Samuel Lourenço Nogueira

**Sistemas Markovianos para Estimativa de
Ângulos Absolutos em Exoesqueletos de
Membros Inferiores**

Tese apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Ciências, Programa de Engenharia Mecânica.

Área de Concentração: Dinâmica de Máquinas
e Sistemas

Orientador: Prof. Dr. Adriano A. G. Siqueira

São Carlos
2015

Trata-se da versão corrigida da tese. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Mecânica.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

N778s Nogueira, Samuel Lourenço
Sistemas Markovianos para Estimativa de Ângulos
Absolutos em Exoesqueletos de Membros Inferiores /
Samuel Lourenço Nogueira; orientador Adriano A. G.
Siqueira. São Carlos, 2015.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Mecânica e Área de Concentração em Dinâmica
de Máquinas e Sistemas -- Escola de Engenharia de São
Carlos da Universidade de São Paulo, 2015.

1. Sistemas lineares. 2. Tempo discreto. 3. Saltos
Markovianos. 4. Filtro de Kalman. 5. Filtro robusto. 6.
Órteses. 7. Exoesqueletos. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **SAMUEL LOURENÇO NOGUEIRA**.

Título da tese: "Sistemas markovianos para estimativa de ângulos absolutos em exoesqueletos de membros inferiores".

Data da defesa: 14/01/2015

Comissão Julgadora:

Resultado:

Prof. Associado **Adriano Almeida Gonçalves Siqueira**
(Orientador)

(Escola de Engenharia de São Carlos/EESC)

Aprovado

Prof. Associado **Marco Henrique Terra**

(Escola de Engenharia de São Carlos/EESC)

Aprovado

Prof. Dr. **Anselmo Frizera Neto**

(Universidade Federal do Espírito Santo/UFES)

Aprovado

Prof. Dr. **Arlindo Neto Montagnoli**

(Universidade Federal de São Carlos/UFSCar)

Aprovado

Dr. **Eduardo Rocon de Lima**

(Universidade Politécnica de Madrid/UPM)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Mecânica:
Prof. Associado **Marcelo Areias Trindade**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo César Lima Segantine**

Aos meus pais Carlos e Adelina, e a minha tia
Alice que tanto me apoiaram durante todo este tempo.

Agradecimentos

Aos meus pais Carlos Alberto Nogueira e Adelina Lourenço Nogueira com amor, admiração e gratidão por sua compreensão, carinho, presença e incansável apoio ao longo do período deste doutorado. A minha tia Alice Adelina Lourenço de Oliveira que tanto me ajudou em minha permanência em São Carlos.

A minha querida Tatiane pelo amor, companheirismo, paciência e por toda a ajuda incondicional durante todo meu doutorado.

Ao Prof. Dr. Adriano Almeida Gonçalves Siqueira pela confiança, orientação, paciência e pelo tempo dedicado a este trabalho.

Ao Prof Dr. Marco Henrique Terra pela atenção, apoio e contribuições deste trabalho.

Aos amigos da pós-graduação: Aline, Amanda, Christoph, Darby, Gildson, Guido, Guilherme, Juan, João Paulo, Pedro, Tubota, Thais, Wilian e Yuri pela amizade, paciência, companheirismo e colaborações durante a realização das disciplinas e deste trabalho.

Em especial agradeço aos professores Dr. Roberto, Dr. Ricardo e Dra. Tatiana e pela paciência e grandes colaborações nesta tese.

Aos professores e funcionários do Departamento de Engenharia Mecânica e Elétrica da Escola de Engenharia de São Carlos, pelas contribuições durante o doutorado.

A Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelas concessões das bolsas de doutorado, que permitiram minha dedicação a este trabalho.

"Convictions are more dangerous enemies of truth than lies."

Friedrich Nietzsche

RESUMO

NOGUEIRA, S. L. Sistemas Markovianos para Estimativa de Ângulos Absolutos em Exoesqueletos de Membros Inferiores. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2015.

Nesta tese de doutorado são apresentados sistemas globais de estimativa baseados em modelos Markovianos aplicados na área de reabilitação robótica. Os sistemas propostos foram desenvolvidos para estimar as posições angulares dos elos de exoesqueletos para membros inferiores, desenvolvidos para reabilitação motora em pacientes que sofreram Acidente Vascular Cerebral (AVC) ou lesão medular. Filtros baseados no filtro de Kalman, um nominal e outro considerando incertezas no modelo, foram utilizados em estratégias de fusão de dados de sensores provenientes de sensores inerciais, possibilitando estimativas de posicionamentos angulares. Algoritmos genéticos são utilizados na otimização dos filtros, ajustando as matrizes de peso destes. Em oposição às modelagens tradicionais, via estimativa local, utilizando somente uma unidade inercial para cada modelo, propõe-se um sistema global de estimativa, obtendo-se a melhor informação de cada sensor combinando-os em um modelo Markoviano. Resultados experimentais com um exoesqueleto foram utilizados para comparar a abordagem Markoviana às convencionais.

Palavras-Chave: *Sistemas lineares, tempo discreto, saltos Markovianos, filtro de Kalman, filtro robusto, ortheses, exoesqueletos.*

ABSTRACT

NOGUEIRA, S. L. *Markovians Systems to Estimate Absolute Angles in Lower Limb Exoskeletons. Thesis (Doctoral) - São Carlos School of Engineering, University of São Paulo, São Carlos, 2015.*

In this thesis are presented global estimation systems based on Markov models applied in robotic rehabilitation area. The proposed systems have been developed to estimate the angular positions of the exoskeletons for lower limbs, designed to provide motor rehabilitation of stroke and spinal cord injured people. Filters based on the Kalman filter, one nominal and other considering uncertainties in the model, were used in sensor data fusion strategies from inertial sensors, to estimate angular positions. Genetic algorithms are used to the optimization of filters, tuning the weighting matrices. In opposition to these modelling via local estimation, using only one inertial unit, we also chose a global modelling getting the best information from each sensor, combining them in a Markov model. Experimental results with an exoskeleton were used to compare the Markovian approach to conventional.

Keywords: *Linear systems, discrete-time systems, Markovian jump, Kalman filter, robust filter, orthoses, exoskeleton.*

PUBLICAÇÕES

Publicações em periódicos

NOGUEIRA, S. L., SIQUEIRA, A. A. G., INOUE, R. S. E TERRA, M. H., *Markov Jump Linear Systems-Based Position Estimation for Lower Limb Exoskeletons. Sensors: Special Issue Wearable Gait Sensors 2014, Vol. 14, pp. 1835-1849.*

Publicações em conferências

NOGUEIRA, S. L., SIQUEIRA, A. A. G., INOUE, R. S. e TERRA, M. H., *Markov Jump Linear Systems-Based Position Estimation for Lower Limb Exoskeletons. In: American Control Conference (ACC), Proceedings of 2014 IEEE/IFAC American Control Conference. Invited paper.*

CHAIM, V. C., NOGUEIRA, S. L. e SIQUEIRA, A. A. G., *Estimativa de Forças de Interação para Exoesqueleto de Membros Inferiores. In: XX Congresso Brasileiro de Automática (CBA), Proceedings of 2014 Congresso Brasileiro de Automática, 2014.*

NOGUEIRA, S. L., SIQUEIRA, A. A. G., INOUE, R. S. e TERRA, M. H., *Estimation of Lower Limbs Angular Positions using Robust Kalman Filter and Genetic Algorithm. In: International Congress of Mechanical Engineering (COBEM 2013), Proceedings of 22nd International Congress of Mechanical Engineering.*

NOGUEIRA, S. L., INOUE, R. S., TERRA, M. H. e SIQUEIRA, A. A. G., *Estimation of Lower Limbs Angular Positions using Kalman Filter and Genetic Algorithm. In: IEEE Biosignals and*

Biorobotics (ISSNIP), Proceedings of IV IEEE Biosignals and Biorobotics (ISSNIP), 2013.

LISTA DE FIGURAS

FIGURA 1.1	Planos anatômicos.	9
FIGURA 1.2	Diagrama de funcionamento.	10
FIGURA 2.1	Filtro de Kalman complementar.	15
FIGURA 2.2	Sensor inercial com giroscópio e acelerômetro mono-axiais.	15
FIGURA 2.3	Filtro complementar, sensor inercial de um eixo.	16
FIGURA 2.4	Algoritmo preditor-corretor para o FK.	18
FIGURA 2.5	Sapato com FSRs na sola.	19
FIGURA 2.6	Modos de operação do FKSM.	26
FIGURA 3.1	Topologia do algoritmo genético.	30
FIGURA 3.2	Método da roleta.	33
FIGURA 4.1	Exoesqueletos Exo-Kanguera e Exo-H1.	38
FIGURA 4.2	Disposição dos ângulos absolutos.	39
FIGURA 4.3	Velocidade do tronco.	41
FIGURA 4.4	Velocidade da coxa.	41

FIGURA 4.5	Velocidade da canela.	41
FIGURA 4.6	Velocidade do pé.	41
FIGURA 4.7	Acelerações do tronco.	43
FIGURA 4.8	Acelerações da coxa.	43
FIGURA 4.9	Acelerações da canela.	44
FIGURA 4.10	Acelerações do pé.	44
FIGURA 4.11	Filtro complementar para um exoesqueleto de membros inferiores. . .	46
FIGURA 4.12	Modos de operação.	55
FIGURA 4.13	Evolução dos AG, simulação, filtros nominais.	64
FIGURA 4.14	Ângulo tronco, simulação, filtros nominais.	65
FIGURA 4.15	Ângulo coxa, simulação, filtros nominais.	66
FIGURA 4.16	Ângulo canela, simulação, filtros nominais.	68
FIGURA 4.17	Ângulo pé, simulação, filtros nominais.	69
FIGURA 4.18	Evolução dos AG, simulação, filtros robustos.	74
FIGURA 4.19	Ângulo do tronco, simulação, filtros robustos.	75
FIGURA 4.20	Ângulo da coxa, simulação, filtros robustos.	75
FIGURA 4.21	Ângulo da canela, simulação, filtros robustos.	76
FIGURA 4.22	Ângulo do pé, simulação, filtros robustos.	76
FIGURA 5.1	Tech IMU, Technaid.	80
FIGURA 5.2	Captura estática com IMU, (a) giroscópios e (b) acelerômetros. . . .	82
FIGURA 5.3	Exo-H1 com IMUs e marcadores foto-reflexivos.	83
FIGURA 5.4	Exoesqueleto Exo-H1.	84
FIGURA 5.5	Smart-D.	85
FIGURA 5.6	Dados capturados pelos giroscópios no plano sagital.	86

FIGURA 5.7	Dados capturados pelos acelerômetros triaxiais.	87
FIGURA 5.8	Dados capturados pelos <i>encoders</i> do Exo-H1, e as fases do caminhar identificadas.	88
FIGURA 6.1	Custos por intervalo, no segmento do tronco.	91
FIGURA 6.2	Ângulo absoluto do tronco, validação, filtros locais.	93
FIGURA 6.3	Ângulo absoluto da coxa, validação, filtros locais.	94
FIGURA 6.4	Ângulo absoluto da canela, validação, filtros locais.	94
FIGURA 6.5	Ângulo absoluto do pé, validação, filtros locais.	95
FIGURA 6.6	Ângulo absoluto do tronco, validação, filtros nominais.	97
FIGURA 6.7	Ângulo absoluto da coxa, validação, filtros nominais.	97
FIGURA 6.8	Ângulo absoluto da canela, validação, filtros nominais.	98
FIGURA 6.9	Ângulo absoluto do pé, validação, filtros nominais.	98
FIGURA 6.10	Ângulo absoluto do tronco, validação, filtros robustos.	101
FIGURA 6.11	Ângulo absoluto da coxa, validação, filtros robustos.	101
FIGURA 6.12	Ângulo absoluto da canela, validação, filtros robustos.	102
FIGURA 6.13	Ângulo absoluto do pé, validação, filtros robustos.	102
FIGURA B.1	Eixo de coordenadas.	116
FIGURA B.2	Funcionamento do acelerômetro.	119
FIGURA D.1	Algoritmo genético.	129
FIGURA F.1	Exoesqueleto Exo-Kanguera.	136
FIGURA F.2	Exoesqueleto Exo-H1. Imagens retiradas de Bortole et al. (2013) e <i>www.technaid.com</i>	137
FIGURA F.3	OpenSim 2.4 utilizando um modelo para membros inferiores.	138
FIGURA F.4	Tech IMU, Technaid.	139

LISTA DE TABELAS

TABELA 2.1	Fases do caminhar identificadas com FSRs.	19
TABELA 3.1	Universo de discurso para o FK nominal.	31
TABELA 3.2	Constantes ajustadas no genético, FK local.	32
TABELA 4.1	Tabela de estados Markovianos	57
TABELA 4.2	Parâmetros do sistema, FK local, simulação.	63
TABELA 4.3	Parâmetros do sistema, FK matricial, simulação.	63
TABELA 4.4	Parâmetros do sistema, FKSM, simulação.	67
TABELA 4.5	Parâmetros do sistema, FKR para $\alpha = 0,55$, simulação.	73
TABELA 4.6	Parâmetros do sistema, FKRS para $\alpha = 0,38$, simulação.	74
TABELA 6.1	Parâmetros do sistema, FK local com FSR, captura com Exo-H1. . .	93
TABELA 6.2	Parâmetros do sistema, FK local com acelerômetro, captura com Exo-H1.	93
TABELA 6.3	Parâmetros do sistema, FK matricial, captura com Exo-H1.	96
TABELA 6.4	Parâmetros do sistema, FKSM, captura com Exo-H1.	96

TABELA 6.5	Parâmetros do sistema, FKR matricial para $\alpha = 0,61$, , captura com Exo-H1.	99
TABELA 6.6	Parâmetros do sistema, FKRSM para $\alpha = 0,92$, , captura com Exo-H1.	100
TABELA 7.1	Índices de desempenho.	103
TABELA E.1	Universo de discurso para os FKs locais com acelerômetros, simulações, para $i = \{B, T, S, F\}$	131
TABELA E.2	Universo de discurso para os FKs locais com FSR, experimentos reais, para $i = \{B, T, S, F\}$	132
TABELA E.3	Universo de discurso para os FKs locais com acelerômetros, experimentos reais, para $i = \{B, T, S, F\}$	132
TABELA E.4	Universo de discurso para os filtros nominais, simulações, para $i = \{B, T, S, F\}$	133
TABELA E.5	Universo de discurso para os filtros nominais, experimentos reais, para $i = \{B, T, S, F\}$	133
TABELA E.6	Universo de discurso para os filtros robustos, simulações e experimentos reais, para $i = \{B, T, S, F\}$	134
TABELA F.1	Faixas de movimentação do Exo-Kanguera e do caminhar humano. . .	136
TABELA F.2	Faixas de movimentação do Exo-H1 e do caminhar humano.	137
TABELA F.3	Especificações técnicas das IMUs.	140

LISTA DE ABREVIATURAS E SIGLAS

AG(s) - Algoritmo(s) **G**enético(s)

FK(s) - Filtro(s) de **K**alman

FKR(s) - Filtro(s) de **K**alman **R**obusto(s)

FKSM(s) - Filtro(s) de **K**alman sujeito a Saltos **M**arkovianos

FKRSM(s) - Filtro(s) de **K**alman **R**obusto(s) sujeito a Saltos **M**arkovianos

FSR(s) - *Force Sensitive Resistor(s)*

IMU(s) - *Inertial Measurement Unit(s)*

VANT(s) - Veículo(s) **A**éreo(s) **N**ão Tripulado(s)

WR(s) - *Wearable Robot(s)*

SUMÁRIO

1	Introdução	5
1.1	Motivação	5
1.2	Posicionamentos angulares absolutos	6
1.3	Objetivos	8
1.4	Proposta	9
1.5	Organização dos Capítulos	11
2	Metodologias	13
2.1	Abordagem complementar para filtro de Kalman	14
	Exemplo: sensor inercial	14
2.2	Estimativa de ângulos absolutos utilizando FK na abordagem complementar com sensores inerciais	18
2.3	Filtro de Kalman robusto na abordagem complementar	22
2.4	Filtro de Kalman sujeitos a saltos Markovianos com cadeia de Markov conhecida	24
2.5	Considerações finais sobre as metodologias	27
3	Plataforma de busca e otimização	29
3.1	Topologia	29
3.2	Função de aptidão	31
3.3	Seleção	31
3.4	Cruzamento	33
3.5	Mutação	35
3.6	Critérios de parada	35

Considerações finais	35
4 Modelagens e resultados preliminares	37
4.1 Simulação de sensores inerciais	40
4.2 Sistema de estimativa baseado no FK-complementar	45
4.3 Sistema de estimativa baseado no FKSM-complementar	54
4.4 Resultados preliminares para os filtros nominais	61
4.5 Sistema de estimativa baseado no FKR-complementar	67
4.6 Sistema de estimativa baseado no FKRSM-complementar	71
4.7 Resultados preliminares para os filtros robustos	72
5 Coleta de dados	79
5.1 Captura estática com IMU	79
5.2 Captura com Exo-H1	81
5.2.1 Dificuldades inerentes	83
5.2.2 Dados capturados	85
6 Estudos de caso	89
6.1 Confiabilidade do acelerômetro	90
6.2 Sistemas de estimativas baseados nos modelos nominais	95
6.3 Sistemas de estimativas baseados nos modelos robustos	99
7 Conclusões	103
Trabalhos futuros	104
Referências Bibliográficas	105
Apêndice	109
A Filtro de Kalman	111
B Modelagem de sensores inerciais	115
B.1 Modelo dos erros dos sensores inerciais	115
B.2 Modelo inercial do Giroscópio	118
B.3 Modelo inercial do Acelerômetro	118
C Algoritmos de filtragem	121

C.1	FK-complementar local	122
C.2	FK-complementar local com acelerômetros triaxiais	123
C.3	FKR-complementar local	124
C.4	FK-complementar matricial	125
C.5	FKSM-complementar	126
D	Algoritmos genéticos	127
E	Universos de busca dos filtros	131
E.1	Filtros nominais locais	131
E.2	Filtros nominais	133
E.3	Filtros robustos	134
F	Dispositivos e Programas	135
F.1	Exoesqueleto Exo-Kanguera	135
F.2	Exoesqueleto Exo-H1	136
F.3	Open Sim	138
F.4	TECH MCS	139

CAPÍTULO 1

INTRODUÇÃO

1.1 Motivação

O desenvolvimento de tecnologias para reabilitação, usos assistivos e auxiliares ao caminhar humano, tem despertado grande interesse em pesquisadores desde o início do século XXI. Entretanto, numerosos desafios ainda impedem que tais tecnologias sejam clinicamente utilizadas, e tornem-se uma realidade viável, Pons et al. (2007). Dentre estas, destaca-se o desenvolvimento de tecnologias robóticas vestíveis, do inglês *Wearable Robots* (WR), sendo que tais dispositivos podem ser utilizados de forma assistiva ou para reabilitação de indivíduos com deficiência de locomoção.

Segundo Pons (2008), uma importante característica de WR está na intrínseca interação entre o ser humano e o robô. Esta interação implica na cooperação entre o robô e o indivíduo, levando à aplicação de controladores de força e impedância. A ação destes dois agentes deve ser coordenada e adaptada mutualmente pois o comportamento inesperado de um destes durante uma interação poderá ocasionar sérias lesões ao usuário.

A interação física homem-robô representa uma das formas mais críticas de interação entre homens e máquinas. Qualquer movimento do robô que ocorra em contato com o ser humano,

deve ser suave e complacente, e nunca excedendo a força máxima suportada pela pessoa. Desta forma, o sensoriamento de WR deve ser extremamente cuidadoso, pois pequenas falhas podem provocar erros de medição e estimativa, fornecendo informações imprecisas aos controladores.

1.2 Posicionamentos angulares absolutos

Para o acionamento de exoesqueletos, é necessário o conhecimento de posicionamentos absolutos dos elos. Os sistemas mais precisos para captura destas informações consistem no uso de câmeras com marcadores reflexivos. Esses sistemas realizam aquisições do movimento espacial (3D) através de marcadores posicionados no corpo, enquanto algoritmos retornam ângulos de inclinação e orientação e parâmetros da marcha. No entanto, o uso desses equipamentos exigem um laboratório montado e dedicado para este fim, inviabilizando o uso de tais dispositivos para captura e armazenamento de informações fora do ambiente laboratorial. Isto limita a distância de caminhada ou mesmo a liberdade de movimentos. Recentemente, teve início o uso de sensores inerciais fixos ao corpo, para estimativa de ângulos de inclinação e orientação. Isto permitiu uma nova possibilidade para reconstruir o movimento espacial do corpo humano, sem a necessidade de existir um laboratório dedicado, veja Luinge e Veltink (2004), Luinge e Veltink (2005), Young et al. (2010), Caltran e Siqueira (2010) e Caltran et al. (2011).

Uma das metodologias mais significativas dessa nova abordagem pode ser vista em Luinge e Veltink (2004), na qual foi apresentado um estudo sobre um modelo com acelerômetros para aumentar a precisão de medida da inclinação do corpo humano. Após esta abordagem, em Luinge e Veltink (2005), foi proposta a utilização de giroscópios e acelerômetros tri-axiais para estimar orientação dos segmentos do corpo humano. Posteriormente, em Luinge et al. (2007), foi realizado um estudo para estimar orientações em membros superiores do corpo humano, utilizando a metodologia proposta em Luinge e Veltink (2005), mas levando em consideração as restrições anatômicas decorrente do cotovelo.

Em Roetenberg et al. (2007) foi proposto um sistema contendo sensores inerciais e magnéticos para medir posição e orientação de um corpo. Nesta proposta, os sensores inerciais são responsáveis por realizar o sensoriamento do corpo com uma alta taxa de aquisição e os sensores magnéticos geram sinais de referência/correção a uma taxa mais baixa. No entanto, essa

tecnologia utiliza bobinas elétricas presas ao corpo para gerar o campo magnético medido pelos sensores.

Já em Young et al. (2010), foi proposta uma abordagem consistindo de três IMUs por perna, contendo acelerômetros e giroscópios para estimar os ângulos do joelho e tornozelo de cada perna, nessa abordagem utilizou-se o filtro estendido de Kalman.

Analisando os trabalhos citados anteriormente, verifica-se que os mesmos utilizam o filtro de Kalman estendido, que fornecem resultados excelentes quando são utilizados com sensores precisos, (Farrell e Barth (1998), Rogers (2003), Farrell (2008)).

No entanto, algumas aplicações importantes têm utilizado sensores de baixo custo para estimativa de posição angular. Veículos não tripulados são exemplos nos quais esses sistemas de navegação têm sido utilizados para estimar os ângulos de arfagem, rolagem e guinada, veja (Roumeliotis et al. (1998), Castellanos et al. (2005), Jung e Tsiotras (2007), Bijker e Steyn (2008)). Infelizmente, a utilização de sensores de baixo custo significa, geralmente, o aumento de incertezas e ruídos, veja Xing e Gebre-Egziabher (2008), que viola a premissa central do filtro de Kalman, em que o modelo em espaço de estados deve ser preciso, Sayed (2001). Assim, este tipo de problema motiva o uso da estimativa robusta para limitar a degradação do desempenho de filtros ótimos. Diversos métodos para estimar parâmetros do modelo linear sujeitos a incertezas foram desenvolvidos (Sayed (2001), Ishihara et al. (2006), Ishihara e Terra (2008), Bianco et al. (2008)). Essas técnicas têm sido aplicadas em problemas práticos e os resultados obtidos têm sido promissores. Por exemplo, os filtros robustos propostos em Sayed (2001) foram utilizados em Dominguez et al. (2006) para estimar o acompanhamento de trajetória da ponta de um dedo em uma interface homem máquina, e em Inoue et al. (2009) para estimar atitude, velocidade, e posição de um veículo a partir de dados de uma IMU e um receptor GPS.

No Laboratório de Reabilitação Robótica, da Universidade de São Paulo em São Carlos, os filtros robustos descritos acima foram utilizados em (Caltran e Siqueira (2010), Caltran et al. (2011)) para a correção do ângulo absoluto de uma órtese de tornozelo-pé ativa. Os dados foram obtidos a partir de giroscópios e acelerômetros de uma IMU. Vale notar que neste caso, apenas um grau de liberdade foi estimado, sendo que no caso do exoesqueleto para membros inferiores a ser utilizado neste projeto, pelo menos quatro graus de liberdade serão estimados.

Outro problema decorrente da fusão de sensores inerciais, refere-se ao aumento da acelera-

ção dinâmica. Pois as estimativas de ângulos absolutos destes realizam a fusão de giroscópios e acelerômetros, sendo que a incidência de acelerações dinâmicas afetam diretamente a precisão dos acelerômetros, diminuindo a eficiência de estimativa angular. Com isso, as abordagens propostas em Luinge e Veltink (2005) e Young et al. (2010), tornam-se altamente dependentes das acelerações dinâmicas, o que pode diminuir suas eficiências de estimativa. Como a dinâmica dos segmentos inferiores humanos mudam a cada instante do caminhar, seria interessante que o sistema de estimativa suportasse tais mudanças, sem que a sua eficiência fosse afetada.

A modelagem Markoviana para sistemas robóticos tem sido utilizada para resolver problemas de controle, na qual a dinâmica do sistema muda bruscamente. A principal característica desta abordagem é que probabilidade do sistema estar em uma configuração diferente no próximo instante de tempo, dependendo somente da configuração atual, independentemente do intervalo de tempo considerado. Por exemplo, em Siqueira e Terra (2004), um controlador de posição Markoviano $\mathcal{H}_\infty$ foi implementado em um manipulador subatuado, sujeito a mudanças bruscas em sua configuração. Este foi desenvolvido para atuar com um conjunto de falhas em suas juntas.

Nesta tese, é proposta uma nova abordagem baseada em modelos Markovianos para estimativa de ângulos absolutos em exoesqueletos de membros inferiores, tal que a confiabilidade dos acelerômetros seja aumentada para todas as fases do caminhar. Em contraste com as abordagens anteriormente descritas, nas quais os sistemas de estimativa eram individuais para cada elo, nesta tese é proposto um modelo coletivo de todos os sensores inerciais fixos no exoesqueleto.

