

Universidade Federal de Juiz de Fora
Faculdade de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Pablo Henrique Gonçalves

**Análise da Metodologia SOESGOPE em malha fechada para a Estimação
Ótima de Parâmetros de um quadrotor**

Juiz de Fora

2021

Pablo Henrique Gonçalves

Análise da Metodologia SOESGOPE em malha fechada para a Estimação
Ótima de Parâmetros de um quadrotor

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, como requisito para obtenção do título de Mestre em Engenharia Elétrica

Orientador: Augusto Santiago Cerqueira, D. Sc.

Juiz de Fora

2021

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF
com os dados fornecidos pelo(a) autor(a)

Gonçalves, Pablo Henrique.

Análise da Metodologia SOESGOPE em malha fechada para a Estimação Ótima de Parâmetros de um quadrotor / Pablo Henrique Gonçalves. – 2021. 92 f. : il.

Orientador: Augusto Santiago Cerqueira, D. Sc.

dissertação de mestrado – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2021.

1. Quadrotor. 2. Identificação de Sistemas. 3. Estimação Ótima de Parâmetros. 4. Projeto de Entradas Ótimas. 5. Método *Twiddle* I. Cerqueira, Augusto Santiago, orient. II. Análise da Metodologia SOESGOPE aplicada a um Quadrotor para Estimação Ótima de Parâmetros.

Pablo Henrique Gonçalves

Análise da Metodologia SOESGOPE em malha fechada para a Estimação Ótima de Parâmetros de um quadrotor

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, como requisito para obtenção do título de Mestre em Engenharia Elétrica

Aprovado em: 01/02/2021

BANCA EXAMINADORA



Prof. Dr. Augusto Santiago Cerqueira - Orientador
Universidade Federal de Juiz de Fora (UFJF)



Prof. Dr. Leonardo de Mello Honório
Universidade Federal de Juiz de Fora (UFJF)



Prof. Dr. Carlos Henrique Valério de Moraes
Universidade Federal de Itajubá (UNIFEI)

À minha família e aos meus amigos.

AGRADECIMENTOS

Agradeço à Deus por me dar forças e sabedoria. Ao meu orientador Dr. Augusto Santiago Cerqueira pela paciência na orientação, bem como pelos ensinamentos repassados, os quais foram essenciais para a minha formação profissional. Agradeço também ao professor Dr. Exuperry Barros Costa pela dedicação e disponibilidade no auxílio da elaboração do trabalho. À toda minha família, em especial à minha mãe e irmã, que sempre me apoiaram e me incentivaram a alcançar novos horizontes. Aos professores e funcionários do Programa de Pós-Graduação em Engenharia Elétrica (UFJF) pelos ensinamentos e dedicação a mim ao longo da minha caminhada. Aos colegas do Programa, em especial a Elaine, Thais, Tiago, Katia e Josué, sempre presentes tornando todo o caminho mais fácil de ser seguido. Aos amigos, professores, alunos e funcionários da UFOP-JM pelo aprendizado durante os dois anos em que estive por lá.

“A persistência é o caminho do êxito.”
Charles Chaplin

RESUMO

Existem diversos métodos de Estimação Ótima de Parâmetros. Em identificação de sistemas é necessário um sinal de excitação rico, que excite suficientemente o sistema. Se a relação entrada/saída não for capaz de gerar informação suficiente, qualquer técnica de Estimação Ótima de Parâmetros (OPE) falhará. O processo de identificação de sistemas em malha fechada é fundamental para situações em que a planta possui não linearidades e comportamentos que são difíceis de prever e com estabilidade não garantida para malha aberta. Este trabalho apresenta uma análise da metodologia SOESGOPE para a estimação dos parâmetros de um sistema em malha fechada e a geração de sinal de excitação para o experimento. Para a identificação de sistemas não lineares em malha fechada é necessário um controlador simples que mantenha o sistema estável e que permita a passagem de frequências que sensibilizem adequadamente o sistema. A metodologia SOESGOPE é responsável pela busca de um sinal de excitação para o experimento que seja compatível com o controlador, de modo que a excitação do sinal fornecido seja suficiente para estimar os parâmetros. Para os casos em que as incertezas sobre os parâmetros dificultam o projeto do controlador, foi proposta uma nova abordagem da metodologia, visando sintonizar um controlador simples e eficiente para a estimação de parâmetros. A nova abordagem proposta busca, a partir do processo de otimização em duas camadas, um conjunto de controladores para manter o sistema estável e que seja compatível com o sinal de excitação para o processo de estimação de parâmetros. A nova abordagem da metodologia SOESGOPE apresenta resultados positivos para aplicação em VANTs, sendo seu desempenho satisfatório na estimação dos parâmetros em todos os cenários considerados. O erro obtido nas estimativas dos parâmetros chegou a diminuir até 1,5% em um dos parâmetros, na nova abordagem, o tempo de convergência do novo algoritmo chegou a reduzir na faixa de 100 segundos e a entropia dos sinais utilizados para a estimação paramétrica chegou a ter um aumento de 3,3646 quando comparado a metodologia original, garantindo que a informação para a estimação paramétrica não seja perdida quando o sinal de excitação é filtrado pelo controlador do sistema.

Palavras-chave: Quadrotor. Identificação de sistemas. Estimação Ótima de Parâmetros. Projeto de Entradas Ótimas. Entropia. Controlador.

ABSTRACT

There are several methods of optimal parameter estimation. In system identification, a rich excitation signal is required, which excites the system sufficiently. If the input/output ratio is not able to generate enough information, any OPE technique will necessarily fail. The process of identifying closed-loop systems is fundamental for situations in which the plant has non-linearities and behaviors that are difficult to predict and with stability not guaranteed for open-loop systems. This work presents an analysis of the SOESGOPE methodology for estimation of the parameters of a closed-loop system and excitation signal generation for the experiment. For the identification of closed loop non-linear systems, a simple controller is needed to preserve the system stable and to allow the passage of frequencies that adequately sensitize the system. For cases in which the uncertainties about the parameters complicate the design of the controller, a new approach to the methodology was proposed, aiming to find a simple and efficient controller for the estimation of parameters. The proposed new approach find, from the optimization process in two layers, a set of controllers to keep the system stable and compatible with with the excitation signal for the parameter estimation process. The new approach of the SOESGOPE methodology presents positive results for application in UAVs, with satisfactory performance in the estimation of parameters in all considered cases. The error obtained in the estimates of the parameters decreased to 1.5% in one of the parameters, in the new approach, the convergence time of the new algorithm was reduced in the range of 100 seconds and the entropy of the signals used for the parametric estimation increased by 3.3646 when compared to the original methodology, ensuring that the information for the parametric estimation is not lost when the excitation signal is filtered by the system controller.

Keywords: Quadrotor. System's identification. Optimal Parameter Estimation. Optimal Input Design. Entropy. Controller.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fluxograma do processo de identificação de sistemas.	21
Figura 2 – Exemplos de configurações de aeronaves de asa fixa.	32
Figura 3 – Exemplos de configurações de aeronaves de asa rotativa.	33
Figura 4 – Exemplos de aeronaves para monitoramento e mapeamento.	34
Figura 5 – Voo real do UAV durante a inspeção de linhas de transmissão de energia.	34
Figura 6 – Diagrama de blocos em malha fechada para o quadrotor.	37
Figura 7 – Diagrama de blocos em malha aberta para o quadrotor.	37
Figura 8 – Controlador PID do quadrotor simulado.	44
Figura 9 – Resposta obtida com a sintonia dos parâmetros do controlador pelo método <i>twiddle</i> - Eixos <i>roll</i> e <i>pitch</i> - Referência em vermelho e resposta obtida em azul.	45
Figura 10 – Resposta obtida com a sintonia dos parâmetros do controlador pelo método <i>twiddle</i> - Eixo <i>yaw</i> - Referência em vermelho e resposta obtida em azul.	45
Figura 11 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Cenário 1 - Caso 1.	50
Figura 12 – Ajustes dos estados p, q, r, ϕ, θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Cenário 1 - Caso 1.	51
Figura 13 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Cenário 1 - Caso 1.	55
Figura 14 – Ajustes dos estados p, q, r, ϕ, θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Cenário 1 - Caso 1.	56
Figura 15 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Cenário 3 - Caso 1.	58
Figura 16 – Ajustes dos estados p, q, r, ϕ, θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Cenário 3 - Caso 1.	59
Figura 17 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Caso 3b.	63
Figura 18 – Ajustes dos estados p, q, r, ϕ, θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Caso 3b.	64
Figura 19 – Diagrama de blocos da metodologia SOESGOPE em malha fechada.	69
Figura 20 – Lugar geométrico das raízes da equação característica do sistema - Eixos ϕ e θ	72
Figura 21 – Lugar geométrico das raízes da equação característica do sistema - Eixo ψ	73
Figura 22 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Caso 1.	75
Figura 23 – Ajustes dos estados p, q, r, ϕ, θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Caso 1.	76

Figura 24 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Caso 1.	78
Figura 25 – Ajustes dos estados p, q, r, ϕ, θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Caso 1.	78

LISTA DE TABELAS

Tabela 1 – Parâmetros do quadrotor do modelo real – Γ	36
Tabela 2 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Modelo real . .	45
Tabela 3 – Métricas obtidas na geração do conjunto de sinais - Primeiro Cenário .	50
Tabela 4 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Primeiro Cenário	52
Tabela 5 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Segundo Cenário	53
Tabela 6 – Conjunto de parâmetros iniciais e perturbados	54
Tabela 7 – Métricas obtidas na geração do conjunto de sinais - Primeiro Cenário .	54
Tabela 8 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Primeiro Cenário	56
Tabela 9 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Segundo Cenário	57
Tabela 10 – Conjunto de parâmetros iniciais e perturbados	58
Tabela 11 – Métricas obtidas na geração do conjunto de sinais - Quarto Cenário . .	58
Tabela 12 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Quarto Cenário	60
Tabela 13 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Caso 3b	62
Tabela 14 – Métricas obtidas na geração do conjunto de sinais - Comparação dos controladores	62
Tabela 15 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Comparação dos controladores	63
Tabela 16 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Batelada	64
Tabela 17 – Limites dos Controladores PID para os eixos ϕ , θ e ψ	73
Tabela 18 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Caso tutorial .	74
Tabela 19 – Métricas obtidas na geração do conjunto de sinais - Caso tutorial . . .	74
Tabela 20 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Caso tutorial .	76
Tabela 21 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Caso completo	77
Tabela 22 – Métricas obtidas na geração do conjunto de sinais - Caso completo . .	77
Tabela 23 – Estimação de parâmetros ótimos “ <i>a posteriori</i> ” – $\hat{\Gamma}^+$ – Caso completo .	79
Tabela 24 – Resultados metodologia original – Caso tutorial	79
Tabela 25 – Resultados metodologia aprimorada – Caso tutorial	80
Tabela 26 – Resultados comparativos entre a metodologia original e a metodologia aprimorada – Caso completo	80

LISTA DE ABREVIATURAS E SIGLAS

AABB	<i>Axis-Aligned Bounding Box</i>
AG	Algoritmo Genético
ARMAX	<i>AutoRegressive Moving Average with eXogenous inputs</i>
ARX	<i>AutoRegressive with eXogenous input</i>
BJ	<i>Box-Jenkins</i>
CNP	<i>Continuous Nonlinear Problem</i>
DBP	<i>Dynamic BackPropagation</i>
DNN	<i>Deep Neural Network</i>
DRNN	<i>Diagonal Recurrent Neural Network</i>
FCC	Função de Correlação Cruzada
GPS	<i>Global Positioning System</i>
LGR	Lugar Geométrico das Raízes
LQG	<i>Linear Quadratic Gaussian</i>
LQR	<i>Linear Quadratic Regulator</i>
MATLAB	<i>MATrix LABoratory</i>
MIMO	<i>Multiple-Input Multiple-Output</i>
MOESP	<i>Multivariable Output-Error State sPace</i>
NDS	<i>Nonlinear dynamic system</i>
NNARX	<i>Neural Network AutoRegressive with eXogenous inputs</i>
OID	<i>Optimal Input Design</i>
OPE	<i>Optimal Parameter Estimation</i>
PD	Proporcional-Derivativo
PID	Proporcional-Integral-Derivativo
PSLO	<i>Particle Swarm-Like Optimization</i>
PWM	<i>Pulse Width Modulation</i>

RNAs	Redes Neurais Artificiais
SBIP	<i>Safety Barrier Interior Point</i>
SDRNN	<i>Second order Diagonal Recurrent Neural Network</i>
SMI	<i>Subspace Model Identification</i>
SOESGOPE	<i>Sub-Optimal Excitation Signal Generation and Optimal Parameter Estimation</i>
TS	<i>Takagi-Sugeno</i>
TSK	<i>Takagi-Sugeno-Kang</i>
UAVs	<i>Unmanned Aerial Vehicles</i>
VANTS	Veículos Aéreos Não Tripulados

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS	17
1.2	ESTRUTURA DO TRABALHO	17
2	REVISÃO BIBLIOGRÁFICA	19
2.1	METODOLOGIA SOESGOPE	27
2.2	IMPLEMENTAÇÃO DA CAMADA EXTERNA	29
2.2.1	Operador do enxame de partículas	30
2.2.2	Crossover unitário	31
2.2.3	Mutação aleatória	31
2.2.4	Recombinação linear	31
3	FUNDAMENTAÇÃO TEÓRICA	32
3.1	MODELO DINÂMICO DO QUADROTOR	34
3.1.1	Modelo matemático simplificado	36
3.2	APLICAÇÃO DA METODOLOGIA SOESGOPE AO QUADROTOR	36
3.3	TÉCNICAS DE CONTROLE APLICADAS AOS QUADROTORES	38
3.3.1	Controle PID	40
3.4	ENTROPIA	42
4	PARAMETRIZAÇÃO DOS EXPERIMENTOS	43
4.1	CASO TUTORIAL	46
4.2	CASO COMPLETO	47
5	RESULTADOS E DISCUSSÕES - METODOLOGIA ORIGINAL	49
5.1	RESULTADOS - CASO TUTORIAL	49
5.1.1	Cenário 1: Diferentes modelos iniciais	49
5.1.2	Cenário 2: Estimacão a partir do mesmo sinal de excitação	52
5.2	RESULTADOS - CASO COMPLETO	53
5.2.1	Cenário 1: Diferentes modelos iniciais	54
5.2.2	Cenário 2: Estimacão a partir do mesmo sinal de excitação	56
5.2.3	Cenário 3: Sensibilidade à região de busca	57
6	APRIMORAMENTO DA METODOLOGIA SOESGOPE APLICADA AO QUADROTOR	61
6.1	ATUALIZAÇÃO DO CONTROLADOR EM BATELADA	62

6.2	OTIMIZAÇÃO RECURSIVA PARA O CONTROLADOR	65
6.2.1	Sintonia do controlador PID por <i>Successive Loop Closure</i>	67
6.3	ALGORITMO FINAL	68
7	RESULTADOS E DISCUSSÕES - METODOLOGIA APRI-	
	MORADA	71
7.1	LIMITES DOS CONTROLADORES	71
7.1.1	Eixos <i>roll</i> e <i>pitch</i>	71
7.1.2	Eixo <i>yaw</i>	72
7.2	SIMULAÇÕES	73
7.2.1	Caso tutorial	74
7.2.2	Caso completo	77
7.3	METODOLOGIA ORIGINAL X METODOLOGIA APRIMORADA . .	79
8	CONCLUSÕES FINAIS	82
8.1	TRABALHOS FUTUROS	85
	REFERÊNCIAS	86
	APÊNDICE A – PRODUÇÃO CIENTÍFICA	92
A.1	ARTIGO EM CONGRESSO NACIONAL	92

1 INTRODUÇÃO

Os sistemas dinâmicos são modelos matemáticos para muitos problemas na física, biologia, economia, engenharia, entre outros. Estes são, normalmente, associados às equações diferenciais. Os sistemas dinâmicos encontrados na prática são, em última análise, não lineares. Em alguns casos, aproximações lineares dos modelos são suficientes para aplicações práticas, entretanto, por outro lado, as representações não lineares devem ser utilizadas em alguns casos, trazendo um aumento na complexidade dos algoritmos a serem utilizados. A motivação para se utilizar os modelos não lineares vai além de melhorar a sua exatidão, como por exemplo, o fato de que modelos não lineares produzem certos regimes dinâmicos que os lineares não conseguem representar. Sistemas dinâmicos não lineares, como os veículos aéreos, veículos aquáticos, robôs móveis, entre outros, são desafiadores devido ao fato de seu comportamento não ser previsível e periódico. A análise de sistemas deste tipo deve ser feita cautelosamente, desde sua modelagem matemática até a execução final do projeto para o sistema.

Os modelos matemáticos dos sistemas podem ser obtidos por três vertentes: a modelagem caixa branca, caixa preta e caixa cinza [1]. A modelagem caixa branca baseia-se em compreender todas as variáveis referentes ao sistema em estudo, bem como as leis e princípios físicos devidamente aplicados. Sendo assim, este tipo de modelagem também é conhecida como modelagem pela física ou da natureza ou modelagem conceitual. A modelagem caixa preta, também conhecida como modelagem empírica, baseia-se em técnicas de identificação de sistemas, as quais procuram descrever as relações de causa e efeito entre as variáveis de entrada e saída. Este tipo de modelagem é aplicada quando o sistema dinâmico em estudo é muito complexo ou quando é possível obter os dados de respostas relacionando a evolução temporal das variáveis em estudo. Estas duas técnicas são consideradas como os extremos das técnicas de modelagem. Teoricamente, qualquer procedimento que não esteja nesses extremos pode ser denominado em modelagem caixa cinza. Neste caso, a modelagem utiliza algumas informações auxiliares, conhecidas do sistema, e dados de entrada e saída obtidos. Essa combinação visa agregar as vantagens dos procedimentos de modelagem caixa branca e caixa preta. A motivação para o estudo de técnicas de identificação de sistemas surge do fato que frequentemente não se conhecem as equações do sistema ou elas são conhecidas, mas seria impraticável, por limitações de tempo e recursos, levantar tais equações e estimar seus respectivos parâmetros.

A modelagem dos sistemas dinâmicos é uma das etapas mais importantes para a realização de projetos. Para o modelo obtido ser uma representação fiel do sistema, os parâmetros do modelo devem ser estimados adequadamente. Experimentos de estimação paramétrica ou identificação de sistemas podem ser executados para se obter um modelo mais fiel. Contudo, a qualidade do sinal de excitação e do método de estimação dos parâmetros são críticos para o sucesso do experimento. Em [2], uma nova metodologia ,

denominada SOESGOPE (*Sub-Optimal Excitation Signal Generation and Optimal Parameter Estimation*) foi apresentada. Seu intuito é obter a estimação dos parâmetros de sistemas não lineares. Tal método é responsável pela obtenção de um sinal de excitação confiável (OID – *Optimal Input Design*) e posteriormente pela estimação dos parâmetros do modelo (OPE – *Optimal Parameter Estimation*).

Tal metodologia, já testada em simulações, obteve resultados satisfatórios para aplicações de robôs móveis e veículos aquáticos [2]. A metodologia apresentada pode ser utilizada com uma abordagem em malha fechada para a estimação paramétrica, permitindo assim que uma análise de tal método seja realizada com um sistema altamente não linear e multivariável, dado pelo quadrotor. Sistemas não lineares, como os veículos aéreos, sofrem de um aspecto em comum, que é a estabilidade, tais sistemas não possuem estabilidade garantida em malha aberta e necessitam de uma lei de controle para manter o experimento estável e seguro. Independente de qual seja o controlador usado, é normalmente útil conhecer como a variável manipulada afeta a variável controlada. Frequentemente, a relação entre essas variáveis é dinâmica. Isso requer, portanto, um modelo dinâmico para quantificar a relação de causa e efeito que existe entre as variáveis em questão.

No desenvolvimento dos veículos aéreos, existem diversas linhas de pesquisa, dentre elas o desenvolvimento de robustos algoritmos de controle de baixo nível, tornando possível planejar seu movimento, detectar e evitar obstáculos e o voo autônomo, com capacidade de se localizar no ambiente. O quadrotor possui uma topologia e dinâmica diferenciada, o que permite manobras mais precisas em comparação a outros veículos aéreos. Um empecilho é o desafio no controle para integrar sensores, atuadores e inteligência do sistema, que deve ser leve e com tempo de operação muito rápido. Os quadrotores possuem uma dinâmica não linear e têm sido utilizados em diversas aplicações nas últimas décadas, por isso faz-se necessário o avanço no projeto de controladores e, para isso, modelos precisos se tornam uma parte vital do projeto. A este respeito, a identificação do sistema é conhecida há muito tempo como uma abordagem viável para a derivação de modelos dinâmicos orientados para controle no campo de aeronaves de asas rotativas. O uso de uma nova metodologia para estimação de parâmetros de sistemas não lineares, se torna viável ao se aplicar a quadrotores, para encontrar um modelo confiável para o sistema em estudo.

Em [2], a metodologia SOESGOPE foi apresentada e aplicada em abordagens em que o sinal de excitação obtido foi utilizado em malha aberta. Por fim, uma abordagem da metodologia foi considerada para o caso de um veículo aquático, em que os efeitos hidrodinâmicos e outras características não modeladas podem causar distorções no experimento, caso não haja uma lei de controle. Deste modo, a metodologia foi adaptada para sistemas em malha fechada. Para sistemas não lineares em malha fechada, é necessário que o controlador seja bem ajustado para não haver a perda de informação e conseqüentemente em problemas de identificação consideráveis. Para o caso em estudo, foi projetado um

controlador simples, respeitando as características reais do sistema.

Em identificação de sistemas de malha fechada, o controlador atua como um filtro para os sinais de referência, o que acarreta em perda de informação do sinal. O grande desafio em sistemas desta natureza está em conseguir obter um controlador que não reduza drasticamente a entropia dos sinais de controle. É necessário ter uma riqueza de excitação entre os sinais de entrada e saída. Desta forma, quando o controlador do sistema é incerto, é necessário obter uma representação que evite a perda de informação e, caso haja a perda de informação, que ela não resulte em problemas de identificação consideráveis.

1.1 OBJETIVOS

O objetivo do trabalho é analisar, avaliar e aprimorar a metodologia SOESGOPE, aplicada ao quadrotor. A partir da análise dos resultados obtidos com a metodologia original, propor uma extensão da metodologia, em malha fechada, que encontre um controlador que não provoque perda significativa de informação, considerando a aplicação do método em um quadrotor.

1.2 ESTRUTURA DO TRABALHO

Este trabalho está organizado como se segue. No Capítulo 2, uma revisão da bibliografia referente a identificação de sistemas e posteriormente a metodologia SOESGOPE é definida.

No Capítulo 3 é apresentado o modelo dinâmico do veículo aéreo trabalhado. O capítulo inicia-se com a modelagem matemática do sistema e em seguida uma breve revisão sobre o controle de sistemas dinâmicos, abordando a técnica de controle PID e sua sintonia pelo método de otimização *twiddle*, utilizado para o projeto trabalhado, além da descrição da proposta de utilizar e analisar a metodologia SOESGOPE na simulação de um quadrotor.

No Capítulo 4 é feita a parametrização dos experimentos a serem simulados utilizando a metodologia para a estimação dos parâmetros do veículo aéreo, com a indicação das definições aplicadas à metodologia e os cenários analisados.

No Capítulo 5 estão expostos os resultados obtidos através de simulações para a estimação paramétrica do veículo aéreo que servem de base para a análise da metodologia em malha fechada.

No Capítulo 6 é indicado o aprimoramento da metodologia SOESGOPE, para a estimação de parâmetros do quadrotor. É apresentada a motivação para tal avanço e a parametrização dos experimentos a serem realizados para comprovar a adição na metodologia, aplicada aos quadrotoros.

No Capítulo 7 estão expostos os resultados obtidos através de simulações para a estimação paramétrica do veículo aéreo, utilizando a metodologia SOESGOPE com o avanço indicado.

No Capítulo 8, apresentam-se as conclusões do trabalho, bem como as perspectivas de trabalhos futuros.

O Apêndice A se refere a produção científica oriunda deste trabalho.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma revisão sobre o processo de identificação de sistemas com a discussão de alguns trabalhos correlatos. Em seguida apresenta a definição da metodologia SOESGOPE que será utilizada para a estimação dos parâmetros de um quadrotor.

Um sistema é caracterizado por um conjunto de processos interconectados. Para um bom entendimento de tal, é necessário compreender a sua modelagem. O modelo matemático de um sistema dinâmico é definido como um conjunto de equações que representa a dinâmica do sistema com precisão ou, pelo menos, razoavelmente bem [3]. Um sistema pode ser representado por diversas maneiras e, portanto, pode possuir vários modelos matemáticos. A dinâmica de muitos sistemas pode ser descrita em termos de equações diferenciais, que são obtidas pelas leis da física que regem o sistema. Por exemplo, nos problemas de controle ótimo é vantajoso utilizar representações de espaço de estados. Por outro lado, para a análise de resposta transitória ou da resposta em frequência de um sistema linear, invariante no tempo, de entrada e saída únicas, a representação por função de transferência pode ser mais conveniente [3].

Há varias formas e técnicas de se obter modelos matemáticos, uma delas é a caixa branca. A modelagem teórica, ou caixa branca, é obtida através de um conjunto de equações que descrevam o comportamento do modelo, nesse caso, faz-se necessário conhecer a fundo o sistema a ser modelado, além de conhecer as relações matemáticas que descrevem os fenômenos envolvidos. A identificação de sistemas é uma área que estuda as técnicas alternativas de modelagem matemática, uma destas técnicas é conhecida como modelagem experimental, ou caixa preta, parte de premissas pré-estabelecidas que podem ser baseadas em uma análise teórica preliminar incompleta ou testes já realizados [1, 4]. A modelagem de veículos aéreos possui parte dos princípios físicos bem conhecidos [5, 6, 7].

De acordo com [1], existem cinco etapas envolvidas no processo de identificação de sistemas, são eles:

- **testes dinâmicos e coleta de dados:** uma vez que a identificação se propõe a obter o modelo a partir de dados, é necessário gerar tais dados. Os dados são obtidos a partir de medições das respostas, $y(k)$, do sistema quando aplicado um sinal, $u(k)$, previamente determinado. A velocidade do sinal, ou, a faixa de frequências em que um sinal tem potência espectral, deve ser cuidadosamente escolhida, quando o objetivo é excitar a dinâmica da planta;
- **escolha da representação matemática a ser usada:** avaliar a aplicação e determinar a melhor representação para o modelo, sua importância se dá ao fato da escolha ser realizada de acordo com as características do processo, o que implica

avaliar o sistema como dados com características altamente não lineares, o objetivo para o qual o modelo será utilizado;

- **determinação da estrutura do modelo:** escolha de polos e zeros, atraso de tempo, estabilidade do sistema, relacionar ao sistema estável e controlado;
- **estimação de parâmetros:** escolha do algoritmo a ser utilizado para a estimação;
- **validação do modelo:** verificar se os modelos encontrados incorporam ou não as características do sistema original.

Ao executar as etapas que constituem a identificação de um sistema, chega-se a um modelo ou a uma família de modelos. Comumente, em problemas de estimação atribui-se que o modelo da planta é exato. Entretanto, tais modelos não fornecem o sistema real como um todo e sim aproximações [1]. A diferença entre a planta real e o modelo obtido se deve a vários fatores como por exemplo, alterações bruscas dos parâmetros do sistema, não linearidades e comportamentos dinâmicos não analisados ou desconhecidos, retardos ou atrasos não incluídos no modelo, ruídos de componentes e perturbações imprevistas, entre outros. Contudo, se faz necessário verificar se o modelo obtido é satisfatório para a finalidade desejada, ou, se tratando de uma família de diversos modelos, é necessário identificar qual dos modelos é o mais apropriado. A última etapa da identificação de sistemas é a validação do modelo, logo, esta tem a função de avaliar, examinar e aceitar ou não o modelo em questão. Conforme [8], alguns critérios devem ser levados em conta na escolha do modelo, como: se o modelo representa de forma satisfatória os dados observados; se o modelo é suficientemente bom para o seu propósito de uso, e, por fim, se o modelo descreve o sistema real. É fundamental salientar que nenhum modelo incorporará todos os aspectos do sistema real. Entretanto, a validade do modelo passa pelo fato de incorporar as características que sejam fundamentais para a aplicação que se deseja fazer [1]. Recomenda-se que sejam utilizadas várias ferramentas e valide-se o modelo considerando um conjunto de indicadores em vez de um indicador só. Em resumo, o processo de identificação de sistemas pode ser definido pelo fluxograma representado na Figura 1.

