



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

Accacio Ferreira dos Santos Neto

**METODOLOGIA DE ESTIMAÇÃO PARAMÉTRICA ROBUSTA APLICADA A
UM VEÍCULO AUTÔNOMO DE SUPERFÍCIE**

Tese de Doutorado

Juiz de Fora
2021

ACCACIO FERREIRA DOS SANTOS NETO

**Metodologia de Estimaco Paramtrica Robusta Aplicada
a um Veculo Autnomo de Superfcie**

Tese de Doutorado apresentada ao Programa de Ps-Graduao em Engenharia Eltrica da Universidade Federal de Juiz de Fora, na rea de concentrao em Sistemas de Energia, como requisito para obteno do ttulo de Doutor em Engenharia Eltrica.

Orientador: Prof. Dr. Leonardo de Mello Honrio
Co-orientador: Prof. Dr. Edimar Jos de Oliveira

Juiz de Fora
2021

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Ferreira dos Santos Neto, Accacio.

Metodologia de Estimaco Paramétrica Robusta Aplicada a um Veículo Autônomo de Superfície /Accacio Ferreira dos Santos Neto. -- 2021.

108 f. : il.

Orientador: Leonardo de Melo Honrório

Coorientador: Edimar José de Oliveira

Tese (doutorado) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduao em Engenharia Elétrica, 2021.

1. Veículos Autônomos de Superfície. 2. Identificao de Sistemas. 3. Projeto de Sinais de Identificao. 4. Estimaco Paramétrica Robusta. 5. Otimizao. I. de Melo Honrório, Leonardo, orient II. José de Oliveira, Edimar, coorient III. Título.

Accacio Ferreira dos Santos Neto

Metodologia de Estimação Paramétrica Robusta Aplicada a um Veículo Autônomo de Superfície

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica

Aprovada em 23 de dezembro de 2021.

BANCA EXAMINADORA

Prof. Dr. Leonardo de Melo Honório - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. Edimar José de Oliveira

Universidade Federal de Juiz de Fora

Profa. Dra. Milena Faria Pinto

Centro Federal de Educação Tecnológica Celso Suckow da Fonseca

Prof. Dr. Edson da Costa Bortoni

Universidade Federal de Itajubá

Prof. Dr. Leonardo Willer de Oliveira

Universidade Federal de Juiz de Fora

Prof. Dr. André Luis Marques Marcato

Universidade Federal de Juiz de Fora

Juiz de Fora, 09/12/2021.



Documento assinado eletronicamente por **Leonardo de Mello Honorio, Professor(a)**, em 23/12/2021, às 19:30, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo Willer de Oliveira, Professor(a)**, em 23/12/2021, às 19:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Edson da Costa Bortoni, Usuário Externo**, em 23/12/2021, às 19:52, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Milena Faria Pinto, Usuário Externo**, em 24/12/2021, às 10:41, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Edimar Jose de Oliveira, Professor(a)**, em 23/02/2022, às 11:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Andre Luis Marques Marcato, Professor(a)**, em 05/03/2022, às 19:44, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **0609960** e o código CRC **417BBEEE**.

“Dedico este humilde trabalho a todos aqueles que permitiram que este sonho fosse possível”.

AGRADECIMENTOS

Agradeço primeiramente a Deus pela oportunidade de vivenciar e concluir este período de qualificação com saúde e entusiasmo. À minha família, representada pelos meus pais Accacio (*In memoriam*) e Maria de Fátima, expresso toda a minha gratidão ao apoio e incentivos constantes que me permitiram chegar até aqui com dignidade, respeito e merecimento.

Minha gratidão à minha esposa Máyra, pelo companheirismo, compreensão, incentivo e carinho, os quais foram fundamentais para a superação de todos os desafios envolvidos nesta etapa de qualificação.

Não poderia deixar de agradecer aos meus queridos amigos orientadores do mestrado, Francisco José Gomes e Flávio Barbosa, que constantemente reverberam em minhas memórias e foram fundamentais para que esta etapa fosse possível.

Aos sinceros amigos do Grupo de Robótica Inteligente (GRIn) da UFJF, sou muito grato pelo companheirismo, empatia e apoio neste período. Período de muitos diálogos, testes de campo e desafios enfrentados com muita cumplicidade.

Aos professores Daniel Fernandes e Exuperry Costa também deixo meus agradecimentos às conversas iniciais sobre identificação e teoria de controle que, com certeza, foram fundamentais para o desenvolvimento da tese proposta.

Também deixo meus sinceros agradecimentos ao meu orientador Leonardo Honório e co-orientador Edimar José de Oliveira pela confiança, incentivo e aprendizados. Através da orientação tive a oportunidade de vivenciar o verdadeiro papel de um engenheiro. Este que projeta, “coloca a mão na massa” e, principalmente, observa os equívocos como uma oportunidade de crescimento e construção de um novo olhar sobre os problemas.

Por fim, agradeço à querida Universidade Federal de Juiz de Fora, esta que tenho a imensa satisfação de ter cursado graduação, mestrado e doutorado. Ao Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG) também deixo meus sinceros agradecimentos por permitir que estes estudos pudessem acontecer e retornar mais qualificado às atividades de docência.

*“Eu aprendi muito mais com os meus erros
do que com meus acertos”.*

Thomas Edison

RESUMO

Sabe-se que em atividades de água corrente ou quando expostos a ventos e ondas, os Veículos Autônomos de Superfície (VASs) estão expostos aos cenários mais desafiadores. Nessas condições, o conhecimento de um modelo matemático robusto é um aspecto fundamental para o ajuste do sistema de controle. Constituinte, portanto, premissa básica para alcançar segurança e desempenho nos cenários de incertezas. É neste contexto que este trabalho apresenta uma nova metodologia de identificação a partir do uso de múltiplos sinais de identificação. Nesta perspectiva, o experimento de identificação é composto por múltiplos sinais otimizados do tipo *Amplitude-modulated Pseudo-Random Binary Signal* (APRBS). Estes são projetados para excitar distintas amostras no torno da estimação inicial do sistema e são otimizados por uma topologia composta pelo *Particle Swarm Optimization* (PSO) e Método dos Pontos-Interiores (MPI). Através deste artifício busca-se ampliar a capacidade de excitação do experimento e, portanto, proporcionar a estimação de modelos paramétricos mais robustos e confiáveis. Para verificar a eficácia da metodologia, um problema de modelagem do VAS do tipo catamarã foi escolhido. Os resultados demonstraram alta similaridade entre os modelos estimados e a embarcação real em todas as etapas, inclusive nos diversos testes de validação. Portanto, demonstrando a aplicabilidade do método proposto e sua capacidade de produzir modelos paramétricos mais robustos e confiáveis.

Palavras-chave: Veículos Autônomos de Superfície, Identificação de Sistemas, Projeto de Sinais de Identificação, Estimação Paramétrica Robusta, Otimização.

ABSTRACT

It is known that in running water activities or when exposed to winds and waves, the *Autonomous Surface Vehicles (ASVs)* are exposed to the most challenging scenarios. Under these conditions, knowledge of a robust mathematical model is a fundamental aspect for adjusting the control system. Therefore, it is a basic premise to achieve safety and performance in uncertain scenarios. In this context, this work presents a new identification methodology based on the use of multiple identification signals. In this perspective, the identification experiment is composed of optimized APRBS-type signals. These are designed to excite different samples around the initial estimation of the system and are optimized by an approach composed of the Particle Swarm Optimization (PSO) and the Interior-Point Method (IPM). Through this artifice, we seek to expand the excitation capacity of the experiment and, therefore, provide the estimation of more robust and reliable parametric models. To verify the effectiveness of the methodology, a catamaran-type ASV modeling problem was chosen. The results showed high similarity between the estimated models and the real vessel at all stages, including the various validation tests. Therefore, demonstrating the applicability of the proposed method and its ability to produce more robust and reliable parametric models.

Keywords: Autonomous Surface Vehicles, System Identification, Identification Signals Design, Robust Parameter Estimation, Optimization.

LISTA DE ILUSTRAÇÕES

1	Exemplos de ASVs desenvolvidos em universidades.	19
2	Representação dos eixos de movimento do veículo.	31
3	Fenômeno de Massa Adicionada.	34
4	Corpo submerso em um fluido ideal (não-invíscido).	36
5	Conceito SOESGOPE.	48
6	Fluxograma do método SOESGOPE.	50
7	Situação desfavorável ao método SOESGOPE.	51
8	Conceito rSOESGOPE.	53
9	Fluxograma do método rSOESGOPE.	53
10	Visão real do ASV AERO4River.	60
11	Diagrama de Aplicação do rSOESGOPE.	64
12	Sinais APRBS Projetados pelo rSOESGOPE.	67
13	Localização do ensaios de estimação.	71
14	Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_1^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_1^\oplus)$	71
15	Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_2^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_2^\oplus)$	72
16	Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_3^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_3^\oplus)$	72
17	Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_4^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_4^\oplus)$	73
18	Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_5^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_5^\oplus)$	73
19	Trajetórias no plano- xy : C1 a C9.	74
20	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1. . .	75
21	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C2. . .	76
22	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C3. . .	77
23	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C4. . .	78

24	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C5. . .	79
25	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C6. . .	80
26	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C7. . .	81
27	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C8. . .	82
28	Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C9. . .	83
29	<i>Boxplot</i> detalhando o RMSE geral dos modelos $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1 a C9. . .	84
30	<i>Frames</i> Inercial e do Veículo	90
31	Sistema de Coordenadas: \mathcal{F}^{v1}	91
32	Sistema de Coordenadas: \mathcal{F}^{v2}	91
33	Sistema de Coordenadas: \mathcal{F}^b	92
34	Ilustração do Corpo rígido	95
35	Exemplo de Parametrização do Sinal APRBS.	100

LISTA DE TABELAS

1	Notação para Veículos Marinhos - (LEWIS, 1988).	30
2	Análise da dimensão dos problemas de identificação conforme $D(\nu)$. . .	43
3	Comparação entre as características do SOESGOPE e rSOESGOPE. . .	58
4	Características Inerciais do AERO4River.	61
5	Limites Operacionais do AERO4River.	61
6	Resumo da Estimção Inicial $\mathcal{M}(\hat{\Gamma}^-)$	63
7	Parâmetros de Referência Gerados - P^\oplus	65
8	Análise do número de estágios e indivíduos.	66
9	Desempenho dos Sinais Projetados U^\oplus	67
10	Estimações Paramétricas obtidas com $U_1^\oplus, U_2^\oplus, U_3^\oplus, U_4^\oplus$ e U_5^\oplus	69
11	Análise de desempenho geral de $\mathcal{M}(\hat{\Gamma}_n^+)$	70
12	Análise de desempenho geral de cada DoF de $\mathcal{M}(\hat{\Gamma}_n^+)$	70
13	Análise de desempenho geral de $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1 a C9.	83
14	Análise de desempenho geral de cada DoF de $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1 a C9.	84
15	Análise do impacto do número de sinais para a estimção de $\mathcal{M}(\hat{\Gamma}_n^+)$. . .	85
16	Análise do número de estágios e indivíduos.	100
17	Configuração PSO	103

LISTA DE ABREVIATURAS E SIGLAS

ASV *Autonomous Surface Vehicle*

VAS *Veículo Autônomo de Superfície*

DoF *Degree of Freedom*

OSD *Optimal Signal Design*

FIM *Fisher Information Matrix*

ACO *Ant Colony Optimization*

PSO *Particle Swarm Optimization*

GA *Genetic Algorithm*

PRBS *Pseudo-Random Binary Sequence*

APRBS *Amplitude-modulated Pseudo-Random Binary Signal*

FGN *Filtered Gaussian Noise*

MPI *Método dos Pontos-Interiores*

IPM Interior-Point Method

LSM *Least-Squares Method*

RMSE *Root-Mean Square Error*

CG Centro de Gravidade

SOESGOPE *Sub-Optimal Excitation Signal Generation and Optimal Parameter Estimation*

rSOESGOPE *Robust SOESGOPE*

SNAME *Society of Naval Architects and Marine Engineers*

EP *Estimação Paramétrica*

SUMÁRIO

1	Introdução	18
1.1	Contextualização e Motivação	18
1.2	Trabalhos Relacionados	20
1.3	Objetivos da Tese	24
1.4	Principais contribuições da Tese	24
1.5	Resultados Científicos Alcançados	26
1.6	Organização da Tese	28
2	Modelagem de Veículos Marinhos de Superfície	29
2.1	Introdução	29
2.2	Variáveis de Estado	30
2.3	Equações Dinâmicas de um Corpo Rígido	31
2.4	Forças e Momentos Hidrodinâmicos	33
2.5	Equações de Movimento	39
2.6	Embarcações de Superfície	40
2.7	Definição do Problema de Estimação Paramétrica	42
3	Método de Identificação SOESGOPE Robusto	44
3.1	Introdução ao Problema de Identificação de Sistemas	44
3.2	Abordagem a priori: SOESGOPE	47
3.3	Abordagem a posteriori: SOESGOPE Robusto (rSOESGOPE)	51
3.4	Comparação: SOESGOPE e rSOESGOPE	58
3.5	Algoritmo Geral da Metodologia	59

4	Resultados Experimentais	60
4.1	ASV AERO4River	60
4.2	Aplicação do Método rSOESGOPE	64
4.3	Validação dos Modelos	74
5	Conclusões e Trabalhos Futuros	86
5.1	Trabalhos Futuros	88
	Apêndice A - Sistemas de Coordenadas	89
A.1	Referencial Inercial: \mathcal{F}^i	89
A.2	Referencial do Veículo: \mathcal{F}^v	90
A.3	Referencial do Corpo-rígido: \mathcal{F}^{v1}	90
A.4	Referencial do Corpo-rígido: \mathcal{F}^{v2}	91
A.5	Referencial do Corpo-rígido: \mathcal{F}^b	92
	Apêndice B - Cinemática e Dinâmica de Corpo Rígido	93
B.1	Cinemática do Corpo Rígido	93
B.2	Dinâmica do Corpo Rígido	95
B.3	Equações Dinâmicas de um Corpo Rígido	97
	Apêndice C - Metaheurística Aplicada no OSD	99
C.1	Representação do Sinal	99
C.2	Configuração do Sinal e População da Metaheurística	100
C.3	Particle Swarm Optimization	100
	Referências	104

1 INTRODUÇÃO

1.1 Contextualização e Motivação

As embarcações marinhas de superfície, também conhecidas como veículos de superfície autônomos, (do inglês, *Autonomous Surface Vehicles* - ASVs), tem atraído a atenção de pesquisadores de todo o mundo (LIU et al., 2016; DONG et al., 2019).