1.3 Objetivos

Neste trabalho, visando obter uma aplicação mais confiável, propõe-se uma abordagem global e robusta para sensoriamento de posições angulares absolutas em exoesqueletos de membros inferiores, utilizadas para estimar a intenção de caminhar do paciente e para o controle do caminhar. Além disso, busca-se desenvolver uma plataforma para otimização dos parâmetros da abordagem proposta, visando automatizar a adaptação desta a diferentes tipos de exoesqueletos e sensores.

Figura 1.1: Planos anatômicos.

1.4 Proposta

Neste trabalho é proposto o desenvolvimento de um sistema robusto para estimativa de posicionamentos angulares absolutos para um exoesqueleto de membros inferiores. Seu diferencial com relação a Luinge e Veltink (2005) e Young et al. (2010) está no uso de filtros de Kalman robustos e Markovianos, com o acréscimo de *encoders*, constituindo assim uma abordagem global de sensores para estimativas. Assim, espera-se uma melhoria imediata da precisão de medida e maior tolerância a incertezas paramétricas, as quais não são previstas por Luinge e Veltink (2005) e Young et al. (2010). O objetivo é estimar os ângulos absolutos de todos os segmentos de um exoesqueleto para membros inferiores no plano sagital, veja a Figura 1.1. Com isso haverá informações suficientes para a reconstituição do movimento angular humano para membros inferiores, durante o uso de exoesqueletos.

Portanto, propõe-se um modelo generalista e de fácil adaptação para exoesqueletos e órteses de membros inferiores. A Figura 1.2 exhibe o funcionamento básico do modelo proposto. Abaixo são descritos os aspectos tecnológicos e científicos desta tese.

Figura 1.2: Diagrama de funcionamento.

Ponto de vista tecnológico:

- Projeto e construção de sistema para estimativa de posicionamentos angulares para membros inferiores,
- Utilização de acelerômetros, giroscópios e *encoders*,
- Posicionamento angular de exoesqueletos, robôs bípedes e humanoides,
- Utilização em ambulatórios móveis, reabilitação bio-motora,
- Análise do caminhar humano.

Ponto de vista científico:

- Modelagem redundante para uso de filtros e comparação de desempenho, tais como:
 - Filtro de Kalman,
 - Filtro de Kalman sujeito a Saltos Markovianos.
 - Filtro de Kalman Robusto proposto em Sayed (2001),
 - Filtro de Kalman Robusto sujeito a Saltos Markovianos.

Este projeto visa fornecer estimativas das posições necessárias para alimentar e validar o desenvolvimento de algoritmos de controle de marcha para exoesqueletos de membros inferiores.

Por fim, ressaltamos que as principais contribuições deste trabalho são:

- O desenvolvimento do sistema Markoviano para estimativas angulares absolutas em exoesqueletos.
- Metodologia para identificação ou otimização das matrizes de incerteza para filtros robustos.
- Plataforma de identificação ou otimização de parâmetros utilizando algoritmos genéticos concorrentes.

1.5 Organização dos Capítulos

Este documento está organizado da seguinte forma: No Capítulo 2, são abordadas as principais metodologias que foram utilizados neste trabalho. No Capítulo 3, é apresentada a plataforma de busca/otimização via algoritmos genéticos (AG), desenvolvida neste trabalho para otimizar os parâmetros dos filtros modelados. Já no Capítulo 4, são apresentados todos os modelos no espaço de estados desenvolvidos para os sistemas de estimativas propostos, e também resultados preliminares obtidos através de simulações computacionais. No Capítulo 5, são apresentados os procedimentos experimentais realizados, juntamente com os dados capturados. No Capítulo 6, são apresentados três estudos comparativos visando demonstrar as características de cada sistema de estimativa. Por fim, no capítulo de conclusões são feitas sínteses dos principais resultados e contribuições desta tese.

CAPÍTULO 2

METODOLOGIAS

Neste capítulo serão apresentados os principais métodos e abordagens utilizados ao longo dessa tese. As principais metodologias apresentadas nesse capítulo são:

- Abordagem complementar para o Filtro de Kalman, FK-complementar.
- Estimativa de ângulos absolutos utilizando FK-complementar com sensores inerciais.
- Filtro de Kalman Robusto (FKR) na abordagem complementar, FKR-complementar.
- Sistemas discretos sujeitos a saltos Markovianos.

Decorrente da sequência proposta acima, na Seção 2.1 será apresentada a base conceitual para todo o desenvolvimento e modelagens precedentes, bem como a justificativa para o uso do Filtro de Kalman (FK) na abordagem complementar. Na Seção 2.2 será apresentado o modelo de estimativas para ângulos absolutos de uma órtese pé-tornozelo proposto por Caltran e Siqueira (2010), sendo que a mesma pode ser estendida para membros inferiores. Na sequência, Seção 2.3, será introduzido o Filtro de Kalman Robusto (FKR) proposto por Sayed (2001), bem como o exemplo de um sistema de estimativa angular absoluta. Por fim, na Seção 2.4 é apresentado o filtro de Kalman sujeito a saltos Markovianos com cadeia de Markov conhecida, acompanhado de um exemplo ilustrativo.

Ao fim deste capítulo espera-se fornecer as técnicas e ferramentas mínimas para o correto entendimento deste trabalho. Outras técnicas não menos importantes foram dispostas nos apêndices, como por exemplo: o filtro de Kalman discreto no Apêndice A, a modelagem de sensores inerciais no Apêndice B e os algoritmos genéticos no Apêndice D.

2.1 Abordagem complementar para filtro de Kalman

O uso de filtros de Kalman na abordagem complementar fornecem alto grau de generalidade, pois permitem a junção de uma grande variedade de medidas provindas de sensores auxiliares. Ou seja, através destes é possível realizar a integração/fusão de sinais de diferentes tipos de sensores. Além disso, a abordagem complementar possui uma rápida resposta dinâmica para as variáveis de estado. Isto é um fator importante, tendo em vista que o custo da filtragem está associado ao atraso no tempo ou uma resposta lenta. Sendo este atraso indesejável na maioria dos sistemas que operam em tempo real, como é o caso do controle de exoesqueletos, na qual as informações cinemáticas devem ser adquiridas independentemente da velocidade com que elas ocorrerem e são enviadas aos controladores. Dessa forma, tem-se que a filosofia do FK na abordagem complementar realiza a integração dos sinais evitando o atraso de tempo após o processo de filtragem. Este comportamento só é possível pois o filtro complementar opera somente na combinação dos erros dos sinais modelados com os erros dos sinais auxiliares, não atuando na dinâmica total dos sinais, sendo que os sinais modelados passam pelo sistema sem sofrerem distorções ou atrasos. Como pode ser visto na Figura 2.1, os sinais de interesse tais como posições, velocidades, etc, não alimentam diretamente o filtro de Kalman, sendo os erros do sistema a entrada do filtro. Tais filtros são também nomeados, em inglês, como: *distortionless filtering* e *dynamically exact system integration*, veja Brown e Hwang (1997). Abaixo, é ilustrado um exemplo de uso deste filtro.

Exemplo: sensor inercial

Como exemplo, considere um sensor inercial contendo um giroscópio e um acelerômetro mono-axiais, sendo estes dispostos perpendicularmente tal que o giroscópio encontra-se na di-

Figura 2.1: Filtro de Kalman complementar.

reção do eixo-Y e o acelerômetro na direção do eixo-X, como ilustra a Figura 2.2. Neste caso, podemos desenvolver um filtro para estimar o ângulo absoluto no plano X-Z tomando como referência o vetor gravidade. Utilizando o deslocamento angular do giroscópio e os ângulos absolutos obtidos pelo acelerômetro através do plano X-Z, desde que o mesmo esteja parado ou realizando movimento uniforme (velocidade constante), podemos implementar um filtro para estimar o ângulo.

Dessa forma, solucionando o problema de estimativa na forma complementar, Figura 2.3, veja o Apêndice B para maiores detalhes. Temos que, o sensor modelado passa a ser o giroscópio do eixo-Y, e o sensor auxiliar de correção sendo o acelerômetro no eixo-X. Como ilustrado na Figura 2.3, o filtro de Kalman atuará somente no erro ($\Delta\theta$) entre o ângulo medido através do giroscópio ($\hat{\theta}_g$) e o ângulo medido através do acelerômetro ($\hat{\theta}_a$) fornecendo somente uma correção $\Delta\hat{\theta}$ para o ângulo do modelo (giroscópio).

Portanto, através da abordagem complementar teríamos que modelo no espaço de estados utilizado pelo filtro de Kalman, para este exemplo, é dado abaixo.

Figura 2.2: Sensor inercial com giroscópio e acelerômetro mono-axiais.

Figura 2.3: Filtro complementar, sensor inercial de um eixo.

Portanto, as estimativas da velocidade angular e da polarização (*bias*) do giroscópio dadas por:

$$\dot{\hat{\theta}}(t) = \hat{\omega}(t) = \omega_g(t) + \hat{b}_g(t), \quad (2.1)$$

$$\dot{\hat{b}}_g(t) = -\frac{1}{\tau_g} \hat{b}_g(t). \quad (2.2)$$

Então, tem-se:

$$\begin{aligned} \Delta\dot{\theta}(t) &= \Delta\omega(t) = \omega(t) - \hat{\omega}(t) \\ &= b_g(t) - \hat{b}_g(t) + \eta_{b_g}(t) \\ &= \Delta b(t) + \eta_g(t), \end{aligned} \quad (2.3)$$

$$\begin{aligned} \Delta\dot{b}(t) &= \dot{b}_g(t) - \dot{\hat{b}}_g(t) \\ &= -\frac{1}{\tau_g} (b_g(t) - \hat{b}_g(t)) + \eta_{b_g}(t) \\ &= -\frac{1}{\tau_g} \Delta b(t) + \eta_{b_g}(t), \end{aligned} \quad (2.4)$$

obtêm-se a equação dinâmica do sistema:

$$\dot{x} = Ax(t) + Bw(t)$$

$$\dot{x} = \begin{bmatrix} \Delta\dot{\theta}(t) \\ \Delta\dot{b}(t) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & -\frac{1}{\tau_g} \end{bmatrix} \begin{bmatrix} \Delta\theta(t) \\ \Delta b(t) \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \eta_g(t) \\ \eta_{b_g}(t) \end{bmatrix}, \quad (2.5)$$

sendo que $\Delta\theta(t)$ e $\Delta b(t)$ são variáveis de estado, o erro de estimativa do posicionamento abso-

luto e o erro de polarização do giroscópio, respectivamente, $\eta_g(t)$ é o ruído branco Gaussiano de medida do giroscópio, e $\eta_{b_g}(t)$ é o ruído branco Gaussiano de polarização do giroscópio, τ_g é a constante de tempo ou tempo de correlação do processo Gauss-Markov.

O posicionamento angular obtido através do acelerômetro é utilizado nesta estratégia de fusão como um sinal redundante/auxiliar de medida, com o propósito de corrigir o posicionamento baseado no giroscópio. O posicionamento baseado em acelerômetro é dado por:

$$\hat{\theta}_a(t) = \arcsin\left(\frac{a_x}{g}\right) = \theta(t) + \eta_a(t), \quad (2.6)$$

sendo $g = 9.81m/s^2$ a aceleração gravitacional, a_x a aceleração no eixo-X, e $\eta_a(t)$ é o ruído presente no sinal.

Para obter a equação de saída de espaço de estados, a qual é representada pela diferença entre o posicionamento baseado no acelerômetro e no giroscópio, faz-se:

$$\begin{aligned} y(t) &= \hat{\theta}_a(t) - \hat{\theta}_g(t) \\ &= \theta(t) + \eta_a(t) - \hat{\theta}_g(t) \\ &= \Delta\theta(t) + \eta_a(t). \end{aligned} \quad (2.7)$$

Consequentemente:

$$y(t) = Cx(t) + v(t)$$

$$y(t) = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} \Delta\theta(t) \\ \Delta b(t) \end{bmatrix} + \eta_a(t), \quad (2.8)$$

sendo que $y(t)$ corresponde a medida de posicionamento que alimentará o filtro, e $\eta_a(t)$ é o ruído branco Gaussiano de medida do acelerômetro.

A partir do modelo no espaço de estados, bastaríamos discretizar as Equações (2.5) e (2.8) e aplicarmos o filtro de Kalman discreto, ilustrado na Figura 2.4, para obtermos o sistema de estimativa para o ângulo de correção $\Delta\hat{\theta}$ ilustrado na Figura 2.3. Para maiores detalhes sobre o filtro de Kalman veja o Apêndice A.

Figura 2.4: Algoritmo preditor-corretor para o FK.

2.2 Estimativa de ângulos absolutos utilizando FK na abordagem complementar com sensores inerciais

A abordagem complementar com sensores inerciais apresentada na seção anterior fornece uma estimativa ótima para casos de baixa aceleração dinâmica. Como descrito, o ângulo obtido através do acelerômetro só fornecerá uma boa estimativa de posição caso o mesmo esteja parado ou em movimento uniforme. No entanto, a maioria das aplicações envolvendo o uso de sensores inerciais está sujeita a acelerações dinâmicas significativas, como é o caso do sensoriamento de membros inferiores durante o caminhar humano, em que cada segmento possui momentos de aceleração e frenagem distintos durante o caminhar. Dessa forma, temos que o filtro complementar puro apresentado na Seção 2.1 estimaria valores de correção *poluídos* pela aceleração, tornando necessário definir estratégias para evitar que o acelerômetro contribua quando o mesmo não for confiável, ou seja, quando existir acelerações dinâmicas significativas atuando sobre o mesmo, deve-se utilizar o ângulo obtido através da integração do giroscópio. Portanto, tomando como exemplo o filtro complementar para um sensor inercial mono-axial apresentado na Figura 2.3, teríamos estratégias tais como definidas no Algoritmo 1.

Algoritmo 1:

se *aceleração dinâmica é significativa* **então**

 | $\Delta\theta \leftarrow 0$

senão

 | $\Delta\theta \leftarrow \theta_a - \theta_g$

Figura 2.5: Sapato com FSRs na sola.

Eventos	FSR_{calc}	FSR_{meio}	FSR_{frente}
Impacto do calcanhar	Baixo $\rightarrow$ Alto	Baixo	Baixo
Fase de apoio	Alto	Alto	Baixo
	Baixo	Alto	Alto
	Baixo	Baixo	Alto
Fase de balanço	Baixo	Baixo	Baixo

Tabela 2.1: Fases do caminhar identificadas com FSRs.

Ao forçarmos $\Delta\theta = 0$, significa que confiaríamos unicamente no giroscópio, pois neste intervalo existiria aceleração dinâmica significativa tornando o acelerômetro não confiável.

Um exemplo de estratégia para identificar os intervalos com baixa aceleração dinâmica pode ser visto em Caltran e Siqueira (2010), sendo proposto um sistema de estimativa angular absoluta para uma órtese pé-tornozelo, utilizando um sensor inercial (acelerômetro e giroscópio mono-axiais) fixo na órtese e sensores de força resistivos (FSR, do inglês *Force Sensitive Resistor*) dispostos na sola do dispositivo, operando como chaves de contato para identificar as fases do caminhar, veja a Figura 2.5. Nesta figura, existem três sensores FSR_{calc} , FSR_{meio} e FSR_{frente} ; ativados quando cada área do pé entrar em contato com o solo. A Tabela 2.1 mostra os intervalos e fases de interesse do caminhar.

Neste exemplo, foram definidas duas condições para que os intervalos com aceleração dinâmica fossem evitados, considerando o caminhar humano natural:

1. O valor medido no acelerômetro não deverá exceder metade do valor da gravidade (g), portanto temos que:

$$|a_x| < 0,5g$$

2. De acordo com as posições dos FSR, e os eventos de interesse mostrados na Tabela 2.1, o intervalo compreendido da fase de balanço até o impacto do calcanhar com o solo deve ser evitado.

Assim, intervalo em que supostamente teríamos baixos índices de aceleração dinâmica seria: logo após o calcanhar atingir o solo até o momento anterior ao pé deixar completamente o solo, ou seja, na **fase de apoio**.

Originalmente em Caltran e Siqueira (2010), acreditava-se que o intervalo de balanço teria pouca influência de aceleração dinâmica o que demonstramos não ser verdade em Nogueira et al. (2013).

Dessa forma, para projetarmos o filtro de Kalman complementar para este exemplo, bastaríamos discretizar o modelo apresentado na Seção 2.1, e aplicar a estratégia definida nesta seção. Com isso, teríamos que as equações discretas seriam:

$$x_{k+1} = Fx_k + Gw_k, \quad (2.9)$$

com a variável de medição $z \in \mathbb{R}^m$, tal que:

$$z_k = Hx_k + v_k, \quad (2.10)$$

sendo o estado:

$$x_k = \begin{bmatrix} \Delta\theta_k & \Delta b_k \end{bmatrix}^T, \quad (2.11)$$

no qual $F \cong I + AT$, $G = A^{-1}(F - I)$ e $H = C$.

O Algoritmo 2, apresentado abaixo, demonstra de forma resumida o sistema de estimativa angular absoluta utilizando o filtro de Kalman na abordagem complementar. Neste, cada iteração produz um sinal corrigido do erro de estimativa, veja o terceiro passo: **Saída** do Algoritmo 2. A versão completa é apresentada no Apêndice C.1, sendo o mesmo baseado em Nogueira

Algoritmo 2: Estimativa angular absoluta utilizando o FK-complementar

```

// Predição:
 $\hat{x}_{k+1} = F \hat{x}_{k|k}$ 
 $P_{k+1} = F P_{k|k} F^T + G Q G^T$ 

// Correção:
se ( $|a| < 0,5g$ ) E (perna em fase de apoio) então
  |  $z_{k+1} = \hat{\theta}_{k+1}^a - \hat{\theta}_{k+1}^g$ 
senão
  |  $z_{k+1} = 0$ 
 $K_{k+1} = P_{k+1} H^T (H P_{k+1} H^T + R)^{-1}$ 
 $\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H \hat{x}_{k+1})$ 
 $P_{k+1|k+1} = (I - K_{k+1} H) P_{k+1}$ 

// Saída:
// Desde que  $\hat{x}_{k+1|k+1} := \begin{bmatrix} \Delta \hat{\theta}_{k+1|k+1} & \Delta \hat{b}_{k+1|k+1} \end{bmatrix}^T$ 
 $\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^g + \Delta \hat{\theta}_{k+1|k+1};$ 

```

et al. (2013). Para maiores detalhes sobre o filtro Kalman veja o Apêndice A.

As matrizes de ponderação Q e R são consideradas invariantes no tempo e dadas por:

$$Q = \begin{bmatrix} \sigma_g^2 & 0 \\ 0 & \sigma_{b_g}^2 \end{bmatrix}, \quad R = [\sigma_a^2].$$

As variâncias dos giroscópios, (σ_g^2 e $\sigma_{b_g}^2$), e dos acelerômetros (σ_a^2 e $\sigma_{b_a}^2$), não estão disponíveis nas folhas de dados de sensores de baixo custo. Tais informações devem ser levantadas utilizando técnicas tais como as apresentadas em Xing e Gebre-Egziabher (2008), ou através de métodos de otimização.

Para finalizar, pode-se dizer que o FK-complementar utilizado, apresenta uma abordagem ótima para os casos de aceleração dinâmica nula, estando o corpo parado ou em movimento uniforme, e também uma boa precisão para os casos de baixas acelerações dinâmica. Neste exemplo foram demonstradas as estratégias utilizadas em Caltran e Siqueira (2010) para estimativa do ângulo absoluto em uma órtese pé-tornozelo. Tal sistema de estimativa apresenta uma abordagem precisa para esta aplicação, no entanto como demonstrado em Nogueira et al. (2013), tais estratégias tornam-se ineficientes quando o objetivo passa a ser estimar ângulos em todos os segmentos de membros inferiores. Neste trabalho são propostas estratégias mais

eficazes para resolver este problema.

2.3 Filtro de Kalman robusto na abordagem complementar

A abordagem demonstrada na seção anterior fornece resultados precisos para sensores inerciais de alto custo e com controle interno de temperatura (aqueles destinados à aviação). Já para sensores de baixo custo (aqueles destinados à automobilística) devem ser utilizados em capturas de curto prazo, com baixa variação de temperatura e que não necessitam de alta precisão (entre 1 a 2 graus). Considere o prazo curto como uma duração inferior a uma hora e variações de temperaturas inferiores a $1^\circ C$, Xing e Gebre-Egziabher (2008) O giroscópio além do erro de polarização modelado através do $\dot{b}(t)$, possui um erro paramétrico médio que pode aumentar ou diminuir de 0, 1 a 1° por hora, dependendo também da oscilação de temperatura. O erro paramétrico adiciona imprecisão na medida do sensor, e ao passo que o tempo evolui e a temperatura oscile, esta imprecisão poderá degradar significativamente um sistema preditor-corretor utilizando o FK convencional.

Já a abordagem do FKR-complementar com sensores inerciais, apresenta um ganho significativo em aplicações em que o tempo de captura é considerado de médio a longo prazo, ou seja, superior a uma hora, ou ainda quando existem variações de temperaturas significativas, superiores a $1^\circ C$. Dessa forma, segue abaixo a formulação robusta do FK-complementar para a órtese pé-tornozelo, a mesma foi apresentada em Caltran e Siqueira (2011).

O filtro robusto baseado no FK, doravante denominado Filtro de Kalman Robusto (FKR), apresentado nesta subseção realiza a estimativa do estado do sistema considerando a existência de incertezas no modelo. Caso estas incertezas sejam ignoradas, elas podem deteriorar ou mesmo instabilizar o processo de filtragem preditor-corretor, como é o caso do FK-complementar convencional. O filtro robusto utilizado neste trabalho foi baseado no modelo com medição e atualização no tempo, proposto em Sayed (2001).

Comparado com o FK convencional, que minimiza a norma do resíduo $(z_{k+1} - H\hat{x}_{k+1})$, os FKR foram desenvolvidos para minimizar o norma do resíduo no pior caso de incertezas aceitáveis em cada iteração.

Considere o mesmo modelo proposto em (2.9), adicionado a este incertezas nas matrizes do

modelo:

$$x_{k+1} = (F + \delta F)x_k + (G + \delta G)w_k, \quad (2.12)$$

com a variável de medição:

$$z_k = Hx_k + v_k. \quad (2.13)$$

Os distúrbios δF e δG são modelados como:

$$\begin{bmatrix} \delta F & \delta G \end{bmatrix} = M\Delta_k \begin{bmatrix} N_F & N_G \end{bmatrix} \quad (2.14)$$

sendo $\|\Delta_k\| < 1$, e os ruídos dados por $w_k = N(0, Q)$ e $v_k = N(0, R)$, em que $N(\mu, \sigma)$ é uma distribuição normal de média μ e variância σ .

O modelo (2.14) permite que o projetista restrinja as fontes de distorção selecionando as entradas $\{N_F, N_G\}$ apropriadamente.

O FKR procura minimizar o erro de estimativa para o pior caso possível criado pela faixa de incertezas δF e δG , sendo o mesmo formalizado através do Algoritmo 3. Neste as estimativas preditora $\hat{x}_{k+1}$ e corretora $\hat{x}_{k+1|k+1}$ apresentadas, podem ser obtidas por iterações recursivas entre os passos 2 e 3. No passo 1, o termo de minimização do filtro robusto $\hat{\lambda}_k$ deve ser maior que $\|M^T H^T R^{-1} H M\|$, assim, define-se $\hat{\lambda}_k = (1 + \alpha_f) \cdot \|M^T H^T R^{-1} H M\|$, sendo α_f uma constante pequena, veja Sayed (2001). Para o caso em que $\hat{\lambda}_k = 0$, os passos 2 e 3 são reduzidos para o FK convencional. O algoritmo completo, é apresentado no Apêndice C.3.

No entanto, como comentado na seção anterior, utilizando as mesmas estratégias utilizadas em Nogueira et al. (2013), podem-se formular condições mais eficazes para estimar ângulos em todos os segmentos de membros inferiores. Além disso, será proposto neste trabalho de doutorado, estratégias para identificar as matrizes de incerteza N_G e N_F do modelo, veja as Seções 4.5 e 4.6 do Capítulo 4.

Algoritmo 3: Estimativa angular absoluta utilizando o FKR-complementar

// **Passo 1:**

se $HM = 0$ então

$\hat{\lambda}_k = 0$

senão

$\alpha_f = 0,5$

$\hat{\lambda}_k = (1 + \alpha_f) \cdot \|M^T H^T R^{-1} H M\|$

// **Passo 2:**

Substitua $\{Q, R, P_{k|k}, G, F\}$ por

$$\hat{Q}^{-1} = Q^{-1} + \hat{\lambda}_k N_G^T [I + \hat{\lambda}_k N_F P_{k|k} N_F^T]^{-1} N_G$$

$$\hat{R} = R - \hat{\lambda}_k^{-1} H M M^T H^T$$

$$\hat{P}_{k|k} = (P_{k|k}^{-1} + \hat{\lambda}_k N_F^T N_F)^{-1} = P_{k|k} - P_{k|k} N_F^T (\hat{\lambda}_k^{-1} I + N_F P_{k|k} N_F^T)^{-1} N_F P_{k|k}$$

$$\hat{G} = G - \hat{\lambda}_k F \hat{P}_{k|k} N_F^T N_G$$

$$\hat{F} = (F - \hat{\lambda}_k \hat{G} \hat{Q} N_G^T N_F) (I - \hat{\lambda}_k \hat{P}_{k|k} N_F^T N_F)$$

// **Passo 3:**

Filtro de Kalman: Algoritmo 2

2.4 Filtro de Kalman sujeitos a saltos Markovianos com cadeia de Markov conhecida

Um dos principais tópicos em controle de sistemas está em sua capacidade de fornecer um comportamento aceitável e cumprir exigências de performance mesmo na presença de mudanças bruscas na dinâmica do sistema. Tais mudanças podem ser devido a distúrbios no ambiente, falhas de componentes, alterações nas conexões de subsistemas, etc. Alguns exemplos podem ser encontrados em sistemas econômicos, sistemas de controle de tráfego aéreo, manipuladores robóticos, longas estruturas flexíveis em estações espaciais, etc. Em alguns desses casos podem ser modelados conjuntos de sistemas lineares discretos no tempo com a transição entre tais sistemas dada por uma cadeia de Markov. Tais sistemas são conhecidos na literatura como sistemas lineares sujeitos a saltos Markovianos, Costa et al. (2005).