A estimação de parâmetros é uma etapa do processo de identificação de sistemas [1]. Existem diversos métodos de Estimação Ótima de Parâmetros - *Optimal Parameter Estimation* (OPE). Para tal, é necessário um sinal de excitação rico, que excite suficientemente o sistema de forma que os parâmetros estimados se apliquem a uma série de outras entradas e não apenas ao sinal específico da excitação inicialmente utilizado. Se a relação entrada/saída não for capaz de gerar informação suficiente, qualquer técnica de OPE necessariamente falhará. A escolha do sinal é de grande valia, devido ao fato de exercer grande influência, não apenas no resultado final, mas na dinâmica e duração do experimento. Devido a isso, leva-se em consideração:

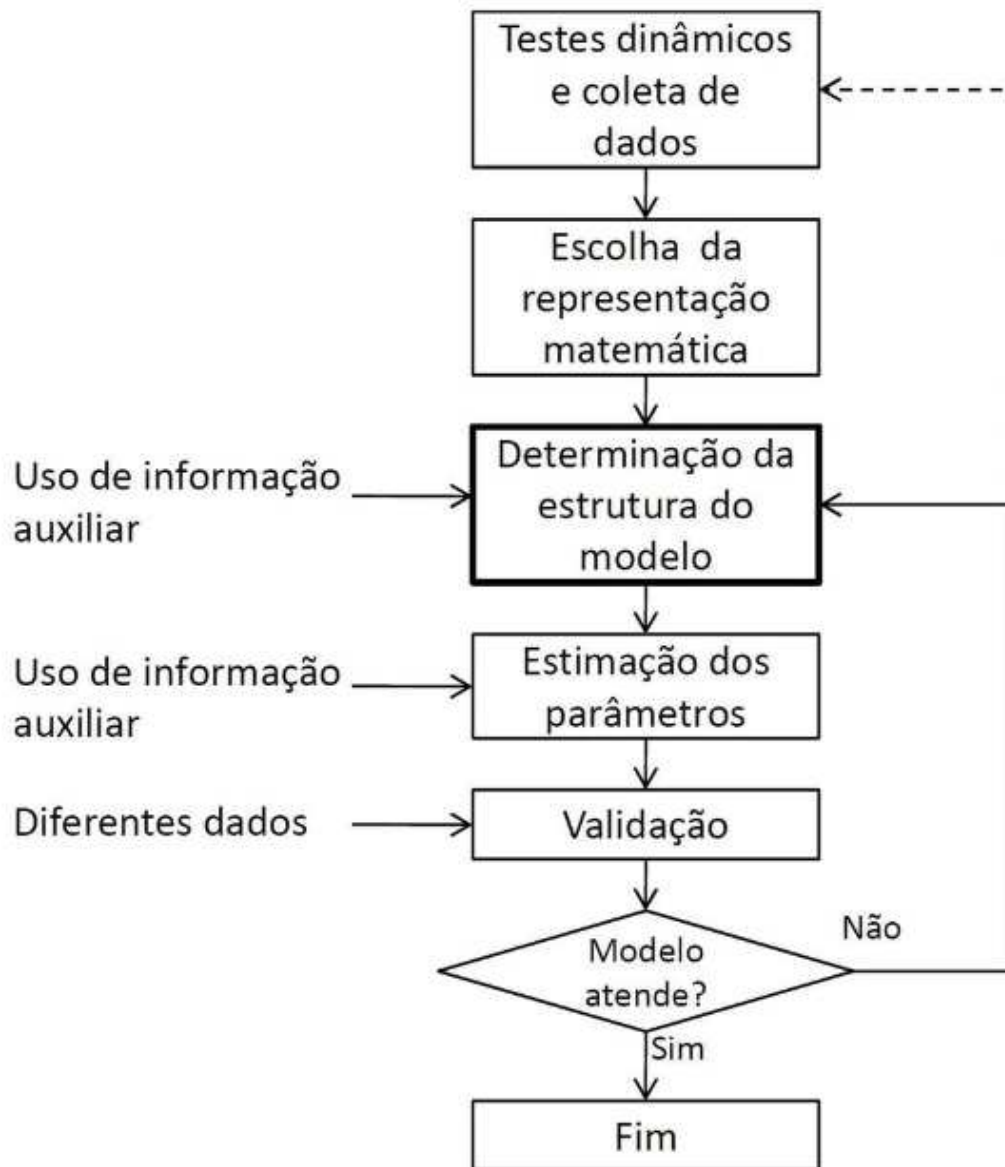


Figura 1 – Fluxograma do processo de identificação de sistemas.

[9]

- a geração do sinal deve ser trivial com descrição matemática simples;
- deve ser aplicável ao processo;
- deve prover excitação adequada a dinâmica do sistema em estudo.

[4]

Os sinais de excitação típicos podem ser classificados em: periódicos, determinísticos e estocásticos, esta última classe possui sinais conhecidos por sua riqueza do espectro de frequências e portanto são muito utilizados na especificação de parâmetros [10, 11]. O sinal deve ser limitado com restrições de ordem econômica - tempo, espaço e recursos -

e restrições de segurança [12]. Devido a este fato é comum que técnicas de OPE sejam utilizadas em conjunto com o Projeto de Sinais de Entrada Ótimos - *Optimal Input Design* (OID).

No contexto de estimação de estados, o clássico filtro de Kalman (do inglês, *Kalman filter* (KF)) foi proposto por [13] para sistemas lineares. Esse filtro é um estimador recursivo ótimo, que pode ser utilizado para estimar os estados de um sistema com incertezas representadas por variáveis aleatórias com distribuição gaussiana. Alguns estimadores, como o filtro de Kalman, podem ser interpretados como algoritmos que implementam uma função de densidade de probabilidade condicional e um critério de otimalidade. Devido as premissas de linearidade que lhe garantem otimalidade, o método original só se aplica a sistemas lineares. Baseado na otimalidade do KF para os sistemas lineares com incertezas gaussianas, outras abordagens foram propostas para lidar com os sistemas não lineares. No contexto de filtragem de Kalman para sistemas não lineares, uma dificuldade é a ausência de expressões matemáticas para determinar a matriz de covariância *a posteriori* analiticamente. Uma das abordagens propostas considera a aplicação do filtro, para sistemas não lineares, realizando a linearização analítica das equações do sistema em torno do estado atual e aplicando as equações do filtro de Kalman. Essa abordagem é conhecida como o filtro de Kalman estendido (do inglês, *Extended Kalman Filter* (EKF)) [14]. Alternativamente, [15] propõe uma solução que se baseia em escolher poucas realizações dos estados e saídas, mas que sejam representativas, no sentido de não haver diferenças entre as matrizes de covariância amostral calculadas a partir dessas poucas relações, ao se comparar com o cálculo das matrizes feito com um grande número de realizações. Este processo veio a ser conhecido como transformação *unscented*. Esta segunda abordagem ficou conhecida como o filtro de Kalman *unscented* (do inglês, *Unscented Kalman Filter* (UKF)).

O KF e suas derivações são estimadores baseados em conceitos estatísticos, considerando que as incertezas são representadas por variáveis aleatórias gaussianas ou aproximadas, no caso não linear, cujo domínio é ilimitado e com função de densidade de probabilidade completamente caracterizada por média e covariância. Essas incertezas são provenientes de entradas exógenas desconhecidas [16]. Outra maneira de se representar tais incertezas é baseada em associação de conjuntos que pode ser utilizada para representar conjuntos como intervalos, polítopos, poliedros, etc [17]. Esta representação considera as incertezas limitadas em regiões. Todas as técnicas de associação de conjuntos visam obter estimativas que indicam que os estados estão contidos nos conjuntos limitados. É apropriada para os casos em que as incertezas não são totalmente caracterizadas e o conhecimento é delimitado apenas por seus limites, motivo pelo qual a técnica sempre trata o pior caso de distúrbio.

Enquanto os algoritmos para o filtro de Kalman estão bem consolidados na literatura,

algoritmos baseados em associação de conjuntos vêm crescendo e ganhando notoriedade na literatura. Representações politópicas vêm sendo utilizadas para tratar sistemas não lineares. Esta representação por ser convexa, permite a utilização de desigualdades matriciais lineares (do inglês, *Linear Matrix Inequalities* (LMIs)) para resolver diversos problemas existentes na área de modelagem e controle de sistemas, tanto lineares quanto não lineares. As LMIs são computacionalmente eficientes, caracterizam os limites de desempenho do sistema, possuem uma flexibilidade para tratar diversos casos (sistemas incertos, invariantes no tempo, etc) e oferecem uma robustez ao sistema [18].

Na literatura de identificação de sistemas, uma das principais novidades das últimas duas décadas foi o desenvolvimento dos chamados métodos de identificação baseados em subespaços - *Subspace Model Identification* (SMI) ([19, 20]), que têm se mostrado extremamente bem sucedidos em lidar com a estimativa de modelos de espaço de estados para sistemas de múltiplas entradas e saídas. Surpreendentemente, apesar da facilidade com que o SMI pode ser explorado ao lidar com problemas de modelagem MIMO (*Multiple-Input Multiple-Output*), até recentemente esses métodos receberam atenção limitada da comunidade de aeronaves de asas rotativas, com exceção parcial de algumas contribuições, como em [21]. Recentemente o interesse em SMI para identificação de modelos de helicópteros foi revivido, no entanto, até o momento, apenas métodos e ferramentas que datam de 10 a 15 anos na literatura SMI foram considerados [22, 23]. Portanto, os benefícios potenciais adicionais oferecidos pelos desenvolvimentos mais recentes no campo não foram totalmente explorados.

O trabalho proposto por [24] dedica-se à modelagem matemática do tempo de vida de baterias de dispositivos móveis utilizando estruturas de modelos paramétricos lineares da teoria de identificação de sistemas. As estruturas de modelos utilizadas foram ARX (*AutoRegressive with eXogenous inputs*), ARMAX (*AutoRegressive Moving Average with eXogenous inputs*) e BJ (*Box-Jenkins*). Os parâmetros de cada modelo foram estimados a partir de dados do sistema real obtidos por uma plataforma experimental. Nos ensaios experimentais foi utilizada uma bateria Modelo Nokia BL-5L (presente em celulares Nokia N95). Finalizando o trabalho, [24] compara os modelos estimados com o modelo real (experimental) e identifica qual modelo estimado apresentou melhor resultado.

Outros trabalhos abordaram a identificação de sistemas não lineares. Um modelo de Rede Neural Dinâmica para identificação de sistemas não lineares é encontrado no estudo feito por [25]. Nesta pesquisa, os autores apresentam uma nova Rede Neural Dinâmica baseada na Rede Neural de Hopfield para realizar a identificação de um sistema não linear. A análise de convergência foi efetuada fazendo uso do critério de Lyapunov para garantir a convergência de erros no processo de identificação. Este critério foi aplicado para derivar as leis de treinamento adaptativo de fatores de ponderação da Rede Neural Profunda (*Deep Neural Network* - (DNN)), baseando-se em Hopfield. De acordo com os

resultados obtidos através de simulações realizadas, pode-se constatar que o identificador DNN baseado na Rede Neural de Hopfield teve um bom desempenho na identificação do sistema perante análise gráfica.

Uma investigação acerca do procedimento de identificação de sistemas não lineares utilizando uma Rede Neural Recorrente Diagonal de Segunda Ordem, é enfatizado em pesquisa por [26]. Nesta aplicação, os autores fazem uso de uma Rede Neural Recorrente Diagonal de Segunda Ordem (*Second Order Diagonal Recurrent Neural Network* - (SDRNN)) baseando-se no algoritmo dinâmico de retropropagação do erro (*Dynamic Backpropagation* - (DBP)), incluindo termo de *momentum* (determinação das mudanças passadas dos pesos). O método de identificação apresentado sobrepuja as desvantagens como velocidade convergente lenta e captura do mínimo local. A Rede Neural Recorrente Diagonal de Segunda Ordem (SDRNN) é similar a Rede Neural Recorrente Diagonal (*Diagonal Recurrent Neural Network* - (DRNN)) na sua estrutura. A (DRNN) faz uso de dois atrasos com derivação (*tapped delays*) em seus neurônios ocultos, a estrutura simples da (DRNN) manteve-se e a identificação do sistema não linear foi feita pela (SDRNN). A arquitetura de identificação aplicada na modelagem foi a serial-paralela. Através dos resultados obtidos na simulação pode-se verificar que o algoritmo aprimorado é eficaz, tendo como proveito: a rápida convergência, uma maior precisão na identificação, melhor adaptabilidade e robustez na identificação do sistema. Além disto, apropriado para identificação em tempo real do sistema dinâmico.

Quando se trata de sistemas não lineares, a utilização de Redes Neurais Artificiais (RNAs) como ferramenta para identificação de sistemas é usual. Em 2017, [27] propôs a identificação do sistema de pêndulo invertido não linear usando rede neural *Multilayer Perceptron*. A RNA foi avaliada para vários números de neurônios de camada oculta, e observou-se que em condições de malha fechada, o aumento nos números de neurônios ocultos tem menos efeito na precisão do modelo.

Em 2018, [28] propuseram a modelagem e controle de um motor CC por meio de técnicas de identificação de sistemas. Para isso foi utilizado a estrutura de identificação NNARX (*Neural Network AutoRegressive with eXogenous inputs*) e o algoritmo de Levenberg-Marquardt para treinamento da rede. Os resultados mostram uma boa aproximação do modelo em relação ao sistema real, em que os resultados dessa modelagem são aplicados no controle do motor CC.

Dentre as RNAs utilizadas como ferramentas de identificação, a MLP (*MultiLayer Perceptron*) é uma das mais usuais. A exemplo de [29], que apresentou uma investigação experimental de uma rede MLP para modelar toda a dinâmica de um Sistema de Manobra Flexível. Basicamente, trata-se de uma estrutura complexa não linear, semelhante a um helicóptero em menor escala. A abordagem introduzida é comprovada experimentalmente empregando as habilidades de adaptação da RNA para identificar a dinâmica do sistema. Os

resultados mostram um desempenho superior das redes neurais em termos de generalização de modelos, predição de resposta e desempenho em domínios de tempo e frequência.

Em [30], apresentaram o desenvolvimento e testes de um *software* para identificação de dinâmicas de um sistema não linear de tanques acoplados, utilizando Redes Neurais Artificiais do tipo MLP. A estrutura de modelagem utilizada foi do tipo NNARX. O *software* é genérico possibilitando ao usuário fazer vários ensaios com quantidades diferentes de camadas escondidas e número de neurônios. Além disso, é possível alterar as funções de ativação e ainda fazer uma análise da curva de aprendizagem através de sua interface. O *software* permite fazer a validação de duas formas diferentes, podendo ser com o sistema em malha aberta ou em malha fechada, possibilitando ainda a realimentação do modelo com dados reais ou dados estimados do modelo.

Em [31] é proposto uma metodologia de identificação de sistemas MIMO não lineares no modelo Fuzzy TSK (*Takagi-Sugeno-Kang*), em que o Algoritmo Genético - (AG) é usado para ajustar os parâmetros da função de pertinência. Esta metodologia é utilizada na identificação de uma coluna de destilação MIMO não linear, e os resultados mostram que a proposta com AG possui maior acurácia que o modelo Fuzzy TSK convencional, o qual foi ajustado por tentativa e erro.

No trabalho de [32] é abordado a identificação de sistemas MIMO não lineares com modelos de blocos interconectados de Hammerstein-Wiener, em que o bloco dinâmico linear é estimado pelo algoritmo MOESP (*Multivariable Output-Error State sPace*) de identificação de subespaço. A técnica proposta é aplicada a um sistema de tanques acoplados e a um reator químico, ambos simulados.

Identificação de sistemas não lineares com modelo multivariável de espaço de estados de Hammerstein, em que o bloco não linear é aproximado de um sistema de inferência Fuzzy TSK é abordado no trabalho [33]. Os resultados mostram a identificação *on-line* de um sistema dinâmico MIMO com não linearidade complexa combinada, e também em um processo de evaporação de três entradas e três saídas.

No trabalho [34] é proposta uma metodologia de identificação de sistemas multivariáveis na qual o algoritmo genético é utilizado para realizar o ajuste de funções de pertinência multidimensionais, e o sistema Fuzzy TS (*Takagi-Sugeno*) é usado para modelar e identificar o sistema não linear. A presente metodologia é aplicada à um sistema de tanques acoplados e os resultados mostram que a metodologia proposta alcançou menor erro de identificação comparada a identificação com TS tradicional.

No trabalho [2] foi proposta uma nova metodologia para a obtenção de sinais para OPE conjuntamente com uma metodologia para a estimação paramétrica de sistemas dinâmicos não lineares. A obtenção de sinais de excitação nem sempre é trivial. O sinal deve conter excitação suficiente para que o sistema opere na região desejada, principalmente

quando se trata de sistemas não lineares. Tal proposta se mostra vantajosa, devido ao fato de obter sinais de entrada, suficientemente excitantes, que são capazes de estimar parâmetros do sistema, de maneira confiável. Diante do exposto, o presente trabalho se baseia na metodologia a fim de obter estimativas de parâmetros de um sistema altamente não linear e em malha fechada, visando encontrar um sinal suficientemente excitante que em conjunto com o controlador não acarrete em perda de informação necessária para a estimação dos parâmetros. A metodologia SOESGOPE é composta por dois eficientes algoritmos de otimização dispostos em uma estratégia de camada dupla. A camada interna é responsável por encontrar a estimativa ótima do conjunto de parâmetros para um dado sinal de excitação, através da minimização do erro quadrático dos sinais de saída desejado e do obtido pelo modelo paramétrico. Utiliza o algoritmo de pontos interiores com barreira de segurança, SBIP - *Safety Barrier Interior Point* -[35], devido ao fato de apresentar maior estabilidade numérica, tempo de convergência reduzido e possibilidade de usar as variáveis duais (variáveis de folga (*slack variables*) e os multiplicadores de Lagrange) para analisar as soluções nas fronteiras de otimização. O resultado desta camada é um conjunto de parâmetros ótimos que minimiza o erro do sinal de saída da planta com o do modelo [2].

Já a camada externa, tem por objetivo gerar e avaliar cada sinal utilizado pela camada interna, utilizando uma função custo multi-objetivo composta pela soma ponderada das seguintes métricas:

- valor final obtido pela função objetivo da camada interna;
- erro quadrático da comparação entre os parâmetros da planta real e os obtidos pelo modelo;
- custo do experimento (o sinal deve minimizar o tempo de experimento e o espaço utilizado).

A primeira e terceira métricas são triviais de serem obtidas, porém a segunda se torna um desafio já que os valores reais dos parâmetros do sistema analisado não são conhecidos. Como os resultados da OPE são usados como métrica de qualidade do sinal, é considerado que o experimento de estimação é um problema de otimização interna, encapsulado pelo problema de otimização do sinal [2].

Segundo [2], a metodologia é comprovada a partir da seguinte hipótese:

”Se for possível gerar um modelo caixa branca inicial, cujos parâmetros são previamente levantados, de um sistema não linear que se deseja estimar, é possível criar um segundo modelo derivado da caixa branca que possa ser utilizado como um sistema de referência. Desta forma, se um sinal for rico o suficiente para identificar os parâmetros

deste sistema de referência, também será rico o suficiente para identificar os parâmetros do sistema não linear real.”

2.1 METODOLOGIA SOESGOPE

Considere um sistema dinâmico não linear, (*Nonlinear Dynamical System* - NDS), definido por $\mathcal{R}(\Gamma)$ que pode ser satisfatoriamente aproximado por um modelo não linear paramétrico $\mathcal{M}(\Gamma)$ de n estados, p entradas, m saídas e r parâmetros, definido da seguinte forma:

$$\mathcal{M}(\Gamma) := \begin{cases} \dot{x}(t) = f(x(t), u(t), \Gamma) \\ y(t) = h(x(t), u(t), \Gamma) \end{cases} \quad (2.1)$$

Com estado inicial $x_0 = x(0)$, em que $x(t) \in \mathbb{R}^n \mid x(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T$ é o vetor de estados, $u(t) \in \mathbb{R}^p \mid u(t) = [u_1(t), u_2(t), \dots, u_p(t)]^T$ é o vetor de entradas, $y(t) \in \mathbb{R}^m \mid y(t) = [y_1(t), y_2(t), \dots, y_m(t)]^T$ é o vetor de saída e $\Gamma \in \mathbb{R}^r \mid \Gamma = [\gamma_1, \gamma_2, \dots, \gamma_r]^T$ é o vetor que representa o conjunto de parâmetros do modelo.

- x representa a trajetória dos estados, isto é, o histórico dos estados no intervalo de tempo $T = [t_0, t_f]$;
- u representa o histórico das entradas;
- y representa o histórico de saídas.

[36]

O vetor Γ é o melhor conjunto de parâmetros do sistema, de modo que \mathcal{M} representa satisfatoriamente \mathcal{R} . O conjunto $\hat{\Gamma}^- = [\hat{\gamma}_1^-, \hat{\gamma}_2^-, \dots, \hat{\gamma}_r^-]$ é uma estimativa "a priori" suficientemente boa de Γ , capaz de emular razoavelmente o comportamento de $\mathcal{R}(\Gamma)$. O sinal de entrada u_i , $i \in \{1, 2, \dots, p\}$ é um sinal discreto, com taxa de amostragem fixa, capaz de excitar p entradas do sistema.

O objetivo da metodologia é gerar um sinal de entrada sub(ótimo) u^\oplus para ser usado em um experimento com um NDS $\mathcal{R}(\Gamma)$ real. Sinais estocásticos possuem uma riqueza no espectro de frequências, sendo muito utilizados para estimação de parâmetros. O sinal deve ser persistentemente excitante para que uma estimativa "a posteriori" ótima $\hat{\Gamma}^+ = [\hat{\gamma}_1^+, \hat{\gamma}_2^+, \dots, \hat{\gamma}_r^+]$ seja obtida, tal que $\mathcal{M}(\hat{\Gamma}^+) \approx \mathcal{R}(\Gamma)$.

É necessário fornecer uma estimativa "a priori" dos parâmetros, conjuntamente com uma estimativa de confiança em cada parâmetro, isso permitirá a criação de um modelo perturbado. A estimativa "a priori" pode ser obtida através de uma modelagem caixa

branca, ou modelagem teórica, sendo obtida de um conjunto de equações previamente conhecidas pelas leis da física, química, etc., que descrevem o comportamento do sistema.

A metodologia SOESGOPE é composta por dois eficientes algoritmos de otimização dispostos em uma estratégia de camada dupla. A camada interna é responsável por encontrar a estimativa ótima do conjunto de parâmetros “*a posteriori*” $\hat{\Gamma}^+$ para um dado sinal de excitação, através da minimização do erro quadrático dos sinais de saída da planta e do obtido pelo modelo paramétrico $\mathcal{M}(\Gamma)$ através da minimização:

$$f_o(\cdot) = \begin{cases} \underset{\hat{\delta}^+}{\text{minimize}} & \sum_{k=0}^{t_u} \varepsilon(k) \\ \text{sujeito a} & -\Delta \leq \hat{\delta}^+ \leq \Delta \end{cases} \quad (2.2)$$

no qual, $\varepsilon(k) = \|\hat{\mathbf{x}}^+(k) - \mathbf{x}(k)\| + \|\hat{\mathbf{y}}^+(k) - \mathbf{y}(k)\|$ é a diferença quadrática entre o estado do modelo estimado $\hat{\mathbf{x}}^+$ e o estado do sistema \mathbf{x} , somado à diferença quadrática entre a saída do modelo estimado $\hat{\mathbf{y}}^+$ e a saída do sistema \mathbf{y} , no instante k . O vetor Δ determina a faixa de busca aceitável para os parâmetros.

Utiliza o algoritmo SBIP, devido ao fato de apresentar maior estabilidade numérica, tempo de convergência reduzido e possibilidade de usar as variáveis duais (variáveis de folga – *slack variables*– e os multiplicadores de Lagrange) para analisar as soluções nas fronteiras de otimização [35].

O resultado desta camada é a variação de parâmetros ótima $\hat{\delta}^+$, que minimiza o erro do sinal de saída da planta com o do modelo $\mathcal{M}(\hat{\Gamma}^+)$, fazendo $\hat{\Gamma}^+ = \hat{\Gamma}^- + \hat{\delta}^+$, onde $\hat{\Gamma}^-$ é o conjunto de parâmetros “*a priori*”, uma estimativa anterior dos parâmetros do sistema [37].

A camada externa, tem por objetivo gerar e avaliar cada sinal utilizado pela camada interna, utilizando uma função custo multi-objetivo:

$$\underset{\mathbf{u}, \hat{\delta}^+}{\text{minimize}} \quad \kappa_1 \Theta(\cdot) + \kappa_2 f_o(\cdot) + \kappa_3 f_{\hat{\delta}}(\cdot) \quad (2.3)$$

onde $\kappa_1 \gg \gg \kappa_2, \kappa_3$

em que $\kappa_1, \kappa_2, \kappa_3 \in \mathbb{R}_{\geq 0}$ são ganhos de ponderação das funções objetivo, $f_o(\cdot)$, e $f_{\hat{\delta}}(\cdot)$ representam a avaliação do sinal em respeito à precisão de saída, e função de recuperabilidade de parâmetros, respectivamente.

A função $\Theta(\cdot)$ representa a avaliação do sinal em relação às restrições de tempo, saída e espaço de estados:

$$\Theta(\cdot) \begin{cases} \frac{1}{\kappa_1} t_u + \frac{\kappa_t}{\kappa_1} f_V(\tilde{\mathbf{x}}^p) + \frac{\kappa_t}{\kappa_1} f_V(\tilde{\mathbf{y}}^p), & \text{se } \sum_{\tilde{\mathbf{x}}^p, \tilde{\mathbf{y}}^p, t_u} \Psi(\cdot) \leq \alpha \\ \Psi(\tilde{\mathbf{x}}^p) + \Psi(\tilde{\mathbf{y}}^p) + \Psi(t_u) + 1, & \text{caso contrário} \end{cases} \quad (2.4)$$

no qual, t_u é a duração do experimento, κ_t um ganho de ponderação, f_V é o volume do *Axis-Aligned Bounding Box* – AABB, que contem os estados $\tilde{\mathbf{x}}^p$ e as saídas $\tilde{\mathbf{y}}^p$, de um modelo $\mathcal{M}(\tilde{\Gamma}^p)$, com parâmetros perturbados $\tilde{\Gamma}^p$. As funções $\Psi(\cdot)$ são penalidades cumulativas, avaliadas em tempo, estados e saídas, que devem estar entre limites mínimos e máximos. Os sinais gerados são parametrizados de modo a serem similares a sinais APRBS – *Amplitude Modulated Pseudo Randomic Binary Signals*, e sua otimização é feita por uma variação do algoritmo *Particle Swarm Optimization* (PSO), proposto por [38]. Para aumentar taxa de convergência, é utilizado α -constrain, que permite nas primeiras iterações que algumas penalidades sejam ignoradas, através de um valor de uma variável α , que diminui com o número de iterações do PSO.

Deste modo, é possível se ponderar a importância de cada métrica com os ganhos κ_1 , κ_2 , κ_3 e κ_t , de modo a obter sinais (sub)ótimos de excitação \mathbf{u}^\oplus , com duração adequada, que utilize uma região confinada e segura do espaço de estados, e que tenham características de excitação condizentes com as necessidades do sistema.