O motivo desta atenção decorre de vantagens naturais da constituição destas embarcações. Caracterizadas por baixo custo, alta mobilidade e alto grau de autonomia, os ASVs oferecem aplicações aos mais diversos ambientes marinhos. É possível encontrar aplicações em represas, rios, lagos até mar aberto (JORGE et al., 2019; PENG et al., 2020), em atividades de: supervisão de águas e portos (MAHACEK, 2005), pesquisa oceanográfica (KIMBALL et al., 2014), mapeamento batimétrico (BECK et al., 2009), inspeção de estruturas em pontes e plataformas (HAN et al., 2015), entre muitas outras aplicações (LIU et al., 2016). Para fins de ilustração, na Figura 1 têm-se alguns exemplares de ASVs desenvolvidos em universidades.

Em virtude da diversidade de aplicações e operações em ambientes abertos, os ASVs podem estar sujeitos a uma grande variação das condições de operação. As atividades em águas correntes, ou quando expostos a ventos e ondas, estão entre as mais desafiadoras (FOSSEN, 2002; WANG et al., 2016). Nessas condições, o conhecimento de um modelo matemático robusto é um aspecto fundamental para o ajuste do sistema de controle (KRAGELUND et al., 2013). Constituindo-se, portanto, premissa básica para alcançar segurança e desempenho nos cenários incertos que possam surgir.

No entanto, o desenvolvimento de modelos sujeitos a incertezas não é uma tarefa trivial. A obtenção desta classe de modelos exige robustez às incertezas oriundas de fontes, como (ZHOU; DOYLE, 1998): variações paramétricas, dinâmicas não-modeladas e não linearidades negligenciadas. Além disso, também são parte do problema os desafios clássicos quanto à escolha da parametrização, o projeto de sinais de identificação e a etapa de estimação paramétrica.

Figura 1: Exemplos de ASVs desenvolvidos em universidades.



(a) AutoCat - Fonte:
(MANLEY, 2008)



(b) CaRoLIME - Fonte:
(WIRTENSOHN et al., 2013)



(c) Charlie - Fonte:
(CACCIA; BRUZZONE; BONO,
2008)



(d) kaiak (MIT) - Fonte:
(CURCIO; LEONARD;
PATRIKALAKIS, 2005)



(e) ROAZ II - Fonte:
(MARTINS et al., 2007)



(f) Wave Glider - Fonte:
(MANLEY; HINE, 2016)



(g) Sonobot - Fonte:
(WIRTENSOHN et al., 2015)



(h) Zarco - Fonte:
(CRUZ et al., 2007)

Conforme apresentado na literatura, especialmente em (HONÓRIO et al., 2018; SOUZA et al., 2020; SOUZA; HONÓRIO; OLIVEIRA, 2020), esta tarefa pode ser definida como um problema de otimização não linear que requer abordagens competentes para lidar com o projeto de sinal, ou experimento de identificação, e posterior estimação paramétrica.

De qualquer forma, independentemente da metodologia adotada, é consenso que a abordagem deve ser capaz de gerar sinais que garantam estímulos assertivos às princi-

país dinâmicas do sistema (GIANNAKIS; SERPEDIN, 2001). No âmbito dos sistemas não lineares, os sinais devem ter uma persistência de excitação adequada ao sistema, estimulando uma ampla gama de amplitudes e frequências. Além disso, também é essencial que os sinais sejam viáveis para a atuação do sistema e respeitem as condições de segurança para o desenvolvimento do experimento de identificação (ISERMANN; MÜNCHHOF, 2010).

Do ponto de vista da técnica de estimação paramétrica, esta deve conseguir adaptar-se à problemática estabelecida e extrair informações essenciais da dinâmica do sistema. No âmbito de sistemas não lineares, a capacidade de inclusão de restrições operacionais e estimação de sistemas não lineares nos parâmetros são características importantes (ISERMANN; MÜNCHHOF, 2010). Portanto, aspectos fundamentais para a estimação de modelos robustos e adequados às características do sistema.

No contexto dos ASVs, todos os requisitos mencionados também não são fáceis de atingir. Caracterizados como sistemas com não linearidades acentuadas, sujeitos a fortes assimetrias mecânicas e acoplamento entre os graus de liberdade (DoFs¹) do sistema, a obtenção de modelos robustos e confiáveis não é trivial (FOSSEN, 2011). A identificação robusta destes sistemas exige sinais com alta persistência (alta codificação) e estimação de modelos com alta parametrizações. Tarefa esta que, computacionalmente, possui complexidade relevante do ponto de vista do espaço interno de solução dos sinais e externo no âmbito da resolução paramétrica (WANG; SOARES; ZOU, 2020).

1.2 Trabalhos Relacionados

Em busca de um direcionamento para a solução do problema proposto, diversas metodologias de identificação de modelos paramétricos foram analisadas. Nesta pesquisa foram investigadas abordagens no âmbito geral de veículos autônomos e, também, específicas aos ASVs.

1.2.1 Contexto Geral

No âmbito geral, os trabalhos investigados propõe metodologias compostas por estratégias de projeto de sinais associados a algoritmos de estimação tradicionais (SOUZA; HONÓRIO; OLIVEIRA, 2020). Nestas composições, a estimação paramétrica recebe

¹Graus de liberdade, do inglês - *Degrees of Freedom* (DoFs)

menor importância e, portanto, a solução do problema concentra-se na busca por estratégias para projeto de sinais ótimos, do inglês *Optimal Signals Design* (OSDs).

Tradicionalmente, o OSD é formulado como um problema de otimização usando a inversa da Matriz de Informação de *Fisher* (FIM²). Esta matriz permite medir a persistência de excitação do sinal, independentemente do algoritmo de estimação implementado. Quanto à solução do problema de otimização, vários algoritmos determinísticos ou probabilísticos são utilizados (SCHRANGL; TKACHENKO; RE, 2020). Dentre os de caráter determinísticos, os algoritmos *Steepest-descent*, gradiente-conjugado, *Quasi-linearization* e o *Newton-Raphson* são alguns destes. Enquanto as meta-heurísticas inspiradas na natureza são exemplos clássicos de métodos probabilísticos frequentemente aplicados (FANG; SHENTON, 2013).

Pesquisando na literatura, várias metodologias são encontrados neste sentido. Em relação às soluções baseadas em métodos determinísticos, os trabalhos de Annergren et al. (2017) e Kumar e Narasimhan (2016) são exemplos clássicos de aplicação de OSD para a estimação paramétrica. Nessas abordagens os sinais são otimizados usando algoritmos determinísticos clássicos que otimizam métricas da inversa da FIM, como o traço médio (*A-Optimality*), máximo autovalor (*E-Optimality*), determinante (*D-Optimality*), etc.

Outra forma encontrada na literatura é a solução combinando métodos determinísticos com a teoria de controle ótimo. Exemplos dessas abordagens podem ser vistos em (HOLZAPFEL, ; LICITRA et al., 2018; JAUBERTHIE et al., 2006; OBERPEILSTEINER et al., 2017). Especificamente, no trabalho de Holzapfel (2020) é possível observar uma aplicação em veículos aéreos. Os sinais ótimos são gerados a partir da combinação de programação dinâmica e controle ótimo, melhorando as tradicionais manobras de identificação para esta categoria de veículo. Por outro lado, apesar dos resultados satisfatórios, também é perceptível que as manobras de entrada ainda poderiam ser aprimoradas aumentando a codificação do sinal. No entanto, nota-se que este aumento proporcionaria também uma maior complexidade espacial do problema e até inviável de tratamento pelas técnicas apresentadas.

No contexto de metodologias baseadas em meta-heurísticas, vale destacar os trabalhos de (HONÓRIO et al., 2018), (WANG; SOARES; ZOU, 2020) e (NOURI; VALADI; ASGHARIAN, 2018) que projetam sinais de sequência pseudo-aleatória multinível. Enquanto Honório et al. (2018) adotou o algoritmo do PSO, Wang, Soares e Zou (2020)

²Matriz de Informação de *Fisher*, do inglês *Fisher Information Matrix* (FIM).

usou o algoritmo *Ant Colony Optimization* (ACO) e Nouri, Valadi e Asgharian (2018) apostou no *Genetic Algorithm* (GA) para resolver o problema de OSD aplicado à identificação paramétrica. O que se destaca nesses trabalhos é a capacidade de projetar sinais com alto nível de codificação com tempos de processamento razoáveis e flexibilidade para a estruturação da função custo que será otimizada. Especificamente no trabalho de Honório et al. (2018), o método desenvolvido, denominado SOESGOPE³, também inclui a otimização do tempo de experimento. Além disso, os autores desenvolveram uma metodologia de otimização própria que permite: o aprimoramento da persistência do sinal, a redução do volume espacial do experimento e do tempo total do experimento.

No que tange à perspectiva da estimação de modelos sujeitos às incertezas, raros são os trabalhos de identificação que se preocupam e previnem às possíveis variações paramétricas, dinâmicas não-modeladas e não linearidades desconsideradas (NOURI; VALADI, 2017). Em sua grande maioria, a compensação dos erros de modelagem é realizada pela lei de controle, como demonstram os trabalhos de (KRAGELUND et al., 2013; FERNANDES et al., 2015; CHNIB et al., 2021).

1.2.2 Contexto dos ASVs

Pesquisando trabalhos no contexto dos ASVs, observa-se que a maioria promove a identificação a partir de sinais de baixa complexidade associados a estimadores clássicos (HERRERO; GONZALEZ, 2012). Constituindo-se raridade a adoção de sinais com alta persistência de excitação como (ISERMANN; MÜNCHHOF, 2010): *Pseudo-Random Binary Sequence* (PRBS), APRBS, *Filtered Gaussian Noise* (FGN). Além disso, a busca por artifícios pela mitigação de incertezas também torna-se raro entre as metodologias de identificação (LIU et al., 2016).

De maneira geral são adotados sinais de baixa complexidade, como os movimentos em linha reta, círculo, espiral e *zigue-zague*. Exemplos claros destas aplicações são observadas em Caccia, Bruzzone e Bono (2008), que utiliza um conjunto de manobras simples como sinal de identificação, e em Dong et al. (2019) cuja excitação da embarcação é feita por manobras do tipo *zigue-zague*.

Quanto aos estimadores, existe uma grande diversidade utilizada, que variam desde o clássico *Least-Squares Method* (LSM) (LI; BACHMAYER, 2014), variações do filtro de Kalman (DENG; YANG; WANG, 2019), Método dos Pontos Interiores (MPI) (WIR-

³*Sub-Optimal Excitation Signal Generation and Optimal Parameter Estimation* (SOESGOPE)

TENSOHN et al., 2015) a até meta-heurísticas (WIRTENSOHN et al., 2013). Fato que pode ser motivado em virtude da complexidade e do propósito da aplicação, como: característica da estrutura dos parâmetros (lineares ou não lineares), função custo de otimização, inclusão de restrições (paramétricas, operacionais), dimensão do espaço de busca, etc.

1.2.3 Reflexões sobre as metodologias

Analisando os trabalhos correlatos é possível desenvolver algumas reflexões sobre a identificação de modelos sujeitos a incertezas.

Na perspectiva do projeto dos sinais foram encontradas diversas metodologias. No âmbito geral foi possível observar abordagens com resultados muito satisfatórios, porém em sua maioria demonstrando dificuldades na solução de sinais com alta codificação. A exceção ocorreu com as metodologias desenvolvidas pelas meta-heurísticas, as quais demonstraram habilidades e eficiência para lidar com amplos espaços de busca. Quanto aos trabalhos dedicados aos ASVs, constatou-se a utilização de sinais de baixa complexidade. Estes que não são planejados e, conforme a literatura, não podem garantir alto perfil de persistência em virtude da faixa de frequências e amplitudes deficientes em excitação. Portanto, não garantindo a estimação de modelos robustos e confiáveis.

No tocante às incertezas, nota-se que este atributo não é uma preocupação da maioria das abordagens. Apesar de basearem-se no projeto de sinais ótimos, este pressuposto não garante robustez às incertezas (Neto et al., 2021). Sabendo que os sinais são tradicionalmente projetados a partir de uma estimativa inicial do sistema, que possui um nível de incerteza relativa, logo é essencial desenvolver artifícios que minimizem estes efeitos e seja possível projetar sinais adequados às características do sistema.

As reflexões, portanto, indicam a necessidade do desenvolvimento de uma abordagem capaz de: ① minimizar os efeitos das incertezas sobre a estimativa inicial do sistema, ② expandir a região de persistência de excitação e ③ projetar sinais adequados ao sistema para posterior estimação paramétrica robusta. A aplicação das meta-heurísticas, neste contexto, oferecem um caminho promissor como demonstrado em (HONÓRIO et al., 2018; NOURI; VALADI; ASGHARIAN, 2018; WANG; SOARES; ZOU, 2020), permitindo o desenvolvimento de metodologias flexíveis com alta capacidade de busca em espaço de soluções complexos, como sugere o problema.

Dentre as metodologias investigadas a abordagem que mais se aproxima dos propósitos traçados é a metodologia **SOESGOPE**, proposta desenvolvida por [Honório et al. \(2018\)](#). Esta abordagem será utilizada como base para um novo método, denominado **SOESGOPE Robusto** (do inglês, *Robust SOESGOPE*). Esta nova abordagem amplia o conceito original utilizando múltiplos sinais de identificação otimizados, ao invés de um único sinal. A partir deste artifício almeja-se minimizar os efeitos oriundos de incertezas e, portanto, propiciar a estimação de modelos mais robustos e confiáveis. Mais informações e comparações entre os métodos serão apresentados no [Capítulo 3](#).

1.3 Objetivos da Tese

Baseado nas limitações encontradas nos métodos descritos nas Seções [1.1](#) e [1.2](#), este trabalho estabelece o seguinte objetivo geral:

- Desenvolver uma metodologia de otimização para estimação paramétrica robusta, aplicada a um [ASV](#) sujeito às seguintes incertezas: variações paramétricas, dinâmicas não-modeladas e não-linearidades negligenciadas.

O alcance do objetivo geral demandará a realização dos seguintes objetivos específicos:

- Desenvolver um modelo paramétrico adequado ao [ASV](#) de estudo de caso;
- Elaborar um procedimento experimental para estimar informações a “priori” de um [ASV](#);
- Projetar sinais de identificação conforme especificações operacionais e de segurança do [ASV](#) de estudo;
- Desenvolver e implementar um algoritmo capaz de aplicar o sinal projetado e coletar as medidas dos estados do [ASV](#) para posterior estimação paramétrica.