Nas seções anteriores foram apresentadas as principais abordagens utilizadas para realizar estimativa angular absoluta, considerando sensores inerciais mono-axiais no plano sagital humano. Tais estratégias são aceitáveis para aplicações bem comportadas, tal que durante o movimento realizado, o acelerômetro apresente baixa aceleração por vários momentos. Pode-se dizer

que à medida em que a dinâmica aumente, a quantidade de momentos com baixa aceleração diminuirá e a precisão também. Portanto, as abordagens anteriores são fortemente dependentes da intensidade de movimentos dinâmicos inferidos sobre os sensores do sistema.

No entanto, os exoesqueletos de membros inferiores apresentam dinâmicas diferentes em cada segmento. O uso das abordagens anteriores, poderia, por exemplo, realizar uma estimativa angular precisa no segmento equivalente ao pé, e uma estimativa angular com baixa precisão no segmento equivalente ao tronco. De forma a contornar tal problema, na Seção 4.3 do Capítulo 4 é proposto um modelo que utiliza somente o sensor inercial com a medida mais confiável de aceleração estática, ou seja, com baixa aceleração dinâmica, a cada instante. Relacionando os demais através dos sinais de *encoders* das articulações.

A técnica utilizada para saltar/escolher entre os sensores inerciais mais precisos a cada instante, foi baseada em filtros de Kalman sujeitos a saltos Markovianos, sendo a mesma apresentada abaixo.

Nesta subseção será discutido um caso específico da filtragem Markoviana, sendo a variável medida do sistema z_k e a condição de salto $\theta(k)$, ou seja, a cadeia de Markov, são ambas conhecidas.

Considere que o sistema dado pelas Equações (2.9) e (2.10), possua suas matrizes variantes no tempo obedecendo a uma cadeia de Markov $\theta(k)$ conhecida. Dessa forma, pode-se representar o sistema sujeito a saltos Markovianos no espaço de estados discreto no tempo por:

$$x_{k+1} = F_{k,\theta(k)}x_k + B_k u_k + G_{k,\theta(k)}w_k, \quad (2.15)$$

com a variável de medição $z \in \mathbb{R}^m$, tal que:

$$z_k = H_{k,\theta(k)}x_k + v_k. \quad (2.16)$$

Sabe-se que para o caso em que z_k e $\theta(k)$ são conhecidos, o melhor estimador linear de x_{k+1} é o próprio FK, veja Chizeck e Ji (1988), desde que todos os modos de operação sejam conhecidos no instante k . Portanto, de forma análoga ao FK previamente discorrido neste capítulo, temos que as equações recursivas preditoras e corretoras do filtro de Kalman sujeitos a saltos

Markovianos (FKSM) podem ser dadas por:

Equações preditoras:

$$\hat{x}_{k+1} = F_{k,\theta(k)}\hat{x}_{k|k} \quad (2.17)$$

$$P_{k+1} = F_{k,\theta(k)}P_{k|k}F_{k,\theta(k)}^T + G_{k,\theta(k)}Q_kG_{k,\theta(k)}^T \quad (2.18)$$

Equações corretoras:

$$K_{k+1} = P_{k+1}H_{k+1,\theta(k)}^T(H_{k+1,\theta(k)}P_{k+1}H_{k+1,\theta(k)}^T + R_{k+1})^{-1} \quad (2.19)$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1}(z_{k+1} - H_{k+1,\theta(k)}\hat{x}_{k+1}) \quad (2.20)$$

$$P_{k+1|k+1} = (I - K_{k+1}H_{k+1,\theta(k)})P_{k+1} \quad (2.21)$$

No entanto, o funcionamento do algoritmo preditor-corretor está sujeito aos saltos da cadeia de Markov $\theta(k)$. Para fins didáticos considere um sistema que possua três estados possíveis ou modos de operação, como na Figura 2.6.

Figura 2.6: Modos de operação do FKSM.

Dessa forma, as equações preditoras e corretoras quando o sistema estiver no modo de operação $\theta(k) = 1$, serão:

Equações preditoras para $\theta(k) = 1$:

$$\hat{x}_{k+1} = F_{k,1}\hat{x}_{k|k}$$

$$P_{k+1} = F_{k,1}P_{k|k}F_{k,1}^T + G_{k,1}Q_kG_{k,1}^T$$

Equações corretoras para $\theta(k) = 1$:

$$\begin{aligned} K_{k+1} &= P_{k+1} H_{k+1,1}^T (H_{k+1,1} P_{k+1} H_{k+1,1}^T + R_{k+1})^{-1} \\ \hat{x}_{k+1|k+1} &= \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H_{k+1,1} \hat{x}_{k+1}) \\ P_{k+1|k+1} &= (I - K_{k+1} H_{k+1,1}) P_{k+1} \end{aligned}$$

De forma análoga as demais equações preditoras e corretoras podem ser encontradas para $\theta(k) = 2$ e $\theta(k) = 3$.

Portanto considerando um horizonte de tempo discreto com 10 instantes, poderíamos ter uma cadeia de Markov $\theta = \{1, 1, 2, 2, 3, 2, 2, 1, 1, 3\}$.

2.5 Considerações finais sobre as metodologias

Neste capítulo foram abordadas as principais técnicas e modelos que servirão de base para todo o desenvolvimento realizado nesta tese. Buscou-se aqui, além de exibir tais técnicas, também indicar pontos de melhoria realizados pelo autor e descritos no próximos capítulos.

No próximo capítulo, será abordada a plataforma de busca/otimização baseada em AGs, desenvolvida para otimizar as constantes e parâmetros dos sistemas de estimativas que serão propostos neste trabalho.

CAPÍTULO 3

PLATAFORMA DE BUSCA E OTIMIZAÇÃO

A partir das metodologias escolhidas para o desenvolvimento dos sistemas de estimativas angulares absolutas para exoesqueletos de membros inferiores, enunciou-se a necessidade do uso de sistemas de otimização/busca para os parâmetros de tais sistemas.

Como o objetivo principal deste trabalho não está no desenvolvimento de abordagens para otimização de sistemas, optou-se por utilizar algoritmos genéticos (AGs) pela simplicidade de implementação, Goldberg (1989). Caso o leitor não tenha conhecimento deste tema, o mesmo pode recorrer ao Apêndice D, para uma rápida introdução neste tema.

Nas seções deste capítulo serão abordados os principais pontos da topologia proposta para os AGs utilizados neste trabalho.

3.1 Topologia

A topologia de otimização desenvolvida, consiste de dois AGs concorrentes com intercâmbio de indivíduos. O primeiro AG, nomeado AG-binário, foi modelado para buscar soluções

aleatórias, sendo os indivíduos distribuídos sobre a curva de solução. Este AG possui a capacidade de encontrar o início de descida a um mínimo, sendo este local ou global. O segundo AG, nomeado AG-decimal, foi modelado para descer mais rapidamente ao ponto mínimo, sendo o início de descida geralmente encontrado pelo primeiro AG.

Os indivíduos potencialmente mais aptos são trocados entre o primeiro e segundo AG. A Figura 3.1, representa um diagrama básico de funcionamento da topologia proposta. O uso de tal topologia foi proposta ao se verificar que as variáveis a serem otimizadas possuíam alto grau de interdependência.

Figura 3.1: Topologia do algoritmo gentico.

Nesta topologia, a populao pode ser vista como um conjunto de indivduos gerados, em que as caractersticas de cada um destes representam os parmetros de cada filtro. Por exemplo, considere o caso nominal do FK para o segmento do tronco. Neste caso necessrio otimizar as varincias dos giroscpios (σ_g^2 e σ_{bg}^2), do acelermetro (σ_a^2), a constante de tempo do processo (τ_g) e a constante que define a confiabilidade do acelermetro (ζ). Portanto, para o sistema de estimativa do tronco, um indivduo poderia ser definido como: $A = (\sigma_g^2, \sigma_{bg}^2, \sigma_a^2, \tau_g, \zeta)$.

Os indivduos gerados inicialmente pelos AGs binrio e decimal contm cromossomos aleatrios dentro de faixas de valores previamente definidos. Para o exemplo anterior do FK no-

minal, temos que o universo de discurso dos cromossomos são dados pela Tabela 3.1. Um indivíduo válido, gerado dentro de tal faixa seria $A = (0, 1; 0, 02; 0, 2; 1500; 0, 05)$.

Cromossomos	Mínimos	Máximos	Unidades
σ_g^2	$2 \cdot 10^{-8}$	0, 4	$(^\circ/s)^2$
$\sigma_{b_g}^2$	$2 \cdot 10^{-8}$	0, 4	$(^\circ/s)^2$
σ_a^2	$2 \cdot 10^{-8}$	0, 4	$(m/s^2)^2$
τ_g	1	10^6	(s)
ζ	10^{-4}	0, 1	(m/s^2)

Tabela 3.1: Universo de discurso para o FK nominal.

3.2 Função de aptidão

Após as populações serem geradas dentro do universo de discurso descrito pela Tabela 3.1, a qualidade dos indivíduos deve ser avaliada.

Cada indivíduo é avaliado segundo sua aptidão, ou seja, os resultados que suas características proporcionam. Neste trabalho, o objetivo está em minimizar o erro médio de estimativa dado pela Equação 3.1, sendo $\hat{\theta}$ o ângulo absoluto estimado pelo sistema com as características do indivíduo selecionado, e θ_{ref} o ângulo absoluto de referência.

$$\bar{E} = \sum_{t=0}^{T_f} \frac{|\hat{\theta} - \theta_{ref}|}{T_f} \quad (3.1)$$

3.3 Seleção

A seleção de indivíduos escolhe os mais aptos, sendo estes os que possuem menor erro de estimativa, e através destes realiza os processos de cruzamento. Existem diversas formas de selecionar os indivíduos mais aptos, por exemplo os métodos de amostragem universal estocástica, roleta e torneio. Neste trabalho optamos pelo método da roleta, primeiro pela simplicidade

de implementação e também por o mesmo ter apresentado melhor convergência dos AGs para os filtros projetados.

O método da roleta distribui os indivíduos em um disco com os setores divididos proporcionalmente pela aptidão de cada indivíduo. Com isso, ao ser rodada a roleta tem-se maior probabilidade de selecionar os indivíduos mais aptos, no entanto, não exclui-se a possibilidade de seleção de um indivíduo menos apto.

Por exemplo, considere que cinco indivíduos possuem aptidões dadas pela Equação 3.1, e listadas na segunda coluna da Tabela 3.2. O indivíduo mais apto, é o indivíduo que possui o menor custo médio de estado, $\bar{E}$. Na terceira coluna, temos a aptidão relativa de cada indivíduo nesta população. Assim, pode-se distribuir a aptidão relativa de cada indivíduo em uma roleta como na Figura 3.2, e rodar a roleta. Portanto, a probabilidade da roleta parar nos indivíduos 3 e 5 é maior do que nos demais indivíduos.

Indivíduos	Aptidão, $\bar{E}$ (°)	Aptidão rel. (%)
1	0,8	19
2	1,4	11
3	0,6	26
4	1,2	13
5	0,5	31
Total	4,5	100

Tabela 3.2: Constantes ajustadas no genético, FK local.

Após a seleção de indivíduos, cada AG (binário ou decimal) disponibiliza o seu indivíduo mais apto e verifica se o indivíduo do AG concorrente tem mais aptidão. Caso tenha, o mesmo é aproveitado imediatamente, substituindo o indivíduo menos apto de sua seleção pelo indivíduo mais apto do AG concorrente.

Por fim, visando garantir a sobrevivência do indivíduo mais apto, optou-se por utilizar a técnica de elitismo, ou seja, será sempre mantido uma cópia do indivíduo mais apto, Jong (1975).

Figura 3.2: Método da roleta.

3.4 Cruzamento

Com a seleção de indivíduos, passa-se aos processos de cruzamento, realizados de duas formas.

A primeira forma através de cruzamento utilizando máscaras e dados binários. Por exemplo, considere dois indivíduos A e B abaixo, sendo o universo de discurso binário dado entre $0000_b = 0$ e $1111_b = 3$.

$$A = (0001_b; 0011_b; 0101_b; 1110_b; 0001_b)$$

$$B = (0010_b; 0110_b; 0001_b; 1101_b; 0010_b)$$

Considere a seguinte máscara definida abaixo:

$$Masc = (0011_b; 0011_b; 0011_b; 0011_b; 0011_b)$$

O cruzamento pode ser realizado como:

$$C = A \cdot Masc + B \cdot (\sim Masc)$$

$$D = A \cdot (\sim Masc) + B \cdot Masc$$

sendo que $(\cdot)$ representa operação lógica E , $(\sim)$ a operação lógica $NÃO$ e $(+)$ a operação lógica

OU. Portanto, o cruzamento via cadeias binárias geraria dois indivíduos, C e D .

Já a segunda forma, utiliza médias numéricas, sendo que estas podem ser via média aritmética, média geométrica, método BLX- α , entre outras. Neste trabalho optamos por utilizar a média aritmética e o método BLX- α , Goldberg (1989). Por exemplo, sejam dois indivíduos:

$$A = (0,5; 0,3; 0,4; 2; 0,1), \quad \text{e} \quad B = (0,6; 0,7; 0,3; 4; 0,2).$$

O cruzamento destes considerando valores reais, através da média aritmética, pode ser dado por, $C = \frac{A+B}{2}$, $C = (0,55; 0,5; 0,35; 3; 0,15)$.

Um exemplo de cruzamento pelo método BLX- α , para os indivíduos anteriores (A e B), seria dado pela geração de indivíduos com cromossomos aleatórios, dentro de uma faixa definida pelos cromossomos de A e B , sendo esta uma distribuição normal e uniforme. Essa faixa é definida pela Equação 3.2, sendo α uma constante pré-definida.

$$\begin{aligned} I_i &= \max(A_i, B_i) - \min(A_i, B_i) \\ F_i &= \left[\min(A_i, B_i) - I_i \cdot \alpha, \max(A_i, B_i) + I_i \cdot \alpha \right] \end{aligned} \quad (3.2)$$

Como os indivíduos A e B possuem cinco cromossomos, estes apresentaram cinco faixas F_i , para seleção aleatória dos cromossomos. Dessa forma, para $\alpha = 0,5$, tem-se:

$$\begin{aligned} F_{c_1} &= \left[0,45 \quad 0,65 \right], & F_{c_2} &= \left[0,1 \quad 0,9 \right], \\ F_{c_3} &= \left[0,25 \quad 0,45 \right], & F_{c_4} &= \left[1 \quad 5 \right], \\ F_{c_5} &= \left[0,05 \quad 0,25 \right], \end{aligned}$$

sendo c_i , para $i = 1$ a 5 , os cromossomos dos indivíduos. Assim, um indivíduo C escolhido aleatoriamente nas faixas definidas, seria $C = (0,55; 0,74; 0,28; 2,69; 0,23)$.

3.5 Mutação

Após realizado o processo de cruzamento, temos o processo de mutação. Na qual o objetivo deste está em realizar pequenas modificações no parâmetros, cromossomos, para que os indivíduos sejam ligeiramente diferentes uns dos outros. Isto diminui de forma razoável a possibilidade de todos os indivíduos convergirem rapidamente para um mínimo local, e ficarem lá estagnados.

O processo de mutação foi realizado de duas formas. A primeira utiliza cadeias binárias, nesta uma porcentagem de *bits* são sorteados e invertidos. Por exemplo, considere o indivíduo *A* (binário) anteriormente definido; este possui 20 *bits*, caso o sistema utilize mutação de 10%, 2 *bits* aleatórios seriam invertidos. Uma mutação possível para este seria: $A_m = (0101_b; 0011_b; 0101_b; 1010_b; 0001_b)$. Por outro lado, caso o AG utilize valores reais, o processo de mutação poderia somar ou subtrair um valor proporcional ao valor nominal do parâmetro. Por exemplo, considere o indivíduo *B* decimal anteriormente definido, caso o sistema utilize mutação também de 10%, ou seja $\pm 5\%$, uma mutação possível para este indivíduo seria $B_m = (0,6 + 0.05 \cdot 0,6; 0,7 - 0.05 \cdot 0,7; 0,3 + 0.05 \cdot 0,3; 4 + 0.05 \cdot 4; 0,01 - 0.05 \cdot 0,01)$.

3.6 Critérios de parada

Os critérios de parada, ou seja, quando os AGs decidem finalizar a busca e retornar o indivíduo mais apto, foram programados para serem realizados de duas formas. A primeira baseada no erro médio de estimativa, por exemplo, $\bar{E} = 0.5^\circ$. Já a segunda forma foi programada segundo um limite de gerações/evoluções dos AGs, por exemplo, 200 gerações.

Considerações finais

Após definida a topologia dos AGs utilizados neste trabalho, juntamente com os principais pontos que a compõe, no próximo capítulo, serão modelados os sistemas de estimativas propostos neste trabalho, sendo mostrados e discutidos resultados pré-liminares, obtidos de simulações computacionais de sensores, e do processo de otimização discutido neste capítulo.

CAPÍTULO 4

MODELAGENS E RESULTADOS PRELIMINARES

Após a definição das principais metodologias utilizadas, no Capítulo 2, e da plataforma de busca/otimização para as constantes e parâmetros dos filtros, no Capítulo 3, neste capítulo, serão realizadas as formulações dos sistemas de estimativas angulares absolutas para um exoesqueleto de membros inferiores. Os sistemas aqui formulados foram idealizados no exoesqueleto Exo-Kanguera (maiores detalhes no Apêndice F). No entanto, como o Exo-Kanguera, até o presente momento, ainda não possui todas as articulações funcionais optou-se por realizar os testes e capturas em um exoesqueleto para membros inferiores equivalente ao Exo-Kanguera. Dessa forma, o autor realizou um estágio de pesquisa no grupo de BioEngenharia do *Consejo Superior de Investigaciones Científicas* na Espanha, CSIC, com o objetivo de realizar testes e capturas com o exoesqueleto para reabilitação desenvolvido neste mesmo grupo.

Como discorrido no parágrafo anterior, o exoesqueleto para reabilitação do grupo de BioEngenharia do CSIC, nomeado doravante de Exo-H1, e apresentado em detalhes no Apêndice F, opera em condições equivalentes ao Exo-Kanguera. Possuindo os acionamentos nas articulações referente ao plano sagital humano, e com *encoders* dispostos nas três articulações de

Figura 4.1: Exoesqueletos Exo-Kanguera e Exo-H1.

interesse (quadril, joelho e tornozelo), veja a Figura 4.1, comparando ambos os exoesqueletos.

A proposta deste trabalho está em estimar os ângulos absolutos dos segmentos para um exoesqueleto de membros inferiores, Exo-Kanguera/Exo-H1. Visando facilitar a associação e visualização de cada segmento dos membros inferiores, estes serão tratados ao longo deste texto como: tronco, coxa, canela e pé. Sendo as articulações nomeadas como: quadril, joelho e tornozelo. Como as simulações e os experimentos são realizadas para somente uma perna do exoesqueleto (perna direita), ao mencionarmos coxa, canela e pé, estamos referenciando a coxa direita, canela direita e pé direito. No entanto, para evitar a ambiguidade nos índices das variáveis representativas de cada segmento, e também por manter um padrão de nomenclatura, os nomes dos segmentos serão doravante nomeados do inglês: *body/trunk(B)*, *thigh(T)*, *shank(S)*, e *foot(F)*, respectivamente. Da mesma forma os nomes das articulações serão nomeados: *hip(h)*, *knee(k)*, e *ankle(a)*.

Com isso, temos que os ângulos absolutos a serem estimados pelos sistemas propostos ao longo desse capítulo, podem ser vistos na Figura 4.2, e descritos abaixo:

- θ_B : ângulo absoluto do tronco (*body/trunk*),
- θ_T : ângulo absoluto da coxa (*thigh*),

Figura 4.2: Disposição dos ângulos absolutos.

- θ_S : ângulo absoluto da canela (*shank*),
- θ_F : ângulo absoluto do pé (*foot*).

Além dos ângulos absolutos, os ângulos das articulações também são ilustrados na Figura 4.2, e descritos abaixo:

- θ_h : ângulo da articulação do quadril (*hip*),
- θ_k : ângulo da articulação do joelho (*knee*),
- θ_a : ângulo da articulação do tornozelo (*ankle*).

Nas seções subsequentes serão propostas 4 abordagens para estimativa angular absoluta para o Exo-Kanguera/Exo-H1. Sendo duas destas baseadas nos modelos propostos por Caltran e Siqueira (2010) e Caltran e Siqueira (2011). Já as restantes, baseadas em sistemas Markovianos, consideradas as principais contribuições científicas deste trabalho de doutorado. Tais abordagens são:

- Sistema de estimativa baseado no FK-complementar, Seção 4.2,
- Sistema de estimativa baseado no FKSM-complementar, Seção 4.3,
- Sistema de estimativa baseado no FKR-complementar, Seção 4.5,

- Sistema de estimativa baseado no FKRSM-complementar, Seção 4.6.

Além disso, na Seção 4.1, será realizada a simulação de sensores inerciais, de forma a viabilizar testes rápidos para as modelagens desenvolvidas. Apresentados posteriormente nas Seções 4.3 e 4.6.

4.1 Simulação de sensores inerciais

Inicialmente foram propostas simulações de sinais provenientes de unidades de medida inercial, IMU do inglês *Inertial Measurement Unit*, com a finalidade de testar as abordagens propostas. Foi utilizado o software OpenSim, apresentado no Apêndice F, para simular sinais de posicionamento angular, velocidade angular e acelerações lineares referentes ao caminhar humano. Tais sinais foram necessários para simular as medições que seriam produzidas pelas unidades inerciais compostas de acelerômetros e giroscópios.

Nas subseções abaixo serão discutidas as gerações dos sinais simulados para cada tipo de sensor.

Sinais simulados de giroscópios

Para simular os sinais medidos por giroscópios, foram utilizados os valores de velocidade angular do centro de massa de cada segmento dos membros inferiores humanos. Tais informações foram obtidas pelo software OpenSim e utilizados como entrada nas Equações (B.6) e (B.7) do Apêndice B. Os valores das variâncias dos sensores, foram considerados da mesma ordem de grandeza de sensores inerciais reais, como em Inoue (2012), visando aproximar-se o máximo possível de um sensor real, ou seja:

$$\sigma_g^2 = 0.01 \text{ } (^{\circ}/s)^2, \quad \sigma_{b_g}^2 = 0.10 \text{ } (^{\circ}/s)^2.$$

Figura 4.3: Velocidade do tronco.

Figura 4.4: Velocidade da coxa.

Figura 4.5: Velocidade da canela.

Figura 4.6: Velocidade do pé.

Os sinais dos quatro segmentos de membros inferiores são apresentados na Figuras 4.3, 4.4, 4.5 e 4.6.

Sinais simulados de acelerômetros

Para simular os sinais medidos por acelerômetros, os sinais de referência com respeito a acelerações dinâmicas (produzida pelo movimento humano) e acelerações estáticas (produzidas pela inclinação do corpo em comparação com o vetor vertical da gravidade) gerados pelo software OpenSim foram utilizados como entrada nas Equações (B.9) e (B.10) do Apêndice B.

Da mesma forma, como nos giroscópios, foram considerados valores de variâncias próximos aos de um sensor real, sendo:

$$\begin{aligned}\sigma_a^2 &= 0.001 (m/s^2)^2, \\ \sigma_{b_a}^2 &= 0.001 (m/s^2)^2.\end{aligned}$$

Da mesma forma, como nos giroscópios, utilizando os sinais gerados no OpenSim, através das Equações (B.9) e (B.10) e das variâncias σ_a^2 e $\sigma_{b_a}^2$, foram simulados sinais de quatro segmentos de membros inferiores. Figuras 4.7, 4.8, 4.9 e 4.10.

Note que as curvas plotadas em verde nas Figuras 4.7, 4.8, 4.9 e 4.10, são as somas das acelerações dinâmicas e estáticas e dos ruídos.

Portanto, a partir dos dados simulados para giroscópios e acelerômetros, torna-se possível o teste dos sistemas de estimativas propostos neste capítulo.

Figura 4.7: Acelerações do tronco.

Figura 4.8: Acelerações da coxa.

Figura 4.9: Acelerações da canela.

Figura 4.10: Acelerações do pé.

4.2 Sistema de estimativa baseado no FK-complementar

O sistema de estimativa angular absoluta para exoesqueletos de membros inferiores, baseado no FK-complementar e proposto nesta seção, utiliza a mesma modelagem de sensores inerciais propostas em Caltran e Siqueira (2010), e apresentada nas Seções 2.1 e 2.2 do Capítulo 2, sendo o mesmo replicado para cada segmento dos exoesqueletos apresentados na Figura 4.1. Doravante este sistema será nomeado FK-complementar local. No entanto, como os sistemas de estimativas Markovianos propostos nas Seções 4.3 e 4.6 deste capítulo apresentam modelos no espaço de estados com arranjos matriciais, o mesmo sistema FK-complementar também será modelado no formato matricial, e nomeado FK-complementar matricial, sendo este o formato utilizado nos demais sistemas de estimativas deste capítulo.

O sistema de estimativa FK-complementar local foi proposto aqui somente para fins de comparação, com o modelo proposto em Caltran e Siqueira (2010), referente as estratégias para escolher os momentos em que o acelerômetro é confiável. O leitor pode pensar que ambos os sistemas **local** e **matricial** são idênticos e somente diferem pelo segundo estar em arranjo matricial. No entanto, como será demonstrado nesta seção, o arranjo matricial propicia combinações ponderadas para cada variável de estado modelada, ao ser utilizado o filtro de Kalman; em outras palavras, a correção do ângulo absoluto estimado do tronco ($\Delta\hat{\theta}_B$) receberá fatores de correção indiretos dos demais segmentos, assim como a correção do ângulo absoluto estimado do pé ($\Delta\hat{\theta}_F$) também receberá fatores de correção indiretos dos demais segmentos.

