descent image motion estimation system. **IEEE Intelligent Systems**, 2004.

NOGUEIRA, S. L. et al. Global Kalman filter approaches to estimate absolute angles of lower limb segments. **BioMedical Engineering Online**, n. 1, 2017.

PARK, M. **Error Analysis and Stochastic Modeling of MEMS based Inertial Sensors for Land Vehicle Navigation Applications**. [S.l.], 2004.

PETER, B. **Development of an Automatic IMU Calibration System**. Dissertação (Mestrado) — Swiss Federal Institute of Technology Zurich, 2011.

PRESS, W. H. et al. **Numerical Recipes in C: The Art of Scientific Computing**. Cambridge: Cambridge University Press, 1992.

QURESHI, U.; GOLNARAGHI, F. An Algorithm for the In-Field Calibration of a MEMS IMU. **IEEE Sensors Journal**, 2017.

SANTOS, W. E. dos et al. Bancada para calibração de giroscópios. In: **Simpósio Brasileiro de Engenharia Inercial**. Rio de Janeiro, Brasil: [s.n.], 2010.

SAXENA, A. et al. In use parameter estimation of inertial sensors by detecting multilevel quasi-static states. In: **Knowledge-Based Intelligent Information and Engineering Systems**. [S.l.]: Springer Berlin Heidelberg, 2005.

- SKOG, I.; HÄNDEL, P. Calibration of a mems inertial measurement unit. In: **IMEKO WORLD CONGRESS**. Rio de Janeiro, Brazil: [s.n.], 2006.
- STORN, R.; PRICE, K. Differential evolution - a simple and efficient adaptive scheme for global optimization over continuous spaces. In: **International computer science institute-publications-TR**,. New Delhi,India: [s.n.], 1997. v. 11, p. 341–359.
- SYED, Z. F. et al. A new multi-position calibration method for MEMS inertial navigation system. **Measurement**, v. 18, n. 7, p. 1897–1907, 2007.
- TEDALDI, D.; PRETTO, A.; MENEGATTI, E. **Proceedings - IEEE International Conference on Robotics and Automation**, IEEE, p. 3042–3049, 2014. ISSN 10504729.
- VCELÁK, J. et al. AMR navigation systems and method of their calibration. **Sensors and Ac**, v. 123-124, n. 0, p. 122–128, 2005.
- WALKER, D. M. Parameter estimation using Kalman filters with constraints. **International Journal of Bifurcation and Chaos**, World Scientific Pub Co Pte Lt, v. 16, n. 04, p. 1067–1078, apr 2006.
- WEI, R. et al. A research on calibration of low-precision mems inertial sensors. In: **IEEE Chinese Control and Decision Conference**. Guiyang, China: [s.n.], 2013.
- WITHROBOT Inc. Data-Sheet IMU myAHRS+ Low Cost Attitude Heading Reference System. 2014.
- XSENS. MTi 100-series Data Sheet. 2015.

Apêndices

Detalhes dos Algoritmos

Algoritmo 7 Detecção de Estático

Entrada: $\mathbf{a}_{sx}, \mathbf{a}_{sy}, \mathbf{a}_{sz}$ (aceleração lida do sensor)

Saída: $\mathbf{a}_{ex}, \mathbf{a}_{ey}, \mathbf{a}_{ez}$ (aceleração estática)

Inicialização: $t_{per} = 80, \mathbf{var}_{lim} = 340, k = 1$

$na = size(\mathbf{a}_{sx}, 1)$

for $i = 1 : t_{per} : na - t_{per}$ **do**

for $j = 1 : t_{per}$ **do**

$x(j) = \mathbf{a}_{sx}(i + j)$

$y(j) = \mathbf{a}_{sy}(i + j);$

$z(j) = \mathbf{a}_{sz}(i + j);$

$va_x(i + j) = var(x);$

$va_y(i + j) = var(y);$

$va_z(i + j) = var(z);$

$va_T(i + j) = sqrt(va_x(i + j)^2 + va_y(i + j)^2 + va_z(i + j)^2);$

if $(va_T(i + j) > \mathbf{var}_{lim})$ **then**

$va_{bool}(i + j) = 0;$

else

$va_{bool}(i + j) = 1;$

$\mathbf{a}_{ex}(k) = \mathbf{a}_{sx}(i + j);$

$\mathbf{a}_{ey}(k) = \mathbf{a}_{sy}(i + j);$

$\mathbf{a}_{ez}(k) = \mathbf{a}_{sz}(i + j);$

$k = k + 1;$

end if

end for

end for

return

Algoritmo 8 Média das regiões estáticas

Entrada: $\mathbf{a}_{ex}, \mathbf{a}_{ey}, \mathbf{a}_{ez}$ (aceleração estática)