1.4 Principais contribuições da Tese

Este trabalho apresenta as seguintes contribuições para o campo da identificação paramétrica e robótica envolvendo [ASVs](#):

1. Nova abordagem de identificação de sistemas considerando incertezas

O trabalho propõe um novo conceito de identificação que proporciona a minimização das incertezas paramétricas. Diferente dos métodos encontrados na literatura (Neto et al., 2021), o conceito SOESGOPE Robusto contém artifícios para mitigar os efeitos das incertezas paramétricas e, conseqüentemente, favorecer a estimação de modelos mais robustos e confiáveis.

2. Utilização de múltiplos sinais de identificação otimizados

Conforme a literatura específica à identificação (ver Seção 1.2), nota-se que esta tese é um dos poucos trabalhos, senão o único, a propor a utilização de múltiplos sinais de excitação otimizados. A maioria das abordagens propõe a aplicação de um sinal único (SOUZA; HONÓRIO; OLIVEIRA, 2020). Esta nova perspectiva permite aumentar a região de excitação e minimizar as “incertezas dinâmicas” sobre o objeto de estudo.

3. Modelo matemático para pequenos ASVs considerando parâmetros de acoplamento

Conforme a literatura específica aos ASVs (LIU et al., 2016), a maior parte das abordagens utilizam modelos simplificados, desconsiderando a maioria das possíveis assimetrias e acoplamentos entre os DoF. Neste trabalho é apresentado um modelo paramétrico admitindo todos os acoplamentos e assimetrias possíveis no tratamento dos fenômenos hidrodinâmicos de arrasto e massa adicionada. Estas considerações mostram-se vantajosas principalmente para ASVs com variados perfis de velocidade de operação. Neste cenário, os veículos estão sujeitos a apresentarem assimetrias estruturais e dinâmicas não modeladas, as quais são fundamentais para a representação de um modelo robusto e mais próximo da realidade.

4. Aplicação em um ASV real com 3 DoFs

O trabalho apresenta uma análise detalhada do processo de modelagem e identificação de um ASV com 3 DoFs e topologia inovadora, conforme os trabalhos de (SILVA et al., 2020) e (REGINA et al., 2021). Ao longo da tese também é possível ter *insights* sobre aspectos teóricos e práticos de modelagem que tradicionalmente não são apresentados na literatura clássica.

1.5 Resultados Científicos Alcançados

Durante a realização desta tese alguns trabalhos desenvolvidos resultaram nas seguintes publicações:

1.5.1 Artigos de Autoria Publicados

- Artigo Publicado na IEEE *Access*: “*Development of Optimal Parameter Estimation Methodologies Applied to a 3 DoF Autonomous Surface Vessel*” (Neto et al., 2021)
 - Data de Publicação: 19 de março de 2021;
 - Autores: **Accacio F. Santos Neto**, Leonardo M. Honório, Mathaus F. Silva, Ivo C. S. Júnior e Luís G. F. Westin;
 - Contribuição: apresentação e demonstração da metodologia SOESGOPE Robusto aplicada na 1ª versão da embarcação AERO4River;

1.5.2 Artigos de Co-autoria Publicados

- Artigo Publicado na Revista *Sensors*: “*Hull and Aerial Holonomic Propulsion System Design for Optimal Underwater Sensor Positioning in Autonomous Surface Vessels*” (REGINA et al., 2021)
 - Data de Publicação: 15 de janeiro de 2021;
 - Autores: Bruno A. Regina, Leonardo M. Honório, Antônio A. N. Pancoti, Mathaus F. Silva, Murillo F. Santos, Vitor M. L. Lopes, **Accacio F. Santos Neto** e Luís G. F. Westin;
 - Contribuição: modelagem e identificação do modelo paramétrico da 1ª versão do AERO4River utilizando o método SOESGOPE, cujos resultados foram confrontados com o modelo estimado pelo CFD;
- Artigo Publicado na IEEE *Access*: “*Project and Control Allocation of a 3 DoF Autonomous Surface Vessel With Aerial Azimuth Propulsion System*” (SILVA et al., 2020)
 - Data de Publicação: 31 de dezembro de 2020

- Autores: Mathaus F. Silva, Leonardo M. Honório, Murillo F. Santos, **Accacio F. Santos Neto**, Nuno A. Cruz, Aníbal C. C. Matos e Luís G. F. Westin
- Contribuição: Modelagem e Identificação de um modelo simplificado para o desenvolvimento do controle de movimento da 1ª versão do AERO4River;

1.5.3 Artigos Submetidos

- Artigo Submetido ao *Journal of Control, Automation and Systems*: “*Performance Comparison of Meta-Heuristics Applied to Optimal Signal Design for Parameter Identification*”
 - Data de Submissão: 7 de outubro de 2021;
 - Data da 1ª Revisão: Aguardando resposta;
 - Autores: **Accacio F. Santos Neto**, Mathaus F. Silva, Leonardo M. Honório, Edimar J. de Oliveira, Ivo C. S. Júnior;
 - Contribuição: estudo comparativo entre meta-heurísticas aplicadas no conceito SOESGOPE Robusto para estimação de um modelo da 2ª versão do **ASV** AERO4River;
- Artigo Submetido à *Robotica - Cambridge Core*: “*A Convolutional System Identification Approach Mixing Optimal Parameter Estimation and Deep Learning*”
 - Data de Submissão: 24 de setembro de 2021;
 - Data da 1ª Revisão: Aguardando resposta;
 - Autores: Marina Borges A. Souza, **Accacio F. Santos Neto**, Leonardo M. Honório, Edimar J. de Oliveira, Mathaus F. Silva e Antônio Pancoti;
 - Contribuição: aprimoramento da modelagem do AERO4River utilizando o SOESGOPE Robusto como base para o desenvolvimento da metodologia híbrida;

1.6 Organização da Tese

Este documento está organizado em 5 capítulos e 3 Apêndices. O Capítulo 1 apresentou o contexto e objetivo da tese desenvolvida, discorrendo sobre os principais desafios e necessidades correlatos à estimação de modelos robustos para ASVs. No Capítulo 2 tem-se a modelagem matemática clássica aplicada aos veículos marinhos em geral e de superfície. Neste capítulo serão apresentadas desde as notações tradicionais até a modelagem dos principais fenômenos hidrodinâmicos e o posterior desenvolvimento das equações de movimento. Em sequência, o Capítulo 3 é dedicado à metodologia SOESGOPE Robusto, apresentando e justificando cada etapa da nova abordagem. Após a apresentação da metodologia, no Capítulo 4 tem-se a sua aplicação em um estudo de caso real, enquanto o Capítulo 5 apresenta as conclusões gerais do trabalho e possíveis trabalhos futuros para a continuação dos estudos desta tese.

Adicionalmente, o Apêndice A apresenta o sistema de coordenadas aplicado a embarcações, enquanto o Apêndice B desenvolve e apresenta as equações da dinâmica geral de um corpo-rígido. Por fim, o Apêndice C é dedicado aos aspectos gerais sobre a aplicação de meta-heurísticas no conceito SOESGOPE Robusto.

2 MODELAGEM DE VEÍCULOS MARINHOS DE SUPERFÍCIE

Este capítulo descreve a modelagem clássica de veículos marinhos de superfície apresentada na literatura. De forma específica, o capítulo apresenta o desenvolvimento de modelos paramétricos a partir da mecânica newtoniana e da representação dos fenômenos característicos desta categoria de embarcação.

2.1 Introdução

Independente da plataforma robótica, seja ela terrestre, marinha ou aérea, a obtenção de um modelo matemático paramétrico envolve o estudo da estática e da dinâmica do corpo rígido. Conceitualmente, o estudo da estática concerne sobre o equilíbrio do corpo em repouso, ou em movimento com velocidade constante, enquanto o estudo da dinâmica relaciona-se com a análise do corpo em movimento acelerado e retardado (BEARD; MCLAIN, 2012).

De modo geral às plataformas marinhas, a modelagem destes veículos envolve o estudo de efeitos característicos da relação entre o corpo rígido e a água, cuja alta densidade do fluido envolvido introduz e que não podem ser desprezadas. Esta relação promove a necessidade do tratamento de conceitos da mecânica dos fluidos, como massa adicionada, amortecimento viscoso e potencial, princípio de “Arquimedes”, entre outros conceitos necessários para o adequado desenvolvimento do modelo matemático (FOSSEN *et al.*, 1994). Além disso, a modelagem destes veículos também pode incorporar a representação de ações externas como ventos, ondas e correntes, conforme o interesse e a necessidade.

Neste contexto, é válido esclarecer que o termo “plataformas marinhas” se refere a uma grande diversidade de embarcações. Dentre alguns exemplos podem-se citar (FOSSEN, 2011): navios, barcos de alta velocidade, plataformas flutuantes, veículos submarinos operados remotamente e autônomos, torpedos, entre outras estruturas. Este trabalho, em específico, será dedicado às embarcações de superfície com baixo

perfil de velocidade de operação e pequeno porte.

A abordagem apresentada é embasada na formulação do espaço de estados, sugerida pela primeira vez por Fossen (1991). A partir desta nova formulação é possível representar o comportamento cinemático e dinâmico de embarcações marinhas em geral, através da manipulação de vetores e matrizes. Esta abordagem também possibilita explorar as propriedades físicas do sistema com uma notação matemática mais compacta. Logo, simplificando a representação dos fenômenos e também beneficiando a aplicação da teoria de controle. Enfim, o que justifica o fato da abordagem proposta por Fossen ser amplamente utilizada pela comunidade acadêmica, como apresenta a revisão desenvolvida por Liu et al. (2016).

2.2 Variáveis de Estado

De modo geral, as embarcações marinhas experimentam movimentos em 6 graus de liberdade (do inglês, *Degrees of Freedom* - DoFs), os quais permitem a descrição de deslocamentos, rotações, posição e orientação da embarcação no espaço tridimensional (FOSSSEN et al., 1994).

Esta descrição envolve três estados de posição e três estados de velocidades relacionados ao movimento de translação do veículo. Da mesma forma, há três estados de posições angulares e três estados de velocidade angular associados ao movimento rotacional (FOSSSEN et al., 1994).

A notação utilizada para a representação de cada DoF baseia-se nas notações de SNAME¹, apresentadas na Tabela 1 e ilustradas na Figura 2.


Tabela 1: Notação para Veículos Marinheiros - (LEWIS, 1988).

DoF	Descrição do Movimento	Forças e Momentos	Vel. Linear e Angular	Posições e Ângulos de Euler
1	Mov. na direção do Eixo- x (<i>surge</i>)	X	u	x
2	Mov. na direção do Eixo- y (<i>sway</i>)	Y	v	y
3	Mov. na direção do Eixo- z (<i>heave</i>)	Z	w	z
4	Rotação em torno do Eixo- x (<i>roll</i>)	K	p	ϕ
5	Rotação em torno do Eixo- y (<i>pitch</i>)	M	q	θ
6	Rotação em torno do Eixo- z (<i>yaw</i>)	N	r	ψ

Na Figura 2 observa-se a representação das variáveis de estados e sua relação com os sistemas de coordenadas: inercial e corpo rígido. Também é possível notar que as

¹Sociedade de Arquitetura Naval e Engenharia Marítima, do inglês *Society of Naval Architects and Marine Engineers* (SNAME)

Figura 2: Representação dos eixos de movimento do veículo.



Fonte: Autor.

posições do veículo, $\eta_1 = [x, y, z]^T$, são definidas em relação ao *frame* inercial (\mathcal{F}^i), enquanto as velocidades lineares, $\nu_1 = [u, v, w]^T$, e velocidades angulares, $\nu_2 = [p, q, r]^T$, são definidas no *frame* do corpo do veículo (\mathcal{F}^b). Quanto aos ângulos de Euler $\eta_2 = [\phi \ \theta \ \psi]^T$, rolagem, arfagem e guinada, estes são definidos pelos *frames* \mathcal{F}^{v2} , \mathcal{F}^{v1} e \mathcal{F}^b , definidos no Apêndice A. Além do mais, acrescenta-se que: $\eta = [x, y, z, \theta, \phi, \psi]^T$ e $\nu = [u, v, w, p, q, r]^T$.

2.3 Equações Dinâmicas de um Corpo Rígido

As equações dinâmicas de um corpo rígido podem ser desenvolvidas a partir da mecânica newtoniana, conforme descrito no Apêndice B. Este sistema de equações é tradicionalmente representado de forma compacta, utilizando espaço de estados da seguinte maneira (FOSSSEN, 1991):

$$M_{RB}\dot{\nu} + C_{RB}(\nu)\nu = \tau_{RB}, \quad (2.1)$$

onde $M_{RB} \in \mathbb{R}^{6 \times 6}$ corresponde à Matriz de Inércia do Corpo Rígido² e $C_{RB}(\nu) \in \mathbb{R}^{6 \times 6}$ exprime a Matriz dos termos de Coriolis e Centrípeta do Corpo Rígido³. As matrizes M_{RB} e $C_{RB}(\nu)$ são expressas por (FOSSSEN, 2011):

² M_{RB} : constitui uma matriz única, constante, simétrica e positiva definida.

³ $C_{RB}(\nu)$: matriz variável, podendo admitir várias representações distintas.

$$M_{RB} = \begin{bmatrix} m & 0 & 0 & 0 & mz_G & -my_G \\ 0 & m & 0 & -mz_G & 0 & mx_G \\ 0 & 0 & m & my_G & -mx_G & 0 \\ 0 & -mz_G & my_G & I_{xx} & I_{xy} & I_{xz} \\ mz_G & 0 & -my_G & I_{yx} & I_{yy} & I_{yz} \\ -my_G & mx_G & 0 & I_{zx} & I_{zy} & I_{zz} \end{bmatrix} \quad (2.2)$$

$$C_{RB}(\nu) = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \\ -m(y_Gq + z_Gr) & m(y_Gp + w) & m(z_Gp - v) \\ m(x_Gq - w) & -m(z_Gr + x_Gp) & m(z_Gq + u) \\ m(x_Gr + v) & m(y_Gr - u) & -m(x_Gp + y_Gq) \\ m(y_Gq + z_Gr) & -m(x_Gq - w) & -m(x_Gr + v) \\ m(y_Gp + w) & m(z_Gr + x_Gp) & -m(y_Gr - u) \\ m(z_Gp - v) & -m(z_Gq + u) & m(x_Gp + y_Gq) \\ 0 & -I_{yz}q - I_{xy}p + I_yr & I_{yz}r + I_{xy}p - I_yq \\ I_{yz}q + I_{xz}p - I_zr & 0 & -I_{xz}r - I_{xy}q + I_xq \\ -I_{yz}q - I_{xy}p + I_yq & I_{xz}r + I_{xy}q - I_xp & 0 \end{bmatrix} \quad (2.3)$$

onde m representa a massa total do corpo rígido, (x_G, y_G, z_G) o Centro de Gravidade (CG) deslocado do eixo de simetria do corpo e $(I_{xx}, I_{xy}, I_{xz}, I_{yx}, I_{yy}, I_{yz}, I_{zx}, I_{zy}, I_{zz})$ os momentos de inércia do corpo.

