

KENJI FABIANO ÁVILA OKADA

**CONTROLE TOLERANTE DE
QUADRICÓPTEROS EM CENÁRIOS COM
FALHAS EM ATUADORES E SENSORES**

UBERLÂNDIA –MG

2022

KENJI FABIANO ÁVILA OKADA

**CONTROLE TOLERANTE DE
QUADRICÓPTEROS EM CENÁRIOS COM
FALHAS EM ATUADORES E SENSORES**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de Mestre em Ciências.

Banca examinadora:

Prof. Dr. Aniel Silva de Moraes (Orientador) – UFU
Prof. Dr. Luís Cláudio Oliveira Lopes (Coorientador) – UFU
Profª. Dra. Gabriela Vieira Lima – UFU
Prof. Dr. Vinícius Abrão da Silva Marques – UFTM

UBERLÂNDIA –MG

2022

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

O41 2022	<p>Okada, Kenji Fabiano Ávila, 1996- Controle tolerante de quadricópteros em cenários com falhas em atuadores e sensores [recurso eletrônico] / Kenji Fabiano Ávila Okada. - 2022.</p> <p>Orientador: Aniel Silva de Moraes. Coorientador: Luís Cláudio Oliveira Lopes. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Engenharia Elétrica. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.di.2022.195 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Engenharia elétrica. I. Moraes, Aniel Silva de , 1979-, (Orient.). II. Lopes, Luís Cláudio Oliveira , 1964-, (Coorient.). III. Universidade Federal de Uberlândia. Pós-graduação em Engenharia Elétrica. IV. Título.</p> <p style="text-align: right;">CDU: 621.3</p>
-------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
 Coordenação do Programa de Pós-Graduação em Engenharia Elétrica
 Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica				
Defesa de:	Dissertação de Mestrado Acadêmico, 770, PPGEELT				
Data:	Vinte e quatro de março de dois mil e vinte e dois	Hora de início:	14:00	Hora de encerramento:	16:27
Matrícula do Discente:	12012EEL005				
Nome do Discente:	Kenji Fabiano Ávila Okada				
Título do Trabalho:	Controle Tolerante de Quadricópteros em Cenários com Falhas em Atuadores e Sensores.				
Área de concentração:	Sistemas de Energia Elétrica				
Linha de pesquisa:	Controle e Automação				
Projeto de Pesquisa de vinculação:	Título do projeto de pesquisa ao qual está vinculada a produção: Controle cooperativo de enxame de veículos aéreos não tripulados especializados no monitoramento e detecção de falhas na indústria 4.0. Agência financiadora: CNPq. Número do processo do projeto de pesquisa na agência financiadora: Processo: 403054/2021-4. Vigência: Início: 17/03/2022. Fim: 31/03/2025.				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Luís Cláudio Oliveira Lopes (Coorientador) - FEQUI/UFU; Gabriela Vieira Lima - FEELT/UFU, Vinicius Abrão da Silva Marques - UFTM; Aniel Silva de Moraes - FEELT/UFU, orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. Aniel Silva de Moraes, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Aniel Silva de Morais, Professor(a) do Magistério Superior**, em 24/03/2022, às 16:28, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Gabriela Vieira Lima, Professor(a) do Magistério Superior**, em 24/03/2022, às 16:28, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luis Claudio Oliveira Lopes, Professor(a) do Magistério Superior**, em 24/03/2022, às 16:28, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Vinicius Abrão da Silva Marques, Usuário Externo**, em 24/03/2022, às 16:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3468077** e o código CRC **45426EEC**.

*Dedico este trabalho a minha
família que sempre lutou pelo meu
bem-estar, formação e felicidade.*

AGRADECIMENTOS

Agradeço à minha mãe Iêda Afonso de Ávila Okada e ao meu pai Walter Okada por terem garantido minha formação pessoal e acadêmica, sempre me aconselhando e me apoiando com carinho e dedicação nos momentos de decisão.

Agradeço a Amanda Aparecida Souza por sempre estar ao meu lado escutando todas as minhas reclamações e desabafos, me apoiando em cada caminho escolhido na vida e me ajudando nas necessidades.

Agradeço aos professores Aniel Silva de Moraes e Luís Cláudio Oliveira Lopes por cederem seu tempo na orientação, sempre disponíveis a me atender com paciência, carisma e muito conhecimento.

Agradeço aos meus amigos Luís Ricardo Cândido Côrtes e Laura Ribeiro por sempre estarem disponíveis em me ajudar nos trabalhos, além de proporcionarem um ambiente descontraído no laboratório.

Agradeço aos professores da Pós-graduação em Engenharia Elétrica e aos funcionários da Universidade Federal de Uberlândia por possibilitarem a minha formação na pós-graduação.

Agradeço, por fim, à CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo apoio financeiro.

“Na vida, não vale tanto o que temos, nem tanto importa o que somos. Vale o que realizamos com aquilo que possuímos e, acima de tudo, importa o que fazemos de nós!”

(Chico Xavier)

RESUMO

Os métodos de detecção e diagnóstico de falhas (FDD) e controle tolerante a falhas (FTC) têm atraído interesse significativo nas pesquisas devido às imposições do desenvolvimento tecnológico de diferentes sistemas em garantir operações seguras, continuidade de execução das funções requisitadas, redução de custos e a otimização das tarefas de manutenção. Dentre esses sistemas, estão os veículos aéreos não tripulados (VANTs), em especial o quadricóptero. Em razão de suas características, o quadricóptero é atualmente aplicado em uma grande escala para a solução de diversos problemas e adversidades. Diante disso, este trabalho implementa diferentes abordagens de FDD baseadas em filtro de Kalman (linear, estendido e *unscented*, todos com estrutura em três estágios e adaptativa) para a estimação das falhas, e um controle tolerante para o quadricóptero, considerando diferentes falhas com comportamentos não lineares e com possibilidade de ocorrência simultânea nos seus atuadores e sensores. As perturbações ocasionadas pelos ventos são abordadas na análise do comportamento do sistema FTC, em conjunto com outras obtidas por meio da comparação do desempenho das diferentes versões do filtro de Kalman. Dentre os resultados, os métodos de FDD foram eficientes nas estimativas das falhas nos cenários considerados, especialmente o filtro adaptativo. Isso proporcionou uma melhoria significativa na segurança e confiabilidade do quadricóptero pela estrutura de FTC, pois o sistema que antes se tornava instável na presença das falhas, se manteve estável com a implementação desse tipo de controle.

Palavras-Chave: Quadricóptero, FDD, FTC, KF, EKF, UKF, Filtro de Kalman em Três Estágios, Filtro de Kalman Adaptativo.

ABSTRACT

The methods of Fault Detection and Diagnosis (FDD) and Fault Tolerant Control (FTC) have attracted significant research attention due to the impositions of technological development of different systems to ensure safe operations, continuity of execution of required functions, cost reduction and optimization of maintenance tasks. Unmanned aerial vehicles (UAV's) are examples of these systems, especially the quadcopter. Due to its characteristics, the quadcopter is currently applied in large scale to solve several problems and adversities. In view of this, this work implements different FDD approaches based on Kalman filter (linear, extended, and unscented, all with a three-stage and adaptive structure) for fault estimation, and a tolerant control for a quadcopter, considering different faults with nonlinear behavior and with the possibility of simultaneous occurrence in its actuators and sensors. The disturbances caused by winds are addressed in the analysis of the FTC system behavior, together with others obtained by comparing the performance of different versions of the Kalman filter. Among the results, the FDD methods were efficient in estimating the faults in the considered scenarios, especially the adaptive filter. This provided a significant improvement in the safety and reliability of the quadcopter by the FTC structure, as the system that previously became unstable in the presence of the faults, remained stable with the implementation of this type of control.

Keywords: Quadcopter, FDD, FTC, KF, EKF, UKF, Three-Stage Kalman Filter, Adaptive Kalman Filter.

LISTA DE ILUSTRAÇÕES

2.1	Estrutura e variáveis do quadricóptero.....	19
3.1	Sistema de controle em malha fechada.....	27
3.2	Função de transferência generalizada.....	28
3.3	Representação do controlador PID utilizado.....	29
3.4	Sistema de controle completo do quadricóptero.....	31
4.1	Sistema de FDD e de FTC implementados para o quadricóptero.....	60
5.1	Inovação do sub filtro das falhas no ATsUKF.....	67
5.2	Estimação das falhas nos sensores pelo ATsUKF.....	68
5.3	Estimação das falhas nos atuadores pelo ATsUKF.....	68
5.4	Deslocamento do quadricóptero submetido as falhas nos atuadores e sensores.....	73
5.5	Sinais de controle gerados nos sistemas com (a) e sem (b) FTC.....	74
5.6	Deslocamento do quadricóptero no plano XY.....	74
5.7	Comportamento dos sistemas na presença de falhas nos sensores do tipo travamento.....	75
5.8	Estimação das falhas nos sensores do tipo travamento.....	76
5.9	Comportamento dos sistemas na presença de perturbações geradas pelos ventos.....	77
5.10	Estimações das falhas nos sensores (a) e nos atuadores (b).....	78

LISTA DE TABELAS

4.1	Algoritmo do KF.....	45
4.2	Algoritmo do EKF.....	46
4.3	Algoritmo do UKF.....	47
4.4	Algoritmo do TsKF.....	49
4.5	Algoritmo do TsUKF.....	52
4.6	Inovação e matriz de covariância das diferentes abordagens do KF.....	57
5.1	Tabela dos parâmetros do quadricóptero.....	62
5.2	Parâmetros do PID.....	62
5.3	Parâmetros dos filtros de Kalman.....	63
5.4	Comportamentos das falhas nos sensores e nos atuadores.....	64
5.5	Desempenho do ATsUKF variando o parâmetro M.....	66
5.6	Desempenho dos filtros para a situação de falhas nos atuadores e sensores.....	70

LISTA DE ABREVIATURA E SIGLAS

ANN	<i>Artificial Neural Networks</i>
ATsKF	<i>Adaptive Three- Stage Extended Kalman Filter</i>
ATsEKF	<i>Adaptive Three-Stage Kalman Filter</i>
ATsUKF	<i>Adaptive Three-Stage Unscented Kalman Filter</i>
CNN	<i>Convolutional Neural Network</i>
EKF	<i>Extended Kalman Filter</i>
EWMA	<i>Exponentially Weighted Moving Average</i>
FDD	<i>Fault Detection and Diagnosis</i>
FTC	<i>Fault Tolerant Control</i>
IAE	<i>Integral Absolute Error</i>
IMU	<i>Inertial Measurement Unity</i>
KF	<i>Kalman Filter</i>
LPV	<i>Linear Parameter Varying</i>
NARX	<i>Nonlinear Autoregressive Exogenous</i>
PID	Proporcional, Integral e Derivativo
PMI	<i>Proportional Multiple Integer</i>
RBFNN	<i>Radial Basis Function Neural Network</i>
RTsUKF	<i>Robust Three-Stage Unscented Kalman Filter</i>
SISO	<i>Single Input – Single Output</i>
STFT	<i>Short Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
TsEKF	<i>Three-Stage Extended Kalman Filter</i>
TsKF	<i>Three-Stage Kalman Filter</i>
TsUKF	<i>Three-Stage Unscented Kalman Filter</i>
UIO	<i>Unknown Input Observer</i>
UKF	<i>Unscented Kalman Filter</i>
VANT	Veículo Aéreo Não-Tripulado
VTOL	<i>Vertical Take-Off and Landing</i>

LISTA DE SÍMBOLOS

Notações gerais

\dot{h}	(-)	Denota a derivada temporal da variável generalizada h
\hat{h}	(-)	Denota a estimação da variável generalizada h
\tilde{h}	(-)	Denota o erro de estimação da variável generalizada h
\mathbf{h}	(-)	Denota um vetor ou uma matriz
h	(-)	Denota uma variável/constante não vetorial/matricial
$S.$	(-)	Operação de seno
$C.$	(-)	Operação de cosseno
$T.$	(-)	Operação de tangente

Modelagem dinâmica

(X, Y, Z)	(-)	Eixos do sistema de coordenadas inercial
(X_b, Y_b, Z_b)	(-)	Eixos do sistema de coordenadas do corpo
(f_1, f_2, f_3, f_4)	(N)	Forças geradas por cada hélice
$(\tau_1, \tau_2, \tau_3, \tau_4)$	(Nm)	Torques geradas por cada hélice
$\Omega_1, \Omega_2, \Omega_3$ e Ω_4	(rad/s)	Velocidade angular de cada rotor
b	Ns^2	Constante de empuxo
d	Nms^2	Constante de arrasto
I_r	(kgm^2)	Momento de inércia do rotor
τ_ψ	(Nm)	Torque de guinada
τ_θ	(Nm)	Torque de arfagem
τ_ϕ	(Nm)	Torque de rolagem
u_z	(N)	Força de empuxo
ϕ	(rad)	Ângulo de rolagem
θ	(rad)	Ângulo de arfagem
ψ	(rad)	Ângulo de guinada

(x, y, z)	(m)	Posições lineares em função do referencial inercial
ξ	(m)	Vetor posição linear
η	(rad)	Vetor de ângulos
V_B	(m/s)	Vetor velocidade linear em função do referencial do corpo
ω	(rad/s)	Vetor Velocidade angular em função do referencial do corpo
$(V_{b,x}, V_{b,y}, V_{b,z})$	(m/s)	Velocidade linear em função do referencial do corpo
(p, q, r)	(rad/s)	Velocidade angular em função do referencial do corpo
W_n	(-)	Matriz de Euler
R	(-)	Matriz de cossenos diretores
$F_{R,B}$	(N)	Força resultante
F_c	(N)	Força de Coriolis
$F_{P,B}$	(N)	Força peso
m	(kg)	Massa do quadricóptero
g	(m/s ²)	Aceleração da gravidade
$\tau_{R,B}$	(Nm)	Torque resultante
τ_c	(Nm)	Torque associado ao efeito de Coriolis
τ_G	(Nm)	Torque referente às forças do efeito giroscópico
I	(kgm ²)	Matriz inercial do quadricóptero
I_{xx}	(kgm ²)	Momento de inércia em relação ao eixo x
I_{yy}	(kgm ²)	Momento de inércia em relação ao eixo y
I_{zz}	(kgm ²)	Momento de inércia em relação ao eixo z
l	(m)	Distância entre o rotor e o centro de gravidade

Controlador PID

$G(s)$	(-)	Função de transferência
$T(s)$	(-)	Função de transferência em malha fechada
$S(s)$	(-)	Função de transferência de sensibilidade

u	(-)	Sinais de controle
u_{bias}	(-)	Sinais de controle para o ponto de operação
y	(-)	Sinais mensurados
r	(-)	Sinais de referência
K_p	(-)	Ganho do modo proporcional
K_i	(-)	Ganho do modo integral
K_d	(-)	Ganho do modo derivativo
OS	(-)	Sobressinal
$T_{s,5\%}$	(s)	Tempo de assentamento
w_n	(rad/s)	Frequência natural do sistema
ξ_c	(-)	Fator de amortecimento
a	(-)	Polo de malha fechada
T_s	(s)	Tempo de amostragem

Sistemas de FDD e de FTC

δ_i	(-)	Falha no i -ésimo atuador
δ_i^{max}	(-)	Valor máximo admissível para a falha no i -ésimo atuador
f^s	(-)	Vetor de falhas nos sensores
f^a	(-)	Vetor de falhas nos atuadores
(w^x, w^{fa}, w^{fs})	(.)	Ruídos do processo
v	(-)	Ruídos do sinal de medição
x_e	(-)	Estados do modelo do quadricóptero
(A, B, C, F, E)	(-)	Matrizes do espaço de estados
(A^a, B^a, C^a)	(-)	Matrizes do espaço de estados aumentado
O	(-)	Matriz de observabilidade
$(Q^a, Q_k^x, Q_k^{fa}, Q_k^{fs})$	(-)	Matrizes de covariância do ruído do processo
R_k	(-)	Matriz de covariância do ruído de medição

$(P^a, P_k^x, P_k^{fa}, P_k^{fs})$	(-)	Matrizes de covariância do erro de estimação
$(K_k^a, K_k^{fa}, K_k^{fs})$	(-)	Ganhos do Filtro de Kalman
$(\lambda, \alpha, \kappa, \beta)$	(-)	Parâmetros do UKF
$(P_{vu,k}, P_{vu,k}^x, P_{vu,k}^{fa}, P_{vu,k}^{fs})$	(-)	Matrizes de covariância da inovação
$(v_k, v_k^x, v_k^{fa}, v_k^{fs})$	(-)	Inovações
M	(-)	Tamanho do intervalo de tempo
λ_k	(-)	Fator de esquecimento
u_k^m	(-)	Sinal de controle do sistema FTC

SUMÁRIO

INTRODUÇÃO	1
1.1. Objetivos	2
1.2. Trabalhos publicados	3
1.3. Organização geral	3
SISTEMAS DE FDD E FTC APLICADOS A QUADRICÓPTEROS.....	5
2.1. Estado da arte.....	5
2.2. Modelagem dinâmica do quadricóptero	18
2.2.1. Considerações iniciais	18
2.2.2. Formulação de Newton-Euler	22
2.2.3. Quadricóptero	24
PROJETO DOS CONTROLADORES	25
3.1. Simplificação do modelo	25
3.2. Controlador PID	28
3.3. Cálculo dos parâmetros do PID	31
PROJETO DOS SISTEMAS DE FDD E FTC.....	35
4.1. Descrição das falhas no atuadores	35
4.2. Descrição das falhas nos sensores.....	36
4.3. Considerações iniciais para o projeto dos filtros de Kalman	37
4.3.1. Representação do modelo em espaço de estados.....	38
4.3.2. Observabilidade.....	41
4.3.3. Variáveis associadas ao filtro de Kalman	43
4.4. Sistemas de detecção e diagnóstico de falhas.....	44
4.4.1. Filtro de Kalman.....	45
4.4.2. Filtro de Kalman Estendido.....	45

4.4.3. Filtro de Kalman Unscented	46
4.4.4. Filtro de Kalman em Três Estágios.....	48
4.4.5. Filtro de Kalman Adaptativo em Três Estágios	56
4.5. Sistema de controle tolerante a falhas	58
RESULTADOS E DISCUSSÕES.....	61
5.1. Parâmetros do quadricóptero.....	61
5.2. Parâmetros dos controladores PID	61
5.3. Parâmetros dos filtros de Kalman	63
5.4. Simulações e resultados	63
5.4.1. Análise dos filtros de Kalman com estrutura adaptativa	65
5.4.2. Análise do desempenho das diferentes abordagens de FDD.....	67
5.4.3. Análise do desempenho da estrutura de FTC	72
5.4.4. Análise do desempenho das estruturas de FDD e FTC em cenário com falhas do tipo travamento.....	75
5.4.5. Análise do desempenho das estruturas de FDD e FTC em cenário com perturbações geradas pelos ventos	76
CONCLUSÕES E SUGESTÕES	79
6.1. Trabalhos futuros	81
REFERÊNCIAS BIBLIOGRÁFICAS	83

CAPÍTULO 1

INTRODUÇÃO

Os Veículos Aéreos Não-Tripulados (VANTs) têm atraído, constantemente, investimentos a nível mundial devido à crescente demanda desses equipamentos na solução de diferentes problemas em diversas áreas, como: detecção de objetos, rastreamento, vigilância, coleta de dados, planejamento de rotas, navegação, prevenção de colisão, coordenação, monitoramento ambiental, entre outros. (SHAKHATREH *et al.*, 2019). Dentre os VANTs, destacam-se os quadricópteros, os quais despertam interesses em inúmeras aplicações por apresentarem decolagem e pouso verticais, capacidade de pairagem, estrutura mecânica simples, presença de uma parte móvel por atuador, baixo custo e fácil manutenção

De acordo com o relatório do Research and Markets, (2019), espera-se que o mercado global de serviços que usufruem da tecnologia de VANTs atinja 92,52 bilhões de dólares em 2026, com um crescimento anual composto de 53,8% entre 2018 a 2026. Além disso, é previsto um crescimento na venda global de VANTs de 30 bilhões de dólares em 2020 para 54,6 bilhões de dólares em 2025 com um crescimento anual composto de 12,7% no período de 2020 a 2025.

Nesse contexto, torna-se necessário que haja a constante melhoria tecnológica desses veículos de modo a afetar a sua eficiência, segurança e garantir a confiabilidade no uso desses produtos. Essa necessidade é relevante devido ao aumento significativo de acidentes com essas aeronaves, podendo ser ocasionados por falhas dos seus atuadores, da sua estrutura ou dos seus

sensores, gerando impactos negativos nos sistemas humanos e ambientais (WANG *et al.*, 2019).

Métodos de monitoramento de processos, reconfiguração do sistema, manutenções periódicas e instalações de componentes seguros são ações preventivas úteis em aprimorar as propriedades voltadas à segurança e confiabilidade dos VANTs (ALLAUDDIN *et al.*, 2018). Em vista disso, as áreas denominadas de FDD (*Fault Detection and Diagnosis*) e de FTC (*Fault Tolerant Control*) têm proporcionado resultados importantes em pesquisas em diferentes setores do conhecimento. O primeiro é responsável em extrair a maior quantidade de informações possível das falhas (detecção, local de ocorrência, magnitude, entre outros), enquanto o segundo corresponde a estruturas de controle capazes de atenuar os efeitos das falhas no desempenho do sistema.

De acordo com a análise realizada de diferentes trabalhos na literatura, há um avanço nos diferentes métodos de FDD e FTC aplicados a VANTs, em especial os quadricópteros. Entretanto, ainda há a necessidade de desenvolver abordagens robustas, eficientes e que envolvem diversas propriedades e cenários das falhas em diferentes componentes dessas aeronaves.

1.1. Objetivos

Este trabalho possui os seguintes objetivos gerais e específicos:

- implementação de diferentes abordagens de FDD baseadas em modelo para um quadricóptero;
 - descrição das falhas dos atuadores e sensores consideradas neste trabalho;
 - implementação das abordagens linear, estendida e *unscented* do filtro de Kalman nas versões em três estágios e adaptativa para a estimação das falhas;
 - análise e comparação dos desempenhos das abordagens do filtro de Kalman em diferentes cenários de voo, os quais consideram diversos comportamentos e ocorrências simultâneas das falhas;
- implementação de um sistema FTC para um quadricóptero;

- implementação dos controladores PID para o sistema livre de falhas;
- implementação da estrutura tolerante a falhas baseada nas informações provenientes do sistema de FDD;
- análise e comparação do desempenho da estrutura de controle com e sem o sistema de FTC em diferentes cenários com falhas e considerando as perturbações externas associadas aos ventos.

1.2. Trabalhos publicados

- OKADA, K. F. A., MORAIS, A. S., LOPES, L. C. O. e RIBEIRO, L., A Survey on Fault Detection and Diagnosis Methods. *2021 14th IEEE International Conference on Industry Applications (INDUSCON)*, pp. 1422-1429, 2021. <https://doi.org/10.1109/INDUSCON51756.2021.9529495>
- OKADA, K. F. A., MORAIS, A. S., LOPES, L. C. O. e RIBEIRO, L., Neuroadaptive Observer-Based Fault Diagnosis and Fault-Tolerant Control for Quadrotor UAV. *2021 14th IEEE International Conference on Industry Applications (INDUSCON)*, pp. 285-292, 2021. <https://doi.org/10.1109/INDUSCON51756.2021.9529573>

1.3. Organização geral

A dissertação é dividida nos seguintes capítulos:

- Capítulo 2: apresentará o estado da arte dos métodos de FDD e FTC aplicados a quadricópteros e a modelagem das dinâmicas não lineares dessa aeronave através do formalismo de Newton-Euler.
- Capítulo 3: discutirá os procedimentos para a obtenção do modelo linear do quadricóptero, além de expor a estrutura do controlador PID e as etapas para o seu projeto.
- Capítulo 4: realizará uma descrição das falhas nos atuadores e nos sensores consideradas no trabalho, e apresentará o modelo em espaço de estados aumentado do sistema, os algoritmos associados a cada abordagem do filtro de Kalman, o qual compõe o sistema de FDD, e a estrutura de FTC.

- Capítulo 5: discussões a respeito dos resultados obtidos considerando diferentes cenários com falhas em atuadores e em sensores, o desempenho das diferentes abordagens dos métodos de FDD e do sistema de FTC, e as interferências geradas pelas perturbações dos ventos.
- Capítulo 6: apresentará as principais conclusões obtidas e sugestões de trabalhos futuros.

CAPÍTULO 2

SISTEMAS DE FDD E FTC APLICADOS A QUADRICÓPTEROS

Este capítulo apresenta o estado da arte dos sistemas de FDD e FTC aplicados a quadricópteros, evidenciando as vantagens e limitações dos diferentes métodos de cada estrutura e expondo os desafios presentes nessa área. Além disso, será descrito o modelo matemático das dinâmicas de um quadricóptero obtido via formulação de Newton-Euler.

2.1. Estado da arte

As ocorrências de falhas em VANTs normalmente acarretam perdas financeiras irreparáveis, quando ‘pequenas’ falhas em diferentes partes do sistema levam a danos catastróficos (SHRAIM, AWADA, YOUNESS, 2018).

As falhas correspondem a qualquer desvio de uma determinada característica do sistema em relação às condições aceitáveis, promovendo ou não, deterioração da sua capacidade de realizar uma função requerida. A incapacidade total ou parcial do sistema em desempenhar a função é denominada de defeito (SARTORI *et al.*, 2012). As falhas manifestam diferentes comportamentos, se apresentando, como: falhas abruptas, incipientes, intermitentes, ruídos, entre outros.

Mosborne *et al.*, (2019) realizaram uma pesquisa sobre a segurança e a confiabilidade de VANTs comerciais emitindo um questionário para 1500 companhias que utilizam essas aeronaves no Reino Unido, tendo uma taxa de resposta de 10%. Dentre os resultados obtidos, 67,1% reportaram a ocorrência

de falhas não críticas e 21% para falhas críticas, defeitos, durante uma escala de uma a cem horas de voo, sendo esses valores influenciados pelo planejamento de manutenção e pela qualidade dos VANTs. Nesse quesito, as falhas na transmissão, na comunicação, na bateria e na navegação foram os itens mais avaliados em relação a possibilidade de ocorrência, além de que as tecnologias de aviso de falhas elétricas, mecânicas e da bateria, os sistemas de controle e de estabilidade tolerantes a falhas, foram os mais considerados em relação aos benefícios que poderiam trazer para o setor de VANT comercial. Conforme Alauddin *et al.*, (2018), as propriedades de segurança e de confiabilidade do sistema podem ser aprimoradas através de ações preventivas resultantes do monitoramento dos processos, da reconfiguração do sistema, das manutenções periódicas e da instalação de componentes seguros.

Em razão disso, as áreas denominadas de FDD e de FTC têm atraído interesse expressivo às pesquisas no desenvolvimento de diferentes métodos e suas aplicações em diferentes setores do conhecimento. Os métodos de FTC são responsáveis em projetar sistemas de controle capazes de atenuar ou suprimir os efeitos das falhas no processo através de duas maneiras: ativamente, por meio do ajuste dos parâmetros ou da estrutura do controlador de acordo com a ocorrência da falha, cujas informações são provenientes da FDD; ou passivamente, de maneira que o controlador é projetado previamente levando em consideração as falhas e seus efeitos no sistema, como é o caso dos controladores robustos.

As estratégias de FDD correspondem à elementos essenciais de sistemas de monitoramento eficazes, que representam a junção de dois passos principais: a detecção, responsável em identificar a presença de falhas no sistema, e o diagnóstico, ligado ao isolamento e à análise da falha determinando as suas diferentes características: local, tempo de ocorrência, magnitude e tipo (TIDRIRI *et al.*, 2016). Baseando-se neste fato, a área de FDD proporciona (ISERMANN, 2006):

- a detecção antecipada de pequenas falhas com comportamentos abruptos ou incipientes;
- o diagnóstico de falhas em atuadores, processos, componentes e sensores;

- a detecção de falhas em sistemas fechados;
- a supervisão dos sistemas no transitório de estados;
- a manutenção e o reparo baseado nas condições do processo;
- um melhor controle na qualidade dos produtos;
- a detecção e diagnóstico de falhas de sistemas remotos;
- o fornecimento de informações para a administração das falhas;
- o fornecimento de informações para a reconfiguração dos sistemas tolerantes a falhas.

Os principais componentes de FDD são os sintomas, os quais são representados por observações ou por sinais que estão associados ou relacionados às falhas. Um sintoma comumente empregado é o resíduo, que corresponde ao desvio de uma determinada característica do sistema quando comparada ao seu estado livre de falhas. Precisamente, haverá a detecção da falha no sistema caso o resíduo seja não nulo ou o seu valor ultrapasse uma faixa aceitável. Dessa maneira, o processo de diagnóstico será realizado dependendo do método empregado.

As abordagens de FDD podem ser classificadas em: métodos baseados em análises de sinais, orientados a dados e baseados em modelo. O estudo publicado na 14th IEEE *International Conference on Industry Applications* (INDUSCON) proveniente desta dissertação (OKADA *et al.*, 2021), trata das diferentes técnicas de cada método composto por descrições de suas vantagens, limitações e possibilidades de aplicações práticas. Esse estudo foi fundamental para esta seção, a qual trata da área de FDD e FTC aplicado aos VANTS.