Abaixo, seguem as modelagens no espaço de estados local e matricial.

Espaço de estados local

O sistema de estimativa utilizando o FK-complementar local replicado para cada segmento do exoesqueleto, é ilustrado na Figura 4.11, no qual os giroscópios e acelerômetros estão alocados nos segmentos do tronco (B), da coxa (T), da canela (S) e do pé (F). Sendo assim, a modelagem no espaço de estados, segue de forma idêntica a apresentada na Seção 2.2, sendo resumidamente apresentada abaixo:

$$\dot{x}_i = \begin{bmatrix} \Delta \dot{\theta}_i(t) \\ \Delta \dot{b}_i(t) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & -\frac{1}{\tau_{ig}} \end{bmatrix} \begin{bmatrix} \Delta \theta_i(t) \\ \Delta b_i(t) \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \eta_{ig}(t) \\ \eta_{b_{ig}}(t) \end{bmatrix}, \quad (4.1)$$

$$y_i(t) = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} \Delta \theta_i(t) \\ \Delta b_i(t) \end{bmatrix} + \eta_{ia}(t), \quad (4.2)$$

sendo $i = \{B, T, S, F\}$.

Figura 4.11: Filtro complementar para um exoesqueleto de membros inferiores.

Espaço de estados matricial

Considerando o equacionamento no espaço de estados para um sensor inercial, descritos pelas Equações (4.1) e (4.2). Temos que o arranjo matricial para quatro sensores inerciais dispostos sobre cada um dos segmentos do exoesqueleto, pode ser descrito como:

$$\dot{x}(t) = Ax(t) + Bw(t), \quad (4.3)$$

$$y(t) = Cx(t) + v(t), \quad (4.4)$$

sendo $x(t) \in \mathbb{R}^n$ o vetor dos estados do sistema, $w(t) \in \mathbb{R}^m$ e $v(t) \in \mathbb{R}^q$ os vetores dos ruídos do estado e de medida, respectivamente, e $y(t) \in \mathbb{R}^q$ o vetor das saídas medidas. Os vetores

dos estados e das saídas medidas são definidos, respectivamente, como:

$$\begin{aligned} x &= \begin{bmatrix} x_B & x_T & x_S & x_F \end{bmatrix}^T = \begin{bmatrix} \Delta\theta_B & \Delta b_B & \Delta\theta_T & \Delta b_T & \Delta\theta_S & \Delta b_S & \Delta\theta_F & \Delta b_F \end{bmatrix}^T, \\ y &= \begin{bmatrix} \Delta\theta_B & \Delta\theta_T & \Delta\theta_F & \Delta\theta_S \end{bmatrix}^T = \begin{bmatrix} \hat{\theta}_{B_a} - \hat{\theta}_{B_g} & \hat{\theta}_{T_a} - \hat{\theta}_{T_g} & \hat{\theta}_{S_a} - \hat{\theta}_{S_g} & \hat{\theta}_{F_a} - \hat{\theta}_{F_g} \end{bmatrix}^T, \end{aligned}$$

sendo $\hat{\theta}_{i_a}$ o ângulo estimado com o acelerômetro no segmento i do exoesqueleto, e $\hat{\theta}_{i_g}$ o ângulo estimado com o giroscópio também no segmento i , para $i = \{B, T, S, F\}$.

Já as matrizes A , B e C são definidas como:

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & -1/\tau_B & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1/\tau_T & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1/\tau_S & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1/\tau_F \end{bmatrix}, \quad B = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix},$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}.$$

sendo τ_i , para $i = \{B, T, S, F\}$ a constante de tempo ou tempo de correlação do processo Gauss-Markov.

Lembrando que, como o modelo proposto nesta seção é baseado no modelo complementar do filtro de Kalman, veja a Seção 2.1, após a estimativa do $\Delta\hat{\theta}$ a mesma deve ser somada ao valor estimado pelo giroscópio. Portanto, no final teremos:

$$\begin{aligned}\hat{\theta}_B &= \hat{\theta}_{B_g} + \Delta\hat{\theta}_B, \\ \hat{\theta}_T &= \hat{\theta}_{T_g} + \Delta\hat{\theta}_T, \\ \hat{\theta}_S &= \hat{\theta}_{S_g} + \Delta\hat{\theta}_S, \\ \hat{\theta}_F &= \hat{\theta}_{F_g} + \Delta\hat{\theta}_B.\end{aligned}$$

Assim, como descrito na Seção 2.2, não são todos os momentos em que o FK-complementar pode utilizar as medidas do acelerômetro para inferir as correções apropriadas ao ângulo calculado através do giroscópio. Dessa forma, serão propostas estratégias para evitar os momentos que o acelerômetro não é confiável.

Estratégias para verificar a confiabilidade do acelerômetro

No exemplo descrito na Seção 2.2 do Capítulo 2, proposto por Caltran e Siqueira (2010), os autores utilizavam sensores de força resistivos localizados na sola do segmento do pé para identificar as fases do caminhar que o acelerômetro disposto na órtese pé-tornozelo apresentasse baixa aceleração dinâmica. Tais estratégias são apresentadas resumidamente abaixo, e podem ser vistas em maiores detalhes na Seção 2.2.

Condições para que os intervalos com aceleração dinâmica sejam evitados, considerando o caminhar humano natural:

1. O valor medido no acelerômetro não deverá exceder metade do valor da gravidade (g), portanto temos que:

$$|a_{x_i}| < 0,5g$$
2. A perna a qual a órtese pé-tornozelo está fixa, deve estar na fase de apoio.

No entanto, como ficará claro nos estudos de casos, apresentados no Capítulo 6, esta estratégia torna-se ineficiente quando o objetivo passa a ser estimar ângulos nos demais segmentos dos membros inferiores, como o tronco, a coxa e a canela. Já que cada segmento possui uma dinâmica distinta.

Com isso, é proposto abaixo uma estratégia equivalente a utilizada em navegação inercial para veículos aéreos não tripulados (VANT). Tal estratégia elimina a necessidade de sensores FSR na sola do segmento pé, mas exige que os acelerômetros sejam triaxiais. Tendo em vista que a maioria dos acelerômetros de baixo custo atuais são triaxiais, este deixa de ser um custo adicional e relevante para o projeto.

A nova estratégia proposta, consiste em calcular o módulo do acelerômetro em cada instante e compara-lo com o módulo do vetor gravidade. Caso o acelerômetro esteja em repouso ou em movimento uniforme (velocidade constante), o módulo do acelerômetro deverá aproximar-se do módulo do vetor gravidade. Dessa forma, temos que:

$$\rho_i(t) = ||a_i|| - |g|, \quad (4.5)$$

sendo $i = \{B, T, S, F\}$, e g o vetor gravidade. Então, a condição geral para verificar a confiabilidade do acelerômetro na medida corrente é dado por:

$$\rho_i(t) \leq \zeta, \quad (4.6)$$

no qual $\zeta > 0$ é um valor pequeno. Portanto, a partir da formalização da estratégia para identificar a confiabilidade do acelerômetro, passamos ao FK-complementar.

FK-complementar

Para ser aplicado o FK-complementar nos modelos **local** e **matricial** deve-se, inicialmente, discretizar os modelos no espaço de estados. Sendo que a versão discreta no tempo dos modelos descritos nesta seção pelas Equações (4.1-4.2) e (4.3-4.4), são dados para cada um deste com dimensões apropriadas por:

$$x_{k+1} = Fx_k + G\eta_k, \quad (4.7)$$

$$z_k = Hx_k + v_k. \quad (4.8)$$

sendo $F \cong I + AT$, $G = A^{-1}(F - I)B$, $H = C$, e T é o tempo de amostragem.

Portanto, a formalização deste sistema de estimativa para o caso **local** é similar ao Algoritmo 2 apresentado no Capítulo 2, com somente a mudança da estratégia para identificação

dos momentos que o acelerômetro é confiável, o algoritmo completo para este filtro é apresentado no Apêndice C.2, no qual o sistema de estimativa é replicado para cada segmento, tendo portanto quatro filtros distintos se considerarmos somente uma perna do exoesqueleto.

Para o caso **matricial** a formalização é descrita resumidamente pelo Algoritmo 4, sendo este baseado nas equações preditoras-corretoras do filtro de Kalman, apresentado no Apêndice A, e no Algoritmo 2. No entanto, o Algoritmo 4 realiza a estimativa de um sistema matricial com um modelo único representando todos os segmentos do exoesqueleto, veja o algoritmo completo no Apêndice C.4.

Para o caso matricial, verificou-se posteriormente, que tanto para as simulações quanto para os dados experimentais, a condição de confiabilidade do sensor apresentava melhores resultados se as medidas dos acelerômetros fossem consideradas confiáveis somente quando todas forem confiáveis, veja o Algoritmo 4.

Algoritmo 4: Estimativa angular absoluta para um exoesqueleto utilizando o FK-complementar matricial

// **Predição:**

$$\hat{x}_{k+1} = F\hat{x}_{k|k}$$

$$P_{k+1} = FP_{k|k}F^T + GQG^T$$

// **Correção:**

se $((\rho_k^B < \zeta^B) \mathbf{E}(\rho_k^T < \zeta^T) \mathbf{E}(\rho_k^S < \zeta^S) \mathbf{E}(\rho_k^F < \zeta^F))$ **então**

$$\quad | \quad z_{k+1} = \hat{\theta}_{k+1}^a - \hat{\theta}_{k+1}^s$$

senão

$$\quad | \quad z_{k+1}(i) = 0$$

$$K_{k+1} = P_{k+1}H^T(H P_{k+1}H^T + R)^{-1}$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1}(z_{k+1} - H\hat{x}_{k+1})$$

$$P_{k+1|k+1} = (I - K_{k+1}H)P_{k+1}$$

// **Saída:**

$$// \text{ Desde que } \hat{x}_{k+1|k+1} := \begin{bmatrix} \Delta\hat{\theta}_{k+1|k+1} & \Delta\hat{b}_{k+1|k+1} \end{bmatrix}^T$$

$$\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^s + \Delta\hat{\theta}_{k+1|k+1};$$

Com relação ao Algoritmo 4, as matrizes de ponderação Q e R , para o caso **matricial**, são

consideradas invariantes no tempo e dadas por:

$$Q = \begin{bmatrix} \sigma_{B_g}^2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \sigma_{b_{B_g}}^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_{T_g}^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_{b_{T_g}}^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \sigma_{S_g}^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \sigma_{b_{S_g}}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \sigma_{F_g}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \sigma_{b_{F_g}}^2 \end{bmatrix} \quad (4.9)$$

e

$$R = \begin{bmatrix} \sigma_{B_a}^2 & \sigma_{T_a}^2 & \sigma_{S_a}^2 & \sigma_{F_a}^2 \end{bmatrix}$$

sendo que variâncias dos giroscópios ($\sigma_{B_g}^2, \sigma_{b_{B_g}}^2, \sigma_{T_g}^2, \sigma_{b_{T_g}}^2, \sigma_{S_g}^2, \sigma_{b_{S_g}}^2, \sigma_{F_g}^2$ e $\sigma_{b_{F_g}}^2$) e as variâncias dos acelerômetros ($\sigma_{B_a}^2, \sigma_{b_{B_a}}^2, \sigma_{T_a}^2, \sigma_{b_{T_a}}^2, \sigma_{S_a}^2, \sigma_{b_{S_a}}^2, \sigma_{F_a}^2$ e $\sigma_{b_{F_a}}^2$), não estão disponíveis nas folhas de dados de sensores. Como descrito anteriormente, tais informações devem ser levantadas utilizando técnicas tais como as apresentadas em Xing e Gebre-Egziabher (2008), ou através de métodos de otimização.

Neste trabalho, optamos por utilizar Algoritmos Genéticos para otimizar as variâncias dos sensores inerciais, giroscópios e acelerômetros, as quais são utilizadas tanto pelo FK-complementar local quanto para o matricial. A topologia utilizada é demonstrada no Capítulo 3.

Comparação da abordagem local e matricial

Após apresentados ambas as abordagens, **local** e **matricial**, serão apresentados dois exemplos meramente ilustrativos para que o leitor possa entender a diferença no uso de cada uma destas.

Considerando o Algoritmo 2 do Capítulo 2, ou seja, a abordagem local. Considere que no passo de **Correção**, para o modelo de estimativa do segmento do tronco, os vetores e matrizes utilizadas sejam como descritos abaixo:

$$\begin{aligned}
H &= \begin{bmatrix} 1 & 0 \end{bmatrix}, \\
\hat{x}_{k+1} &= \begin{bmatrix} \Delta\theta_{B_{k+1}} & \Delta b_{B_{k+1}} \end{bmatrix}^T, \\
z_{k+1} &= \Delta\hat{\theta}_{B_{k+1}}, \\
K_{k+1} &= \begin{bmatrix} k_1 & k_2 \end{bmatrix}^T,
\end{aligned}$$

sendo os ganhos k_1 e k_2 calculados em função das matrizes H e R invariantes no tempo, e da matriz P calculada recursivamente a cada iteração do algoritmo.

Portanto a correção da estimativa do ângulo, neste instante seria:

$$\begin{aligned}
\hat{x}_{k+1|k+1} &= \hat{x}_{k+1} + K_{k+1}(z_{k+1} - H_{k+1}\hat{x}_{k+1}) \\
\begin{bmatrix} \Delta\hat{\theta}_{B_{k+1}|k+1} \\ \Delta\hat{b}_{B_{k+1}|k+1} \end{bmatrix} &= \begin{bmatrix} \Delta\theta_{B_{k+1}} \\ \Delta b_{B_{k+1}} \end{bmatrix} + \begin{bmatrix} k_1(\Delta\hat{\theta}_{B_{k+1}} - \Delta\theta_{B_{k+1}}) \\ k_2(\Delta\hat{\theta}_{B_{k+1}} - \Delta\theta_{B_{k+1}}) \end{bmatrix}
\end{aligned} \tag{4.10}$$

Como pode ser visto na Equação (4.10), a correção da estimativa do ângulo ($\Delta\hat{\theta}_{B_{k+1}|k+1}$), para o segmento do tronco, contém somente a componente de correção do próprio tronco. Como era de se esperar, já que cada modelagem é completamente independente das demais. Sendo a demonstração da abordagem local, trivial.

No entanto, a demonstração da abordagem matricial torna-se mais interessante. Por simplicidade da demonstração, considere que o exoesqueleto possui somente dois segmentos, ou seja, o tronco e a coxa. Portanto, considerando o Algoritmo 4 deste capítulo, suponha que no passo de **Correção**, os vetores e matrizes utilizadas sejam como descritos abaixo:

$$\begin{aligned}
H &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \\
\hat{x}_{k+1} &= \begin{bmatrix} \Delta\theta_{B_{k+1}} & \Delta b_{B_{k+1}} & \Delta\theta_{T_{k+1}} & \Delta b_{T_{k+1}} \end{bmatrix}^T,
\end{aligned}$$

$$z_{k+1} = \begin{bmatrix} \Delta \hat{\theta}_{B_{k+1}} \\ \Delta \hat{\theta}_{T_{k+1}} \end{bmatrix},$$

$$K_{k+1} = \begin{bmatrix} k_1 & k_2 & k_3 & k_4 \\ k_5 & k_6 & k_7 & k_8 \end{bmatrix}^T,$$

sendo os ganhos k_j para $j = \{1 \text{ até } 8\}$ calculados em função das matrizes H e R invariantes no tempo, e da matriz P calculada recursivamente a cada iteração do algoritmo.

Portanto, as correções das estimativas dos ângulos, neste instante seriam:

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1}(z_{k+1} - H_{k+1}\hat{x}_{k+1})$$

$$\begin{bmatrix} \Delta \hat{\theta}_{B_{k+1}|k+1} \\ \Delta \hat{b}_{B_{k+1}|k+1} \\ \Delta \hat{\theta}_{T_{k+1}|k+1} \\ \Delta \hat{b}_{T_{k+1}|k+1} \end{bmatrix} = \begin{bmatrix} \Delta \theta_{B_{k+1}} \\ \Delta b_{B_{k+1}} \\ \Delta \theta_{T_{k+1}} \\ \Delta b_{T_{k+1}} \end{bmatrix} + \begin{bmatrix} k_1(\Delta \hat{\theta}_{B_{k+1}} - \Delta \theta_{B_{k+1}}) + k_5(\Delta \hat{\theta}_{T_{k+1}} - \Delta \theta_{T_{k+1}}) \\ k_2(\Delta \hat{\theta}_{B_{k+1}} - \Delta \theta_{B_{k+1}}) + k_6(\Delta \hat{\theta}_{T_{k+1}} - \Delta \theta_{T_{k+1}}) \\ k_7(\Delta \hat{\theta}_{T_{k+1}} - \Delta \theta_{T_{k+1}}) + k_3(\Delta \hat{\theta}_{B_{k+1}} - \Delta \theta_{B_{k+1}}) \\ k_8(\Delta \hat{\theta}_{T_{k+1}} - \Delta \theta_{T_{k+1}}) + k_4(\Delta \hat{\theta}_{B_{k+1}} - \Delta \theta_{B_{k+1}}) \end{bmatrix} \quad (4.11)$$

Assim, como pode ser visto na Equação (4.11), as correções das estimativas dos ângulos ($\Delta \hat{\theta}_{B_{k+1}|k+1}$ e $\Delta \hat{\theta}_{T_{k+1}|k+1}$), para os segmentos do tronco e da coxa, contêm ambas as contribuições. Em outras palavras, os estados corrigidos conterão fatores de correção ponderados de todos os estados observados.

Por indução, pode-se dizer que para o arranjo matricial completo do exoesqueleto contendo os estados representativos dos quatro segmentos terá os estados corrigidos compostos de fatores de correção de todos os estados observados. Portanto, como dito no início desta seção, a correção do ângulo absoluto estimado do tronco ($\Delta \hat{\theta}_B$) receberá fatores de correção indiretos dos demais segmentos, assim como a correção do ângulo absoluto estimado do pé ($\Delta \hat{\theta}_F$) também receberá fatores de correção indiretos dos demais segmentos.

Considerações finais sobre o FK-complementar

Os resultados preliminares desta seção, serão apresentados na Seção 4.4 conjuntamente com os resultados do sistema de estimativa baseado no FKSM-complementar, sendo estes considerados os sistemas nominais por não serem modeladas incertezas nos mesmos. Portanto o leitor interessado apenas no FK-complementar, poderá seguir diretamente para a Seção 4.4.

4.3 Sistema de estimativa baseado no FKSM-complementar

Nesta seção é proposta uma nova abordagem baseada no modelo Markoviano para estimativa angular absoluta em exoesqueletos de membros inferiores, visando superar o problema de confiabilidade do acelerômetro durante todas as fases do caminhar humano. Diferentemente de Tong e Granat (1999), Pappas et al. (2004), Moreno et al. (2006), Lau e Tong (2008), Nogueira et al. (2013), nos quais as estimativas angulares eram baseadas em configurações individuais do segmentos, esta proposta leva em conta o modelo coletivo de todos sensores inerciais fixos no exoesqueleto. Tal modelo é composto de 4 unidades de medida inercial e 3 *encoders*.

Considerando uma perna do exoesqueleto Exo-Kanguera/Exo-H1, como ilustrado na Figura 4.2, temos os ângulos absolutos dos segmentos e também os ângulos das articulações ou relativos. Tais ângulos descritos anteriormente, são apresentados resumidamente abaixo:

- Ângulos absolutos: θ_B (tronco), θ_T (coxa), θ_S (canela), θ_F (pé),
- Ângulos relativos: θ_h (quadril), θ_k (joelho), θ_a (tornozelo).

Para descrever a configuração no plano sagital do exoesqueleto em um determinado instante de tempo, pode-se utilizar apenas um dos ângulos absolutos e os três ângulos relativos. Os ângulos relativos são geralmente medidos pelos *encoders* acoplados nas articulações do exoesqueleto ou nos atuadores que as movimentam. A precisão das medidas dos *encoders* é alta, sendo portanto consideradas confiáveis.

No caso dos ângulos absolutos, as medidas são realizadas por meio de IMUs, que incluem giroscópios e acelerômetros. Sabe-se que a incidência de acelerações dinâmicas diminuem a eficiência de estimativa angular em sensores inerciais. Durante o caminhar humano, acelerações

dinâmicas nos segmentos dos membros inferiores mudam a cada instante, com isso apenas uma das IMUs presas aos segmentos da perna teria maior eficiência neste instante.

O conceito da aplicação dos Filtros Markovianos em exoesqueletos seria a utilização apenas das medidas mais confiáveis de uma dada IMU, em cada instante de tempo, desprezando as medidas menos confiáveis das demais IMUs. Os saltos Markovianos seriam identificados pela análise de confiabilidade dos sinais gerados pelas IMUs.

Na Figura 4.12 são mostrados os quatro estados Markovianos (B, *Body*; T, *Thigh*; S, *Shank*; F, *Foot*) do modelo proposto. Estes são definidos como sendo os momentos em que cada IMU possui a menor aceleração dinâmica, ou seja, os intervalos que cada IMU possui maior confiabilidade, definidos como modos de operação.

Figura 4.12: Modos de operação.

Espaço de estados

O sistema de estimativa de posicionamento de exoesqueletos pode ser descrito pelo seguinte modelo Markoviano em espaço de estados:

$$\dot{x}(t) = \bar{A}x(t) + \bar{B}w(t), \quad (4.12)$$

$$y(t) = \bar{C}(\Theta(t))x(t) + v(t), \quad (4.13)$$

sendo $x(t) \in \mathbb{R}^n$ o vetor dos estados do sistema, $w(t) \in \mathbb{R}^m$ e $v(t) \in \mathbb{R}^q$ os vetores dos ruídos do estado e de medida, respectivamente, $y(t) \in \mathbb{R}^q$ o vetor das saídas medidas, e $\Theta(t)$ o estado Markoviano (modo de operação). Os vetores dos estados e das saídas medidas são definidos,

respectivamente, como:

$$\begin{aligned} x &= \begin{bmatrix} x_B & x_T & x_S & x_F \end{bmatrix}^T \\ &= \begin{bmatrix} \Delta\theta_B & \Delta b_B & \Delta\theta_T & \Delta b_T & \Delta\theta_S & \Delta b_S & \Delta\theta_F & \Delta b_F \end{bmatrix}^T, \end{aligned} \quad (4.14)$$

$$\begin{aligned} y &= \begin{bmatrix} \Delta_{IMU} & \Delta_h & \Delta_k & \Delta_a \end{bmatrix}^T \\ &= \begin{bmatrix} \hat{\theta}_{a_{IMU}} - \hat{\theta}_{g_{IMU}} & \Delta\theta_B - \Delta\theta_T & \Delta\theta_T - \Delta\theta_S & \Delta\theta_S - \Delta\theta_F \end{bmatrix}^T, \end{aligned} \quad (4.15)$$

sendo $\Delta\theta_i = \theta_i - \hat{\theta}_{gi}$, para $i = \{B, T, S, F\}$, os erros entre os ângulos absolutos (θ_i) e as estimativas de ângulos calculadas pelos giroscópios ($\hat{\theta}_{gi}$); Δb_i , para $i = \{B, T, S, F\}$, os erros de polarização gerados pelos giroscópios em cada segmento (i); Δ_{IMU} são os erros entre as estimativas de ângulos do acelerômetro ($\hat{\theta}_{a_{IMU}}$) e dos giroscópios ($\hat{\theta}_{g_{IMU}}$); e Δ_j , para $j = \{h, k, a\}$, os erros de estimativa dos ângulos relativos das articulações (j).

No caso da implementação do Filtro Markoviano, o segmento associado ao valor de Δ_{IMU} será aquele que apresentar maior confiabilidade de medida a partir dos dados dos acelerômetros.

Considerando a modelagem dos giroscópios, acelerômetros e da polarização dos giroscópios, pode-se construir as matrizes $\bar{A}$, $\bar{B}$ e $\bar{C}$ como:

$$\bar{A} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & -1/\tau_B & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & -1/\tau_T & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1/\tau_S & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1/\tau_F \end{bmatrix}, \quad \bar{B} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix},$$

$$\bar{C}(\Theta(t)) = \begin{bmatrix} M_B(t) & 0 & M_T(t) & 0 & M_S(t) & 0 & M_F(t) & 0 \\ 1 & 0 & -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & -1 & 0 \end{bmatrix}, \quad (4.16)$$

sendo que M_i , para $i = \{B, T, S, F\}$, pode assumir em um dado instante de tempo os valores 0 ou 1 de acordo com qual ângulo está associado ao valor de Δ_{IMU} . Dessa forma, a única matriz variante no tempo é $\bar{C}(t)$. Após gerar os valores dos erros de estimativa de todos os ângulos, as correções dos ângulos absolutos são dadas por:

$$\begin{aligned} \hat{\theta}_B &= \hat{\theta}_{g_B} + \Delta\hat{\theta}_B, & \hat{\theta}_T &= \hat{\theta}_{g_T} + \Delta\hat{\theta}_T, \\ \hat{\theta}_S &= \hat{\theta}_{g_S} + \Delta\hat{\theta}_S, & \hat{\theta}_F &= \hat{\theta}_{g_F} + \Delta\hat{\theta}_F. \end{aligned}$$

Modos de Operação do Sistema Markoviano

De acordo com o descrito anteriormente, somente a medida de correção de um sensor inercial será utilizado em cada instante em conjunto com três sensores relativos existentes (*encoders*). Como o sistema possui ao todo quatro sensores inerciais, um para cada segmento, nesta modelagem serão considerados quatro modos de operação.

Na Equação (4.16), as quatro variáveis: $M_B(t)$, $M_T(t)$, $M_S(t)$ e $M_F(t)$ selecionam o sensor inercial que será utilizado em cada instante de tempo. A Tabela 4.1 apresenta os modos de operação do modelo Markoviano e os valores destas variáveis, provocando assim o salto somente na matriz $C(t)$.