Por fim, $\tau_{RB} \in \mathbb{R}^{6 \times 1}$ representa o vetor de forças e momentos resultantes das ações externas aplicadas no corpo rígido, definido por (FOSSÉN, 2011):

$$\tau_{RB} = [X, Y, Z, K, M, N]^T, \quad (2.4)$$

onde (X, Y, Z) expressam as forças aplicadas nos eixos x , y e z , respectivamente, enquanto (K, M, N) representam os momentos generalizados aplicados nos eixos x , y e z , respectivamente.

É válido acrescentar que estes agentes externos são traduzidos em forças (momentos) característicos do ambiente onde o corpo rígido é exposto. Portanto, no meio

marinho são traduzidos por: fenômenos hidrodinâmicos $\boldsymbol{\tau}_H \in \mathbb{R}^{6 \times 1}$; forças ambientais⁴ $\boldsymbol{\tau}_E \in \mathbb{R}^{6 \times 1}$; forças de propulsão⁵ $\boldsymbol{\tau} \in \mathbb{R}^{6 \times 1}$. Matematicamente, $\boldsymbol{\tau}_{RB}$ é descrito pela superposição desses fenômenos e, portanto (FOSSSEN, 2011):

$$\boldsymbol{\tau}_{RB} = \boldsymbol{\tau}_H + \boldsymbol{\tau}_E + \boldsymbol{\tau} \quad (2.5)$$

Em sequência, a Seção 2.4 descreverá com mais detalhes o vetor $\boldsymbol{\tau}_H$, apresentando conceitos e algumas das parametrizações exploradas pela literatura (LIU et al., 2016). Quanto à modelagem de $\boldsymbol{\tau}_E$ e $\boldsymbol{\tau}$, estes não serão explorados neste trabalho e, recomenda-se a leitura do livro texto (FOSSSEN, 2011) em caso de necessidades.

2.4 Forças e Momentos Hidrodinâmicos

A modelagem das forças e dos momentos hidrodinâmicos envolve o estudo dos efeitos do contato entre o corpo da embarcação e a água. Este estudo se faz necessário em virtude da alta densidade da água e sua influência na dinâmica das embarcações (TECHET, 2005).

O contato entre a água e o corpo rígido implica no tratamento dos seguintes conceitos da mecânica dos fluidos (FOSSSEN et al., 1994): massa adicionada $\boldsymbol{\tau}_A \in \mathbb{R}^{6 \times 1}$, amortecimento hidrodinâmico $\boldsymbol{\tau}_D \in \mathbb{R}^{6 \times 1}$, força de restauração de Arquimedes $\mathbf{g}(\boldsymbol{\eta}) \in \mathbb{R}^{6 \times 1}$.

Para fins de modelagem e simplificação, assume-se que estes fenômenos atuantes do corpo rígido possam ser superpostos e, expressos por (FOSSSEN, 2011):

$$\boldsymbol{\tau}_H = \boldsymbol{\tau}_A + \boldsymbol{\tau}_D - \mathbf{g}(\boldsymbol{\eta}). \quad (2.6)$$

Neste contexto, é válido ressaltar que na modelagem de embarcações marinhas de superfície, normalmente, despreza-se $\mathbf{g}(\boldsymbol{\eta})$ do modelo matemático. Assume-se que a dinâmica da embarcação no eixo- z possui pouca influência no corpo rígido, movimentando-se majoritariamente no plano- xy (LIU et al., 2016).

⁴Forças ambientais típicas: vento, ondas e correntes “oceânicas ou ribeirinhas”.

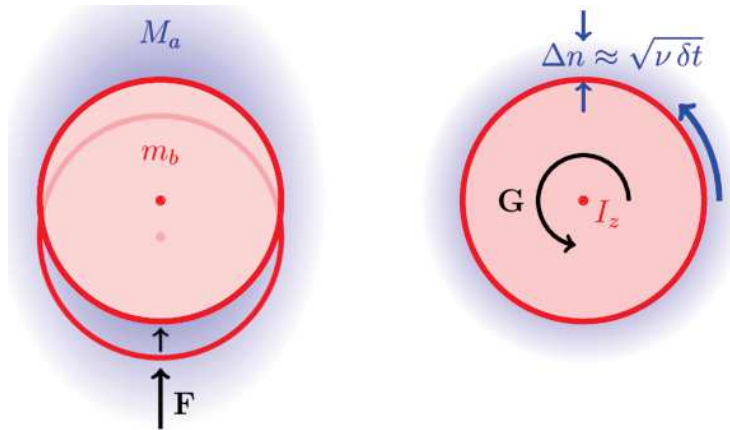
⁵Forças de propulsão: oriundas do sistema propulsores/mecanismos de controle.

2.4.1 Massa Adicionada

O fenômeno de massa adicionada, ou acrescentada, é oriundo do movimento do corpo que, inserido num fluido estacionário, provoca uma perturbação nas partículas que o envolvem. O movimento do corpo promove a aceleração destas partículas que induzem forças e momentos contrários ao movimento do corpo (TECHET, 2005). Anexando ao corpo, deste modo, uma “massa virtual” durante o movimento.

De forma didática, o conceito de “massa adicionada” pode ser compreendido analisando o movimento conceitual de uma bolha de massa m_b e momento de inércia I_z imersa num fluido. A Figura 3 ilustra o fenômeno tanto no movimento de translação, quanto de rotação. Em ambas situações são apresentadas as inércias acrescentadas aos movimentos devido à aceleração das partículas em seu entorno⁶.

Figura 3: Fenômeno de Massa Adicionada.



Fonte: Banks et al. (2016).

De forma similar ao que é feito na derivação das equações da dinâmica de um corpo rígido (Anexo B), este fenômeno é tratado através da separação dos termos dependentes das acelerações e velocidades do corpo. Matematicamente, a expressão utilizada pela literatura é a seguinte (FOSSSEN, 2011):

$$\boldsymbol{\tau}_A = -\mathbf{M}_A \dot{\boldsymbol{\nu}} - \mathbf{C}_A(\boldsymbol{\nu}) \boldsymbol{\nu} \quad (2.7)$$

onde $\boldsymbol{\tau}_A \in \mathbb{R}^{6 \times 1}$ é o vetor de forças e momentos generalizados de massa acrescentada, $\mathbf{M}_A \in \mathbb{R}^{6 \times 6}$ a Matriz de Massa Adicionada e $\mathbf{C}_A(\boldsymbol{\nu}) \in \mathbb{R}^{6 \times 6}$ a Matriz dos termos de Coriolis e Centrípeta adicionados.

⁶Na Figura 3: M_a representa a massa adicionada ao corpo no movimento de translação proporcionado pela força F ; Δn : espessa a inércia adicionada ao movimento conforme a rotação do corpo após a aplicação do momento G .

Matematicamente, \mathbf{M}_A é descrita e parametrizada pela seguinte notação de [SNAME](#) ([LEWIS, 1988](#)):

$$\mathbf{M}_A = - \begin{bmatrix} X_{\dot{u}} & X_{\dot{v}} & X_{\dot{w}} & X_{\dot{p}} & X_{\dot{q}} & X_{\dot{r}} \\ Y_{\dot{u}} & Y_{\dot{v}} & Y_{\dot{w}} & Y_{\dot{p}} & Y_{\dot{q}} & Y_{\dot{r}} \\ Z_{\dot{u}} & Z_{\dot{v}} & Z_{\dot{w}} & Z_{\dot{p}} & Z_{\dot{q}} & Z_{\dot{r}} \\ K_{\dot{u}} & K_{\dot{v}} & K_{\dot{w}} & K_{\dot{p}} & K_{\dot{q}} & K_{\dot{r}} \\ M_{\dot{u}} & M_{\dot{v}} & M_{\dot{w}} & M_{\dot{p}} & M_{\dot{q}} & M_{\dot{r}} \\ N_{\dot{u}} & N_{\dot{v}} & N_{\dot{w}} & N_{\dot{p}} & N_{\dot{q}} & N_{\dot{r}} \end{bmatrix}, \quad (2.8)$$

cujos elementos da matriz denotam a massa adicionada do corpo-rígido em determinada direção, dada uma aceleração específica. Por exemplo, o elemento $X_{\dot{u}}$ denota a massa acrescenta ao movimento ao longo do eixo- x devido à aceleração \dot{u} .

Quanto à matriz $\mathbf{C}_A(\boldsymbol{\nu})$, esta é tratada pela literatura através da seguinte parametrização sugerida por ([FOSSEN et al., 1994](#)):

$$\mathbf{C}_A(\boldsymbol{\nu}) = \begin{bmatrix} 0 & 0 & 0 & 0 & -\alpha_3 & \alpha_2 \\ 0 & 0 & 0 & \alpha_3 & 0 & -\alpha_1 \\ 0 & 0 & 0 & -\alpha_2 & \alpha_1 & 0 \\ 0 & -\alpha_3 & \alpha_2 & 0 & -\beta_3 & \beta_2 \\ \alpha_3 & 0 & -\alpha_1 & \beta_3 & 0 & -\beta_1 \\ -\alpha_2 & \alpha_1 & 0 & -\beta_2 & \beta_1 & 0 \end{bmatrix}, \quad (2.9)$$

onde os elementos da matriz são combinações lineares das massas adicionadas ponderadas pelas velocidades do corpo rígido:

$$\alpha_1 = X_{\dot{u}} \cdot u + X_{\dot{v}} \cdot v + X_{\dot{w}} \cdot w + X_{\dot{p}} \cdot p + X_{\dot{q}} \cdot q + X_{\dot{r}} \cdot r \quad (2.10)$$

$$\alpha_2 = Y_{\dot{u}} \cdot u + Y_{\dot{v}} \cdot v + Y_{\dot{w}} \cdot w + Y_{\dot{p}} \cdot p + Y_{\dot{q}} \cdot q + Y_{\dot{r}} \cdot r \quad (2.11)$$

$$\alpha_3 = Z_{\dot{u}} \cdot u + Z_{\dot{v}} \cdot v + Z_{\dot{w}} \cdot w + Z_{\dot{p}} \cdot p + Z_{\dot{q}} \cdot q + Z_{\dot{r}} \cdot r \quad (2.12)$$

$$\beta_1 = K_{\dot{u}} \cdot u + K_{\dot{v}} \cdot v + K_{\dot{w}} \cdot w + K_{\dot{p}} \cdot p + K_{\dot{q}} \cdot q + K_{\dot{r}} \cdot r \quad (2.13)$$

$$\beta_2 = M_{\dot{u}} \cdot u + M_{\dot{v}} \cdot v + M_{\dot{w}} \cdot w + M_{\dot{p}} \cdot p + M_{\dot{q}} \cdot q + M_{\dot{r}} \cdot r \quad (2.14)$$


$$\beta_3 = N_{\dot{u}} \cdot u + N_{\dot{v}} \cdot v + N_{\dot{w}} \cdot w + N_{\dot{p}} \cdot p + N_{\dot{q}} \cdot q + N_{\dot{r}} \cdot r \quad (2.15)$$

2.4.2 Amortecimento Hidrodinâmico

Quando um corpo rígido é exposto em um fluido em movimento, este corpo está sujeito a uma força exercida pelo fluido ao seu redor. De forma simplificada, esta força resultante é composta pelos fenômenos da massa adicionada, forças de restabelecimento, perturbações ambientais e, também, pelo fenômeno do amortecimento hidrodinâmico (FOSSSEN et al., 1994). Este último efeito, também conhecido por arrasto (do inglês, *drag*), é principalmente oriundo da fricção e pressão gerada pelo contato do corpo com o fluido (BRUNETTI, 2008).

Na Figura 4 tem-se uma exemplificação do fenômeno através da observação do movimento de um corpo submerso na água. Também é possível observar as linhas de fluxo produzidas pelo movimento e notar a denominada “camada limite” (do inglês, *boundary layer*), formada pelas partículas que se aderem ao corpo conforme se movimentam.

Figura 4: Corpo submerso em um fluido ideal (não-inviscido).



Fonte: USNA (2019).

Neste cenário, o amortecimento de fricção surge através do atrito ocorrido na camada limite do corpo, agindo tangencialmente ao corpo. Já o arrasto de pressão, age normal ao corpo, possuindo como fonte principal a forma do corpo rígido.

No que tange à modelagem do fenômeno de amortecimento, matematicamente é representado pela superposição do amortecimento potencial $D_p \in \mathbb{R}^{6 \times 1}$ e viscoso (fricção) $D_v(\nu) \in \mathbb{R}^{6 \times 1}$, expressos pela seguinte equação (FOSSSEN et al., 1994):

$$\tau_D = -D_p \nu_r - D_v(\nu_r) \nu_r \quad (2.16)$$

sendo que $\nu_r \in \mathbb{R}^{6 \times 1}$ representa a velocidade relativa entre o corpo rígido (ν) e fluido (ν_f), ou seja: $\nu_r = \nu - \nu_f$.

Segundo a literatura, a modelagem e definição da parametrização da Equação (2.16) são tratadas tanto pelas relações da teoria linear quanto não linear (FOSSSEN, 2011).

Quando tratada pela teoria linear, adota-se que a contribuição do amortecimento

viscoso $\mathbf{D}_v(\boldsymbol{\nu}_r)$ pode ser desprezada, ou seja, $\boldsymbol{\tau}_D = \mathbf{D}_p \boldsymbol{\nu}_r$, matematicamente expresso por (FOSSSEN et al., 1994):

$$\mathbf{D}_p = - \begin{bmatrix} X_u & X_v & X_w & X_p & X_q & X_r \\ Y_u & Y_v & Y_w & Y_p & Y_q & Y_r \\ Z_u & Z_v & Z_w & Z_p & Z_q & Z_r \\ K_u & K_v & K_w & K_p & K_q & K_r \\ M_u & M_v & M_w & M_p & M_q & M_r \\ N_u & N_v & N_w & N_p & N_q & N_r \end{bmatrix}, \quad (2.17)$$

cujos elementos da matriz são elementos constantes, relacionando a velocidade e o efeito de amortecimento para todos os DoFs. Também é importante salientar que os elementos da matriz denotam um coeficiente geral de amortecimento potencial para determinada direção, dada uma aceleração específica. Por exemplo, o elemento $Y_{\hat{r}}$ denota o coeficiente de amortecimento potencial relativo ao movimento ao longo do eixo- y dada uma velocidade relativa de guinada r .