Diversas são as aplicações de FDD em VANT, variando-as em relação ao tipo da aeronave (multi-rotor, asa fixa, *flapping wings*), tamanho, aplicação, tecnologia embarcada (como sensores e atuadores), tipo da falha e abordagem de FDD. Os VANTS são sensíveis às perturbações aerodinâmicas que podem ocasionar diferentes falhas, como: travamento e degradação dos atuadores, perda de uma hélice ou motor, perda total do sinal de controle e danos estruturais (TORRES, 2018), além das falhas em sensores e na transmissão e comunicação de dados.

Os métodos baseados em análises de sinais consistem em extrair características nos domínios do tempo e/ou frequência dos sinais do processo, que são influenciadas pelas falhas (amplitude e frequência) e são capazes de gerar resíduos, sendo utilizados preferencialmente em casos em que os sinais medidos apresentam oscilações, como: sinais de vibração, de emissão acústica, de corrente elétrica, entre outros. (RAI, UPADHYAY, 2016). Regularmente, esses sinais estão relacionados a um componente específico do sistema, como em rolamentos, engrenagens e motores elétricos, e por esse motivo, o diagnóstico é direto na determinação do local da falha. Nesses casos, normalmente não há um sistema de controle envolvido por se tratar de componentes específicos de um dispositivo ou equipamento. Portanto, o emprego dos métodos FDD possui, nesse cenário, uma importância maior voltada à detecção para o aprimoramento da manutenção dos componentes e nos avisos de segurança do sistema, possíveis pela análise da magnitude do resíduo, ao invés da atenuação dos efeitos das falhas no processo.

Um dos principais problemas envolvendo sinais é o ruído. Ele pode ser gerado pelos próprios sensores ou proveniente de outros locais distantes da região de medição. Em vista deste fato, é importante que o resíduo obtido seja comparado aos limites pré-estabelecidos de maneira a reduzir a quantidade de alarmes falsos e sinalizar a presença de falha, caso esses limites sejam ultrapassados (ZHONG, XUE, DING, 2018). Além do mais, os métodos baseados em análise de sinal necessitam que o resíduo seja gerado pelas melhores características extraídas do sinal que evidenciem a falha, no entanto, há a possibilidade de ser um problema quando as falhas apresentam, principalmente em seu estágio inicial, “fracas” alterações nas características do sinal em ambientes ruidosos, os quais camuflam essas alterações e prejudicam a detecção antecipada das falhas (LI *et al.* 2019).

Benini *et al.*, (2019) realizaram a detecção de falhas em hélices de uma aeronave de asa fixa VTOL (*Vertical Take-Off and Landing*) através da análise do sinal no tempo e na frequência, proveniente do sensor de aceleração, e extraíram as melhores características desse sinal por meio do algoritmo proposto. Isso é possível devido às falhas estruturais das hélices provocarem vibrações na aeronave e serem perceptíveis no sinal analisado. No domínio do

tempo, foram utilizadas treze medidas estatísticas, e no domínio da frequência, a transformada discreta de Fourier em conjunto à função de janela Hanning.

Yu *et al.*, (2018) aplicaram a transformada discreta de Fourier no sinal proveniente do sensor de altitude de uma aeronave hexarotor para a detecção de falhas em seus atuadores. Aplicando a *Persistent Excitation Input*, as características do sinal na frequência ligadas às falhas se tornaram mais evidentes, possibilitando as detecções até das falhas de menor intensidade.

Entretanto, em ambas as pesquisas, apesar da obtenção de resultados satisfatórios na detecção das falhas e contornarem os efeitos dos ruídos no sinal, os estudos se baseiam em apenas um tipo de falha, sendo limitados à sua detecção, a qual não fornece a localização de qual hélice ou motor houve a presença da falha, e não consideram a situação de múltiplas falhas e de ocorrências simultâneas.

Ao invés do uso isolado de técnicas de análise de sinal exclusivamente para a detecção de falhas em VANTs, pesquisas recentes atribuem a essas técnicas a função de tratamento das informações provenientes do sistema (atenuação do ruído, extração de características das falhas no domínio da frequência, redução da quantidade de dados, entre outros) para que assim, essas informações possam ser utilizadas, por exemplo, em métodos de inteligência artificial, os quais estão inclusos nas abordagens de FDD orientados a dados e que em alguns casos, possibilitam o diagnóstico das falhas. Os métodos de FDD orientados a dados têm ganhado popularidade devido ao aumento da complexidade dos sistemas em conjunto com os avanços na capacidade de absorção e armazenamento de dados provenientes dos processos. Dois grupos principais correspondem a essa classificação: o baseado em análises estatísticas e o baseado em inteligência artificial. O primeiro caso atribui probabilidades ao sistema ou aos componentes de estarem com falhas, enquanto o segundo, a detecção e o diagnóstico ocorrem por meio de regressões e problemas de classificação (SKLIROS *et al.*, 2019).

Bondyra *et al.*, (2017) propuseram a detecção e o diagnóstico de falhas estruturais em hélices de quadricópteros baseados na extração do sinal de vibração no sinal de aceleração proveniente do IMU (*Inertial Measurement Unity*). Além disso, os autores fizeram uso do SVM (*Support Vector Machine*) devido a sua simplicidade e facilidade de implementação para determinar a

ocorrência das falhas e suas características através do processo de classificação. Os autores compararam o desempenho da transformada de Fourier e da transformada de *Wavelet* na extração dessas informações e as diagnosticaram pelo SVM, classificando-as qualitativamente: rotor com e sem falha, gravidade do dano em severo e leve, e o tipo da falha em borda danificada e ponta distorcida. Neste caso, não houve a identificação de qual hélice possui a falha e nem a consideração de falhas múltiplas e em outros locais da aeronave. Todavia, a determinação das demais características da falha pode ser útil na geração de informações para o sistema de controle tolerante a falhas, mesmo que a reconfiguração do controlador esteja limitada às situações definidas pela classificação.

Os modelos dos VANTs são caracterizados pelas expressivas não-linearidades, as quais prejudicam o desempenho dos métodos de FDD baseados em modelo. Dentre as técnicas de inteligência artificial, que sugerem a solução desse problema, estão as redes neurais artificiais (*Artificial Neural Networks - ANN*) caracterizadas, no contexto de FDD, pela camada de entrada, a qual recebe os sintomas, camada oculta e a camada de saída, onde estão as classes ou os tipos de falhas. A relação entrada-saída da rede é ponderada por pesos, cujos valores são obtidos através do treinamento da rede embasado em problemas de otimização e que utiliza um conjunto de dados que correspondem aos sintomas e a suas respectivas falhas.

Abbaspour *et al.*, (2020) propuseram uma abordagem adaptativa de rede neural com cálculo dos pesos *online* baseado no EKF (*Extended Kalman Filter*), para a detecção e o diagnóstico de falhas nos elevadores, no leme e nos ailerons de um VANT de asa fixa. Os sintomas eram gerados pela comparação do sinal de controle real e estimado por um observador não-linear, evitando a necessidade de se ter dados experimentais prévios sobre as falhas. O método foi capaz de identificar o local da falha e estimar quantitativamente a perda de eficiência no atuador gerado por ela, sendo essa informação empregada no sistema de controle para atenuar os efeitos das falhas.

Contudo, o artigo não fez considerações a respeito da robustez do sistema de FDD e FTC em relação às perturbações externas, como as correntes de ar que estão presentes na realidade e que influenciam as dinâmicas dos VANTs, dos erros de modelo, uma vez que os resultados foram obtidos de simulação

com um modelo fixo, e da presença de ruídos nos sinais do sistema, podendo, todos esses fatores, interferir no correto treinamento da rede. Além disso, o método de FDD empregado apenas contemplava falhas em atuadores, não mencionando possíveis falhas nos sensores.

Em outros trabalhos, como em Song *et al.*, (2019), a combinação da RBFNN (*Radial Basis Function Neural Network*) com algoritmos de estimação de parâmetro virtual proporcionou o desenvolvimento de uma estrutura neuroadaptativa de controle tolerante a falhas de atuadores em quadricópteros com uma redução no custo computacional. Neste caso, o principal objetivo da pesquisa era projetar um sistema de controle que englobava as incertezas de modelo e as perturbações externas ao sistema, garantindo estabilidade e atenuação dos efeitos das falhas. Entretanto, essa estrutura possui a natureza de caixa preta, ou seja, as determinações dos locais e das magnitudes das falhas não são necessárias *a priori* pelo controlador, e a saída da rede é o sinal de controle. Isso impossibilita a identificação do atuador defeituoso e conseqüentemente, a sua manutenção quando o quadricóptero não estiver em operação. Objetivos de pesquisa similares são apresentados em Zeghlache *et al.*, (2018) por meio da RBNN *fuzzy sliding mode controller* para falhas de atuadores em helicópteros octorotores, tendo, a RBNN, proporcionado a detecção e a reconstrução, estimação, da falha.

Um tópico a se considerar nos trabalhos relacionados à ANN é o custo computacional, principalmente em ao tratar de técnicas adaptativas ou estruturas híbridas envolvendo métodos não lineares. Em razão da implementação embarcada desses sistemas em VANTs, o custo computacional pode ser elevado o suficiente para inviabilizar o projeto (GHALAMCHI, 2019). Os trabalhos aqui citados obtiveram seus resultados via simulação e não apresentaram discussões a respeito desse custo na realização prática do respectivo método em estudo.

Além disso, a ANN possui algumas limitações, dentre elas podem ser indicadas: incapacidade de generalizar apropriadamente uma grande variedade de cenários, a não ser as quais é treinada, tempo e esforço podem ser elevados em função da quantidade de dados, da escolha da estrutura e da configuração adequadas da rede, e a natureza de caixa preta que limita o entendimento de como as decisões são tomadas pela rede (AMIRUDDIN *et al.*, 2018). Divergência

do algoritmo, *overfitting* e se situar em extremos locais são outras possibilidades de ocorrência na ANN (SKLIROS et al., 2019).

Dentre outros exemplos de técnicas de FDD, Guo *et al.*, (2018) implementaram uma estrutura híbrida composta pelo diagnóstico de falhas em sensores através de *Deep Learning*. Os resíduos de sinais provenientes de nove sensores da aeronave foram gerados pelo EKF, e criou-se um mapa 2-D de cada resíduo no tempo-frequência por meio da STFT (*Short Time Fourier Transform*). Esse mapa foi utilizado pela CNN (*Convolutional Neural Network*) para extrair as características das falhas e possibilitar o diagnóstico delas, que nesse caso, resultava apenas na localização do sensor com falhas.

Vale ressaltar que a rede citada foi treinada através de dados simulados. Nesse ponto, o conhecimento do comportamento das falhas é essencial para o projeto dos métodos de FDD, principalmente os orientados a dados. Entretanto, existem situações em que essa informação é escassa por efeito da não ocorrência frequente da falha em processos reais, a inviabilidade de produzir a falha experimentalmente ou o desconhecimento da sua dinâmica para simulação. Isso dificulta a abrangência da totalidade das falhas e a garantia das melhores soluções de FDD.

Em relação às técnicas voltadas para as análises estatísticas de FDD, em Alos *et al.*, (2019), um conjunto de informações estatísticas de dados históricos foi obtido dos sensores e dos atuadores do VANT. Nesse conjunto, os autores aplicaram dois algoritmos: o detector de anomalias baseado no *Principal Component Analysis* e o *One-Cluster K-Means*. Consequentemente, apenas a detecção das falhas ocorreu de maneira a caracterizar o voo como anormal ou normal. Fravolini *et al.*, (2017) fizeram uso do filtro EWMA (*Exponentially Weighted Moving Average*) possuindo, para a detecção de falhas em tubos de *pitot*, parâmetros influenciados pelo modelo NARX (*Nonlinear Autoregressive Exogenous*) do sistema com estrutura adaptativa às condições atuais de voo, e com os limites de detecção calculados via probabilidade de ocorrência de alarmes falsos.

Uma estratégia comumente empregada em aviões é a implementação de atuadores e de sensores redundantes, também conhecida como redundância de *hardware*, que permite a troca de componentes com falha por outros do mesmo tipo livres de falhas. Contudo, esse método é inviável para VANTs, devido a sua

estrutura com peso e dimensões reduzidos, além do aumento do preço dessas aeronaves com sensores e atuadores adicionais.

Uma outra proposta de FDD e FTC é a redundância analítica, associada aos métodos baseados em modelos. Esses métodos são estruturados a partir do modelo físico do sistema ou do componente que se deseja analisar. Neste caso, os resíduos são obtidos através da comparação entre as medições disponíveis do sistema e os valores calculados por meio dos modelos matemáticos, que representam a situação do sistema livre de falhas (ZHONG, XUE, DING, 2018). Esses valores correspondem, por exemplo, aos estados ou parâmetros do modelo empregado. Métodos de identificação de parâmetros, espaço de paridade e observadores e filtros de estimação de estados são estratégias de detecção de falhas baseadas em modelo.

O processo de diagnóstico ocorre das seguintes formas, relacionando cada maneira a uma estratégia: quando os parâmetros do modelo estão intimamente relacionados a um componente do sistema, permitindo a localização da falha e/ou sua estimação; quando a análise simultânea de vários resíduos gerados por diferentes equações de paridade permite a localização da falha; e quando as falhas são estimadas pelos filtros ou observadores através da sua inserção no modelo do processo.

Não obstante, a obtenção desses modelos se torna difícil ou quase impossível quando se trata de sistemas complexos, de larga escala e com operações envolvendo uma quantidade significativa de variáveis (NOR *et al.*, 2019). Além disso, as incertezas do modelo, as não-linearidades, a presença de ruídos do processo e de medição, as perturbações internas e externas e as imprecisões nas representações das falhas, podem afetar consideravelmente o desempenho das técnicas FDD baseadas em modelo.

Han *et al.*, (2017) empregaram a combinação da abordagem do espaço de paridade e o algoritmo de mínimos quadrados recursivos com fator de esquecimento para a detecção, a isolação e a estimação de falhas em atuadores de quadricópteros. O modelo não linear da aeronave foi considerado por meio de modelos LPV (*Linear Parameter Varying*), e o limite de detecção foi adaptado para contornar a presença dos ruídos de medição via norma dois dos resíduos gerados pelas equações de paridade.

Em exemplos utilizando filtros de estimação, Wang *et al.*, (2019) propuseram a solução da detecção e da isolação das falhas em atuadores de um helicóptero hexarotor através de um conjunto de EKF's. Em virtude à estrutura englobar as falhas na representação em espaço de estados do sistema, a estimação delas se tornou possível, o que permitiu a reconfiguração do controlador proposto de maneira a atenuar os efeitos das falhas. Mesmo que a detecção e o diagnóstico das falhas tenham sido obtidos nos resultados, os autores, em ambos os casos, não fizeram considerações a respeito das influências das perturbações externas do sistema, o que pode influenciar tanto no aumento de alarmes falsos, quanto na degradação do desempenho do sistema FTC empregado.

Ghulamchi *et al.*, (2019) identificaram e isolaram as falhas estruturais das hélices de um quadricóptero por meio dos sinais do acelerômetro. Utilizando o EKF, que neste caso considerava as perturbações no modelo do sistema, o filtro predizia os estados relacionados com o balanço da aeronave. Esse balanço é afetado quando alguma hélice apresenta falhas, as quais surgem como vibrações nos próprios estados ligados ao balanço. Por isso, essas vibrações foram analisadas, no domínio do tempo, a fim de detectar essas falhas. A estimação do dano estrutural ocorreu indiretamente pela análise da magnitude do balanço da aeronave. O método se mostrou efetivo para a sinalização de eventos de manutenção e a possibilidade de desencadear, por exemplo, aterrissagens forçadas por motivos de segurança.

Guo *et al.*, (2018) empregaram o filtro PMI (*Proportional Multiple Integer*) para a detecção de falhas no tubo de pitot, no sensor de ângulo de ataque, no acelerômetro, no giroscópio e no sensor de derrapagem. De acordo com o autor, o filtro sugerido é um EKF considerando entradas desconhecidas, que engloba, por exemplo, as perturbações do sistema, possibilitando a geração de resíduos com características das falhas desacopladas dessas entradas. A isolação ocorreu considerando a tabela de assinaturas, que determinou qual sensor está defeituoso de acordo com o resultado dos diferentes resíduos. Xu *et al.*, (2019) utilizaram um observador formulado nas normas H-infinito e H- para a detecção de falhas no sensor de um VANT com rotor-coaxial, e um controle tolerante a falhas baseado em realimentação de estados. Através da norma H-infinito, é possível atenuar os efeitos das perturbações do sistema e dos ruídos de

medição, e considerar as incertezas de modelo, enquanto a norma H- intensifica a sensibilidade do observador às falhas. No entanto, essa técnica possui limitações em problemas envolvendo detecções múltiplas e considerando toda a faixa frequencial das falhas. Abouselima *et al.*, (2019) também fizeram uso do observador robusto H-infinito e H-, no entanto, para o caso de detecção de falhas em atuadores de quadricópteros.

Em situações mais específicas, como em Rotondo *et al.*, (2017), as falhas em atuadores e o encrostamento de gelo na superfície de aeronaves de asa fixa foram detectadas através do UIO (*Unknown Input Observer*), que utilizou um modelo *quasi*-LPV para descrever as não-linearidades por meio da variação de alguns parâmetros do sistema. O emprego desse observador é devido a sua capacidade de geração de resíduos independentes de sinais desconhecidos, como as perturbações de saída do sistema. O método se limitou à detecção das falhas realizada pela tabela de assinaturas.

Em casos distintos, foram considerados outros aspectos de FDD e FTC, como: o aumento do custo computacional em função da inclusão das falhas e das perturbações nos estados do sistema, e o desconhecimento das dinâmicas desses sinais. Zhong *et al.*, (2018) trabalharam na estimação de falhas dos atuadores de quadricópteros através do ATSKF (*Adaptive Three-Stage Kalman Filter*), projetado sem a necessidade das hipóteses sobre as características estocásticas das falhas e das perturbações externas serem exatas. Para isso, o ganho do filtro adapta-se de acordo com o valor real das matrizes de covariância da inovação dos estados, das falhas e das perturbações. Por conseguinte, o custo computacional é reduzido pelo uso da estrutura do filtro em três estágios através da transformação U-V das variáveis do KF, permitindo que a estimação das variáveis ocorra em etapas. Contudo, foi utilizada a abordagem linear do KF considerando um modelo linear da aeronave obtido via simplificações de alguns parâmetros. Nos resultados, a variação do ponto de operação ocorreu em faixas estreitas, não envolvendo situações mais abrangentes como nos trabalhos dos outros autores aqui citados.

Para o caso não linear da última abordagem e em uma aplicação não voltada a VANTs, Xiao *et al.*, (2017) publicaram os filtros TsUKF (*Three-Stage Unscented Kalman Filter*) e o RTsUKF (*Robust Three-Stage Unscented Kalman Filter*) para a estimação das falhas e das perturbações externas, considerando o

modelo não linear do sistema por meio da estrutura do UKF (*Unscented Kalman Filter*) e utilizando a transformação U-V para reduzir o custo computacional de cada filtro. A abordagem robusta é responsável por desacoplar a estimação dos estados, das falhas e das perturbações, para que o desconhecimento das características estocásticas dos dois últimos não prejudique a obtenção do ganho ótimo do filtro.

Acerca de todas as informações apresentadas nesta seção, é possível obter determinadas conclusões a respeito da aplicação dos métodos de FDD e FTC em VANTs atualmente.

1. Os métodos de FDD e FTC são aplicações relevantes aos VANTs, situação visível pela quantidade de diversas publicações recentes sobre o assunto e pelo aumento considerável do interesse privado e público nas aeronaves para a execução de diferentes serviços.

2. Algumas publicações são limitadas à detecção e/ou à isolação das falhas, o que possibilita paradas de segurança em ocorrência de falhas, como pouso seguro, e o aprimoramento dos procedimentos de manutenção dos componentes do sistema. Outras publicações são voltadas para a detecção, isolação, estimação e atenuação dos efeitos das falhas no VANT, garantindo também a continuidade na execução das funções requisitadas às aeronaves. A primeira circunstância ocorre com maior frequência quando a falha é relativa aos sensores e à estrutura da aeronave, enquanto a segunda está relacionada às falhas nos atuadores, em razão da estimação dessas falhas estarem diretamente associadas ao sinal de controle de algumas estruturas de FTC.

2.1. É possível observar que os métodos baseados em análise de sinal são utilizados para monitoramento de componentes específicos dos sistemas, limitando-se à detecção das falhas.

2.2. Os métodos orientados a dados podem fornecer um diagnóstico sobre as falhas, mas normalmente restrito a uma análise qualitativa das mesmas, exceto em casos híbridos, onde há uma fusão desses métodos com outros baseados em modelo. Além disso, a necessidade em se ter o conhecimento sobre o comportamento específico de cada falha gera um problema adicional a esses métodos, visto que dependendo da falha, há a possibilidade de ser

excessivamente difícil tê-la experimentalmente e/ou conhecer as suas dinâmicas para injetá-las artificialmente no sistema, se possível.

2.3. As técnicas de FDD baseadas em modelo apresentaram ser as mais eficientes em termos de fornecer uma maior quantidade de informações sobre as falhas quando a estrutura é capaz de estimar esses sinais. Por esse motivo, o diagnóstico é quantitativo e permite uma melhor atuação do sistema de FTC. Além disso, são métodos que se mostraram mais flexíveis de implementação em relação aos outros orientados a dados quando se trata do desconhecimento do comportamento das falhas.

3. De maneira geral, os métodos de FDD baseados em modelo surgem com a finalidade de solucionar diferentes propriedades presentes nos VANTs que prejudicam na detecção e diagnóstico das falhas, representadas como:

3.1. as não-linearidades presentes nas dinâmicas de voo;

3.2. as perturbações externas geradas principalmente pelos ventos, os quais são normalmente mais intensos quanto maior a altitude e menor o peso da aeronave;

3.3. as incertezas de modelo geradas pela aproximação de dinâmicas do sistema;

3.4. os ruídos provenientes das diferentes partes do sistema, principalmente as originadas pelos sensores;

3.5. o custo computacional, em consequência de o monitoramento ser um complemento do sistema principal, que corresponde às funções pelas quais a aeronave foi requisitada a executar, e ao tamanho do sistema, que impossibilita a implementação de *hardwares* com velocidade mais elevada de processamento de dados.

No tópico antecedente, a maior parte das publicações citadas é ineficiente na resolução de todas essas características simultaneamente.

4. Alguns dos pontos relevantes existentes, que são pouco abordados nas publicações, seja pela incapacidade do método em resolver o problema, seja pela solução parcial apresentada pelos autores, serão discutidos na sequência.

4.1. A integração do monitoramento de falhas de sensores e de atuadores. Comumente, os métodos de FDD para atuadores utilizam os sinais provenientes dos sensores. Caso haja um valor ou uma sequência de valores distorcidos por uma falha no sensor, o método de FDD dedicado aos atuadores pode inferir

erroneamente o estado da aeronave, possibilitando, por exemplo, que sinais de controle da estrutura FTC gerem instabilidade ao sistema.

4.2. Na maior parte das publicações, é considerado uma única falha agindo por vez no sistema. Em situações reais, as falhas múltiplas e de ocorrências simultâneas são possíveis e dependendo do método empregado, o acoplamento entre elas pode gerar falsos diagnósticos pela FDD e sinais de controle incorretos pelo FTC.

4.3. O tempo de detecção das falhas é um fator de destaque em métodos que não possuem a etapa de estimação da falha, principalmente aqueles que fazem uso de resíduos. Dependendo do comportamento da falha, principalmente as do tipo *drift*, que se desenvolvem ao longo do tempo, o valor atribuído ao limiar de detecção pode prejudicar esse tempo, tornando a estrutura incapaz de detectar a falha em seu estágio inicial.

4.4. A maioria das publicações apresentaram resultados simulados, simplificando as falhas como, principalmente, rampas e degraus. Em métodos que utilizam o conhecimento prévio do comportamento das falhas, como os orientados a dados, essas considerações podem gerar resultados práticos insatisfatórios.

5. Dentre os VANTs mencionados, o quadricóptero foi uma das aeronaves mais utilizadas nas pesquisas como estudo de caso. Esse interesse se dá em consequência de suas propriedades citadas anteriormente.

2.2. Modelagem dinâmica do quadricóptero

Esta seção apresenta o modelo matemático das dinâmicas de um quadricóptero obtido via formulação de Newton-Euler.

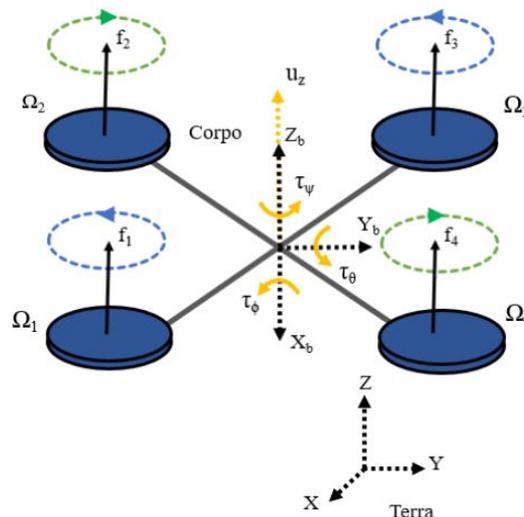
2.2.1. Considerações iniciais

As equações que regem o voo de um quadricóptero são fundamentadas pelo estudo dos efeitos das forças e dos torques aplicados nesse corpo. Neste trabalho, faz-se as seguintes considerações a respeito da aeronave para a obtenção dessas equações (BOUABDALLAH, 2007):

- a sua estrutura é supostamente rígida e simétrica;
- as suas hélices são supostamente rígidas;
- as forças de empuxo e de arraste são proporcionais ao quadrado da velocidade das hélices;
- o seu centro de massa e o centro do sistema de coordenadas do corpo são coincidentes.

O quadricóptero é apresentado na Figura (2.1), a qual inclui o sistema de coordenadas inercial (eixos X , Y , Z), fixo na Terra, e o sistema de coordenadas do corpo, móvel, (eixos X_b , Y_b , Z_b), associado à orientação da aeronave.

Figura 2.1 – Estrutura e variáveis do quadricóptero



Fonte: Próprio autor

As forças (f_1 , f_2 , f_3 e f_4) e os torques (τ_1 , τ_2 , τ_3 , τ_4) gerados por cada hélice variam de acordo com a velocidade angular (Ω_1 , Ω_2 , Ω_3 e Ω_4) de cada motor e estão relacionados com o sistema de coordenadas do corpo, Equação (2.1) e (2.2). O subscrito i denota o i -ésimo motor, b , a constante de empuxo, d , a constante de arraste, e I_r , o momento de inércia de cada rotor.

$$f_i = b\Omega_i^2 \quad (2.1)$$

$$\tau_i = d\Omega_i^2 + I_r\dot{\Omega}_i \quad (2.2)$$

Em razão da contribuição da parcela associada a $\dot{\Omega}_i$ ser relativamente pequena, desconsidera-se esse termo nas equações futuras.