2.2 IMPLEMENTAÇÃO DA CAMADA EXTERNA

Para encontrar um sinal de excitação sub(ótimo) \mathbf{u}^\oplus é necessário primeiramente definir sua representação matemática, de modo que seja possível executar operações básicas com este sinal [2].

Dado o vetor, $\Xi \in \mathbb{R}^{2pk}$, que representa os componentes do sinal u dividido em k estágios:

$$\Xi := \left[t_1^{u_1}, \dots, t_k^{u_1}, t_1^{u_2}, \dots, t_k^{u_2}, t_1^{u_p}, \dots, t_k^{u_p}, a_1^{u_1}, \dots, a_k^{u_1}, a_1^{u_2}, \dots, a_k^{u_2}, a_1^{u_p}, \dots, a_k^{u_p} \right] \quad (2.5)$$

em que:

- $1 \leq i \leq k$ e $1 \leq j \leq p$ representa o i -ésimo estágio do j -ésimo componente da entrada;
- $t_i^{u_j}$ e $a_i^{u_j}$ são, respectivamente, o tempo de execução e a amplitude do estágio.

[2]

A partir daí, é possível gerar o sinal. É importante observar que o tempo de cada componente do sinal é equalizado de acordo com o maior tempo de equalização de todos, isso porque cada componente pode possuir tempo de execução diferente, obtendo assim um tempo comum entre eles. Logo, os componentes do sinal de tempo de execução menores ficam em um *loop* de repetição até que o de maior tempo execute.

É definida, desta forma, a métrica de avaliação do sinal, dada por:

$$f_{\Xi} = \underset{\Xi}{\text{minimize}} \quad \kappa_1 \Theta(\cdot | \cdot, \Xi) + \kappa_2 f_o(\cdot | \Theta) + \kappa_3 f_{\delta}(\cdot | f_o) \quad (2.6)$$

Para resolver o problema da Equação 2.6 é proposto um novo algoritmo baseado em enxame de partículas - *Particle Swarm-Like Optimization* (PSLO).

A população do PSLO consiste de $z \in \mathbb{N}$ sinais Ξ em que, a avaliação de um dado sinal id é representada por f_{Ξ}^{id} . O progresso de busca é uma combinação de operadores globais e locais que visam a convergência e/ou divergência entre os indivíduos, baseado na metodologia proposta em [7] de maneira simplificada, com quatro operadores. É definido que o algoritmo obteve convergência pela *flag*

$$fPop = 0 \quad (2.7)$$

que acontece quando as seguintes condições são satisfeitas:

$$(\kappa_1 \Theta \leq \epsilon_1) \cap (\kappa_2 f_o \leq \epsilon_2) \cap (\kappa_3 f_{\delta} \leq \epsilon_3) \cup (I_i \geq I_{max}) \quad (2.8)$$

em que, $\epsilon_1, \epsilon_2, \epsilon_3 \in \mathbb{R}$ são os índices de cada medida de aptidão, definidos pelo usuário. $I_{max} \in \mathbb{N}$ é o número máximo de iterações e I_i é a iteração corrente. Até o critério de convergência ser encontrado, para cada iteração, um dos seguintes operadores é escolhido para evoluir a população [2].

2.2.1 Operador do enxame de partículas

Este operador considera o deslocamento do indivíduo Ξ^{id} no espaço de solução, com velocidade $V \in \mathbb{R}^{2pk}$ definida por [2]:

$$V^{id} = c_{in} V^{id} + c_1 rnd(0,1) \times (\Xi^{id,best} - \Xi^{id}) + c_2 rnd(0,1) \times (\Xi^{BEST} - \Xi^{id}) \quad (2.9)$$

em que $c_{in} \in \mathbb{R}$ é o parâmetro de inércia, c_1 e $c_2 \in \mathbb{R}$ são os coeficientes do tamanho do passo, e $rnd(0,1) \in \mathbb{R} | rnd(0,1) \subset [0,1]$ é um número aleatório. A atualização da população é dada por:

$$\Xi^{id} = \Xi^{id} + w_{id} \times V^{id}, \forall id \in \{1,2,\dots,z\} \quad (2.10)$$

tal que, $w_{id} \in \mathbb{R}$ é o parâmetro de inovação. É assumido que $c_{in} = 0,2$, $c_1 = 0,5$ e $c_2 = 0,3$.

2.2.2 Crossover unitário

Este operador gera um novo indivíduo a partir de uma mistura uniforme dos parâmetros de dois outros indivíduos, o indivíduo pai e um indivíduo aleatório. Para um dado indivíduo pai $\Xi^{id,best}$, um segundo indivíduo $\Xi^{n,best}$ com $id \neq n$ é selecionado aleatoriamente. Eles darão origem a um novo indivíduo Ξ^0 , com uma mistura uniforme dos seus parâmetros, de modo que para cada parâmetro d [2]:

$$\Xi_d^0 := \begin{cases} \Xi_d^{id,best}, & \text{if } rnd(0,1) \leq 0.5 \\ \Xi_d^{n,best}, & \text{otherwise} \end{cases} \quad (2.11)$$

em que para cada parâmetro p , um novo $rnd(0,1)$ é selecionado.

2.2.3 Mutação aleatória

Este operador gera um novo indivíduo Ξ^0 aleatoriamente, nos parâmetros do pior indivíduo $\Xi^{id,best}$ presente na população Pop [2].

$$\Xi_d^0 := rnd(0,9; 1,1) \times \Xi_d^{id,best} \quad (2.12)$$

em que para cada p uma nova amostra aleatória é gerada.

2.2.4 Recombinação linear

Para um dado indivíduo pai $\Xi^{id,best}$, um segundo $\Xi^{n,best}$ é aleatoriamente escolhido, com $id \neq n$. Este operador gera um novo indivíduo Ξ^0 como uma combinação linear dos dois indivíduos pais [2].

$$\Xi^0 := \Xi^{id,best} + rnd(-1,5; +1,5) \times (\Xi^{n,best} - \Xi^{id,best}) \quad (2.13)$$

Identificação de sistemas dinâmicos não lineares é um problema que continua a desafiar pesquisadores e se mantém fundamental e em crescente em diversas áreas da engenharia. Nesse contexto, a metodologia SOESGOPE foi recentemente proposta e se apresenta promissora para a estimação de parâmetros de quadrotoros, devido a sua possibilidade de utilização em malha fechada.

3 FUNDAMENTAÇÃO TEÓRICA

O objetivo deste capítulo é analisar o sistema não linear que será trabalhado junto a metodologia, partindo de sua definição, aplicações e indo até a sua modelagem matemática. Com o modelo matemático bem definido, é feita uma análise do comportamento da metodologia para a aplicação em quadrotor, planta fortemente não linear e desafiadora do ponto de vista do controle.

Os veículos aéreos não tripulados (UAV's - *Unmanned Aerial Vehicles*) são alvo de estudo em diversas áreas das engenharias e tecnologias, entre as engenharias aeroespacial, mecânica, eletrônica, controle e automação, robótica e também a ciência da computação. São de pequeno e médio porte e possuem inteligência para desenvolverem determinadas tarefas, sejam remotamente operados ou totalmente independentes. As tarefas podem ser das mais diversificadas, desde as mais simples como acompanhamento de trajetórias, até mais complexas como monitoramento de áreas e linhas de transmissão de energia.

Os veículos aéreos possuem uma classificação segundo a sua topologia: aeronaves de asa fixa (aviões), asa rotativa (helicópteros e multicópteros) entre outras, como balões, dirigíveis, etc. Nas Figuras 2 e 3 estão representados alguns modelos destas topologias.



Figura 2 – Exemplos de configurações de aeronaves de asa fixa.

[39]

Os veículos aéreos de asa fixa possuem como característica o voo de longo alcance e alta duração, muito utilizados para monitoramento e busca em grandes áreas; os de asa rotativa possuem a capacidade de pairar, voar em altitudes muito baixas, girar em torno de seu próprio eixo e mover para trás e para os lados, muito utilizados em situações que exigem uma maior precisão.

Os VANTs (Veículos Aéreos Não Tripulados) estão cada vez mais presentes na

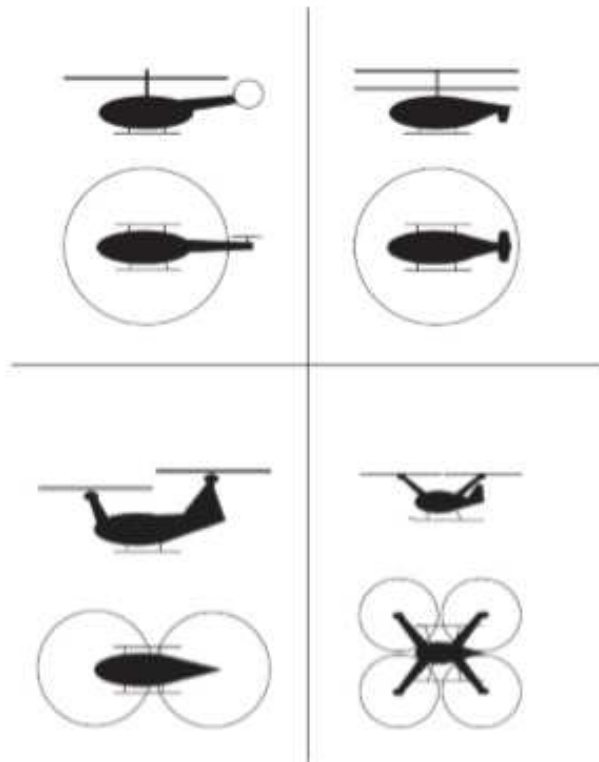


Figura 3 – Exemplos de configurações de aeronaves de asa rotativa.

[39]

engenharia, como, por exemplo, na aquisição de imagens aéreas e monitoramento [40], inspeção de dutos e linhas de transmissão de energia [41], mapeamento e pulverização de plantações [42], visando redução de custo, aumento de segurança e a preservação da vida humana.

Em um cenário de busca e salvamento o tempo é crítico e qualquer atraso pode resultar em perdas humanas e animais. Os VANTs podem ser muito úteis em tais situações devido ao fato de serem ágeis e conseguirem ter acesso a locais hostis para os seres humanos. Nos atuais desastres ocorridos pelo rompimento de barragens em Minas Gerais, os drones foram utilizados para a busca por pessoas desaparecidas.

Os veículos aéreos podem também, se equipados com câmera e GPS (*Global Positioning System* - Sistema de Posicionamento Global), realizar o monitoramento e mapeamento de ambientes. Com uma trajetória pré-determinada, eles realizam voos com a finalidade de reconhecer ambientes, identificar queimadas e desmatamento em áreas naturais. Outra aplicação que está em crescente, é o uso dos quadrotores para a identificação do ambiente para a instalação de placas solares em residências e empresas.

Além da identificação dos ambientes para a instalação de painéis solares, os quadrotores também são utilizados para realizar inspeções em linhas de transmissão de alta voltagem, isso porque é uma tarefa de alta periculosidade e pode ser realizada sem a



Figura 4 – Exemplos de aeronaves para monitoramento e mapeamento.

[43]

exposição do ser humano com um menor custo de operação.



Figura 5 – Voo real do UAV durante a inspeção de linhas de transmissão de energia.

[44]

Com o recente avanço do estudo e as crescentes aplicações dos veículos aéreos, obter modelos mais precisos e confiáveis se tornou um aspecto importante para a sua aplicação. Para isso, conhecer e alcançar o modelo matemático fiel ao veículo é um ponto primordial para a sua aplicação.

3.1 MODELO DINÂMICO DO QUADROTOR

A primeira e segunda etapas para a identificação de sistemas, geralmente são definidas em conjunto. Os testes dinâmicos e coletas de dados fazem parte da modelagem matemática do sistema, e a partir daí define-se qual a representação matemática a ser utilizada.

Para modelar o sistema proposto é necessário o entendimento de algumas teorias a respeito dos quadrotoros e seu funcionamento. O modelo matemático apresentado é encontrado em [45], passo a passo.

A definição do modelo dinâmico inicia-se com a representação matemática da planta em estudo. Para a modelagem simplificada de um quadrotor, considera-se uma esfera maciça no centro, com massa M , raio R e massas pontuais m localizadas a uma distância l do centro. Além dos parâmetros mensuráveis coletados, existem dois parâmetros que podem ser obtidos experimentalmente, que são as constantes que relacionam de modo linear a força dos atuadores com o sinal PWM (*Pulse Width Modulation*) aplicado aos motores, k_1 e k_2 .

O modelo dinâmico do quadrotor em questão é definido através da representação matemática do modelo para o controle do veículo:

$$\begin{pmatrix} \dot{p}_n \\ \dot{p}_e \\ \dot{h} \end{pmatrix} = \begin{pmatrix} c\theta c\psi & s\phi s\theta c\psi - c\phi s\psi & c\phi s\theta c\psi + s\phi s\psi \\ c\theta s\psi & s\phi s\theta s\psi + c\phi c\psi & c\phi s\theta s\psi - s\phi c\psi \\ s\theta & -s\phi c\theta & -c\phi c\theta \end{pmatrix} \begin{pmatrix} u \\ v \\ w \end{pmatrix} \quad (3.1)$$

$$\begin{pmatrix} \dot{u} \\ \dot{v} \\ \dot{w} \end{pmatrix} = \begin{pmatrix} rv - qw \\ pw - ru \\ qu - pv \end{pmatrix} + \begin{pmatrix} -g \sin \theta \\ g \cos \theta \sin \phi \\ g \cos \theta \cos \phi \end{pmatrix} + \frac{1}{m} \begin{pmatrix} 0 \\ 0 \\ -F \end{pmatrix} \quad (3.2)$$

$$\begin{pmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{pmatrix} = \begin{pmatrix} 1 & \sin \phi \tan \theta & \cos \phi \tan \theta \\ 0 & \cos \phi & -\sin \phi \\ 0 & \frac{\sin \phi}{\cos \theta} & \frac{\cos \phi}{\cos \theta} \end{pmatrix} \begin{pmatrix} p \\ q \\ r \end{pmatrix} \quad (3.3)$$

$$\begin{pmatrix} \dot{p} \\ \dot{q} \\ \dot{r} \end{pmatrix} = \begin{pmatrix} \frac{J_y - J_z}{J_x} qr \\ \frac{J_z - J_x}{J_y} pr \\ \frac{J_x - J_y}{J_z} pq \end{pmatrix} + \begin{pmatrix} \frac{1}{J_x} \tau_\phi \\ \frac{1}{J_y} \tau_\theta \\ \frac{1}{J_z} \tau_\psi \end{pmatrix} \quad (3.4)$$

Os momentos de inércia em cada eixo, podem ser calculados da seguinte forma:

$$J_x = \frac{2MR^2}{5} + 2l^2m \quad (3.5)$$

$$J_y = \frac{2MR^2}{5} + 2l^2m \quad (3.6)$$

$$J_z = \frac{2MR^2}{5} + 4l^2m \quad (3.7)$$

Dado o modelo dinâmico, é possível realizar o controle angular utilizando diversas técnicas de controle distintas.

Os parâmetros estruturais do projeto estão representados na Tabela 1 abaixo:

Tabela 1 – Parâmetros do quadrotor do modelo real – Γ

Parâmetro	Valor	Unidade
M	1,00	kg
m	0,105	kg
R	0,10	m
l	0,25	m
k_1	0,0268	s.u
k_2	0,0147	s.u

3.1.1 Modelo matemático simplificado

As equações de movimento do quadrotor descritas ao longo do tópico de modelagem podem ser simplificadas para o cálculo dos controladores. O modelo simplificado do quadrotor é dado por:

$$\ddot{p}_n = -\cos\phi \sin\theta \frac{F}{m} \quad (3.8)$$

$$\ddot{p}_e = \sin\phi \frac{F}{m} \quad (3.9)$$

$$\ddot{h} = g - \cos\phi \cos\theta \frac{F}{m} \quad (3.10)$$

$$\ddot{\phi} = \frac{1}{J_x} \tau_\phi \quad (3.11)$$

$$\ddot{\theta} = \frac{1}{J_y} \tau_\theta \quad (3.12)$$

$$\ddot{\psi} = \frac{1}{J_z} \tau_\psi \quad (3.13)$$

3.2 APLICAÇÃO DA METODOLOGIA SOESGOPE AO QUADROTOR

Em [2] foram feitos testes em robôs diferenciais e tanques utilizando a metodologia SOESGOPE. Em tais testes, o sinal sub(ótimo), capaz de excitar o sistema, foi obtido em malha aberta, visto que para tais casos esta técnica é considerada segura. Já para o veículo aquático, os efeitos hidrodinâmicos e outras características não modeladas podem causar distorções ao experimento, e levar o veículo a condições perigosas, caso não haja a lei de controle. Desta forma, [2] propõe uma variação do uso da metodologia SOESGOPE para malha fechada, em que os sinais \mathbf{u}^\oplus serão usados como referências para os controladores

do veículo. Do mesmo modo, para os veículos aéreos, tal variação da metodologia será utilizada, visto que o sistema é naturalmente instável e necessita de uma lei de controle. O ambiente onde o experimento real deve ser aplicado é bastante desafiador e o uso de malha fechada aumenta consideravelmente a segurança do experimento.

Para a simulação da metodologia SOESGOPE em um quadrotor é necessário o modelo estar bem definido e controlado, para, a partir daí, se obter os sinais sub(ótimos) e a estimação ótima dos parâmetros a serem encontrados. Para simplificar o problema de estimação paramétrica, será considerado que toda a imprecisão no modelo é relativa aos parâmetros estruturais da aeronave. Analisando as posições angulares do quadrotor, dadas por três graus de liberdade do sistema (Equações 3.3 e 3.4), é possível realizar a estimação dos seis parâmetros estruturais do veículo aéreo, além de o sistema ser não linear e com estabilidade crítica para controle angular. Dado isso, o sistema deve ser analisado em malha aberta e malha fechada, conforme as Figuras abaixo:




Figura 6 – Diagrama de blocos em malha fechada para o quadrotor.




Figura 7 – Diagrama de blocos em malha aberta para o quadrotor.

Os sinais de excitação são gerados através da lei de controle para $\mathcal{M}(\hat{\Gamma}^p)$, e aplicados em malha aberta para a estimação de $\hat{\Gamma}^+$. Isso implica que as saídas do sistema estimado não estão correlacionadas com suas entradas, e o sistema se comporta como em uma estimação paramétrica em malha aberta convencional, reconhecidamente mais trivial. O controlador deve ser projetado de acordo com as características do sistema real, permitindo a passagem de frequências que sensibilizem adequadamente o sistema, isso quer dizer que, no caso de um controlador bem ajustado, a perda de informação não acarretará em problemas de identificação consideráveis, a depender da qualidade do sinal.

A Figura 6 representa o sistema em malha fechada. A entrada são os ângulos de referência dos eixos *roll*, *pitch* e *yaw*. Tal referência é comparada com os ângulos de saída do sistema e obtém-se o erro entre a saída e a referência. O erro é processado no controlador PID a fim de tornar o sistema o mais estável e fiel a referência. Os torques do sistema são enviados a matriz de modelagem para serem transformados em força de cada um dos motores das hélices do quadrotor, com a finalidade de saturar os motores e

não permitir valores fora do escopo para o PWM para não danificar o sistema. Após a saturação retorna-se para os torques controlados do sistema que são aplicados ao modelo para obter os ângulos de saída. A transformação dos torques do sistema para as forças aplicadas ao PWM é feita através da matriz M e sua pseudo-inversa, calculada através da matriz de Moore-Penrose. A obtenção da inversa da matriz M não é possível devido ao fato de não ser uma matriz quadrada, com isso, aplica-se o método da pseudo-inversa. A matriz M é definida como pela Equação 3.14 [45].

$$M = \begin{pmatrix} 0 & -lk_1 & 0 & lk_1 \\ lk_1 & 0 & -lk_1 & 0 \\ -k_2 & k_2 & -k_2 & k_2 \end{pmatrix} \quad (3.14)$$

E a sua pseudo-inversa é dada pela Equação 3.15:

$$M^{-1} = \begin{pmatrix} 0 & \frac{1}{2lk_1} & -\frac{1}{4k_2} \\ -\frac{1}{2lk_1} & 0 & \frac{1}{4k_2} \\ 0 & -\frac{1}{2lk_1} & -\frac{1}{4k_2} \\ \frac{1}{2lk_1} & 0 & \frac{1}{4k_2} \end{pmatrix} \quad (3.15)$$

As variáveis de estado de um sistema dinâmico são aquelas que constituem o menor conjunto de variáveis capaz de descrever todo o comportamento do sistema [3]. Para o quadrotor em questão, as variáveis de estado são $x = [p \ q \ r \ \phi \ \theta \ \psi]^T$ em que, p , q e r são as velocidades angulares em cada eixo, *roll*, *pitch* e *yaw*, respectivamente, e *phi*, *theta* e *psi* são os ângulos de Euler para cada eixo. As variáveis de entrada são $y = [\phi \ \theta \ \psi]^T$. O objetivo é, dado uma estimativa inicial para os parâmetros, encontrar um sinal de excitação capaz de obter a estimativa "a posteriori".

Os quatro primeiros parâmetros da Tabela 1 podem ser medidos de forma simples. Os dois últimos parâmetros, são as constantes que relacionam de modo linear a força dos atuadores com o sinal PWM (*Pulse Width Modulation*) aplicado aos motores, k_1 e k_2 , são as fontes pertinentes de imprecisão, devido ao fato de serem obtidas a partir de testes práticos [46]. A metodologia é analisada para a estimação destes dois parâmetros e também para a estimação completa do quadrotor.

A partir de uma modelagem adequada, seguida de uma busca eficiente dos parâmetros desconhecidos, feita com a metodologia, será permitido o desenvolvimento de controladores de alto desempenho para a planta.

3.3 TÉCNICAS DE CONTROLE APLICADAS AOS QUADROTORES

Em quadrotores, o controle de estabilidade possui características não lineares e multivariáveis [47], sendo necessário o desenvolvimento de leis de controle simples e

robustas. As técnicas de controle aplicadas aos quadrotoros encontradas na literatura são: PD (Proporcional-Derivativo) [48], PID (Proporcional-Integral-Derivativo) [49], LQR (*Linear Quadratic Regulator*) [50], LQG (*Linear Quadratic Gaussian*) [51], *Lyapunov* [52, 53], *Sliding Mode* [48, 54, 55], *Backstepping* [48, 52, 55, 56], *Fuzzy* [57], redes neurais [58] e *Reinforcement Learning* [54].

O cálculo dos parâmetros do controlador PID pode ser realizado através de diversas técnicas de sintonia: alocação dos polos e zeros obtendo o valor de margem de fase e ganho desejados [59]; através da saturação de atuadores (*Successive Loop Closure*) [46], ou por otimização (método *twiddle*) [60]. Na realidade, um controlador PD é suficiente, porém com o aumento da velocidade, o erro entre o ângulo desejado e o ângulo medido aumenta, aplicar o controle integral em conjunto é uma alternativa para minimizar o erro estacionário do sistema [49]. O PID apresenta bons resultados para trajetórias simples, baixas velocidades e em ambientes fechados. Em velocidades mais altas e na presença de distúrbios de vento, o controle é inadequado para o acompanhamento de trajetórias exatas em ambientes não controlados [49]. Uma comparação feita entre as técnicas de controle *Sliding Mode*, PD e *Backstepping*, indica que a primeira técnica obteve melhores resultados [48].

Para o controle de estabilidade de um quadrotor, três etapas são fundamentais:

- Modelagem dinâmica, a fim de obter uma representação matemática fiel do sistema mecânico;
- Projeto do quadrotor, com o objetivo de integrar sensores, atuadores e inteligência do sistema para minimizar o tempo de operação e o peso da aeronave;
- Projeto do controlador, para compreender e dominar a dinâmica do veículo e aplicar as técnicas de controle desejadas.

No processo de identificação de sistemas, a representação do modelo dinâmico a ser estudado é de grande valia. A definição do modelo dinâmico inicia-se com a representação matemática da planta em estudo, representação esta, que pode ser determinada a partir das leis da física, através de equações diferenciais, e assim obter a função de transferência, que relaciona a entrada e a saída, do sistema. Dado o modelo dinâmico, é possível realizar o controle do sistema utilizando diversas técnicas de controle distintas.

Um controlador automático compara o valor real de saída da planta com a entrada de referência (valor desejado), determina o desvio (erro) e produz um sinal de controle que reduzirá o desvio a zero ou a um valor pequeno. A maneira pela qual o controlador automático produz o sinal de controle, é chamada ação de controle [3]. A maioria dos controladores podem ser classificados de acordo com suas ações de controle, dentre

elas, as ações de controle clássicas estão divididas em: controlador *on-off*; controladores proporcionais; controladores integrais; controladores proporcional-integrais; controladores proporcional-derivativos; controladores proporcional-integral-derivativos [4].

A escolha do tipo de controlador a ser utilizado deve ser decidida com base na natureza da planta e nas condições de operação, incluindo certas considerações como segurança, custo, disponibilidade, confiabilidade, precisão, peso e tamanho [3]. Os sinais de entrada dos sistemas controlados típicos utilizados, são geralmente, degrau, rampa, parábola de aceleração, impulso, senoidais e ruído branco. Se as entradas de um sistema de controle são funções de tempo que variam gradualmente, então a rampa é um bom sinal de teste. Se um sistema estiver sujeito a mudanças bruscas de entrada, a função degrau poderá ser um bom sinal de teste. Do mesmo modo, se o sistema estiver sujeito a entradas de impacto, a função impulso poderá ser a melhor opção. Uma vez projetado o sistema de controle com base nos sinais teste, o desempenho do sistema deve ser analisado e geralmente satisfatório [3].

3.3.1 Controle PID

A técnica de controle PID é a combinação das ações de controle proporcional, integral e derivativo. Esta ação combinada tem as vantagens individuais de cada uma das três ações de controle [3]. A ação de controle proporcional é, simplesmente, um amplificador com ganho ajustável, utilizado para amplificar a saída para o valor de referência. Em sistemas cuja função de transferência não possui um integrador $\frac{1}{s}$, existe um erro estacionário, ou erro residual, na resposta a uma entrada em degrau. Este erro residual pode ser eliminado se uma ação de controle integral for incluída no controlador. A ação de controle integral, embora remova o erro residual, pode conduzir a uma resposta oscilatória com uma amplitude que decresce lentamente ou mesmo uma amplitude sempre decrescente. Já a ação de controle derivativa permite que se obtenha um controlador de alta sensibilidade, responde a uma taxa de variação do erro atuante e pode produzir uma correção significativa antes que o valor do erro atuante se torne muito elevado, em linhas gerais, o controle derivativo prevê o erro atuante, inicia uma ação corretiva antecipada e tende a aumentar a estabilidade do sistema. A ação derivativa não atua diretamente no erro estacionário, mas ele aumenta o amortecimento do sistema, tornando mais fácil a aplicação do controle integral, resultando numa maior precisão em regime permanente. Devido ao fato da ação de controle derivativo atuar sobre a taxa de variação do erro atuante e não sobre o próprio erro, ela nunca é utilizada sozinha [3].

A equação de um controlador com essas ações combinadas é dada por:

$$u(t) = K_p e(t) + \frac{K_p}{T_i} \int_0^t e(t) dt + K_p T_d \frac{de(t)}{dt} \quad (3.16)$$

e a função de transferência é:

$$\frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{T_i s} + T_d s \right) \quad (3.17)$$

no qual, K_p é o ganho proporcional, T_i é o tempo integrativo e T_d é o tempo derivativo. Para se projetar o controlador PID é necessário determinar tais constantes. Existem diversos métodos para a sintonia de controladores, como por exemplo o *Successive Loop Closure* que implica que o desempenho do sistema é algumas vezes limitado por restrições de saturação dos atuadores [46]. De forma resumida, tal método de sintonia, realiza os ajustes dos parâmetros a partir do conhecimento da saturação do sistema. Para quadrotores o método pode ser aplicado [46]. Além deste método, diversos outros são encontrados na literatura, como Ziegler-Nichols [3].