Saída: $\mathbf{ma}_{ex}, \mathbf{ma}_{ey}, \mathbf{ma}_{ez}$ (média da aceleração estática)

Inicialização: $\mathbf{dif}_{lim} = 1000, k = 1, i = 1$
 $na = size(\mathbf{a}_{ex}, 1)$
 $\mathbf{da}_{ex} = diff(\mathbf{a}_{ex});$
 $\mathbf{da}_{ey} = diff(\mathbf{a}_{ey});$
 $\mathbf{da}_{ez} = diff(\mathbf{a}_{ez});$
for $j = 1 : na - 1$ **do**
 $\mathbf{dT}(j) = sqrt(\mathbf{da}_{ex}(j)^2 + \mathbf{da}_{ey}(j)^2 + \mathbf{da}_{ez}(j)^2);$
if $\mathbf{dT}(j) > \mathbf{dif}_{lim}$ **then**
 $\mathbf{ma}_{ex}(i) = sumx/k;$
 $\mathbf{ma}_{ey}(i) = sumy/k;$
 $\mathbf{ma}_{ez}(i) = sumz/k;$
 $k = sumx = sumy = sumz = 0;$
 $i = i + 1;$
else
 $sumvx = +\mathbf{a}_{ex}(j);$
 $sumvy = +\mathbf{a}_{ey}(j);$
 $sumvz = +\mathbf{a}_{ez}(j);$
 $k = k + 1;$
end if
end for
 $\mathbf{ma}_{ex} = \mathbf{ma}_{ex} / max(\mathbf{ma}_{ex});$
 $\mathbf{ma}_{ey} = \mathbf{ma}_{ey} / max(\mathbf{ma}_{ey});$
 $\mathbf{ma}_{ez} = \mathbf{ma}_{ez} / max(\mathbf{ma}_{ez});$
return

Algoritmo 9 Calibração com Filtro de Kalman

Entrada: \mathbf{ma}_{ex} , \mathbf{ma}_{ey} , \mathbf{ma}_{ez} , (média da aceleração estática) \mathbf{a}_{ref} , (valores de referência gravidade)

Saída: \mathbf{x}_k (parâmetros)

Inicialização: $\mathbf{x}_k = \mathbf{ones}(12, 1)$, $\mathbf{Phi} = \mathbf{eye}(12)$, $\mathbf{Q} = 0.001 * \mathbf{eye}(12)$, $\mathbf{R} = 1$, $\mathbf{H} = \mathbf{ones}(1, 12)$, $a(1, :) = \mathit{mev}1_{my}/\mathit{max}(\mathit{mev}1_{my})$, $a(2, :) = \mathit{mev}2_{my}/\mathit{max}(\mathit{mev}2_{my})$, $a(3, :) = \mathit{mev}3_{my}/\mathit{max}(\mathit{mev}3_{my})$, $\mathbf{P} = 0.001 * \mathbf{eye}(12)$;

$na = \mathit{size}(\mathbf{a}, 2)$

for $contA = 1 : na$ **do**

$\mathbf{P}1 = \mathbf{P}$;

$\mathbf{xp} = \mathbf{Phi} * \mathbf{x}$;

$\mathbf{P}p = \mathbf{Phi} * \mathbf{P} * \mathbf{Phi}' + \mathbf{Q}$;

$\mathbf{xt} = \mathbf{xp}'$;

$\mathbf{Theta}1_a = \mathbf{xt}(1 : 3)$;

$\mathbf{Theta}2_a = \mathbf{xt}(4 : 6)$;

$\mathbf{Theta}3_a = \mathbf{xt}(7 : 9)$;

$\mathbf{Theta}_a = [\mathbf{Theta}1_a; \mathbf{Theta}2_a; \mathbf{Theta}3_a]$;

$\mathbf{b}_a = \mathbf{xt}(10 : 12)'$;