Com o intuito de balancear o contra torque presente nos motores, efeito responsável pelo surgimento do torque de guinada (τ_ψ), e conseqüentemente a rotação do quadricóptero em torno do eixo Z_b , um par de motores gira em sentido horário, enquanto o outro par, em sentido anti-horário. O torque de arfagem (τ_θ), responsável pela rotação em torno do eixo Y_b , é resultante da diferença entre as forças (f_1, f_4) e (f_2, f_3), o que permite o deslocamento do quadricóptero na direção do eixo X_b . Para o caso do torque de rolagem (τ_ϕ), a diferença reside entre as forças (f_1, f_2) e (f_3, f_4) e proporciona rotações em torno do eixo X_b e um deslocamento na direção do eixo Y_b , Equação (2.3). O parâmetro l corresponde à distância entre o centro de massa do quadricóptero e cada motor.

$$\boldsymbol{\tau}_B = \begin{bmatrix} \tau_\phi \\ \tau_\theta \\ \tau_\psi \end{bmatrix} = \begin{bmatrix} -\frac{bl}{\sqrt{2}} & -\frac{bl}{\sqrt{2}} & \frac{bl}{\sqrt{2}} & \frac{bl}{\sqrt{2}} \\ \frac{bl}{\sqrt{2}} & \frac{bl}{\sqrt{2}} & \frac{bl}{\sqrt{2}} & -\frac{bl}{\sqrt{2}} \\ -\frac{bl}{\sqrt{2}} & \frac{bl}{\sqrt{2}} & \frac{bl}{\sqrt{2}} & -\frac{bl}{\sqrt{2}} \\ d & -d & d & -d \end{bmatrix} \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} = \mathbf{T}_\tau \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} \quad (2.3)$$

Nota-se na Equação (2.3) que todos os motores contribuem para o torque em cada eixo da aeronave. Isso se deve a sua configuração cruzada, ou em x, de maneira que nenhum motor está situado em um eixo de coordenadas. De acordo com (GUPTE *et al.*, 2012), essa disposição permite uma manobrabilidade ligeiramente maior em relação à configuração P, ou em '+'. A força de empuxo (\mathbf{U}_B) equivale à soma das forças geradas por cada hélice e possui a mesma direção do eixo Z_b , Equação (2.4).

$$\mathbf{U}_B = \begin{bmatrix} 0 \\ 0 \\ u_z \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ b & b & b & b \end{bmatrix} \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} = \mathbf{T}_z \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} \quad (2.4)$$

As posições lineares no espaço (x, y, z) do quadricóptero estão definidas no sistema de coordenadas inercial, bem como as suas posições angulares, as quais estão associadas a três ângulos de Euler (ϕ, θ e ψ – rolagem, arfagem e

guinada, respectivamente) e responsáveis por determinar a sua orientação, Equação (2.5). Os ângulos de Euler estão limitados a: $(-\pi/2 < \phi < \pi/2)$, $(-\pi/2 < \theta < \pi/2)$ e $(-\pi < \psi < \pi)$.

$$\xi = \begin{bmatrix} x \\ y \\ z \end{bmatrix}, \quad \eta = \begin{bmatrix} \phi \\ \theta \\ \psi \end{bmatrix} \quad (2.5)$$

As velocidades lineares e angulares das variáveis da Equação (2.5) equivalem a $\dot{\xi}$ e $\dot{\eta}$, respectivamente. Para o caso do sistema de coordenadas do corpo, essas velocidades são descritas pela Equação (2.6), sendo \mathbf{V}_B a velocidade linear e $\boldsymbol{\omega}$, a velocidade angular.

$$\mathbf{V}_B = \begin{bmatrix} V_{b,x} \\ V_{b,y} \\ V_{b,z} \end{bmatrix}, \quad \boldsymbol{\omega} = \begin{bmatrix} p \\ q \\ r \end{bmatrix} \quad (2.6)$$

A relação das velocidades angulares no sistema de coordenadas do corpo e as derivadas temporais dos ângulos de Euler é expressa pela matriz de transformação \mathbf{W}_n , Equação (2.7) e (2.8), também conhecida como matriz de Euler, tal que $S. = \text{sen}(\cdot)$, $C. = \text{cos}(\cdot)$ e $T. = \text{tan}(\cdot)$. A matriz \mathbf{W}_n é inversível se $\theta \neq (2k-1)\pi/2$, $(k \in \mathbb{Z})$ (RAFFO, 2011).

$$\dot{\eta} = \mathbf{W}_n^{-1} \boldsymbol{\omega}, \quad \begin{bmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{bmatrix} = \begin{bmatrix} 1 & S_\phi T_\theta & C_\phi T_\theta \\ 0 & C_\phi & -S_\phi \\ 0 & \frac{S_\phi}{C_\theta} & \frac{C_\phi}{C_\theta} \end{bmatrix} \begin{bmatrix} p \\ q \\ r \end{bmatrix} \quad (2.7)$$

$$\boldsymbol{\omega} = \mathbf{W}_n \dot{\eta}, \quad \begin{bmatrix} p \\ q \\ r \end{bmatrix} = \begin{bmatrix} 1 & 0 & -S_\phi \\ 0 & C_\phi & S_\phi C_\theta \\ 0 & -S_\phi & C_\phi C_\theta \end{bmatrix} \begin{bmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{bmatrix} \quad (2.8)$$

Para as demais variáveis vetoriais (posições, velocidades e acelerações lineares, forças e torques), essa relação é obtida através da matriz de cossenos diretores ($\mathbf{R}:B \rightarrow I$), Equação (2.9), que associa a orientação do sistema de coordenadas do corpo, B , ao sistema inercial, I . Essa matriz foi calculada considerando a convenção Tait-Bryan, que estabelece a orientação do corpo

rígido através de três rotações sucessivas em torno dos eixos do sistema móvel, seguindo uma ordem de rotação que se inicia em função de ψ , posteriormente em θ , e finalizando em função de ϕ (USMAN, 2020).

$$\mathbf{R} = \begin{bmatrix} C_\psi C_\theta & C_\psi S_\theta S_\phi - S_\psi C_\phi & C_\psi S_\theta C_\phi + S_\psi S_\phi \\ S_\psi C_\theta & S_\psi S_\theta S_\phi + C_\psi C_\phi & S_\psi S_\theta C_\phi - C_\psi S_\phi \\ -S_\theta & C_\theta S_\phi & C_\theta C_\phi \end{bmatrix} \quad (2.9)$$

Uma das propriedades de \mathbf{R} é de ser uma matriz ortogonal, portanto, $\mathbf{R}_I = \mathbf{R}^{-1} = \mathbf{R}^t$, tal que \mathbf{R}_I representa a matriz de rotação do sistema inercial para o sistema de coordenadas do corpo ($\mathbf{R}_I: I \rightarrow B$).

Uma outra consideração a respeito do quadricóptero é a sua simetria mecânica que torna possível negligenciar os produtos de inércia, portanto, a sua matriz de inércia (\mathbf{I}) é diagonal, Equação (2.10) (BOUABDALLAH, 2007).

$$\mathbf{I} = \begin{bmatrix} I_{xx} & 0 & 0 \\ 0 & I_{yy} & 0 \\ 0 & 0 & I_{zz} \end{bmatrix} \quad (2.10)$$

2.2.2. Formulação de Newton-Euler

As dinâmicas dos quadricópteros podem ser descritas pela formulação de Newton-Euler devido à consideração inicial sobre a estrutura da aeronave ser rígida. Ademais, de acordo com a suposição realizada sobre o centro de massa da aeronave ser coincidente com a origem do sistema de coordenadas fixo ao corpo, é possível analisar separadamente o sistema translacional, associado às forças, e o sistema rotacional, associado aos torques (LIMA, 2015). No sistema de coordenadas do corpo, o deslocamento linear é definido pela Equação (2.11).

$$\mathbf{F}_{R,B} + \mathbf{F}_C = \mathbf{F}_{P,B} + \mathbf{U}_B \quad (2.11)$$

$$\mathbf{F}_{R,B} = m\dot{\mathbf{V}}_B \quad (2.12)$$

$$\mathbf{F}_C = \boldsymbol{\omega} \times (m\mathbf{V}_b) \quad (2.13)$$

$$\mathbf{F}_{P,B} = \mathbf{R}_I \mathbf{G} \quad (2.14)$$

$$\mathbf{G} = \begin{bmatrix} 0 \\ 0 \\ -mg \end{bmatrix} \quad (2.15)$$

sendo $\mathbf{F}_{R,B}$ a força necessária para que o corpo de massa m adquira uma aceleração $\dot{\mathbf{V}}_B$, \mathbf{F}_c , a força de Coriolis, e $\mathbf{F}_{P,B}$, a força peso gerado pela ação da gravidade. Como é de interesse representar o deslocamento do quadricóptero em função das coordenadas inerciais, aplica-se a matriz de rotação \mathbf{R} na Equação (2.11), obtendo a Equação (2.16).

$$m\ddot{\boldsymbol{\xi}} = \mathbf{G} + \mathbf{R}\mathbf{U}_B$$

$$\begin{bmatrix} \ddot{x} \\ \ddot{y} \\ \ddot{z} \end{bmatrix} = -g \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} + \frac{u_z}{m} \begin{bmatrix} C_\psi S_\theta C_\phi + S_\psi S_\phi \\ S_\psi S_\theta C_\phi - C_\psi S_\phi \\ C_\theta C_\phi \end{bmatrix} \quad (2.16)$$

Devido à força de Coriolis ser uma pseudoforça com representação única em sistemas não-inerciais, ela não aparece na Equação (2.16), a qual é definida por um sistema inercial.

Em relação ao sistema rotacional, é possível obter a Equação (2.17), associada ao sistema de coordenadas do corpo.

$$\boldsymbol{\tau}_{R,B} + \boldsymbol{\tau}_C + \boldsymbol{\tau}_G = \boldsymbol{\tau}_B \quad (2.17)$$

$$\boldsymbol{\tau}_{R,B} = \mathbf{I}\dot{\boldsymbol{\omega}} \quad (2.18)$$

$$\boldsymbol{\tau}_C = \boldsymbol{\omega} \times (\mathbf{I}\boldsymbol{\omega}) \quad (2.19)$$

$$\boldsymbol{\tau}_G = I_r \left(\boldsymbol{\omega} \times \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \right) (\Omega_1 - \Omega_2 + \Omega_3 - \Omega_4) \quad (2.20)$$

sendo $\boldsymbol{\tau}_{R,B}$ o torque necessário para que o corpo de matriz inercial \mathbf{I} adquira uma aceleração angular $\dot{\boldsymbol{\omega}}$, $\boldsymbol{\tau}_C$, o torque associado ao efeito de Coriolis, e $\boldsymbol{\tau}_G$, o torque referente às forças do efeito giroscópico. Expandindo a Equação (2.17), obtém-se a Equação (2.21).

$$\begin{bmatrix} \dot{p} \\ \dot{q} \\ \dot{r} \end{bmatrix} = \begin{bmatrix} \frac{(I_{yy} - I_{zz})qr}{I_{xx}} \\ \frac{(I_{zz} - I_{xx})pr}{I_{yy}} \\ \frac{(I_{xx} - I_{yy})pq}{I_{zz}} \end{bmatrix} - I_r \begin{bmatrix} q \\ -p \\ 0 \end{bmatrix} (\Omega_1 - \Omega_2 + \Omega_3 - \Omega_4) + \begin{bmatrix} \frac{\tau_\phi}{I_{xx}} \\ \frac{\tau_\theta}{I_{yy}} \\ \frac{\tau_\psi}{I_{zz}} \end{bmatrix} \quad (2.21)$$

Aplicando a transformação W_n^{-1} na Equação (2.21) e derivando esse resultado, obtém-se a modelo dinâmico do quadricóptero associado ao sistema rotacional, Equação (2.22).

$$\begin{aligned} \dot{\eta} &= \frac{d}{dt}(W_n^{-1}\omega) = \frac{d}{dt}(W_n^{-1})\omega + W_n^{-1}\dot{\omega} \\ \dot{\eta} &= \begin{bmatrix} 0 & \dot{\phi}C_\phi T_\theta + \frac{\dot{\theta}S_\phi}{C_\theta} & -\dot{\phi}S_\phi C_\theta + \frac{\dot{\theta}C_\phi}{C_\theta^2} \\ 0 & -\dot{\phi}S_\phi & -\dot{\phi}C_\phi \\ 0 & \frac{\dot{\phi}C_\phi}{C_\theta} + \frac{\dot{\phi}S_\phi T_\theta}{C_\theta} & \frac{-\dot{\phi}S_\phi}{C_\theta} + \frac{\dot{\theta}C_\phi T_\theta}{C_\theta} \end{bmatrix} \omega + W_n^{-1}\dot{\omega} \end{aligned} \quad (2.22)$$

Portanto, define-se o modelo matemático das dinâmicas do quadricóptero pelas Equações (2.16) e (2.22) em conjunto com as Equações (2.3) e (2.4), as quais estão relacionadas com os sinais de entrada do sistema.

2.2.3. Quadricóptero

No presente trabalho, o *Parrot Minidrone* apresentado em MathWorks Simulink Team, (2017) é utilizado como modelo de quadricóptero para a implementação dos sistemas de FDD e FTC. Essa aeronave é constituída de sensor ultrassônico, acelerômetro, giroscópio, sensor de pressão de ar e câmera frontal, que em conjunto, permitem as medições das suas posições e velocidades lineares e angulares em ambos os sistemas de coordenadas diretamente ou indiretamente via integrações numéricas e matrizes de transformação.

CAPÍTULO 3

PROJETO DOS CONTROLADORES

Este capítulo apresentará o procedimento para o projeto dos controladores PID (Proporcional, Integral, Derivativo) para o quadricóptero, descrevendo o modelo simplificado da aeronave, a estrutura descentralizada de controle e o controle em cascata. Ressalta-se que as falhas em atuadores e sensores não serão consideradas para esse projeto neste capítulo.

3.1. Simplificação do modelo

Considera-se o ponto de operação do quadricóptero sendo o estado de pairagem, em que os ângulos de rolagem e arfagem são próximos a zero. Portanto, é possível realizar as seguintes aproximações, tal que β é qualquer um dos três ângulos:

- $\lim_{\beta \rightarrow 0} \text{sen}(\beta) = 0$
- $\lim_{\beta \rightarrow 0} \text{cos}(\beta) = 1$
- $\dot{\phi} = \dot{\theta} = \dot{\psi} = 0$

Substituindo esses valores na Equação (2.7), a matriz de transformação \mathbf{W}_n^{-1} se torna uma matriz identidade, de tal forma que: $\dot{\phi} = p, \dot{\theta} = q$ e $\dot{\psi} = r$. Ainda, substituindo as aproximações na Equação (2.22), a primeira parcela do lado direito da equação se torna nula, resultando em $\dot{\boldsymbol{\eta}} = \dot{\boldsymbol{\omega}}$. Portanto, obtém-se

o primeiro modelo simplificado do quadricóptero pela Equação (3.1), em que $\bar{\Omega} = (\Omega_1 - \Omega_2 + \Omega_3 - \Omega_4)$.

$$\left\{ \begin{array}{l} \ddot{x} = (S_\psi S_\phi + C_\psi S_\theta C_\phi) \frac{u_z}{m} \\ \ddot{y} = (-C_\psi S_\phi + S_\psi S_\theta C_\phi) \frac{u_z}{m} \\ \ddot{z} = C_\theta C_\phi \frac{u_z}{m} - g \\ \ddot{\phi} = \frac{(I_{yy} - I_{zz})\dot{\theta}\dot{\psi}}{I_{xx}} + I_r \frac{\dot{\theta}}{I_{xx}} \bar{\Omega} + \frac{\tau_\phi}{I_{xx}} \\ \ddot{\theta} = \frac{(I_{zz} - I_{xx})\dot{\phi}\dot{\psi}}{I_{yy}} + I_r \frac{-\dot{\phi}}{I_{yy}} \bar{\Omega} + \frac{\tau_\theta}{I_{yy}} \\ \ddot{\psi} = \frac{(I_{xx} - I_{yy})\dot{\theta}\dot{\phi}}{I_{zz}} + \frac{\tau_\psi}{I_{zz}} \end{array} \right. \quad (3.1)$$

Executando novamente as simplificações e considerando que enquanto o quadricóptero estiver pairando as velocidades angulares de todos os motores serão aproximadamente iguais ($\bar{\Omega} \simeq 0$), define-se o segundo modelo pela Equação (3.2).

$$\left\{ \begin{array}{l} \ddot{z} = \frac{u_z}{m} - g \\ \ddot{\phi} = \frac{\tau_\phi}{I_{xx}} \\ \ddot{\theta} = \frac{\tau_\theta}{I_{yy}} \\ \ddot{\psi} = \frac{\tau_\psi}{I_{zz}} \end{array} \right. \quad (3.2)$$

Observa-se que na última equação, o controlador deverá ser capaz de estabilizar quatro graus de liberdade. Contudo, é de interesse neste trabalho que o quadricóptero também se posicione nas coordenadas (x,y) desejadas.

De acordo com a Equação (3.1), haverá deslocamentos em relação ao eixo X e ao eixo Y , se os ângulos θ e ϕ forem não nulos, respectivamente. Por esse motivo, para as equações das acelerações de x e y , considera-se uma nova condição de operação, caracterizada por pequenos valores dos ângulos de rolagem e arfagem, de tal maneira que:

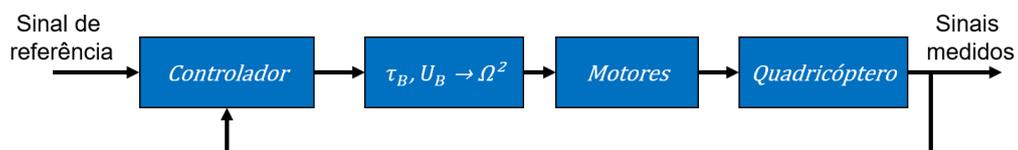
- $\text{sen}(\theta) \simeq \theta$;
- $\text{sen}(\phi) \simeq \phi$;
- $\text{cos}(\phi) = \text{cos}(\theta) = 1$.

Além disso, é estabelecido que enquanto há movimentos nas direções de X e Y, a aeronave estará fixa em uma posição em relação à vertical, eixo Z, ou seja, o valor de u_z nessas equações será aproximadamente igual à força peso (mg). A Equação (3.3) é o modelo linear final das dinâmicas do quadricóptero, o qual será utilizado para o projeto dos controladores.

$$\left\{ \begin{array}{l} \ddot{x} = \theta g \\ \ddot{y} = -\phi g \\ \ddot{z} = \frac{u_z}{m} - g \\ \ddot{\phi} = \frac{\tau_\phi}{I_{xx}} \\ \ddot{\theta} = \frac{\tau_\theta}{I_{yy}} \\ \ddot{\psi} = \frac{\tau_\psi}{I_{zz}} \end{array} \right. \quad (3.3)$$

Visando a Equação (3.3), é possível substituir os valores da força de empuxo e dos torques pelos valores das Equações (2.2) e (2.3) associados aos motores. Entretanto, para manter o desacoplamento entre essas equações, é utilizada a configuração da Equação (3.3), de maneira que os sinais de controle sejam a força e os torques. Após o cálculo desses sinais, os mesmos são modificados para equivaler ao sinal de entrada dos motores, Figura (3.1).

Figura 3.1 – Sistema de controle em malha fechada



Fonte: Próprio autor

3.2. Controlador PID

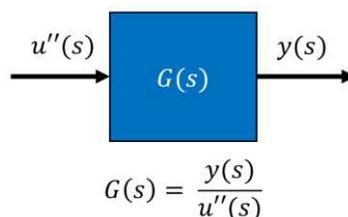
O controlador PID é um algoritmo de controle popular, cuja larga utilização, principalmente em processos industriais, se deve a algumas das suas características, como (LIMA, 2015):

- baixo custo e de fácil implementação da estratégia de controle;
- compatível com diversas aplicações;
- capacidade de fornecer comportamentos transitórios satisfatórios;
- eliminação do erro de regime permanente.

Esse tipo de controlador é projetado para sistemas SISO (*Single Input – Single Output*), ou seja, sistemas que associam um único sinal de saída a um único sinal de entrada. Graças ao desacoplamento entre as equações do modelo do quadricóptero, é possível estabelecer um controlador para cada variável (posições lineares e angulares).

Aplicando a transformada de Laplace na Equação (3.3), obtém-se as funções de transferência ($G(s)$), Equação (3.4), as quais associam o sinal de controle $u''(s)$ ao sinal de medição $y(s)$, Figura (3.2).

Figura 3.2 – Função de transferência generalizada

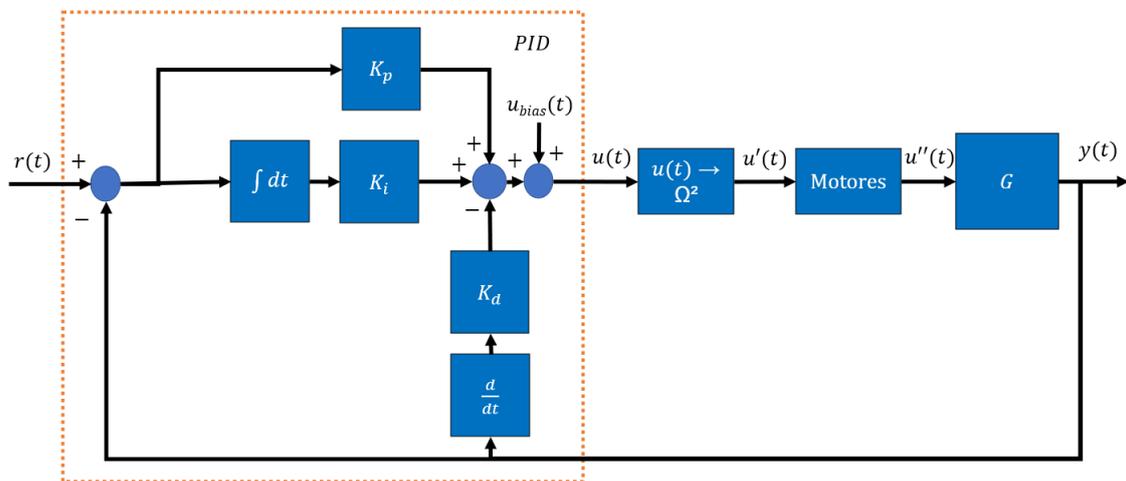


Fonte: Próprio autor

Na literatura, há diferentes abordagens de algoritmos PID. Neste trabalho, optou-se pelo PID paralelo com o modo derivativo na medição, Equações (3.5) e (3.6), cuja estrutura é apresentada na Figura (3.3). A variável r é o sinal de referência, que estabelece o valor desejado para o sinal de saída, a constante K_p é o ganho do modo proporcional, K_i , o ganho do integrador, e K_d , o ganho do derivativo. O projeto do controlador PID é obter os valores dessas três constantes de ganho.

$$\begin{cases} \frac{x(s)}{\theta(s)} = \frac{g}{s^2} \\ \frac{y(s)}{\phi(s)} = -\frac{g}{s^2} \\ \frac{z(s)}{u_z(s)} = \frac{1}{ms^2} \\ \phi(s) = \frac{1}{\tau_\phi(s)} = \frac{1}{I_{xx}s^2} \\ \theta(s) = \frac{1}{\tau_\theta(s)} = \frac{1}{I_{yy}s^2} \\ \psi(s) = \frac{1}{\tau_\psi} = \frac{1}{I_{zz}s^2} \end{cases} \quad (3.4)$$

Figura 3.3 – Representação do controlador PID utilizado



Fonte: Próprio autor

$$u(t) = u_{bias}(t) + K_p[r(t) - y(t)] + K_i \int [r(t) - y(t)] dt - K_d \frac{d}{dt} y(t) \quad (3.5)$$

$$u(s) = u_{bias}(s) + K_p[r(s) - y(s)] + \frac{K_i}{s} [r(s) - y(s)] - K_d s y(s) \quad (3.6)$$

A variável u_{bias} é o valor do sinal de controle para que o sistema esteja inicialmente nos pontos de operação citados anteriormente. De acordo com a Equação (3.3), o valor de u_{bias} para u_z equivale a mg e nulo para os demais sinais de controle. Além disso, ressalta-se que u' e $u \simeq u''$ são obtidos em função das Equações (2.3) e (2.4).

O modo proporcional gera uma atuação no processo proporcional ao erro de realimentação ($r(t)-y(t)$), o que possibilita alterações na velocidade de

resposta do sistema. Quanto maior o ganho desse modo, maior poderá ser o sobressinal da saída, aumentando as possibilidades do sistema se tornar instável (WADE, 2104).

O modo integral proporciona o acúmulo gradativo do erro ao longo do tempo no sinal de controle. Essa característica permite que o erro de realimentação se torne nulo no regime permanente, pois haverá a atuação do integrador enquanto esse erro for diferente de zero (KUMAR, MINZ, 2016).

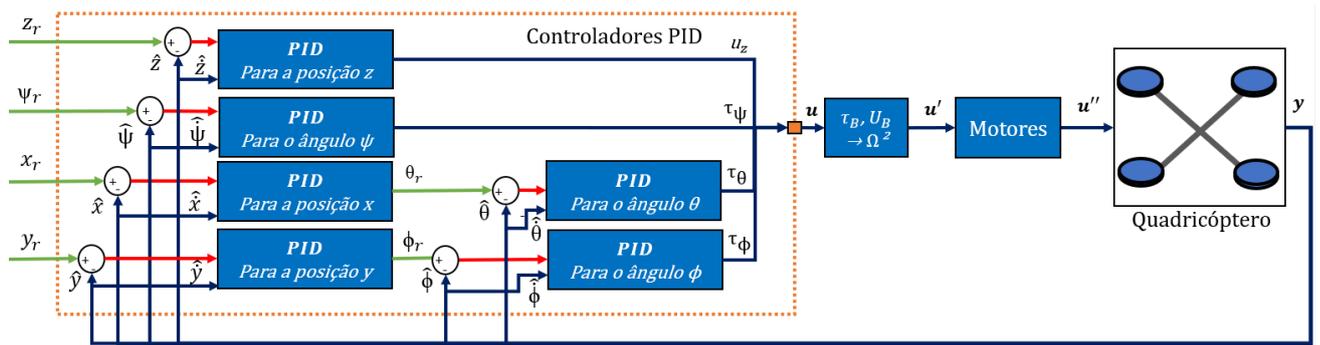
O modo derivativo é definido pela antecipação do erro no tempo levando a uma redução mais rápida, em relação aos outros modos, do desvio total entre o sinal de saída e o de referência (LONGHI, 2018). Devido a sua ação ser baseada na derivada do sinal de entrada do controlador, a presença de ruídos pode interferir de maneira significativa no sinal de controle. Por esse motivo, é necessário filtrar o sinal de entrada do modo derivativo para atenuar esses efeitos no sistema.

De acordo com (WADE, 2004), a configuração do PID com o modo derivativo na medição reduz o pico do derivativo ocasionado pela mudança abrupta do sinal de referência, evitando perturbações na malha de controle e variações repentinas nas ações dos atuadores. Outra vantagem, neste caso associada ao sistema do quadróptero, é a presença das medições das suas velocidades lineares e angulares, não necessitando de executar derivações nos sinais de posições. Além disso, como será abordado no capítulo 4, todos esses sinais são filtrados, reduzindo o efeito dos ruídos na ação de controle, principalmente para o modo derivativo.

Em relação às posições em X e em Y , os sinais de controle correspondem aos ângulos de arfagem e rolagem, respectivamente. Diante disso, é possível estabelecer uma estrutura de controle em cascata, Figura (3.4), de maneira que o controlador associado as posições x e y será responsável em ajustar o sinal de referência dos controladores referentes aos ângulos citados. Nessa configuração, é necessário que a malha interna, nesse caso associada aos ângulos, tenha um tempo de resposta inferior ao da malha externa, relacionada às posições (WADE, 2004).

A configuração inicial da malha de controle do quadróptero é apresentada na Figura (3.4).

Figura 3.4 – Sistema de controle inicial do quadricóptero



Fonte: Próprio autor

3.3. Cálculo dos parâmetros do PID

O cálculo e o ajuste dos parâmetros do PID podem ser realizados por meio de diferentes abordagens, como: métodos heurísticos, lugar das raízes e alocação de polos. Neste trabalho, optou-se pelo último método devido aos ganhos serem obtidos diretamente por equações associadas a função de transferência de malha fechada com o comportamento desejado.

Pela Equação (3.7), todas as funções de transferência são do tipo:

$$G(s) = \frac{1}{Ks^2} \quad (3.7)$$

em que K varia entre a gravidade, a massa e os momentos de inércia do quadricóptero. Considerando individualmente cada controlador da Figura (3.4), é possível obter a seguinte equação da função de transferência em malha fechada ($T(s)$), tal que $y(s)$ e $r(s)$ são os sinais de saída e de entrada, respectivamente, da malha do controlador analisado:

$$T(s) = \frac{y(s)}{r(s)} = \frac{\frac{K_p}{K} (s + \frac{K_i}{K_p})}{(s^3 + \frac{K_d}{K} s^2 + \frac{K_p}{K} s + \frac{K_i}{K})} \quad (3.8)$$

O método baseado em alocação de polos calcula os valores dos parâmetros do PID comparando a equação desejada e a atual do sistema em malha fechada, de modo que os polos de ambos os sistemas sejam iguais

(ALBERTOS, SALA, 2004). Os polos são as raízes do denominador da função de transferência e são os responsáveis em determinar as características do sinal de saída dessa função (sobressinal e tempo de assentamento). A Equação (3.9) é a representação do denominador do sistema em malha fechada desejada ($D(s)$), constituída pelos polos dominantes, que caracterizam o comportamento do sistema, e de um terceiro polo em $-a$ no plano complexo, cujo valor é escolhido para ser distante o suficiente a esquerda dos outros polos no plano para não interferir consideravelmente nesse comportamento. Além disso, esse polo é ajustado para assegurar robustez do controlador às incertezas do modelo através de $\|S\|_{\infty} < 2$ e $\|T\|_{\infty} < 2$, em que S é a função de transferência de sensibilidade tal que $S = 1 - T$ (GOSH *et al.*, 2014).

$$D(s) = (s + a)(s^2 + 2\xi_c w_n s + w_n^2) \quad (3.9)$$

Os valores da frequência natural do sistema, w_n (rad/s), e do fator de amortecimento, ξ_c , são obtidos através dos requisitos de projeto: sobressinal (OS) e tempo de assentamento em 5% do valor final ($T_{s,5\%}$), Equações (3.10) e 3.11, respectivamente.

$$OS = e^{\frac{-\xi_c \pi}{\sqrt{1-\xi_c^2}}} \quad (3.10)$$

$$T_{s,5\%} = \frac{3}{\xi_c w_n} \quad (3.11)$$

Portanto, comparando o denominador da Equação (3.8) e a Equação (3.9), obtém-se os valores dos parâmetros do PID, Equações (3.12) - (3.14).

$$K_p = (2\xi_c w_n a + w_n^2)K \quad (3.12)$$

$$K_i = w_n^2 a K \quad (3.13)$$

$$K_d = (2\xi_c w_n + a)K \quad (3.14)$$

Para a implementação do PID no quadricóptero, é necessário utilizar o controlador discretizado em função do tempo de amostragem T_s . Em vista disso, aplicou-se o método de integração *Forward Euler* para o modo integral, Equação

(3.16), sendo u_k o sinal de controle no instante k e v_k , a velocidade linear ou angular.

$$P_k = K_p[r_k - y_k] \quad (3.15)$$

$$I_k = I_{k-1} + K_i T_s[r_k - y_k] \quad (3.16)$$

$$D_k = K_d v_k \quad (3.17)$$

$$u_k = P_k + I_k + D_k \quad (3.18)$$

Desta maneira, o sinal calculado pela Equação (3.18) representa a saída de um controlador, que em conjunto com os demais, comandarão os motores do quadricóptero e, por consequência, o movimento da aeronave em função de um deslocamento desejado ou de referência.