Por outro lado, quando o amortecimento é tratado pela teoria não linear, sua representação contempla ambas as contribuições de \mathbf{D}_p e $\mathbf{D}_v(\boldsymbol{\nu}_r)$. Nesta abordagem, a parametrização é normalmente efetuada utilizando expansões truncadas da série Taylor. Duas maneiras são muito utilizadas (FOSSSEN, 2011):

1. Abordagem de Abkowitz (1964): utiliza os termos ímpares (de primeira e terceira ordem) da série de Taylor. Conforme a proposta, \mathbf{D}_p permanece definido pela Equação (2.17), enquanto $\mathbf{D}_v(\boldsymbol{\nu})$ é expresso por:

$$\mathbf{D}_v(\boldsymbol{\nu}) = - \begin{bmatrix} X_{uuu}u^2 & 0 & 0 & 0 & 0 & 0 \\ 0 & Y_{vvv}v^2 & 0 & 0 & 0 & 0 \\ 0 & 0 & Z_{www}w^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & K_{ppp}p^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & M_{qqq}q^2 & 0 \\ 0 & 0 & 0 & 0 & 0 & N_{rrr}r^2 \end{bmatrix}, \quad (2.18)$$

cujos elementos da matriz ($X_{uuu}, Y_{vvv}, Z_{www}, K_{ppp}, M_{qqq}, N_{rrr}$) são elementos constantes, ponderados pela velocidade quadrática.

2. Abordagem de Fedyaevsky e Sobolev (1964): utiliza os termos de primeira e segunda ordem da série de Taylor. Logo, por consequência, \mathbf{D}_p também permanece

definido pela Equação (2.17), enquanto $\mathbf{D}_v(\boldsymbol{\nu})$ é expresso por:

$$\mathbf{D}_v(\boldsymbol{\nu}) = - \begin{bmatrix} X_{|u|u}|u| & 0 & 0 & 0 & 0 & 0 \\ 0 & Y_{|v|v}|v| & 0 & 0 & 0 & 0 \\ 0 & 0 & Z_{|w|w}|w| & 0 & 0 & 0 \\ 0 & 0 & 0 & K_{|p|p}|p| & 0 & 0 \\ 0 & 0 & 0 & 0 & M_{|q|q}|q| & 0 \\ 0 & 0 & 0 & 0 & 0 & N_{|r|r}|r| \end{bmatrix}, \quad (2.19)$$

onde os elementos da matriz $(X_{|u|u}, Y_{|v|v}, Z_{|w|w}, K_{|p|p}, M_{|q|q}, N_{|r|r})$ são elementos constantes, neste caso, ponderados pelo módulo da velocidade do DoF relacionado.

Uma terceira opção é a abordagem desenvolvida durante a elaboração desta tese, cujos resultados são apresentados em (Neto et al., 2021). Similiar à modelagem de Fedyaevsky e Sobolev (1964), a nova abordagem utiliza os termos de primeira e segunda ordem da série de Taylor, porém considerando todos os acoplamentos possíveis entre os DoFs. Deste modo, \mathbf{D}_p permanece definido pela Equação (2.17), enquanto $\mathbf{D}_v(\boldsymbol{\nu})$ é expresso por:

$$\mathbf{D}_v(\boldsymbol{\nu}) = - \begin{bmatrix} X_{|u|u}|u| & X_{|u|v}|u| & X_{|u|w}|u| & X_{|u|p}|u| & X_{|u|q}|u| & X_{|u|r}|u| \\ Y_{|v|u}|v| & Y_{|v|v}|v| & Y_{|v|w}|v| & Y_{|v|p}|v| & Y_{|v|q}|v| & Y_{|v|r}|v| \\ Z_{|w|u}|w| & Z_{|w|v}|w| & Z_{|w|w}|w| & Z_{|w|p}|w| & Z_{|w|q}|w| & Z_{|w|r}|w| \\ K_{|p|u}|p| & K_{|p|v}|p| & K_{|p|w}|p| & K_{|p|p}|p| & K_{|p|q}|p| & K_{|p|r}|p| \\ M_{|q|u}|q| & M_{|q|v}|q| & M_{|q|w}|q| & M_{|q|p}|q| & M_{|q|q}|q| & M_{|q|r}|q| \\ N_{|r|u}|r| & N_{|r|v}|r| & N_{|r|w}|r| & N_{|r|p}|r| & N_{|r|q}|r| & N_{|r|r}|r| \end{bmatrix} \quad (2.20)$$

Acrescenta-se que todos os elementos da Equação (2.20), ponderados pelas velocidades, são constantes. Nesta modelagem é possível expressar possíveis acoplamentos e/ou assimetrias entre os DoFs da embarcação. Representações estas que são fundamentais para descrever o fenômeno de amortecimento, principalmente, nos casos de embarcações com movimentos altamente acoplados. Um exemplo de aplicação desta abordagem é descrita em (Neto et al., 2021), cujo objeto de estudo é um catamarã com 3 DoFs acoplados.

2.5 Equações de Movimento

Nas seções anteriores foram apresentadas as equações dinâmicas de uma embarcação marinha e a modelagem dos fenômenos hidrodinâmicos. Nesta seção, as equações serão combinadas em um único sistema de equações que representam o comportamento cinemático e dinâmico de uma embarcação marinha.

Utilizando as equações desenvolvidas durante o capítulo, bem como a relação cinemática expressa no Anexo B, é possível chegar ao seguinte sistema de equação:

$$M_{RB}\dot{\boldsymbol{\nu}} + C_{RB}(\boldsymbol{\nu})\boldsymbol{\nu} = \boldsymbol{\tau}_H + \boldsymbol{\tau}_E + \boldsymbol{\tau} \quad (2.21)$$

$$\dot{\boldsymbol{\eta}} = \mathbf{J}(\boldsymbol{\eta})\boldsymbol{\nu} \quad (2.22)$$

onde a primeira equação descreve a dinâmica da embarcação, enquanto a segunda expressa o comportamento cinemático. Acrescenta-se que $\mathbf{J}(\cdot)$ representa a matriz jacobiana que relaciona as velocidades expressas no corpo-rígido e *frame* inercial. Mais informações sobre esta matriz encontram-se no Anexo B.

Substituindo as forças e os momentos aplicados ao corpo-rígido (ver Seção 2.4), chega-se a:

$$[M_{RB} + M_A]\dot{\boldsymbol{\nu}} + [C_{RB}(\boldsymbol{\nu}) + C_A(\boldsymbol{\nu})]\boldsymbol{\nu} + [D_p + D_v(\boldsymbol{\nu})]\boldsymbol{\nu} = \boldsymbol{\tau} + \boldsymbol{\tau}_E - \mathbf{g}(\boldsymbol{\eta}) \quad (2.23)$$

$$\dot{\boldsymbol{\eta}} = \mathbf{J}(\boldsymbol{\eta})\boldsymbol{\nu} \quad (2.24)$$

Por fim, definindo que:

$$\mathbf{M} = M_{RB} + M_A \quad (2.25)$$

$$\mathbf{C}(\boldsymbol{\nu}) = C_{RB}(\boldsymbol{\nu}) + C_A(\boldsymbol{\nu}) \quad (2.26)$$

$$\mathbf{D}(\boldsymbol{\nu}) = D_p + D_v(\boldsymbol{\nu}), \quad (2.27)$$

chega-se a expressão amplamente utilizada na literatura de embarcações marinhas (FOSSÉN, 2011):

$$\begin{aligned}
M\dot{\nu} + C(\nu)\nu + D(\nu)\nu + g(\eta) &= \tau + \tau_E \\
\dot{\eta} &= J(\eta)\nu
\end{aligned}
\tag{2.28}$$

É válido informar que a Equação (2.28) aplica-se para a descrição de embarcações marinhas em geral, como: navios, barcos de alta velocidade, plataformas flutuantes, veículos submarinos, entre outras estruturas.

2.6 Embarcações de Superfície

Nas seções anteriores todas as definições acerca dos elementos da Equação (2.28) foram definidas considerando 6 DoFs. No entanto, sabe-se que a operação das embarcações de superfície exige, em grande parte das aplicações, a descrição de apenas 3 DoFs. Fato que induz a algumas simplificações, como é observado na literatura (LIU et al., 2016).

Considerando que uma embarcação movimenta-se majoritariamente no plano- xy e possui pequenos movimentos de rolagem e arfagem, é possível simplificar o modelo aos seguintes DoFs:

- Movimento de Translação do Eixo - X (*Surge*);
- Movimento de Translação do Eixo - Y (*Sway*);
- Movimento de Rotação em torno do Eixo - Z (*Yaw*);

Assim, matematicamente, a equação de movimento se resume em:

$$M\dot{\nu} + C(\nu)\nu + D(\nu)\nu = \tau + \tau_E \tag{2.29}$$

$$\dot{\eta} = J(\psi)\nu \tag{2.30}$$

onde os vetores de estados serão reduzidos a $\eta = [x \ y \ \psi]^T$ e $\nu = [u \ v \ r]^T$, enquanto o vetor de forças e momento do sistema de propulsão a $\tau = [F_X \ F_Y \ \tau_N]^T$ e o vetor de distúrbios a $\tau_E = [F_X^E \ F_Y^E \ \tau_N^E]^T$.

Ademais, as matrizes das equações de movimento serão simplificadas a:

- Matriz de Rotação:

$$\mathbf{J}(\psi) = \begin{bmatrix} \cos(\psi) & -\sin(\psi) & 0 \\ \sin(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (2.31)$$

- Matriz de Inércia:

$$\mathbf{M} = \begin{bmatrix} m - X_{\dot{u}} & -X_{\dot{v}} & -my_G - X_{\dot{r}} \\ -Y_{\dot{u}} & m - Y_{\dot{v}} & mx_G - Y_{\dot{r}} \\ -my_G - N_{\dot{u}} & mx_G - N_{\dot{v}} & I_z - N_{\dot{r}} \end{bmatrix} \quad (2.32)$$

- Matriz dos termos de Coriolis e Centrípeta do corpo rígido:

$$\mathbf{C}(\boldsymbol{\nu}) = \begin{bmatrix} 0 & 0 & -m(x_{Gr} + v) + \alpha_2 \\ 0 & 0 & -m(y_G - u) - \alpha_1 \\ m(x_{Gr} + v) - \alpha_2 & m(y_G - u) + \alpha_1 & 0 \end{bmatrix} \quad (2.33)$$

onde $\alpha_1 = (X_{\dot{u}}u + X_{\dot{v}}v + X_{\dot{r}}r)$ e $\alpha_2 = (Y_{\dot{u}}u + Y_{\dot{v}}v + Y_{\dot{r}}r)$.

- Matriz de Amortecimento Hidrodinâmico:

Quando à matriz de amortecimento, vale a ressalva de que a representação dependerá da abordagem, seja ela linear ou não linear. Utilizando o modelo linear:

$$\mathbf{D}(\boldsymbol{\nu}) = - \begin{bmatrix} X_u & X_v & X_r \\ Y_u & Y_v & Y_r \\ N_u & N_v & N_r \end{bmatrix} \quad (2.34)$$

Utilizando o modelo não linear têm-se as opções do método de ([ABKOWITZ, 1964](#)) na Equação (2.35), ([FEDYAEVSKY; SOBOLEV, 1964](#)) na Equação (2.36) e ([Neto et al., 2021](#)) na Equação (2.37).

$$\mathbf{D}(\boldsymbol{\nu}) = - \begin{bmatrix} X_u + X_{uuu}u^2 & X_v & X_r \\ Y_u & Y_v + Y_{vvv}v^2 & Y_r \\ N_u & N_v & N_r + N_{rrr}r^2 \end{bmatrix} \quad (2.35)$$

$$\mathbf{D}(\boldsymbol{\nu}) = - \begin{bmatrix} X_u + X_{|u|u}|u| & X_v & X_r \\ Y_u & Y_v + Y_{|v|v}|v| & Y_r \\ N_u & N_v & N_r + N_{|r|r}|r| \end{bmatrix} \quad (2.36)$$

$$\mathbf{D}(\boldsymbol{\nu}) = - \begin{bmatrix} X_u + X_{|u|u}|u| & X_v + X_{|u|v}|u| & X_r + X_{|u|r}|u| \\ Y_u + Y_{|v|u}|v| & Y_v + Y_{|v|v}|v| & Y_r + Y_{|v|r}|v| \\ N_u + N_{|r|u}|r| & N_v + N_{|r|v}|r| & N_r + N_{|r|r}|r| \end{bmatrix} \quad (2.37)$$

2.7 Definição do Problema de Estimação Paramétrica

Na Seção (2.6) foi apresentado o modelo tradicionalmente utilizado para a representação de embarcações de superfície. Conforme disposto, o modelo pode possuir diferentes parametrizações, as quais devem ser escolhidas conforme a aplicação e necessidade. De acordo com Fossen (2011), em aplicações dedicadas aos projetos de sistemas de controles normalmente utilizam-se modelos de ordem reduzida ou simplificados, enquanto aplicações destinadas à simulação são preferidos modelos com alta fidelidade. Além do mais, Fossen (2011) também cita aplicações relacionadas à modelagem de dinâmicas adicionais⁷ da embarcação, as quais são identificadas pelo denominado *modelo-observador* com uma versão mais simplificada do modelo de simulação. Exemplos de modelos direcionados ao controle, simulação e modelo-observador podem ser visualizados nos trabalhos de (SILVA et al., 2020), (Neto et al., 2021) e (FERNANDES et al., 2015), respectivamente.

Independente da parametrização escolhida, o problema de estimação ou identificação paramétrica resume-se à determinação das variáveis do sistema. Admitindo que as variáveis inerciais e geométricas são obtidas com razoável precisão, logo o problema consiste na determinação das derivadas hidrodinâmicas, ou seja, dos elementos das matrizes \mathbf{M}_A , $\mathbf{C}_A(\boldsymbol{\nu})$, \mathbf{D}_p , $\mathbf{D}_v(\boldsymbol{\nu})$. Nesta direção, desde que objetivo do trabalho seja a identificação de modelos robustos e precisos, conseqüentemente a problemática envolve a identificação de uma modelo de simulação com grande riqueza de detalhes.

Na Tabela 2 tem-se uma análise da dimensão das diferentes parametrizações apresentadas, indicando o número de parâmetros referentes às matrizes e também à dimensão do problema em \mathbb{R}^n .

⁷Exemplos de dinâmicas adicionais são: modelagem de ruídos e distúrbios, identificação de falhas, etc.

Tabela 2: Análise da dimensão dos problemas de identificação conforme $D(\nu)$.