Modo de operação ($\Theta(t)$)	$M_B(t)$	$M_T(t)$	$M_S(t)$	$M_F(t)$
B	1	0	0	0
T	0	1	0	0
S	0	0	1	0
F	0	0	0	1

Tabela 4.1: Tabela de estados Markovianos

Estratégias para verificar a confiabilidade dos acelerômetros

A confiabilidade do sinal de um acelerômetro é essencial para definir o estado Markoviano corrente, para que o sinal possa ser utilizado pelo FKSM. Sabe-se que quando o módulo dos vetores de medida de acelerômetros triaxiais são próximos do valor da gravidade, ocorrerá baixa incidência de acelerações dinâmicas, tornando-os confiáveis. Dessa forma, define-se que a incidência de aceleração dinâmica e o estado Markoviano corrente, discretos no tempo, são:

$$\rho(k) = \min_i (||a_i|| - |g|), \quad (4.17)$$

$$\Theta(k) = \arg \min_i (||a_i|| - |g|), \quad (4.18)$$

sendo a_i os valores medidos de cada eixo dos acelerômetros triaxiais, g o valor da gravidade, $\Theta(k) \in \{B, T, S, F\}$ representa o modo de operação associado a cada segmento do exoesqueleto de membros inferiores, no qual $\Theta(k)$ é o estado Markoviano corrente, e por fim $\rho(k)$ é o índice que descreve a confiabilidade do acelerômetro utilizado no estado Markoviano corrente, $\Theta(k)$.

Portanto, a condição geral para verificar a confiabilidade da IMU no estado Markoviano corrente é dado por:

$$\rho(k) \leq \zeta, \quad (4.19)$$

sendo $\zeta > 0$ um valor pequeno.

Por exemplo, seja a magnitude do vetor de medidas das quatro IMUs fixos ao exoesqueleto, dados para $k = 1$ to 10:

$$||a_B|| - |g| = (0, 8; 0, 9; 0, 6; 0, 5; 0, 4; 0, 1; 0, 2; 0, 4; 0, 3; 0, 1),$$

$$||a_T|| - |g| = (0, 7; 0, 7; 0, 4; 0, 2; 0, 6; 0, 2; 0, 2; 0, 3; 0, 6; 0, 2),$$

$$||a_S|| - |g| = (0, 1; 0, 2; 0, 7; 0, 6; 0, 5; 0, 5; 0, 1; 0, 5; 0, 1; 0, 7),$$

$$||a_F|| - |g| = (0, 3; 0, 4; 0, 3; 0, 3; 0, 3; 0, 4; 0, 3; 0, 4; 0, 9; 0, 8),$$

portanto, aplicando as Equações (4.17) e (4.18), tem-se:

$$\rho(k) = (0, 1; 0, 2; 0, 3; 0, 2; 0, 3; 0, 1; 0, 1; 0, 3; 0, 1; 0, 1),$$

$$\Theta(k) = (S, S, F, T, F, B, S, T, S, B),$$

se considerarmos $\zeta = 0, 2$, então através da Equação (4.19), os instantes em que o acelerômetro será confiável são $k = \{1, 2, 4, 6, 7, 9, 10\}$.

FKSM-complementar

Considerando a modelagem dos sensores inerciais no Apêndice B, juntamente com o modelo no espaço de estados apresentado nesta seção. Temos o filtro de Kalman sujeito a Saltos Markovianos (FKSM) para o sistema de estimativa proposto, é dado pelo algoritmo preditor-corretor apresentado na Seção 2.4 do Capítulo 2. Portanto, temos que a versão discreta no tempo do modelo Markoviano acima, é dado por:

$$x_{k+1} = Fx_k + Gw_k, \quad (4.20)$$

$$z_k = H_{\Theta_k}x_k + v_k, \quad (4.21)$$

sendo $F \cong I + \bar{A}T$, $G = \bar{A}^{-1}(F - I)\bar{B}$, e $H(k) = \bar{C}$. Sabe-se da literatura que se $(z_k, \Theta(k))$ são conhecidos, então o melhor estimador linear de x_{k+1} é o próprio filtro de Kalman (KF), desde que todos os modos de operação em cada instante k sejam conhecidos, Chizeck e Ji (1988).

Com isso, as equações recursivas de predição e atualização para o FKSM são dadas por:

Equações de predição:

$$\hat{x}_{k+1} = F\hat{x}_{k|k}, \quad (4.22)$$

$$P_{k+1} = FP_{k|k}F_k^T + GQ_kG^T, \quad (4.23)$$

Equações de correção:

$$K_{k+1} = P_{k+1}H_{\Theta(k)}^T(H_{\Theta(k)}P_{k+1}H_{\Theta(k)}^T + R)^{-1}, \quad (4.24)$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1}(z_{k+1} - H_{\Theta(k)}\hat{x}_{k+1}), \quad (4.25)$$

$$P_{k+1|k+1} = (I - K_{k+1}H_{\Theta(k)})P_{k+1}. \quad (4.26)$$

O FKSM é formalizado pelo Algoritmo 5, sendo a versão completa deste dados no Apêndice

C.5. Neste a matriz de pesos Q invariante no tempo e dada por:

$$Q = \begin{bmatrix} \sigma_{\mathbf{g}_B}^2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \sigma_{b_{\mathbf{g}_B}}^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \sigma_{\mathbf{g}_T}^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \sigma_{b_{\mathbf{g}_T}}^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & \sigma_{\mathbf{g}_S}^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \sigma_{b_{\mathbf{g}_S}}^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \sigma_{\mathbf{g}_F}^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & \sigma_{b_{\mathbf{g}_F}}^2 \end{bmatrix}. \quad (4.27)$$

Por outro lado, a matriz de pesos R é considerada variante no tempo, no qual sofre mudanças de acordo com a cadeia de Markov. Sendo R dado por:

$$R = \begin{bmatrix} \sigma_{\mathbf{a}_{\Theta(k)}}^2 & \sigma_{\mathbf{e}_h}^2 & \sigma_{\mathbf{e}_k}^2 & \sigma_{\mathbf{e}_a}^2 \end{bmatrix}, \quad (4.28)$$

para $\Theta(k) = \{B, T, S, F\}$.

As variâncias dos giroscópios ($\sigma_{\mathbf{g}_B}^2, \sigma_{b_{\mathbf{g}_B}}^2, \sigma_{\mathbf{g}_T}^2, \sigma_{b_{\mathbf{g}_T}}^2, \sigma_{\mathbf{g}_S}^2, \sigma_{b_{\mathbf{g}_S}}^2, \sigma_{\mathbf{g}_F}^2$ e $\sigma_{b_{\mathbf{g}_F}}^2$) e dos acelerômetros ($\sigma_{\mathbf{a}_B}^2, \sigma_{b_{\mathbf{a}_B}}^2, \sigma_{\mathbf{a}_T}^2, \sigma_{b_{\mathbf{a}_T}}^2, \sigma_{\mathbf{a}_S}^2, \sigma_{b_{\mathbf{a}_S}}^2, \sigma_{\mathbf{a}_F}^2$ e $\sigma_{b_{\mathbf{a}_F}}^2$), não são fornecidas nas folhas de dados de sensores de baixo custo. Como considerado anteriormente, tais variâncias são desconhecidas, sendo utilizada a mesma topologia proposta no Capítulo 3, para gerar uma estimativa para tais valores.

Apesar de *encoders* possuírem grande precisão, sugerindo variância nula, aqui as variâncias dos mesmos são definidas como ($\sigma_{\mathbf{e}_h}^2, \sigma_{\mathbf{e}_k}^2, \sigma_{\mathbf{e}_a}^2$).

Considerações finais sobre FKSM

Os resultados preliminares desta seção serão apresentados na Seção 4.4 conjuntamente com os resultados do sistema de estimativa baseado no FK-complementar, sendo estes considerados os sistemas nominais por não serem modeladas incertezas nos mesmos.

Algoritmo 5: Estimativa angular absoluta para um exoesqueleto utilizando o FKSM-complementar

// **Predição:**

$$\hat{x}_{k+1} = F \hat{x}_{k|k}$$

$$P_{k+1} = F P_{k|k} F^T + G Q G^T$$

// **Correção:**

se ($\rho_k < \zeta$) **então**

$$\left| \begin{array}{l} z_{k+1}^{\Theta(k)} = \theta_{k+1} - \hat{\theta}_{k+1}^g \end{array} \right.$$

senão

$$\left| \begin{array}{l} z_{k+1}^{\Theta(k)} = \mathbf{0} \end{array} \right.$$

$$z_{k+1}^e = \theta_{k+1}^e - \hat{\theta}_{k+1}^e$$

$$z_{k+1} = \begin{bmatrix} z_{k+1}^{\Theta(k)} & z_{k+1}^e \end{bmatrix}^T$$

$$K_{k+1} = P_{k+1} H_{\Theta(k)}^T (H_{\Theta(k)} P_{k+1} H_{\Theta(k)}^T + R_{\Theta(k)})^{-1}$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H_{\Theta(k)} \hat{x}_{k+1})$$

$$P_{k+1|k+1} = (I - K_{k+1} H_{\Theta(k)}) P_{k+1}$$

// **Saída:**

$$\hat{x}_{k+1|k+1} := \begin{bmatrix} \Delta \hat{\theta}_{k+1|k+1} & \Delta \hat{b}_{k+1|k+1} \end{bmatrix}^T$$

$$\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^g + \Delta \hat{\theta}_{k+1|k+1};$$

4.4 Resultados preliminares para os filtros nominais

Os resultados aqui apresentados tem como objetivo somente a validação funcional dos filtros modelados. Estudos sobre eficiência dos mesmos, bem como comparação de modelagens serão realizadas através dos estudos de caso apresentados no próximo capítulo.

Como descrito nas subseções anteriores, as variâncias utilizadas nos filtros modelados, tais como as dos giroscópios ($\sigma_{B_g}^2, \sigma_{b_{B_g}}^2, \sigma_{T_g}^2, \sigma_{b_{T_g}}^2, \sigma_{S_g}^2, \sigma_{b_{S_g}}^2, \sigma_{F_g}^2$ e $\sigma_{b_{F_g}}^2$), dos acelerômetros ($\sigma_{B_a}^2, \sigma_{T_a}^2, \sigma_{S_a}^2$ e $\sigma_{F_a}^2$), não estão disponíveis nas folhas de dados de sensores de baixo custo.

Dessa forma, foi utilizado o AG proposto no Capítulo 3 para otimização dos valores das variâncias aqui descritas, das constantes de tempo correlacionadas do processo de Gauss Markov ($\tau_{B_g}, \tau_{T_g}, \tau_{S_g}$ e τ_{F_g}) dos giroscópios e da constante ζ utilizada para identificar os momentos de baixa aceleração dinâmica. Os universos de buscas, ou seja, a faixa de variabilidade das constantes, são definidas no Apêndice E. Foram aplicadas 200 gerações evolutivas com populações de 50 indivíduos por geração, sofrendo uma mutação variável de 0 a 30% nos cromossomos de seus indivíduos, o processo utilizado para seleção de indivíduos foi o elitismo genético.

Os gráficos da Figura 4.13 demonstram o processo evolutivo dos AGs aplicados ao FK local, FK matricial e FKSM. Como descrito no Capítulo 3, cada filtro terá suas constantes otimizadas utilizando AGs, sendo realizados dois treinamentos paralelos. O primeiro realiza buscas utilizando um AG baseados em cadeias binárias, promovendo uma busca distribuída ao longo do universo de discurso. Enquanto que no segundo é utilizado um AG baseado em cruzamentos numéricos (média aritmética e método BLX- α), promovendo assim uma convergência mais rápida do AG. Para maiores detalhes veja o Capítulo 3.

Como pode ser visto na Figura 4.13, a evolução dos AGs utilizando cadeias binárias são representadas pelos gráficos de subíndices (a), (c) e (e), enquanto que os AGs utilizando cruzamentos numéricos são representados pelos gráficos de subíndices (b), (d) e (f). Ao compararmos os gráficos, verifica-se que existe intensa troca de indivíduos aptos entre os AGs binários e reais, representados pelos círculos vermelhos. Como verifica-se, os AGs com cadeias binárias contribuem mais no início do processo de busca, ou seja, identificando os possíveis vales. Estas contribuições são apresentadas nos gráficos dos AGs com médias numéricas como contribuições paralelas recebidas. Por outro lado, os AGs com médias numéricas promovem sua maior contribuição após o período de início, garantindo a descida de cada vale, estas são apresentadas nos gráficos de AGs binários como contribuições paralelas recebidas. Além disso, os AGs com cadeias binárias após a estagnação, ou seja, convergência em um mínimo local, promove a busca de outros vales com possíveis mínimos locais melhores do que os atuais.

Nas Tabelas 4.2 a 4.4 são apresentados os parâmetros encontrados, utilizando os AGs para os filtros nominais (FK-local, FK-matricial e FKSM). Além dos termos relacionados aos sensores inerciais, também foram otimizadas as variâncias referentes aos *encoders* do exoesqueleto, para o FKSM, sendo as mesmas $\sigma_{e_h}^2 = 0,3749(^{\circ})^2$, $\sigma_{e_k}^2 = 0,3609(^{\circ})^2$, $\sigma_{e_a}^2 = 0,2021(^{\circ})^2$. Note que o termo C_c , refere-se ao coeficiente de correlação de Pearson dado pela Equação (4.29).

$$C_c = \frac{\sum_{k=t_0}^T (\hat{\theta}_k - \hat{\bar{\theta}}_k)(\theta_k^r - \bar{\theta}_k^r)}{\sqrt{\sum_{k=t_0}^T (\hat{\theta}_k - \hat{\bar{\theta}}_k)^2} \sqrt{\sum_{k=t_0}^T (\theta_k^r - \bar{\theta}_k^r)^2}} \quad (4.29)$$

A análise de correlação utilizando o C_c , representa a relação entre duas variáveis lineares na qual os valores obtidos estarão sempre entre $+1$ e -1 , com o sinal representa se a correlação é

FK-loc	ζ (m/s ²)	σ_g^2 (°/s) ²	$\sigma_{b_g}^2$ (°/s) ²	σ_a^2 (m/s ²) ²	τ_g (s)	C_c
B	0,062	0,0079	$3 \cdot 10^{-6}$	0,2000	124454,1	0,983
T	0,002	10^{-8}	0,2000	0,0423	219737,1	1,000
S	0,001	0,0796	10^{-8}	10^{-5}	76858,3	0,999
F	0,086	0,1494	0,0004	0,0447	267753,2	0,999

Tabela 4.2: Parâmetros do sistema, FK local, simulação.

positiva ou negativa e a magnitude indica a correlação entre as variáveis. Sendo:

- C_c entre 0,7 e 1 indica forte correlação,
- C_c entre 0,3 e 0,7 indica correlação moderada,
- C_c entre 0 e 0,3 indica fraca correlação.

Utilizando os parâmetros encontrados pelos AGs, nas Figuras 4.14 a 4.17 são apresentados os resultados obtidos para os filtros FK local, FK matricial e FKSM. Note que os gráficos de subíndice (a), (c) e (e) contêm os sinais filtrados comparados com as referências, já os gráficos de subíndice (b), (d) e (f) contêm todos os sinais utilizados. Esta última sequência de gráficos é interessante pois é possível verificar que a fusão dos sensores é efetiva pois são aproveitados os melhores momentos de cada sensor.

FK-mat	ζ (m/s ²)	σ_g^2 (°/s) ²	$\sigma_{b_g}^2$ (°/s) ²	σ_a^2 (m/s ²) ²	τ_g (s)	C_c
B	0,09	0,0984	0,0076	0,1931	62112,7	0,943
T	0,05	0,1159	0,1963	0,0757	116631,1	0,999
S	0,10	0,1057	0,0262	0,0012	26382,7	0,999
F	0,10	0,1826	0,1870	0,0418	256985,8	0,999

Tabela 4.3: Parâmetros do sistema, FK matricial, simulação.

(a) FK local binário.

(b) FK local decimal.

(c) FK matricial binário.

(d) FK matricial decimal.

(e) FKSM binário.

(f) FKSM decimal.

Figura 4.13: Evolução dos AG, simulação, filtros nominais.

(a) FK - local.

(b) Sinais - local.

(c) FK - matricial.

(d) Sinais - matricial.

(e) FKSM.

(f) Sinais.

Figura 4.14: Ângulo tronco, simulação, filtros nominais.

(a) FK - local.

(b) Sinais - local.

(c) FK - matricial.

(d) Sinais - matricial.

(e) FKSM.

(f) Sinais.

Figura 4.15: Ângulo coxa, simulação, filtros nominais.

FKSM	ζ (m/s ²)	σ_g^2 (°/s) ²	$\sigma_{b_g}^2$ (°/s) ²	σ_a^2 (m/s ²) ²	τ_g (s)	C_c
B	0,04	0,1906	0,0482	0,0011	361510,3	0,970
T	0,07	0,1843	0,0359	0,0068	584930,7	1,000
S	0,06	0,1766	0,1473	0,0843	504513,9	1,000
F	0,02	0,0255	0,0478	0,0003	643308,1	0,999

Tabela 4.4: Parâmetros do sistema, FKSM, simulação.

4.5 Sistema de estimativa baseado no FKR-complementar

Nesta seção é apresentado o filtro de Kalman robusto (FKR) para o modelo no espaço de estados da Seção 4.2 considerando a solução proposta por Sayed (2001), reveja a Seção 2.3 para maiores detalhes.

A discretização das Equações (4.3) e (4.4) no espaço de estados é dado por:

$$x_{k+1} = Fx_k + G\eta_k, \quad z_k = Hx_k + v_k,$$

sendo $F \cong I + AT$, $G = A^{-1}(F - I)B$, $H = C$, e T é o tempo de amostragem.

Portanto, adicionando incertezas paramétricas no estado, temos que:

$$x_{k+1} = (F + \delta F)x_k + (G + \delta G)\eta_k, \quad (4.30)$$

sendo que δF e δG podem ser modeladas como:

$$\begin{bmatrix} \delta F & \delta G \end{bmatrix} = M\Delta_k \begin{bmatrix} N_F & N_G \end{bmatrix}, \quad (4.31)$$

sendo $\|\Delta_k\| < 1$. Então, através da Equação (4.31), pode-se restringir as fontes de incerteza e distorção selecionando apropriadamente as entradas N_F e N_G , veja Sayed (2001).

O FKR é dado pelo Algoritmo 6, definido como uma variação do Algoritmo 3 do Capítulo 2, diferenciado-se somente no **Passo 3**, por ser aplicado a um modelo matricial, e também pelas

(a) FK - local.

(b) Sinais - local.

(c) FK - matricial.

(d) Sinais - matricial.

(e) FKSM.

(f) Sinais.

Figura 4.16: Ângulo canela, simulação, filtros nominais.

Figura 4.17: Ângulo pé, simulação, filtros nominais.

Algoritmo 6: Estimativa angular absoluta utilizando o FKR-complementar

// **Passo 1:**

se $HM_k = 0$ então

$\hat{\lambda}_k = 0$

senão

$\alpha_f = 0,5$

$\hat{\lambda}_k = (1 + \alpha_f) \cdot \|M_k^T H^T R^{-1} H M_k\|$

// **Passo 2:**

Substitua $\{Q, R, P_{k|k}, G, F\}$ por

$$\hat{Q}^{-1} = Q^{-1} + \hat{\lambda}_k N_G^T [I + \hat{\lambda}_k N_F P_{k|k} N_F^T]^{-1} N_G$$

$$\hat{R} = R - \hat{\lambda}_k^{-1} H M_k M_k^T H^T$$

$$\hat{P}_{k|k} = (P_{k|k}^{-1} + \hat{\lambda}_k N_F^T N_F)^{-1} = P_{k|k} - P_{k|k} N_F^T (\hat{\lambda}_k^{-1} I + N_F P_{k|k} N_F^T)^{-1} N_F P_{k|k}$$

$$\hat{G} = G - \hat{\lambda}_k F \hat{P}_{k|k} N_F^T N_G$$

$$\hat{F} = (F - \hat{\lambda}_k \hat{G} \hat{Q} N_G^T N_F) (I - \hat{\lambda}_k \hat{P}_{k|k} N_F^T N_F)$$

// **Passo 3:**

Filtro de Kalman: Algoritmo 4

estratégias de verificação da confiabilidade dos acelerômetros, definidas no Algoritmo 4.

As matrizes Q , R , M , N_F e N_G são consideradas invariantes no tempo, sendo Q e R definidas como no caso nominal do FK matricial. Já as demais são dadas por:

$$M = \begin{bmatrix} m_1 & m_2 & m_3 & m_4 & m_5 & m_6 & m_7 & m_8 \end{bmatrix}^T, \quad (4.32)$$

$$N_F = \begin{bmatrix} n_{F_1} & n_{F_2} & n_{F_3} & n_{F_4} & n_{F_5} & n_{F_6} & n_{F_7} & n_{F_8} \end{bmatrix}, \quad (4.33)$$

$$N_G = \begin{bmatrix} n_{G_1} & n_{G_2} & n_{G_3} & n_{G_4} & n_{G_5} & n_{G_6} & n_{G_7} & n_{G_8} \end{bmatrix}. \quad (4.34)$$

Como visto na Seção 4.2, as matrizes Q e R foram estimadas utilizando algoritmos genéticos para o caso nominal do FK. No entanto, para o caso robusto consideramos que os valores são conhecidos, já que os mesmos foram anteriormente obtidos para o caso nominal do FK.

No entanto, para o caso robusto do FK, deseja-se estimar os parâmetros que modelam as incertezas do modelo. Como visto na Equação (4.31), tais parâmetros são M , N_F e N_G . Novamente utilizamos AG para gerar estimativas destes valores, sendo aproveitada a mesma topologia proposta no Capítulo 3.

Os resultados preliminares desta seção, serão apresentados na Seção 4.7 conjuntamente

com os resultados do sistema de estimativa baseado no FKRSM-complementar, sendo estes considerados os sistemas robustos. Portanto o leitor interessado apenas no FKR-complementar, poderá seguir diretamente para a Seção 4.7.

4.6 Sistema de estimativa baseado no FKRSM-complementar

Nesta seção apresentamos a modelagem do sistema de estimativa baseado no filtro de Kalman robusto sujeito a salto Markovianos (FKRSM). Da mesma forma como na Seção 4.5, temos que o FKRSM é proposto para o modelo no espaço de estados da Seção 4.3, sendo de solução idêntica a proposta por Sayed (2001).

Portanto, temos a equação de estado discreta para o FKRSM dada por:

$$x_{k+1} = (F + \delta F)x_k + (G + \delta G)\eta_k, \quad (4.35)$$

sendo que δF e δG podem ser modeladas como:

$$\begin{bmatrix} \delta F & \delta G \end{bmatrix} = M \Delta_k \begin{bmatrix} N_F & N_G \end{bmatrix} \quad (4.36)$$

sendo $\|\Delta_k\| < 1$. Então através da Equação (4.31), pode-se restringir as fontes de incerteza/distorção selecionando apropriadamente as entradas N_F e N_G , veja Sayed (2001).

O FKRSM é resumidamente dado pelo Algoritmo 7, sendo as matrizes Q , R , M , N_F e N_G consideradas invariantes no tempo, com Q dada como nos casos nominais do FK local, já as demais são dadas por:

$$R = \begin{bmatrix} \sigma_{a_\theta(k)}^2 & \sigma_{e_h}^2 & \sigma_{e_k}^2 & \sigma_{e_a}^2 \end{bmatrix}, \quad (4.37)$$

$$M = \begin{bmatrix} m_1 & m_2 & m_3 & m_4 & m_5 & m_6 & m_7 & m_8 \end{bmatrix}^T, \quad (4.38)$$

$$N_F = \begin{bmatrix} n_{F_1} & n_{F_2} & n_{F_3} & n_{F_4} & n_{F_5} & n_{F_6} & n_{F_7} & n_{F_8} \end{bmatrix}, \quad (4.39)$$

$$N_G = \begin{bmatrix} n_{G_1} & n_{G_2} & n_{G_3} & n_{G_4} & n_{G_5} & n_{G_6} & n_{G_7} & n_{G_8} \end{bmatrix}. \quad (4.40)$$

Algoritmo 7: Estimativa angular absoluta utilizando o FKRSM-complementar

// **Passo 1:**

se $H_{\Theta(k)}M = 0$ então

$\hat{\lambda}_k = 0$

senão

$\alpha_f = 0,5$

$\hat{\lambda}_k = (1 + \alpha_f) \cdot \left\| M^T H_{\Theta(k)}^T R^{-1} H_{\Theta(k)} M \right\|$

// **Passo 2:**

Substitua $\{Q, R, P_{k|k}, G, F\}$ por

$$\hat{Q}^{-1} = Q^{-1} + \hat{\lambda}_k N_G^T [I + \hat{\lambda}_k N_F P_{k|k} N_F^T]^{-1} N_G$$

$$\hat{R} = R_{\Theta(k)} - \hat{\lambda}_k^{-1} H_{\Theta(k)} M_k M_k^T H_{\Theta(k)}^T$$

$$\hat{P}_{k|k} = (P_{k|k}^{-1} + \hat{\lambda}_k N_F^T N_F)^{-1} = P_{k|k} - P_{k|k} N_F^T (\hat{\lambda}_k^{-1} I + N_F P_{k|k} N_F^T)^{-1} N_F P_{k|k}$$

$$\hat{G} = G - \hat{\lambda}_k F \hat{P}_{k|k} N_F^T N_G$$

$$\hat{F} = (F - \hat{\lambda}_k \hat{G} \hat{Q} N_G^T N_F) (I - \hat{\lambda}_k \hat{P}_{k|k} N_F^T N_F)$$

// **Passo 3:**

Filtro de Kalman sujeito a Saltos Markovianos:

Algoritmo 5.

As matrizes Q e R , foram consideradas conhecidas pois foram obtidas anteriormente no caso nominal do FKSM. Já as matrizes M , N_F e N_G , foram obtidas de forma idêntica ao FKR da Seção 4.5.