CAPÍTULO 4

PROJETO DOS SISTEMAS DE FDD E FTC

Este capítulo apresentará o projeto do sistema de detecção e diagnóstico de falhas baseado em filtros de Kalman. Inicialmente será feita uma descrição das falhas em atuadores e nos sensores, de maneira a poder inseri-los no modelo matemático do quadricóptero como estados. Sequencialmente, serão descritas diferentes abordagens do filtro, as quais são as responsáveis em estimar as falhas (detectá-las e diagnosticá-las) e atenuar os ruídos nos sinais de medição, e tendo, cada uma delas, características específicas voltadas ao custo computacional, utilização de modelos lineares e não lineares da aeronave, e robustez na estimação perante o desconhecimento das dinâmicas das falhas. Além disso, será apresentada a estrutura de controle tolerante a falhas, descrevendo a maneira como o sinal de controle é gerado ao quadricóptero levando em consideração essas falhas.

4.1. Descrição das falhas no atuadores

Devido às falhas inesperadas nas hélices ou nos motores de um quadricóptero, os atuadores podem exibir um comportamento indesejado, colocando em questão a confiabilidade e a segurança dos mesmos. Wang *et al.*, (2019) citam uma série de falhas associadas aos atuadores de VANT: altas temperaturas de operação e elevada carga de trabalho dos motores, envelhecimento e desgaste dos componentes (como hélices e rolamentos) e

falhas elétricas no driver do motor (curto-circuito, circuito aberto, envelhecimento dos componentes, entre outros).

No contexto geral das publicações na revisão bibliográfica, excetuando alguns casos que trabalharam especificamente com as falhas estruturais das hélices, as falhas nos atuadores são englobadas e representadas por uma única falha: a perda de eficiência do motor, sendo modelada, normalmente, como degrau ou rampa. Quando se trata apenas das falhas em hélices, estas são equacionadas através dos parâmetros do modelo do sistema relacionados a estrutura da aeronave.

No vigente trabalho, será considerada a falha em atuadores, a qual engloba os problemas em todos os seus componentes, desde as hélices até os motores, e a sua representação pela perda de eficiência do motor.

Desta maneira, o sinal de controle com falhas (\mathbf{u}^f) pode ser expresso pela Equação (4.1) em função do sinal de controle livre de falhas (\mathbf{u}') e de δ_i , o fator de perda de eficiência de controle do i -ésimo motor (ZHONG *et al.*, 2018).

$$u_i^f = (1 - \delta_i)u_i', \quad 0 \leq \delta_i \leq \delta_i^{max} \leq 1 \quad (4.1)$$

O parâmetro δ_i^{max} representa o valor máximo permitido de δ_i para que o sistema continue sendo controlável. Caso o quadricóptero esteja operando corretamente, $\delta_i = 0$. $\delta_i > 0$ indica a presença de falhas no i -ésimo atuador. A partir da Equação (4.1), é possível obter a seguinte relação do sinal de controle com falhas:

$$\mathbf{u}^f = \mathbf{u}' - \mathbf{U}\boldsymbol{\delta} = \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} - \begin{bmatrix} \Omega_1^2 & 0 & 0 & 0 \\ 0 & \Omega_2^2 & 0 & 0 \\ 0 & 0 & \Omega_3^2 & 0 \\ 0 & 0 & 0 & \Omega_4^2 \end{bmatrix} \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \end{bmatrix} \quad (4.2)$$

4.2. Descrição das falhas nos sensores

O sinal de controle é obtido em função das informações provenientes dos sensores, logo, caso alguma medição esteja distorcida por uma falha, o processo poderá continuar operando em um ponto distante do desejado e as variações

bruscas nas medições podem gerar variações também elevadas nos atuadores. Ni *et al.*, (2009) citaram e classificaram diferentes características ambientais, do sistema, e de dados que caracterizam as falhas nos sensores em geral. *Offset*, ruído, *outlier*, *spikes* e travamentos são alguns exemplos de comportamentos gerados pelas falhas.

Assim, neste trabalho, serão consideradas as falhas de sensores como falhas de medições, uma vez que algumas variáveis são medidas indiretamente, como as posições lineares e angulares, e relacionadas ao *offset* e à travamentos no projeto do filtro de Kalman. Ressalta-se que o termo “falha em sensor” terá significado igual a “falha na medição” nesta dissertação. O seu comportamento será descrito pela Equação (4.3) através do sinal f^s , tal que y^f é a representação generalizada de um sinal de medição com falhas.

$$y^f = y + f^s \quad (4.3)$$

O ruído de medição é considerado, com o objetivo do sistema em atenuá-lo ao invés de estimá-lo. *Outlier* e *spikes* geram variações instantâneas com magnitude significativa e correspondem a uma etapa anterior as estimações das falhas pelo filtro de Kalman. É de interesse apenas detectá-los, sendo isso possível por meio da definição de um intervalo em que os sinais de medição podem variar. Caso o sinal ultrapasse o limite máximo, o sistema sinalizará a presença dessas falhas e essa informação será transmitida ao estimador de estados, que não utilizará, nesse instante de tempo, o valor gerado pela medição, ou seja, a estimacão corresponderá apenas à etapa de predição, não havendo uma atualização pela medição.

4.3. Considerações iniciais para o projeto dos filtros de Kalman

O filtro de Kalman é um algoritmo utilizado extensivamente em diferentes áreas de controle, processamento de sinais, otimização, entre outros. Esse filtro é um estimador de estados ótimo definido pela minimização da variância do erro de estimacão e com otimização baseada em suposições gaussianas (GREWAL, ANDREWS, 2015). Permitindo assim, em conjunto com a sua facilidade de implementação, que o filtro se tornasse popular na detecção e diagnóstico de

falhas em processos estocásticos. De acordo com (RAHIMI, 2017), essa técnica tem proporcionado baixa taxa de alarmes falsos, pequeno atraso na detecção das falhas, robustez em relação às incertezas do modelo, isolamento de falhas com ocorrências simultâneas e a possibilidade de estimação das falhas.

4.3.1. Representação do modelo em espaço de estados

Nesta seção serão apresentados os modelos lineares e não lineares do quadricóptero no espaço de estados, os quais são necessários para o algoritmo do filtro de Kalman de acordo com a abordagem utilizada. As falhas dos atuadores e dos sensores serão incluídas de acordo com as Equações (4.1) e (4.2).

As Equações (4.4) e (4.5) representam o modelo não linear da aeronave incluindo as falhas nos atuadores e alterando o sinal de controle em função das Equações (2.3) e (2.4).

$$\begin{bmatrix} \ddot{x} \\ \ddot{y} \\ \ddot{z} \end{bmatrix} = -g \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} + \frac{\mathbf{RT}_z}{m} \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} - \frac{\mathbf{RT}_z \mathbf{U}}{m} \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \end{bmatrix} \quad (4.4)$$

$$\begin{bmatrix} \ddot{\Phi} \\ \ddot{\theta} \\ \ddot{\psi} \end{bmatrix} = \frac{d}{dt}(\mathbf{W}_n^{-1})\boldsymbol{\omega} + \mathbf{W}_n^{-1}\dot{\boldsymbol{\omega}} \quad (4.5)$$

Com:

$$\dot{\boldsymbol{\omega}} = \begin{bmatrix} \dot{p} \\ \dot{q} \\ \dot{r} \end{bmatrix} = \begin{bmatrix} \frac{(I_{yy} - I_{zz})qr}{I_{xx}} \\ \frac{(I_{zz} - I_{xx})pr}{I_{yy}} \\ \frac{(I_{xx} - I_{yy})pq}{I_{zz}} \end{bmatrix} - I_r \begin{bmatrix} q \\ I_{xx} \\ -p \\ I_{yy} \\ 0 \end{bmatrix} \bar{\boldsymbol{\Omega}} + \mathbf{IT}_\tau \begin{bmatrix} \Omega_1^2 \\ \Omega_2^2 \\ \Omega_3^2 \\ \Omega_4^2 \end{bmatrix} - \mathbf{IT}_\tau \mathbf{U} \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \end{bmatrix}$$

A partir das Equações (4.6) - (4.10), definem-se os seguintes vetores: dos estados do modelo do quadricóptero ($\mathbf{x}_e \in \mathbb{R}^n$), do sinal de entrada do sistema

($\mathbf{u}' \in \mathbb{R}^r$), de medição ($\mathbf{y} \in \mathbb{R}^m$), das falhas nos atuadores ($\mathbf{f}^a \in \mathbb{R}^p$) e das falhas nos sensores ($\mathbf{f}^s \in \mathbb{R}^q$).

$$\mathbf{x}_e = [x \ y \ z \ \dot{x} \ \dot{y} \ \dot{z} \ \Phi \ \theta \ \psi \ \dot{\Phi} \ \dot{\theta} \ \dot{\psi}]^T \quad (4.6)$$

$$\mathbf{y} = [x \ y \ z \ \dot{x} \ \dot{y} \ \dot{z} \ \Phi \ \theta \ \psi \ \dot{\Phi} \ \dot{\theta} \ \dot{\psi}]^T \quad (4.7)$$

$$\mathbf{u}' = [\Omega_1^2 \ \Omega_2^2 \ \Omega_3^2 \ \Omega_4^2]^T \quad (4.8)$$

$$\mathbf{f}^a = [\delta_1 \ \delta_2 \ \delta_3 \ \delta_4]^T \quad (4.9)$$

$$\mathbf{f}^s = [f^x \ f^y \ f^z \ f^{\dot{x}} \ f^{\dot{y}} \ f^{\dot{z}} \ f^{\Phi} \ f^{\theta} \ f^{\psi} \ f^{\dot{\Phi}} \ f^{\dot{\theta}} \ f^{\dot{\psi}}]^T \quad (4.10)$$

Portanto, obtém-se as equações não lineares de estados, Equação (4.11), e de observação, Equação (4.12). A função $f(\cdot)$ está associada às Equações (4.4) e (4.5). As variáveis \mathbf{w}^x e \mathbf{v} são os ruídos do processo e da medição, respectivamente, assumindo que ambos são ruídos brancos de média nula.

$$\dot{\mathbf{x}}_e = \mathbf{f}(\mathbf{x}_e, \mathbf{u}', \mathbf{f}^a) + \mathbf{w}^x \quad (4.11)$$

$$\mathbf{y} = \mathbf{h}(\mathbf{x}_e, \mathbf{u}, \mathbf{f}^s) + \mathbf{w}^y = \mathbf{x}_e + \mathbf{f}^s + \mathbf{v} \quad (4.12)$$

Para o caso linear, esse modelo é calculado através da expansão em séries de Taylor em torno do ponto de operação do quadricóptero ($\bar{\mathbf{x}}_e, \bar{\mathbf{u}}', \bar{\mathbf{f}}^s, \bar{\mathbf{f}}^a$), descartando os termos de ordem superior da expansão, Equações (4.13) - (4.16).

$$\mathbf{A} = \left. \frac{\partial \mathbf{f}(\mathbf{x}_e, \mathbf{u}', \mathbf{f}^a)}{\partial \mathbf{x}_e} \right|_{\mathbf{x}_e = \bar{\mathbf{x}}_e, \mathbf{u}' = \bar{\mathbf{u}}', \mathbf{f}^a = \bar{\mathbf{f}}^a} \quad (4.13)$$

$$\mathbf{B} = \left. \frac{\partial \mathbf{f}(\mathbf{x}_e, \mathbf{u}, \mathbf{f}^a)}{\partial \mathbf{u}} \right|_{\mathbf{x}_e = \bar{\mathbf{x}}_e, \mathbf{u}' = \bar{\mathbf{u}}', \mathbf{f}^a = \bar{\mathbf{f}}^a} \quad (4.14)$$

$$\mathbf{C} = \left. \frac{\partial \mathbf{h}(\mathbf{x}_e, \mathbf{u}, \mathbf{f}^s)}{\partial \mathbf{x}_e} \right|_{\mathbf{x}_e = \bar{\mathbf{x}}_e, \mathbf{u}' = \bar{\mathbf{u}}', \mathbf{f}^s = \bar{\mathbf{f}}^s} \quad (4.15)$$

$$\mathbf{E} = \left. \frac{\partial \mathbf{h}(\mathbf{x}_e, \mathbf{u}, \mathbf{f}^s)}{\partial \mathbf{f}^s} \right|_{\mathbf{x}_e = \bar{\mathbf{x}}_e, \mathbf{u}' = \bar{\mathbf{u}}', \mathbf{f}^s = \bar{\mathbf{f}}^s} \quad (4.16)$$

Pelas Equações (4.4) e (4.5), observa-se que as matrizes associadas ao sinal \mathbf{u}' são as mesmas de $\mathbf{U}^m \mathbf{f}^a$. Para adquirir informações continuamente do

signal de controle e aprimorar as estimações das falhas, a matriz U^m é associada a falha no momento da linearização e representa o valor do sinal de controle nesse instante. Por esse motivo, obtém-se a seguinte matriz linear e variante no tempo referente as falhas nos atuadores:

$$F = -BU^m \quad (4.17)$$

A Equação (4.18) define a representação em espaço de estados do modelo linear do quadricóptero.

$$\begin{cases} \dot{x}_e = Ax_e + Bu' + Ff^a + w^x \\ y = Cx_e + Ef^s + v \end{cases} \quad (4.18)$$

O filtro de Kalman utilizado será o discreto, o que impõe a necessidade de se discretizar as Equações (4.4), (4.5) e (4.18). Considerando a seguinte relação da derivada temporal e os estados discretos:

$$\dot{x}_e = \frac{x_{e,k+1} - x_{e,k}}{T_s} \quad (4.19)$$

Obtém-se os seguintes modelos não linear e linear discretos do sistema, em que I é a matriz identidade:

$$\begin{cases} x_{e,k+1} = x_{e,k} + T_s f(x_{e,k}, u'_k, f_k^a) + w_k^x \\ y_k = h(x_{e,k}, u'_k, f_k^s) + v_k = C_k x_{e,k} + E_k f_k^s + v_k \end{cases} \quad (4.20)$$

$$\begin{cases} x_{e,k+1} = A_k x_{e,k} + B_k u'_k + F_k f_k^a + w_k^x \\ y_k = C_k x_{e,k} + E_k f_k^s + v_k \end{cases} \quad (4.21)$$

Com:

$$A_k = I + T_s A, \quad B_k = T_s B, \quad F_k = T_s F, \quad C_k = C, \quad E_k = E$$

Para que o filtro de Kalman realize as estimações das falhas nos atuadores e nos sensores, é necessário incluir esses sinais no vetor de estados

do modelo, resultando no espaço de estados aumentado. Normalmente, as dinâmicas das falhas são desconhecidas, entretanto elas podem ser modeladas da seguinte maneira, com os seus respectivos sinais de ruído (XIAO *et al.*, 2017):

$$f_{k+1}^a = f_k^a + w_k^{fa} \quad (4.22)$$

$$f_{k+1}^s = f_k^s + w_k^{fs} \quad (4.23)$$

O artigo baseado neste trabalho (OKADA, 2021) empregou um sistema FDD híbrido de observadores e de redes neurais para a estimação de falhas. O sistema se mostrou eficaz na estimação de múltiplas falhas, com ocorrências simultâneas e de comportamento não linear utilizando o modelo das falhas da Equação (4.22).

Conseqüentemente, obtêm-se as seguintes representações em espaço de estados aumentado linear e não linear do quadricóptero, em que o caso não linear incluiu as Equações (4.22) e (4.23) no modelo:

$$\begin{cases} x_{e,k+1}^a = x_{e,k}^a + T_s f(x_{e,k}^a, u_k') + w_k^a \\ y_k = h(x_{e,k}^a, u_k') + v_k = C_k^a x_{e,k}^a + v_k \end{cases} \quad (4.24)$$

$$\begin{cases} x_{e,k+1}^a = A_k^a x_{e,k}^a + B_k^a u_k' + w_k^a \\ y_k = C_k^a x_{e,k}^a + v_k \end{cases} \quad (4.25)$$

Com:

$$A_k^a = \begin{bmatrix} A_k & F_k & \mathbf{0} \\ \mathbf{0} & I & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & I \end{bmatrix}, \quad B_k^a = \begin{bmatrix} B_k \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix}, \quad C_k^a = [C_k \quad \mathbf{0} \quad E_k]$$

$$x_{e,k+1}^a = [x_{e,k}^T \quad f_k^{aT} \quad f_k^{sT}]^T$$

$$w_k^a = [w_k^{xT} \quad w_k^{faT} \quad w_k^{fsT}]^T$$

4.3.2. Observabilidade

Um sistema linear e invariante no tempo é dito observável se qualquer valor inicial do estado pode ser obtido em função dos valores do sinal de controle e da saída mensurável para todo instante de tempo maior que zero (BROWN,

HWANG, 2012). Ainda, a observabilidade de um sistema define a capacidade do filtro de Kalman em poder estimar os seus estados.

Para o caso linear, é possível estabelecer a matriz de observabilidade (\mathbf{O}), indicada pela Equação (4.26), considerando a aeronave livre de falhas. O sistema só será observável, caso o posto dessa matriz seja igual ao número de estados.

$$\mathbf{O} = \begin{bmatrix} \mathbf{C}_k^{aT} & \mathbf{A}_k^{aT} \mathbf{C}_k^{aT} & \dots & (\mathbf{A}_k^{aT})^{n+p+q-1} \mathbf{C}_k^{aT} \end{bmatrix} \quad (4.26)$$

Observa-se que nesse caso, há a perda de posto e, portanto, o sistema não é observável. Por esse motivo, é necessário reduzir a quantidade de falhas que se deseja estimar. As falhas nos atuadores estão diretamente relacionadas ao sistema de controle, logo, não sofrerão modificações. Para o cenário das falhas nos sensores, optou-se, então, em retirar as variáveis das falhas nas medições das posições lineares e angulares.

Por conseguinte, como não haverá estimações dessas falhas, quando elas estiverem presentes nas medições, o filtro gerará falsos positivos nas demais estimações de falhas, ou seja, as medições de velocidade apresentarão como defeituosas. Devido às posições serem integrações das velocidades, na hipótese de haver a estimativa dessas variáveis ao invés das velocidades, o filtro integraria o sinal que contém a informação da falha ao longo do tempo, podendo levar o filtro à instabilidade. O contrário não ocorre, uma vez que as velocidades são derivações das posições. Portanto, caso haja uma falha na medição da posição com comportamento de *offset* do tipo degrau, por exemplo, haverá um *spike* na estimativa da velocidade correspondente.

Por esse motivo, define-se o novo vetor das falhas nos sensores como sendo:

$$\mathbf{f}^s = [f^{\dot{x}} \quad f^{\dot{y}} \quad f^{\dot{z}} \quad f^{\dot{\phi}} \quad f^{\dot{\theta}} \quad f^{\dot{\psi}}]^T \quad (4.27)$$

É também de interesse, levar em consideração as perturbações ocasionadas pelos ventos para que não gerem alarmes falsos nas estimativas das falhas. Essas perturbações agem no quadricóptero como forças, alterando

os estados do sistema de acordo com a sua magnitude e direção. Entretanto, devido aos problemas de observabilidade e como a prioridade é realizar estimações das falhas nos atuadores e nos sensores, não foi possível incluir essas variáveis no modelo aumentado do filtro.

Para os modelos não-lineares envolvendo outros pontos de operação além daquele utilizado para o caso linear, a análise de observabilidade é mais complexa. Entretanto, o quadricóptero é composto por medições de todas as variáveis de posição e velocidade linear e angular, o que caracteriza a melhor estrutura para a estimação das falhas em relação à observabilidade.

4.3.3. Variáveis associadas ao filtro de Kalman

O filtro de Kalman é aplicado em sistemas estocásticos, onde os estados são considerados como variáveis aleatórias gaussianas submetidos a ruídos brancos de média nula. Essa propriedade permite definir características estatísticas a essas variáveis, as quais serão descritas a seguir por serem parâmetros comuns a todas as abordagens do filtro.

O algoritmo do filtro é dividido em duas etapas: predição, associada ao cálculo do valor estimado baseado no modelo do sistema, ou valor *a priori*, o qual é denotado pelo subscrito $k|k-1$, e atualização, em que o valor *a priori* é atualizado pelo ganho do filtro em conjunto às medições, resultando no valor *a posteriori*, denotado por $k|k$.

- Estimações dos estados no instante k . Para valores iniciais, $k = 0$.

$$\hat{\mathbf{x}}_{e,k}^a = [\hat{\mathbf{x}}_{e,k} \quad \hat{\mathbf{f}}_k^a \quad \hat{\mathbf{f}}_k^s]^T \quad (4.28)$$

- Matriz de covariância dos ruídos do processo Q e do ruído de medição R . δ_{kj} é o delta de Kronecker, equivalendo a 1, se $k = j$, e nulo para os demais casos, e $E[.]$, o operador esperança. As matrizes Q_k^a , Q_k^x , Q_k^{fa} , Q_k^{fs} e R_k são positivas definidas.

$$E \left[\begin{bmatrix} \mathbf{w}_k^x \\ \mathbf{w}_k^{fa} \\ \mathbf{w}_k^{fs} \\ \mathbf{v}_k \end{bmatrix} \begin{bmatrix} \mathbf{w}_k^x \\ \mathbf{w}_k^{fa} \\ \mathbf{w}_k^{fs} \\ \mathbf{v}_k \end{bmatrix}^T \right] = \begin{bmatrix} Q_k^x & Q_k^{xfa} & Q_k^{xfs} & 0 \\ Q_k^{fax} & Q_k^{fa} & Q_k^{fafs} & 0 \\ Q_k^{fsx} & Q_k^{fsfa} & Q_k^{fs} & 0 \\ 0 & 0 & 0 & R_k \end{bmatrix} \delta_{kJ} = \begin{bmatrix} Q_k^a & 0 \\ 0 & R \end{bmatrix} \quad (4.29)$$

- Erro de estimação.

$$\tilde{\mathbf{x}}_{e,k}^a = \hat{\mathbf{x}}_{e,k}^a - \mathbf{x}_{e,k}^a \quad (4.30)$$

$$\tilde{\mathbf{x}}_{e,k} = \hat{\mathbf{x}}_{e,k} - \mathbf{x}_{e,k} \quad (4.31)$$

$$\tilde{\mathbf{f}}_k^a = \hat{\mathbf{f}}_k^a - \mathbf{f}_k^a \quad (4.32)$$

$$\tilde{\mathbf{f}}_k^s = \hat{\mathbf{f}}_k^s - \mathbf{f}_k^s \quad (4.33)$$

- Matriz de covariância do erro de estimação.

$$\mathbf{P}_k^a = \begin{bmatrix} \mathbf{P}_k^x & \mathbf{P}_k^{xfa} & \mathbf{P}_k^{xfs} \\ \mathbf{P}_k^{fax} & \mathbf{P}_k^{fa} & \mathbf{P}_k^{fafs} \\ \mathbf{P}_k^{fsa} & \mathbf{P}_k^{fsfa} & \mathbf{P}_k^{fs} \end{bmatrix} \quad (4.34)$$

- Ganho do filtro de Kalman.

$$\mathbf{K}_k^a = \begin{bmatrix} \mathbf{K}_k^x \\ \mathbf{K}_k^{fa} \\ \mathbf{K}_k^{fs} \end{bmatrix} \quad (4.35)$$

- Sinal de medição.

$$\mathbf{y}_{m,k}$$

4.4. Sistemas de detecção e diagnóstico de falhas

Neste trabalho serão consideradas três abordagens de filtro de Kalman (linear - KF, estendido - EKF, *unscented* - UKF) e duas variações para cada

abordagem (três estágios, TsKF, TsEKF, TsUKF, e adaptativo, ATsKF, ATsEKF, ATsUKF), totalizando nove filtros.

4.4.1. Filtro de Kalman

O algoritmo dessa abordagem do KF é apresentado na Tabela (4.1), em que a coluna a direita representa o número da sua etapa. A principal característica que deve ser ressaltada é o emprego do espaço de estados aumentado linear do quadricóptero.

Tabela 4.1 – Algoritmo do KF

Inicialização:	
$\hat{x}_{e,k}^a = E[x_{e,0}]$	1
$P_0^a = E[\tilde{x}_{e,0}^a \tilde{x}_{e,0}^{aT}]$	2
Predição:	
$\hat{x}_{e,k k+1}^a = A_{k-1}^a x_{e,k-1 k-1}^a + B_{k-1}^a u'_{k-1}$	3
$P_{k k-1}^a = A_{k-1}^a P_{k-1 k-1}^a A_{k-1}^{aT} + Q_{k-1}^a$	4
Atualização:	
$K_k^a = P_{k k-1}^a C_k^{aT} (C_k^a P_{k k-1}^a C_k^{aT} + R_k)^{-1}$	5
$\hat{x}_{e,k k}^a = \hat{x}_{e,k k+1}^a + K_k^a (y_{m,k} - C_k^a \hat{x}_{e,k k+1}^a)$	6
$P_{k k}^a = (I - K_k^a C_k^a) P_{k k-1}^a$	7

Fonte: Próprio autor

4.4.2. Filtro de Kalman Estendido

Um dos problemas do filtro de Kalman é a presença de não linearidades do modelo, que proporcionam comportamentos distintos dos estados em relação a versão linear, a qual é utilizada pelo filtro. Esse problema é intensificado na presença de estados com dinâmicas desconhecidas, no caso, as falhas (XIAO *et al.*, 2018).

Visando contornar esse problema, o EKF realiza linearizações do modelo não linear a cada instante de acordo com os valores atuais dos estados, o que provoca redução nos efeitos das não-linearidades (GREWAL, ANDREWS, 2015). O algoritmo do EKF é apresentado na Tabela (4.2).

Tabela 4.2 – Algoritmo do EKF

Inicialização:	
$\hat{x}_{e,k}^a = E[x_{e,0}]$	1
$P_0^a = E[\tilde{x}_{e,0}^a \tilde{x}_{e,0}^{aT}]$	2
Predição:	
$\hat{x}_{e,k k-1}^a = x_{e,k-1 k-1}^a + T_s f(x_{e,k-1 k-1}^a, u'_{k-1})$	3
$A_{k-1}^a = \left. \frac{\partial f(x_e^a, u')}{\partial x_e^a} \right _{\substack{x_e = \hat{x}_{e,k-1 k-1}^a \\ u' = u'_{k-1} \\ f^a = \hat{f}_{k-1 k-1}^a}}, C_k^a = \left. \frac{\partial h(x_e^a, u)}{\partial x_e^a} \right _{\substack{x_e = \hat{x}_{e,k k-1}^a \\ u' = u'_k \\ f^s = \hat{f}_{k k-1}^s}}$	4
$P_{k k-1}^a = A_{k-1}^a P_{k-1 k-1}^a A_{k-1}^{aT} + Q_{k-1}^a$	5
Atualização:	
$K_k^a = P_{k k-1}^a C_k^{aT} (C_k^a P_{k k-1}^a C_k^{aT} + R_k)^{-1}$	6
$\hat{x}_{e,k k}^a = \hat{x}_{e,k k-1}^a + K_k^a (y_{m,k} - C_k^a \hat{x}_{e,k k-1}^a)$	7
$P_{k k}^a = (I - K_k^a C_k^a) P_{k k-1}^a$	8

Fonte: Próprio autor

4.4.3. Filtro de Kalman Unscented

O filtro de Kalman estendido propaga analiticamente os estados no modelo linearizado com precisão até o primeiro momento. Contudo, essas aproximações podem introduzir erros significativos nos valores *a posteriori*, levando o filtro a uma condição subótima ou em condições mais severas, divergência nas estimações (LU *et al.*, 2014).

Diante disso, o UKF surge com a finalidade de reduzir as imprecisões geradas pela linearização por meio da transformada *unscented*. Sendo assim, os estados continuam sendo representados por variáveis aleatórias gaussianas. Entretanto, há a seleção de amostras, os pontos sigma, que capturam a verdadeira média e covariância da distribuição gaussiana dos estados e que são propagadas no modelo não linear do sistema, ao invés do modelo aproximado via linearização (BROWN, HWANG, 2012). Isso permite obter precisões da média e covariância a posteriores até o terceiro momento da expansão em série

de Taylor. O algoritmo do filtro é apresentado na Tabela (4.3), tal que n^a é a quantidade de estados do sistema aumentado.