Outro método utilizado para a sintonia do controlador PID é o método *twiddle*. Este método, baseado num processo de otimização, possui grande versatilidade, podendo ser aplicado a qualquer processo, tendo sido aplicado inclusive em quadrotores [61]. O método *twiddle* foi criado baseado em estratégia de sintonia fina e nos critérios de desempenho de integrais de erro para gerar uma técnica que minimize o erro médio medido na resposta da planta. Para executar o método, é importante conseguir reproduzir a performance da planta a ser controlada em uma simulação, pois para atingir a minimização do erro podem ser necessárias muitas iterações.

O método tem como parâmetros um vetor P de ganhos a serem inseridos no controlador PID ($P = [K_p, T_i, T_d]$), um vetor dP de variação diferencial para os ganhos de P , e uma porcentagem de variação ξ para os parâmetros do vetor dP . Inicialmente, os valores de P são inseridos no controlador PID, e a simulação executa um teste com estes valores, medindo o erro total E obtido. A seguir, o primeiro parâmetro de P (K_p), é acrescido de dP e o teste é refeito. Caso o valor de E seja menor do que na iteração anterior, o que indica que a variação feita foi na direção certa, o valor de K_p continua sendo acrescido de dP . Caso contrário, tenta-se variar K_p na direção contrária, decrescendo este por dP . Obtendo piora de resultado em ambas as direções, tenta-se novamente reduzindo o valor de dP por ξ , e assim sucessivamente até que a variação de resultado seja desprezível, passando então para o próximo parâmetro (T_i). Após executar o mesmo processo por todos os parâmetros, são obtidos os valores de K_p , T_i e T_d para os quais são obtidos os menores valores de erro atingidos. O método não garante atingir precisamente o mínimo global do sistema, porém se mostra altamente eficiente para a grande maioria dos casos [60].

3.4 ENTROPIA

Em identificação de sistemas em malha fechada, deve-se contornar dois problemas para se obter uma boa estimativa do sistema em estudo. O primeiro é a correlação dada entre o sinal de entrada e o sinal de saída. Este problema é contornado pela metodologia SOESGOPE no instante em que os sinais de excitação obtidos são gerados por uma lei de controle para o sistema perturbado e aplicados em malha aberta para a estimação dos parâmetros, evitando que as saídas do sistema estimado estejam correlacionadas com as entradas, fazendo com que o sistema se comporte como em uma estimação paramétrica em malha aberta convencional. O segundo problema se refere ao controlador do sistema. O controlador atua como um filtro para os sinais de referência, o que acarreta em perda de informação do sinal. Desta forma, o controlador deve ser sintonizado de acordo com o sistema real, para permitir a passagem de frequências que sensibilizem adequadamente o sistema. No caso de um controlador bem ajustado, a perda de informação não acarretará em problemas de identificação consideráveis, a depender da qualidade do sinal de excitação.

O conceito de entropia, está intimamente relacionado ao conceito de informação. A análise da entropia portanto, pode ser verificada para observar se o controlador mascarou os dados dos sinais e com isso perdeu informação necessária para a identificação. A entropia informacional de um sinal é definida como [62]:

$$H = - \sum_{j=1}^N p_j \log_2 p_j \quad (3.18)$$

Em que, para N amostras de um sinal, cada um com probabilidade p_j , esta expressão pode ser interpretada como a esperança matemática da quantidade de informação considerando o sinal completo N .

4 PARAMETRIZAÇÃO DOS EXPERIMENTOS

O capítulo anterior abordou a modelagem matemática do quadrotor que será utilizado para a estimação de parâmetros com a metodologia SOESGOPE e as configurações da metodologia em malha fechada para o veículo aéreo. O objetivo deste capítulo é analisar o comportamento desta metodologia, explorando características para aplicação em quadrotor. Serão apresentadas algumas definições importantes para a utilização da metodologia SOESGOPE, utilizadas nos experimentos, e a identificação dos cenários, em que a metodologia é aplicada, para uma melhor análise do método.

O quadrotor simulado será considerado como um sistema $\mathcal{M}(\Gamma)$, cujos parâmetros $\Gamma = [M, m, R, l, k_1, k_2]^T$ possuem os valores indicados na Tabela 1, baseados em [46]. Para a estimação paramétrica pela metodologia SOESGOPE, é necessário uma estimativa a priori $\hat{\Gamma}^-$ dos parâmetros e uma perturbação da estimativa $\tilde{\Gamma}^p$. Os parâmetros perturbados foram gerados aleatoriamente utilizando a estimativa inicial numa faixa de 30%. A região de busca dos parâmetros foi definida por Δ , de modo que os parâmetros encontrados estarão confinados a $\hat{\Gamma}^- \pm \Delta$. A região de busca é definida de acordo com a imprecisão do sistema, quanto maior a confiança sobre a estimativa inicial do parâmetro, menor o seu espaço de busca e vice-versa.

O sistema é composto por $n = 6$ estados $\mathbf{x} = [p, q, r, \phi, \theta, \psi]^T$, em que p , q e r são as velocidades angulares em cada eixo, *roll*, *pitch* e *yaw*, respectivamente. Serão consideradas $m = 3$ saídas controláveis, os ângulos da aeronave $\mathbf{y} = [\phi, \theta, \psi]^T$. O modelo ainda considera que os estados e as saídas estão corrompidos por ruído gaussiano branco $\mathcal{N}(0, \sigma)$, com intuito de emular os ruídos dos processos reais. O desvio padrão do ruído presente nos estados e nas saídas foram considerados $\sigma_{\mathbf{x}} = [10^{-3}, 10^{-3}, 10^{-3}, \frac{\pi}{180}, \frac{\pi}{180}, \frac{\pi}{180}]^T$ e $\sigma_{\mathbf{y}} = [\frac{\pi}{180}, \frac{\pi}{180}, \frac{\pi}{180}]^T$, respectivamente.

Para preservar o quadrotor, foi delimitada uma região de segurança de operação no espaço de estados (e portanto também nas saídas). Os máximos e mínimos permitidos para os estados nesse experimentos foram $\mathcal{O}\mathbf{x}_{\max} = [10^5, 10^5, 10^5, \frac{\pi}{3}, \frac{\pi}{3}, \frac{\pi}{3}]^T$ e $\mathcal{O}\mathbf{x}_{\min} = [-10^5, -10^5, -10^5, -\frac{\pi}{3}, -\frac{\pi}{3}, -\frac{\pi}{3}]^T$, respectivamente. Note que apenas as saídas (os três últimos estados) estão de fato limitadas, por restrições de segurança no voo da aeronave, os estados relativos às velocidades não foram impostas restrições, por se considerar que sua estabilidade é garantida pelos controladores que são capazes de manter a segurança do experimento. Para implementação eles são ajustados com valores inatingíveis pelo modelo (pequenos ou grandes demais) de modo que são ignorados pelo otimizador no cálculo de $\Psi(\cdot)$. No projeto em questão, os estados receberam valores arbitrariamente altos.

Por fim, o sinal de excitação u^\oplus foi parametrizado de modo a gerar referências para os controladores de ϕ , θ e ψ . Os sinais serão compostos de 5 estágios, com duração variável entre $\mathbf{t}_{\min} = [0,071; 0,071; 0,105]^T$ e $\mathbf{t}_{\max} = [3,565; 3,565; 5,250]^T$. Essa duração

foi escolhida de modo que o estágio mínimo tenha duração de um décimo da constante de tempo estimada para o sistema, e o máximo tenha a duração de cinco constantes de tempo, visto que é razoável afirmar que o veículo não consegue reagir a estágios 10 vezes mais rápidos que a constante de tempo. Do mesmo modo, pode se considerar que o veículo se encontrará em regime permanente após 4 constantes de tempo. Como há um desconhecimento parcial dos parâmetros, pode haver uma diferença nesta constante. Portanto, o tempo máximo de cada sinal foi definido como 5 vezes a constante de tempo. A amplitude das referências foi proposta de modo a respeitar as restrições angulares, de modo que não excedam os limites máximos permitidos para cada eixo $\pm \frac{1\pi}{3}$ (ou $\pm 60^\circ$) para *roll* e *pitch* e 1π (ou $\pm 180^\circ$) para *yaw*.

Para a metodologia ser utilizada em malha fechada, um controlador deve ser projetado para manter o sistema estável. Existem diversos controladores que podem ser aplicados aos quadrotoros. Para o caso em estudo, serão utilizados os controladores mais simples que garantam estabilidade do veículo. O método utilizado para a sintonia do controlador PID foi o método *twiddle*.

Foram realizadas duas abordagens para o algoritmo *twiddle*, uma para determinar o controlador para os eixos *roll* e *pitch*, que são simétricos, e uma para determinar o controlador para o eixo *yaw*.

Para a sintonia do controlador PID pelo método *twiddle* o diagrama de blocos que representa o modelo simulado é dado pela Figura 8, apenas com a mudança do modelo entre as duas abordagens.

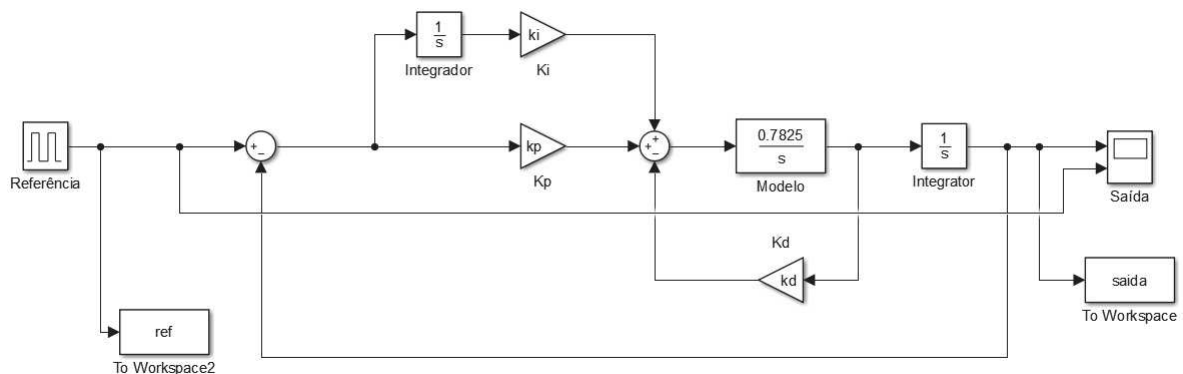


Figura 8 – Controlador PID do quadrotor simulado.

Para a primeira abordagem, o algoritmo realizou 143 iterações e para a segunda, 132 iterações, procurando obter o menor valor para a integral do erro absoluto do sistema. Os ganhos obtidos para os controladores são apresentados na Tabela 2:

Com tais parâmetros, aplicando uma referência de amplitude de dez graus de inclinação para os eixos *roll* e *pitch*, o sistema controlado se comportou conforme a Figura

Tabela 2 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Modelo real

	K_p	K_i	K_d
ϕ, θ	9,2566	0	0,2205
ψ	3,7261	0	0,5473

9. O eixo *yaw* também obteve uma boa resposta a sintonia do controlador pelo método *twiddle*. Todos os graus de liberdade controlados obtiveram estabilidade e convergiram para a referência desejada.

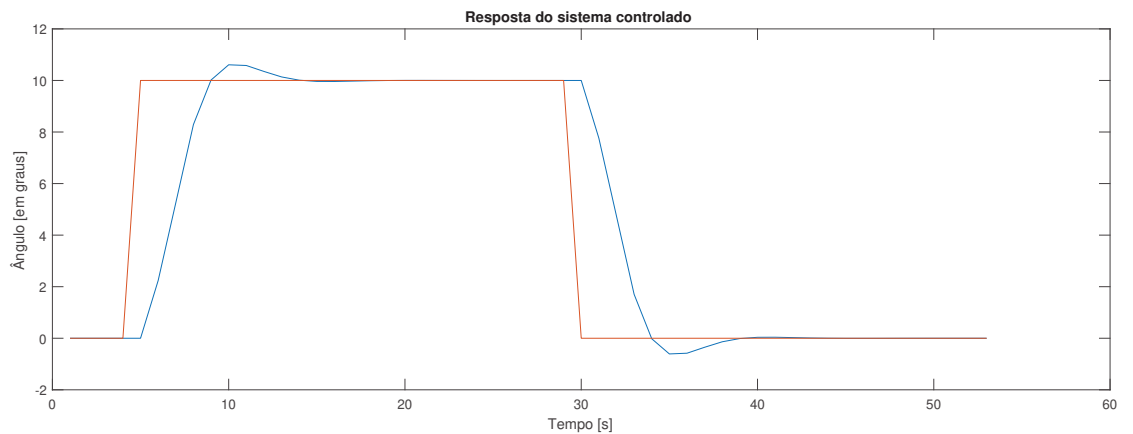


Figura 9 – Resposta obtida com a sintonia dos parâmetros do controlador pelo método *twiddle* - Eixos *roll* e *pitch* - Referência em vermelho e resposta obtida em azul.

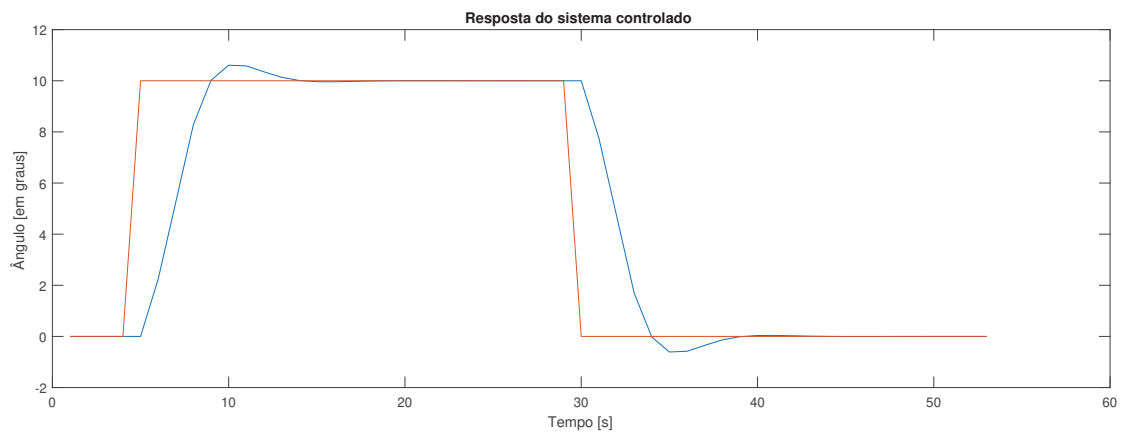


Figura 10 – Resposta obtida com a sintonia dos parâmetros do controlador pelo método *twiddle* - Eixo *yaw* - Referência em vermelho e resposta obtida em azul.

Os resultados obtidos foram divididos em dois grupos, um caso tutorial, com a estimação paramétrica de apenas dois parâmetros do quadrotor e um caso completo, com a estimação dos seis parâmetros do quadrotor.

Em [2], foi feita uma análise do impacto do número de partículas usadas para obter um sinal sub(ótimo), onde foram analisados quatro cenários, com 5, 10, 25 e 100 partículas usadas para a resolução do problema de otimização, através do PSLO apresentado. Como resultados observados, a conclusão é de que quanto maior o número de partículas, menores foram todos os termos da função objetivo, portanto maior convergência para o conjunto dos parâmetros reais com menor tempo de estimação e utilizando uma porção menor do espaço de estados. Para as simulações realizadas para o quadrotor, foram adotadas 100 partículas para o problema de otimização, seguindo os resultados obtidos no trabalho de [2]. Uma análise de confiabilidade da robustez do método também foi realizada para o caso com robôs móveis, com um aumento gradual da incerteza dos parâmetros, isto é, a distância da estimativa inicial, o procedimento foi adotado para 100 casos e a metodologia obteve sucesso em mais de 90% dos casos, indicando que quanto melhor forem as estimativas iniciais, elas impactarão diretamente na qualidade do sinal gerado, quanto maior a distância entre a estimativa e os valores reais, mais pobre o sinal de excitação gerado. A partir dos resultados obtidos, [2] e [63] indicam em seus trabalhos que a metodologia pode ser utilizada de forma recursiva, e a cada iteração uma estimativa melhor para os parâmetros é obtida.

4.1 CASO TUTORIAL

O quadrotor simulado será considerado como um sistema $\mathcal{M}(\Gamma)$, cujos parâmetros $\Gamma = [k_1, k_2]^T$ são os únicos não conhecidos, e os demais são considerados fixos e bem conhecidos. O objetivo é, dada uma estimação inicial dos parâmetros, encontrar um sinal de excitação capaz de obter a estimação "a posteriori" que correspondam aos parâmetros da Tabela 1. As saídas ($\mathbf{y} = [\phi, \theta, \psi]^T$) do sistema possuem a origem como posição inicial. A região de busca dos parâmetros foi definida $\Delta = [0,03; 0,05]^T$, de modo que os parâmetros encontrados estarão confinados a $\hat{\Gamma}^- \pm \Delta$. Os parâmetros da Tabela 1 representam com precisão a dinâmica do quadrotor e serão tratados como o veículo aéreo real $\mathcal{R}(\Gamma)$.

Supõe que não se conhece com exatidão os dois parâmetros $\Gamma = [k_1, k_2]^T$, assim é necessário fazer uma estimativa inicial deles. O modelo $\mathcal{M}(\hat{\Gamma}^-)$, denominado como simulado, representa a estimativa "a priori" dos parâmetros. Assumindo que não se sabe tais parâmetros reais, é impossível garantir que um determinado sinal tenha persistência de excitação para encontrar exatamente os valores reais do sistema (Tabela 1), mesmo que seja capaz de reproduzir a mesma saída de ambos os sistemas reais e simulados. Para contornar este problema, outro conjunto de parâmetros é definido, a estimativa inicial perturbada $\tilde{\Gamma}^p$, deste modo, um novo sistema $\mathcal{M}(\tilde{\Gamma}^p)$ será denominado como perturbado. Dado os dois sistemas, o algoritmo é executado de modo a gerar um sinal de excitação \mathbf{u}^\oplus , que torne possível encontrar uma estimativa $\hat{\delta}^+$ que minimize a heurística para a persistência de excitação ($f_{\hat{\delta}}(\cdot)$), conjuntamente com o ajuste de saída ($f_o(\cdot)$), e a soma

ponderada das restrições de tempo e espaço de estados ($\Theta(\cdot)$).

Dois cenários de análises foram propostos para atestar a aplicabilidade da metodologia SOESGOPE em um quadrotor. O primeiro cenário apresenta uma situação na qual há quatro modelos “*a priori*” $\mathcal{M}(\hat{\Gamma}^-)$ diferentes. Deseja-se atestar a capacidade de cada um dos modelos gerar um sinal de excitação (sub)ótimo capaz de estimar os parâmetros corretamente de um modelo dito real. Uma vez que, nem sempre é possível, na prática, conhecer o parâmetro real de um sistema, devido à fatores, como as incertezas de medição, um segundo cenário propõe a geração de apenas um sinal de excitação \mathbf{u}^\oplus , e quatro hipóteses de estimativas iniciais, ou seja, quatro conjuntos $\hat{\Gamma}^-$. Deseja-se atestar a capacidade do sinal em excitar estes modelos distintos, permitindo a sua correta estimação em cada caso.

Para todos os casos do primeiro e segundo cenários, os ganhos de ponderação das métricas para geração dos sinais foram definidas como:

- penalidade para restrições de tempo, saída e espaço de estados, $\kappa_1 = 10^5$;
- penalidade para função de precisão de saída, $\kappa_2 = 10^2$;
- penalidade para função de recuperabilidade de parâmetros, $\kappa_3 = 10^3$;
- ganho de ponderação $\kappa_t = 1$

Tais valores para as métricas, são comprovados pelo estudo feito em [2] sobre a sensibilidade dos ganhos de ponderação. Ele conclui que o volume do espaço de estados e o tempo do experimento tem a mesma relevância, de tal modo que a recuperação de parâmetros é mais importante do que a precisão do resultado, uma vez que a convergência de parâmetros do problema leva à convergência de saída. Há de se apontar que o aumento dos ganhos foi benéfico ao problema de OPE.

4.2 CASO COMPLETO

Aumentando a complexidade para aplicação do método, o quadrotor simulado será considerado como um sistema $\mathcal{M}(\Gamma)$, cujos parâmetros $\Gamma = [M, m, R, l, k_1, k_2]^T$ serão estimados. As especificações do modelo dinâmico e das penalidade do espaço de estados, bem como as características para a geração de sinais, são mantidas conforme as especificadas para o caso tutorial. Serão considerados três cenários para a estimação paramétrica total do quadrotor.

Os dois primeiros cenários de análises considerados são os mesmos propostos no caso tutorial, em que no primeiro cenário deseja-se atestar a capacidade de cada um dos modelos gerar um sinal de excitação (sub)ótimo capaz de estimar os parâmetros corretamente de

um modelo dito real; no segundo cenário deseja-se atestar a capacidade de um mesmo sinal em excitar modelos distintos, permitindo a sua correta estimação em cada caso. Porém, todos eles para a estimação dos seis parâmetros da planta em questão. A região de busca dos parâmetros para estes cenários foi definida por $\Delta = [0,03; 0,05; 0,05; 0,1; 0,03; 0,05]^T$, de modo que os parâmetros encontrados estarão confinados a $\hat{\Gamma}^- \pm \Delta$.

Um terceiro cenário é criado para a análise do efeito da região de busca dos parâmetros para a estimação, para analisar os limites da região de busca. O objetivo é analisar se o algoritmo, com uma região de busca maior, ainda é capaz de encontrar uma boa estimação dos parâmetros, que agora são considerados mais imprecisos, ou se essa imprecisão afeta na metodologia. A região de busca para esse cenário foi definida por $\Delta = [1,0; 0,105; 0,10; 0,25; 0,0268; 0,0147]^T$, que corresponde a 100% dos valores dos parâmetros do modelo real $\mathcal{M}(\Gamma)$, de modo que os parâmetros encontrados estarão confinados a $\hat{\Gamma}^- \pm \Delta$.

5 RESULTADOS E DISCUSSÕES - METODOLOGIA ORIGINAL

O objetivo deste capítulo é a análise dos resultados obtidos com a metodologia SOESGOPE original, através da resposta obtida, com testes realizados para a estimação de parâmetros de um quadrotor, inicialmente para dois parâmetros do veículo aéreo e por fim, para seis parâmetros.

5.1 RESULTADOS - CASO TUTORIAL

Assume-se que os parâmetros indicados na Tabela 1 representam com precisão o veículo aéreo e serão tratados como o quadrotor real $\mathcal{M}(\Gamma)$. No entanto, supõe-se que não se conhece precisamente dois destes parâmetros (k_1 e k_2), assim é necessário fazer uma estimativa inicial deles. O sistema $\mathcal{M}(\hat{\Gamma}^-)$, denominado como simulado, representa a estimativa "a priori". Assumindo que não se sabe o valor dos 2 parâmetros reais, é impossível garantir que um determinado sinal tenha persistência de excitação para encontrar exatamente os valores mostrados na Tabela 1, mesmo que seja capaz de reproduzir a mesma saída de ambos os sistemas reais e simulados. Para contornar este problema, outro conjunto de parâmetros é definido: a estimativa inicial perturbada $\tilde{\Gamma}^p$. Deste modo, um novo sistema $\mathcal{M}(\tilde{\Gamma}^p)$, denominado perturbado é criado.

5.1.1 Cenário 1: Diferentes modelos iniciais

Para o primeiro teste realizado, dado um certo conjunto de parâmetros considerados como reais, analisa-se a geração de sinais sub(ótimos) a partir de estimativas iniciais diferentes ($\hat{\Gamma}^-$) para verificação e validação dos sinais gerados. Alguns cenários de parâmetros k_1 e k_2 iniciais foram gerados para se obter os sinais sub(ótimos) referentes a cada um dos casos, conforme indicado na Tabela 3. O primeiro caso se refere ao modelo real, no segundo caso há um acréscimo de 25% aos valores do modelo real, no terceiro caso há um acréscimo de 50%, e no quarto caso há um decréscimo de 40%. Tais valores foram escolhidos a fim de observar o desempenho da metodologia em alcançar os resultados, a partir de estimativas iniciais distintas e distantes dos valores do modelo real. Juntamente aos parâmetros iniciais, foram criadas as estimativas perturbadas ($\tilde{\Gamma}^p$).

Em cada caso, um conjunto de sinais distintos foi gerado para excitar suficientemente a planta em questão. A partir do conjunto de parâmetros perturbados ($\tilde{\Gamma}^p$) é possível obter a estimativa dos parâmetros "a posteriori" utilizando o mesmo sinal obtido. Os sinais de excitação são gerados através de uma lei de controle para $\mathcal{M}(\tilde{\Gamma}^p)$, e aplicados em malha aberta para a estimação de $\hat{\Gamma}^+$. Para o primeiro caso, os sinais gerados estão expostos na Figura 11. Ao analisar os sinais de excitação, observa-se que as amplitudes dos sinais não ultrapassam os limites permitidos no experimento. O sinal enviado ao estado ϕ , em azul, não ultrapassa a faixa entre $\pm 30^\circ$, o sinal enviado ao θ , em vermelho, oscila

Tabela 3 – Métricas obtidas na geração do conjunto de sinais - Primeiro Cenário

Caso	1	2	3	4
$\hat{\Gamma}^- - k_1$	0,0268	0,0335	0,0402	0,0161
$\hat{\Gamma}^- - k_2$	0,0147	0,0184	0,0220	0,0088
$\tilde{\Gamma}^p - k_1$	0,0278	0,0348	0,0417	0,0167
$\tilde{\Gamma}^p - k_2$	0,0189	0,0236	0,0283	0,0113
$f_o(\cdot)$	$8,7199 \cdot 10^{-4}$	$8,7228 \cdot 10^{-4}$	$8,7243 \cdot 10^{-4}$	$8,7375 \cdot 10^{-4}$
$f_{\hat{\delta}}(\cdot)$	$1,4437 \cdot 10^{-6}$	$1,0069 \cdot 10^{-6}$	$1,1847 \cdot 10^{-6}$	$3,0798 \cdot 10^{-7}$
$f_{v_x}(\cdot)$	0,3576	0,3486	0,3569	0,2722
$f_{v_y}(\cdot)$	0,2375	0,2467	0,2423	0,1036
$\theta(\cdot)$	$7,595 \cdot 10^{-5}$	$7,5953 \cdot 10^{-5}$	$7,5992 \cdot 10^{-5}$	$7,3758 \cdot 10^{-5}$

entre valores próximos a faixa entre $\pm 20^\circ$ e o sinal enviado ao estado ψ , em amarelo, se mantém entre $+10^\circ$ e -40° . Em todos os conjuntos de sinais, o sinal de excitação \mathbf{u}^\oplus induz posições angulares positivas e negativas, de modo a excitar adequadamente a planta, mantendo dentro da porção do espaço de estados permitida, utilizando menos tempo e espaço quanto possível.




Figura 11 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Cenário 1 - Caso 1.