Modelo	Descrição	$M_A + C_A$	D_p	$D_v(\nu)$	\mathbb{R}^n
1	Amortecimento Linear (ordem reduzida)	9	9	-	18
2	Amortecimento não-Linear (2.35)	9	9	3	21
3	Amortecimento não-Linear (2.36)	9	9	3	21
4	Amortecimento não-Linear (2.37)	9	9	9	27

Analisando a Tabela 2 é possível notar a complexidade envolvida ao problema de estimação paramétrica. Conforme a escolha da parametrização do *arrasto* será necessário projetar um sinal que estimule e permita observar de 18 até 27 características distintas, representadas pelas matrizes de amortecimento e do fenômeno de massa adicionada. Ou seja, é possível dizer que o problema de estimação paramétrica envolve dois espaços de soluções distintos: ① espaço de solução interno relativo à estimação paramétrica e ② um espaço de solução externo dedicado ao projeto do sinal de excitação \mathbb{R}^n . Este problema será abordado no próximo capítulo, apresentando as dificuldades envolvidas, como também a nova abordagem proposta.

3 MÉTODO DE IDENTIFICAÇÃO SOESGOPE ROBUSTO

Neste capítulo será descrito o método proposto para o projeto de sinais de identificação e estimação paramétrica robusta. Para uma melhor compreensão do leitor, o capítulo segue organizado da seguinte maneira: Seção 3.1 descreve as características, os desafios e a formulação matemática do problema envolvido; Seção 3.2 discorre sobre a abordagem inicial para o desenvolvimento do método proposto; Seção 3.3 apresenta a metodologia desenvolvida, suas etapas e algoritmo.

3.1 Introdução ao Problema de Identificação de Sistemas

Sabe-se que a escolha da estrutura do modelo, o projeto de sinais de entrada, a estimação paramétrica e a validação são elementos fundamentais para a identificação de sistemas. Dentre estes, é consenso que o projeto dos sinais possui um papel crucial para o sucesso da identificação (ISERMANN; MÜNCHHOF, 2010).

A partir de sinais de entrada bem projetados é possível estimular e ressaltar as principais dinâmicas do sistema. Permitindo que tais comportamentos sejam posteriormente estimados e representados por modelos paramétricos (NOWAK, 2002). Tratando-se, portanto, de um elemento crucial para a obtenção de modelos precisos, sintonia de controladores baseados em modelos (ÅSTRÖM; HÄGGLUND, 2006), projeto de observadores de estado (FERNANDES et al., 2015), desenvolvimento de simuladores (PARAVISI et al., 2019), entre outras aplicações (ÅSTRÖM; WITTENMARK, 2013).

No entanto, projetar sinais de identificação não é uma tarefa trivial. Conforme apresentado em Honório et al. (2018), esta tarefa é definida como um problema de otimização não linear que requer abordagens competentes para lidar com o projeto do sinal e a estimativa paramétrica a priori, simultaneamente.

O tratamento simultâneo destes problemas torna a tarefa desafiadora, exigindo do

processo de otimização do sinal a análise da excitação do modelo do sistema a priori. Demandando, portanto, a estimação paramétrica do sistema excitado, que também constitui um problema de otimização interno. Deste modo, a metodologia deve ser capaz de lidar com o problema que engloba tanto o espaço externo de solução da codificação do sinal, quanto o espaço interno de solução do modelo paramétrico.

De qualquer forma, independentemente da metodologia adotada, é consenso que a abordagem deve ser capaz de gerar sinais que garantam estímulos assertivos às principais dinâmicas do sistema (GIANNAKIS; SERPEDIN, 2001). Os sinais devem ter uma persistência de excitação adequada ao sistema, estimulando uma ampla gama de amplitudes e frequências. Além disso, também é essencial que os sinais sejam viáveis para o sistema de atuação e adequados às condições de segurança para o desenvolvimento do experimento de identificação (ISERMANN; MÜNCHHOF, 2010).

Outro aspecto desafiador é assegurar que as metodologias sejam robustas às incertezas decorrentes das estimativas iniciais e possíveis variações de operação do sistema (NOURI; VALADI, 2017). Metodologias que não contemplam tais situações estão sujeitas a produção de sinais com baixa qualidade de excitação e, conseqüentemente, estimar modelos com capacidades de generalização limitadas.

Todos os requisitos mencionados não são fáceis de se atingir, principalmente no âmbito de sistemas dinâmicos não lineares que requerem sinais com alta persistência e, portanto, uma codificação com grande detalhamento. Nesses casos, pode haver um grande aumento na complexidade computacional e no espaço de solução dos problemas, tornando a resolução computacionalmente demorada (WANG; SOARES; ZOU, 2020).

Em síntese pode-se afirmar que o problema do projeto de sinais de identificação e estimação paramétrica encontra as seguintes dificuldades:

1. Desenvolvimento de uma metodologia para lidar com a otimização do sinal e estimação paramétrica simultaneamente;
2. Obtenção de persistência de excitação adequada ao sistema;
3. Robustez às incertezas paramétricas iniciais e variações de operação do sistema;
4. Complexo espaço de solução (“Codificação do sinal” + “Modelo paramétrico”);

3.1.1 Formulação Matemática do Problema

Considere que o modelo de um sistema de dinâmica não linear $\mathcal{R}(\Gamma)$ seja satisfatoriamente aproximado por um modelo não linear paramétrico $\mathcal{M}(\Gamma)$, constituído de n estados, p entradas, m saídas e r parâmetros, matematicamente representado por:

$$\mathcal{M}(\Gamma) = \begin{cases} \dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}(t), \mathbf{u}(t), \Gamma) \\ \mathbf{y}(t) = \mathbf{h}(\mathbf{x}(t), \mathbf{u}(t), \Gamma) \end{cases} \quad (3.1)$$

onde \mathbf{f} e \mathbf{h} são as funções não lineares do sistema, dependentes do vetor de estados $\mathbf{x} \in \mathbb{R}^n$, do vetor de entradas $\mathbf{u} \in \mathbb{R}^p$, do vetor de saídas $\mathbf{y} \in \mathbb{R}^m$ e do conjunto dos parâmetros do modelo $\Gamma \in \mathbb{R}^r$. Adicionalmente, considere que o sistema $\mathcal{R}(\Gamma)$ possui algumas restrições que necessitam ser respeitadas durante sua operação, representadas por:

$$\underline{\mathbf{x}} \leq \mathbf{x}(t) \leq \bar{\mathbf{x}} \quad (3.2)$$

$$\underline{\mathbf{y}} \leq \mathbf{y}(t) \leq \bar{\mathbf{y}} \quad (3.3)$$

$$\underline{\mathbf{u}} \leq \mathbf{u}(t) \leq \bar{\mathbf{u}} \quad (3.4)$$

sendo que $\underline{\mathbf{x}}$ e $\bar{\mathbf{x}} \in \mathbb{R}^n$ representam, respectivamente, os limites de operação inferior e superior do vetor estados, $\underline{\mathbf{y}}$ e $\bar{\mathbf{y}} \in \mathbb{R}^m$ expressam os limites de operação inferior e superior do vetor saídas da embarcação, respectivamente, enquanto $\underline{\mathbf{u}}$ e $\bar{\mathbf{u}} \in \mathbb{R}^p$ representam os limites de operação inferior e superior do sinal de entrada, respectivamente.

Admita também que o sistema $\mathcal{R}(\Gamma)$ esteja sujeito a incertezas paramétricas $\delta\Gamma$ de origem diversas e que a representação adequada do sistema é dada por $\mathcal{R}(\Gamma + \delta\Gamma)$. Além disso, considere que Γ^* seja o conjunto de parâmetros ótimo do sistema, porém desconhecido, e que $\mathcal{M}(\Gamma^*)$ é a melhor representação de $\mathcal{R}(\Gamma + \delta\Gamma)$ para qualquer sinal $\mathbf{u} \in \mathbf{U}$, onde \mathbf{U} é o domínio de todos os sinais de entrada possíveis.

Neste contexto, o problema de identificação robusta de sistemas pode ser definido como: “encontrar o melhor sinal de excitação $\mathbf{u}^\oplus \in \mathbf{U}$ que, quando aplicado no sistema real $\mathcal{R}(\Gamma + \delta\Gamma)$, permita a estimativa paramétrica a posteriori $\hat{\Gamma}^+$ que torne verdadeira a seguinte relação: $\mathcal{M}(\hat{\Gamma}^+, \mathbf{u}) \approx \mathcal{R}(\Gamma + \delta\Gamma, \mathbf{u})$ ”. Portanto, a solução do problema requer o projeto de \mathbf{u}^\oplus que matematicamente pode ser expresso por um problema de

otimização definido por:

$$\mathcal{S}(\mathcal{M}(\hat{\Gamma}^-), \mathcal{R}(\Gamma)) = \mathbf{u}^\oplus \quad (3.5)$$

onde $\hat{\Gamma}^-$ é a estimação paramétrica inicial e \mathcal{S} é um arbitrário algoritmo de otimização não linear que busca pelo melhor $\mathbf{u}^\oplus \in \mathbf{U}$. Finalmente, a estimação do conjunto de parâmetros robustos estabelecida por:

$$\mathcal{P}(\mathcal{M}(\hat{\Gamma}^-, \mathbf{u}^\oplus), \mathcal{R}(\Gamma, \mathbf{u}^\oplus)) = \hat{\Gamma}^+ \quad (3.6)$$

onde \mathcal{P} é um procedimento de otimização arbitrário dedicado à estimação paramétrica $\hat{\Gamma}^+$ que melhor represente: $\mathcal{M}(\hat{\Gamma}^+, \mathbf{u}^\oplus) \approx \mathcal{R}(\Gamma + \delta\Gamma, \mathbf{u}^\oplus)$. Além disso, nesta notação é possível substituir os estados $[\mathbf{x}, \mathbf{y}]$ por $\mathcal{M}(\Gamma, \mathbf{u})$ ou $\mathcal{R}(\Gamma + \delta\Gamma, \mathbf{u})$ sem perda de generalização.

3.2 Abordagem a priori: SOESGOPE

Conforme a pesquisa apresentada no Capítulo 1 é possível encontrar diversas metodologias dedicadas à resolução do problema proposto na Seção 3.1. Encontram-se abordagens que combinam desde a otimização da inversa da FIM com algoritmos determinísticos (SCHRANGL; TKACHENKO; RE, 2020), técnicas baseadas na teoria de controle ótimo (LICITRA et al., 2018) até abordagens estruturadas por meta-heurísticas (NOURI; VALADI; ASGHARIAN, 2018).

Dentre as abordagens estudadas, o método proposto por Honório et al. (2018), denominado SOESGOPE, é aderente à presente proposta e deve ser melhor investigado. Analisando-o cuidadosamente é possível perceber os avanços na (i) solução de sinais com alta codificação, (ii) inclusão de restrições na otimização, (iii) avaliação da persistência dos sinais por métricas próprias e adequadas para a estimação paramétrica de modelos não lineares nos parâmetros. No entanto, este método não apresenta meios para minimizar os efeitos oriundos das incertezas paramétricas iniciais e da operação do sistema, conforme relata Neto et al. (2021).

Esta mesma deficiência apresentada pelo SOESGOPE também é observada nos demais métodos estudados, adicionando, neste caso, dificuldades no âmbito do projeto de sinais com alta característica de codificação, restrições¹, bem como na escolha de

¹Restrições de cunho operacional e de segurança.

métricas de avaliação adequadas ao algoritmo de otimização.

Estes aspectos positivos do método **SOESGOPE** são explorados e, uma nova abordagem denominada “**SOESGOPE** Robusto” é desenvolvida para obter maior robustez e confiabilidade aos modelos estimados no âmbito do problema proposto na Seção 3.1.

Para uma melhor compreensão do leitor, em sequência a Seção 3.2.1 descreve o método **SOESGOPE**, suas características e *framework*, enquanto a Seção 3.2.2 apresenta reflexões que fomentam a base para o desenvolvimento do método **SOESGOPE** robusto.

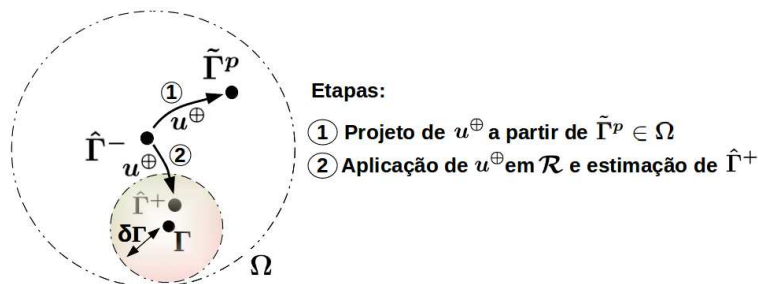
3.2.1 Método SOESGOPE

De forma sucinta, o método **SOESGOPE** propõe a estimação de modelos paramétricos utilizando apenas um único sinal de identificação. Conceitualmente, a abordagem foi desenvolvida a partir da comprovação da seguinte hipótese:

“se possuímos uma estimativa paramétrica a priori $\hat{\Gamma}^-$ aproximada, porém válida, de Γ , e conseguirmos projetar um sinal de entrada sub-ótimo u^\oplus para ser aplicado em $\mathcal{M}(\hat{\Gamma}^-)$ e re-estimar $\hat{\Gamma}^-$, então este mesmo sinal u^\oplus também será adequado para excitar $\mathcal{R}(\Gamma)$ ” (HONÓRIO et al., 2018).

Como consequências desta comprovação é possível compreender que o espaço de busca de excitação de u^\oplus é reduzido a um subespaço no entorno de $\mathcal{M}(\hat{\Gamma}^-)$ ou a uma região de incerteza paramétrica Ω no entorno de $\hat{\Gamma}^-$. Ou seja, o *design* de u^\oplus para determinado sistema $\mathcal{R}(\Gamma)$ pode ser desenvolvido simulando sua capacidade de excitar um modelo “perturbado” $\mathcal{M}(\tilde{\Gamma}^p)$, cujos parâmetros $\tilde{\Gamma}^p$ encontram-se na região de incerteza de $\hat{\Gamma}^-$. Consequentemente, este mesmo sinal também será capaz de excitar $\mathcal{R}(\Gamma)$ e permitir a posterior estimação de $\hat{\Gamma}^+$. Estas conclusões são sintetizadas na Figura 5 que apresenta as etapas do conceito **SOESGOPE**: projeto e aplicação/estimação.

Figura 5: Conceito SOESGOPE.



Fonte: Autor.