Tabela 4.3 – Algoritmo do UKF

Inicialização:	
$\hat{\mathbf{x}}_{e,k}^a = E[\mathbf{x}_{e,0}]$	1
$\mathbf{P}_0^a = E[\tilde{\mathbf{x}}_{e,0}^a \tilde{\mathbf{x}}_{e,0}^{a T}]$	2
Predição:	
$\chi_{k-1 k-1,0}^a = \hat{\mathbf{x}}_{e,k-1 k-1}^a$	
$\chi_{k-1 k-1,i}^a = \hat{\mathbf{x}}_{e,k-1 k-1}^a - \left(\sqrt{(n^a + \lambda) \mathbf{P}_{k-1 k-1}^a} \right)_i, i = 1, \dots, n^a$	3
$\chi_{k-1 k-1,i+n^a}^a = \hat{\mathbf{x}}_{e,k-1 k-1}^a + \left(\sqrt{(n^a + \lambda) \mathbf{P}_{k-1 k-1}^a} \right)_i, i = 1, \dots, n^a$	
$\lambda = \alpha^2(n^a + \kappa) - n^a$	4
$1e^{-4} \leq \alpha \leq 1$	5
$0 \leq \kappa \leq 3 - n^a$	6
$\chi_{k k-1,i}^a = \chi_{k-1 k-1,i}^a + T_s \mathbf{f}(\chi_{k-1 k-1,i}^a, \mathbf{u}'_{k-1})$	7
$\hat{\mathbf{x}}_{e,k k-1}^a = \sum_{i=0}^{2n^a} \omega_i^{(m)} \chi_{k k-1,i}^a$	8
$\mathbf{P}_{k k-1}^a = \sum_{i=0}^{2n^a} \omega_i^{(c)} [\chi_{k k-1,i}^a - \hat{\mathbf{x}}_{e,k k-1}^a] [\chi_{k k-1,i}^a - \hat{\mathbf{x}}_{e,k k-1}^a]^T + \mathbf{Q}_{k-1}^a$	9
$\omega_0^{(m)} = \frac{\lambda}{n^a + \lambda}$	10
$\omega_0^{(c)} = \frac{\lambda}{n^a - \lambda} + (1 + \alpha^2 + \beta)$	11
$\omega_i^{(m)} = \omega_i^{(c)} = \frac{\lambda}{2(n^a + \lambda)}$	12
$\beta = 2$	13
$\chi_{k k-1,0}^a = \hat{\mathbf{x}}_{e,k k-1}^a$	
$\chi_{k k-1,i}^a = \hat{\mathbf{x}}_{e,k k-1}^a - \left(\sqrt{(n^a + \lambda) \mathbf{P}_{k k-1}^a} \right)_i, i = 1, \dots, n^a$	14
$\chi_{k k-1,i+n^a}^a = \hat{\mathbf{x}}_{e,k k-1}^a + \left(\sqrt{(n^a + \lambda) \mathbf{P}_{k k-1}^a} \right)_i, i = 1, \dots, n^a$	
$\gamma_{k k-1,i}^a = \mathbf{h}(\chi_{k k-1,i}^a, \mathbf{u}'_k)$	15

$$\mathbf{y}_{k|k-1}^a = \sum_{i=0}^{2n^a} \omega_i^{(m)} \mathbf{y}_{k|k-1,i}^a \quad 16$$

Atualização:

$$\mathbf{P}_{xy}^a = \sum_{i=0}^{2n^a} \omega_i^{(c)} [\mathbf{x}_{k|k-1,i}^a - \hat{\mathbf{x}}_{e,k|k-1}^a] [\mathbf{y}_{k|k-1,i}^a - \mathbf{y}_{k|k-1}^a]^T \quad 17$$

$$\mathbf{P}_{yy}^a = \sum_{i=0}^{2n^a} \omega_i^{(c)} [\mathbf{y}_{k|k-1,i}^a - \mathbf{y}_{k|k-1}^a] [\mathbf{y}_{k|k-1,i}^a - \mathbf{y}_{k|k-1}^a]^T + \mathbf{R}_k \quad 18$$

$$\mathbf{K}_k^a = \mathbf{P}_{xy}^a (\mathbf{P}_{yy}^a)^{-1} \quad 19$$

$$\hat{\mathbf{x}}_{e,k|k}^a = \hat{\mathbf{x}}_{e,k|k-1}^a + \mathbf{K}_k^a (\mathbf{y}_{m,k} - \mathbf{y}_{k|k-1}^a) \quad 20$$

$$\mathbf{P}_{k|k}^a = \mathbf{P}_{k|k-1}^a - \mathbf{K}_k^a \mathbf{P}_{yy}^a (\mathbf{K}_k^a)^T \quad 21$$

Fonte: Próprio autor

No algoritmo do UKF da Tabela (4.3), as etapas 3 e 7 estão associadas ao cálculo dos pontos sigma e as etapas 4 e 8 relacionadas à propagação desses pontos nas funções não-lineares do sistema. As constantes λ , α , κ e β são calculadas ou selecionadas de acordo com o intervalo apresentado no algoritmo. Sendo $\beta = 2$, o valor ótimo para distribuições gaussianas.

4.4.4. Filtro de Kalman em Três Estágios

O sistema em espaço de estados aumentado é necessário para que haja a estimação das falhas nos atuadores e nos sensores. Todavia, uma desvantagem no uso desse modelo é o aumento drástico do custo computacional em função do aumento do número de estados (HMIDA *et al.*, 2012). Esse fato é expressivo, neste trabalho, devido a inclusão de 4 falhas em atuadores e 6 falhas de medições, sendo quase equivalente ao número de estados referentes às dinâmicas do quadricóptero.

Uma das maneiras de reduzir o custo computacional é através do uso da abordagem em três estágios, a qual desacopla o filtro de Kalman em três subfiltros. Um subfiltro estará associado à estimação dos estados das dinâmicas da aeronave, o segundo às falhas nos atuadores e o terceiro às falhas nos sensores. Hmida *et al.*, 2012, compararam o custo computacional do filtro de

Kalman em três estágios e a versão aumentada. Para isso, utilizaram a quantidade total de operações envolvendo multiplicações e somas de cada algoritmo como critério de análise. Como resultado, houve uma redução de aproximadamente 10% dessas operações no filtro em três estágios para um sistema de apenas 3 estados e 2 falhas.

O aparecimento de três sub filtros ocorre por meio da aplicação da transformada U-V, Equações (4.36) - (4.40), sendo U e V matrizes representadas pelas Equações (4.41) e (4.42), respectivamente.

$$\hat{\mathbf{x}}_{e,k|k-1}^a = \mathbf{U}_k \bar{\mathbf{x}}_{e,k|k-1}^a \quad (4.36)$$

$$\mathbf{P}_{k|k-1}^a = \mathbf{U}_k \bar{\mathbf{P}}_{k|k-1}^a (\mathbf{U}_k)^T \quad (4.37)$$

$$\hat{\mathbf{x}}_{e,k|k}^a = \mathbf{V}_k \bar{\mathbf{x}}_{e,k|k}^a \quad (4.38)$$

$$\mathbf{P}_{k|k}^a = \mathbf{V}_k \bar{\mathbf{P}}_{k|k}^a (\mathbf{V}_k)^T \quad (4.39)$$

$$\mathbf{K}_k^a = \mathbf{V}_k \bar{\mathbf{K}}_k^a \quad (4.40)$$

$$\mathbf{U}_k = \begin{bmatrix} \mathbf{I} & \mathbf{U}_k^{12} & \mathbf{U}_k^{13} \\ \mathbf{0} & \mathbf{I} & \mathbf{U}_k^{23} \\ \mathbf{0} & \mathbf{0} & \mathbf{I} \end{bmatrix} \quad (4.41)$$

$$\mathbf{V}_k = \begin{bmatrix} \mathbf{I} & \mathbf{V}_k^{12} & \mathbf{V}_k^{13} \\ \mathbf{0} & \mathbf{I} & \mathbf{V}_k^{23} \\ \mathbf{0} & \mathbf{0} & \mathbf{I} \end{bmatrix} \quad (4.42)$$

A transformação U-V pode ser aplicada para o KF, EKF e UKF. Ressalta-se que essa abordagem pode ser utilizada em sistemas em que as falhas nos atuadores também estão acopladas às equações de observação e as falhas nos sensores, às equações de estado, como em (HMIDA *et al.*, 2012). Como esse não é o caso deste trabalho, a Tabela (4.4) apresenta o algoritmo do KF em três estágios adaptado ao caso do quadricóptero e das falhas consideradas.

Tabela 4.4 – Algoritmo do TsKF

Inicialização:	
$\mathbf{V}_0^{13} = \mathbf{P}_0^{xfs} (\mathbf{P}_0^{fs})^{-1}$	1
$\mathbf{V}_0^{23} = \mathbf{P}_0^{bfs} (\mathbf{P}_0^{fs})^{-1}$	2

$$V_0^{12} = \left[P_0^{xfa} - V_0^{13} P_0^{fs} (V_0^{23})^T \right] \left[P_0^{fa} - V_0^{23} P_0^{fs} (V_0^{23})^T \right]^{-1} \quad 3$$

$$\bar{f}_{0|0}^s = \hat{f}_0^s \quad 4$$

$$\bar{f}_{0|0}^a = \hat{f}_0^a - V_0^{23} \bar{f}_{0|0}^s \quad 5$$

$$\bar{x}_{e,0|0} = \hat{x}_{e,0} - V_0^{12} \bar{f}_{0|0}^a - V_0^{13} \bar{f}_{0|0}^s \quad 6$$

$$\bar{P}_{0|0}^{fs} = P_0^{fs} \quad 7$$

$$\bar{P}_{0|0}^{fa} = P_0^{fa} - V_0^{23} \bar{P}_{0|0}^{fa} (V_0^{23})^T \quad 8$$

$$\bar{P}_{0|0}^x = P_0^x - V_0^{12} \bar{P}_{0|0}^{fa} (V_0^{12})^T - V_0^{13} \bar{P}_{0|0}^{fs} (V_0^{13})^T \quad 9$$

Cálculo de parâmetros da transformação:

$$\bar{U}_k^{12} = A_{k-1} V_{k-1}^{12} + F_{k-1} \quad 10$$

$$\bar{U}_k^{13} = A_{k-1} V_{k-1}^{13} + F_{k-1} V_{k-1}^{23} \quad 11$$

$$\bar{U}_k^{23} = V_{k-1}^{23} \quad 12$$

$$\bar{P}_{k|k-1}^{fs} = \bar{P}_{k-1|k-1}^{fs} + Q_{k-1}^{fs} \quad 13$$

$$U_k^{13} = \left(\bar{U}_k^{13} \bar{P}_{k-1|k-1}^{fs} + Q_{k-1}^{xfs} \right) \left(\bar{P}_{k|k-1}^{fs} \right)^{-1} \quad 14$$

$$U_k^{23} = \left(\bar{U}_k^{23} \bar{P}_{k-1|k-1}^{fs} + Q_{k-1}^{fafs} \right) \left(\bar{P}_{k|k-1}^{fs} \right)^{-1} \quad 15$$

$$\bar{Q}_{k-1}^2 = Q_{k-1}^{fa} + \bar{U}_k^{23} \bar{P}_{k-1|k-1}^{fs} \bar{U}_k^{23T} - U_k^{23} \bar{P}_{k|k-1}^{fs} U_k^{23T} \quad 16$$

$$\bar{P}_{k|k-1}^{fa} = \bar{P}_{k-1|k-1}^{fa} + \bar{Q}_{k-1}^2 \quad 17$$

$$U_k^{12} = \left(\bar{U}_k^{12} \bar{P}_{k-1|k-1}^{fa} + \bar{U}_k^{13} \bar{P}_{k-1|k-1}^{fs} \bar{U}_k^{23T} - U_k^{13} \bar{P}_{k|k-1}^{fs} U_k^{13T} + Q_{k-1}^{xfa} \right) \left(\bar{P}_{k|k-1}^{fa} \right)^{-1} \quad 18$$

$$\bar{Q}_{k-1}^1 = \left(\begin{array}{l} Q_{k-1}^x + \bar{U}_k^{12} \bar{P}_{k-1|k-1}^{fa} \bar{U}_k^{12T} + U_k^{12} \bar{P}_{k|k-1}^{fa} U_k^{12T} + \\ + \bar{U}_k^{13} \bar{P}_{k-1|k-1}^{fs} \bar{U}_k^{13T} - U_k^{13} \bar{P}_{k|k-1}^{fs} U_k^{13T} \end{array} \right) \quad 19$$

$$\bar{u}_{k-1}^1 = (\bar{U}_k^{12} - U_k^{12}) \bar{f}_{k-1|k-1}^a + [\bar{U}_k^{13} - \bar{U}_k^{13} - U_k^{12} (\bar{U}_k^{23} - U_k^{23})] \bar{f}_{k-1|k-1}^s \quad 20$$

$$\bar{u}_{k-1}^2 = (\bar{U}_k^{23} - U_k^{23}) \bar{f}_{k-1|k-1}^s \quad 21$$

$$S_k^1 = C_k \quad 22$$

$$S_k^2 = C_k U_k^{12} \quad 23$$

$$S_k^3 = C_k U_k^{13} + E_k \quad 24$$

Sub filtro dos estados:

$$\bar{x}_{e,k|k-1} = A_{k-1} \bar{x}_{e,k-1|k-1} + B_{k-1} u'_{k-1} + \bar{u}_{k-1}^1 \quad 26$$

$$\bar{P}_{k|k-1}^x = A_{k-1} \bar{P}_{k-1|k-1}^x A_{k-1}^T + \bar{Q}_{k-1}^1 \quad 27$$

$\bar{K}_k^x = \bar{P}_{k k-1}^x S_k^{1T} \left(S_k^1 \bar{P}_{k k-1}^x S_k^{1T} + R_k \right)^{-1}$	28
$\bar{x}_{e,k k} = \bar{x}_{e,k k-1} + \bar{K}_k^x (y_{m,k} - S_k^1 \bar{x}_{e,k k-1})$	29
$\bar{P}_{k k}^x = (I - \bar{K}_k^x S_k^1) \bar{P}_{k k-1}^x$	30
Sub filtro das falhas nos atuadores:	
$\bar{f}_{k k-1}^a = \bar{f}_{k-1 k-1}^a + \bar{u}_{k-1}^2$	31
$\bar{K}_k^{fa} = \bar{P}_{k k-1}^{fa} S_k^{2T} \left(S_k^2 \bar{P}_{k k-1}^{fa} S_k^{2T} + S_k^1 \bar{P}_{k k-1}^x S_k^{1T} + R_k \right)^{-1}$	32
$\bar{f}_{k k}^a = \bar{f}_{k k-1}^a + \bar{K}_k^{fa} (y_{m,k} - S_k^1 \bar{x}_{e,k k-1} - S_k^2 \bar{f}_{k k-1}^a)$	33
$\bar{P}_{k k}^{fa} = (I - \bar{K}_k^{fa} S_k^2) \bar{P}_{k k-1}^{fa}$	34
Sub filtro das falhas dos sensores:	
$\bar{f}_{k k-1}^s = \bar{f}_{k-1 k-1}^s$	35
$\bar{K}_k^{fs} = \bar{P}_{k k-1}^{fs} S_k^{3T} \left(S_k^3 \bar{P}_{k k-1}^{fa} S_k^{3T} + S_k^2 \bar{P}_{k k-1}^{fa} S_k^{2T} + S_k^1 \bar{P}_{k k-1}^x S_k^{1T} + R_k \right)$	36
$\bar{f}_{k k}^s = \bar{f}_{k k-1}^s + \bar{K}_k^{fs} (y_{m,k} - S_k^1 \bar{x}_{e,k k-1} - S_k^2 \bar{f}_{k k-1}^a - S_k^3 \bar{f}_{k k-1}^s)$	37
$\bar{P}_{k k}^{fs} = (I - \bar{K}_k^{fs} S_k^3) \bar{P}_{k k-1}^{fs}$	38
Correção dos estados e das falhas:	
$V_k^{12} = U_k^{12} - \bar{K}_k^x S_k^2$	39
$V_k^{13} = U_k^{13} - V_k^{12} \bar{K}_k^{fa} S_k^3 - \bar{K}_k^x S_k^3$	40
$V_k^{23} = U_k^{23} - \bar{K}_k^{fa} S_k^3$	41
$\hat{x}_{e,k k} = \bar{x}_{e,k k} + V_k^{12} \bar{f}_{k k}^a + V_k^{13} \bar{f}_{k k}^s$	42
$\hat{f}_{k k}^a = \bar{f}_{k k}^a + V_k^{23} \bar{f}_{k k}^s$	43
$\hat{f}_{k k}^s = \bar{f}_{k k}^s$	44
$P_{k k}^x = \bar{P}_{k k}^x + V_k^{12} \bar{P}_{k k}^{fa} V_k^{12T} + V_k^{13} \bar{P}_{k k}^{fs} V_k^{13T}$	45
$P_{k k}^{fa} = \bar{P}_{k k}^{fa} + V_k^{23} \bar{P}_{k k}^{fs} V_k^{23T}$	46
$P_{k k}^{fs} = \bar{P}_{k k}^{fs}$	47

Fonte: Próprio autor

Para o caso do TsEKF (XIAO *et al.*, 2018), modifica-se o algoritmo da Tabela (4.4) da seguinte maneira:

- calcula-se as matrizes do espaço de estado linear por meio da expansão em série de Taylor e em função do ponto de operação atual do quadricóptero antes da etapa 10 da tabela;
- a etapa 26 é alterada pela Equação (4.43), em que o estado (nesse caso) é propagado na função não linear do modelo.

$$\bar{\mathbf{x}}_{e,k|k-1} = \mathbf{A}_{k-1}\bar{\mathbf{x}}_{e,k-1|k-1} + \mathbf{f}_{k-1}^*(\cdot) + \bar{\mathbf{u}}_{k-1}^1 \quad (4.43)$$

$$\mathbf{f}_{k-1}^*(\cdot) = \begin{pmatrix} \hat{\mathbf{x}}_{e,k-1|k-1} + T_s \mathbf{f}(\hat{\mathbf{x}}_{e,k-1|k-1}, \hat{\mathbf{f}}_{k-1|k-1}^a, \mathbf{u}'_{k-1}) - \\ + \mathbf{A}_{k-1}\hat{\mathbf{x}}_{e,k-1|k-1} - \mathbf{F}_{k-1}\hat{\mathbf{f}}_{k-1|k-1}^a \end{pmatrix}$$

A versão do UKF em três estágios, TsUKF (XIAO *et al.*, 2017), adaptado ao modelo do quadricóptero é apresentada na Tabela (4.5).

Tabela 4.5 – Algoritmo do TsUKF

Inicialização:	
$\mathbf{V}_0^{13} = \mathbf{P}_0^{xfs} (\mathbf{P}_0^{fs})^{-1}$	1
$\mathbf{V}_0^{23} = \mathbf{P}_0^{fafs} (\mathbf{P}_0^{fs})^{-1}$	2
$\mathbf{V}_0^{12} = \left[\mathbf{P}_0^{xfa} - \mathbf{V}_0^{13} \mathbf{P}_0^{fs} (\mathbf{V}_0^{23})^T \right] \left[\mathbf{P}_0^{fa} - \mathbf{V}_0^{23} \mathbf{P}_0^{fs} (\mathbf{V}_0^{23})^T \right]^{-1}$	3
$\bar{\mathbf{f}}_{0 0}^s = \hat{\mathbf{f}}_0^s$	4
$\bar{\mathbf{f}}_{0 0}^a = \hat{\mathbf{f}}_0^a - \mathbf{V}_0^{23} \bar{\mathbf{f}}_{0 0}^s$	5
$\bar{\mathbf{x}}_{e,0 0} = \hat{\mathbf{x}}_{e,0} - \mathbf{V}_0^{12} \bar{\mathbf{f}}_{0 0}^a - \mathbf{V}_0^{13} \bar{\mathbf{f}}_{0 0}^s$	6
$\bar{\mathbf{P}}_{0 0}^{fs} = \mathbf{P}_0^{fs}$	7
$\bar{\mathbf{P}}_{0 0}^{fa} = \mathbf{P}_0^{fa} - \mathbf{V}_0^{23} \bar{\mathbf{P}}_{0 0}^{fa} (\mathbf{V}_0^{23})^T$	8
$\bar{\mathbf{P}}_{0 0}^x = \mathbf{P}_0^x - \mathbf{V}_0^{12} \bar{\mathbf{P}}_{0 0}^{fa} (\mathbf{V}_0^{12})^T - \mathbf{V}_0^{13} \bar{\mathbf{P}}_{0 0}^{fs} (\mathbf{V}_0^{13})^T$	9
Predição:	
$\bar{\mathbf{P}}_{k k-1}^{fs} = \bar{\mathbf{P}}_{k-1 k-1}^{fs} + \mathbf{Q}_{k-1}^{fs}$	10
$\mathbf{U}_k^{23} = \left(\mathbf{V}_{k-1}^{23} \bar{\mathbf{P}}_{k-1 k-1}^{fs} + \mathbf{Q}_{k-1}^{fafs} \right) \left(\bar{\mathbf{P}}_{k k-1}^{fs} \right)^{-1}$	11
$\bar{\mathbf{Q}}_{k-1}^2 = \mathbf{Q}_{k-1}^{fa} + \mathbf{V}_{k-1}^{23} \bar{\mathbf{P}}_{k-1 k-1}^{fs} \mathbf{V}_{k-1}^{23}{}^T - \mathbf{U}_k^{23} \bar{\mathbf{P}}_{k k-1}^{fs} \mathbf{U}_k^{23}{}^T$	12

$$\bar{\mathbf{P}}_{k|k-1}^{fa} = \bar{\mathbf{P}}_{k-1|k-1}^{fa} + \bar{\mathbf{Q}}_{k-1}^2 \quad 13$$

$$\lambda = \alpha^2(n^a + \kappa) - n^a \quad 14$$

$$1e^{-4} \leq \alpha \leq 1 \quad 15$$

$$0 \leq \kappa \leq 3 - n^a \quad 16$$

$$\bar{\chi}_{k-1|k-1,0}^a = \bar{x}_{k-1|k-1}^a$$

$$\bar{\chi}_{k-1|k-1,i}^a = \bar{x}_{k-1|k-1}^a - \left(\sqrt{(n^a + \lambda) \bar{\mathbf{P}}_{k-1|k-1}^a} \right)_i, i = 1, \dots, n^a$$

$$\bar{\chi}_{k-1|k-1,i+n^a}^a = \bar{x}_{k-1|k-1}^a + \left(\sqrt{(n^a + \lambda) \bar{\mathbf{P}}_{k-1|k-1}^a} \right)_i, i = 1, \dots, n^a \quad 17$$

$$\bar{\chi}_{(\cdot),i}^a = \begin{bmatrix} \bar{x}_{(\cdot),i} \\ \bar{f}_{(\cdot),i}^a \\ \bar{f}_{(\cdot),i}^s \end{bmatrix}, \bar{\mathbf{P}}_{(\cdot)}^a = \begin{bmatrix} \bar{\mathbf{P}}_{(\cdot)}^x & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \bar{\mathbf{P}}_{(\cdot)}^{fa} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \bar{\mathbf{P}}_{(\cdot)}^{fs} \end{bmatrix}$$

$$\bar{\chi}_{k-1|k-1,i}^{a,p} = \bar{x}_{e,k-1|k-1,i} + V_{k-1}^{12} \bar{f}_{k-1|k-1,i}^a + V_{k-1}^{13} \bar{f}_{k-1|k-1,i}^s \quad 18$$

$$\mathbf{f}_{k-1,i}^*(\cdot) = \mathbf{f}_{k-1}^* \left(\bar{\chi}_{k-1|k-1,i}^{a,p}, \mathbf{u}'_{k-1}, \hat{\mathbf{f}}_{k-1|k-1}^a, \bar{\mathbf{f}}_{k-1|k-1}^s \right) \quad 19$$

$$\mathbf{f}_{k-1,i}^*(\cdot) = \left(\bar{\chi}_{k-1|k-1,i}^{a,p} + T_s \mathbf{f} \left(\bar{\chi}_{k-1|k-1,i}^{a,p}, \mathbf{u}'_{k-1}, \hat{\mathbf{f}}_{k-1|k-1}^a, \bar{\mathbf{f}}_{k-1|k-1}^s \right) - \right. \\ \left. + \mathbf{F}_{k-1} \hat{\mathbf{f}}_{k-1|k-1}^a \right) \quad 20$$

$$\bar{\chi}_{k|k-1,i}^a = \begin{bmatrix} \mathbf{f}_{k-1,i}^*(\cdot) \\ \bar{f}_{k-1|k-1,i}^a + (V_{k-1}^{23} - U_k^{23}) \bar{f}_{k-1|k-1,i}^s \\ \bar{f}_{k-1|k-1,i}^s \end{bmatrix} \quad 21$$

$$\omega_0^{(m)} = \frac{\lambda}{n^a + \lambda} \quad 22$$

$$\omega_0^{(c)} = \frac{\lambda}{n^a - \lambda} + (1 + \alpha^2 + \beta) \quad 23$$

$$\omega_i^{(m)} = \omega_i^{(c)} = \frac{\lambda}{2(n^a + \lambda)} \quad 24$$

$$\beta = 2 \quad 25$$

$$\mathbf{f}_{k-1}^*(\cdot) = \sum_{i=0}^{2n^a} \omega_i^{(m)} \mathbf{f}_{k-1,i}^*(\cdot) \quad 26$$

$$\bar{\chi}_{k|k-1}^{a,t} = \begin{bmatrix} \mathbf{f}_{k-1}^*(\cdot) \\ \bar{f}_{k-1|k-1}^a + (V_{k-1}^{23} - U_k^{23}) \bar{f}_{k-1|k-1}^s \\ \bar{f}_{k-1|k-1}^s \end{bmatrix} \quad 27$$

$$U_k^{13} = \left(\sum_{i=0}^{2n^a} \omega_i^{(c)} [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] [\bar{f}_{k-1|k-1,i}^s - \bar{f}_{k-1|k-1}^s]^T + \right. \\ \left. + (F_{k-1} V_k^{23}) \bar{P}_{k-1|k-1}^{fs} + Q_{k-1}^{xfs} \right) (\bar{P}_{k|k-1}^{fs})^{-1} \quad 28$$

$$U_k^{12} = \left(\sum_{i=0}^{2n^a} \omega_i^{(c)} [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] [\bar{f}_{k-1|k-1,i}^a - \bar{f}_{k-1|k-1}^a]^T + \right. \\ \left. + \sum_{i=0}^{2n^a} \omega_i^{(c)} [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] [\bar{f}_{k-1|k-1,i}^s - \bar{f}_{k-1|k-1}^s]^T (V_{k-1}^{23})^T + \right) (\bar{P}_{k|k-1}^{fa}) \\ \left. + F_{k-1} \bar{P}_{k-1|k-1}^{fa} + (F_{k-1} V_{k-1}^{23}) \bar{P}_{k-1|k-1}^{fs} (V_{k-1}^{23})^T - \right. \\ \left. + U_k^{13} \bar{P}_{k|k-1}^{fs} (U_k^{23})^T + Q_{k-1}^{xfa} \right) \quad 29$$

$$\bar{P}_{k|k-1}^x = \left(\sum_{i=0}^{2n^a} \omega_i^{(c)} [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] + \right. \\ \left. + \sum_{i=0}^{2n^a} \omega_i^{(c)} [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] [\bar{f}_{k-1|k-1,i}^a - \bar{f}_{k-1|k-1}^a]^T (F_{k-1})^T + \right. \\ \left. + \sum_{i=0}^{2n^a} \omega_i^{(c)} [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)] [\bar{f}_{k-1|k-1,i}^s - \bar{f}_{k-1|k-1}^s]^T (F_{k-1} V_{k-1}^{23})^T + \right. \\ \left. + \sum_{i=0}^{2n^a} \omega_i^{(c)} F_{k-1} [\bar{f}_{k-1|k-1,i}^a - \bar{f}_{k-1|k-1}^a] [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)]^T + \right. \\ \left. + \sum_{i=0}^{2n^a} \omega_i^{(c)} (F_{k-1} V_{k-1}^{23}) [\bar{f}_{k-1|k-1,i}^s - \bar{f}_{k-1|k-1}^s] [f_{k-1,i}^*(\cdot) - f_{k-1}^*(\cdot)]^T + \right. \\ \left. + F_{k-1} \bar{P}_{k-1|k-1}^{fa} (F_{k-1})^T + (F_{k-1} V_{k-1}^{23}) \bar{P}_{k-1|k-1}^{fs} (F_{k-1} V_{k-1}^{23})^T - \right. \\ \left. + U_k^{12} \bar{P}_{k-1|k-1}^{fa} (U_k^{12})^T - U_k^{13} \bar{P}_{k|k-1}^{fs} (U_k^{13})^T + Q_{k-1}^x \right) \quad 30$$

$$\bar{x}_{k|k-1}^a \\ = \begin{bmatrix} f_{k-1}^*(\cdot) + (F_{k-1} - U_k^{12}) \bar{f}_{k-1|k-1}^a + [(F_{k-1} - U_k^{12}) V_k^{23} + U_k^{12} U_k^{23} - U_k^{13}] \bar{f}_{k-1|k-1}^s \\ \bar{f}_{k-1|k-1}^a + (V_{k-1}^{23} - U_k^{23}) \bar{f}_{k-1|k-1}^s \\ \bar{f}_{k-1|k-1}^s \end{bmatrix} \quad 31$$