De posse dos resultados indicados na Tabela 3, a métrica de restrições de tempo, saída e espaço de estados ($\Theta(\cdot)$) (Equação 2.4) retornou uma função de valor baixo em todos os casos, na faixa de 10^{-5} , isto significa que o algoritmo manteve a saída y e os estados x dentro dos limites de espaço admissíveis. A função de precisão de saída, f_o mede a diferença entre a saída e os estados de dois sistemas excitados pelo mesmo sinal, ou seja, o modelo inicial, $\hat{\Gamma}^-$, e o modelo perturbado, $\tilde{\Gamma}^p$, obtendo uma diferença pequena entre eles como se pode observar em todos os quatro casos, facilitando assim a estimação do conjunto de parâmetros ótimos. A função de recuperabilidade de parâmetros, $f_{\hat{\delta}_+}$, avalia a persistência de excitação do sinal, é a garantia de que o conjunto de parâmetros estimados convergem para os parâmetros perturbados, garantindo assim que o sinal gerado é um sinal rico. O sistema se manteve dentro da região desejada do espaço de estados, comprovado pelos baixos valores de f_v . Ao analisar a Tabela 3, percebe-se que em todos os casos, a geração de sinal sub(ótimo) de excitação foi realizada com sucesso, garantindo assim que o

conjunto de parâmetros ótimos será obtido. Todas as funções de avaliação se mantiveram com pequenos valores em todos os casos. Os quatro conjuntos de dados iniciais distintos foram suficientes para gerar os sinais sub(ótimos) diferentes capazes de excitar o modelo para a estimação do conjunto de parâmetros ótimos.

Na Figura 12 estão representadas as curvas de ajuste dos estados de $\mathcal{M}(\Gamma)$ e $\mathcal{M}(\hat{\Gamma}^+)$ obtidas para o primeiro caso, em cada um dos seis estados: p , q , r , $roll$, $pitch$ e yaw . As três curvas da esquerda são referentes as velocidades angulares do quadrotor, já as três da direita são referentes as variações angulares. Na figura, o sinal em vermelho se refere ao modelo real $\mathcal{M}(\Gamma)$ e o sinal em azul ao modelo estimado $\mathcal{M}(\hat{\Gamma}^+)$. É possível notar que a estimativa obtida foi capaz de ajustar os dois modelos adequadamente, o que pode ser quantificado com o baixo valor de f_o . As curvas de ajustes de estado, para as velocidades angulares, não possuem efeito do ruído evidente, isto porque a sua estabilidade é garantida pelos controladores que são capazes de manter a segurança do experimento. Já as curvas de ajuste para as variações angulares, comparando a saída a partir do modelo real (em vermelho) e o modelo estimado (em azul), é notório o efeito do ruído adicionado ao sistema. O nível de ruído afeta muito pouco os estados, sendo mais evidente no ψ . Todos os estados se mantiveram dentro dos limites de espaço admissíveis e o experimento pode ser reproduzido com segurança.

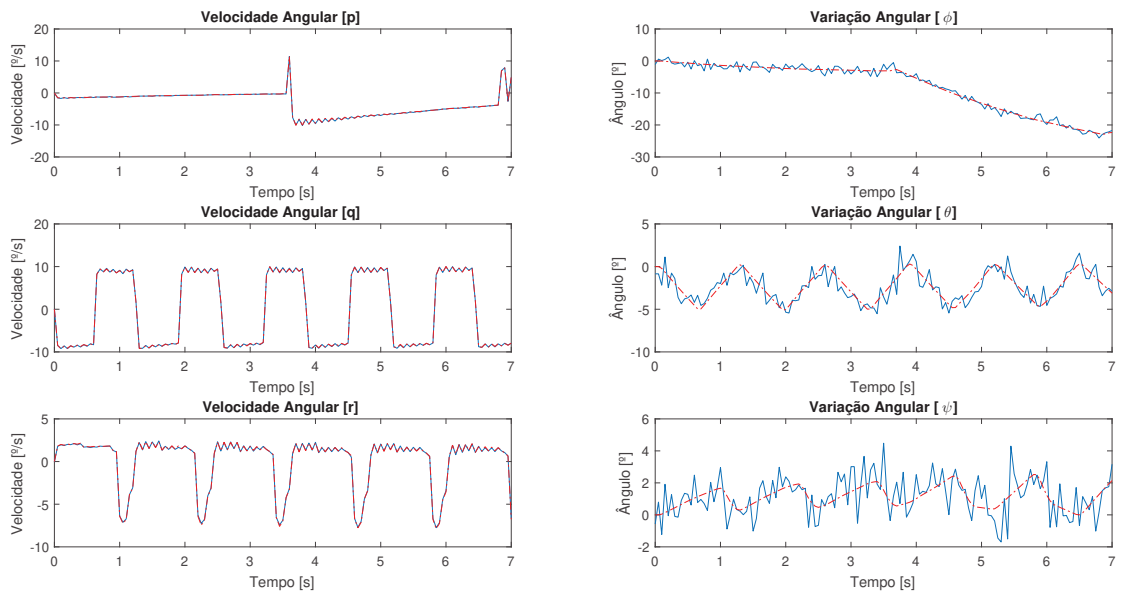


Figura 12 – Ajustes dos estados p , q , r , ϕ , θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Cenário 1 - Caso 1.

Continuando o processo, o sinal de entrada \mathbf{u}^\oplus é aplicado a $\mathcal{R}(\Gamma)$ com o intuito de encontrar a estimativa ótima. O resultado desta estimativa é $\hat{\Gamma}^+$. Comparando os resultados obtidos com os valores reais, é possível observar a métrica Σ_Γ , considerando

os ruídos do processo e de medição, esta métrica avalia o desvio de $\hat{\Gamma}^+$ em relação a Γ , retornando baixos valores. A métrica Σ_Γ é definida por:

$$\Sigma_\Gamma = \sum_{i=1}^r \left| \frac{\gamma_i - \hat{\gamma}_i^+}{\gamma_i} \right| \quad (5.1)$$

A Tabela 4 possui o valor dos parâmetros estimados com os sinais gerados, o erro de estimação para cada parâmetro (em porcentagem), o erro quadrático da estimação (Σ_Γ) e o tempo de convergência (t_{conv}) para a estimação, em segundos.

Tabela 4 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Primeiro Cenário

Caso	$\hat{\Gamma}^+$		Erro [%]		Σ_Γ	t_{conv}
	k_1	k_2	k_1	k_2		
1	0,0267	0,0149	0,3731	1,3605	$4,1307 \cdot 10^{-8}$	93,6879
2	0,0269	0,0148	0,3731	0,6803	$1,4820 \cdot 10^{-8}$	70,8727
3	0,0269	0,0147	0,3731	0	$7,9101 \cdot 10^{-9}$	34,6923
4	0,0269	0,0147	0,3731	0	$6,9684 \cdot 10^{-9}$	89,4545

Dado o desvio pequeno das variáveis, é possível dizer que a Hipótese 1 da metodologia foi mantida verdadeira. O sistema se manteve dentro da região desejada do espaço de estados e dentro dos limites temporais. A estimação dos parâmetros foi satisfatória, visto que o conjunto de parâmetros estimados está próximo ao conjunto de parâmetros reais como se pode analisar através dos baixos valores de erro quadrático de estimação (Σ_Γ) obtidos.

5.1.2 Cenário 2: Estimação a partir do mesmo sinal de excitação

Inicialmente, a abordagem realizada previa quatro modelos iniciais e a partir deles, quatro conjuntos de sinais de excitação eram gerados para a estimação do conjunto de parâmetros, um conjunto para cada modelo distinto.

Uma verificação acerca da metodologia a ser feita, é a possibilidade de que, a partir de um modelo inicial ($\mathcal{M}(\hat{\Gamma}^-)$), neste caso, considerado o modelo real ($\mathcal{R}(\Gamma)$), gerar apenas um conjunto de sinais sub(ótimos) de excitação, para a partir deste conjunto de sinais, estimar diversos modelos distintos. Em suma, o mesmo conjunto de sinais gerados pelo modelo real, com: $k_1 = 0,0268$ e $k_2 = 0,0147$, deve conseguir estimar o conjunto de parâmetros ótimos a partir de modelos iniciais diferentes.

A partir do mesmo conjunto de sinais de excitação, tentou-se estimar os parâmetros a partir de modelos iniciais diferentes. Quatro casos foram observados. O primeiro caso se refere ao modelo com acréscimo de 10% dos valores do modelo real, o segundo caso há um acréscimo de 30%, o terceiro caso há um decréscimo de 30% e o quarto caso há um acréscimo de 25% no parâmetro k_1 e um decréscimo de 25% no parâmetro k_2 . Novamente,

foram escolhidos desvios dos valores do modelo real, para verificar os resultados obtidos pelo método, a partir de diferentes modelos iniciais e que não são o modelo real do sistema.

Tabela 5 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Segundo Cenário

Caso	$\hat{\Gamma}^-$		$\hat{\Gamma}^+$		Erro [%]		Σ_{Γ}	t_{conv}
	k_1	k_2	k_1	k_2	k_1	k_2		
1	0,0295	0,0162	0,0267	0,0148	0,3731	0,6803	$1,8015 \cdot 10^{-8}$	129,5169
2	0,0348	0,0191	0,0269	0,0148	0,3731	0,6803	$1,2985 \cdot 10^{-8}$	110,5819
3	0,0188	0,0103	0,0269	0,0146	0,3731	0,6803	$2,1994 \cdot 10^{-8}$	74,7341
4	0,0335	0,0011	0,0270	0,0148	0,7463	0,6803	$5,2174 \cdot 10^{-8}$	151,2011

Os resultados de estimação obtidos estão indicados na Tabela 5. A estimação dos parâmetros foi satisfatória, visto que o conjunto de parâmetros estimados está próximo ao conjunto de parâmetros reais como se pode analisar pelos baixos valores de erro quadrático de estimação (Σ_{Γ}). Em todos os casos o erro de estimação em cada parâmetro foi pequeno, a estimação do parâmetro k_2 obteve o mesmo erro em todos os casos e para o k_1 o maior erro foi observado no quarto caso. Mesmo com o erro maior no quarto caso, a estimação foi satisfatória, visto que o erro não chega a 1% do valor real. Além disso é perceptível que a metodologia consegue estimar parâmetros de diversos modelos, considerando um mesmo conjunto de sinais de excitação.

A metodologia de otimização busca encontrar o conjunto de parâmetros ótimos do sistema com base na minimização do erro quadrático dos sinais de saída da planta e do obtido pelo modelo paramétrico através de uma função custo. Essa minimização é limitada pela região de busca dos parâmetros, isto significa que, quanto mais estreita for essa região, mais facilmente o algoritmo obterá melhores resultados. Para os dois cenários a região de busca foi bem delimitada, o que fez com que o erro quadrático da estimação seja minimizado. Bons resultados foram obtidos em todos os casos.

5.2 RESULTADOS - CASO COMPLETO

Assume-se que os parâmetros indicados na Tabela 1 representam com precisão o veículo aéreo e serão tratados como o quadrotor real $\mathcal{M}(\Gamma)$. No entanto, supõe-se que não se conhece precisamente nenhum de seus parâmetros, assim é necessário fazer uma estimativa inicial deles. Os conjuntos de parâmetros $\tilde{\Gamma}^p$ e $\hat{\Gamma}^-$ serão utilizados para a geração do sinal de excitação sub(ótimo) \mathbf{u}^{\oplus} que deve ser capaz de reconstruir $\tilde{\Gamma}^p$ a partir de $\hat{\Gamma}^-$ e então ser usado em $\mathcal{R}(\Gamma)$ para se obter uma estimativa $\hat{\Gamma}^+$. O grande número de parâmetros tornou o algoritmo de OPE mais lento, devido ao algoritmo de pontos interiores.

5.2.1 Cenário 1: Diferentes modelos iniciais

O modelo do veículo aéreo considerado como real para os testes é definido pelo conjunto de parâmetros conforme indicado na Tabela 1.

Para o primeiro teste realizado, dado um certo conjunto de parâmetros considerados como reais, analisa-se a geração de sinais sub(ótimos) a partir de estimativas iniciais diferentes para verificação e validação dos sinais gerados. Alguns casos de parâmetros iniciais foram gerados para se obter os sinais sub(ótimos) referentes a cada um dos casos, conforme indicado na Tabela 6. O primeiro caso se refere ao modelo real, no segundo caso há um acréscimo de 20% aos valores do modelo real e no terceiro caso há um decréscimo de 20% em todos os parâmetros.

Tabela 6 – Conjunto de parâmetros iniciais e perturbados

Caso	Parâmetros	M	m	R	l	k_1	k_2
1	$\hat{\Gamma}^-$	1,0	0,105	0,1	0,25	0,0268	0,0147
	$\tilde{\Gamma}^p$	1,0384	0,1349	0,0970	0,2597	0,0281	0,0162
2	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764
	$\tilde{\Gamma}^p$	1,2461	0,1618	0,1164	0,3116	0,0337	0,0194
3	$\hat{\Gamma}^-$	0,8	0,084	0,08	0,2	0,02144	0,01176
	$\tilde{\Gamma}^p$	0,7678	0,0942	0,0614	0,2275	0,0181	0,0097

Para tal simulação, como pode-se analisar pela Tabela 6, os conjuntos de parâmetros do modelo inicial $\hat{\Gamma}^-$ e o conjunto de parâmetros perturbados $\tilde{\Gamma}^p$ são diferentes para cada caso.

Tabela 7 – Métricas obtidas na geração do conjunto de sinais - Primeiro Cenário

Caso	1	2	3
$f_o(\cdot)$	$8,6605 \cdot 10^{-4}$	$8,7223 \cdot 10^{-4}$	$8,6890 \cdot 10^{-4}$
$f_{\hat{\delta}}(\cdot)$	0,0071	0,0090	0,0061
$f_{v_x}(\cdot)$	0,5946	0,4223	0,6125
$f_{v_y}(\cdot)$	0,4270	0,3660	0,3426
$\theta(\cdot)$	$8,0716 \cdot 10^{-5}$	$7,7884 \cdot 10^{-5}$	$7,9551 \cdot 10^{-5}$

O sinal de excitação \mathbf{u}^\oplus gerado, para o primeiro caso, pela metodologia é representado pela Figura 13.

Com os resultados obtidos, indicados na Tabela 7, a métrica de restrições de tempo, saída e espaço de estados ($\theta(\cdot)$) retornou uma função de valor baixo em todos os casos, na faixa de 10^{-5} , isto significa que o algoritmo manteve a saída y e os estados x dentro dos limites de espaço admissíveis. A função de precisão de saída f_o por possuir valores baixos em todos os três casos, facilita a estimação do conjunto de parâmetros, isso porque ela indica uma pequena diferença entre o modelo inicial e o modelo perturbado, quando excitados por um mesmo sinal. A função de recuperabilidade de parâmetros,




Figura 13 – Sinal de excitação \mathbf{u}^{\oplus} para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Cenário 1 - Caso 1.

$f_{\hat{\delta}^+}$, avalia a persistência de excitação do sinal, sendo a garantia de que o conjunto de parâmetros estimados convergem para os parâmetros perturbados e que o sinal gerado é um sinal rico. Em comparação a estimação paramétrica do caso tutorial (estimação de apenas dois parâmetros), a métrica de recuperabilidade de parâmetros foi maior para o caso completo, mas não grande o suficiente para impedir o algoritmo da metodologia SOESGOPE conseguir estimar os parâmetros. A função atinge valores maiores devido ao fato de estar realizando a estimação de mais parâmetros.

Na Figura 14 estão representados as curvas dos estados de $\mathcal{M}(\Gamma)$ e $\mathcal{M}(\hat{\Gamma}^+)$ obtidos para o primeiro caso, em cada um dos seis estados: p , q , r , $roll$, $pitch$ e yaw . O sinal em vermelho se refere ao $\mathcal{M}(\Gamma)$, gerado a partir do sistema com os parâmetros reais, e o sinal em azul ao $\mathcal{M}(\hat{\Gamma}^+)$, gerado a partir do sistema com os parâmetros estimados e influência do ruído adicionado ao sistema. É possível notar que a estimativa ”a posteriori” foi capaz de ajustar os dois modelos adequadamente, o que pode ser quantificado com o baixo valor de f_o . O nível de ruído afeta muito pouco os estados. Os estados ajustados pelo sistema $\mathcal{M}(\hat{\Gamma}^+)$ correspondem a um bom ajuste ao se comparar com o sistema real, visto que as suas trajetórias são bem próximas e o controlador consegue minimizar o efeito do ruído acrescentado.

Observa-se que em todos os conjuntos de sinais gerados para todos os casos, o sinal de excitação \mathbf{u}^{\oplus} induz inclinações angulares positivas e negativas, para excitar a planta adequadamente, mantendo dentro da porção do espaço de estados permitida. Todos os estados se mantiveram dentro dos limites de espaço admissíveis.

A Tabela 8 possui o valor dos parâmetros estimados com os sinais gerados, o erro de estimação, em porcentagem, de cada parâmetro; o erro quadrático da estimação (Σ_{Γ}); e o tempo de convergência (t_{conv}) para a estimação, em segundos.

Com os resultados das estimções obtidos, é perceptível que para o modelo inicial considerado como o real, indicado no primeiro caso, a metodologia apresentou melhor exatidão, como se pode notar pelo valor do erro quadrático de estimação obtido. É notória a convergência de alguns parâmetros estimados ao modelo real, e em outros esta

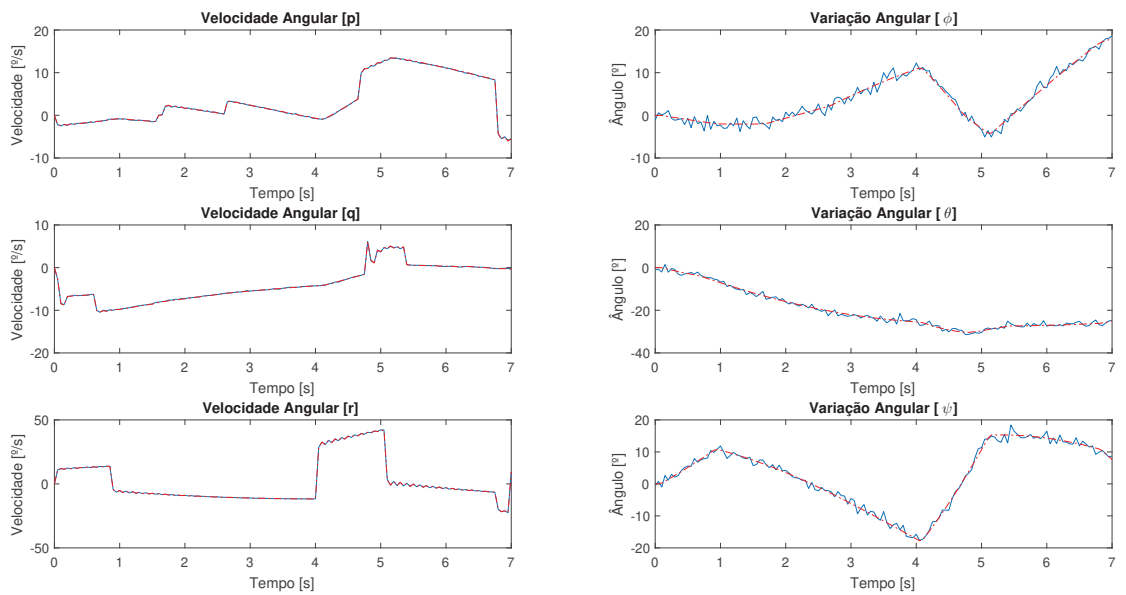


Figura 14 – Ajustes dos estados p , q , r , ϕ , θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Cenário 1 - Caso 1.

Tabela 8 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Primeiro Cenário

Caso	Modelo	M	m	R	l	k_1	k_2	Σ_{Γ}	t_{conv}
1	$\hat{\Gamma}^-$	1,0	0,105	0,1	0,25	0,0268	0,0147	$1,262 \cdot 10^{-7}$	307,1499
	$\hat{\Gamma}^+$	0,9999	0,1051	0,0997	0,2501	0,0269	0,0147		
	Erro [%]	0,01	0,0952	0,3	0,04	0,3731	0		
2	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764	0,0410	429,5388
	$\hat{\Gamma}^+$	1,1961	0,1212	0,1150	0,2937	0,0336	0,0237		
	Erro [%]	19,61	15,4286	15	17,48	25,3731	61,2245		
3	$\hat{\Gamma}^-$	0,8	0,084	0,08	0,2	0,02144	0,01176	0,0422	613,8822
	$\hat{\Gamma}^+$	0,8020	0,0862	0,0813	0,2032	0,0178	0,0078		
	Erro [%]	19,8	17,9048	18,7	18,72	33,5821	46,9388		

convergência não é tão boa. Em [2] é indicado que a dificuldade da estimação se deve ao fato da distância entre o modelo inicial $\mathcal{M}(\hat{\Gamma}^-)$ e o modelo real $\mathcal{M}(\Gamma)$, o que invalidaria a Hipótese 1 e dificultaria a estimação com baixo erro dos parâmetros. Porém o algoritmo pode ser trabalhado de maneira recursiva e a partir da primeira estimação obter melhores resultados com o aumento da riqueza dos sinais e melhoria na estimativa.

5.2.2 Cenário 2: Estimação a partir do mesmo sinal de excitação

Inicialmente, a abordagem realizada previa três modelos iniciais e a partir deles, três conjuntos de sinais de excitação eram gerados para a estimação do conjunto de parâmetros, um conjunto para cada modelo distinto.

Uma verificação realizada acerca da metodologia foi a possibilidade de que, a partir

de um modelo inicial $\mathcal{M}(\hat{\Gamma}^-)$, neste caso, considerado o modelo real $\mathcal{M}(\Gamma)$, gerar apenas um conjunto de sinais sub(ótimos) de excitação, para a partir deste conjunto de sinais, estimar diversos modelos distintos. Para este cenário, os conjuntos de sinais foram gerados pelo modelo inicial considerado como real, o correspondente ao caso 1 da Tabela 6, obtendo exatamente as mesmas métricas no processo de geração do sinal, presentes na Tabela 7.

A partir do mesmo conjunto de sinais de excitação, tentou-se estimar os parâmetros a partir de modelos iniciais diferentes. Três casos foram observados. O primeiro caso se refere ao modelo com acréscimo de 20% dos valores do modelo real (corresponde ao modelo do caso 2 da Tabela 6), o segundo caso há um decréscimo de 20% do modelo real (corresponde ao modelo do caso 3 da Tabela 6) e o terceiro caso foram gerados valores arbitrários. Os resultados de estimação obtidos estão indicados na Tabela 9.

Tabela 9 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Segundo Cenário

Caso	Modelo	M	m	R	l	k_1	k_2	Σ_{Γ}	t_{conv}
1	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764	0,0392	274,7069
	$\hat{\Gamma}^+$	1,1908	0,1226	0,1148	0,2956	0,0368	0,0243		
	Erro [%]	19,08	16,7619	14,8	18,24	37,3134	65,3061		
2	$\hat{\Gamma}^-$	0,8	0,084	0,08	0,2	0,02144	0,01176	0,0413	482,2163
	$\hat{\Gamma}^+$	0,8030	0,0874	0,0813	0,2083	0,0183	0,0082		
	Erro [%]	19,7	16,7619	18,7	16,68	31,7164	44,2177		
3	$\hat{\Gamma}^-$	1,05	0,1	0,09	0,28	0,0260	0,015	0,0046	265,9390
	$\hat{\Gamma}^+$	1,066	0,0953	0,0980	0,2627	0,0260	0,0150		
	Erro [%]	6,6	9,2381	10	5,08	2,9851	2,0408		

A estimação dos parâmetros não foi tão satisfatória quanto as obtidas no primeiro cenário, visto que o conjunto de parâmetros estimados não está tão próximo ao conjunto de parâmetros reais. Ao se comparar o caso 1 deste cenário com o caso 2 do cenário anterior e o caso 2 deste cenário com o caso 3 do cenário anterior, é perceptível que mesmo com as mesmas estimativas iniciais para os casos, este cenário possui uma estimação paramétrica não tão boa quanto ao anterior, isto se deve ao fato de o conjunto de sinais utilizados para excitar o sistema, em todos os casos deste cenário, foi o mesmo e, gerado a partir de outro conjunto de estimativas iniciais. Porém, é notório que a metodologia consegue estimar parâmetros de diversos modelos, considerando um mesmo conjunto de sinais de excitação mesmo que com erros maiores.

5.2.3 Cenário 3: Sensibilidade à região de busca

O intuito é avaliar a estimação de parâmetros, em dois casos distintos, com uma região de busca maior. A região de busca dos parâmetros para este cenário é definida por $\Delta = [1,0; 0,105; 0,10; 0,25; 0,0268; 0,0147]^T$. Dois casos com modelos iniciais serão avaliados e, o modelo perturbado será gerado, como dispostos na Tabela 10.

Para tal simulação, como pode-se analisar pela Tabela 10, o conjunto de parâmetros

Tabela 10 – Conjunto de parâmetros iniciais e perturbados

Caso	Parâmetros	M	m	R	l	k_1	k_2
1	$\hat{\Gamma}^-$	1,0	0,105	0,1	0,25	0,0268	0,0147
	$\tilde{\Gamma}^p$	1,0384	0,1349	0,0970	0,2597	0,0281	0,0162
2	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764
	$\tilde{\Gamma}^p$	1,2461	0,1618	0,1164	0,3116	0,0337	0,0194

do modelo inicial $\hat{\Gamma}^-$ gerou um conjunto de parâmetros perturbados $\tilde{\Gamma}^p$ diferente para cada caso.

Tabela 11 – Métricas obtidas na geração do conjunto de sinais - Quarto Cenário

Caso	1	2
$f_o(\cdot)$	$8,6601 \cdot 10^{-4}$	$8,6596 \cdot 10^{-4}$
$f_{\hat{\delta}}(\cdot)$	0,0054	0,0072
$f_{v_x}(\cdot)$	0,2219	0,2484
$f_{v_y}(\cdot)$	0,1565	0,1410
$\theta(\cdot)$	0,1083	0,0374

É possível perceber que em todos os casos, a geração de sinal sub(ótimo) de excitação foi realizada com sucesso e garantindo assim que o conjunto de parâmetros ótimos será obtido.

Os dois conjuntos de dados iniciais distintos foram suficientes para gerar os sinais sub(ótimos) diferentes capazes de excitar o modelo para a estimação do conjunto de parâmetros ótimos. O sinal sub(ótimo) de excitação obtido pela metodologia para o primeiro caso, é apresentado na Figura 15.




Figura 15 – Sinal de excitação \mathbf{u}^\oplus para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Cenário 3 - Caso 1.

Na Figura 16 estão representados as curvas dos estados de $\mathcal{M}(\Gamma)$ e $\mathcal{M}(\hat{\Gamma}^+)$ obtidos para o primeiro caso, em cada um dos seis estados: p , q , r , $roll$, $pitch$ e yaw . O sinal em vermelho se refere ao $\mathcal{M}(\Gamma)$ e o sinal em azul ao $\mathcal{M}(\hat{\Gamma}^+)$. É possível notar que a estimativa "a posteriori" foi capaz de ajustar os dois modelos adequadamente, o que pode ser quantificado com o baixo valor de f_o . As curvas de ajustes de estado, para as

velocidades angulares, não possuem efeito do ruído evidente, isto porque a sua estabilidade é garantida pelos controladores que são capazes de manter a segurança do experimento. Já as curvas de ajuste para as variações angulares, comparando a saída a partir do modelo real (em vermelho) e o modelo estimado (em azul), é notório o efeito do ruído adicionado ao sistema. O nível de ruído afeta muito pouco os estados, sendo mais evidente no ψ . Todos os estados se mantiveram dentro dos limites de espaço admissíveis e o experimento pode ser reproduzido com segurança.