Fundamentado nestas conclusões, o método SOESGOPE foi matematicamente estruturado em duas etapas (HONÓRIO et al., 2018):

$$\mathcal{S}(\mathcal{M}(\hat{\Gamma}^-), \mathcal{M}(\tilde{\Gamma}^p)) = \mathbf{u}^\oplus \quad (3.7)$$

$$\mathcal{P}(\mathcal{M}(\tilde{\Gamma}^-, \mathbf{u}^\oplus), \mathcal{R}(\Gamma, \mathbf{u}^\oplus)) = \hat{\Gamma}^+ \quad (3.8)$$

onde a primeira etapa ①, representada pela Equação (3.7), corresponde ao projeto de \mathbf{u}^\oplus baseado nas informações de $\mathcal{M}(\hat{\Gamma}^-)$ e $\mathcal{M}(\tilde{\Gamma}^p)$ e a etapa posterior ②, representada pela Equação (3.8), é dedicada à estimação paramétrica após a aplicação do sinal projetado em $\mathcal{R}(\Gamma, \mathbf{u}^\oplus)$. Quanto aos algoritmos \mathcal{S} e \mathcal{P} é válido ressaltar que:

1. O algoritmo \mathcal{S} representa uma metodologia de otimização própria de Honório et al. (2018). Nesta topologia são conjugados o MPI e a meta-heurística do PSO. O PSO é o otimizador principal, responsável pelo projeto do sinal do tipo APRBS², enquanto o MPI é o otimizador secundário, dedicado a um sub-problema do projeto do sinal. Este sub-problema está relacionado à necessidade da análise da recuperação paramétrica, aspecto fundamental para a avaliação da qualidade dos sinais gerados pelo PSO. Mais informações sobre a avaliação dos sinais são apresentadas na Seção 3.3.3.
2. O algoritmo \mathcal{P} consiste numa variação do MPI, proposta por Byrd, Gilbert e Nocedal (2000), dedicada à estimação de $\mathcal{M}(\hat{\Gamma}^+)$. Este é mesmo algoritmo empregado no sub-problema do projeto do sinal com finalidade de calcular a recuperabilidade paramétrica.

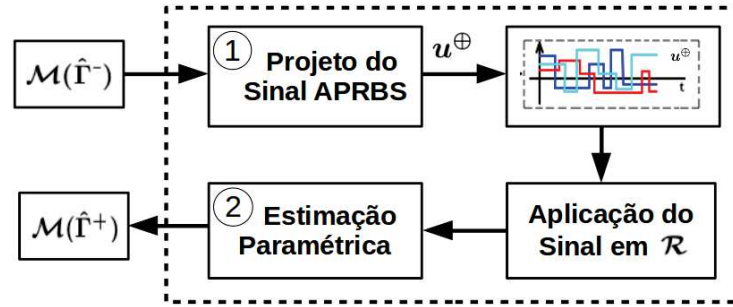
Em sequência, a Figura 6 apresenta esquematicamente a metodologia para uma melhor compreensão do leitor.

3.2.2 Reflexões sobre o método

Analisando o método SOESGOPE fica evidente que a abordagem traz contribuições para a identificação de sistemas, principalmente em cenários de baixa incerteza sobre $\mathcal{M}(\Gamma^-)$. Nota-se que a abordagem proporciona:

²A otimização do sinal APRBS consiste na determinação dos parâmetros do sinal, cujos indivíduos da meta-heurística são candidatos a solução destes parâmetros.

Figura 6: Fluxograma do método SOESGOPE.



Fonte: Autor.

1. Flexibilidade na definição da codificação de \mathbf{u}^\oplus e inserção de restrições;
2. Projeto de sinais com excitação assertiva e adequadas às dinâmicas de interesse;
3. Estimação paramétrica de sistemas não-lineares nos parâmetros.

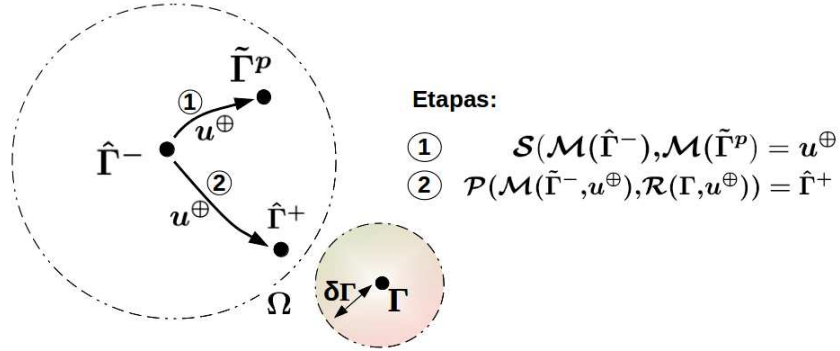
No contexto relacionado a altas incertezas, no entanto, a metodologia **SOESGOPE** não é mais recomendável. Nestas condições a estimativa inicial $\mathcal{M}(\Gamma^-)$ não fornece informações suficientes para o projeto de \mathbf{u}^\oplus que, conseqüentemente, implicará na estimativa de modelos $\mathcal{M}(\hat{\Gamma}^+)$ deficientes e sem robustez (SOUZA et al., 2020). Situações como esta podem ser encontradas em sistemas com:

- Alto número de parâmetros e poucas estimações confiáveis;
- Características não lineares acentuadas e de difícil modelagem;
- Assimetrias acentuadas e acoplamentos entre os DoFs;
- Exposição a distúrbios ambientais (ex.: ventos, ondas, correnteza).

Teoricamente, tais situações podem ser representadas através da Figura 7. Nestas condições, a estimativa inicial $\hat{\Gamma}^-$ é uma representação deficiente de $\mathcal{R}(\Gamma)$ e, deste modo, é possível dizer que: $\Gamma \notin \Omega$ e que o projeto de \mathbf{u}^\oplus não pode garantir que $\mathcal{M}(\hat{\Gamma}^+) \approx \mathcal{R}(\Gamma)$.

Partindo do pressuposto que é de desejo utilizar o método **SOESGOPE** como base para uma nova abordagem, é evidente a necessidade de introduzir estratégias para torná-la mais robusta às incertezas iniciais. Estas estratégias são apresentadas em sequência, as quais definem a nova abordagem denominada por “**SOESGOPE Robusto**”, ou seja, “**SOESGOPE** robusto às incertezas”.

Figura 7: Situação desfavorável ao método SOESGOPE.



Fonte: Autor.

3.3 Abordagem a posteriori: SOESGOPE Robusto (rSOESGOPE)

O método SOESGOPE Robusto (do inglês, *Robust SOESGOPE* - *Robust SOESGOPE* (rSOESGOPE)) propõe a estimação de modelos paramétricos utilizando múltiplos sinais de identificação. A abordagem foi desenvolvida a partir da seguinte hipótese sobre o método SOESGOPE:

“se para pequenos níveis de incerteza é possível projetar um sinal u^\oplus que excite adequadamente a região no entorno de $\mathcal{M}(\hat{\Gamma}^-)$, então a partir de múltiplos sinais $[u_1^\oplus, u_2^\oplus, \dots, u_n^\oplus]$ projetados por um conjunto de parâmetros $[\tilde{\Gamma}_1^p, \tilde{\Gamma}_2^p, \dots, \tilde{\Gamma}_n^p]$, bem distribuídos no entorno de $\hat{\Gamma}^-$, também é possível excitar adequadamente uma região maior”.

Como pode ser apreendido, a hipótese levantada estimula a expansão do conceito SOESGOPE e também apresenta uma nova perspectiva para a identificação de sistemas sujeitos a incertezas. Neste caso é sugerida a utilização de múltiplos sinais para a composição de experimentos mais ricos dinamicamente. Estratégia que corretamente utilizada permitirá expandir a região de excitação no entorno de $\hat{\Gamma}^-$ e, proporcionar a estimação de modelos mais robustos às variações de $\mathcal{R}(\Gamma + \delta\Gamma)$.

3.3.1 Conceito rSOESGOPE

Sintetizando as reflexões, o conceito rSOESGOPE é matematicamente descrito pela seguinte hipótese:

“se o conjunto $\hat{\Gamma}^-$ é uma aproximação grosseira de Γ , $\mathbf{P}^\oplus = [\tilde{\Gamma}_1^p, \tilde{\Gamma}_2^p, \dots, \tilde{\Gamma}_n^p]$ um conjunto de parâmetros espacialmente bem distribuídos em torno da estimativa inicial $\hat{\Gamma}^-$ e $\mathbf{U}^\oplus = [\mathbf{u}_1^\oplus, \mathbf{u}_2^\oplus, \dots, \mathbf{u}_n^\oplus]$ o conjunto de sinais capaz de excitar cada modelo de $\mathcal{M}(\mathbf{P}^\oplus)$ e re-estimar $\mathbf{P}^\oplus = [\tilde{\Gamma}_1^p, \tilde{\Gamma}_2^p, \dots, \tilde{\Gamma}_n^p]$, então o mesmo \mathbf{U}^\oplus também será capaz de excitar $\mathcal{R}(\Gamma + \delta\Gamma, \mathbf{U}^\oplus)$ e conseqüentemente obter $\hat{\Gamma}^+$ que respeite $\mathcal{M}(\hat{\Gamma}^+, \mathbf{U}^\oplus) \approx \mathcal{R}(\Gamma + \delta\Gamma, \mathbf{U}^\oplus)$ ”.

O conceito, portanto, propõe uma metodologia com três estágios bem definidos: ① geração do conjunto de parâmetros de referência $\mathbf{P}^\oplus = [\tilde{\Gamma}_1^p, \tilde{\Gamma}_2^p, \dots, \tilde{\Gamma}_n^p]$ no entorno de $\hat{\Gamma}^-$, ② projeto de cada sinal $\mathbf{u}_i^\oplus \in \mathbf{U}^\oplus$ para excitar seu correspondente $\tilde{\Gamma}_i^p \in \mathbf{P}^\oplus$, ③ aplicação de \mathbf{U}^\oplus em $\mathcal{R}(\Gamma)$ e posterior estimação paramétrica de $\hat{\Gamma}^+$.

Matematicamente os estágios são definidos por:

$$\mathbf{P}^\oplus = \mathcal{B}(\hat{\Gamma}^-) \quad (3.9)$$


$$\mathbf{U}^\oplus = \mathcal{S}(\mathcal{M}(\hat{\Gamma}^-), \mathcal{M}(\mathbf{P}^\oplus)) \quad (3.10)$$

$$\hat{\Gamma}^+ = \mathcal{P}(\mathcal{M}(\hat{\Gamma}^-, \mathbf{U}^\oplus), \mathcal{R}(\Gamma + \delta\Gamma, \mathbf{U}^\oplus)) \quad (3.11)$$

sendo que \mathcal{B} representa a função geradora dos parâmetros de referência, \mathcal{S} é a metodologia de otimização de \mathbf{U}^\oplus e \mathcal{P} é o algoritmo responsável pela estimação paramétrica.

Antes da descrição de \mathcal{B} , \mathcal{S} e \mathcal{P} é válido apresentar um esquemático do conceito rSOESGOPE. Na Figura 8 tem-se um possível cenário de aplicação no sistema $\mathcal{R}(\Gamma + \delta\Gamma)$ com pequena variação paramétrica $\delta\Gamma$. Em princípio $\hat{\Gamma}^-$ demonstra estar distante de $\mathcal{R}(\Gamma + \delta\Gamma)$ e que dificilmente o projeto a partir de seu entorno permitiria uma excitação adequada. No entanto, nota-se que a partir da região de confiança Ω , ou excitação, produzida por \mathbf{P}^\oplus , isso sim é possível, sendo que $\mathcal{R}(\Gamma + \delta\Gamma) \in \Omega$. Neste cenário \mathbf{U}^\oplus teoricamente permite que $\mathcal{M}(\hat{\Gamma}^+) \approx \mathcal{R}(\Gamma + \delta\Gamma)$.

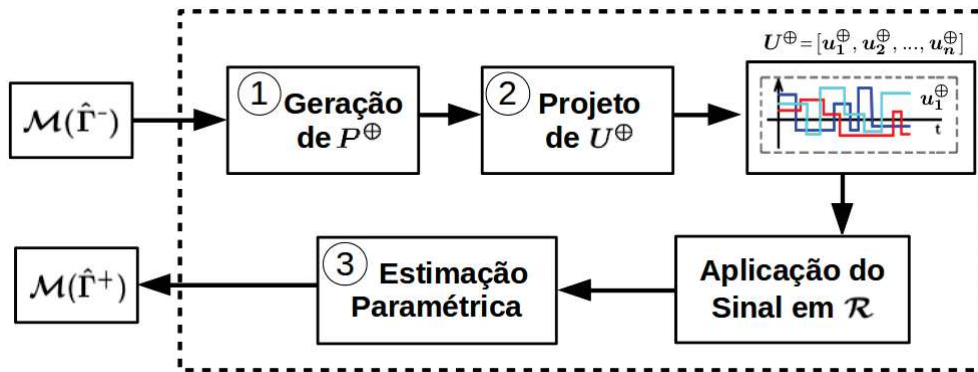
Figura 8: Conceito rSOESGOPE.



Fonte: Autor.

Em sequência, a Figura 9 apresenta o fluxograma da metodologia para uma melhor compreensão do leitor.

Figura 9: Fluxograma do método rSOESGOPE.



Fonte: Autor.

3.3.2 Geração dos Parâmetros de Referência - P^\oplus

A função \mathcal{B} tem a responsabilidade de gerar o conjunto de parâmetros P^\oplus bem distribuídos em torno de $\hat{\Gamma}^-$. Conforme o conceito rSOESGOPE, \mathcal{B} possui o objetivo de minimizar as incertezas da estimação inicial e permitir a construção de U^\oplus com persistência de excitação o suficiente para excitar $\mathcal{R}(\Gamma + \delta\Gamma)$.

Dentre as estratégias de desenvolvimento, uma opção é a definição de um espaço $\Omega \in \mathbb{R}^r$ a partir da combinação das condições extremas de todos os elementos de $\tilde{\Gamma}^p \in \mathbb{R}^r$ em um intervalo de incerteza $[(1-\sigma)\tilde{\Gamma}^p, (1+\sigma)\tilde{\Gamma}^p]$. Logo, gerando 2^r amostras

de $\tilde{\Gamma}^{\mathcal{P}}$.

No âmbito das parametrizações com alto número de parâmetros (r), a estratégia anterior pode gerar um número excessivo de combinações, tornando-a inviável em alguns cenários. Em situações como esta a geração randômica de $\tilde{\Gamma}^{\mathcal{P}} \in \Omega$ é uma alternativa. Neste caso, atenta-se que a definição do número de amostras de $\tilde{\Gamma}^{\mathcal{P}}$ seja o suficiente para minimizar as incertezas iniciais e proporcionar diversidade dinâmica. Nesta estratégia cada amostra de \mathbf{P}^{\oplus} é gerada por:

$$\tilde{\Gamma}_i^{\mathcal{P}} = \left(1 + \frac{\sigma}{100} \mathbf{r}_i\right) \hat{\Gamma}_i^- \quad (3.12)$$

sendo que i é o índice da i -ésima amostra $\tilde{\Gamma}_i^{\mathcal{P}} \in \mathbf{P}^{\oplus} = [\tilde{\Gamma}_1^{\mathcal{P}}, \tilde{\Gamma}_2^{\mathcal{P}}, \dots, \tilde{\Gamma}_n^{\mathcal{P}}]$, $\sigma \in \mathbb{R}$ representa o nível de incerteza paramétrica entre $[0,100]$ e $\mathbf{r}_i \in \mathbb{R}^r$ é o vetor de números randômicos com distribuição entre $[-1,1]$, distinto para cada amostra de $\hat{\Gamma}_i^-$.