$$\bar{x}_{k|k-1,0}^a = \bar{x}_{k|k-1}^a \\ \bar{x}_{k|k-1,i}^a = \bar{x}_{k|k-1}^a - \left(\sqrt{(n^a + \lambda) \bar{P}_{k|k-1}^a} \right)_i, i = 1, \dots, n^a \\ \bar{x}_{k|k-1,i+n^a}^a = \bar{x}_{k|k-1}^a + \left(\sqrt{(n^a + \lambda) \bar{P}_{k|k-1}^a} \right)_i, i = 1, \dots, n^a \quad 32$$

$$h_{k,i}^*(\cdot) = h(\bar{x}_{e,k|k-1,i}, \mathbf{u}'_{k-1}, \bar{f}_{k|k-1}^s) - E_{k-1} \bar{f}_{k|k-1}^s \quad 33$$

$$\bar{\mathbf{y}}_{k|k-1}^a = \mathbf{h}_{k,i}^*(\cdot) \quad 34$$

$$\bar{\mathbf{y}}_{k|k-1}^a = \sum_{i=0}^{2n^a} \omega_i^{(m)} \bar{\mathbf{y}}_{k|k-1}^a \quad 35$$

$$\bar{\mathbf{P}}_{xy} = \sum_{i=0}^{2n^a} \omega_i^{(c)} [\bar{\mathbf{x}}_{e,k|k-1,i} - \bar{\mathbf{x}}_{e,k|k-1}] [\bar{\mathbf{y}}_{k|k-1,i}^a - \bar{\mathbf{y}}_{k|k-1}^a]^T \quad 36$$

$$\bar{\mathbf{P}}_{yy} = \sum_{i=0}^{2n^a} \omega_i^{(c)} [\bar{\mathbf{y}}_{k|k-1,i}^a - \bar{\mathbf{y}}_{k|k-1}^a] [\bar{\mathbf{y}}_{k|k-1,i}^a - \bar{\mathbf{y}}_{k|k-1}^a]^T + \mathbf{R}_k \quad 37$$

$$\mathbf{S}_k^2 = \mathbf{C}_k \mathbf{U}_k^{12} \quad 38$$

$$\mathbf{S}_k^3 = \mathbf{C}_k \mathbf{U}_k^{13} + \mathbf{E}_k \quad 39$$

Atualização:

$$\bar{\mathbf{K}}_k^x = \bar{\mathbf{P}}_{xy} (\bar{\mathbf{P}}_{yy})^{-1} \quad 40$$

$$\bar{\mathbf{K}}_k^{fa} = \bar{\mathbf{P}}_{k|k-1}^{fa} \mathbf{S}_k^{2T} (\bar{\mathbf{P}}_{yy} + \mathbf{S}_k^2 \bar{\mathbf{P}}_{k|k-1}^{fa} \mathbf{S}_k^{2T})^{-1} \quad 41$$

$$\bar{\mathbf{K}}_k^{fs} = \bar{\mathbf{P}}_{k|k-1}^{fs} \mathbf{S}_k^{3T} (\bar{\mathbf{P}}_{yy} + \mathbf{S}_k^2 \bar{\mathbf{P}}_{k|k-1}^{fa} \mathbf{S}_k^{2T} + \mathbf{S}_k^3 \bar{\mathbf{P}}_{k|k-1}^{fs} \mathbf{S}_k^{3T})^{-1} \quad 42$$

$$\bar{\mathbf{x}}_{e,k|k} = \bar{\mathbf{x}}_{e,k|k-1} + \bar{\mathbf{K}}_k^x (\mathbf{y}_{m,k} - \bar{\mathbf{y}}_{k|k-1}^a) \quad 43$$

$$\bar{\mathbf{f}}_{k|k}^a = \bar{\mathbf{f}}_{k|k-1}^a + \bar{\mathbf{K}}_k^{fa} (\mathbf{y}_{m,k} - \bar{\mathbf{y}}_{k|k-1}^a - \mathbf{S}_k^2 \bar{\mathbf{f}}_{k|k-1}^a) \quad 44$$

$$\bar{\mathbf{f}}_{k|k}^s = \bar{\mathbf{f}}_{k|k-1}^s + \bar{\mathbf{K}}_k^{fs} (\mathbf{y}_{m,k} - \bar{\mathbf{y}}_{k|k-1}^a - \mathbf{S}_k^2 \bar{\mathbf{f}}_{k|k-1}^a - \mathbf{S}_k^3 \bar{\mathbf{f}}_{k|k-1}^s) \quad 45$$

$$\bar{\mathbf{P}}_{k|k}^x = \bar{\mathbf{P}}_{k|k-1}^x - \bar{\mathbf{K}}_k^x \bar{\mathbf{P}}_{yy} \bar{\mathbf{K}}_k^{xT} \quad 46$$

$$\bar{\mathbf{P}}_{k|k}^{fa} = (\mathbf{I} - \bar{\mathbf{K}}_k^{fa} \mathbf{S}_k^2) \bar{\mathbf{P}}_{k|k-1}^{fa} \quad 47$$

$$\bar{\mathbf{P}}_{k|k}^{fs} = (\mathbf{I} - \bar{\mathbf{K}}_k^{fs} \mathbf{S}_k^3) \bar{\mathbf{P}}_{k|k-1}^{fs} \quad 48$$

Correção dos estados e das falhas:

$$\mathbf{V}_k^{12} = \mathbf{U}_k^{12} - \bar{\mathbf{K}}_k^x \mathbf{S}_k^2 \quad 49$$

$$\mathbf{V}_k^{23} = \mathbf{U}_k^{23} - \bar{\mathbf{K}}_k^{fa} \mathbf{S}_k^3 \quad 50$$

$$\mathbf{V}_k^{13} = \mathbf{U}_k^{13} - \mathbf{V}_k^{12} \bar{\mathbf{K}}_k^{fa} \mathbf{S}_k^3 - \bar{\mathbf{K}}_k^x \mathbf{S}_k^3 \quad 51$$

$$\hat{\mathbf{x}}_{e,k|k} = \bar{\mathbf{x}}_{e,k|k} + \mathbf{V}_k^{12} \bar{\mathbf{f}}_{k|k}^a + \mathbf{V}_k^{13} \bar{\mathbf{f}}_{k|k}^s \quad 52$$

$$\hat{\mathbf{f}}_{k|k}^a = \bar{\mathbf{f}}_{k|k}^a + \mathbf{V}_k^{23} \bar{\mathbf{f}}_{k|k}^s \quad 53$$

$$\hat{\mathbf{f}}_{k|k}^s = \bar{\mathbf{f}}_{k|k}^s \quad 54$$

$$\mathbf{P}_{k|k}^x = \bar{\mathbf{P}}_{k|k}^x + \mathbf{V}_k^{12} \bar{\mathbf{P}}_{k|k}^{fa} \mathbf{V}_k^{12T} + \mathbf{V}_k^{13} \bar{\mathbf{P}}_{k|k}^{fs} \mathbf{V}_k^{13T} \quad 55$$

$$\mathbf{P}_{k|k}^{fa} = \bar{\mathbf{P}}_{k|k}^{fa} + \mathbf{V}_k^{23} \bar{\mathbf{P}}_{k|k}^{fs} \mathbf{V}_k^{23T} \quad 56$$

$$\mathbf{P}_{k|k}^{fs} = \bar{\mathbf{P}}_{k|k}^{fs} \quad 57$$

Fonte: Próprio autor

4.4.5. Filtro de Kalman Adaptativo em Três Estágios

Todas as abordagens do filtro de Kalman mencionadas até o momento serão ótimas se as propriedades estatísticas do modelo do sistema forem perfeitamente conhecidas. Sabe-se que as falhas nos atuadores e nos sensores possuem dinâmicas desconhecidas e que por esse motivo, haverá um deterioramento no desempenho do filtro no processo de estimação, podendo levar a resultados insatisfatórios (ZHONG *et al.*, 2018).

Visando a solução desse problema, existem abordagens adaptativas do filtro de Kalman que modificarão alguns dos seus parâmetros de acordo com determinadas ocorrências na estimação ao longo do tempo. Neste trabalho, a característica adaptativa do filtro será baseada no fator de esquecimento para a ponderação da matriz de covariância da inovação (KIM, LEE, PARK, 2006).

A inovação é uma medida importante dos filtros de Kalman, podendo ser utilizada para avaliar o desempenho do estimador. Caso o filtro esteja apropriadamente modelado, a inovação apresentará as seguintes propriedades: média nula, não é correlacionado no tempo, e possui matriz de covariância conhecida (GREWAL, ANDREWS, 2015).

Cada um desses parâmetros é indicado na Tabela (4.6), referente a cada abordagem do filtro de Kalman apresentada. Observa-se que no caso em três estágios, existem três valores de cada um dos parâmetros devido à estrutura baseada em três sub filtros.

A matriz de covariância obtida analiticamente pelo filtro corresponde ao cálculo da covariância de um conjunto de inovações no instante de tempo k , ou seja, um conjunto obtido executando o filtro N vezes, com N sendo qualquer valor inteiro positivo.

Tabela 4.6 – Inovação e matriz de covariância das diferentes abordagens do KF

Inovação:	
KF, EKF	$\mathbf{v}_k = \mathbf{y}_{m,k} - \mathbf{C}_k^a \hat{\mathbf{x}}_{e,k k+1}^a$
UKF	$\mathbf{v}_k = \mathbf{y}_{m,k} - \mathbf{y}_{k k-1}^a$
TsKF, TsEKF	$\mathbf{v}_k^x = \mathbf{y}_{m,k} - \mathbf{S}_k^1 \bar{\mathbf{x}}_{e,k k-1}$ $\mathbf{v}_k^{fa} = \mathbf{y}_{m,k} - \mathbf{S}_k^1 \bar{\mathbf{x}}_{e,k k-1} - \mathbf{S}_k^2 \bar{\mathbf{f}}_{k k-1}^a$ $\mathbf{v}_k^{fs} = \mathbf{y}_{m,k} - \mathbf{S}_k^1 \bar{\mathbf{x}}_{e,k k-1} - \mathbf{S}_k^2 \bar{\mathbf{f}}_{k k-1}^a - \mathbf{S}_k^3 \bar{\mathbf{f}}_{k k-1}^s$
TsUKF	$\mathbf{v}_k^x = \mathbf{y}_{m,k} - \bar{\mathbf{y}}_{k k-1}^a$ $\mathbf{v}_k^{fa} = \mathbf{y}_{m,k} - \bar{\mathbf{y}}_{k k-1}^a - \mathbf{S}_k^2 \bar{\mathbf{f}}_{k k-1}^a$ $\mathbf{v}_k^{fs} = \mathbf{y}_{m,k} - \bar{\mathbf{y}}_{k k-1}^a - \mathbf{S}_k^2 \bar{\mathbf{f}}_{k k-1}^a - \mathbf{S}_k^3 \bar{\mathbf{f}}_{k k-1}^s$
Matriz de covariância:	
KF, EKF	$\mathbf{P}_{vv,k} = \mathbf{C}_k^a \mathbf{P}_{k k-1}^a \mathbf{C}_k^{aT} + \mathbf{R}_k$
UKF	$\mathbf{P}_{vv} = \mathbf{P}_{yy}^a$
TsKF, TsEKF	$\mathbf{P}_{vv,k}^x = \mathbf{S}_k^1 \bar{\mathbf{P}}_{k k-1}^x \mathbf{S}_k^{1T} + \mathbf{R}_k$ $\mathbf{P}_{vv,k}^{fa} = \mathbf{S}_k^2 \bar{\mathbf{P}}_{k k-1}^{fa} \mathbf{S}_k^{2T} + \mathbf{S}_k^1 \bar{\mathbf{P}}_{k k-1}^x \mathbf{S}_k^{1T} + \mathbf{R}_k$ $\mathbf{P}_{vv,k}^{fs} = \mathbf{S}_k^3 \bar{\mathbf{P}}_{k k-1}^{fs} \mathbf{S}_k^{3T} + \mathbf{S}_k^2 \bar{\mathbf{P}}_{k k-1}^{fa} \mathbf{S}_k^{2T} + \mathbf{S}_k^1 \bar{\mathbf{P}}_{k k-1}^x \mathbf{S}_k^{1T} + \mathbf{R}_k$
TsUKF	$\mathbf{P}_{vv,k}^x = \bar{\mathbf{P}}_{yy}$ $\mathbf{P}_{vv,k}^{fa} = \bar{\mathbf{P}}_{yy} + \mathbf{S}_k^2 \bar{\mathbf{P}}_{k k-1}^{fa} \mathbf{S}_k^{2T}$ $\mathbf{P}_{vv,k}^{fs} = \bar{\mathbf{P}}_{yy} + \mathbf{S}_k^2 \bar{\mathbf{P}}_{k k-1}^{fa} \mathbf{S}_k^{2T} + \mathbf{S}_k^3 \bar{\mathbf{P}}_{k k-1}^{fs} \mathbf{S}_k^{3T}$

Fonte: Próprio autor

O cálculo do valor real dessa matriz, entretanto, é dificultado por questões práticas quando se usa um conjunto N de execuções, uma vez que há apenas um sistema operando e é necessário obter essa matriz em tempo real. Por essa razão, utiliza-se de outro artifício baseado em selecionar uma janela no tempo de tamanho M e calcular a covariância da inovação nesse intervalo em uma única execução do sistema, Equação (4.44). Isso é possível devido às propriedades da inovação em não ser correlacionada no tempo e possuir média nula.

$$\tilde{\mathbf{P}}_{vv,k} = \frac{1}{M-1} \sum_{i=k-M+1}^k \mathbf{v}_i \mathbf{v}_i^T \quad (4.44)$$

Caso o valor real seja diferente do calculado pelo filtro, haverá uma deterioração no processo de estimação. Para contornar esse problema, a abordagem adaptativa pondera o valor P_{vv} por um fator de esquecimento definido pela Equação (4.45).

$$\lambda_k = \max \left\{ 1, \frac{\text{tr}(\tilde{P}_{vv,k})}{P_{vv,k}} \right\} \quad (4.45)$$

No algoritmo dos filtros de Kalman, define-se o novo valor de $P_{vv,k}$ como sendo:

$$P_{vv,k}^\lambda = \lambda_k P_{vv,k} \quad (4.46)$$

Para o caso em três estágios, é possível aplicar esse fator em cada sub filtro ou em um sub filtro em específico.

No decurso da seção de estado da arte dos métodos de FDD baseadas em modelo, identifica-se uma abordagem robusta do filtro de Kalman (XIAO *et al.*, 2017) (HMIDA, 2012). Nessa técnica, os ganhos dos sub filtros das falhas são modificados de maneira a não depender do modelo dessas variáveis, algo relevante quando essas dinâmicas são desconhecidas. Entretanto, o modelo aumentado do quadricóptero é incompatível com os requisitos mínimos dessa estrutura de estimação.

4.5. Sistema de controle tolerante a falhas

Os sistemas de controle tolerante às falhas são responsáveis em atenuar ou neutralizar os efeitos desses sinais na malha de controle de maneira a garantir o desempenho e estabilidade do processo. Neste trabalho, o método FTC empregado utiliza as estimações provenientes do método FDD de acordo com a Equação (4.47), agindo de maneira semelhante a um controle antecipativo. A variável u'_k é o sinal gerado pelo controlador PID modificado para o sinal dos motores, U_k^m , a matriz associada a u'_k , \hat{f}_k^a , o valor da falha estimada em cada atuador, e u_k^m , o sinal final de controle transmitido aos atuadores do quadricóptero.

$$\mathbf{u}_k^m = \mathbf{u}'_k + \mathbf{U}_k^m \hat{\mathbf{f}}_k^a \quad (4.47)$$

É possível observar na seção (4.1) que as falhas nos atuadores são consideradas como aditivas, como representadas pela Equação (4.48), em que $\mathbf{u}_k^{m'}$ é o sinal que efetivamente será convertido em força e torque pelos motores, uma vez que há uma perda de eficiência gerada pelas falhas.

$$\mathbf{u}_k^{m'} = \mathbf{u}_k^m - \mathbf{U}_k^m \mathbf{f}_k^a \quad (4.48)$$

Substituindo a Equação (4.47) na Equação (4.48) e considerando que o sistema de FDD estimará corretamente a falha, obtém-se a Equação (4.49)

$$\mathbf{u}_k^{m'} = \mathbf{u}'_k + \mathbf{U}_k^m \hat{\mathbf{f}}_k^a - \mathbf{U}_k^m \mathbf{f}_k^a = \mathbf{u}'_k \quad (4.49)$$

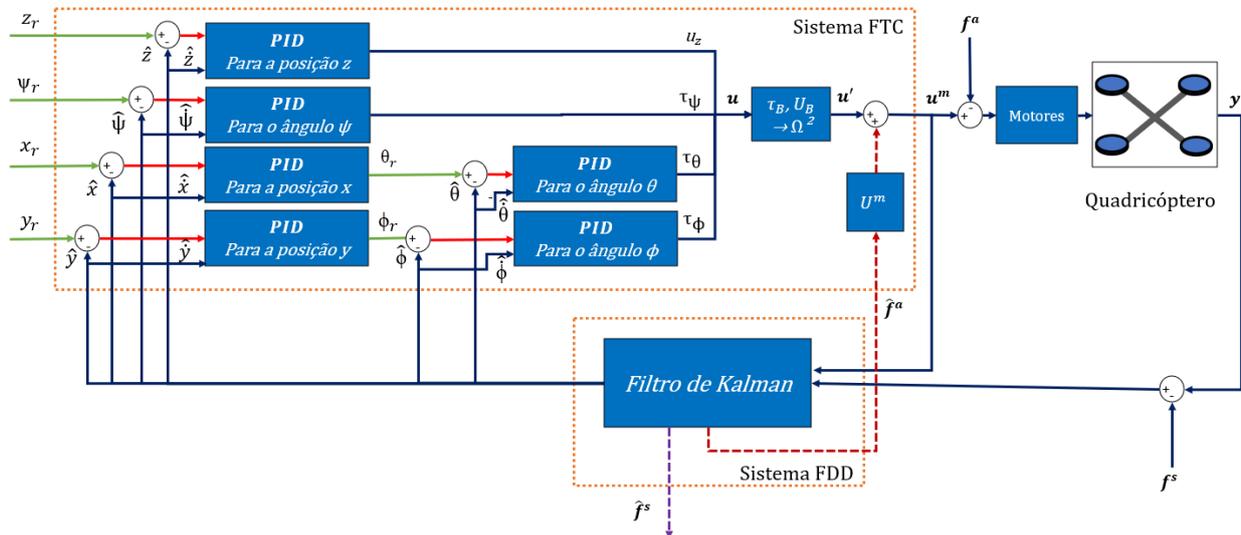
Portanto, pela Equação (4.49), o sinal que efetivamente será convertido em força e torque pelos motores é igual àquele calculado pelos controladores PID. Caso não houvesse uma estrutura de FTC e de FDD, o controlador PID seria o responsável em gerar um sinal de controle que contrabalancearia as perdas geradas pelas falhas, tendo um desempenho de acordo com a sua velocidade em responder aos efeitos das falhas no sistema. Com essas estruturas, essa função é totalmente atribuída às estimações das falhas dos atuadores pelo filtro de Kalman, sendo executada de maneira mais eficaz devido à sua velocidade e precisão em realizar essas estimações.

Em relação às falhas nos sensores, uma malha de controle baseada unicamente no PID não seria capaz de distinguir medições reais das que apresentam valores distorcidos pelas falhas. Portanto, esse tipo de controle sempre posicionaria o quadricóptero erroneamente no espaço. Com o uso dos sistemas de FDD e FTC, essa distinção é possível a partir dos estados estimados, que representam os valores reais das dinâmicas do voo, possibilitando o deslocamento correto da aeronave.

A malha completa envolvendo os sistemas de FDD, FTC e o quadricóptero é apresentada na Figura (4.1). Ressalta-se que com a inclusão das estimações

das falhas no sinal de controle, a entrada do filtro de Kalman é alterada de u'_k para u^m_k .

Figura 4.1 – Sistema de FDD e de FTC implementados para o quadricóptero



Fonte: Próprio autor

CAPÍTULO 5

RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados obtidos, via simulação, das implementações dos métodos de FDD e FTC em um VANT do tipo quadricóptero com o objetivo de atenuar os efeitos das falhas nos atuadores e nos sensores no desempenho e na estabilidade desse sistema. Cenários distintos serão analisados, abrangendo a ocorrência de falhas simultâneas e comportamentos não lineares, o desempenho das diferentes abordagens do KF, efetividade de atuação do controlador tolerante às falhas e robustez do sistema perante perturbações associadas aos ventos.

5.1. Parâmetros do quadricóptero

O quadricóptero utilizado é um *Parrot Minidrone*, cujos parâmetros descritos na Tabela (5.1) foram obtidos na aplicação disponibilizada pela MathWorks Simulink Team (MATHWORKS, 2017).

5.2. Parâmetros dos controladores PID

A Tabela (5.2) mostra os valores calculados dos ganhos do controlador PID referente à variável controlada de acordo com as Equações (3.12) - (3.14). O tempo de amostragem utilizado foi de 5ms.

Optou-se por valores do tempo de assentamento para os ângulos de rolagem e arfagem inferiores ao demais devido a estrutura em cascata com os controladores das posições x e y .

Tabela 5.1 – Tabela dos parâmetros do quadricóptero

Parâmetro	Variável	Unidade	Valor
Massa do quadricóptero	m	kg	$6,3 \cdot 10^{-2}$
Distância entre o centro de massa e os rotores	l	m	$6,24 \cdot 10^{-2}$
Coefficiente de empuxo rotores	b	Ns^2	$4,69 \cdot 10^{-8}$
Coefficiente de arrasto dos rotores	d	Nms^2	$1,13 \cdot 10^{-10}$
Aceleração da gravidade	g	m/s^2	9,81
Momento de inércia em relação ao eixo X	I_{xx}	kgm^2	$5,829 \cdot 10^{-3}$
Momento de inércia em relação ao eixo Y	I_{yy}	kgm^2	$7,169 \cdot 10^{-3}$
Momento de inércia em relação ao eixo Z	I_{zz}	kgm^2	$1,0 \cdot 10^{-4}$
Momento de inércia do rotor	I_r	kgm^2	$1,02 \cdot 10^{-7}$

Fonte: MathWorks Simulink Team, 2017

Tabela 5.2 – Parâmetros do PID

Variável controlada	OS (%)	$T_{s,5\%}$ (s)	Terceiro polo (a)	K_p	K_i	K_d
x	< 1	2	6	2,11	1,66	$9,17 \cdot 10^{-1}$
y	< 1	2	6	-2,11	-1,66	$-9,17 \cdot 10^{-1}$
z	< 1	2	6	1,31	1,03	$0,57 \cdot 10^{-1}$
ϕ	< 1	0,5	24	$1,93 \cdot 10^{-2}$	$6,08 \cdot 10^{-2}$	$2,10 \cdot 10^{-2}$
θ	< 1	0,5	24	$2,38 \cdot 10^{-2}$	$7,48 \cdot 10^{-2}$	$2,58 \cdot 10^{-2}$
ψ	< 1	2	6	$2,10 \cdot 10^{-3}$	$2,58 \cdot 10^{-3}$	$9,00 \cdot 10^{-4}$

Fonte: Próprio autor

5.3. Parâmetros dos filtros de Kalman

A Tabela (5.3) apresenta os parâmetros de configurações de todas as abordagens de filtro de Kalman utilizadas nas simulações.

Tabela 5.3 – Parâmetros dos filtros de Kalman

Q^x	Matriz diagonal: 2,5.[10^{-6} 10^{-6} 10^{-6} 10^{-6} 10^{-6} 10^{-6} 10^{-8} 10^{-8} 10^{-8} 10^{-8} 10^{-8} 10^{-8}]
Q^{fa}	Matriz diagonal: 3,0.[10^{-6} 10^{-6} 10^{-6} 10^{-6}]
Q^{fs}	Matriz diagonal: 3,0.[10^{-6} 10^{-6} 10^{-6} 10^{-6} 10^{-6} 10^{-6}]
$Q^{xfa}, Q^{xfs}, Q^{fafs}$	Matrizes nulas
P_0^x	Matriz diagonal: [10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4}]
P_0^{fa}	Matriz diagonal: [10^{-4} 10^{-4} 10^{-4} 10^{-4}];
P_0^{fs}	Matriz diagonal: [10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4} 10^{-4}]
$P_0^{xfa}, P_0^{xfs}, P_0^{fafs}$	Matrizes nulas
R	Matriz diagonal: [10^{-3} 10^{-3} $5,0 \cdot 10^{-4}$ 10^{-1} 10^{-1} $5,0 \cdot 10^{-4}$ 10^{-4} 10^{-4} 10^{-2} 10^{-2} 10^{-2} 10^{-2}]
M	50

Fonte: Próprio autor

As matrizes de covariância do ruído do processo, principalmente aquelas associadas às falhas, foram ajustadas manualmente de maneira a garantir velocidade satisfatória de convergência, redução do sobressinal das estimações e a atenuação dos ruídos de medição. Esses três fatores estão associados diretamente ao desempenho do método de FTC em atenuar os efeitos das falhas no sistema, sendo degradado pelo atraso em determinar o valor real da falha ou pela inserção incorreta de informação ao sinal de controle. A matriz de covariância dos ruídos de medição foi obtida junto aos demais parâmetros do quadricóptero.

5.4. Simulações e resultados

Os resultados envolvendo as implementações dos métodos de FDD e FTC no quadricóptero foram obtidos via simulação pelo software Simulink e Matlab. Para a análise, foi empregada a métrica IAE (*Integral Absolute Error*) no valor real e estimado e houve a normalização de todos os valores associados a essa métrica.

As simulações consideraram duas trajetórias de voo, sendo um movimento inicial ascendente e posteriormente, um movimento retangular no plano XY mantendo a posição vertical constante. O movimento completo do quadricóptero é realizado em 35s. Os gráficos das figuras de cada simulação possuem o eixo da variável independente com unidade e nome de acordo com as variáveis apresentadas na legenda. Isso foi ocultado, nesse eixo, devido à quantidade de variáveis com nomes e unidades diferentes.

Uma das vantagens no uso dos métodos de FDD baseado em filtro de Kalman é a possibilidade de estimação de falhas em atuadores e sensores com comportamentos não lineares e de ocorrências múltiplas. Visando esse cenário, aplicou-se falhas em cada um desses elementos do quadricóptero de acordo com a Tabela (5.4).

Tabela 5.4 – Comportamentos das falhas nos sensores e nos atuadores

Falha	Tempo de ocorrência (s)	Comportamento	Magnitude (valor máximo) (%)
δ_1	5	Degrau	50
δ_2	11	Dente de serra	50
δ_3	17	Senóide	50
δ_4	23	Intermitente	50
$f^{\dot{x}}$	8	Degrau	20
$f^{\dot{y}}$	12	Degrau	20
$f^{\dot{z}}$	16	Degrau	20
$f^{\dot{\phi}}$	20	Degrau	15
$f^{\dot{\theta}}$	24	Degrau	15
$f^{\dot{\psi}}$	28	Degrau	40

Fonte: Próprio autor

A magnitude é baseada na porcentagem do valor nominal da variável que sofre a ação da respectiva falha. Para as falhas nos atuadores, o valor foi definido baseado no parâmetro δ_{max} , que corresponde ao valor máximo admissível das falhas para que o sistema mantenha a estabilidade. Em relação às falhas nos sensores, elas são injetadas no sistema como degrau para representar o comportamento de *offset*. Para a situação de travamentos, serão

feitas simulações a parte. O valor foi escolhido de maneira a contemplar situações diversas nas medições.

Para efeito de comparação do desempenho das diferentes abordagens dos filtros de Kalman, serão apresentados os resultados de nove filtros contemplando as versões linear, não linear, aumentada, em três estágios e adaptativo: KF, EKF, UKF, TsKF, TsEKF, TsUKF, ATsKF, ATsEKF, ATsUKF.

5.4.1. Análise dos filtros de Kalman com estrutura adaptativa

A primeira simulação é referente ao desempenho de duas estruturas adaptativas dos filtros em três estágios variando o tamanho do intervalo de tempo M . A estrutura 1 da Tabela (5.5), utiliza o fator de esquecimento apenas no sub filtro das falhas nos sensores, enquanto a estrutura 2, nos três sub filtros.

Nota-se que o uso do fator de esquecimento nos três sub filtros apresenta uma deterioração na estimação em relação ao uso em apenas um sub filtro. Além disso, a estrutura 2 é mais sensível à variação do intervalo de tempo determinado por M . A estrutura 1 se mostrou praticamente invariante a essa última situação. Isso também pode ser observado para os filtros ATsKF e ATsEKF.

A justificativa dos resultados está relacionada às médias das inovações dos sub filtros dos estados e das falhas nos atuadores, que não serão nulas na presença de um segundo sinal no sistema, contrapondo ao que foi mencionado na seção (4.4.5) sobre garantir determinadas propriedades da inovação para realizar o cálculo da matriz de covariância desse sinal. Isso ocorre pela existência da correção das estimações no final do algoritmo. Diante disso, valores grandes de M afetarão o cálculo da covariância se a inovação apresentar comportamentos não estacionários e persistentes no tempo, como senoides e intermitentes, enquanto valores pequenos de M serão sensíveis a variações repentinas no sinal. A Figura (5.1) é a inovação do sub filtro dos estados no ATsUKF.