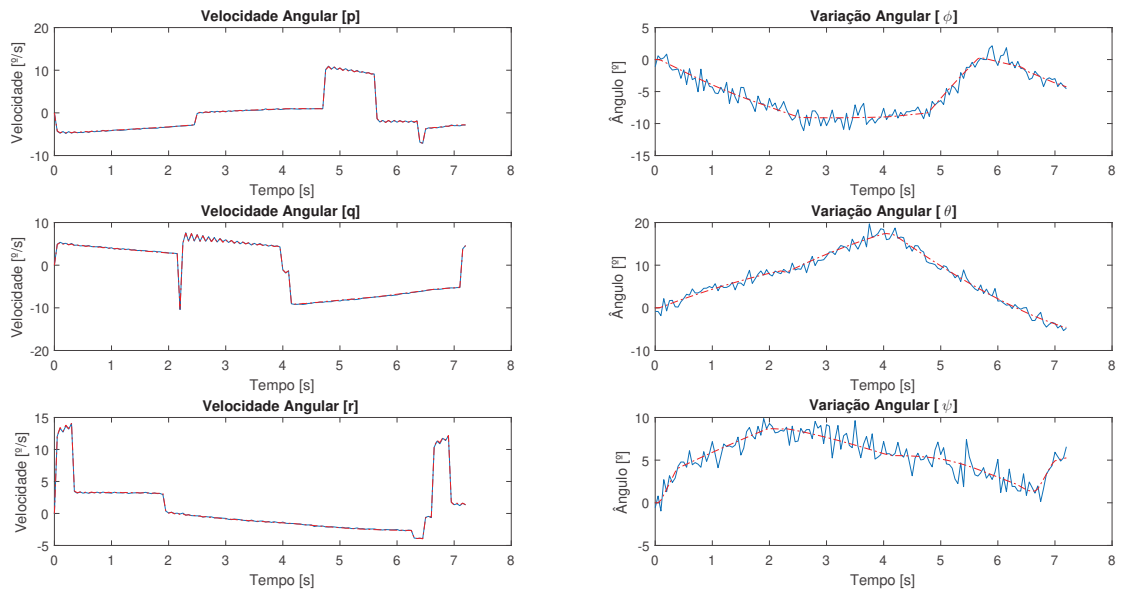


Figura 16 – Ajustes dos estados p , q , r , ϕ , θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Cenário 3 - Caso 1.

Com a análise dos resultados obtidos para a geração dos sinais de excitação, percebe-se que os sinais serviram para excitar de maneira suficiente o sistema e a partir daí estimar os valores ótimos dos parâmetros. Visto que na geração dos sinais sub(ótimos) \mathbf{u}^\oplus , a métrica da precisão de saída obteve valores mínimos, da ordem de 10^{-4} como indicado na Tabela 11. A função da restrição de espaço de estados $\Theta(\cdot)$ obteve valores mais altos porém, todas as saídas se mantiveram dentro dos limites de espaço admissíveis.

A Tabela 12 possui o valor dos parâmetros estimados com os sinais gerados, o desvio percentual da estimação de cada parâmetro, o erro quadrático da estimação (Σ_Γ) e o tempo de convergência (t_{conv}) para a estimação, em segundos.

Com os resultados das estimações obtidos, é perceptível que com o modelo inicial considerado como o real (primeiro caso), a metodologia se tornou muito mais eficaz, como se pode notar através do erro quadrático de estimação. Além disso, o tempo de convergência para a estimação foi menor neste caso. Já o segundo caso, a estimativa "a posteriori" $\hat{\Gamma}^+$ não foi tão rica devido a distância da estimativa inicial ao modelo real,

Tabela 12 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Quarto Cenário

Caso	Modelo	M	m	R	l	k_1	k_2	Σ_{Γ}	t_{conv}
1	$\hat{\Gamma}^-$	1,0	0,105	0,1	0,25	0,0268	0,0147	$3,2823 \cdot 10^{-5}$	243,1648
	$\hat{\Gamma}^+$	1,0015	0,1046	0,1038	0,246	0,0268	0,0145		
	Erro [%]	0,15	0,381	3,8	1,6	0	1,3605		
2	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764	0,0374	529,6996
	$\hat{\Gamma}^+$	1,1917	0,1195	0,1015	0,27	0,0324	0,0192		
	Erro [%]	19,17	13,8095	1,5	8	20,8955	30,6122		

como indicado no trabalho [2]. Mesmo aumentando a região de busca dos parâmetros, a metodologia se mostrou eficaz e não atingiu valores exorbitantes durante a estimação. O espaço de busca pode ser aumentado para as situações em que a imprecisão dos valores da estimativa inicial é alta, sem perder uma estimativa significativa caso os parâmetros estejam confinados a regiões de busca menores.

Analisando os resultados do caso tutorial e do caso completo, percebe-se um comportamento parecido nos cenários de estimação, em que quanto mais próxima do valor real for a estimativa inicial, melhor será o resultado obtido pela metodologia. Mesmo com estimativas finais de parâmetros distintas, o sistema se comportou de maneira adequada, como foi observado nas figuras de ajustes de estados, dado que em todos os casos o sistema estimado possui curvas próximas ao sistema real em todos os estados. Este comportamento pode ser analisado ao observar o controlador projetado para o sistema. Em todos os casos o controlador foi projetado a partir dos parâmetros reais do sistema, assim, a busca de parâmetros será feita de modo a manter o sistema estável com o controlador já inserido. Um outro ponto importante a se analisar é que as informações a respeito do controlador, nem sempre estarão disponíveis, pois podem depender dos parâmetros que serão estimados e possuem uma incerteza ou nenhum conhecimento relacionado a eles. Desta forma, uma maneira de contornar tal problema é fazer com que a metodologia em malha fechada seja capaz de buscar o conjunto de controladores que melhor se aplicam para a identificação do sistema.

6 APRIMORAMENTO DA METODOLOGIA SOESGOPE APLICADA AO QUADROTOR

O processo de identificação de sistemas em malha fechada é fundamental para situações em que a planta possui não linearidades e comportamentos que são difíceis de prever e com estabilidade não garantida para malha aberta. Além disso, aplicando a metodologia SOESGOPE em malha aberta, para a estimação de muitos parâmetros, eles podem configurar o mesmo comportamento e causar redundância de parâmetros e, conseqüentemente, não possuir uma estimação adequada para o sistema. O problema de redundância de parâmetros pode continuar acontecendo para o sistema em malha fechada, por este fato, é importante ter um controlador no sistema bem projetado para a identificação. Na metodologia SOESGOPE, a geração do sinal é feita para o sistema perturbado, em malha fechada, e o sinal que é enviado para o sistema em malha aberta, para a identificação, é o sinal controlado, isso para garantir que os sinais de entrada e saída não estejam correlacionados e desta forma, pode-se tratar o problema como um problema de identificação em malha aberta, que reconhecidamente é mais trivial.

O controlador é de suma importância para o processo em sistemas de malha fechada, para garantir uma boa estimação é necessário conseguir performar o sistema e isso inclui o controlador. O controlador atua como um filtro para os sinais de referência, o que acarreta em perda de informação do sinal. Contudo, se o controlador for bem projetado, permitindo a passagem de frequências que sensibilizem adequadamente o sistema, a perda de informação não acarretará em problemas de estimação consideráveis, a depender da qualidade do sinal de excitação.

Para a análise dos cenários do Capítulo 5 o controlador foi projetado, para o sistema em malha fechada, da mesma maneira para todos os casos, de acordo com as características do sistema real, indicado na Tabela 1, permitindo a passagem de frequências que sensibilizem adequadamente o sistema. Os resultados obtidos com a metodologia original foram satisfatórios, isso porque a obtenção do sinal sub-ótimo \mathbf{u}^\oplus leva em consideração os efeitos do controlador, portanto gera um sinal compatível com este controlador. Porém o projeto do controlador, junto a metodologia SOESGOPE, pode melhorar e avançar a metodologia no sentido da velocidade de convergência do método e em melhores resultados para os parâmetros estimados, uma vez que nem sempre os parâmetros reais do sistema estão disponíveis para o projeto do controlador adequado.

Inicialmente, um primeiro método aplicado serviu de motivação para um projeto do controlador junto a geração do sinal sub(ótimo). A motivação surge através da atualização do controlador em batelada, em que o projeto do controlador é feito a partir da estimativa inicial fornecida ao método SOESGOPE e, a cada estimação encontrada atualiza-se o controlador para aquele novo conjunto de parâmetros estimados. A segunda abordagem é otimizar a geração do sinal, para que durante o processo de otimização, o projeto do

controlador seja feito junto aos processos de otimização da amplitude e tempo de duração do sinal gerado, sendo indicado apenas os limites superior e inferior para cada termo do controlador PID, das amplitudes e do tempo. Na Seção 6.1 são indicados os resultados obtidos com o controlador obtido em batelada, que serviram de motivação. Nas Seções 6.2 e 6.3 é indicado o processo para o acréscimo de busca do controlador para a estimação de parâmetros.

6.1 ATUALIZAÇÃO DO CONTROLADOR EM BATELADA

Inicialmente, testes para a otimização do controlador em batelada foram realizados. Utilizando os casos 2 e 3 do primeiro cenário para a estimação de dois parâmetros do quadrotor. Com os controladores projetados a partir do conjunto de parâmetros do modelo inicial houveram divergências entre os resultados durante o processo de otimização para o mesmo sistema com controladores diferentes. Considerando o terceiro caso do cenário, um novo controlador foi projetado a partir das estimativas "a priori" ($\mathcal{M}(\hat{\Gamma}^-)$) do modelo, e não com os valores reais ($\mathcal{R}(\Gamma)$). A Tabela 13 possui o valor dos ganhos do controlador projetado para este caso.

Tabela 13 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Caso 3b

	K_p	K_i	K_d
ϕ, θ	6,1707	0	0,3304
ψ	4,0257	0	1,0

Na Tabela 14 estão indicados os resultados obtidos. Os casos analisados são os casos 2 e 3 como já informado. Os casos que estão identificados com a letra *a*, são os resultados obtidos com o controlador projetado a partir do modelo $\mathcal{R}(\Gamma)$ e os casos identificados com a letra *b* são os casos obtidos com os novos controladores, resultantes do modelo $\mathcal{M}(\hat{\Gamma}^-)$.

Tabela 14 – Métricas obtidas na geração do conjunto de sinais - Comparação dos controladores

Caso	2a	2b	3a	3b
$\hat{\Gamma}^- - k_1$	0,0335	0,0335	0,0402	0,0402
$\hat{\Gamma}^- - k_2$	0,0184	0,0184	0,0220	0,0220
$\tilde{\Gamma}^p - k_1$	0,0348	0,0348	0,0417	0,0417
$\tilde{\Gamma}^p - k_2$	0,0236	0,0236	0,0283	0,0283
$f_o(\cdot)$	$8,7228 \cdot 10^{-4}$	$8,7412 \cdot 10^{-4}$	$8,7243 \cdot 10^{-4}$	$8,7103 \cdot 10^{-4}$
$f_{\delta}(\cdot)$	$1,0069 \cdot 10^{-6}$	$1,8104 \cdot 10^{-7}$	$1,1847 \cdot 10^{-6}$	$3,1016 \cdot 10^{-6}$
$f_{v_x}(\cdot)$	0,3486	0,1581	0,3569	0,2722
$f_{v_y}(\cdot)$	0,2467	0,0947	0,2983	0,1974
$\theta(\cdot)$	$7,5953 \cdot 10^{-5}$	$7,7580 \cdot 10^{-5}$	$7,5992 \cdot 10^{-5}$	$7,4956 \cdot 10^{-5}$

Apenas com a alteração do projeto do controlador, as métricas para a geração do sinal sub(ótimo) obtidas foram distintas. A função de precisão de saída obteve valores

muito próximos entre si, indicando uma diferença mínima entre os estados e saída do sistema. A função de recuperabilidade de parâmetros que avalia a persistência do sinal também retornou valores indicando que o sinal é persistentemente excitante em ambos os casos, além disso as métricas indicam que em todos os casos as saídas e estados foram mantidos dentro dos limites operacionais admissíveis. Os resultados obtidos na estimação dos parâmetros estão indicados na Tabela 15.

Tabela 15 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Comparação dos controladores

Caso	$\hat{\Gamma}^+$		Erro [%]		Σ_{Γ}	t_{conv}
	k_1	k_2	k_1	k_2		
2a	0,0269	0,0148	0,3731	0,6803	$1,4820 \cdot 10^{-8}$	70,8727
2b	0,0267	0,0147	0,3731	0	$5,3425 \cdot 10^{-9}$	65,5398
3a	0,0269	0,0147	0,3731	0	$7,9101 \cdot 10^{-9}$	34,6923
3b	0,0268	0,0147	0	0	$2,6368 \cdot 10^{-9}$	35,7574

Analisando os resultados de estimação, é possível verificar uma melhoria para os dois casos, corroborando com o fato de que o controlador influencia para a identificação de sistemas em malha fechada. As Figuras 17 e 18 correspondem aos sinais de excitação gerados pela metodologia e o ajuste dos estados de $\mathcal{M}(\Gamma)$ e $\mathcal{M}(\hat{\Gamma}^+)$ para o caso 3b projetado anteriormente, os sinais são diferentes do que os gerados pelo caso 3a.




Figura 17 – Sinal de excitação \mathbf{u}^{\oplus} para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Caso 3b.

Para a estimação de todos os parâmetros do quadrotor, um teste também foi realizado atualizando o controlador a cada iteração para ter uma base de comparação entre os casos. Foi utilizado o segundo caso do primeiro cenário. A Tabela 16 indica os resultados da estimação de todos os parâmetros em duas iterações, com duas vertentes. A primeira iteração é a mesma para ambos os casos, em que o controlador foi projetado a partir do conjunto de parâmetros “a priori” ($\hat{\Gamma}^-$). A segunda iteração foi realizada, num primeiro momento, sem a atualização do controlador, e no segundo momento com a atualização do controlador para a nova atualização dos parâmetros iniciais.

O caso 2a se refere ao caso sem atualização do controlador e o caso 2b se refere ao caso com a atualização do controlador para a segunda iteração em batelada. Como se

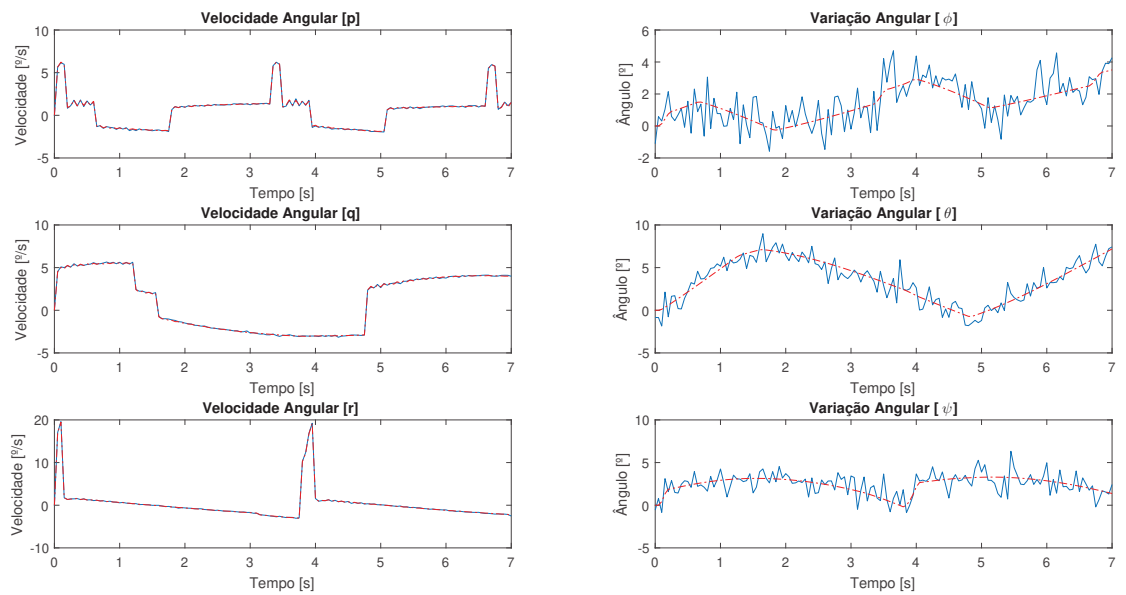


Figura 18 – Ajustes dos estados p , q , r , ϕ , θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Caso 3b.

Tabela 16 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Batelada

Iter.	Modelo	M	m	R	l	k_1	k_2	Σ_{Γ}	t_{conv}
1	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764	0,0403	366,7457
	$\hat{\Gamma}^+$	1,1940	0,122	0,1159	0,2936	0,0368	0,0238		
	Erro [%]	19,4	16,1905	15,9	17,44	37,3134	61,9048		
2a	$\hat{\Gamma}^-$	1,1940	0,122	0,1159	0,2936	0,0368	0,0238	0,0410	510,6518
	$\hat{\Gamma}^+$	1,1952	0,1238	0,1163	0,2971	0,0348	0,0193		
	Erro [%]	19,52	17,9048	16,3	18,84	29,8507	31,2925		
2b	$\hat{\Gamma}^-$	1,1940	0,122	0,1159	0,2936	0,0368	0,0238	0,0429	456,0964
	$\hat{\Gamma}^+$	1,2005	0,1230	0,1191	0,2943	0,0349	0,0192		
	Erro [%]	20,05	17,1429	19,10	17,72	30,2239	30,6122		

obtem resultados diferentes, é plausível obter uma otimização do controlador de forma recursiva para a geração do sinal com o melhor desempenho para a identificação dos parâmetros a serem estimados.

O motivo de realizar a atualização do controlador no processo em batelada deriva do fato de o controlador projetado no início do processo ser desconhecido, ele é projetado a partir das estimativas “a priori” do modelo. Considerando o modelo inicial com baixo nível de conhecimento, o controlador é baseado num modelo que pode estar distante do modelo real, e com isso a metodologia poderá demandar mais tempo até chegar numa boa estimativa dos parâmetros. O primeiro teste realizado serviu como ponto de partida para entender que o projeto do controlador altera o resultado da metodologia. Foi possível perceber que o controlador projetado para o mesmo caso, mas a partir de estimativas dos parâmetros distintas, obteve resultados diferentes durante o processo de geração do sinal e

da estimação paramétrica.

De maneira geral, o Algoritmo 1 corresponde a representação da atualização do controlador em batelada.

Algoritmo 1: Atualização do Controlador em Batelada

Entrada: Modelo Inicial do sistema – $\mathcal{M}(\hat{\Gamma}^-)$

1. **Inicialização:** Projeta o controlador a partir do modelo inicial – $\mathcal{M}(\hat{\Gamma}^-)$
 2. **Efetue:** O processo da metodologia SOESGOPE.
 3. **Para:** O novo conjunto de parâmetros estimados **faça:**
 4. **Projete:** o novo controlador e execute o passo 2 novamente.
 5. **Avalie:** A estimação paramétrica obtida.
 7. *Retorne:* $\hat{\Gamma}^+$
-
-

A partir dos resultados obtidos, torna-se viável atualizar a metodologia SOESGOPE para que dentro do seu processo de otimização, seja possível encontrar um conjunto de controladores que melhor se aplica ao sistema para a estimação paramétrica seja realizada e sem a necessidade de realizar um projeto para o controlador, utilizando parâmetros incertos e desconhecidos, e não obter sucesso.

6.2 OTIMIZAÇÃO RECURSIVA PARA O CONTROLADOR

A metodologia SOESGOPE apresentada e avaliada, com testes no quadrotor, consegue contornar um dos impasses presentes em identificação de sistemas em malha fechada, que é a correlação existente entre o sinal de referência e a saída medida do sistema. A metodologia contorna este problema fazendo com que os sinais sub-ótimos obtidos pela metodologia sirvam de referência para o sistema, mas os sinais que são gerados através da lei de controle para o sistema perturbado que são efetivamente utilizados e aplicados em malha aberta para a estimação paramétrica. O outro inconveniente existente nestes casos, se deve ao fato do controlador atuar como um filtro para os sinais de referência e acarretar em perda de informação do sinal que será utilizado para a estimação. Devido a este fato, o controlador deve ser projetado de acordo com as características do sistema real, o que se torna um empecilho, visto que no sistema existem incertezas paramétricas que podem dificultar o projeto dos controladores. Uma adição na metodologia SOESGOPE, para sanar este segundo problema, é proposta. Ela consiste em encontrar junto ao sinal sub(ótimo), um bom controlador para a identificação.

Com um controlador bem ajustado, a perda de informação não acarretará em problemas de identificação consideráveis, a depender da qualidade do sinal de excitação fornecido ao sistema. A metodologia original, obtém o sinal de excitação \mathbf{u}^\oplus levando em consideração os efeitos do controlador, portanto gera um sinal compatível com ele. Deste modo, a adição na metodologia consiste em buscar, via otimização, os ganhos dos controladores, junto ao sinal de excitação, de modo que sejam compatíveis. Para

isso, deve-se definir os limites máximos e mínimos para o controlador e, a partir daí, o método de otimização utilizar tais valores como referência e obter o sinal e os ganhos do controlador sub(ótimo) para a estimação dos parâmetros. Os limites mínimos de cada termo do controlador PID serão equivalentes a zero, visto que não há ganhos negativos para o controlador. Já os limites máximos serão obtidos a partir da técnica de sintonia do controlador por *Successive Loop Closure*, técnica esta, que consiste em obter os ganhos a partir dos limites de saturação dos atuadores, desta forma garantindo a segurança do experimento.

Conforme indicado na Seção 2.2, para encontrar um sinal de excitação sub(ótimo) \mathbf{u}^\oplus é necessário primeiramente definir sua representação matemática, de modo que seja possível executar operações básicas com este sinal [2]. Para a implementação da otimização do controlador, sugere-se um acréscimo na representação deste sinal, com os valores dos ganhos dos controladores obtidos, tais ganhos são limitados pelos valores obtidos a partir da sintonia do controlador PID por *Successive Loop Closure*.

Dado o vetor, $\Xi \in \mathbb{R}^{2pk}$, que representa os componentes do sinal u dividido em k estágios:

$$\begin{aligned} \Xi := & \left[t_1^{u_1}, \dots, t_k^{u_1}, t_1^{u_2}, \dots, t_k^{u_2}, t_1^{u_p}, \dots, t_k^{u_p}, \right. \\ & a_1^{u_1}, \dots, a_k^{u_1}, a_1^{u_2}, \dots, a_k^{u_2}, a_1^{u_p}, \dots, a_k^{u_p}, \\ & \left. k_p^{u_1}, k_i^{u_1}, k_d^{u_1}, k_p^{u_2}, k_i^{u_2}, k_d^{u_2}, k_p^{u_p}, k_i^{u_p}, k_d^{u_p} \right] \end{aligned} \quad (6.1)$$

em que:

- $1 \leq i \leq k$ e $1 \leq j \leq p$ representa o i -ésimo estágio do j -ésimo componente da entrada;
- $t_i^{u_j}$ e $a_i^{u_j}$ são, respectivamente, o tempo de execução e a amplitude do estágio;
- k_p, k_i, k_d correspondem aos ganhos do controlador obtidos para cada sinal de entrada.

A partir daí, é possível gerar o sinal. É importante observar que cada componente do sinal pode possuir um tempo de execução diferente, deste modo, cada componente é equalizado de acordo com o maior tempo de equalização de todos, obtendo assim um tempo comum entre eles. Logo, os componentes do sinal de tempo de execução menores ficam em um *loop* de repetição até que o de maior tempo execute.

Utilizando o mesmo algoritmo proposto na Seção 2.2, baseado em enxame de partículas - *Particle Swarm-Like Optimization* (PSLO), será realizada a busca pelo melhor sinal, que além da busca pelos tempos e amplitudes dos estágios de entrada, também irá realizar a busca dos ganhos dos controladores considerando os seus limites máximos e mínimos.

6.2.1 Sintonia do controlador PID por *Successive Loop Closure*

A sintonia do controlador PID por *Successive Loop Closure* [45] implica que o desempenho do sistema é, algumas vezes, limitado por restrições de saturação dos atuadores. Conhecendo essas restrições, é possível utilizá-las para desenvolver especificações de desempenho para o controlador. Nesse contexto, considerando o sistema estável, o maior esforço de controle à uma resposta ao degrau ocorre imediatamente após o degrau, em que $u^{max} = k_p e^{max}$. Manipulando matematicamente essa expressão, pode-se obter o ganho de controle proporcional (k_p) através do erro máximo antecipado, e o limite de atuação do atuador como

$$k_p = \frac{u^{max}}{e^{max}} \quad (6.2)$$

Considerando um sistema de segunda ordem com realimentação proporcional ao erro e realimentação derivativa na saída, a função de transferência em malha fechada é dada por

$$\frac{\phi}{\phi^d} = \frac{b_x k_p (s + \frac{k_i}{k_p})}{s^3 + b_x K_d s^2 + b_x k_p s + b_x k_i} \quad (6.3)$$

Para selecionar k_d , fixa-se o valor de k_p e considera-se $k_i = 0$, a função de transferência em malha fechada do sistema da Equação 6.3 torna-se

$$\frac{\phi}{\phi^d} = \frac{b_x k_p}{s^2 + b_x K_d s + b_x k_p} \quad (6.4)$$

O modelo do sistema que se deseja controlar é dado pela Equação 3.11 que representa a equação de movimento para o ângulo ϕ . O torque é dado por $\tau_\phi = l(F_l + F_r)$ e a força é diretamente proporcional ao comando PWM tal que $F = k_1 \delta$, assim

$$\tau_\phi = l(k_1 \delta_l - k_1 \delta_r) = 2lk_1 \Delta \delta_\phi \quad (6.5)$$

No qual $\Delta \delta_\phi = (\delta_l - \delta_r)/2$ é a variação de comando calculada pelo controlador que será somada ao motor esquerdo e diminuirá no motor direito. Analisando essa condição de acordo com a Equação 3.11, b_x é dado por

$$b_x = \frac{2lk_1}{J_x} \quad (6.6)$$

É importante também, conhecer a forma canônica da função de transferência de segunda ordem com zeros inexistentes que é dada pela forma padrão

$$H(s) = \frac{Y(s)}{X(s)} = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (6.7)$$

Em que ζ é o coeficiente de amortecimento e ω_n é a frequência natural do sistema. Caso $0 \leq \zeta \leq 1$, o sistema é dito subamortecido e, seus polos complexos são dados por:

$$polos = -\zeta\omega_n \pm \sqrt{1 - \zeta^2} \quad (6.8)$$

Comparando os coeficientes do polinômio do denominador da função de transferência de malha fechada do sistema da Equação 6.3 com os coeficientes da função de transferência canônica do sistema de segunda ordem da Equação 6.7, levando em consideração os limites de saturação do atuador, pode-se derivar uma expressão para a largura de banda realizável para o sistema em malha fechada.

Equacionando os coeficientes dos termos s^0 , tem-se

$$\omega_n = \sqrt{b_x k_p} \quad (6.9)$$

Para selecionar k_i , a equação característica do sistema em malha fechada é escrita como

$$1 + k_i \frac{b_x}{s^3 + b_x k_d s^2 + k_p b_x s} = 0 \quad (6.10)$$

Utilizando o Lugar Geométrico das Raízes (LGR) é possível encontrar um valor para k_i de forma que o coeficiente de amortecimento do sistema permaneça próximo a 0,8.

O projeto feito para o controle do ângulo ϕ pode ser refeito o controle do ângulo θ mudando apenas a constante b_x para $b_y = 2lk_1/J_y$ e alterando as respectivas nomenclaturas. De forma semelhante, para realizar o controle do ângulo ψ pode ser utilizado o mesmo projeto realizado para o controle do ângulo ϕ alterando o b_x por b_z com $b_z = 4k_2/J_z$.

Desta forma, é possível definir os ganhos do controlador PID para cada eixo, considerando a saturação dos atuadores do sistema.

6.3 ALGORITMO FINAL

A metodologia SOESGOPE em malha fechada apresenta uma dificuldade em projetar o controlador, visto a falta de informação e conhecimento sobre os parâmetros que definem o sistema. Para contornar esse problema, na Seção 6.2 foi descrita a metodologia de otimização para encontrar um controlador suficiente para garantir a geração de sinais

persistentemente excitantes e a estimação de parâmetros ótimos para um sistema não linear em malha fechada. A Figura 19 indica como a metodologia pode ser utilizada em malha fechada.




Figura 19 – Diagrama de blocos da metodologia SOESGOPE em malha fechada.