$\mathbf{aax} = a(1, contA)$;

$\mathbf{aay} = a(2, contA)$;

$\mathbf{aaz} = a(3, contA)$;

$\mathbf{H} = 16$

$\mathbf{K} = \mathbf{P}p * \mathbf{H}' * \mathit{inv}(\mathbf{H} * \mathbf{P}p * \mathbf{H}' + \mathbf{R})$;

$\mathbf{P} = (\mathbf{eye}(12) - \mathbf{K} * \mathbf{H}) * \mathbf{P}p$;

$\mathbf{abar}_{hat} = \mathbf{Theta}_a * a(:, contA) - \mathbf{b}_a$;

$\mathbf{abar}_{hat}_v(:, contA) = \mathbf{abar}_{hat}$;

$\mathbf{z} = \mathbf{abar}(:, contA)$;

$\mathbf{error} = \mathbf{z} - \mathbf{abar}_{hat}$

$\mathbf{x} = \mathbf{xp} + \mathbf{K} * (\mathbf{error})$;

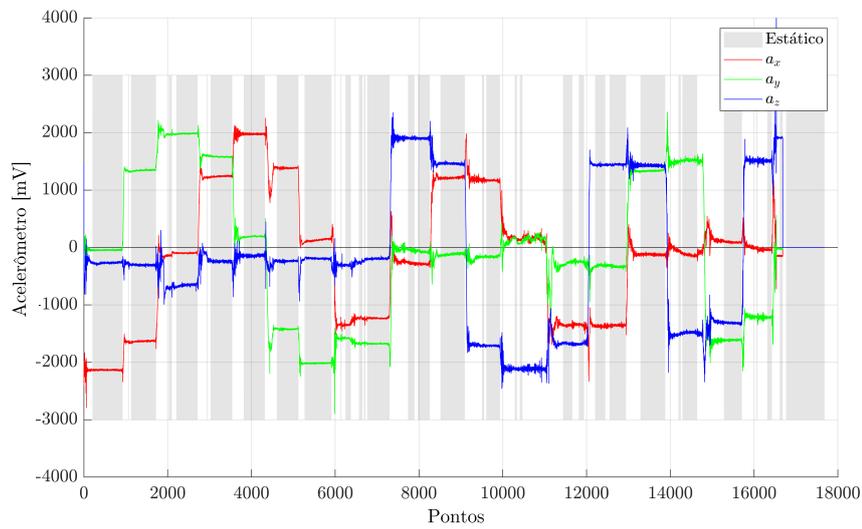
end for

return

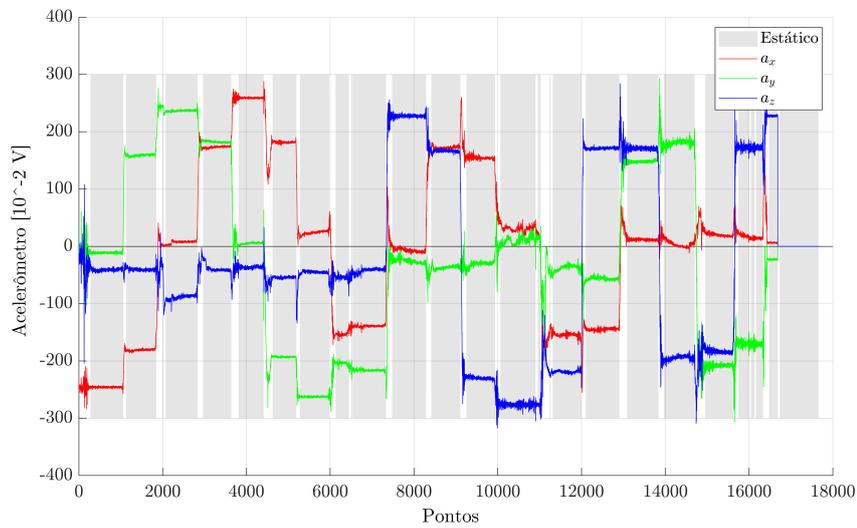
Resultados complementares

Tabela 3 – MAE para os três eixos dos sensores, normalizados em 1g

	<i>myAHRS+</i>				<i>9 DoF Razor</i>			
	<i>x</i>	<i>y</i>	<i>z</i>	média	<i>x</i>	<i>y</i>	<i>z</i>	média