4.7 Resultados preliminares para os filtros robustos

Como descrito nas subseções anteriores, as variâncias utilizadas nos filtros modelados, tais como as dos giroscópios ($\sigma_{B_g}^2$, $\sigma_{b_{B_g}}^2$, $\sigma_{T_g}^2$, $\sigma_{b_{T_g}}^2$, $\sigma_{S_g}^2$, $\sigma_{b_{S_g}}^2$, $\sigma_{F_g}^2$ e $\sigma_{b_{F_g}}^2$) e dos acelerômetros ($\sigma_{B_a}^2$, $\sigma_{T_a}^2$, $\sigma_{S_a}^2$ e $\sigma_{F_a}^2$), foram consideradas conhecidas e dadas pelos valores obtidos na Seção 4.4. Da mesma forma, as constantes de tempo correlacionadas do processo de Gauss Markov (τ_{B_g} , τ_{T_g} , τ_{S_g} e τ_{F_g}) dos giroscópios, e da constante ζ utilizada para identificar os momentos de baixa aceleração dinâmica, também foram levantadas anteriormente e consideradas conhecidas nesta seção.

No entanto, os termos que modelam as incertezas paramétricas adicionadas ao modelo nominal, afim de projetarmos o filtro robusto para o mesmo, devem ser identificados através de

alguma metodologia de busca/otimização. Neste caso, foi aproveitada a topologia desenvolvida com algoritmos genéticos no Capítulo 3 para o levantamento de tais termos. Os universos de buscas, ou seja, a faixa de variabilidade das constantes, são definidas no Apêndice E. Foram aplicadas 200 gerações evolutivas com populações de 50 indivíduos por geração, sofrendo uma mutação variável de 0 a 30% nos cromossomos de seus indivíduos, o processo utilizados para seleção de indivíduos foi o elitismo genético.

Os gráficos da Figura 4.18 demonstram o processo evolutivo dos AGs aplicados ao FKR e FKRSM.

Ao compararmos os gráficos, verifica-se o mesmo comportamento observado para os filtros nominais, no qual existe intensa troca de indivíduos aptos entre os AGs binários e reais.

Utilizando os parâmetros encontrados pelos AGs, apresentados nas Tabela 4.5 e 4.6, temos que os resultados obtidos são mostrados nas Figuras 4.19 a 4.22. Note que para ambos os casos, o C_c está acima de 0.9, indicando uma forte correlação positiva entre a referência e o sinal filtrado.

FKR	M	N_F	N_G	C_c
<i>Body</i>	-4,8419	-1,7503	2,1367	0,903
	-3,4219	4,5037	0,8246	
<i>Thigh</i>	0,8622	-2,0238	3,9780	0,999
	-3,8983	0,9233	-1,2256	
<i>Shank</i>	-2,2616	0,2701	1,5425	0,999
	3,8947	-0,0920	-0,4656	
<i>Foot</i>	-4,5367	-5,0000	2,0077	0,999
	2,7086	-0,2556	0,7720	

Tabela 4.5: Parâmetros do sistema, FKR para $\alpha = 0,55$, simulação.

$FKRSM$	M	N_F	N_G	C_c
<i>Body</i>	2,1175	-0,0463	-0,0494	0,978
	1,0851	0,00004	-0,0122	
<i>Thigh</i>	0,3628	-2,9000	-3,1000	1,000
	3,6496	-0,0334	0,0096	
<i>Shank</i>	-3,4347	0,0400	-0,0479	1,000
	3,1803	0,0174	-0,0042	
<i>Foot</i>	-0,0349	-4,9000	-0,1000	0,999
	-0,0206	0,0060	0,0428	

Tabela 4.6: Parâmetros do sistema, FKRSM para $\alpha = 0,38$, simulação.

Figura 4.18: Evolução dos AG, simulação, filtros robustos.

Figura 4.19: Ângulo do tronco, simulação, filtros robustos.

Figura 4.20: Ângulo da coxa, simulação, filtros robustos.

Figura 4.21: Ângulo da canela, simulação, filtros robustos.

Figura 4.22: Ângulo do pé, simulação, filtros robustos.

Após apresentadas todas as modelagens projetadas neste trabalho, nos próximos capítulos serão desenvolvidos estudos de caso envolvendo experimentos reais. Tendo como objetivo a realização de testes, validações e comparações dos modelos aqui propostos.

CAPÍTULO 5

COLETA DE DADOS

Após todo o desenvolvimento e os testes realizados sobre as modelagens, propomos neste capítulo um experimento real utilizando um exoesqueleto de membros inferiores, possuindo *encoders* e sensores FSR. Também foram fixados IMUs e marcadores reflexivos nos segmentos do exoesqueleto.

São apresentados dois experimentos, sendo o primeiro uma captura estática utilizando somente IMUs, com o objetivo de verificar o comportamento dos sensores a variação de temperatura e o tempo de operação. No segundo será apresentado o experimento realizado com o exoesqueleto Exo-H1, sendo discutido o procedimento experimental realizado para captura de dados.

5.1 Captura estática com IMU

Abaixo são apresentados os dados dos giroscópios e acelerômetros de 1 dos 4 sensores inerciais que serão utilizados neste e nos demais experimentos deste capítulo. Os demais sensores apresentaram respostas semelhantes e, portanto, não serão demonstrados nesta seção.

Tais dispositivos consistem de um sistema de captura de movimento da empresa Technaid,

ilustrados na Figura 5.1 e apresentados em maiores detalhes no Apêndice F.4.

Figura 5.1: Tech IMU, Technaid.

Como sabe-se, os sinais brutos dos giroscópios e acelerômetros apresentam dependência do tempo de acionamento, decorrente do aquecimento do dispositivo durante sua ativação, e também da temperatura externa do ambiente, por a mesma influenciar diretamente no aquecimento do dispositivo.

Com o intuito de verificar a dependência dos sensores inerciais decorrente do aumento de temperatura, foi realizada uma captura estática durante o período de aproximadamente 4 horas, sendo esta apresentada na Figura 5.2. Nesta, nota-se nos momentos iniciais de ativação do dispositivo, uma subida exponencial na temperatura medida. Da mesma forma, os sinais dos giroscópios apresentam uma dependência direta a esse aumento de temperatura. No início da captura é registrada a menor temperatura, em torno de 25°C , neste instante as medidas registradas pelos três giroscópios do sensor são respectivamente: $0,0027$, $0,002$ e $-0,0046^{\circ}/\text{s}$. Após aproximadamente 2 horas e 23 minutos, ocorreu a maior alta de temperatura, atingindo 55°C , neste instante as medidas dos giroscópios registravam $0,0498$, $-0,1920$ e $0,1520^{\circ}/\text{s}$, apresentando desvios de medida nos três giroscópios de aproximadamente $0,0471$, $-0,194$ e $0,1566^{\circ}/\text{s}$. Estes desvios estão dentro dos limites esperados para giroscópios de baixo custo, já que grande parte dos fornecedores informa que seus sensores podem possuir desvios entre

$|0, 1|$ e $|0, 5|^\circ/s$ por hora de operação. No entanto, tais desvios, como ficará claro no Capítulo 6, passam a ser significativos para os filtros de Kalman (FK) baseados no modelo nominal.

Como a IMU possui somente um sensor de temperatura na placa principal, os instantes de maior e menor temperatura são os mesmos para ambos os tipos de sensores aqui estudados (giroscópios e acelerômetros). Dessa forma, os acelerômetros no início da captura, quando a temperatura era em torno de $25^\circ C$, registravam respectivamente $0,23$, $0,75$ e $9,20 \text{ m/s}^2$, sendo a norma do mesmo $\sqrt{0,23^2 + 0,75^2 + 9,20^2} = 9,23 \text{ m/s}^2$. Já no instante de tempo com a maior temperatura, $55^\circ C$, os acelerômetros registravam respectivamente $-0,02$, $1,04$ e $8,49 \text{ m/s}^2$, sendo a norma do mesmo $8,55 \text{ m/s}^2$.

Era esperado que a norma do acelerômetro, estando o mesmo estático, fosse próxima de $9,81 \text{ m/s}^2$, ou seja, o valor da gravidade terrestre. No entanto, como sabe-se, durante o processo de fabricação dos acelerômetros, pequenos desalinhamentos entre os eixos triaxiais são possíveis, sendo previsível que este valor seja ligeiramente diferente, dependendo da construção física do mesmo e das oscilações de temperatura.

Portanto, as regras utilizadas para verificarem a confiabilidade dos acelerômetros, como por exemplo: $||a|| - |g| < \zeta$, são diretamente dependentes da temperatura, sendo necessário atualizar o valor da $|g|$ para o valor da $||a||$ quando a IMU estiver estático. Ou seja, é necessário no início de cada experimento ter alguns segundos de captura estáticos, para calibrar o valor inicial da $||g||$.

No entanto, ao calcularmos os ângulos através do giroscópio verificamos que as variâncias de temperatura associados aos erros gerados pelo processo de integração numérica, faz com que o erro acumulado na estimativa angular pelo giroscópio seja bem mais significativo do que sobre o acelerômetro, veja a Figura 5.2. O que justifica o desenvolvimento de filtros robustos as incertezas paramétricas do modelo.

5.2 Captura com Exo-H1

Como descrito ao longo de todo o texto, os experimentos que possibilitaram capturas reais foram realizados sobre o exoesqueleto de membros inferiores do grupo de bioengenharia do

Figura 5.2: Captura estática com IMU, (a) giroscópios e (b) acelerômetros.

CSIC, Exo-H1.

Tais experimentos consistiram em capturar o movimento do caminhar humano sobre uma esteira elétrica, para uma pessoa sadia vestindo o exoesqueleto Exo-H1. Nos segmentos da perna direita do exoesqueleto foram fixadas IMUs, sendo as mesmas dispostas paralelamente ao plano sagital humano, reveja as Figuras 1.1 e 4.2. Visando validar os modelos de estimativa que utilizam as IMUs e os *encoders*, foram capturados os movimentos também com um sistema de aquisição óptica, utilizando marcadores foto-reflexivos, veja a Figura 5.3.

No entanto, para que fosse possível a captura de todos os dados necessários, para aplicação e validação dos modelos propostos, foram utilizados vários sistemas de aquisição de dados distintos.

Os sistemas de aquisição de dados utilizados foram:

- Sistema de captura de movimento da TECHNAID, utilizando unidades de medida inercial, Figura 5.1.
- Exoesqueleto Exo-H1 do grupo de bioengenharia do CSIC, possuindo *encoders* e senso-

Figura 5.3: Exo-H1 com IMUs e marcadores foto-reflexivos.

res de contato, Figura 5.4.

- Sistema de captura óptica da *BTS Engineering*, utilizando marcadores ópticos, Figura 5.5.

5.2.1 Dificuldades inerentes

Quando deseja-se realizar capturas de dados com sistemas distintos, como: exoesqueletos (*encoders* e *FSR*), IMUs e sistema óptico, a sincronização e frequência de aquisição dos sinais passam a ser processos críticos e assim tal atividade não é trivial.

A primeira dificuldade surge da captura sincronizada de todos os dados adquiridos, na qual pequenos atrasos de tempo entre os sinais capturados poderia inviabilizar a comparação dos filtros desenvolvidos para cada sistema de estimativa. Dentre os três sistemas de aquisição utilizados, o que apresentou atrasos mais significativos, foi o sistema de captura de movimento da *TECHNAID*, pois o dispositivo de sincronia utilizado consistia de um transmissor sem fio. Este fato, notado posteriormente à captura, exigiu que o autor realiza-se pré-processamento dos sinais de forma corrigir o atraso ocorrido em cada captura.

Figura 5.4: Exoesqueleto Exo-H1.

A segunda situação refere-se a frequência de aquisição das plataformas de captura. Essa apesar de ser configurável na grande maioria dos sistemas, em muitos casos não é determinística e consiste de uma média do tempo de aquisição. Nestes casos, frequentemente a taxa de captura não é um número inteiro ou mesmo múltiplo das taxas de aquisição configuráveis nas demais plataformas, o que pode causar desalinhamentos das capturas em determinados momentos. Portanto, torna-se necessário definir algumas estratégias para posterior reamostragem dos sinais capturados, por exemplo, realizar capturas com vários ciclos repetitivos contendo todos os dispositivos, o que permitiria posteriormente realizar reamostragem e alinhamentos através dos picos e vales bem definidos.

A terceira questão a ser considerada refere-se aos diferentes padrões de gravação dos dados capturados, sendo necessário o desenvolvimento de funções de leitura dos diferentes padrões dos sistemas e também o desenvolvimento de funções para junção e normalização em um formato único a ser utilizado nos filtros desenvolvidos.

Figura 5.5: Smart-D.

5.2.2 Dados capturados

Os dados capturados de todos os sensores são apresentados nas Figuras 5.6, 5.7 e 5.8. Observe que a Figura 5.8(d) mostra as fases do caminhar para a perna direita.

Após os experimentos realizados, com os dados capturados, preprocessados e normalizados, passamos aos estudos de caso para verificar a eficiência dos modelos propostos anteriormente.

(a) Tronco.

(b) Coxa.

(c) Canela.

(d) Pé.

Figura 5.6: Dados capturados pelos giroscópios no plano sagital.

(a) Tronco.

(b) Coxa.

(c) Canela.

(d) Pé.

Figura 5.7: Dados capturados pelos acelerômetros triaxiais.

(a) Quadril.

(b) Joelho.

(c) Tornozelo.

(d) Fases do caminhar.

Figura 5.8: Dados capturados pelos *encoders* do Exo-H1, e as fases do caminhar identificadas.

CAPÍTULO 6

ESTUDOS DE CASO

Neste capítulo são apresentados estudos de caso sobre as capturas de dados realizadas com o Exo-H1, sendo realizados sobre os modelos de estimativas anteriormente propostos neste trabalho. Através dos estudos de caso apresentados, espera-se demonstrar as vantagens e desvantagens dos modelos de estimativas aqui propostos. Para o estudo comparativo dos filtros, sejam nominais ou robustos, foram feitas as seguintes considerações:

1. Os parâmetros de todos os filtros foram otimizados pela mesma estratégia, definida no Capítulo 3.
2. Cada AG (bin. ou dec.) possui as seguintes características:
 - Tamanho da população por geração: 50 indivíduos,
 - Quantidade de gerações: 400,
 - Mutação máxima por cromossomos: 30%,
 - Número de gerações consecutivas para realizar operação de elitismo com genocídio: 10.
3. A função que determina o custo, ou seja, a eficiência do filtro decorrente dos parâmetros

escolhidos e dos dados a serem filtrados, é dada por $\bar{E} = \frac{1}{T} \sum_{k=t_0}^T |\hat{\theta}_k - \theta_k^r|$, sendo a mesma aplicada:

- Para um conjunto de 20 s de dados, separado em 6 janelas com inícios distintos e intervalos de sobreposição, no qual cada janela possui 15 s de dados, veja a Figura 6.1,
 - Erro médio de estado, ou seja, o custo consiste da média do erro de estado das 6 janelas.
4. Serão utilizados dois conjuntos de dados um para os treinamentos dos AGs, Figura 6.1(a), e um para validação dos AGs, Figura 6.1(b).

A Consideração 3, ou seja, a função custo, é ilustrada na Figura 6.1. A justificativa na proposição desta consideração está no fato de que a convergência das matrizes de covariância (P_k) dos filtros propostos são sensíveis ao valor inicial do acelerômetro, e afetam significativamente o cálculo da eficiência do filtro.

Para comparar os resultados, também é utilizado o coeficiente de correlação, C_c , definido no Capítulo 4. Neste trabalho buscamos minimizar o $\bar{E}$ e obter uma correlação positiva com a maior magnitude possível.

Após as considerações iniciais definidas para todos os estudos de casos, nas próximas seções serão apresentados três estudos. Sendo o primeiro referente a análise de confiabilidade dos acelerômetros. No segundo é realizado um estudo comparativo dos filtros nominais, e por fim, o mesmo estudo é reproduzido para os filtros robustos.

6.1 Confiabilidade do acelerômetro

Nesta seção reproduzimos, com os dados experimentais, os mesmos procedimentos apresentadas pelo autor no artigo Nogueira et al. (2013). O objetivo deste estudo de caso é demonstrar a superioridade de se utilizar estratégias, tais como a norma do acelerômetro para verificar a confiabilidade dos acelerômetros dispostos nos segmentos do exoesqueleto de membros inferiores, sobre o uso de sensores *FSR* dispostos na sola do pé.

(a) Dados de treinamento

(b) Dados de validação

Figura 6.1: Custos por intervalo, no segmento do tronco.

Para verificar a viabilidade da proposta em Nogueira et al. (2013), inicialmente foram definidas as seguintes estratégias:

- Primeira estratégia:

Para $i = \{B, T, S, F\}$

Se ((perna em apoio) **E** ($\|a_{x_F}\| < 0,5|g|$)) **então**

a_{x_i} *é confiável*

Caso contrário

a_{x_i} *não é confiável*

Fim Para

- Segunda estratégia:

Para $i = \{B, T, S, F\}$

Se $(\rho_i < \zeta)$ **então**

a_i *é confiável*

Caso contrário

a_i *não é confiável*

Fim Para

Nas Tabelas 6.1 e 6.2 são mostrados os parâmetros encontrados para os filtros utilizando respectivamente a primeira e segunda estratégias, ao aplicarmos o AG.

Como se esperava, a primeira estratégia utilizando o FK-complementar local, nomeado resumidamente com *FK* local com FSR, apresenta bons resultados somente para os segmentos do pé e da canela, pois a medida que nos distanciamos do pé, esta deixa de ser um indicativo dos momentos de baixa aceleração dinâmica. No entanto, a segunda estratégia, *FK* local com acelerômetro, apresenta bons resultados para todos os segmentos, pois a mesma avalia a confiabilidade local de cada IMU.

Do ponto de vista qualitativo, temos que o sinal filtrado utilizando o *FK* local com acelerômetro apresenta menor desvio na estimativa, veja as Figuras 6.2 a 6.5. O *FK* local com acelerômetro também apresenta melhores resultados do ponto de vista quantitativo através dos índices de desempenho, $\bar{E}$ e C_c , para os dados de treinamento, $\bar{E}^{tr}$ e $\bar{C}_c^{tr}$, e para os dados de validação, $\bar{E}^{vl}$ e $\bar{C}_c^{vl}$, demonstrando assim, a superioridade em se utilizar a segunda estratégia para identificação dos momentos com baixa aceleração dinâmica.

Outro ponto importante a ser observado, nas Figuras 6.2 a 6.5 é que para o *FK* local com acelerômetro, os instantes em que o acelerômetro é considerado confiável apresenta-se mais distribuído ao longo do tempo, o que sugere a existência de instantes de tempo fora da fase de apoio da perna em que os acelerômetros teriam seus sinais confiáveis.

Portanto, nos estudos subsequentes, será utilizado somente a segunda estratégia doravante referenciada somente como *FK* local.

FK_{LOC}^{FSR}	σ_g^2 ($^\circ/s$) ²	$\sigma_{b_g}^2$ ($^\circ/s$) ²	σ_a^2 (m/s^2) ²	τ_g (s)	$\bar{E}^{tr}[x]$ ($^\circ$)	$\bar{E}^{vl}[x]$ ($^\circ$)	C_c^{tr}	C_c^{vl}
Body	0,00008	0,0567	0,1425	186760	2,208	2,008	0,639	0,720
Thigh	0,00003	0,0050	0,1855	213388	1,199	0,782	0,979	0,994
Shank	0,00002	0,0007	0,0869	700576	0,736	1,066	0,996	0,993
Foot	0,00042	0,0002	0,1348	26297	1,239	1,101	0,993	0,995

Tabela 6.1: Parâmetros do sistema, FK local com FSR, captura com Exo-H1.

FK_{LOC}^{ACEL}	ζ (m/s^2)	σ_g^2 ($^\circ/s$) ²	$\sigma_{b_g}^2$ ($^\circ/s$) ²	σ_a^2 (m/s^2) ²	τ_g (s)	$\bar{E}^{tr}[x]$ ($^\circ$)	$\bar{E}^{vl}[x]$ ($^\circ$)	C_c^{tr}	C_c^{vl}
Body	0,0151	0,0108	0,1015	0,1115	221195	1,236	1,723	0,827	0,736
Thigh	0,0118	0,0009	0,1518	0,1124	165138	0,707	0,581	0,996	0,998
Shank	0,0312	0,0002	0,1098	0,0497	32926	0,455	0,710	0,999	0,997
Foot	0,0099	0,1799	0,1187	0,3751	338	1,092	1,061	0,995	0,996

Tabela 6.2: Parâmetros do sistema, FK local com acelerômetro, captura com Exo-H1.

Figura 6.2: Ângulo absoluto do tronco, validação, filtros locais.

Figura 6.3: Ângulo absoluto da coxa, validação, filtros locais.

Figura 6.4: Ângulo absoluto da canela, validação, filtros locais.

Figura 6.5: Ângulo absoluto do pé, validação, filtros locais.

6.2 Sistemas de estimativas baseados nos modelos nominais

Nesta seção são apresentados os sistemas de estimativas com filtros baseados nos modelos nominais, sendo o primeiro baseado no filtro de Kalman na abordagem matricial (FK matricial), apresentado na Seção 4.2, e o segundo baseado no filtro de Kalman sujeito a salto Markovianos (FKSM) apresentado na Seção 4.3.

Como demonstrado na Seção 4.2, existem diferenças substanciais na aplicação do FK para os modelos local e matricial. Como o FKSM apresenta um modelo matricial, que propicia correções ponderadas colaborativas entre os estados, não seria justa uma comparação entre o FK local e o $FKSM$, dessa comparamos o FK matricial com o $FKSM$.

Segundo as considerações feitas no início do capítulo, temos que os parâmetros encontrados para os filtros, utilizando o AG, proposto no Capítulo 3, são dados respectivamente pelas Tabelas 6.3 e 6.4. Além dos termos relacionados aos sensores inerciais, também foram otimizadas variâncias referentes ao *encoders* do exoesqueleto, para o FKSM, sendo as mesmas

$$\sigma_{e_h}^2 = 0,1393 (^\circ)^2, \sigma_{e_k}^2 = 0,2741 (^\circ)^2 \text{ e } \sigma_{e_a}^2 = 0,3657 (^\circ)^2.$$

FK_{MAT}	ζ (m/s^2)	σ_g^2 ($^\circ/s$) ²	$\sigma_{b_g}^2$ ($^\circ/s$) ²	σ_a^2 (m/s^s) ²	τ_g (s)	$\bar{E}^{tr}[x]$ ($^\circ$)	$\bar{E}^{vl}[x]$ ($^\circ$)	C_c^{tr}	C_c^{vl}
Body	0,040	0,1668	0,2832	0,2199	516177	0,730	1,856	0,895	0,791
Thigh	0,010	0,0438	0,3507	0,3613	976531	0,567	0,799	0,998	0,995
Shank	0,025	0,0368	0,4000	0,2580	178949	0,726	1,080	0,997	0,994
Foot	0,002	0,3481	0,0160	0,0755	378816	0,965	1,328	0,995	0,988

Tabela 6.3: Parâmetros do sistema, FK matricial, captura com Exo-H1.

$FKSM$	ζ (m/s^2)	σ_g^2 ($^\circ/s$) ²	$\sigma_{b_g}^2$ ($^\circ/s$) ²	σ_a^2 (m/s^s) ²	τ_g (s)	$\bar{E}^{tr}[x]$ ($^\circ$)	$\bar{E}^{vl}[x]$ ($^\circ$)	C_c^{tr}	C_c^{vl}
Body	0,0004	0,0028	0,1904	0,3240	785453	0,496	0,667	0,964	0,924
Thigh	0,0072	0,0013	0,3623	0,3644	868798	0,530	0,654	0,998	0,997
Shank	0,0027	0,0261	0,1044	0,4000	761537	0,467	0,612	0,999	0,997
Foot	0,0018	0,0057	0,1342	0,3230	570643	0,842	1,000	0,996	0,994

Tabela 6.4: Parâmetros do sistema, FKSM, captura com Exo-H1.

Portanto, temos que o erro médio de estado no conjunto de dados de treinamento para o FK matricial é igual a $0,747^\circ$ e para o $FKSM$ é igual $0,584^\circ$, isto representa um aumento da precisão de medida em $0,163^\circ$ ou, aproximadamente, uma melhoria de sobre o erro de 22%.

Da mesma forma, temos que erro médio de estado no conjunto de dados de validação para o FK matricial é igual a $1,266^\circ$ e para o $FKSM$ é igual a $0,733^\circ$, isto representa um aumento da precisão de medida em $0,533^\circ$ ou, aproximadamente, uma melhoria de sobre o erro de 42%.

O coeficiente de correlação das estimativas do FK matricial para segmento *Body/trunk* apresentam queda significativa entre os dados de treinamento e validação, se comparados com o mesmo segmento do $FKSM$. Outro detalhe importante, é que os desvios de estimativas do $FKSM$ são bem menores do que no FK , veja as Figuras 6.6 a 6.9.

Figura 6.6: Ângulo absoluto do tronco, validação, filtros nominais.

Figura 6.7: Ângulo absoluto da coxa, validação, filtros nominais.

Figura 6.8: Ângulo absoluto da canela, validação, filtros nominais.

Figura 6.9: Ângulo absoluto do pé, validação, filtros nominais.

Além disso, o uso do $FKSM$, propicia um aumento significativo dos instantes com medida confiável do acelerômetro. Pois basta que um sensor tenha o acelerômetro confiável para que a correção seja aplicada em todos os ângulos.

6.3 Sistemas de estimativas baseados nos modelos robustos

Nesta seção são apresentados os sistemas de estimativas com filtros baseados nos modelos robustos, sendo o primeiro baseado no filtro de Kalman robusto na abordagem matricial (FKR_{MAT}), apresentado na Seção 4.5, e o segundo baseado no filtro de Kalman robusto sujeito a salto Markovianos (FKRSM) apresentado na Seção 4.6.

Novamente, segundo as considerações feitas no início do capítulo, temos que os parâmetros encontrados para cada um dos filtros, utilizando o AG, proposto no Capítulo 3, são dados respectivamente pelas Tabelas 6.5 e 6.6.