A eficiência do estimador com fator de esquecimento nos três sub filtros implementados em (ZHONG *et al.*, 2018) é possivelmente explicado pelo uso exclusivo de falhas do tipo degrau, que pela sua constância no tempo, não interferem consideravelmente no cálculo correto da covariância da inovação.

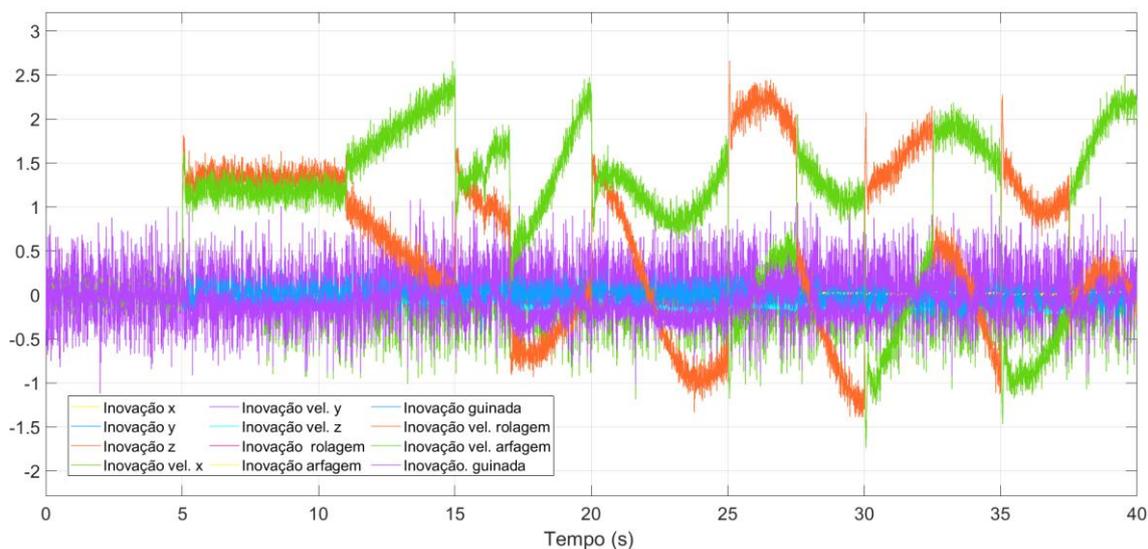
Tabela 5.5 – Desempenho do ATsUKF variando o parâmetro M

Variável	M					
	100		500		1000	
	1	2	1	2	1	2
x	0,772	0,834	0,771	0,939	0,771	1,000
y	0,756	0,810	0,757	0,942	0,756	1,000
z	0,894	1,000	0,915	0,965	0,916	0,953
\dot{x}	0,915	0,949	0,915	0,918	0,915	1,000
\dot{y}	1,000	0,949	1,000	0,956	1,000	0,921
\dot{z}	1,000	0,977	0,982	0,977	0,982	0,952
Φ	0,727	1,000	0,725	0,739	0,726	0,742
θ	0,795	1,000	0,794	0,846	0,794	0,857
ψ	0,839	0,988	0,886	0,957	0,899	1,000
$\dot{\Phi}$	0,929	1,000	0,930	0,913	0,930	0,913
$\dot{\theta}$	0,922	1,000	0,922	0,929	0,922	0,889
$\dot{\psi}$	1,000	0,986	0,988	0,864	0,990	0,721
δ_1	0,612	0,681	0,613	0,665	0,621	1,000
δ_2	0,609	0,663	0,617	0,704	0,620	1,000
δ_3	0,651	0,801	0,777	0,841	0,779	1,000
δ_4	0,626	1,000	0,612	0,808	0,616	0,946
f^x	0,559	0,852	0,553	0,693	0,555	1,000
f^y	0,338	0,454	0,370	0,670	0,378	1,000
f^z	0,864	1,000	0,861	0,936	0,861	0,967
f^Φ	0,888	1,000	0,889	0,982	0,889	0,988
f^θ	0,873	1,000	0,869	0,942	0,869	0,962
f^ψ	0,867	1,000	0,868	0,958	0,867	0,984

Fonte: Próprio autor

O único sub filtro cuja estimação não sofre correções no final do algoritmo é o associado às falhas nos sensores. Por esse motivo, a inovação terá características de média nula e não será influenciada, significativamente, pelo tamanho de M . Diante disso, para o restante das simulações, será utilizado o fator de esquecimento apenas para o sub filtro das falhas nos sensores e uma constante M igual ao apresentado na Tabela (5.3).

Figura 5.1 – Inovação do sub filtro das falhas no ATsUKF



Fonte: Próprio autor

5.4.2. Análise do desempenho das diferentes abordagens de FDD

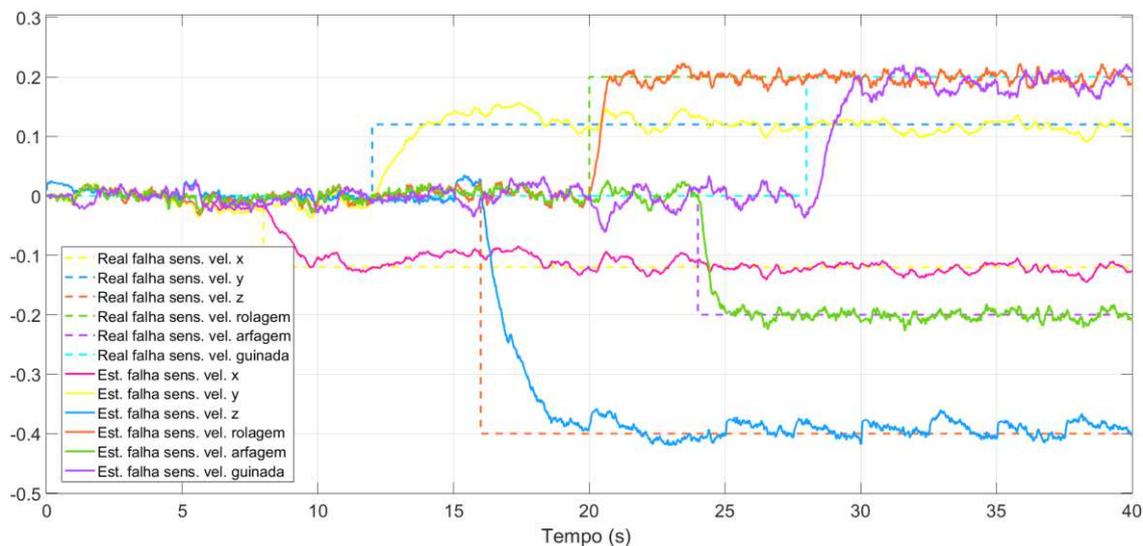
A segunda simulação é referente à capacidade do sistema de FDD em estimar todas as falhas simultaneamente, evidenciando a sua precisão e isolamento das estimações. Este último fator é associado na possibilidade de diagnosticar uma falha sem que as demais provoquem interferências significativas e persistentes no tempo.

Devido à quantidade de filtros e ao intervalo de tempo da simulação, que dificulta a observação das diferenças dos seus desempenhos em um intervalo curto de tempo, ilustra-se apenas as estimações das falhas do ATsUKF nas Figuras (5.2) e (5.3). As unidades dos eixos de cada gráfico são iguais às unidades das variáveis afetadas pela respectiva falha. No gráfico das falhas nos atuadores, duas falhas estão com o valor negativo devido ao sentido de rotação das hélices.

Nota-se que nesse último resultado há um transitório (visualmente identificado por picos) em uma falha, gerado pela variação de outra com duração inferior a aproximadamente 0,5s, para o caso dos atuadores. Esse comportamento é associado diretamente à velocidade de convergência de estimação. O filtro é capaz de estimar as falhas por meio da inovação, a qual está em função dos sinais de medição e estes, relacionados aos estados das dinâmicas da aeronave. Pelas equações do modelo do quadricóptero, todas as

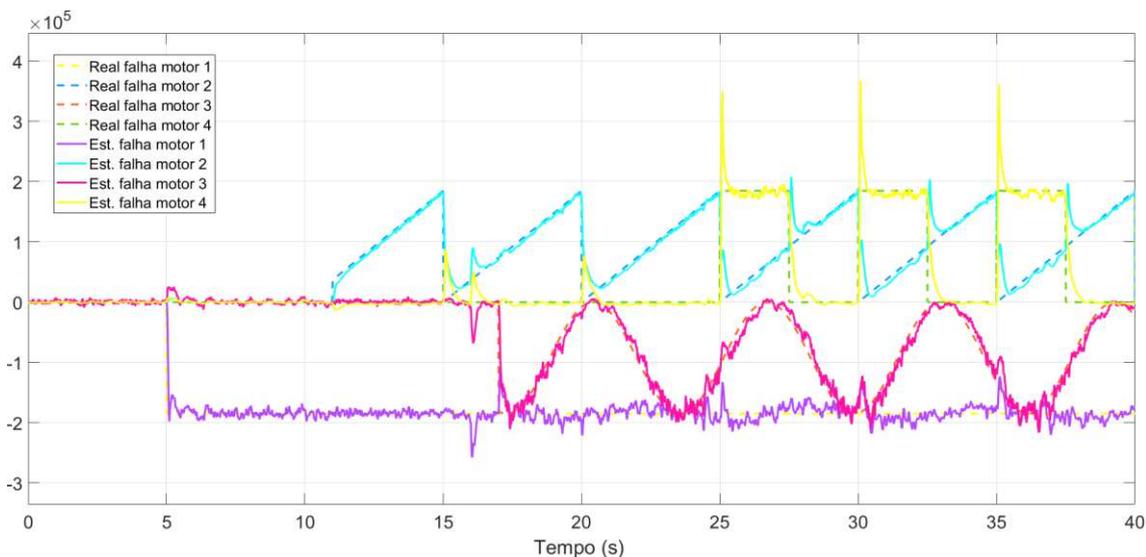
falhas nos atuadores contribuirão para alterar uma variável de estado. Por esse motivo, os transitórios são consequências do intervalo de tempo que o filtro leva para determinar a localização da falha corretamente.

Figura 5.2 – Estimação das falhas nos sensores pelo ATsUKF



Fonte: Próprio autor

Figura 5.3 – Estimação das falhas nos atuadores pelo ATsUKF



Fonte: Próprio autor

Em relação às falhas dos sensores, esse acoplamento não é verificado entre si. Entretanto, há uma interferência das falhas nos atuadores nessas estimativas, observado, principalmente, na medição da velocidade em Z, que atingiu variações de aproximadamente 10% do valor real. Os transitórios são

novamente a causa do problema, pois representam estimacões incorretas nas falhas dos atuadores. Como esses sinais atuam no sinal de controle na estrutura FTC, essas informacões são capazes de promover um comportamento indesejado no quadricóptero e que será interpretado, parcialmente, como problemas nas medições.

Ressalta-se que essa interferência também é presente para a falha na medição da velocidade de guinada e menos significativa nas demais falhas. Como será abordado nas próximas simulações, o controlador PID gera um sinal de controle em resposta às diferentes perturbações, no caso as falhas, com o intuito de atenuá-las no sistema. O sistema de FDD auxilia o PID proporcionando uma atenuação mais rápida desses efeitos, reduzindo o esforço desse controlador em obter soluções para essas situações. Entretanto, caso o FDD gere estimacões indevidas, como é o caso dos transitórios, o PID deverá atuar para mitigá-los na malha. No projeto desse controlador, a especificação de tempos de resposta menores para os ângulos de rolagem e arfagem, além da estrutura em cascata, permitiu uma atuação mais acentuada do PID no transitório e conseqüentemente, uma menor interferência nas estimacões das falhas nos sensores.

Outro ponto a se comentar é a frequência do sinal da falha. Como existem os transitórios, o filtro será incapaz de diagnosticar corretamente um sinal que oscile a uma taxa superior a velocidade de estimacão, pois não haverá tempo suficiente para a convergência. Isso pode levar o sistema a instabilidade, havendo ou não o sistema de FTC. Por esse motivo, além da magnitude máxima admissível para estimar as falhas, é preciso levar em consideração a frequência desses sinais.

Excetuando as falhas nas medições de velocidade em Z e de guinada, as variações nas estimacões são, consideravelmente, resultado da presença dos ruídos nos sensores.

O desempenho dos diferentes filtros é mostrado na Tabela (5.6), associados à métrica IAE. A primeira análise será feita considerando os filtros linear (KF) e não lineares (EKF e UKF). Em relação ao desempenho na estimacão dos estados do quadricóptero, todas as abordagens apresentaram um comportamento semelhante, com diferença máxima de 2% no valor IAE. Contudo, em relação às estimacões das falhas nos atuadores, as versões não

lineares apresentaram uma redução máxima de 7% comparada com a versão linear, e para as falhas nos sensores, redução máxima de 48%.

Tabela 5.6 – Desempenho dos filtros para a situação de falhas nos atuadores e sensores

Variável	KF	EKF	UKF	TsKF	TsEKF	TsUKF	ATsKF	ATsEKF	ATsUKF
x	0,998	0,992	0,992	0,998	0,992	0,992	1,000	0,994	0,994
y	0,999	0,998	1,000	0,999	0,998	0,998	1,000	0,999	0,999
z	0,985	0,992	1,000	0,985	0,992	0,992	0,951	0,951	0,951
\dot{x}	1,000	0,974	0,974	1,000	0,974	0,974	0,990	0,968	0,968
\dot{y}	0,992	0,981	0,981	0,992	0,981	0,981	1,000	0,987	0,987
\dot{z}	0,976	0,973	0,969	0,976	0,973	0,973	1,000	1,000	1,000
Φ	0,956	0,959	1,000	0,956	0,959	0,959	0,957	0,957	0,957
θ	0,985	0,980	1,000	0,985	0,980	0,980	0,980	0,976	0,976
ψ	0,975	1,000	0,990	0,975	1,000	1,000	0,932	0,926	0,926
$\dot{\Phi}$	0,998	1,000	0,998	0,998	1,000	1,000	0,994	0,996	0,997
$\dot{\theta}$	0,998	1,000	0,997	0,998	1,000	1,000	0,997	1,000	1,000
$\dot{\psi}$	0,995	0,953	0,958	0,995	0,953	0,953	1,000	0,953	0,953
f^x	1,000	0,933	0,938	1,000	0,933	0,933	0,990	0,931	0,931
f^y	1,000	0,976	0,973	1,000	0,976	0,976	0,963	0,946	0,946
f^z	0,924	0,965	1,000	0,924	0,965	0,965	0,695	0,709	0,709
f^{Φ}	0,893	0,897	1,000	0,893	0,897	0,897	0,882	0,885	0,885
f^{θ}	0,948	0,948	1,000	0,948	0,948	0,948	0,940	0,938	0,938
f^{ψ}	0,903	1,000	0,979	0,903	1,000	1,000	0,830	0,871	0,871
δ_1	0,990	0,582	0,579	0,990	0,582	0,582	1,000	0,583	0,583
δ_2	0,985	0,507	0,500	0,985	0,507	0,509	1,000	0,503	0,505
δ_3	0,991	0,598	0,600	0,991	0,598	0,597	1,000	0,600	0,600
δ_4	0,985	0,461	0,452	0,985	0,461	0,462	1,000	0,458	0,459

Fonte: Próprio autor

Os métodos de monitoramento diagnosticam a falha de acordo com sinais, eventos, dados etc. que contenham o seu comportamento, sendo conhecidos como resíduos. Quanto maior for a quantidade de informações, melhor será a análise em relação ao seu local, tempo de ocorrência, magnitude e tipo. Para o caso dos filtros, serão as inovações em conjunto com o modelo do

sistema que terão essas informações. Como o quadricóptero é capaz de medir diretamente ou indiretamente todos os seus estados, o modelo utilizado definirá o desempenho dos filtros. O modelo linear desacopla algumas equações de estados das demais, através da consideração de um ponto fixo de operação da aeronave, e reduzem, além disso, o seu conhecimento sobre determinadas dinâmicas não lineares que são influenciadas por falhas. Isso reduz a capacidade do filtro em determinar corretamente a correspondência do resíduo à falha. Justificando assim, as diferenças de resultados observadas.

Para algumas falhas, f^{ψ} e f^z , a versão linear se mostrou mais eficiente em torno de 8%, o que se deve à questão do modelo linear. Isto é, o filtro desacopla determinadas equações das demais, tornando-as mais sensíveis a determinadas falhas e elevando o seu desempenho para essas estimativas. Entretanto, essa melhoria deteriora, em maior peso, as demais estimativas

Em relação às duas abordagens não-lineares (EKF e UKF), ambos apresentaram desempenho semelhante com diferença máxima de 1%, exceto para algumas falhas, em que esse valor atingiu 4% e 11%, tendo o UKF, o pior desempenho. Dois fatores são, possivelmente, o motivo: ajuste incorreto dos parâmetros do UKF e o desconhecimento das dinâmicas das falhas. Variou-se o primeiro fator, mas os resultados não alteraram de maneira significativa, a modo de reduzir essa diferença de desempenho. Em relação ao segundo fator, isso pode ter gerado uma distribuição e propagação dos pontos sigma contendo informações imprecisas sobre a média e a covariância das falhas, ocasionando uma maior deterioração da estimativa quando comparada ao método de linearização do modelo pelo EKF.

Esse problema é elucidado observando o resultado do UKF com o TsUKF. A versão em três estágios realiza linearizações em função das falhas e a propagação dos pontos sigma se restringe aos estados das dinâmicas do quadricóptero. Nota-se que no desempenho do TsUKF há uma melhora nas estimativas em relação ao UKF e uma semelhança de resultados considerando o EKF, reduzindo todas as diferenças para um valor inferior a 0,5%. Isso prova que, para as dinâmicas não lineares consideradas e o movimento realizado pelo quadricóptero, o segundo momento da série de Taylor não tem efeito significativo nas precisões da média e da covariância, e não beneficia, obrigatoriamente, a estimativa em casos considerando falhas com modelos desconhecidos.

A segunda análise é relativa aos filtros em três estágios. Essa abordagem não possui como objetivo aperfeiçoar as estimações, apenas reduzir o custo computacional, a qual é comprovada e mencionada na seção de fundamentação teórica dos métodos de FDD quando se considera o número total de somas e multiplicações realizadas pelo filtro. Por esse motivo, os resultados foram iguais comparando a versão aumentada e em três estágios. A diferença presente entre os filtros UKF e TsUKF se deve as questões ditas anteriormente.

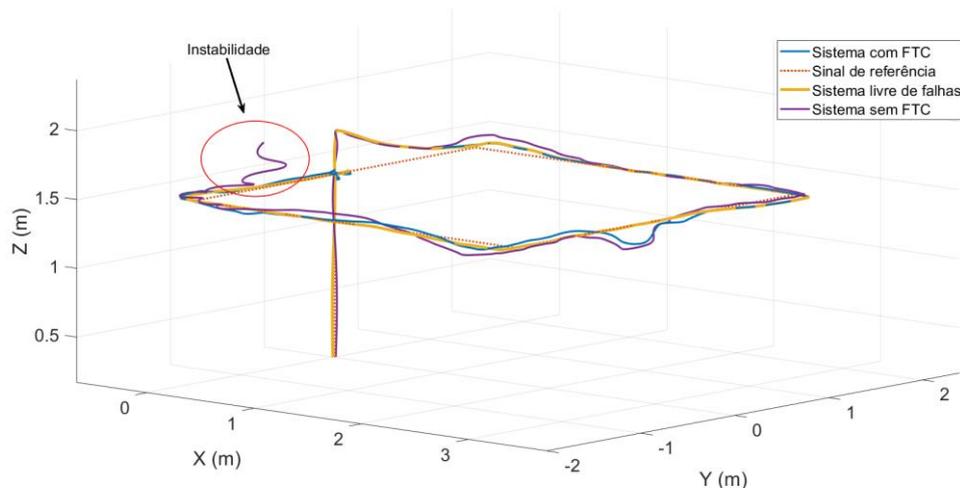
A terceira análise é referente aos filtros adaptativos. Para as estimações das falhas em sensores, houve um aumento de precisão de 22% a 30% em f^z e de 7% a 13% em f^ψ . Para as demais variáveis, a melhoria máxima foi de 7% com média em torno de 2%. O fator de esquecimento foi utilizado apenas no sub filtro das falhas nos sensores, logo, os melhores resultados estariam associados a essas variáveis. O aumento de precisão dos demais estados ocorreu devido às correções nas estimações que o filtro em três estágios executa no final do algoritmo. Portanto, a melhoria do sub filtro das falhas é propagada para os demais.

Caso houvesse a correção adequada da matriz de covariância da inovação nos sub filtros dos estados e das falhas nos atuadores, a melhoria poderia ter sido maior. Apesar disso, como discutido na primeira simulação, isso dependeria fortemente do intervalo M e das dinâmicas e das ocorrências das falhas, algo extremamente difícil de se considerar, no momento que esses sinais possuem comportamentos desconhecidos e de ocorrência inesperadas.

5.4.3. Análise do desempenho da estrutura de FTC

A terceira simulação é referente ao sistema de controle tolerante a falhas, evidenciando a vantagem em se utilizar um método FDD para antecipar as falhas e reduzir o esforço do controlador em atenuar os efeitos desses sinais no sistema. O filtro ATsUKF foi utilizado para essa simulação. A Figura (5.4) apresenta os resultados obtidos para os sistema com e sem o método de FTC, o sistema livre de falhas e o sinal de referência para as posições x, y e z .

Figura 5.4 – Deslocamento do quadricóptero submetido as falhas nos atuadores e sensores



Fonte: Próprio autor

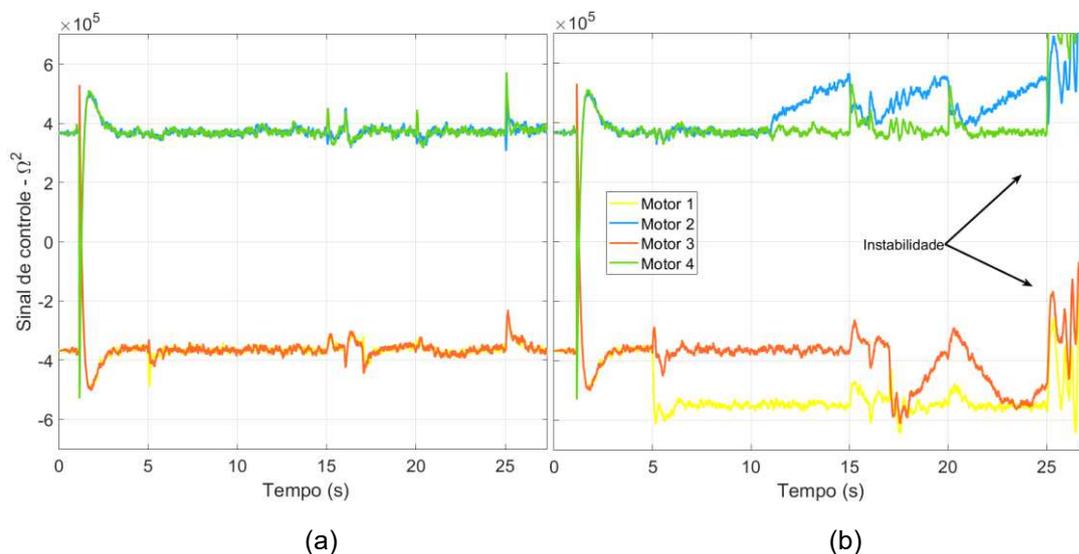
O principal objetivo do FTC é atenuar os efeitos das falhas no processo e garantir a estabilidade. Observa-se na Figura (5.4) que o sistema sem essa estrutura se tornou instável a partir de um instante de tempo. Além disso, o seu deslocamento oscilou em torno da resposta do sistema livre de falhas. Como dito na simulação anterior, nesse caso, o PID é o único responsável em gerar uma resposta às falhas. Entretanto, como o controlador depende unicamente do erro de realimentação e das velocidades angulares e lineares, sua velocidade em responder a esse tipo de situação acaba sendo inferior em relação aos sistemas que usam os filtros como FDD, uma vez que estes usufruem de um modelo do comportamento da aeronave considerando os diferentes tipos de falhas.

A Figura (5.5) ilustra a comparação dos sinais gerados pelo PID dos sistemas com e sem FTC. Observa-se que toda a ação associada à atenuação das falhas é destinada ao sistema FDD e que as variações de curto intervalo de tempo presentes no PID do sistema com FTC estão relacionadas aos transitórios da estimação. Ressalta-se que para o sistema sem FTC, os ruídos das medições foram atenuados através do uso de um filtro de Kalman que considera apenas o modelo do quadricóptero.

Na Figura (5.4), em certos instantes, o sistema com FTC apresentou uma oscilação em torno do sinal livre de falhas com valor máximo de 9%. Nesse caso, essa diferença é atribuída às estimativas das falhas nos sensores por dois

motivos: tempo necessário para a estimação atingir o valor real, como pode ser visto na Figura (5.2), e principalmente, as variações geradas pelos transitórios nessas variáveis, que afetam principalmente a medição de velocidade em Z.

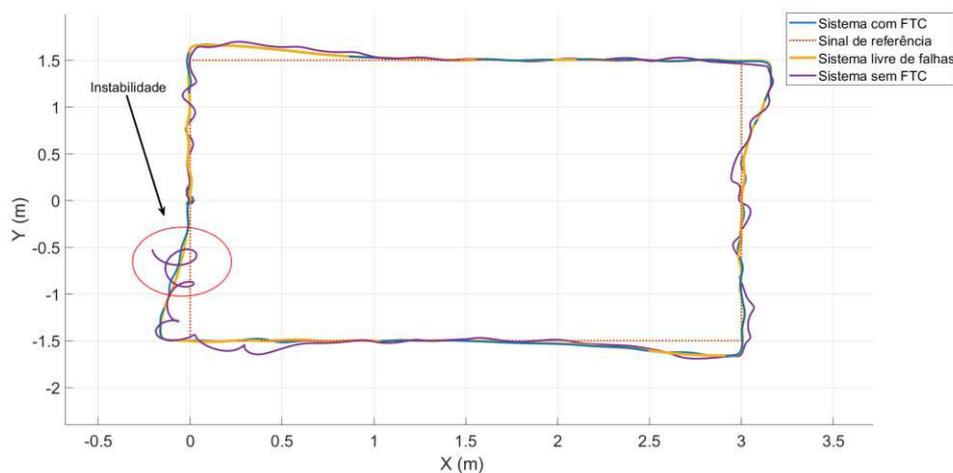
Figura 5.5 – Sinais de controle gerados nos sistemas com (a) e sem (b) FTC



Fonte: Próprio autor

A Figura (5.6) é a visualização do deslocamento do quadricóptero no plano XY. Assim sendo, visualiza-se que o movimento do sistema com FTC atingiu uma oscilação com valor máximo inferior a 2%, justificado, em parte, pela interferência reduzida dos transitórios nas estimções das falhas nas medições de velocidade em X e Y, como discutido anteriormente.

Figura 5.6 – Deslocamento do quadricóptero no plano XY



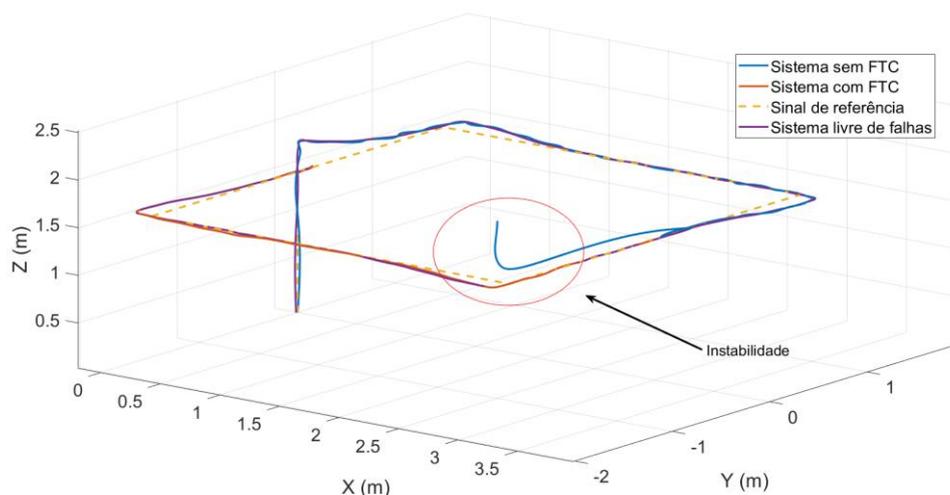
Fonte: Próprio autor

5.4.4. Análise do desempenho das estruturas de FDD e FTC em cenário com falhas do tipo travamento

A quarta simulação é associada às falhas com comportamento de travamento, ou seja, o sinal de medição se mantém, durante um intervalo de tempo, igual ao último valor antes da ocorrência da falha. O intuito dessa simulação é apresentar a eficiência da estrutura FDD para essa situação.

A Figura (5.7) apresenta os comportamentos dos diferentes sistemas nessa situação. A falha foi introduzida na medição de velocidade em Y no instante de 14s, mantendo o valor dessa medição fixo em -0,6m/s até 24s da simulação, momento em que os valores reais voltaram a aparecer. Todas as outras falhas foram retiradas do sistema para poder observar o comportamento isolado do travamento.