[2]

Na Figura 19, $C(\cdot)$ é uma lei de controle simples, τ é efetivamente o sinal de entrada do sistema e u é um conjunto de sinais referências, com a mesma dimensão de y . Há um ruído simulado de medição e de processo aplicado a todos os estados ($\mathcal{N}(0, \sigma^2)$). Como dito anteriormente, os sinais de excitação τ são gerados através de uma lei de controle para o sistema $\mathcal{M}(\tilde{\Gamma}^p)$ e, aplicados em malha aberta para a estimação de $\hat{\Gamma}^+$. O bloco $C(\cdot)$ atua como um filtro para os sinais de referência u , o que acarreta perda de informação do sinal. Por isso, o controlador deve ser ajustado de acordo com as características do sistema real, para permitir a passagem de frequências que sensibilizem o sistema adequadamente, desta forma, a perda de informação não acarretará em problemas de identificação consideráveis [2].

Na metodologia proposta originalmente, é necessário fornecer os controladores do sistema, baseados em informações do sistema real, isso porque a obtenção de \mathbf{u}^\oplus leva em consideração os efeitos do controlador, portanto gera um sinal de estimação compatível com o controlador. Pressupondo que nem sempre é possível realizar o projeto do controlador adequadamente, devido a falta de informação dos parâmetros do sistema, o aprimoramento da metodologia induz uma busca do conjunto de controladores que são compatíveis com o sistema em questão.

Como abordado na Seção 6.2, a busca do controlador é feita pelo mesmo processo de otimização da metodologia original. Na metodologia original, o processo de otimização era responsável por buscar as amplitudes e tempos de execução de cada estágio dos sinais que são capazes de prover excitação suficiente para a estimação paramétrica. Para a nova abordagem da metodologia, além da busca referente aos componentes dos sinais, o processo de otimização também irá buscar os controladores compatíveis ao sistema para que não haja perda de informação do sistema, utilizando o algoritmo PSLO. Com a nova direção da metodologia é possível realizar a estimação paramétrica, de sistemas não lineares em malha fechada, para situações em que projetar o controlador suficiente para o sistema se

torna uma tarefa árdua, necessitando apenas dos limites máximos e mínimos dos ganhos dos controladores.

7 RESULTADOS E DISCUSSÕES - METODOLOGIA APRIMORADA

No capítulo anterior, foi indicada uma motivação para o aprimoramento do método SOESGOPE. O avanço se dá no projeto para o controlador do sistema, em malha fechada, que deve possuir características que mantenha o sinal suficientemente excitante e garanta que o sistema atinja as velocidades desejadas que o sistema perturbado performou, para evitar a redundância e obter boas estimativas dos parâmetros. A partir dos resultados obtidos na motivação, foi necessário acrescentar ao método, durante a geração do sinal, uma busca por controladores que atinjam tal desempenho. Este capítulo apresenta os resultados obtidos com a adição na metodologia, iniciando com a definição dos limites máximos do controlador para a busca pela metodologia.

7.1 LIMITES DOS CONTROLADORES

Os controladores terão seus ganhos limitados, por valores máximos e mínimos, para que a busca feita pela metodologia não atinja valores indesejáveis. Os valores mínimos para os controladores serão considerados zero, visto que na prática não temos ganhos negativos para o controlador PID. Os limites máximos serão limitados, por eixo, de acordo com o método de sintonia *Successive Loop Closure* indicado anteriormente.

7.1.1 Eixos *roll* e *pitch*

Para definir o valor de k_p utiliza-se a Equação 6.2, sendo u^{max} correspondente ao maior valor possível de $\Delta\delta_\phi$ e e^{max} referente ao valor máximo do erro. O valor do PWM, que comanda os motores, varia entre $1150\mu s$ e $1950\mu s$, isso significa que $\Delta\delta_\phi$ consiste em $u^{max} = 800\mu s$. O ângulo de trabalho dos quadrotores são entre -60° e 60° portanto $e^{max} = 120^\circ$, logo

$$k_p = \frac{800}{120} = 6,6667 \quad (7.1)$$

Para determinar o k_d , fixa-se o valor de k_p e considera-se $k_i = 0$. Sendo a função de transferência de malha fechada do sistema igual a

$$\frac{\phi}{\phi^d} = \frac{k_p b_x}{s^2 + k_d b_x s + k_p b_x} \quad (7.2)$$

Ao comparar os coeficientes do polinômio do denominador da Equação 7.2 com a função de transferência canônica do sistema de segundo ordem, tem-se

$$\omega_n = \sqrt{k_p b_x} \quad (7.3)$$

$$k_d = \frac{2\zeta\omega_n}{b_x} = 4,6702 \quad (7.4)$$

Utiliza-se o coeficiente de amortecimento ζ igual a 0,8, uma vez que um valor menor do que 0,4 produz uma máximo sobressinal excessivo no sistema e acima de 0,8 o sistema responde de forma lenta, encontrando um k_d correspondente. A partir da Equação 6.10, que é a equação característica do sistema em malha fechada, é possível utilizar o método do lugar das raízes para encontrar o valor de k_i . Diante disso, o valor de k_i é determinado quando o coeficiente de amortecimento ζ seja igual ou o mais próximo possível de 0,8.

Observa-se a Figura 20, que o ganho integral é igual a 0,0494, no instante que o coeficiente de amortecimento é igual a 0,8.

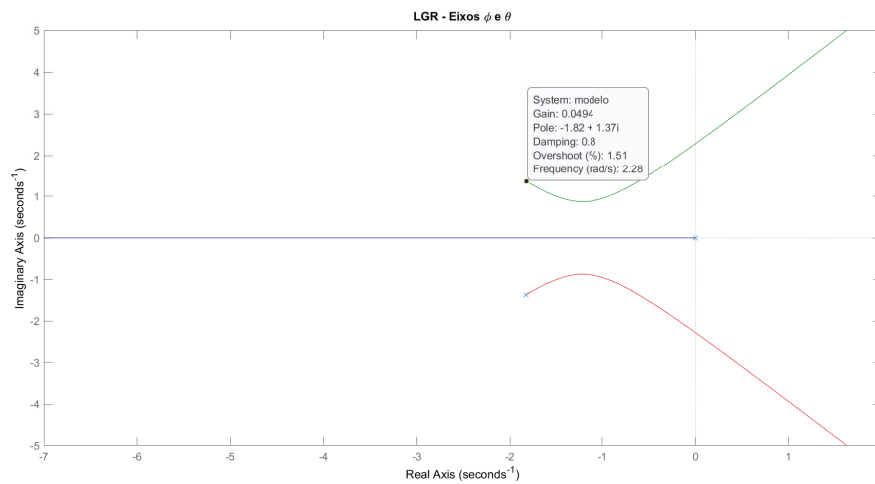


Figura 20 – Lugar geométrico das raízes da equação característica do sistema - Eixos ϕ e θ

7.1.2 Eixo *yaw*

Para o eixo z os cálculos são realizados de forma análoga aos do eixo x , ou seja, o ganho k_p continua sendo calculado pela divisão do maior valor possível de $\Delta\delta_\phi$ (u^{max}) pelo valor máximo do erro (e^{max}). O u^{max} continua sendo igual a $800\mu s$, que é o valor do PWM que comanda os motores, porém o ângulo de trabalho deste eixo é entre -180° a 180° , assim $e^{max} = 360^\circ$. Logo

$$k_p = \frac{800}{360} = 2,2222 \quad (7.5)$$

O valor de k_d para este eixo é calculado de forma análoga ao eixo x , substituindo-se b_x por b_z nas Equações 7.2, 7.3 e 7.4, então

$$\omega_n = \sqrt{k_p b_z} \quad (7.6)$$

$$k_d = \frac{2\zeta\omega_n}{b_z} = 1,7108 \quad (7.7)$$

Na Figura 21 verifica-se que o ganho integral é igual a 0,0126.




Figura 21 – Lugar geométrico das raízes da equação característica do sistema - Eixo ψ

Os limites máximos e mínimos impostos para os controladores, considerando a saturação dos atuadores, estão indicados na Tabela 17.

Tabela 17 – Limites dos Controladores PID para os eixos ϕ , θ e ψ

	Eixos	K_p	K_i	K_d
Mínimos	ϕ, θ	0	0	0
	ψ	0	0	0
Máximos	ϕ, θ	6,6667	0,0494	4,6702
	ψ	2,2222	0,0126	1,7108

7.2 SIMULAÇÕES

Para atestar a eficácia do projeto do controlador sub(ótimo) junto a metodologia SOESGOPE, foram realizados os testes para o primeiro cenário (presente na Seção 5.1.1 do Capítulo 5). Foram analisados todos os casos deste cenário, porém com a busca do controlador sub(ótimo) para a estimação dos parâmetros k_1 e k_2 . Logo em seguida, foi realizada a avaliação para a estimação paramétrica total do quadrotor, conforme o primeiro cenário do Capítulo 5, indicado na Seção 5.2.1. Em todos os casos analisados, as configurações iniciais para a aplicação do método se mantiveram com as mesmas características, a única diferença é que neste instante, o controlador não foi projetado a partir do conjunto de parâmetros reais, ele será encontrado pela metodologia.

7.2.1 Caso tutorial

Para cada caso em questão, o algoritmo buscou o melhor conjunto de sinais para a estimação dos parâmetros, junto ao melhor controlador. A Tabela 18 possui a indicação dos valores dos ganhos dos controladores obtidos pela metodologia para cada caso.

Tabela 18 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Caso tutorial

Caso	Eixo	K_p	K_i	K_d
Caso 1	ϕ	0,0030	0,0	0,0025
	θ	0,0489	0,0037	0,0071
	ψ	0,0014	0,0	0,0037
Caso 2	ϕ	0,0136	0,0	0,0012
	θ	0,0250	0,0046	0,0010
	ψ	0,0195	0,0	0,0
Caso 3	ϕ	0,0	0,0048	0,0
	θ	0,0405	0,0258	0,0067
	ψ	0,0	0,0016	0,0
Caso 4	ϕ	0,0064	0,0042	0,0
	θ	0,0032	0,0023	0,0077
	ψ	0,0030	0,0092	0,0

Em cada caso, um conjunto de sinais distintos foi gerado para excitar suficientemente a planta em questão. A partir do conjunto de parâmetros perturbados ($\tilde{\Gamma}^p$) é possível obter a estimativa dos parâmetros "a posteriori" utilizando o mesmo sinal obtido. A Tabela 19 possui os resultados obtidos na geração do sinal sub(ótimo) com o controlador obtido.

Tabela 19 – Métricas obtidas na geração do conjunto de sinais - Caso tutorial

Caso	1	2	3	4
$\hat{\Gamma}^- - k_1$	0,0268	0,0335	0,0402	0,0161
$\hat{\Gamma}^- - k_2$	0,0147	0,0184	0,0220	0,0088
$\tilde{\Gamma}^p - k_1$	0,0278	0,0348	0,0417	0,0167
$\tilde{\Gamma}^p - k_2$	0,0189	0,0236	0,0283	0,0113
$f_o(\cdot)$	$8,7442 \cdot 10^{-4}$	$8,7389 \cdot 10^{-4}$	$8,7295 \cdot 10^{-4}$	$8,7344 \cdot 10^{-4}$
$f_{\hat{\delta}}(\cdot)$	$9,1035 \cdot 10^{-7}$	$8,3156 \cdot 10^{-6}$	$1,1683 \cdot 10^{-5}$	$1,0722 \cdot 10^{-5}$
$f_{v_x}(\cdot)$	0,1134	0,2143	0,0933	0,1309
$f_{v_y}(\cdot)$	0,0989	0,0962	0,0889	0,1016
$\theta(\cdot)$	$7,2123 \cdot 10^{-5}$	$7,3105 \cdot 10^{-5}$	$7,1822 \cdot 10^{-5}$	$7,2325 \cdot 10^{-5}$

Com os resultados obtidos, a métrica de restrições de tempo, saída e espaço de estados ($\Theta(\cdot)$) retornou uma função de valor baixo em todos os casos, na faixa de 10^{-5} , isto significa que o algoritmo manteve a saída y e os estados x dentro dos limites de espaço admissíveis. A função de precisão de saída, f_o mede a diferença entre a saída e os estados de dois sistemas excitados pelo mesmo sinal, ou seja, o modelo inicial, $\hat{\Gamma}^-$, e o modelo perturbado, $\tilde{\Gamma}^p$, obtendo uma diferença pequena entre eles, na faixa de 10^{-4} , facilitando

assim a estimação do conjunto de parâmetros ótimos. A função de recuperabilidade de parâmetros, f_{δ^+} , avalia a persistência de excitação do sinal, é a garantia de que o conjunto de parâmetros estimados convergem para os parâmetros perturbados, garantindo assim que o sinal gerado é um sinal rico.

É possível perceber que em todos os casos, a geração de sinal sub(ótimo) de excitação foi realizada com sucesso e garantindo assim que o conjunto de parâmetros ótimos será obtido. Os quatro conjuntos de dados iniciais distintos foram suficientes para gerar os sinais sub(óticos) diferentes capazes de excitar o modelo para a estimação do conjunto de parâmetros ótimos.

As Figuras 22 e 23 correspondem aos sinais de excitação gerados pela metodologia e o ajuste dos estados de $\mathcal{M}(\Gamma)$ e $\mathcal{M}(\hat{\Gamma}^+)$ para o caso 1, respectivamente. Os sinais indicados na Figura 22 são diferentes do que os gerados pelo caso 1 da estimação paramétrica de dois parâmetros, no caso 1 da Seção 5.1.1 do Capítulo 5, isso devido ao controlador do sistema ser diferente em cada caso. A maior diferença observada no sinal gerado pela metodologia original e a nova abordagem, é a amplitude do eixo ψ (em amarelo). Analisando a Figura 23, pode-se perceber que os estados do sistema formado com os parâmetros estimados (em azul) possui uma grande influência do ruído de medição e processo adicionado durante a simulação, porém todos os estados se mantêm estáveis e acompanham o modelo formado com os parâmetros reais do sistema.




Figura 22 – Sinal de excitação \mathbf{u}^{\oplus} para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Caso 1.

A Tabela 20 possui o valor dos parâmetros estimados com os sinais gerados, o erro de estimação para cada parâmetro (em porcentagem), o erro quadrático da estimação (Σ_{Γ}) e o tempo de convergência (t_{conv}) para a estimação, em segundos. A partir da tabela, é perceptível que o processo de estimação paramétrica atingiu bons resultados, indicando que a metodologia com a busca do controlador funciona, visto que o maior desvio entre os parâmetros estimados é de 4,0816% e, em todos os casos, o método obteve resultados rapidamente, o maior tempo gasto foi de 74,2104 segundos, indicando que a adição na metodologia não demandou um tempo maior para a convergência.

Ao se fazer uma análise comparativa entre os resultados obtidos a partir da

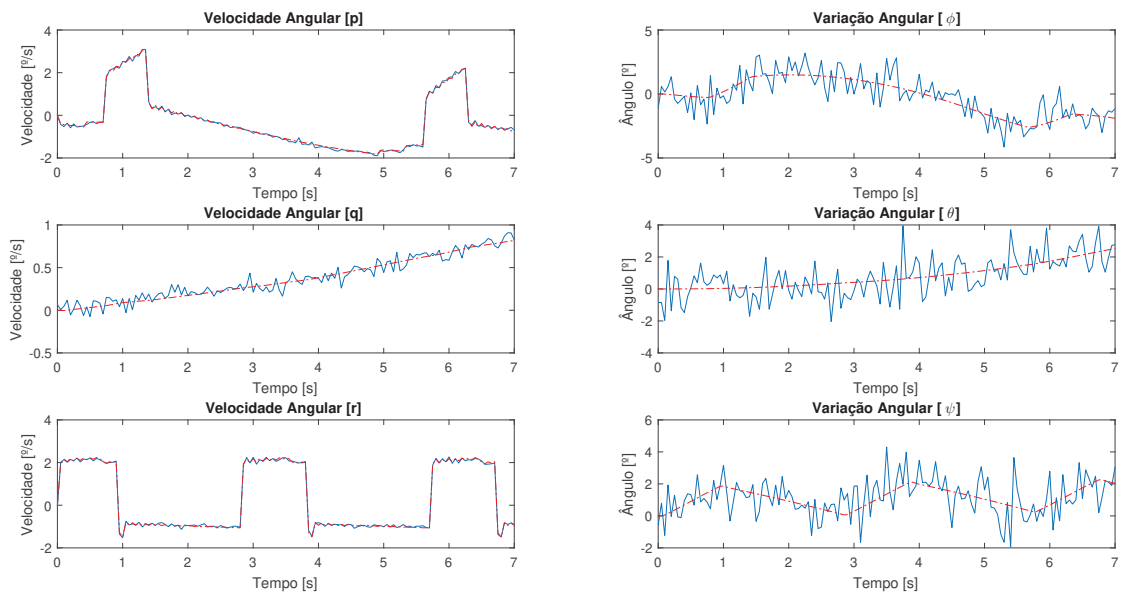


Figura 23 – Ajustes dos estados p , q , r , ϕ , θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Caso 1.

metodologia original (Seção 5.1.1) com os resultados obtidos pela metodologia aprimorada, é possível verificar na Tabela 19 que as métricas para a geração do sinal sub(ótimo) gerado na nova abordagem tiveram uma pequena diminuição em seus valores, o que torna a minimização das métricas mais efetiva para a estimação paramétrica. Em relação as estimativas obtidas, houve um pequeno aumento no erro das estimativas de cada parâmetro, mas todos eles mantêm valores aceitáveis para a estimativa. Ao se analisar fielmente os valores, a nova abordagem aparenta ter um desempenho inferior, se comparada a metodologia original, porém há de se considerar que a metodologia inicial necessita de um alto conhecimento para se realizar o projeto dos controladores e nesta nova abordagem não é necessário. Os casos simulados com a metodologia original tiveram seus controladores projetados a partir dos parâmetros reais do sistema, o que facilita a busca das estimativas, mas na prática, nem sempre isso é possível.

Tabela 20 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Caso tutorial

Caso	$\hat{\Gamma}^+$		Erro [%]		Σ_{Γ}	t_{conv}
	k_1	k_2	k_1	k_2		
1	0,0266	0,0148	0,7463	0,6803	$3,4563 \cdot 10^{-8}$	83,1096
2	0,0270	0,0144	0,7463	2,0408	$1,4399 \cdot 10^{-7}$	74,2104
3	0,0266	0,0149	0,7463	1,3605	$9,6083 \cdot 10^{-8}$	69,2269
4	0,0264	0,0153	1,4925	4,0816	$5,7874 \cdot 10^{-7}$	66,1360

7.2.2 Caso completo

Para cada caso em questão, o algoritmo buscou o melhor conjunto de sinais para a estimação dos parâmetros, junto ao melhor controlador. A Tabela 21 possui a indicação dos valores dos ganhos dos controladores obtidos pela metodologia para cada caso.

Tabela 21 – Ganhos dos Controladores PID para os eixos ϕ , θ e ψ – Caso completo

Caso	Eixo	K_p	K_i	K_d
Caso 1	ϕ	0,0083	0,0321	0,0
	θ	0,0144	0,0483	0,00015
	ψ	0,0014	0,011	0,0
Caso 2	ϕ	0,0061	0,0580	0,0011
	θ	0,0035	0,0064	0,0133
	ψ	0,0190	0,0040	0,0013
Caso 3	ϕ	0,0310	0,0016	0,0186
	θ	0,0116	0,00118	0,0157
	ψ	0,0059	0,0022	0,0044

Em cada caso, um conjunto de sinais distintos foi gerado para excitar suficientemente a planta em questão. A partir do conjunto de parâmetros perturbados ($\tilde{\Gamma}^p$) é possível obter a estimativa dos parâmetros "a posterior" utilizando o mesmo sinal obtido. A Tabela 22 possui os resultados obtidos na geração do sinal sub(ótimo) com o controlador obtido.

Tabela 22 – Métricas obtidas na geração do conjunto de sinais - Caso completo

Caso	1	2	3
$f_o(\cdot)$	$8,7079 \cdot 10^{-4}$	$8,7183 \cdot 10^{-4}$	$8,7377 \cdot 10^{-4}$
$f_{\hat{\delta}}(\cdot)$	0,0121	0,0098	$2,16 \cdot 10^{-6}$
$f_{v_x}(\cdot)$	0,1700	0,6749	0,4818
$f_{v_y}(\cdot)$	0,1215	0,5275	0,2369
$\theta(\cdot)$	$7,2915 \cdot 10^{-5}$	$8,2024 \cdot 10^{-5}$	$7,7187 \cdot 10^{-5}$

É possível perceber que em todos os casos, a geração de sinal sub(ótimo) de excitação foi realizada com sucesso e garantindo assim que o conjunto de parâmetros ótimos será obtido.

As Figuras 24 e 25 correspondem aos sinais de excitação gerados pela metodologia e o ajuste dos estados de $\mathcal{M}(\Gamma)$ e $\mathcal{M}(\hat{\Gamma}^+)$ para o caso 1, os sinais são diferentes do que os gerados pelo caso 1 da estimação paramétrica de dois parâmetros, no caso 1 da Seção 5.2.1 do Capítulo 5. O ajuste dos estados, indicado na Figura 25, indica que os estados do sistema estimado $\mathcal{M}(\hat{\Gamma}^+)$ (azul) estão corrompidos pelo ruído adicionado ao sistema, em suas variações angulares. O controlador não conseguiu inibir o efeito do ruído presente nos estados angulares, mas manteve os estados estáveis e com o mesmo comportamento e trajetória do que os estados do sistema real $\mathcal{M}(\Gamma)$ (vermelho), o que é suficiente para a estimação paramétrica.




Figura 24 – Sinal de excitação u^{\oplus} para os estados ϕ (azul), θ (vermelho) e ψ (amarelo) - Caso 1.

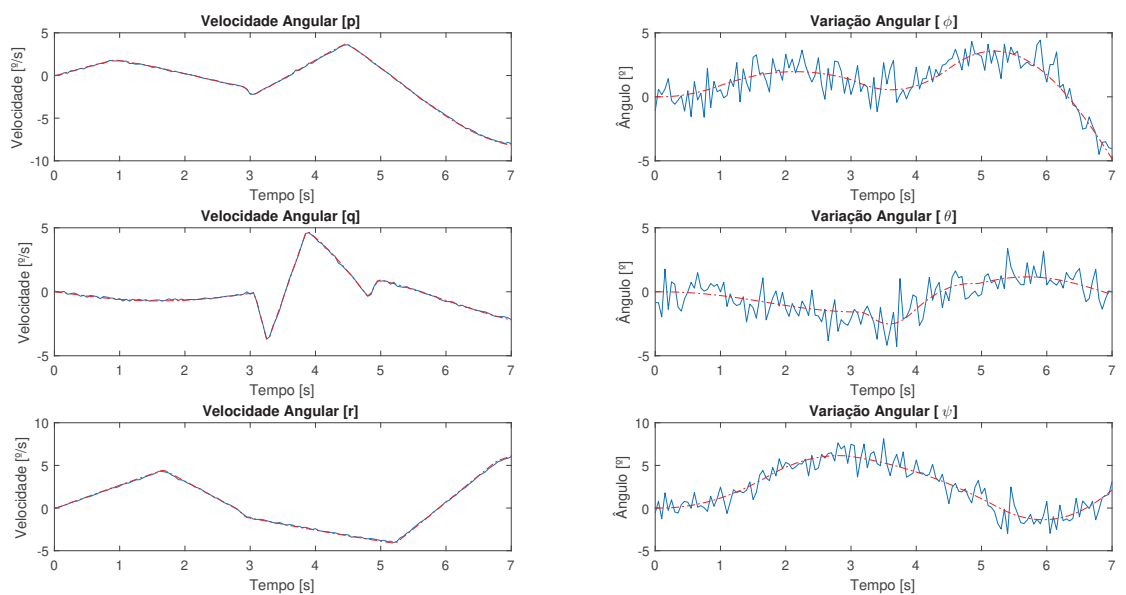


Figura 25 – Ajustes dos estados p , q , r , ϕ , θ e ψ dos sistemas real $\mathcal{M}(\Gamma)$ (azul) e simulado $\mathcal{M}(\hat{\Gamma}^+)$ (vermelho) - Caso 1.

A Tabela 23 possui o valor dos parâmetros estimados com os sinais gerados, o erro de estimação, em porcentagem, de cada parâmetro; o erro quadrático da estimação (Σ_{Γ}); e o tempo de convergência (t_{conv}) para a estimação, em segundos.

Pela tabela, é notório que o processo de estimação paramétrica para o quadrotor completo obteve resultados satisfatórios, se comparados aos casos obtidos no Capítulo 5, uma vez que os desvios entre as estimativas estão bem próximos, indicando o sucesso para essa nova abordagem da metodologia SOESGOPE. No primeiro caso, os parâmetros estimados condizem com os valores reais do sistema, chegando a erros de estimação nulos. O segundo e o terceiro casos, mesmo que com algumas estimativas pobres, se comparadas aos resultados obtidos com a metodologia original, as estimativas se mantêm próximas. O fato de em ambos os casos as estimativas não serem tão boas, se deve a distância da

Tabela 23 – Estimação de parâmetros ótimos “*a posteriori*” – $\hat{\Gamma}^+$ – Caso completo

Caso	Modelo	M	m	R	l	k_1	k_2	Σ_Γ	t_{conv}
1	$\hat{\Gamma}^-$	1,0	0,105	0,1	0,25	0,0268	0,0147	$1,8412 \cdot 10^{-7}$	190,8718
	$\hat{\Gamma}^+$	1,0002	0,1054	0,1000	0,2500	0,0268	0,0147		
	Erro [%]	0,02	0,3810	0	0	0	0		
2	$\hat{\Gamma}^-$	1,2	0,126	0,12	0,3	0,03216	0,01764	0,0405	334,2494
	$\hat{\Gamma}^+$	1,1946	0,1220	0,1166	0,2931	0,0368	0,0239		
	Erro [%]	19,46	16,1905	16,6	17,24	37,3134	62,5850		
3	$\hat{\Gamma}^-$	0,8	0,084	0,08	0,2	0,02144	0,01176	0,0421	532,2458
	$\hat{\Gamma}^+$	0,8025	0,0861	0,0828	0,2019	0,0177	0,0076		
	Erro [%]	19,75	18,0	17,2	19,24	33,9552	48,2993		

estimativa inicial fornecida à metodologia, conforme citado anteriormente.

Os casos do Capítulo 5 foram estimados, com o projeto do controlador utilizando os parâmetros reais do quadrotor. Neste capítulo, os resultados foram obtidos com a busca do controlador, considerando que não há um conhecimento do sistema real para o projeto. Deste modo, a metodologia em malha fechada pode ser utilizada quando não há informação suficiente do sistema para o projeto dos controladores, sem acarretar em perda de informação.

7.3 METODOLOGIA ORIGINAL X METODOLOGIA APRIMORADA

A metodologia aprimorada avança no sentido de obter um controlador que consiga resolver os impasses existentes em problemas de identificação de sistemas em malha fechada. As Tabelas 24 e 25 apresentam os resultados obtidos com a metodologia original e com a metodologia aprimorada, para o caso tutorial, com estimação de apenas dois parâmetros (k_1 e k_2) e a Tabela 26 apresenta os resultados para a estimação dos seis parâmetros estruturais da aeronave, obtidos com a metodologia.