FKR_{MAT}	M	N_F	N_G	$\bar{E}_{tr}[x]$	$\bar{E}_{vl}[x]$	C_{tr}^c	C_{vl}^c
Body	-0,7856	-4,6373	-4,5057	0,595	1,307	0,886	0,863
	-3,8789	-0,5152	-1,6567				
Thigh	-4,1729	-2,9595	-1,3374	0,569	0,786	0,998	0,995
	0,4879	1,0118	-1,8573				
Shank	-2,5890	-4,9366	-3,9910	0,731	1,032	0,997	0,994
	4,3290	0,1626	0,5874				
Foot	-0,3474	-4,8915	1,0896	0,779	1,193	0,994	0,989
	-1,6454	1,5055	0,8125				

Tabela 6.5: Parâmetros do sistema, FKR matricial para $\alpha = 0,61$, , captura com Exo-H1.

$FKRSM$	M	N_F	N_G	$\bar{E}^{tr}[x]$	$\bar{E}^{vl}[x]$	C_c^{tr}	C_c^{vl}
Body	0,4111	0,8952	2,6291	0,406	0,635	0,971	0,924
	3,4194	-0,2409	2,2113				
Thigh	3,5681	-0,6833	1,5524	0,454	0,571	0,998	0,997
	0,4775	0,6614	1,5780				
Shank	-3,1985	5,0000	4,8679	0,361	0,377	0,999	0,998
	2,8240	1,4711	-0,2357				
Foot	-3,8490	-5,0000	4,3432	0,799	0,919	0,996	0,995
	1,2032	1,6973	-2,5204				

Tabela 6.6: Parâmetros do sistema, FKRSM para $\alpha = 0,92$, , captura com Exo-H1.

Portanto, temos que o erro médio de estado no conjunto de dados de treinamento para o FKR matricial é igual a $0,669^\circ$ e para o $FKRSM$ é igual a $0,505^\circ$, isto representa um aumento da precisão de medida em $0,15^\circ$ ou, aproximadamente, um melhoria de sobre o erro de 25%. Para o conjunto de dados de validação, os erros médios de estado são FKR matricial é igual a $1,080^\circ$ e $FKRSM$ é igual a $0,626^\circ$, isto representa um aumento da precisão de medida em $0,697^\circ$ ou, aproximadamente, um melhoria de sobre o erro de 42%. Novamente nota-se uma resposta qualitativa superior do filtro Markoviano, apresentando desvios de estimativas menores do que o FKR , veja as Figuras 6.10 a 6.13. Além do aumento significativo dos instantes com medidas confiáveis do acelerômetro pelo $FKSM$.

Figura 6.10: Ângulo absoluto do tronco, validação, filtros robustos.

Figura 6.11: Ângulo absoluto da coxa, validação, filtros robustos.

Figura 6.12: Ângulo absoluto da canela, validação, filtros robustos.

Figura 6.13: Ângulo absoluto do pé, validação, filtros robustos.

CAPÍTULO 7

CONCLUSÕES

Nesta tese foram desenvolvidos quatro sistemas para estimativas angulares absolutas em exoesqueletos de membros inferiores, sendo a principal contribuição deste trabalho os sistemas baseados em saltos Markovianos . Também foi desenvolvida uma ferramenta de otimização de parâmetros dos filtros, baseada em algoritmos genéticos paralelos, o que permitiu uma comparação mais precisa e justa entre os filtros propostos.

Na Tabela 7.1 temos os índices de desempenho encontrados para cada filtro:

<i>Filtro</i>	$\bar{E}_{tr}[x]$	$\bar{E}_{vl}[x]$	C_{tr}^c	C_{vl}^c
FK	0,747	1,266	0,971	0,942
FKSM	0,584	0,733	0,989	0,978
FKR	0,669	1,080	0,969	0,960
FKRSM	0,505	0,626	0,991	0,979

Tabela 7.1: Índices de desempenho.

Como pode ser visto na Tabela 7.1 os filtros Markovianos (FKSM e FKRSM) propostos nesta tese superam com boa vantagem os filtros convencionais. Sendo que o FKSM apresenta

uma melhoria de **22%** sobre o FK nos dados de treinamento e **42%** nos dados de validação. Já o FKRSM apresenta uma melhoria de **25%** sobre o FKR nos dados de treinamento e **42%** nos dados de validação.

Tanto para os casos nominais quanto para os robustos, os filtros Markovianos apresentaram resultados mais significativos no conjunto de dados de validação, o que sugere que os filtros Markovianos possibilitam maior repetibilidade do processo de filtragem.

Além disso tanto no caso nominal (FK e FKSM) quanto no caso robusto (FKR e FKRSM) os filtros Markovianos apresentaram menores desvios de estimativas para os dados de treinamento e validação, o que demonstra que a modelagem coletiva de sensores inerciais baseada em sistemas Markovianos é superior a modelagem matricial convencional.

Trabalhos futuros

A continuidade dos trabalhos realizados, pode ser dividida em dois grupos, sendo o primeiro relacionado aos trabalhos científicos e o segundo relacionado ao desenvolvimento tecnológico.

Trabalhos científicos

Como trabalhos futuros, pretende-se projetar os filtros Markovianos para casos de falhas nos modelos coletivos, ou seja, quando uma unidade inercial perde comunicação com o sistema. Além disso, para os casos robustos, seria interessante o projeto do filtro também para o caso de incertezas paramétricas na equação de saída do espaço de estados, ou seja, na medição.

Desenvolvimento tecnológico

Como futuros desenvolvimentos tecnológicos, temos primeiramente a necessidade de automatizar o processo de captura e sincronia de múltiplos sensores em exoesqueletos. Além disso, para a utilização dos algoritmos desenvolvidos para exoesqueletos, torna-se necessário portá-los para plataformas embarcadas.

REFERÊNCIAS BIBLIOGRÁFICAS

- Bianco, A., J. Ishihara, e M. Terra (2008). Optimal robust prediction for general discrete time singular systems. In *Control, Automation, Robotics and Vision, 2008. ICARCV 2008. 10th International Conference on*, Hanoi, Vietnam, pp. 1793–1798.
- Bijker, J. e W. Steyn (2008). Kalman filter configurations for a low-cost loosely integrated inertial navigation system on an airship. *Control Engineering Practice* 16, 1509–1518.
- Bortole, M., A. del Ama, E. Rocon, J. Moreno, F. Brunetti, e J. Pons (2013). A robotic exoskeleton for overground gait rehabilitation. In *Robotics and Automation (ICRA), 2013 IEEE International Conference on*, Karlsruhe, Germany, pp. 3356–3361.
- Brown, R. G. e P. Y. C. Hwang (1997). *Introduction to random signal and applied Kalman filtering: with Matlab exercises and solutions* (3rd ed.). New York, USA: John Wiley & Sons.
- Caltran, C. e A. Siqueira (2011). Sensor fusion applied to position estimation and gait identification of an ankle-foot orthosis. In *Biosignals and Biorobotics Conference (BRC), 2011 ISSNIP*, Vitória, Brazil, pp. 1–6.
- Caltran, C. e A. A. G. Siqueira (2010). Position estimation of an active ankle-foot orthosis using sensor fusion. In *1st International Conference on Applied Bionics and Biomechanics (ICABB-2010)*, Venice, Italy.

- Caltran, C., A. A. G. Siqueira, R. S. Inoue, e M. H. Terra (2011). Robust filtering applied to position estimation of an active ankle-foot orthosis. In *Accepted to 18th World Congress of the International Federation of Automatic Control (IFAC)*, Milano, Italy, pp. 1–6.
- Castellanos, J., S. Lesecq, N. Marchand, e J. Delamare (2005). A low-cost air data attitude heading reference system for the tourism airplane applications. In *Sensors, 2005 IEEE*, Irvine, CA, USA, pp. 4.
- Chizeck, H. e Y. Ji (1988). Optimal quadratic control of jump linear systems with gaussian noise in discrete-time. In *Proceedings of the 27th IEEE Conference on Decision and Control*, Austin, Texas, pp. 1989–1993 vol.3.
- Chu, A., H. Kazerooni, e A. Zoss (2005). On the biomimetic design of the berkeley lower extremity exoskeleton (bleex). In *Robotics and Automation, 2005. ICRA 2005. Proceedings of the 2005 IEEE International Conference on*, Barcelona, Spain, pp. 4345–4352.
- Costa, O. L. V., M. D. Fragoso, e R. P. Marques (2005). *Discrete-time Markov jump linear systems*. Probability and its applications. London: Springer.
- Delp, S. L., F. C. Anderson, A. S. Arnold, P. Loan, A. Habib, C. T. John, E. Guendelman, e D. G. Thelen (2007). Opensim: Open-source software to create and analyze dynamic simulations of movement. *IEEE Trans. Biomed. Engineering* 54(11), 1940–1950.
- Dominguez, S. M., T. Keaton, e A. H. Sayed (2006). A robust tracking method for multimodal wearable computer interfacing. *IEEE Transactions on Multimedia* 8(5), 956–972.
- El-Sheimy, N., H. Hou, e X. Niu (2008). Analysis and modeling of inertial sensors using allan variance. *IEEE Transactions on Instrumentation and Measurement* 57, 140–149.
- Farrell, J. (2008). *Aided Navigation: GPS with High Rate Sensors* (1 ed.). New York: McGraw-Hill, Inc.
- Farrell, J. e M. Barth (1998). *The global positioning system and inertial navigation*. New York: McGraw-Hill.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Massachusetts: Addison-Wesley.

-
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: University of Michigan Press. second edition, 1992.
- IEEE (1997). Guide and test procedure for single axis interferometric fiber optic gyros. *IEEE Std 952*.
- Inoue, R. S. (2012). *Controle robusto descentralizado de movimentos coordenados de robôs heterogêneos*. Tese de Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo.
- Inoue, R. S., M. H. Terra, A. A. G. Siqueira, e J. M. S. C. Yabarrena (2009). Filtragem robusta para navegação inercial. In *IX Simpósio Brasileiro de Automação Inteligente*, Brasília, Brasil.
- Ishihara, J. Y. e M. H. Terra (2008). Robust state prediction for descriptor systems. *Automatica* 44(8), 2185 – 2190.
- Ishihara, J. Y., M. H. Terra, e J. C. T. Campos (2006). Robust Kalman filter for descriptor systems. *IEEE Transaction on Automatic Control* 51(8), 1354–1358.
- Jacobs, O. L. R. (1994). *Introduction to Control Theory*. Oxford University Press, USA.
- Jong, K. A. D. (1975). *An Analysis of the Behavior of a Class of Genetic Adaptive Systems*. Tese de Doutorado, University of Michigan.
- Jung, D. e P. Tsiotras (2007). Inertial attitude and position reference system development for a small UAV. In *American Institute of Aeronautics and Astronautics*, Rohnert Park, California.
- Kailath, T., A. H. Sayed, e B. Hassibi (2000). *Linear Estimation*. Prentice-Hall, NJ.
- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Transactions of the ASME - Journal of Basic Engineering* 82(Series D), 35–45.
- L., M., P. A. T., e B. A. M. (2011). An open source lower limb model: Hip joint validation. *Journal of Biomechanics* 44, 2185–2193.
- Lau, H. e K. Tong (2008). The reliability of using accelerometer and gyroscope for gait event identification on persons with dropped foot. *Gait & Posture* 27(2), 248–257.

- Luinje, H. J. e P. Veltink (2005). Measuring orientation of human body segments using miniature gyroscopes and accelerometers. *Medical & Biological engineering & Computing* 43(2), 273–282.
- Luinje, H. J. e P. H. Veltink (2004). Inclination measurement of human movement using a 3-D accelerometer with autocalibration. *IEEE Transactions on neural systems and rehabilitation engineering* 12(1), 112–121.
- Luinje, H. J., P. H. Veltink, e C. T. M. Baten (2007). Ambulatory measurement of arm orientation. *Journal of Biomechanics* 40(1), 78–85.
- M., A. E., W. S. R., L. R. L., e D. S. L. (2010). A model of the lower limb for analysis of human movement. In *Annals Biomedical Engineering 2010*, Volume 38, pp. 269–79.
- Moreno, J. C., E. R. de Lima, A. F. Ruíz, F. J. Brunetti, e J. L. Pons (2006). Design and implementation of an inertial measurement unit for control of artificial limbs: Application on leg orthoses. *Sensors and Actuators B: Chemical* 118(1-2), 333–337. Eurosensors XIX - Eurosensors XIX - The 19th European Conference on Solid-State Transducers.
- Nogueira, S. L., R. S. Inoue, M. H. Terra, e A. A. G. Siqueira (2013). Estimation of lower limbs angular positions using kalman filter and genetic algorithm. In *Biosignals and Biorobotics Conference (BRC), 2013 ISSNIP*, Rio de Janeiro, pp. 1–6.
- Pappas, I., T. Keller, S. Mangold, M. Popovic, V. Dietz, e M. Morari (2004). A reliable gyroscope-based gait-phase detection sensor embedded in a shoe insole. *Sensors Journal, IEEE* 4(2), 268–274.
- Pons, J., J. Moreno, F. Brunetti, e E. Roccon (2007). Lower-limb wearable exoskeleton. In *Rehabilitation Robotics*, Vienna, Austria. Sashi S Kommu (Ed.).
- Pons, J. L. (2008). *Wearable Robots : Biomechatronic Exoskeletons*. Madrid, Spain: John Wiley & Sons, Ltd.
- Roetenberg, D., P. Slycke, e P. Veltink (2007). Ambulatory position and orientation tracking fusing magnetic and inertial sensing. *Biomedical Engineering, IEEE Transactions on* 54(5), 883 –890.

-
- Rogers, R. M. (2003). *Applied mathematics in integrated navigation systems* (2nd ed.). Reston, VA: AIAA education series.
- Roumeliotis, S. I., G. S. Sukhatme, e G. A. Bekey (1998). Smoother based 3d attitude estimation for mobile robot localization. Technical report, USC, <http://iris.usc.edu/>.
- Sayed, A. (2001). A framework for state-space estimation with uncertain models. *Automatic Control, IEEE Transactions on* 46(7), 998–1013.
- Siqueira, A. e M. Terra (2004). Nonlinear and markovian $\mathcal{H}_\infty$ controls of underactuated manipulators. *Control Systems Technology, IEEE Transactions on* 12(6), 811–826.
- Tong, K. e M. H. Granat (1999). A practical gait analysis system using gyroscopes. *Medical Engineering & Physics* 21(2), 87–94.
- Wall, J. e D. Bevy (2006). Characterization of inertial sensor measurements for navigation performance analysis. In *Proceedings of the 19th International Technical Meeting of the Satellite Division of the Institute of Navigation ION GNSS*, Fort Worth, Texas.
- Xing, Z. e D. Gebre-Egziabher (2008). Modeling and bounding low cost inertial sensor errors. In *IEEE/ION Position, Location and Navigation Symposium*.
- Young, D., S. D'Orey, R. Opperman, C. Hainley, e D. J. Newman (2010). Estimation of lower limb joint angles during walking using extended kalman filtering. In C. T. Lim, J. C. H. Goh, e R. Magjarevic (Eds.), *6th World Congress of Biomechanics (WCB 2010). August 1-6, 2010 Singapore*, Volume 31 of *IFMBE Proceedings*, pp. 1319–1322. Springer Berlin Heidelberg.

APÊNDICE A

FILTRO DE KALMAN

Em 1960, R. E. Kalman publicou seu famoso artigo descrevendo uma solução recursiva para problemas de filtragem linear discretos, Kalman (1960). Desde então, devido ao grande avanço em computação digital, o Filtro de Kalman (FK) está entre os principais temas de pesquisa e aplicação.

Processo a ser estimado

O FK consiste, no problema geral, em gerar uma estimativa do estado $x \in \mathbb{R}^n$ de um controle de processo no tempo discreto que é regido por equações diferenciais lineares e estocásticas, por exemplo:

$$x_{k+1} = F_k x_k + B_k u_k + G_k w_k, \quad (\text{A.1})$$

com a variável de medição $z \in \mathbb{R}^m$, tal que:

$$z_k = H_k x_k + v_k. \quad (\text{A.2})$$

As variáveis randômicas w_k e v_k representam o ruído do processo e de medida respectivamente. Estes são independentes entre si e são ruídos brancos Gaussianos.

A matriz $F_{n \times n}$ na equação diferencial (A.1) relaciona o estado anterior no passo k ao estado atual no passo $k + 1$, na ausência de uma entrada de controle ou ruído no processo. A matrix $B_{n \times l}$ relaciona a entrada de controle opcional $u \in \mathbb{R}^l$ ao estado x . A matrix $H_{m \times n}$ é a equação de medição (A.2) que relaciona o estado a medição z_k . A seguir considere que a entrada de controle é nula.

Conceitos preliminares

Define-se $\hat{x}_k \in \mathbb{R}^n$ como estimativa preditora sendo este dado para as medições $\{z_0, z_1, \dots, z_{k-1}\}$ contendo o conhecimento do processo anterior ao passo k , e $\hat{x}_{k|k} \in \mathbb{R}^n$ como estimativa filtrada sendo este dado para medições $\{z_0, z_1, \dots, z_{k-1}, z_k\}$ contendo o conhecimento do processo até o passo k . Pode-se definir a estimativa de erros preditora e filtrada respectivamente como:

$$\begin{aligned} e_k &\equiv x_k - \hat{x}_k, \\ e_{k|k} &\equiv x_k - \hat{x}_{k|k}. \end{aligned}$$

A covariância da estimativa de erro preditora é dada por:

$$P_k = e_k e_k^T, \quad (\text{A.3})$$

e a covariância da estimativa de erro filtrada é:

$$P_{k|k} = e_{k|k} e_{k|k}^T. \quad (\text{A.4})$$

A dedução das equações do FK iniciam com o objetivo de encontrar uma equação que calcule uma estimativa filtrada do estado $\hat{x}_{k|k}$ como uma combinação linear da estimativa preditora do estado $\hat{x}_k$ e uma ponderação/ajuste da diferença entre a medição atual z_k e a medição predita $H\hat{x}_k$.

Então as estimativas preditoras e filtradas $\{\hat{x}_k, \hat{x}_{k|k}\}$ podem ser recursivamente dadas por

(veja Kailath et al. (2000)):

$$\hat{x}_{k+1} = F_k \hat{x}_{k|k}, \quad (\text{A.5})$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_k (z_{k+1} - H_k \hat{x}_{k+1}). \quad (\text{A.6})$$

A diferença $(z_{k+1} - H_{k+1} \hat{x}_{k+1})$ em (A.6) é conhecida como inovação de medida ou o resíduo. O resíduo reflete a discrepância entre a medição predita $H_{k+1} \hat{x}_{k+1}$ e a medição atual z_{k+1} . Caso o resíduo seja zero significa que ambas as medições são equivalentes.

A matriz $K_{n \times m}$ em (A.6) é escolhida como sendo o ganho que minimizará a covariância do erro filtrado em (A.4). Uma forma de K_{k+1} que resulta na minimização de (A.4) é dada por:

$$K_{k+1} = P_{k+1} H_{k+1}^T (H_{k+1} P_{k+1} H_{k+1}^T + R_{k+1})^{-1}. \quad (\text{A.7})$$

Desta forma pode-se concluir que a ponderação exercida por K_{k+1} quando a covariância do erro de medida R_{k+1} aproxima-se de zero, faz com que a medida z_{k+1} seja cada vez mais confiável, enquanto que a medição predita $H_{k+1} \hat{x}_{k+1}$ seja cada vez menos confiável. Por outro lado a medida que a covariância da estimativa preditora de erro P_{k+1} aproxima-se de zero a medição atual z_{k+1} torna-se cada vez menos confiável, enquanto que a medição predita $H_{k+1} \hat{x}_{k+1}$ torna-se cada vez mais confiável.

Para mais detalhes sobre as origens computacionais ou mesmo probabilísticas sobre o FK consulte Brown e Hwang (1997) e Jacobs (1994).

Algoritmo para o filtro de Kalman

O FK gera a estimativa do processo utilizando o formato de um controle por realimentação: criando uma estimativa do estado em cada instante de tempo, utilizando a medição do processo. Desta forma, as equações para o FK recaem em dois grupos: equações de atualização no tempo e equações de atualização das medidas.

As equações de atualização no tempo são responsáveis por projetar a frente no tempo o estado atual e sua estimativa do erro de covariância de forma a obter a estimativa preditora. As equações de atualização das medidas são responsáveis pela realimentação, ou seja, por incor-

porar a nova medição na estimativa preditora para obter uma melhoria na estimativa corretora.

De forma análoga as equações de atualização no tempo também podem ser consideradas como equações preditoras, enquanto que as equações de atualização das medidas podem ser consideradas como equações corretoras. Assemelhando-se assim a um algoritmo preditor-corretor.

As equações preditoras são:

$$\hat{x}_{k+1} = F_k \hat{x}_{k|k}, \quad (\text{A.8})$$

$$P_{k+1} = F_k P_{k|k} F_k^T + G_k Q_k G_k^T. \quad (\text{A.9})$$

As equações corretoras são:

$$K_{k+1} = P_{k+1} H_{k+1}^T (H_{k+1} P_{k+1} H_{k+1}^T + R_{k+1})^{-1}, \quad (\text{A.10})$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H_{k+1} \hat{x}_{k+1}), \quad (\text{A.11})$$

$$P_{k+1|k+1} = (I - K_{k+1} H_{k+1}) P_{k+1}. \quad (\text{A.12})$$

APÊNDICE B

MODELAGEM DE SENSORES INERCIAIS

Os sensores utilizados para obtenção dos ângulos absolutos, no caminhar humano utilizando o exoesqueleto Exo-Kanguera foram: giroscópios, acelerômetros e *encoders*. Como a informação obtida dos *encoders* são utilizadas diretamente, sem a necessidade de integração numérica para obtenção de ângulos, e como a relação sinal ruído é muito alta, fica evidente a confiabilidade deste em relação aos demais e portando este não será modelado. A disposição geral dos sensores obedece a forma exposta na Figura B.1. Abaixo seguem as modelagens do giroscópios e acelerômetros.

B.1 Modelo dos erros dos sensores inerciais

As medidas realizadas através de unidades de medida inercial (do inglês *inertial measurement unit*, IMU), são geralmente corrompidas por diferentes tipos de fontes de erros, tais como: ruídos presentes nos sinais de sensores, fator de escala, e variações da polarização com a temperatura, entre outros, veja IEEE (1997). Ao se realizar integração numéricas das medidas de

uma IMU, geralmente em um algoritmo de navegação, estes erros acumulam provocando um desvio significativo nas saídas de posição, velocidade e atitude. Portanto, para uma estimativa precisa da informação de navegação, uma modelagem estocástica dos erros de saída dos sensores inerciais é necessária, (El-Sheimy et al. (2008); Wall e Bevly (2006)). Porém, são poucas as informações fornecidas pelos fabricantes destes sensores para elaboração de um modelo de erros apropriado para a análise de desempenho de sistemas de navegação inercial (do inglês, *inertial navigation system*, INS). Dessa forma, deve-se buscar algum modo de calcular aproximadamente os valores de variância na saída de tais sensores que compõe a IMU. Neste projeto, será demonstrado que o uso de algoritmos genéticos podem ser uma forma simples e eficiente para se obter esta aproximação. Assim, segue abaixo o modelo dos erros de saída dos sensores inerciais, segundo a metodologia proposta por Xing e Gebre-Egziabher (2008) para estimativa do modelo dos erros dos sensores.

O modelo geral da saída de um sensor inercial após calibração pode ser dado por:

$$y_m = (1 + k)y_t + b(t), \quad (\text{B.1})$$

sendo y_m a saída medida do sensor, y_t o valor exato da medida do sensor, k erro de fator de escala e $b(t)$ a polarização. O erro de fator de escala é geralmente modelado como uma constante randômica, veja Xing e Gebre-Egziabher (2008). Porém, neste trabalho o termo ky_t será considerado como uma incerteza δy_t .

Figura B.1: Eixo de coordenadas.

Sem perda de generalidade o termo da polarização pode ser considerado como:

$$b(t) = b_0 + b_R(t), \quad (\text{B.2})$$

sendo b_0 uma constante de desvio nulo, ou seja, invariante no tempo, e $b_R(t)$ representa o desvio de polarização randômico ou o resíduo da polarização após a calibração, que é variante no tempo.

O termo $b_R(t)$ é dado por:

$$b_R(t) = b_w(t) + \sum_{i=1}^N b_i(t), \quad (\text{B.3})$$

sendo $b_w(t)$ o processo de ruído de largura de banda e $b_i(t)$ o i -ésimo processo de erro correlacionado no domínio do tempo. Como sensores de baixo custo são normalmente usados em configurações em que eles são integrados como um sensor de auxilio e são usados por momentos breves, o modelo detalhado de longos termos de erros de características são desnecessários. Deste modo, como proposto em Xing e Gebre-Egziabher (2008) pode-se escrever:

$$b_R(t) = b_w(t) + b_1(t), \quad (\text{B.4})$$

sendo $b_1(t)$ o processo Gauss-Markov escalar, veja Brown e Hwang (1997) para maiores detalhes, dado por:

$$\dot{b}_1(t) = -\frac{1}{\tau_{b_1}} b_1(t) + w_{b_1}. \quad (\text{B.5})$$

A variável τ_{b_1} é a constante de tempo do processo ou o tempo de correlação, w_{b_1} é o ruído do processo branco.

B.2 Modelo inercial do Giroscópio

O giroscópio fornece a medida de velocidade angular, $\omega(t)$, em seu eixo de rotação no instante t . Este pode ser modelado segundo apresentado acima, como:

$$\omega(t) = \omega_g(t) + b_g(t) + \eta_g(t), \quad (\text{B.6})$$

$$\dot{b}_g(t) = -\frac{1}{\tau_g} b_g(t) + \eta_{b_g}(t), \quad (\text{B.7})$$

sendo que $\omega_g(t)$ é a velocidade angular medida sobre o eixo Z , $\eta_g(t)$ é o ruído branco Gaussiano com variância σ_g^2 , $b_g(t)$ é a polarização do giroscópio, τ_g é a constante de tempo ou tempo de correlação do processo Gauss-Markov, e $\eta_{b_g}(t)$ é o ruído branco Gaussiano da polarização do giroscópio com variância $\sigma_{b_g}^2$.