Figura 5.7 – Comportamento dos sistemas na presença de falhas nos sensores do tipo travamento



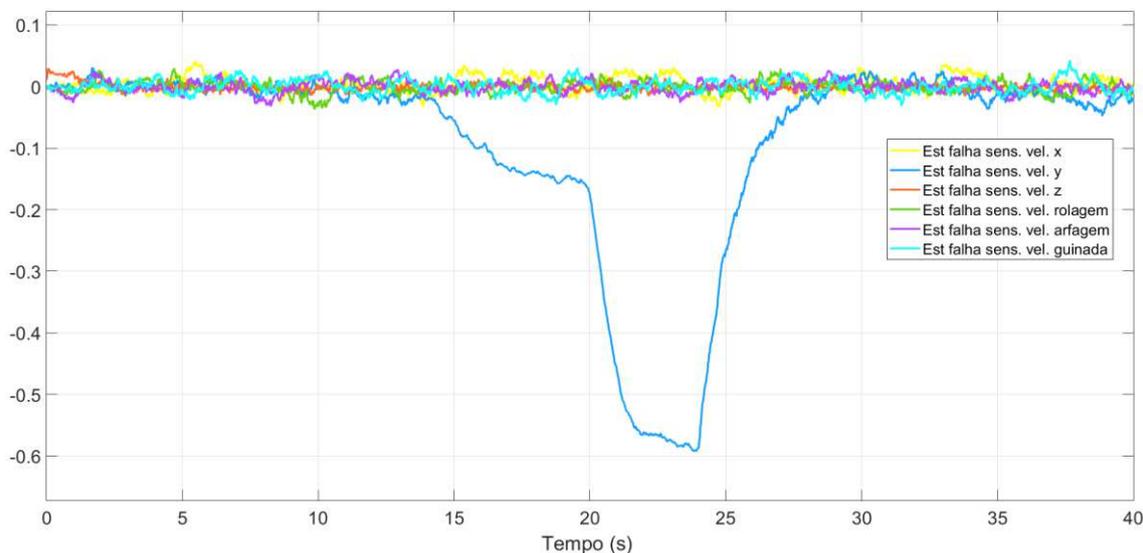
Fonte: Próprio autor

O sistema sem FTC se tornou instável após 4s do início do travamento. Nesse caso de falhas, os controladores são mais vulneráveis do que em relação às falhas consideradas nos atuadores e ao comportamento de *offset* nas medições. Incapaz de determinar se a medição possui falhas, o PID utilizará o valor corrompido para gerar um sinal de controle ao quadricóptero. A perturbação ocasionada pelo travamento no sistema levará o modo integral a agir

continuamente de maneira crescente, uma vez que a medição está travada em um valor e o erro de realimentação se torna constante e não nulo, levando o processo a instabilidade caso a mesma não volte ao valor de operação normal.

A Figura (5.8) é a estimação dessa falha pelo filtro de Kalman. O seu comportamento é a diferença entre o valor de travamento e o valor real da variável alvo. Nesse caso, o sistema de FDD é capaz de distinguir o sinal real, o qual é enviado ao controlador, da falha gerada pelo travamento, não proporcionando os mesmos problemas no controlador que o sistema sem o uso dessa estrutura e conseqüentemente, mantendo a estabilidade da aeronave.

Figura 5.8 – Estimação das falhas nos sensores do tipo travamento



Fonte: Próprio autor

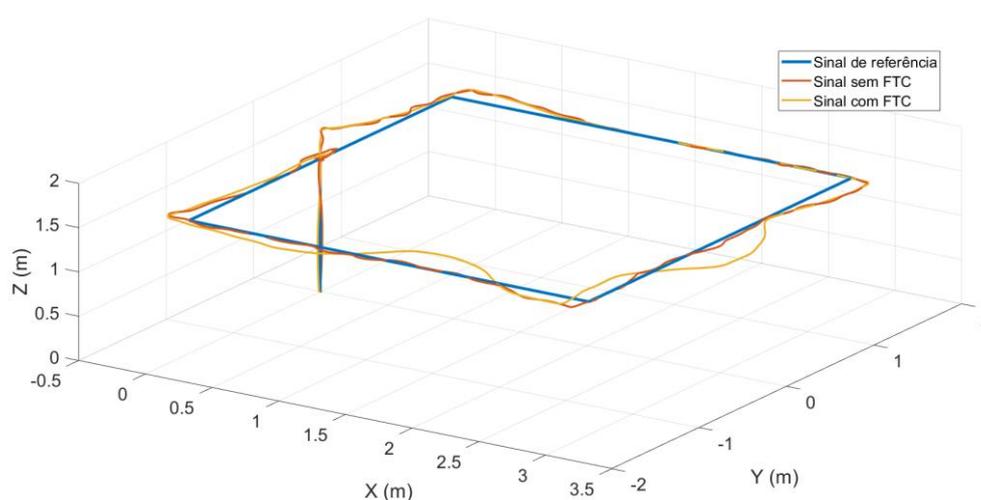
5.4.5. Análise do desempenho das estruturas de FDD e FTC em cenário com perturbações geradas pelos ventos

A quinta simulação se refere à influência das perturbações externas, consideradas aqui como os ventos, no processo de estimação das falhas. Os ventos agem no sistema como forças, ou seja, modificam os valores dos estados do sistema de acordo com a sua direção e magnitude. O seu comportamento pode ser descrito por equações, como apresentado em (SIERRA, SANTOS, 2019), que utiliza a tabela de Beaufort para determinar a velocidade do vento de acordo com o ambiente. Neste trabalho, não se deseja medir o desempenho dos sistemas de FDD e FTC na ocorrência dos ventos, e sim, apenas analisar a

influência dessas perturbações nesses sistemas por não terem sido consideradas no modelo do quadricóptero. Diante desse motivo, a simulação representará esse sinal externo de uma forma generalizada, como um valor constante não nulo durante um intervalo de tempo.

A Figura (5.9) mostra a resposta do sistema às seguintes perturbações: adição de forças nas direções de X , Y e Z nos instantes de tempo iguais a 15s, 21s e 27s, respectivamente, com valor constante igual a 10% de u_z e duração de 2s.

Figura 5.9 - Comportamento dos sistemas na presença de perturbações geradas pelos ventos



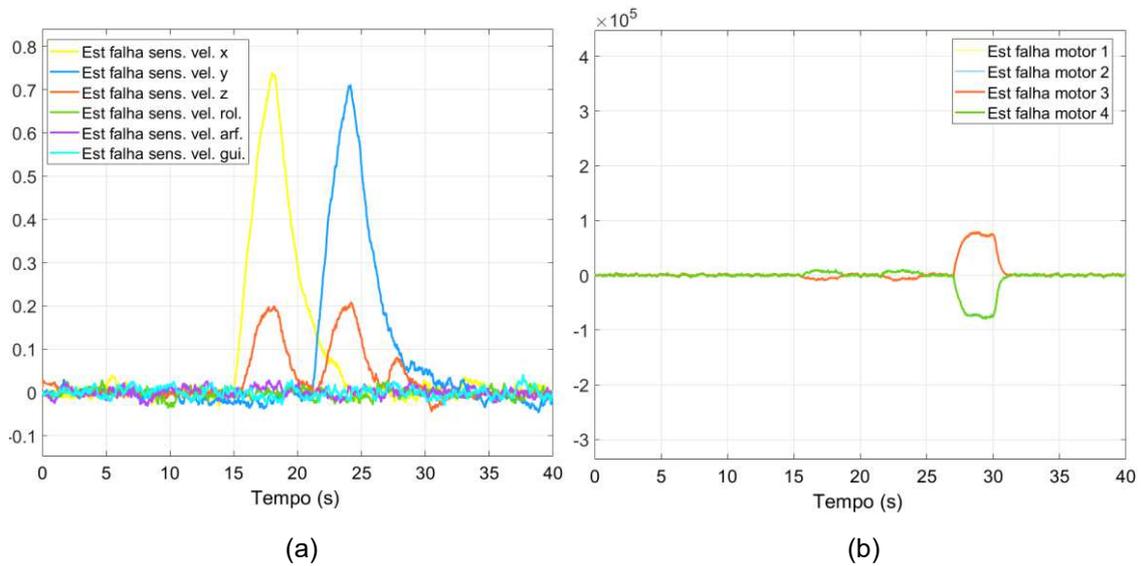
Fonte: Próprio autor

Observa-se que o sistema com FTC apresentou uma resposta deteriorada pelas perturbações em relação ao sistema sem o FTC. A justificativa é a presença de alarmes falsos gerados pelas estimações das falhas nos sensores e nos atuadores, Figura (5.10), as quais injetam sinais errôneos na malha de controle. Conseqüentemente, forçam o controlador, o único capaz de atenuar as perturbações, a atuar de maneira a reduzir os efeitos das perturbações dos ventos em conjunto com as geradas pelo filtro. Paro o sistema sem o uso do FTC, o PID apenas atua para reduzir os efeitos dos ventos.

Mesmo diante disso, é importante salientar que os ventos não são perturbações fixas, visto que variam de acordo com uma série de fatores ambientais, ou seja, os alarmes falsos são como os transitórios que se anulam após um intervalo de tempo. Por esse motivo, dependendo do tempo de atuação

do vento, da sua magnitude e da sua direção (observa-se que em Z a perturbação teve um efeito consideravelmente menor que em X e Y), o sistema de FTC poderá não ter um desempenho afetado significativamente.

Figura 5.10 – Estimações das falhas nos sensores (a) e nos atuadores (b)



Fonte: Próprio autor

CAPÍTULO 6

CONCLUSÕES E SUGESTÕES

O presente trabalho possui como contribuição primordial, a implementação de sistemas de FDD e FTC aplicados em um VANT do tipo quadricóptero em diferentes cenários com falhas em atuadores e sensores. O emprego desses métodos permitiu uma considerável melhoria nos fatores de confiabilidade e segurança da aeronave em relação à estabilidade e ao desempenho de voo em situações de falha, quando comparado ao sistema sem o controle tolerante.

Diferentes problemas foram observados e devidamente pontuados durante a seção de estado da arte. Todos esses pontos foram abordados no projeto dos sistemas de FDD e FTC excetuando as perturbações ocasionadas pelos ventos, que devido às questões de observabilidade do sistema, não foi possível considerá-las no modelo.

A partir dos resultados obtidos comparando diferentes estruturas de FDD baseadas em filtro de Kalman e o desempenho do controlador tolerante às falhas, realiza-se as seguintes afirmações:

- as estruturas de FDD foram capazes de estimar corretamente todas as falhas consideradas através dos modelos desses sinais descritos nas seções (4.1) e (4.2), e com comportamentos diversos e ocorrências simultâneas no sistema;
- o uso do fator de esquecimento nos três sub filtros da abordagem em três estágio não é aconselhável, pois só seria efetivo em caso de falhas com

comportamentos do tipo degrau, sendo algo complexo de se determinar, uma vez que, geralmente, considera-se as falhas como sinais com dinâmicas desconhecidas;

- os transitórios na estimação representam sinalizações de alarme falso de falhas e que no sistema FTC, podem gerar perturbações na malha de controle. O controlador PID é projetado para o sistema livre de falhas, entretanto, torna necessário considerar no seu projeto, o seu desempenho em função desses transitórios, pois será o responsável em atenuá-los;
- o último ponto pode ser também direcionado ao desempenho dos filtros de Kalman, que atenuariam os transitórios de acordo com a sua velocidade de convergência nas estimações. O problema, nesse caso, é estabelecer um estimador que atenuie os ruídos das medições consideravelmente e ao mesmo tempo, tenha velocidade de estimação desejada, uma vez que aperfeiçoar um desses fatores, irá, por consequência, deteriorar o outro. De acordo com os resultados, foi possível observar que a abordagem adaptativa contribuiu com uma melhoria nesse quesito de convergência;
- é necessário considerar a frequência do sinal das falhas no projeto dos filtros de Kalman, devido estes possuírem uma velocidade de convergência. Caso essa frequência seja superior a essa velocidade, o filtro será incapaz de convergir ao valor real da falha, impossibilitando o diagnóstico correto dos defeitos;
- quando se trata de métodos de FDD baseados em modelo, sua eficiência é influenciada diretamente pela quantidade de informações disponibilizadas sobre o processo, algo observável quando se analisa o desempenho dos filtros nas versões lineares e não-lineares;
- comparando os resultados das versões do EKF e do UKF, observa-se que, para as dinâmicas não lineares e os movimentos lineares e angulares do quadricóptero considerados, o segundo momento da série de Taylor não tem efeito significativo nas precisões da média e da covariância, e não beneficia, obrigatoriamente, a estimação em casos considerando falhas com modelos desconhecidos;

- constata-se a comprovação da efetividade do sistema FTC em manter a estabilidade do quadricóptero em situações de falhas em atuadores e nas medições, principalmente aquelas com comportamento de travamentos;
- o único fator que se mostrou desfavorável ao uso dos sistemas FTC foram as perturbações associadas aos ventos, uma vez que geram alarmes falsos e prejudicam, conseqüentemente, o desempenho do quadricóptero. Dependendo da magnitude, da direção e do intervalo de tempo dos ventos, essas perturbações podem não afetar significativamente a atuação do FTC. Por esse motivo, é necessário conhecer antecipadamente o ambiente de uso do quadricóptero e determinar a grau de interferência dos ventos nas dinâmicas da aeronave e nas estimações do sistema FDD.

6.1. Trabalhos futuros

Visando alguns pontos discutidos na conclusão e a continuidade do trabalho, é possível determinar os seguintes trabalhos futuros:

- estudar o comportamento real de diferentes falhas nos quadricópteros, uma vez que normalmente são generalizadas como degraus ou rampas nas pesquisas;
- aplicação dos métodos de FDD e FTC em um veículo real. Em hipótese de que não seja possível o uso de componentes defeituosos durante os testes, devido à dificuldade em obter as falhas experimentalmente, seria analisado a possibilidade de injetá-las computacionalmente no processo;
- estudar o desempenho dos sistemas de FDD e FTC para outras situações de voo, considerando, principalmente, maiores variações dos ângulos de rolagem, arfagem e guinada em relação ao que foi apresentado nos resultados, para analisar o efeito das não linearidades, possivelmente mais acentuado nesse cenário, na estimação;
- implementação de novas estratégias de controle que possuam propriedades que justifiquem o seu uso no lugar do PID, como os controladores preditivos baseados em modelo, controladores robustos, entre outros;

- adaptação do sistema de FTC para incluir as perturbações geradas pelos ventos e reduzir os seus efeitos na malha de controle;
- adaptação do método de FDD para aprimorar a sua velocidade de convergência de estimação, reduzindo os transitórios e aperfeiçoando o diagnóstico.
- comparação do desempenho dos sistemas de FDD e FTC para diferentes aeronaves.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBASPOUR, A., YEN, K. K., FOROUZANNEZHAD, P. e SARGOLZAEI, A. A Neural Adaptive Approach for Active Fault-Tolerant Control Design in UAV. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, v. 50, nº. 9, pp. 3401-3411, 2020. <https://doi.org/10.1109/TSMC.2018.2850701>

ABOUSELIMA, E., ICHALAL, D. e MAMMAR S. Quadrotor Control and Actuator Fault Detection: LQG Versus Robust H-/H-infinity observer. *4th Conference on Control and Fault Tolerant Systems (SysTol)*, Casablanca, Marrocos, pp. 86-91, 2019. <https://doi.org/10.1109/SYSTOL.2019.8864775>

ALBERTOS, P. e SALA, A. Multivariable control systems: An engineering approach. Springer, Estados Unidos, 2004.

ALOS, A. M. e DAHROUJ Z. Using the Statistical Features of the Data to Detect Potential Failure of Unmanned Aerial Vehicles. *International Journal of Applied Engineering Research*, v. 14, nº. 20, pp. 3946-3952, 2019. <https://doi.org/10.5281/zenodo.3557687>

AMIRUDIN, A.A.A.M, ZABIRI, H., TAQVI, S.A.A e TUFA, L. D. Neural Network Applications in Fault Diagnosis and Detection: An Overview of Implementations in Engineering-Related Systems. *Neural Computing & Applications*, v. 32, pp. 447-472, 2018. <https://doi.org/10.1007/s00521-018-3911-5>

BBC Research. Drone Technology and Global Markets, 2020.

BENINI, A., FERRACUTI, F., MONTERIÙ, A. e RADENSLEBEN, S. Fault Detection of a VTOL UAV Using Acceleration Measurements. *18th European Control Conference (ECC)*, Nápoles, Itália, pp. 3990-3995, 2019. <https://doi.org/10.23919/ECC.2019.8796198>

BONDRYA, A., GASIOR, P., GARDECKI, S. e KASIŃSKI, A. Fault Diagnosis and Condition Monitoring of UAV Rotor Using Signal Processing. *Signal Processing:*

Algorithms, Architectures, Arrangements, and Applications (SPA), Poznan, Polônia, pp. 233-238, 2017. <https://doi.org/10.23919/SPA.2017.8166870>

BOUABDALLAH, S. Design and Control of Quadrotors with Application to Autonomous Flying. 2007. 129 f. Tese (Doutorado). École Polytechnique Fédérale de Lausanne, Lausanne, 2007.

BROWN, R. G. e HWANG, P. Y. C. Introduction to Random Signals and Applied Kalman Filtering with MATLAB Exercises. John Wiley and Sons, Inc., USA, 2012.

FRAVOLINI, M. L., DEL CORE, G., PAPA, U., VALIGI, P. e NAPOLITANO, M. R. Data-Driven Schemes for Robust Fault Detection of Air Data System Sensors. *IEEE Transactions on Control Systems Technology*, v. 27, nº. 1, pp. 234-248, 2019. <https://doi.org/10.1109/TCST.2017.2758345>

GHALAMCHI, B., JIA, Z. e MUELLER, M. W., Real-Time Vibration-Based Propeller Fault Diagnosis for Multicopters. *IEEE/ASME Transactions on Mechatronics*, v. 25, nº. 1, pp. 395-405, 2020. <https://doi.org/10.1109/TMECH.2019.2947250>

GOSH, A., KRISHNAN, T. R., TEJASWY, P., MANDAL, A., PRADHAN, J. K. e RANASINGH, S. Design and Implementation of a 2-DOF PID Compensation for Magnetic Levitation Systems. *ISA transactions*, v. 53, pp. 1216-1222, 2014. <https://doi.org/10.1016/j.isatra.2014.05.015>

GREWAL, M. S. e ANREWS, A. P. Kalman Filtering: Theory and Practice Using MATLAB. John Wiley and Sons, Inc., New Jersey, 2015.

GUPTA, S., MOHANDAS, P. I. T. e CONRAD, J. M. A Survey of Quadrotor Unmanned Aerial Vehicles. *Proceedings of IEEE Southeastcon*, pp. 1-6, 2012. <https://doi.org/10.1109/SECon.2012.6196930>

GUO, D., ZHONG, M., JI, H., LIU, Y. e YANG, R. A Hybrid Feature Model and Deep Learning Based Fault Diagnosis for Unmanned Aerial Vehicle Sensors.

Neurocomputing, v. 319, pp. 155-163, 2018.

<https://doi.org/10.1016/j.neucom.2018.08.046>

GUO, D., Wang, Y., ZHONG, M. e ZHAO, Y. Fault Detection and Isolation for Unmanned Aerial Vehicle Sensors by Using Extended PMI Filter. *IFAC-PaperOnline*, v. 51, pp. 818-823, 2018.

<https://doi.org/10.1016/j.ifacol.2018.09.669>

HAN, W., WANG, Z., e SHEN, Y. Fault Estimation for a Quadrotor Unmanned Aerial Vehicle by Integrating the Parity Space Approach with Recursive Least Squares. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, v. 232, pp. 783–796, 2018.

<https://doi.org/10.1177/0954410017691794>

HASAN, A. e JOHANSEN, T. A. Model-Based Actuator Fault Diagnosis in Multicopter UAVs, *2018 International Conference on Unmanned Aircraft Systems (ICUAS)*, Dallas, TX, 2018, pp. 1017-1024.

<https://doi.org/10.1109/ICUAS.2018.8453420>

HMIDA, F. B., KHÉMIRI, K., RAGOT, J. e GOSSA, M. Three-Stage Kalman Filter for State and Fault Estimation of Linear Stochastic Systems with Unknown Inputs, *Journal of the Franklin Institute*, v. 349, pp. 2369-2388, 2012.

<https://doi.org/10.1016/j.jfranklin.2012.05.004>

ISERMAN, R. *Fault Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*. Springer, Alemanha, 2006.

KIM, K. H., LEE, J. G. e PARK, C. G. Adaptive Two-Stage Kalman Filter in the Presence of Unknown Random Bias. *International Journal of Adaptive Control and Signal Processing*, v. 20, pp. 305-319, 2006.

<https://doi.org/10.1002/acs.900>

KUMAR, P. e MINZ, S. Control of Magnetic Levitation System Using PD and PID Controller. *International Journal of Scientific Research and Education*, v. 4, pp. 5596-5602, 2016.

LI, S., XIN, Y., LI, X., WANG, J. e XU, K. A Review on the Signal Processing Methods of Rotating Machinery Fault Diagnosis. *IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC)*, Chongqing, China, pp. 1559-1565, 2019.

<https://doi.org/10.1109/ITAIC.2019.8785572>

LIMA, G. V. Modelagem Dinâmica e Controle para Navegação de uma Veículo Aéreo Não Tripulado do Tipo Quadricóptero. Dissertação (Mestrado). Universidade Federa de Uberlândia, Uberlândia, 2015.

LONGHI, L. G. S. Uma Proposta para Adequar a Sintonia de um Controlador PID com Parametrização I-PD. 2018.

LU, P., EYKEREN, L. V., KAMPEN, E. V., CHU, Q. P. e YU, B. Adaptive Hybrid Unscented Kalman Filter for Aircraft Sensor Fault Detection, Isolation and Reconstruction. *AIAA Guidance, Navigation, and Control Conference*. Maryland, 2014. <https://doi.org/10.2514/6.2014-1145>

MathWorks Simulink Team. Simulink Support Package for Parrot Minidrones, 2017. Disponível em:

<https://www.mathworks.com/matlabcentral/fileexchange/63318-simulink-support-package-for-parrot-minidrones>.

MOSBORNE, M., LANTAIR, J., SHAFIQ, Z., ZHAO, X., ROBU, V., FLYNN, D. e PERRY, J., UAS Operators Safety and Reliability Survey: Emerging Technologies towards the Certification of Autonomous UAS. *4th International Conference on System Reliability and Safety (ICSRS)*, Roma, Itália, 2019, pp. 203-212. <https://doi.org/10.1109/ICSRS48664.2019.8987692>

NI, K. *et al.* Sensor Network Data Fault Types. *ACM Transactions on Sensor Networks*, v. 5, n^o. 3, artigo 25, 2009. <https://doi.org/10.1145/1525856.1525863>

OKADA, K. F. A., MORAIS, A. S., LOPES, L. C. O. e RIBEIRO, L., A Survey on Fault Detection and Diagnosis Methods. *2021 14th IEEE International Conference on Industry Applications (INDUSCON)*, pp. 1422-1429, 2021.

<https://doi.org/10.1109/INDUSCON51756.2021.9529495>

OKADA, K. F. A., MORAIS, A. S., LOPES, L. C. O. e RIBEIRO, L., Neuroadaptive Observer-Based Fault Diagnosis and Fault-Tolerant Control for Quadrotor UAV. *2021 14th IEEE International Conference on Industry Applications (INDUSCON)*, pp. 285-292, 2021. <https://doi.org/10.1109/INDUSCON51756.2021.9529573>

RAFFO, G. V. Robust Control Strategies for a Quadrotor Helicopter. Tese (Doutorado). Universidade de Sevilha, Sevilha, 2011.

RAHIMI, A., KUMAR, K. D. e ALIGHANBARI, H. Fault Estimation of Satellite Reaction Wheels Using Covariance Based Adaptive Unscented Kalman Filter. *Acta Astronautica*, v. 134, pp. 159-169, 2017.

<https://doi.org/10.1016/j.actaastro.2017.02.003>

Research and Markets, Global Drone Service Market Analysis 2019.

ROTONDO, D., *et al.* Diagnosis of Icing and Actuator Faults in UAVs Using LPV Unknown Input Observers. *Journal Intelligent & Robotic Systems*, v. 91, pp. 651–665, 2018. <https://doi.org/10.1007/s10846-017-0716-1>

SARTORI, I., AMARO, C.A, SOUZA, M.B. e EMBIRUÇU, M., Detecção, Diagnóstico e Correção de Falhas: uma Proposição Consistente de Definições e Terminologias. *Ciência e Engenharia*, v. 21, pp. 41-53, 2012.

SHAKHATREH, H. *et al.* Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges. *IEEE Access*, v. 7, pp. 48572-48634, 2019. <https://doi.org/10.1109/ACCESS.2019.2909530>

SHRAIM, H., A. AWADA, A. e YOUNESS, R., A Survey on Quadrotors: Configurations, Modeling and Identification, Control, Collision Avoidance, Fault Diagnosis and Tolerant Control. *IEEE Aerospace and Electronic Systems Magazine*, v. 33, nº. 7, pp. 14-33, 2018.

<https://doi.org/10.1109/MAES.2018.160246>

SIERRA, J. E. e SANTOS, M. Wind and Payload Disturbance Rejection Control Based Adaptive Neural Estimators: Application on Quadrotors. *Complexity*, v. 2019, pp. 20, 2019. <https://doi.org/10.1155/2019/6460156>

SKILIROU, C., MIGUEZ, M.E., FAKHRE, A. e JENNIONS, I.K. A Review of Model Based and Data Driven Methods Targeting Hardware Systems Diagnostics. *Diagnostyka*, v. 20, pp. 3-21, 2019. <https://doi.org/10.29354/diag/99603>

SONG, Y., HE, L., ZHANG, D., QIAN, J. e FU, J. Neuroadaptive Fault-Tolerant Control of Quadrotor UAVs: A More Affordable Solution. *IEEE Transactions on Neural Networks and Learning Systems*, v. 30, nº. 7, pp. 1975-1983, 2019.

<https://doi.org/10.1109/TNNLS.2018.2876130>

TIDRIRI, K., CHATTI, N., VERRON, S. e TIPLICA, T. Bridging Data-Driven and Model-Based Approaches for Process Fault Diagnosis and Health Monitoring: A Review of Researches and Future Challenges. *Annual Reviews in Control*, v. 42, pp. 63-81, 2016. <https://doi.org/10.1016/j.arcontrol.2016.09.008>

USMAN, M. Quadcopter Modelling and Control with MATLAB/Simulink Implementation. 2020. 68 f. Tese (Doutorado). LAB University of Applied Sciences, Mukkulankatum, 2020.

WADE, H. L. Basic and Advanced Regulatory Control: System Design and Application. 2ª Edição. ISA – The Instrumentation, Systems, and Automation Society. USA, 2004.

WANG, R., ZHAO, C., BAI, Y., DU, W. e WANG, J. An Actuator Fault Detection and Reconstruction Scheme for Hex-Rotor Unmanned Aerial Vehicle. *IEEE Access*, v. 7, pp. 93937-93951, 2019.

<https://doi.org/10.1109/ACCESS.2019.2927010>.

XIAO, M., ZHANG, Y. e FU, H. Three-stage Unscented Kalman Filter for State and Fault Estimation of Nonlinear System with Unknown Input. *Journal of the Franklin Institute*, v. 354, pp. 8421-8443, 2017.

<https://doi.org/10.1016/j.jfranklin.2017.09.031>

XU, C., JIA, H. e CHEN, Z. Simultaneous Robust Control and Sensor Fault Detection for a Ducted Coaxial-Rotor UAV. *IEEE Access*, v. 7, pp. 167739-167753, 2019. <https://doi.org/10.1109/ACCESS.2019.2952386>

YOUNES, Y. A., NOURA, H., RABHI, A. e HAJJAJI, A. E. Actuator Fault-Diagnosis and Fault-Tolerant-Control using intelligent-Output-Estimator Applied on Quadrotor UAV. *2019 International Conference on Unmanned Aircraft Systems (ICUAS)*, Atlanta, USA, pp. 413-420, 2019.

<https://doi.org/10.1109/ICUAS.2019.8798232>

YU, Z., FU, J., LIU, L. e ZHU, C. A. Fault Detection Method Based on Persistent Excitation for a Six-rotor UAV. *2018 IEEE CSAA Guidance, Navigation and Control Conference (GNCC)*, Xiamen, China, pp. 1-5, 2018

<https://doi.org/10.1109/GNCC42960.2018.9018651>

ZEGHLACHE, S., MEKKI, H., BOUGUERRA, A. e DJERIOUI, A. Actuator fault Tolerant Control Using Adaptive RBFNN Fuzzy Sliding Mode Controller for Coaxial Octorotor UAV. *ISA Transactions*, v. 80, pp. 267-278, 2018.

<https://doi.org/10.1016/j.isatra.2018.06.003>

ZHONG, M., XUE, T. e DING, S. X. A Survey on Model-Based Fault Diagnosis for Linear Discrete Time-Varying Systems. *Neurocomputing*, v. 306, pp. 51-60, 2018. <https://doi.org/10.1016/j.neucom.2018.04.037>