<i>primeira captura</i>								
KF	0.100	0.041	0.080	0.074	0.106	0.06	0.071	0.079
CEKF	0.091	0.054	0.076	0.074	0.055	0.065	0.065	0.062
BKF	0.075	0.055	0.064	0.065	0.057	0.07	0.066	0.064
CBEKF	0.079	0.025	0.061	0.055	0.053	0.072	0.064	0.063
<i>segunda captura</i>								
KF	0.098	0.087	0.092	0.092	0.121	0.085	0.076	0.094
CEKF	0.065	0.067	0.065	0.065	0.090	0.090	0.059	0.080
BKF	0.075	0.054	0.062	0.064	0.068	0.075	0.081	0.075
CBEKF	0.039	0.056	0.05	0.050	0.057	0.086	0.077	0.073

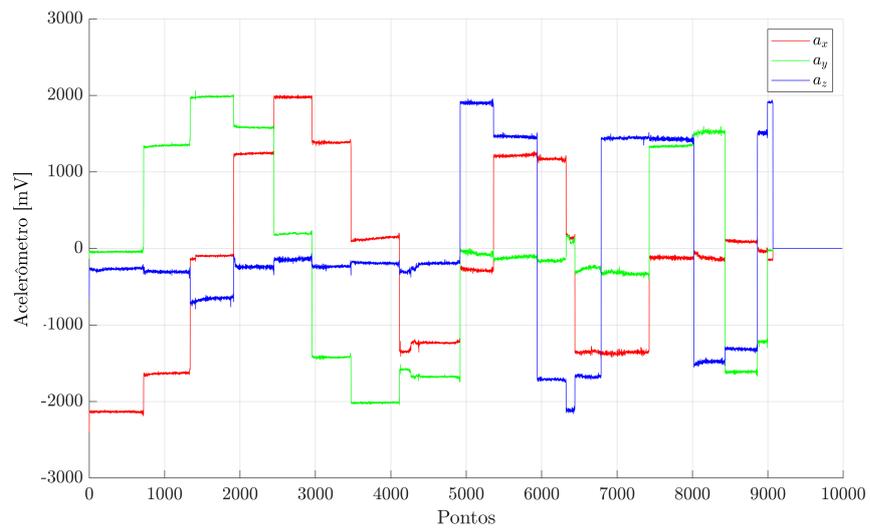


(a) myAHRs+ (segunda captura)

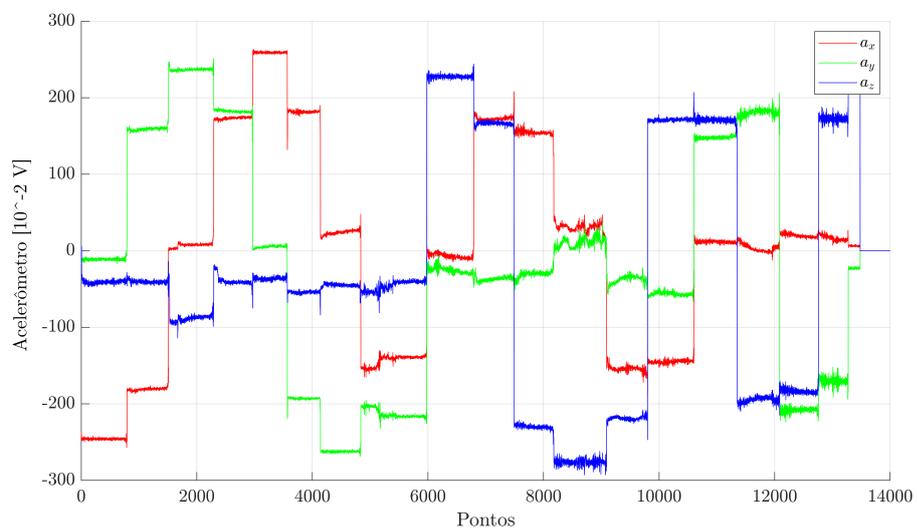


(b) 9DOF Razor (segunda captura)

Figura 13 – Capturas da aceleração bruta IMUs com marcação de períodos estáticos segunda captura.



(a) myAHRS+ (segunda captura)



(b) 9DOF Razor (segunda captura)

Figura 14 – Períodos estáticos das capturas de aceleração das IMUs segunda captura.