Pode-se obter o ângulo do giroscópio através da integração de ω_g :

$$\hat{\theta}_h = \int_0^t \omega_g(\tau) d\tau + \theta_0. \quad (\text{B.8})$$

B.3 Modelo inercial do Acelerômetro

De forma análoga a aceleração obtida através do acelerômetro, $a(t)$ no instante t , pode ser modelada como:

$$a(t) = a_a(t) + b_a(t) + \eta_a(t), \quad (\text{B.9})$$

$$\dot{b}_a(t) = -\frac{1}{\tau_a} b_a(t) + \eta_{b_a}(t), \quad (\text{B.10})$$

sendo que $a_a(t)$ é a aceleração medida no sistema de coordenadas locais da IMU na direção do eixo X , o qual coincide com o sistema de coordenadas globais definidas na Figura B.1, $\eta_a(t)$ é o ruído branco Gaussiano com variância σ_a^2 , $b_a(t)$ é a polarização do acelerômetro, τ_a é a constante de tempo ou tempo de correlação do processo Gauss-Markov, e $\eta_{b_a}(t)$ é o ruído branco Gaussiano da polarização do acelerômetro, com variância $\sigma_{b_a}^2$.

Com isto, e desde que as variâncias σ_g^2 , $\sigma_{b_g}^2$, σ_a^2 , $\sigma_{b_a}^2$ sejam conhecidas, é possível realizar fusão de sensores utilizando algoritmos de filtragem para se obter os valores de $\theta(t)$ e $a(t)$ em

cada instante de tempo t .

Considere que um corpo está parado como uma inclinação α , seja X e Y o sistema de coordenadas global e X' e Y' o sistema de coordenadas local do IMU, veja Figura B.2. Neste ponto pode-se calcular a inclinação do corpo como: $\alpha = \arcsen(\frac{a_y}{g})$, $\alpha = \arccos(\frac{a_x}{g})$ ou $\arctan(\frac{a_y}{a_x})$, caso o ângulo desejado de inclinação seja θ , pode-se calculá-lo como: $\theta = \arcsen(\frac{a_x}{g})$, $\theta = \arccos(\frac{a_y}{g})$ ou $\arctan(\frac{a_x}{a_y})$.

No entanto, em determinados pontos de inclinação, pode-se obter medidas ambíguas. Para que isso não ocorra optamos por utilizar a função *atan2* (MATLAB) que leva em consideração o sinal de a_x e a_y . Dessa forma, utiliza-se sempre a medida de dois acelerômetros perpendiculares para se calcular o ângulo de inclinação de cada segmento do corpo humano.

Figura B.2: Funcionamento do acelerômetro.

APÊNDICE C

ALGORITMOS DE FILTRAGEM

Neste apêndice são apresentados os principais algoritmos de estimativa desenvolvidos neste trabalho.

Note que, as funções **calcular_estimativas** dos algoritmos implementam os métodos de integração e as relações trigonométricas utilizados. Para a integração numérica optamos pela regra trapezoidal, baseado nas fórmulas de Newton-Cotes. Optamos na escolha desta, por a mesma fornecer um valor de integração a cada instante, e também por possibilitar uma precisão razoável para a frequência de aquisição utilizada, sendo esta aplicada sobre o sinal de velocidade angular do giroscópio, $\omega(t)$. Já para as relações trigonométricas sobre o acelerômetro, optamos por utilizar a função *atan2* que considera os sinais dos valores de projeções.

C.1 FK-complementar local

Neste apêndice, será apresentado a versão completa do Algoritmo 2, do Capítulo 2.

Algoritmo 8: Estimativa angular absoluta utilizando o FK-complementar

Resultado: $\hat{\theta}_{k+1}$
 // Inicialização:
 $\hat{\theta}_0^g = \hat{\theta}_0^a$;
 $P_{0|0} = \mathbf{I}_{2 \times 2}$;
 $\hat{x}_{0|0} = \mathbf{0}_{2 \times 1}$;
para $k \leftarrow 0$ **até fim do processo faça**
 $[\omega_{k+1}^g, a_{k+1}^a] = \text{ler (sensores)}$;
 $[\hat{\theta}_{k+1}^a, \hat{\theta}_{k+1}^g] = \text{calcular_estimativas}(\hat{\theta}_{k+1}, \omega_{k+1}^g, a_{k+1}^a)$;

 // **Predição:**
 $\hat{x}_{k+1} = F\hat{x}_{k|k}$;
 $P_{k+1} = FP_{k|k}F^T + GQG^T$;

 // **Correção:**
 se $(|a| < 0, 5g)$ **E** *(perna em fase de apoio)* **então**
 $z_{k+1} = \hat{\theta}_{k+1}^a - \hat{\theta}_{k+1}^g$;
 senão
 $z_{k+1} = 0$;
 $K_{k+1} = P_{k+1}H^T(HP_{k+1}H^T + R)^{-1}$;
 $\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1}(z_{k+1} - H\hat{x}_{k+1})$;
 $P_{k+1|k+1} = (I - K_{k+1}H)P_{k+1}$;

 // **Saída:**
 // Desde que $\hat{x}_{k+1|k+1} := [\Delta\hat{\theta}_{k+1|k+1} \quad \Delta\hat{b}_{k+1|k+1}]^T$
 $\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^g + \Delta\hat{\theta}_{k+1|k+1}$;

C.2 FK-complementar local com acelerômetros triaxiais

Algoritmo 9: Estimativa angular absoluta utilizando o FK-complementar com acelerômetros triaxiais

Resultado: $\hat{\theta}_{k+1}$

```
// Inicialização:
 $\hat{\theta}_0^g = \hat{\theta}_0^a$ ;
 $P_{0|0} = \mathbf{I}_{2 \times 2}$ ;
 $\hat{x}_{0|0} = \mathbf{0}_{2 \times 1}$ ;
para  $k \leftarrow 0$  até fim do processo faça
     $[\omega_{k+1}^g, a_{k+1}^a] = \text{ler}(\text{sensores})$ ;
     $[\hat{\theta}_{k+1}^a, \hat{\theta}_{k+1}^g] = \text{calcular\_estimativas}(\hat{\theta}_{k+1}, \omega_{k+1}^g, a_{k+1}^a)$ ;

    // Predição:
     $\hat{x}_{k+1} = F \hat{x}_{k|k}$ ;
     $P_{k+1} = F P_{k|k} F^T + G Q G^T$ ;

    // Correção:
     $\rho_k = |||a_k|| - ||g|||$ ;
    se ( $\rho_k \leq \zeta$ ) então
         $z_{k+1} = \hat{\theta}_{k+1}^a - \hat{\theta}_{k+1}^g$ ;
    senão
         $z_{k+1} = \mathbf{0}$ ;

     $K_{k+1} = P_{k+1} H^T (H P_{k+1} H^T + R)^{-1}$ ;
     $\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H \hat{x}_{k+1})$ ;
     $P_{k+1|k+1} = (I - K_{k+1} H) P_{k+1}$ ;

    // Saída:
    // Desde que  $\hat{x}_{k+1|k+1} := [\Delta \hat{\theta}_{k+1|k+1} \quad \Delta \hat{b}_{k+1|k+1}]^T$ 
     $\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^g + \Delta \hat{\theta}_{k+1|k+1}$ ;
```

C.3 FKR-complementar local

Neste apêndice é apresentado a versão completa do Algoritmo 3 do Capítulo 2.

Algoritmo 10: Estimativa angular absoluta utilizando o FKR-complementar

Resultado: $\hat{\theta}_{k+1}$
 // Inicialização:
 $\hat{\theta}_0^g = \hat{\theta}_0^a$;
 $P_{0|0} = \mathbf{I}_{2 \times 2}$;
 $\hat{x}_{0|0} = \mathbf{0}_{2 \times 1}$;
para $k \leftarrow 0$ **até fim do processo faça**
 $[\omega_{k+1}^g, a_{k+1}^a] = \text{ler (sensores)}$;
 $[\hat{\theta}_{k+1}^a, \hat{\theta}_{k+1}^g] = \text{calcular_estimativas}(\hat{\theta}_{k+1}, \omega_{k+1}^g, a_{k+1}^a)$;

 // **Passo 1:**
 se $HM_k = 0$ **então**
 // filtro não robusto
 $\hat{\lambda}_k = 0$;
 senão
 // tipicamente $0 \leq \alpha_f \leq 1$
 $\alpha_f = 0,5$;
 $\hat{\lambda}_k = (1 + \alpha_f) \cdot \|M_k^T H^T R^{-1} H M_k\|$;

 // **Passo 2:**
 // Substitua $\{Q, R, P_{k|k}, G, F\}$ por:
 $\hat{Q}^{-1} = Q^{-1} + \hat{\lambda}_k N_G^T [I + \hat{\lambda}_k N_F P_{k|k} N_F^T]^{-1} N_G$;
 $\hat{R} = R - \hat{\lambda}_k^{-1} H M_k M_k^T H^T$;
 $\hat{P}_{k|k} = (P_{k|k}^{-1} + \hat{\lambda}_k N_F^T N_F)^{-1} = P_{k|k} - P_{k|k} N_F^T (\hat{\lambda}_k^{-1} I + N_F P_{k|k} N_F^T)^{-1} N_F P_{k|k}$;
 $\hat{G} = G - \hat{\lambda}_k F \hat{P}_{k|k} N_F^T N_G$;
 $\hat{F} = (F - \hat{\lambda}_k \hat{G} \hat{Q} N_G^T N_F) (I - \hat{\lambda}_k \hat{P}_{k|k} N_F^T N_F)$;

 // **Passo 3:**
 Filtro de Kalman: passos de **Predição, Correção e Saída** do Algoritmo 8 do Apêndice C.1.

C.4 FK-complementar matricial

Neste apêndice é apresentado a versão completa do Algoritmo 4 do Capítulo 4.

Algoritmo 11: Estimativa angular absoluta para um exoesqueleto utilizando o FK-complementar

Resultado: $\hat{\theta}_{k+1}$

```
// Inicialização:
 $\hat{\theta}_0^g = \hat{\theta}_0^a;$ 
 $P_{0|0} = \mathbf{I}_{8 \times 8};$ 
 $\hat{x}_{0|0} = \mathbf{0}_{8 \times 1};$ 
para  $k \leftarrow 0$  até fim do processo faça
     $[\hat{\theta}_{k+1}^g, a_{k+1}^a] = \text{ler}(\text{sensores});$ 
     $[\hat{\theta}_{k+1}^a, \hat{\theta}_{k+1}^g] = \text{calcular\_estimativas}(\hat{\theta}_{k+1}, \hat{\theta}_{k+1}^g, a_{k+1}^a);$ 
    // Predição:
     $\hat{x}_{k+1} = F \hat{x}_{k|k};$ 
     $P_{k+1} = F P_{k|k} F^T + G Q G^T;$ 
    // Correção:
     $\rho_k = |||a_k|| - ||g|||;$ 
    se  $((\rho_k^B < \zeta^B) \mathbf{E}(\rho_k^T < \zeta^T) \mathbf{E}(\rho_k^S < \zeta^S) \mathbf{E}(\rho_k^F < \zeta^F))$  então
         $| \quad z_{k+1} = \hat{\theta}_{k+1}^a - \hat{\theta}_{k+1}^g ;$ 
    senão
         $| \quad z_{k+1} = \mathbf{0};$ 
     $K_{k+1} = P_{k+1} H^T (H P_{k+1} H^T + R)^{-1};$ 
     $\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H \hat{x}_{k+1});$ 
     $P_{k+1|k+1} = (I - K_{k+1} H) P_{k+1};$ 
    // Saída:
    // Desde que  $\hat{x}_{k+1|k+1} := \begin{bmatrix} \Delta \hat{\theta}_{k+1|k+1} & \Delta \hat{b}_{k+1|k+1} \end{bmatrix}^T$ 
     $\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^g + \Delta \hat{\theta}_{k+1|k+1};$ 
```

C.5 FKSM-complementar

Neste apêndice é apresentado a versão completa do Algoritmo 5 do Capítulo 4.

Algoritmo 12: Estimativa angular absoluta para um exoesqueleto utilizando o FKSM-complementar

Resultado: $\hat{\theta}_{k+1}$

// Inicialização:

$$\hat{\theta}_0^g = \hat{\theta}_0^a;$$

$$P_{0|0} = \mathbf{I}_{8 \times 8};$$

$$\hat{x}_{0|0} = \mathbf{0}_{8 \times 1};$$

para $k \leftarrow 0$ **até** *fim do processo* **faça**

 // **Predição:**

$$\hat{x}_{k+1} = F \hat{x}_{k|k};$$

$$P_{k+1} = F P_{k|k} F^T + G Q G^T;$$

 // **Correção:**

$$\rho_k = \min_i (||a_k|| - g|);$$

$$\theta_k = \arg \min_i (||a_k|| - g|);$$

se $(\rho_k < \zeta)$ **então**

$$\quad \mid z_{k+1}^{\Theta(k)} = \theta_{k+1} - \hat{\theta}_{k+1}^g ;$$

senão

$$\quad \mid z_{k+1}^{\Theta(k)} = \mathbf{0};$$

$$z_{k+1}^e = \theta_{k+1}^e - \hat{\theta}_{k+1}^e ;$$

$$z_{k+1} = \begin{bmatrix} z_{k+1}^{\Theta(k)} & z_{k+1}^e \end{bmatrix}^T ;$$

$$K_{k+1} = P_{k+1} H_{\Theta(k)}^T (H_{\Theta(k)} P_{k+1} H_{\Theta(k)}^T + R)^{-1};$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1} + K_{k+1} (z_{k+1} - H_{\Theta(k)} \hat{x}_{k+1});$$

$$P_{k+1|k+1} = (I - K_{k+1} H_{\Theta(k)}) P_{k+1};$$

 // **Saída:**

$$\quad // \text{ Desde que } \hat{x}_{k+1|k+1} := \begin{bmatrix} \Delta \hat{\theta}_{k+1|k+1} & \Delta \hat{b}_{k+1|k+1} \end{bmatrix}^T$$

$$\hat{\theta}_{k+1} = \hat{\theta}_{k+1}^g + \Delta \hat{\theta}_{k+1|k+1};$$

APÊNDICE D

ALGORITMOS GENÉTICOS

Um algoritmo genético (AG) pode ser definido como uma busca eurística que imita o processo de evolução natural. Este processo é normalmente utilizado para gerar soluções de otimização e problemas de busca, veja Holland (1975). AGs são uma classe de procedimentos, com passos bem definidos, fundamentando-se em analogias a conceitos biológicos já testados a exaustão. São amplamente utilizados, com sucesso, em problemas de difícil manipulação pelas técnicas tradicionais. Os AGs são uma classe particular de algoritmos evolutivos que usam técnicas inspiradas pela biologia evolutiva como hereditariedade, mutação, seleção natural e recombinação. Podem ser utilizados para encontrar soluções aproximadas em problemas de otimização e busca. Uma das grandes vantagens de AGs é que podem ser facilmente utilizados de forma híbrida, associados a outras arquiteturas.

Os principais termos utilizados em AGs são:

- Função de aptidão: é a função que se deseja otimizar, em algoritmos de otimização esta é conhecida como função objetivo.
- Indivíduos: é qualquer ponto em que aplica-se a função de aptidão, sendo o valor desta a aptidão do indivíduo. Por exemplo, considere a seguinte função objetivo,

$$f(x_1, x_2, x_3) = (2x_1 + 1)^2 + (3x_2 + 4)^2 + (x_3 - 2)^2,$$

pode-se considerar vetor $(2, -3, 1)$ como sendo um indivíduo. No qual sua aptidão é $f(2, -3, 1) = 51$.

- Populações e gerações: a população é um conjunto de indivíduos. Por exemplo, se o tamanho da população é 100 e o número de variáveis na função de aptidão é 3, então tem-se a população representada por uma matriz de 100 por 3. A cada iteração, o AG realiza um série de cálculos e procedimentos na população atual e com isso gera uma nova população, sendo esta chamada de nova geração.
- Pais e filhos: para criar a nova geração, o AG seleciona alguns indivíduos da geração atual, chamados pais, e utiliza estes para criar os indivíduos da próxima geração, chamados filhos. Normalmente, o algoritmo seleciona os pais mais aptos para gerar os filhos da próxima geração.

Funcionamento geral de um AG,

1. Gerar população inicial
2. Descartar parte dos indivíduos menos aptos
3. Aplicar operadores de reprodução
4. Aplicar operadores de mutação
5. Se o critério de parada foi satisfeito
 - Então $\rightarrow$ encerrar processo
 - Senão $\rightarrow$ voltar ao passo 2

Este mesmo algoritmo pode ser visualizado na Figura D.

Figura D.1: Algoritmo genético.

APÊNDICE E

UNIVERSOS DE BUSCA DOS FILTROS

Neste apêndice são apresentados os universos de buscas dos filtros utilizando AGs.

E.1 Filtros nominais locais

Cromossomos	Mínimos	Máximos	Unidades
$\sigma_{g_i}^2$	10^{-8}	0, 2	$(^\circ/s)^2$
$\sigma_{b_{g_i}}^2$	10^{-8}	0, 2	$(^\circ/s)^2$
$\sigma_{a_i}^2$	10^{-8}	0, 2	$(m/s^2)^2$
τ_{g_i}	1	10^6	(s)
ζ_i	10^{-4}	0, 1	(m/s^2)

Tabela E.1: Universo de discurso para os FKs locais com acelerômetros, simulações, para $i = \{B, T, S, F\}$.

Cromossomos	Mínimos	Máximos	Unidades
$\sigma_{g_i}^2$	10^{-6}	0, 4	$(^\circ/s)^2$
$\sigma_{b_{g_i}}^2$	10^{-6}	0, 4	$(^\circ/s)^2$
$\sigma_{a_i}^2$	10^{-6}	0, 4	$(m/s^2)^2$
τ_{g_i}	1	10^6	(s)

Tabela E.2: Universo de discurso para os FKs locais com FSR, experimentos reais, para $i = \{B, T, S, F\}$.

Cromossomos	Mínimos	Máximos	Unidades
$\sigma_{g_i}^2$	10^{-6}	0, 4	$(^\circ/s)^2$
$\sigma_{b_{g_i}}^2$	10^{-6}	0, 4	$(^\circ/s)^2$
$\sigma_{a_i}^2$	10^{-6}	0, 4	$(m/s^2)^2$
τ_{g_i}	1	10^6	(s)
ζ_i	10^{-4}	0, 1	(m/s^2)

Tabela E.3: Universo de discurso para os FKs locais com acelerômetros, experimentos reais, para $i = \{B, T, S, F\}$.

E.2 Filtros nominais

Cromossomos	Mínimos	Máximos	Unidades
$\sigma_{g_i}^2$	10^{-8}	0, 2	$(^\circ/s)^2$
$\sigma_{b_{g_i}}^2$	10^{-8}	0, 2	$(^\circ/s)^2$
$\sigma_{a_i}^2$	10^{-8}	0, 2	$(m/s^2)^2$
τ_{g_i}	1	10^6	(s)
ζ_i	10^{-4}	0, 1	(m/s^2)

Tabela E.4: Universo de discurso para os filtros nominais, simulações, para $i = \{B, T, S, F\}$.

Cromossomos	Mínimos	Máximos	Unidades
$\sigma_{g_i}^2$	10^{-4}	0, 4	$(^\circ/s)^2$
$\sigma_{b_{g_i}}^2$	10^{-4}	0, 4	$(^\circ/s)^2$
$\sigma_{a_i}^2$	10^{-4}	0, 4	$(m/s^2)^2$
τ_{g_i}	1	10^6	(s)
ζ_i	10^{-4}	0, 1	(m/s^2)

Tabela E.5: Universo de discurso para os filtros nominais, experimentos reais, para $i = \{B, T, S, F\}$.

E.3 Filtros robustos

Cromossomos	Mínimos	Máximos
α_i	10^{-4}	1
m_{1_i}	-5	5
m_{2_i}	-5	5
n_{f1_i}	-5	5
n_{f2_i}	-5	5
n_{g1_i}	-5	5
n_{g2_i}	-5	5

Tabela E.6: Universo de discurso para os filtros robustos, simulações e experimentos reais, para $i = \{B, T, S, F\}$.

APÊNDICE F

DISPOSITIVOS E PROGRAMAS

Neste apêndice são documentados e apresentados os dispositivos e programas utilizados neste trabalho de doutorado.

F.1 Exoesqueleto Exo-Kanguera

O Exo-Kanguera consiste de um exoesqueleto desenvolvido para a reabilitação dos movimentos de membros inferiores de pessoas com locomoção comprometida, em decorrência de um Acidente Vascular Encefálico (AVE). Estabelecendo uma plataforma de reabilitação de membros inferiores em que diferentes protocolos e estratégias de controle podem ser avaliados. Seu benefício consiste dar suporte aos terapeutas, visando a recuperação mais rápida dos pacientes. A Figura F.1 contém o modelo mecânico deste exoesqueleto, juntamente com uma foto do modelo final construído.

A faixa de movimentação das articulações do Exo-Kanguera comparada a movimentação de uma pessoa saudável realizando uma marcha com velocidade padrão do caminhar humano obtidas em Chu et al. (2005), pode ser vista na Tabela F.1. Demonstrando que o Exo-Kanguera

Figura F.1: Exoesqueleto Exo-Kanguera.

pode movimentar-se dentro dessa faixa.

Junta	Caminhar Humano	Exo-Kanguera
Quadril (Flexão / Extensão)	30° / 20°	35° / 25°
Joelho (Flexão / Extensão)	70° / 0°	90° / 0°
Tornozelo (Dorsiflexão / Flexão plantar)	15° / 20°	20° / 30°

Tabela F.1: Faixas de movimentação do Exo-Kanguera e do caminhar humano.

F.2 Exoesqueleto Exo-H1

O exoesqueleto para reabilitação, desenvolvido no grupo de bioengenharia do CSIC, foi publicado em Bortole et al. (2013). Este consiste de um exoesqueleto robótico desenvolvido para auxiliar o treinamento de marcha em pacientes sobreviventes de acidente vascular cerebral (AVC), os quais possuem dificuldades na coordenação da marcha, após a realização da reabilitação convencional, veja a Figura F.2. Atualmente uma versão deste é comercializada pela empresa TechNaid, com o nome comercial Exo-H1, veja a Figura F.2(c).

O dispositivo é um exoesqueleto bilateral com seis graus de liberdade, projetado para implementar duas estratégias de controle. Sendo a primeira, o controle de trajetória adaptável e

Figura F.2: Exoesqueleto Exo-H1. Imagens retiradas de Bortole et al. (2013) e www.technaid.com.

desenvolvido para orientar os membros do paciente dentro de uma trajetória desejada, permitindo assim interação entre o usuário e o exoesqueleto. Já a segunda, consiste em uma estratégia de controle de admissão/admitância para permitir a captura de movimentos do usuário durante o treinamento assistivo e replicá-lo durante o treinamento ativo.

A faixa de movimentação das articulações do Exo-H1 comparada a movimentação de uma pessoa saudável realizando uma marcha com velocidade padrão do caminhar humano obtidas em Chu et al. (2005), pode ser vista na Tabela F.2. Demonstrando que o Exo-H1 pode movimentar-se dentro dessa faixa.

Junta	Caminhar Humano	Exo-H1
Quadril (Flexão / Extensão)	30° / 20°	100° / 20°
Joelho (Flexão / Extensão)	70° / 0°	100° / 5°
Tornozelo (Dorsiflexão / Flexão plantar)	15° / 20°	15° / 20°

Tabela F.2: Faixas de movimentação do Exo-H1 e do caminhar humano.

F.3 Open Sim

OpenSim é *software* gratuitamente disponível que pode ser utilizado para construir, compartilhar, e avaliar modelos computacionais de sistemas musculoesqueléticos e simulações da dinâmica de movimentos. Este *software* fornece uma plataforma para a comunidade de biomecânica poder construir bibliotecas de simulações que podem ser compartilhadas, testadas, analisadas, e constantemente melhorada através de colaborações multi-institucionais, Delp et al. (2007). Além disso neste software pode-se utilizar modelos tais como M. et al. (2010) ou L. et al. (2011), que carregam arquivos contendo o posicionamento de marcadores em uma captura de movimento de membros inferiores, e calcula-se a cinemática inversa para obter posicionamentos, velocidades e acelerações, veja a Figura F.3. Neste trabalho o software OpenSim, foi utilizado para realizar simulações enquanto os sensores inerciais estavam sendo adquiridos.

Figura F.3: OpenSim 2.4 utilizando um modelo para membros inferiores.

F.4 TECH MCS

O sistema de captura movimento baseado em IMUs utilizado nesta trabalho, consiste de um sistema comercial, nomeado Tech MCS, da empresa TechNaid. Este sistema é composto de um *hub*, ao qual as IMUs são conectados por fios, veja a Figura F.4. Sendo que as capturas realizadas podem tanto ser armazenadas internamente, para posterior descarga em um computador, quanto ser transmitida diretamente vim conexão sem fio.

Figura F.4: Tech IMU, Technaid.

Este sistema permite a conexão simultânea de até 16 IMUs, sendo a alimentação elétrica fornecida por duas baterias AA ao *hub*, ou por uma fonte de 5V. As interfaces de comunicação suportadas pelo sistema são: via cabo (USB) e sem fio (Bluetooth). As especificações técnicas das IMUs, são apresentadas na Tabela F.4.

Sensor		Valor	Unidade
Giroscópio	faixa de medição	± 500	$^{\circ}/s$
	sensibilidade	4	$mV/(^{\circ}/s)$
Acelerômetro	faixa de medição	$\pm 35,32$	m/s^2
	sensibilidade	300	mV/g
Magnetômetro	faixa de medição	± 2	$gauss$
	sensibilidade	0,5	$V/gauss$

Tabela F.3: Especificações técnicas das IMUs.