Tabela 24 – Resultados metodologia original – Caso tutorial

Metodologia	Original				
Caso	1	2	3	4	
Erro (Σ_Γ)	$4,1307 \times 10^{-8}$	$1,4820 \times 10^{-8}$	$7,9101 \times 10^{-9}$	$6,9684 \times 10^{-9}$	
$t_{conv} [seg]$	93,6879	70,8727	34,6923	89,4545	
Entropia (H)	ϕ	2,9339	0,2804	1,0404	4,5304
	θ	7,8603	3,8015	0,3749	2,7408
	ψ	13,5769	0,6111	3,0834	2,6576

Ao analisar os resultados obtidos com a metodologia no caso tutorial, percebe-se que a metodologia original e aprimorada conseguiram obter estimativas dos parâmetros com erros pequenos e tempo de convergência aceitável para os algoritmos. Isso se deve ao fato de a busca ser realizada apenas para dois parâmetros e com isso a convergência do algoritmo se dá de modo mais rápido. Mesmo com a busca dos ganhos do controlador PID com a metodologia aprimorada, o tempo de convergência chegou a ser menor (como no

Tabela 25 – Resultados metodologia aprimorada – Caso tutorial

Metodologia		Aprimorada			
Caso		1	2	3	4
Erro (Σ_{Γ})		$3,4563 \times 10^{-8}$	$1,4399 \times 10^{-7}$	$9,6083 \times 10^{-8}$	$5,7874 \times 10^{-7}$
$t_{conv}[seg]$		83,1096	74,2104	69,2269	66,1360
Entropia (H)	ϕ	0,2198	3,8208	$4,9978 \times 10^{-5}$	0,4516
	θ	$3,5579 \times 10^{-6}$	$1,3790 \times 10^{-6}$	0,0111	0,2527
	ψ	0,6537	$8,8767 \times 10^{-5}$	$2,1759 \times 10^{-4}$	$3,7673 \times 10^{-4}$

primeiro e quarto casos) ou próximo aos tempos de convergência da metodologia original. Desta forma pode-se inferir que a busca dos ganhos do controlador junto ao processo de otimização não prejudica o algoritmo em relação ao seu tempo de convergência.

Em relação a entropia dos sinais, para a metodologia aprimorada a entropia foi menor, o que leva a acreditar que haverá uma grande perda de informação do sinal para o processo de estimação paramétrica. Porém, com a otimização do controlador, a metodologia busca um controlador e um sinal de excitação que sejam compatíveis e desta forma o sinal de referência é suficientemente excitante para obter estimativas de parâmetros que condizem com o sistema, como observado nos resultados obtidos.

Tabela 26 – Resultados comparativos entre a metodologia original e a metodologia aprimorada – Caso completo

Metodologia		Original			Aprimorada		
Caso		1	2	3	1	2	3
Erro (Σ_{Γ})		$1,2620 \times 10^{-7}$	0,0410	0,0422	$1,8412 \times 10^{-7}$	0,0405	0,0421
$t_{conv}[seg]$		307,1499	429,5388	613,8822	190,8718	334,2494	532,2458
Entropia (H)	ϕ	0,6797	2,2363	2,4000	0,0289	5,1713	3,4879
	θ	0,5961	0,1340	1,2096	0,0265	3,3090	4,5742
	ψ	17,1276	16,6409	6,7880	0,0130	0,3338	8,7838

Para o caso de estimação completa dos parâmetros estruturais do quadrotor, nota-se um tempo de convergência do algoritmo maior, devido ao fato do processo de otimização ter de buscar muitos parâmetros para a estimação. Comparando a metodologia original com a metodologia aprimorada, percebe-se que o tempo de convergência da metodologia aprimorada reduziu em relação ao da metodologia original, o que é uma vantagem da metodologia aprimorada. O tempo de convergência diminuiu porque para a metodologia original, o sinal sub-ótimo é buscado de forma que seja compatível com o controlador fornecido. Já na metodologia aprimorada, a busca do controlador junto ao sinal se torna mais rápida para encontrar a compatibilidade entre eles. Em relação ao erro de estimação, ambas as abordagens possuíram valores próximos e coerentes com o sistema em questão, como foi observado anteriormente pelos parâmetros obtidos e o ajuste dos estados do sistema com a estimação paramétrica.

Em relação a entropia, percebe-se um aumento de entropia para os sinais, nos casos 2 e 3 da metodologia aprimorada, o que facilita a estimação paramétrica pois não há perda

de informação significativa nos sinais utilizados para a estimação. Para o primeiro caso a entropia teve uma queda entre a metodologia original e a metodologia aprimorada, porque o primeiro caso se refere ao modelo real do controlador, que para a metodologia original, o controlador foi projetado utilizando as características do quadrotor real, desta forma, era de se esperar tal resultado. Mesmo com a queda de entropia para este primeiro caso, o processo de estimação paramétrica não foi prejudicado devido ao fato da metodologia aprimorada ter buscado um controlador que fosse compatível com o sinal de excitação encontrada e, desta forma, a qualidade do sinal encontrado foi boa para prover a excitação necessária para o sistema.

8 CONCLUSÕES FINAIS

Este trabalho apresentou uma análise sobre a metodologia de Geração de Sinal Sub(Ótimo) de Excitação e Estimação Ótima de Parâmetros – SOESGOPE para sistemas em malha fechada, em que o mecanismo de Estimação Ótima de Parâmetros – OPE é baseado na minimização da diferença entre os históricos de saídas e dos estados do modelo e do sistema real.

A metodologia foi aplicada em um veículo aéreo. Um dos desafios presentes é a modelagem e implementação do controle do sistema, visto que existem diversas técnicas de sintonia de parâmetros para o controlador PID. Uma técnica de sintonia baseada em otimização foi aplicada para a construção do controlador. Com o sistema controlado, foi possível aplicar a metodologia para gerar sinais sub(ótimos) de excitação e, a partir deles, estimar os parâmetros desconhecidos do sistema em diversos cenários. O processo proposto em malha fechada utiliza de controladores simples, que estabilizam o sistema sem mascarar as não linearidades do processo. O aumento de segurança da estimação com o sistema não linear real não interfere significativamente na qualidade da estimação, uma vez que a entrada e a saída do sistema estimado são não correlacionadas.

A metodologia foi analisada em dois casos (tutorial e completo) para a estimação paramétrica do quadrotor. Inicialmente, a estimação foi feita para apenas dois parâmetros (caso tutorial), que não são triviais de serem mensurados, considerando que os outros parâmetros são únicos e bem definidos. No primeiro cenário do caso tutorial, inicialmente, uma simulação com os parâmetros do sistema real gerou um conjunto de sinais de excitação e a partir deles os parâmetros foram estimados. Sem penalidades na estimação dos parâmetros, eles foram próximos aos parâmetros considerados reais, com valor do erro quadrático da estimação baixo. Em seguida, mais três conjuntos de sinais diferentes foram gerados para tentar obter a estimação dos mesmos parâmetros, e novamente o método obteve sucesso. Analisando o primeiro cenário considerado, através da estimação ótima de parâmetros e o erro quadrático encontrado, a metodologia se mostra aplicável ao gerar conjuntos de sinais sub(ótimos) capazes de excitar o sistema, mesmo considerando modelos iniciais distintos. O maior desvio encontrado entre os parâmetros reais e os parâmetros estimados no primeiro cenário foi de 1,3605%.

Já o segundo cenário, do caso tutorial, viabiliza a metodologia a estimar os parâmetros de um sistema, com modelos iniciais distintos, mas partindo de um mesmo conjunto de sinais sub(ótimos). Neste cenário também foram obtidas estimativas com boa exatidão, visto que o maior desvio encontrado foi de 0,7463%. Deste modo, observa-se um ganho até então não identificado na metodologia, em que os sistemas iniciais podem ser excitados por sinais oriundos de um mesmo conjunto de sinais. Em todos os cenários, o erro quadrático médio da estimação foi consideravelmente pequeno, em que, o maior se

encontra na faixa de 10^{-8} , o que indica que os parâmetros foram bem estimados.

Posteriormente, foram analisadas as estimativas considerando a aplicabilidade da metodologia da mesma maneira que nos mesmos cenários, porém para a estimação paramétrica total do veículo aéreo, aumentando a complexidade exigida à metodologia. Além disso, um cenário foi gerado para analisar se a região de busca dos parâmetros, que indica o nível de confiança sobre o conhecimento de cada um deles, afeta na estimação.

Para a estimação paramétrica completa, no primeiro cenário, o maior desvio obtido na estimativa de parâmetros foi de 61,2245%, equivalente ao parâmetro k_2 do segundo caso. As estimativas para o segundo e terceiro casos, não obtiveram resultados tão interessantes, mas isso se deve ao valor da estimativa inicial dos parâmetros estar distante dos valores do modelo real $\mathcal{M}(\Gamma)$. No segundo cenário os erros de estimação também chegaram alcançar alguns altos valores, chegando a 65,3061% de desvio em um dos parâmetros, também devido ao distanciamento da estimativa inicial dos parâmetros. Por fim, o terceiro cenário indica que a região de busca dos parâmetros pode ser extrapolada, desde que tenha um bom conhecimento da estimativa inicial dos parâmetros para utilizar. Pode-se utilizar o algoritmo de maneira recursiva para se obter melhores resultados.

Na ampla maioria dos casos estudados, a metodologia proposta obteve resultados contundentes, mesmo na presença de ruído, considerando uma grande variação paramétrica e alto desconhecimento dos parâmetros. Pelo ajuste das curvas dos estados pode-se concluir que o conjunto de parâmetros $\hat{\Gamma}^+$ gerou um modelo $\mathcal{M}(\hat{\Gamma}^+)$ muito representativo em todos os casos estudados.

Após a análise da metodologia original, aplicada ao quadrotor e, considerando o fato de que para se utilizar a metodologia original em malha fechada é necessário um bom conhecimento inicial dos parâmetros para projetar de maneira satisfatória o controlador, uma nova abordagem foi apresentada. Inicialmente foi identificado que os mesmos casos estudados, com controladores projetados distintos, obtinham estimações paramétricas diferentes. A partir daí e, considerando que o projeto do controlador, para o sistema em malha fechada, é feito com pouco ou nenhum conhecimento do sistema em questão, uma proposta de avanço na metodologia SOESGOPE foi indicada e comprovada com testes realizados para o quadrotor trabalhado. A nova abordagem indica que durante a geração do sinal sub(ótimo) de excitação do sistema, também é encontrado o controlador sub(ótimo) suficiente para a identificação do sistema, a partir da estimativa inicial fornecida ao método, de modo que o processo de otimização encontrará um sinal de entrada que seja compatível com o controlador obtido para que, se houver perda de informação no sinal utilizado para a estimação, esta perda de informação não acarrete em problemas significativos de estimação paramétrica.

Tal adição na metodologia se mostrou eficaz em todos os casos abordados, ao analisar o ajuste dos estados do sistema com os parâmetros estimados. Uma vantagem da

nova abordagem para a metodologia é conseguir utilizá-la em malha fechada sem depender fielmente dos valores de estimativas iniciais para sintonizar o controlador. De fato, a metodologia aprimorada encontra um sinal sub(ótimo) junto a sintonia do controlador que melhor se relacionam, para garantir que caso haja perda de informação do sinal controlador (após ser filtrado pelo controlador), a excitação do sinal seja suficiente para a estimação paramétrica. Ao analisar os resultados obtidos com a metodologia aprimorada, conclui-se que para a estimação realizada no caso tutorial (dois parâmetros), houveram poucas diferenças entre a metodologia original e a metodologia proposta. Os ganhos são vistos ao se aplicar a metodologia aprimorada para a estimação de mais parâmetros, como visto no caso completo. Para esta situação a metodologia aprimorada possuiu um tempo de convergência, do algoritmo de otimização, menor, o que contribui computacionalmente para análise de outros sistemas. Além disso, a nova metodologia conseguiu garantir a entropia do sinal utilizado para a estimação, nos casos dos cenários 2 e 3, em que as estimativas iniciais dos parâmetros eram mais distantes dos parâmetros reais do quadrotor. A entropia chegou a aumentar de 1,2096 para 4,5742, como visto no terceiro caso. Desta forma, sem perda de entropia significativa, sem perda de informação utilizada para a estimação.

A metodologia se mostrou uma alternativa eficaz para estimar parâmetros de sistemas não lineares, sendo possível utilizá-la em malha fechada sem levar o sistema a comportamentos instáveis e descontinuidades. A busca do controlador junto à metodologia oferece uma alternativa mais confiável, para o processo de busca do sinal sub(ótimo), visto que o pouco conhecimento sobre os parâmetros do sistema não prejudica o projeto de um bom controlador para a estimação. O sinal de excitação impede que o sistema deixe uma região de comportamento segura. Com a modelagem adequada e com uma boa estimativa dos parâmetros desconhecidos é possível desenvolver controladores de alto desempenho para o sistema não linear em estudo.

A partir dos resultados do trabalho é possível admitir ganhos para a metodologia SOESGOPE, são eles:

- é possível realizar a estimação ótima de parâmetros a partir de modelos iniciais distintos, mas partindo de um mesmo conjunto de sinais sub(ótimos), sem a necessidade de cada modelo inicial gerar o seu próprio conjunto de sinais;
- a região de busca dos parâmetros pode ser extrapolada e não interferirá na estimação caso tenha uma boa estimativa inicial para o modelo;
- a metodologia aprimorada conta com o processo de otimização para sintonizar o controlador, de modo que o controlador e o sinal de excitação sejam compatíveis evitando a perda de informação nos sinais utilizados para a estimação paramétrica e,

caso haja uma baixa entropia no sinal, as características do sinal de excitação são suficientes para não acarretar em problemas de identificação consideráveis;

- o tempo de convergência do algoritmo da metodologia aprimorada é menor que o da metodologia original, o que contribui computacionalmente, para sistemas com um maior número de incertezas.

8.1 TRABALHOS FUTUROS

Para trabalhos futuros, podem ser destacados os seguintes estudos:

- aplicação prática da metodologia SOESGOPE em quadrotoros, devido ao desafio técnico de sua implementação em veículos aéreos;
- estudo de novas abordagens de ajustes dos controladores;
- junção da metodologia SOESGOPE recursiva com a otimização dos controladores para analisar se os resultados serão satisfatórios e assim obter um método completo para a estimação paramétrica de sistemas não lineares com muitas incertezas;
- realizar testes do aprimoramento da metodologia em outros sistemas não lineares para se analisar o resultado, visto que cada sistema possui as suas particularidades;
- propor uma nova abordagem para a sintonia dos controladores com a adição de uma métrica na metodologia que maximize a entropia dos sinais de modo a garantir uma melhor estimação paramétrica.

REFERÊNCIAS

- [1] L. A. AGUIRRE, *Introdução à Identificação de Sistemas- Técnicas lineares e não-lineares aplicadas a sistemas reais.*, 4th ed. Editora UFMG, 2015.
- [2] E. B. COSTA, “Metodologia de otimização em dois níveis para a geração de sinal sub-Ótimo de excitação e estimação de parâmetros de sistemas não lineares restritos.” 2017.
- [3] K. OGATA, *Engenharia de Controle Moderno.*, 5th ed. São Paulo: Pearson Education do Brasil., 2011.
- [4] R. ISERMANN, *Mechatronic systems: fundamentals.* London, UK: Springer-Virlag., 2005.
- [5] E. B. COSTA, “Algoritmos de controle aplicados à estabilização de vôo de um quadrotor.” 2012.
- [6] M. F. SANTOS, V. S. PEREIRA, A. C. RIBEIRO, M. F. SILVA, M. J. DO CARMO, V. F. VIDAL, L. M. HONÓRIO, A. S. CERQUEIRA, and E. J. OLIVEIRA, “Simulation and compatison between a linear and nonlinear technique applied to altitude control in quadcopters.” in *IEEE Carpathian Control Conference (ICCC) 18th Internacional.*, May 2017, pp. 234–239.
- [7] A. M. L. d. SILVA, M. R. FREIRE, and L. M. HONÓRIO, “Transmission expansion planning optimization by adaptative multi-operator evolutionary algorithms.” in *Electric Power Systems Research, Elsevier.*, vol. 133, April 2016, pp. 173–181.
- [8] L. LJUNG, *System Identification: Theory for User.*, 2nd ed. Prentice Hall, 1999.
- [9] A. M. BARBOSA, “Técnicas de otimização bi-objetivo para a determinação da estrutura de modelos narx.” 2010.
- [10] M. DEFLORIAN and S. ZAGLAUER, “Design of experiments for nonlinear dynamic system identification.” in *IFAC Proceedings Volumes.*, vol. 44, no. 1, August 2011, pp. 13 175–13 184.
- [11] J. E. A. DIAS, G. A. S. PEREIRA, and R. M. PALHARES, “Longitudinal model identification and velocity control of an autonomous car.” in *IEEE Transactions on Intelligent Transportation Systems.*, vol. 16, no. 2, April 2015, pp. 776–786.
- [12] G. C. GOODWIN, “Optimal input signals for nonlinear-system identification.” in *Proceedings of the Institution of Electrical Engineers.*, vol. 118, no. 7, July 1971, pp. 922–926.

- [13] R. E. KALMAN, “A new approach to linear filtering and prediction problems,” *Journal of Basic Engineering*, vol. 82, no. 1, pp. 35–45, 1960.
- [14] A. H. JAZWINSKI, “Stochastic processes and filtering theory,” *Academic Press, Inc.*, 1970.
- [15] S. J. JULIER and J. K. UHLMANN, “Unscented filtering and nonlinear estimation,” *Proceedings of the IEEE.*, vol. 92, no. 3, pp. 401–422, 2004.
- [16] J. ACKERMANN, ***Robust control: Systems with uncertain physical parameters.*** Springer Science & Business Media, 2012.
- [17] L. JAULIN and M. KIEFFER, “Applied interval analysis,” *Springer.*, 2001.
- [18] G.-R. DUAN and H.-H. YU, ***LMI in Control Systems: Analysis, Design and Applications.*** CRC Press, 1a edition, 2013.
- [19] P. V. OVERSCHEE and B. L. R. D. MOOR, ***Subspace identification: theory, implementation, application.*** Academic Publishers., 1996.
- [20] M. VERHAEGEN and V. VERDULT, ***Filtering and system identification - A least squares approach.***, 1st ed. Cambridge University Press., 2007.
- [21] M. LOVERA, “Identification of mimo state space models for helicopter dynamics.” *13th IFAC Symposium on System Identification*, 2003.
- [22] M. VERHAEGEN, “Identification of the deterministic part of mimo state space models given in innovations form from input-output data.” *Automatica*, vol. 30, pp. 61–74, 01 1994.
- [23] S. BITTANTI and M. LOVERA, “Bootstrap-based estimates of uncertainty in subspace identification methods.” *Automatica*, vol. 36, pp. 1605–1615, 11 2000.
- [24] L. C. ROMIO, A. T. Z. R. SAUSEN, P. S. SAUSEN, and M. M. P. REIMBOLD, “Aplicação de identificação de sistemas no tempo de vida de baterias de dispositivos móveis.” *Revista de ciências exatas e engenharias. Rio Grande do Sul*, pp. 18–33, 2012.
- [25] C.-h. WANG, P.-c. CHEN, and P.-z. LIN, “A dynamic neural network model for nonlinear system identification.” *IEEE International Conference On Information Reuse Integration*, 2009.
- [26] Y. SHEN, X. JU, and C. LIU, “Application of second order diagonal recurrent neural network in nonlinear system identification.” *International Conference On Web Information Systems And Mining*, pp. 420–424, 2010.

- [27] P. GAUTAM, “System identification of nonlinear inverted pendulum using artificial neural network.” *International Conference on Recent Advances and Innovations in Engineering, IEEE*, pp. 1–5, 2017.
- [28] Y. NAUNG and et al., “Implementation of data driven control system of dc motor by using system identification process.” *IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus*, p. 1801–1804, 01 2018.
- [29] M. MONESS and T. DIAA-ELDEEN, “Experimental nonlinear identification of a lab-scale helicopter system using mlp neural network.” *13th International Computer Engineering Conference: Boundless Smart Societies*, pp. 166–171, 01 2018.
- [30] J. K. E. d. C. MARTINS, F. R. d. L. SOUZA, and F. M. U. d. ARAUJO, “Identificação de um sistema de tanques acoplados não linear com atraso utilizando rna.” *Instituto Brasileiro de Petróleo, Gás e Biocombustíveis (IBP). Congresso Rio Automação 2015*, 2015.
- [31] B. M. SANANDAJI and et. al., “Multivariable ga-based identification of ts fuzzy models: Mimo distillation column model case study.” *IEEE International Conference on Fuzzy Systems*, pp. 1–6, 2007.
- [32] M. V. d. PAULA, “Identificação de modelos de hammerstein e wiener para sistemas não lineares multivariáveis via métodos de subespaços.” 2016.
- [33] J. A. SANTOS and L. O. S. GINALBER, “Recursive identification approach of multivariable nonlinear dynamic systems based on evolving fuzzy hammerstein models.” *IEEE International Conference on Fuzzy Systems*, pp. 1–8, 07 2018.
- [34] J. M. ADÁNEZ and et al, “Multidimensional membership functions in t-s fuzzy models for modelling and identification of nonlinear multivariable systems using genetic algorithms.” *Applied Soft Computing. Elsevier B.V.*, vol. 75, pp. 607–615, 02 2019.
- [35] E. J. OLIVEIRA, L. W. OLIVEIRA, J. L. R. PEREIRA, L. M. HONÓRIO, I. C. S. JUNIOR, and A. L. M. MARCATO, “An optimal power flow based on safety barrier interior point method.” in *International Journal of Electrical Power Energy Systems.*, vol. 64, January 2015, pp. 977–985.
- [36] D. E. KIRK, *Optimal control theory: an introduction*. Mineola: Dover Publications, Inc., 2004.
- [37] L. M. HONÓRIO, E. B. COSTA, E. OLIVEIRA, D. FERNANDES, and A. MOREIRA, “Persistently-exciting signal generation for optimal parameter estimation of constrained nonlinear dynamical systems.” in *ISA Transactions.*, vol. 77, Abril 2018, pp. 231–241.

- [38] L. M. HONORIO, A. M. L. d. SILVA, D. A. BARBOSA, and L. F. N. DELBONI, “Solving optimal power flow problems using a probabilistic α -constrained evolutionary approach.” in *Generation, transmission distribution, IET.*, vol. 4, no. 6, July 2010, pp. 674–682.
- [39] R. AUSTIN, *Unmanned aircraft systems: UAVS design, development and deployment.*, 3rd ed. John Wiley & Sons, 2011.
- [40] P. ISCOLD, G. PEREIRA, and L. TORRES, “Development of a hand-launched small uav for ground reconnaissance.” in *Aerospace and Electronic Systems, IEEE Transactions on.*, vol. 46, February 2010, pp. 335–348.
- [41] S. HRABAR, T. MERZ, and D. FROUSHEGER, “Development of an autonomous helicopter for aerial powerline inspections.” in *IEEE. Applied Robotics for the Power Industry (CARPI).*, November 2010, pp. 1–6.
- [42] S. GRZONKA, G. GRISETTI, and W. BURGARD, “A fully autonomous indoor quadrotor.” in *IEEE Transactions on Robotics.*, vol. 28, no. 1, February 2012, pp. 90–100.
- [43] L. MERINO, F. CABALLERO, J. R. MARTINEZ-DE-DIOS, I. MAZA, and A. OLLERO, “An unmanned aircraft system for automatic forest fire monitoring and measurement.” *Journal of Intelligent and Robotic Systems.*, vol. 65, no. 1, pp. 533–548, January 2012.
- [44] T. HE, Y. ZENG, and Z. HU, “Research of multi-rotor uavs detailed autonomous inspection technology of transmission lines based on route planning.” *IEEE Access.*, vol. 7, pp. 114955–114965, August 2019.
- [45] R. W. BEARD, “Quadrotor dynamics and control.” *Brigham Young University.*, vol. 19, no. 3, pp. 46–56, May 2008.
- [46] A. S. C. ALVES, “Estudo e aplicação de técnicas de controle embarcadas para estabilização de voo de quadricópteros.” 2012.
- [47] C. COZA and C. J. B. MACNAB, “A new robust adaptive-fuzzy control method applied to quadrotor helicopter stabilization.” in *NAFIPS 2006 - 2006 Annual Meeting of the North American Fuzzy Information Processing Society.*, June 2006, pp. 454–458.
- [48] I. C. DIKMEN, A. ARISOY, and H. TEMELTAS, “Attitude control of a quadrotor.” in *2009 4th International Conference on Recent Advances in Space Technologies.*, July 2009, pp. 722–727.

- [49] G. HOFFMANN, H. HUANG, S. WASLANDER, and C. TOMLIN, “Quadrotor helicopter flight dynamics and control: Theory and experiment.” in *AIAA Guidance, Navigation, and Control Conference.*, August 2007, pp. 1–20.
- [50] J. M. B. DOMINGUES, “Quadrotor prototype.” 2009.
- [51] L. D. MINH and C. HA, “Modeling and control of quadrotor mav using vision-based measurement.” in *International Forum on Strategic Technology 2010.*, October 2010, pp. 70–75.
- [52] S. BOUABDALLAH and R. SIEGWART, “Backstepping and sliding-mode techniques applied to an indoor micro quadrotor.” in *IEEE. ICRA 2005. Proceedings of the 2005 IEEE International Conference on Robotics and Automation.*, January 2005, pp. 2247–2252.
- [53] K. J. AMSTRÖM and B. WITTENMARK, *Adaptive control.*, 2nd ed. Mineola: Dover Publications, Inc., 2013.
- [54] S. L. WASLANDER, G. M. HOFFMANN, J. S. JANG, and C. J. TOMLIN, “Multi-agent quadrotor testbed control design: integral sliding mode vs. reinforcement learning.” in *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems.*, December 2005, pp. 3712–3717.
- [55] P. ADIGBLI, C. GRAND, J.-b. MOURET, and S. DONCIEUX, “Nonlinear attitude and position control of a micro quadrotor using sliding mode and backstepping techniques.” in *3rd US-European Competition and Workshop on Micro Air Vehicle Systems (MAV07) European Micro Air Vehicle Conference and Flight Competition (EMAV2007).*, October 2007, pp. 17–21.
- [56] Y. AL-YOUNES and M. A. JARRAH, “Attitude stabilization of quadrotor uav using backstepping fuzzy logic backstepping least-mean-square controllers.” in *2008 5th International Symposium on Mechatronics and Its Applications.*, October 2008, pp. 1–11.
- [57] A. RABHI, M. CHADLI, and C. PEGARD, “Robust fuzzy control for stabilization of a quadrotor.” in *2011 15th International Conference on Advanced Robotics (ICAR).*, June 2011, pp. 471–475.
- [58] C. NICOL, C. J. B. MACNAB, and A. RAMIREZ-SERRANO, “Robust neural network control of a quadrotor helicopter.” in *2008 Canadian Conference on Electrical and Computer Engineering.*, July 2008, pp. 1233–1238.
- [59] J. D. A. d. SOUSA, “Simulação e desenvolvimento de um veículo aéreo autônomo de quatro rotores.” 2011.

- [60] P. NORVIG and S. THRUN. (2019, February) Udacity - intro to artificial intelligence. [Online]. Available: <https://www.udacity.com/course/intro-to-artificial-intelligence--cs271>
- [61] R. GOLDSTEIN, K. MCKAY, Y. ZHAI, R. STEWART, A. HIRA, C. LI, R. MOZER, and D. SINGAMSETTY, “Beohawk: Autonomous quadroter.” in *Symposium on Indoor Flight Issue.*, 2011, pp. 1–11.
- [62] L. A. AGUIRRE, *Sistemas dinâmicos não lineares: conceitos e análise de dados*. Kindle, 1a edition, 2020.
- [63] M. B. A. SOUZA, L. M. HONÓRIO, E. J. d. OLIVEIRA, and A. P. G. M. MOREIRA, “Recursive approach of sub-optimal excitation signal generation and optimal parameter estimation.” *International Journal of Control, Automation and Systems.*, vol. 18, pp. 1965–1974, February 2020.

APÊNDICE A – PRODUÇÃO CIENTÍFICA

A.1 ARTIGO EM CONGRESSO NACIONAL

GONÇALVES, P. H.; CERQUEIRA, A. S.; COSTA, E. B. Análise da Metodologia SOESGOPE aplicada a um Quadrotor para Estimação Ótima de Parâmetros. In: ANAIS DO 14º SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 2019, Ouro Preto. Anais eletrônicos... Campinas, GALOÁ, 2020. Disponível em: <<https://proceedings.science/sbai-2019/papers/analise-da-metodologia-soesgope-aplicada-a-um-quadrotor-para-estimacao-otima-de-parametros>> Acesso em: 30 mar. 2020.