3.3.3 Projeto dos Sinais de Identificação - U^{\oplus}

A metodologia \mathcal{S} foi desenvolvida de forma muito semelhante ao método SOESGOPE original. De forma resumida, a metodologia de otimização em camada-dupla foi definida da seguinte maneira:

1. Camada Externa ou malha principal de otimização (Otimizador: **PSO**): dedicada à otimização de $\mathbf{u}(\Xi)$ a partir da definição da parametrização Ξ do sinal. Cada indivíduo (Ξ) do enxame é um candidato à solução do sinal do tipo **APRBS**. Os indivíduos são avaliados por uma função custo $f(\Xi)$ que mensura a persistência de excitação e o desrespeito às restrições estabelecidas através das métricas: ① Precisão de Saída $f_o(\cdot)$, ② Recuperabilidade Paramétrica $f_{\delta}(\cdot)$ e ③ Restrições operacionais $\Theta(\cdot)$. A persistência de excitação, em específico, é avaliada pelas métricas ① e ②, as quais exigem um processo adicional de otimização definido como uma camada interna à otimização do **PSO**. Mais informações sobre a representação do sinal **APRBS** e aplicação do **PSO** são descritas no Anexo C.
2. Camada Interna ou malha secundária de otimização (Otimizador: **MPI**): responsável pela estimativa paramétrica necessária para a avaliação da qualidade de persistência de $\mathbf{u}(\Xi)$. Este mesmo otimizador é utilizado para resolver a etapa de estimação paramétrica de \mathcal{P} , como será descrito em detalhes posteriormente.

Expressando a metodologia de camada-dupla em termos matemáticos, o problema de otimização é definido pela seguinte expressão:

$$\begin{aligned} \text{Minimizar}_{\Xi} \quad f(\Xi) &= k_o \mathbf{f}_o(\cdot) + k_{\delta} \mathbf{f}_{\delta}(\cdot | \mathbf{f}_o) + k_{\Theta} \Theta(\cdot) \\ \Xi_{min} &\leq \Xi \leq \Xi_{max} \end{aligned} \quad (3.13)$$

onde Ξ_{min} e Ξ_{max} são os limites mínimo e máximo da codificação de Ξ , respectivamente, enquanto k_o , k_{δ} e $k_{\Theta} \in \mathbb{R}_{\geq 0}$ são pesos constantes relacionados às métricas. Além disso, é válido ressaltar que a notação $\mathbf{f}_{\delta}(\cdot | \mathbf{f}_o)$ exprime a dependência de \mathbf{f}_{δ} aos resultados de \mathbf{f}_o .

A seguir são descritas as métricas que compõem a metologia de otimização:

1. Precisão de Saída $\mathbf{f}_o(\hat{\Gamma}^-, \mathcal{M}(\tilde{\Gamma}^p, \mathbf{u}))$: responsável por avaliar as divergências entre o modelo internamente estimado $\mathcal{M}(\hat{\Gamma}^+, \mathbf{u})$ e $\mathcal{M}(\tilde{\Gamma}^p, \mathbf{u})$, estimulados pelo sinal $\mathbf{u}(\Xi)$. Esta tarefa exige a estimação de $\hat{\Gamma}^+$ a partir de $\hat{\Gamma}^-$ e a utilização de um estimador dedicado. Matematicamente, a estimação de $\hat{\Gamma}^+$ busca minimizar o somatório do erro quadrático médio:

$$\mathcal{J} = \frac{1}{N} \sum_{k=1}^N \|\hat{\mathbf{x}}^+(k) - \tilde{\mathbf{x}}^p(k)\| + \|\hat{\mathbf{y}}^+(k) - \tilde{\mathbf{y}}^p(k)\| \quad (3.14)$$

ou pela minimização do somatório do erro quadrático médio ponderado, no caso de variáveis com dimensões muito distintas,

$$\begin{aligned} \mathcal{J} &= \frac{1}{N} \sum_{k=1}^N [\hat{\mathbf{x}}^+(k) - \tilde{\mathbf{x}}^p(k)]^T \mathbf{Q}_x [\hat{\mathbf{x}}^+(k) - \tilde{\mathbf{x}}^p(k)] \\ &+ \frac{1}{N} \sum_{k=1}^N [\hat{\mathbf{y}}^+(k) - \tilde{\mathbf{y}}^p(k)]^T \mathbf{Q}_y [\hat{\mathbf{y}}^+(k) - \tilde{\mathbf{y}}^p(k)] \end{aligned} \quad (3.15)$$

onde $[\hat{\mathbf{x}}^+(k), \hat{\mathbf{y}}^+(k)]$ e $[\tilde{\mathbf{x}}^p(k), \tilde{\mathbf{y}}^p(k)]$ são os estados e saídas de $\mathcal{M}(\hat{\Gamma}^+)$ e $\mathcal{M}(\tilde{\Gamma}^p)$, respectivamente, N é o número total de amostras k do experimento (t_u), \mathbf{Q}_x e \mathbf{Q}_y são as ponderações dos estados e das variáveis de saídas, respectivamente. Conforme descrito na camada interna, o algoritmo do MPI será utilizado para minimização de \mathcal{J} . Este algoritmo será descrito com detalhes necessários na Seção (3.3.4).

2. Recuperabilidade Paramétrica $\mathbf{f}_{\delta}(\tilde{\Gamma}^p, \hat{\Gamma}^+ | \mathbf{f}_o)$: mede a capacidade de recuperação do conjunto de parâmetros de referência $\tilde{\Gamma}^p$ a partir de um sinal $\mathbf{u}(\Xi)$. A métrica

é expressa matematicamente pelo somatório do erro relativo entre a estimativa obtida $\hat{\Gamma}^+$ e a referência $\tilde{\Gamma}^p$:

$$\mathbf{f}_\delta(\tilde{\Gamma}^p, \hat{\Gamma}^+ | \mathbf{f}_o) = \sum_{i=1}^r \frac{|\hat{\Gamma}_i^+ - \tilde{\Gamma}_i^p|}{|\tilde{\Gamma}_i^p|} \quad (3.16)$$

onde $\hat{\Gamma}_i^+$ e $\tilde{\Gamma}_i^p$ representam o i -ésimo parâmetro de $\hat{\Gamma}^+$ e $\tilde{\Gamma}^p$.

Obs.: É válido dizer que esta métrica avalia a similaridade entre o resultado fornecido e obtido pela métrica $\mathbf{f}_o(\cdot)$. Esta avaliação é importante visto que conjuntos de parâmetros completamente diferentes podem gerar a mesma saída. Assim, esta métrica observa quão próximos estão os parâmetros estimados de $\tilde{\Gamma}^p$. Portanto, tornando a avaliação da persistência de excitação de $\mathbf{u}(\Xi)$ eficaz em conjunto com $\mathbf{f}_o(\cdot)$.

3. Restrições operacionais $\Theta(\cdot)$: penaliza o sinal $\mathbf{u}(\Xi)$ que estimule os estados de $\mathcal{M}(\tilde{\Gamma}^p)$ em ocasiões de desrespeito às restrições operacionais estabelecidas (ex.: limite espacial, velocidades de operação, etc.). Matematicamente:

$$\Theta(\mathcal{M}(\tilde{\Gamma}^p, \mathbf{u})) = \left\{ \begin{array}{l} \sum_{k=1}^N \sum_{i=1}^n \frac{|\tilde{x}_i^p(k) - \bar{x}_i|}{|\bar{x}_i|}, \forall \tilde{x}_i^p(k) > \bar{x}_i \\ + \\ \sum_{k=1}^N \sum_{i=1}^n \frac{|\tilde{x}_i^p(k) - \underline{x}_i|}{|\underline{x}_i|}, \forall \tilde{x}_i^p(k) < \underline{x}_i \\ + \\ \sum_{k=1}^N \sum_{i=1}^m \frac{|\tilde{y}_i^p(k) - \bar{y}_i|}{|\bar{y}_i|}, \forall \tilde{y}_i^p < \bar{y}_i \\ + \\ \sum_{k=1}^N \sum_{i=1}^m \frac{|\tilde{y}_i^p(k) - \underline{y}_i|}{|\underline{y}_i|}, \forall \tilde{y}_i^p < \underline{y}_i \end{array} \right. \quad (3.17)$$

onde \bar{x}_i e \underline{x}_i representam os limites inferior e superior de i -ésimo estado, respectivamente; \bar{y}_i e \underline{y}_i representam os limites inferior e superior da i -ésima saída, respectivamente.

3.3.4 Estimação Paramétrica

Conceitualmente, o algoritmo de estimação paramétrica tem o compromisso de determinar $\hat{\Gamma}^+$ que minimize a divergências entre $\mathcal{M}(\hat{\Gamma}^+)$ e o modelo de referência: $\mathcal{M}(\tilde{\Gamma}^p)$ ou de $\mathcal{R}(\Gamma)$. Esta tarefa, portanto, exige a utilização de um otimizador dedicado à minimização das divergências observadas nos estados.

Para exercer esta tarefa foi desenvolvido um algoritmo utilizando o **MPI** do tipo *Primal-Dual*, descrito em (BYRD; GILBERT; NOCEDAL, 2000). A utilização do **MPI** possui características fundamentais para o problema proposto, como: aplicabilidade em sistemas não lineares nos parâmetros, solução de problemas com restrições e convergência para soluções ótimas.

Conforme compreendido, o problema da otimização de \mathbf{f}_o (Métrica de Precisão de Saída) e \mathcal{P} (Etapa de Estimação Paramétrica) é o mesmo, porém em contextualizações diferentes. Para ambos os casos a problemática envolve encontrar $\hat{\Gamma}^+$ que minimize o erro quadrático \mathcal{J} a partir de: $\hat{\Gamma}^-$, \mathbf{u} e correspondente resposta do sistema referência $[\mathbf{x}, \mathbf{y}]$. Portanto, matematicamente descrito por:

$$\begin{aligned} \text{Minimizar}_{\hat{\Gamma}^+} \quad \mathcal{J} = \mathbf{f}_{plus}(\hat{\Gamma}^-, \mathcal{M}(\hat{\Gamma}^+, \mathbf{u}), [\mathbf{x}, \mathbf{y}]) \\ -\Gamma_{min} \leq \hat{\Gamma}^+ \leq \Gamma_{max} \end{aligned} \quad (3.18)$$

onde \mathbf{f}_{plus} é a função responsável pelo cálculo de \mathcal{J} baseada na simulação de $\mathcal{M}(\hat{\Gamma}^+, \mathbf{u})$ e em comparação com $[\mathbf{x}, \mathbf{y}]$. Adicionalmente, Γ_{min} e Γ_{max} são os limites mínimo e máximo estabelecidos para a estimação de $\hat{\Gamma}^+$ e $[\mathbf{x}, \mathbf{y}]$ pode ser substituído por $\mathcal{M}(\tilde{\Gamma}^p, \mathbf{u})$ ou $\mathcal{R}(\Gamma, \mathbf{U}^\oplus)$, sem perda de generalização.

Utilizando o **MPI** Primal-Dual, bem como a adequação de \mathbf{f}_{plus} à sua respectiva etapa na metodologia, é possível definir $\mathbf{f}_o(\cdot)$ e $\mathcal{P}(\cdot)$:

- Função de Precisão $\mathbf{f}_o(\cdot)$:

$$\mathbf{f}_o(\hat{\Gamma}^-, \mathcal{M}(\tilde{\Gamma}^p, \mathbf{u})) = \begin{cases} \text{Minimizar}_{\hat{\Gamma}^+} \quad \mathcal{J} = \mathbf{f}_{plus}(\hat{\Gamma}^-, \mathcal{M}(\hat{\Gamma}^+, \mathbf{u}), \mathcal{M}(\tilde{\Gamma}^p, \mathbf{u})) + \\ \quad -\mu \sum_{i=1}^n \ln(s_{1,i}) - \mu \sum_{i=1}^n \ln(s_{2,i}) \\ \text{Sujeito a:} \quad \hat{\Gamma}^+ - \mathbf{s}_1 = \Gamma_{min} \\ \quad \hat{\Gamma}^+ + \mathbf{s}_2 = \Gamma_{max} \\ \quad \mathbf{s}_1 > 0, \mathbf{s}_2 > 0 \end{cases} \quad (3.19)$$

onde $\mathbf{s}_1, \mathbf{s}_2 \in \mathbb{R}^n$ são as variáveis de folga (do inglês, *slack variables*), $\mu \in \mathbb{R}$ é o parâmetro de barreira tal que $\mu \rightarrow 0$ ao fim do processo de otimização.

- Algoritmo de Estimação Final (\mathcal{P}):

$$P^\oplus(\cdot) = \begin{cases} \text{Minimizar: } \mathcal{J} = f_{plus}(\hat{\Gamma}^-, \mathcal{M}(\hat{\Gamma}^+, \mathbf{u}), \mathcal{R}(\Gamma, U^\oplus)) + \\ \hat{\Gamma}^+ & -\mu \sum_{i=1}^n \ln(s_{1,i}) - \mu \sum_{i=1}^n \ln(s_{2,i}) \\ \text{Sujeito a:} & \hat{\Gamma}^+ - \mathbf{s}_1 = \Gamma_{min} \\ & \hat{\Gamma}^+ + \mathbf{s}_2 = \Gamma_{max} \\ & \mathbf{s}_1 > 0, \mathbf{s}_2 > 0 \end{cases} \quad (3.20)$$

3.4 Comparação: SOESGOPE e rSOESGOPE

Para fins de comparação, a Tabela 3 descreve as principais distinções entre o método SOESGOPE e sua nova derivação.

Tabela 3: Comparação entre as características do SOESGOPE e rSOESGOPE.

Características	SOESGOPE	Robust SOESGOPE
n° de sinais	1	Múltiplos
Rest. nos estados	✓	✓
Rest. Temporais	✓	✗
α -constrain	✓	✗
Método do MPI	<i>Safety barrier interior-point method</i>	Primal-dual
Algoritmo do PSO	<i>Particle Swarm-Like Optimization</i>	Original

A partir da Tabela 3 é possível perceber que as diferenças entre os métodos vão além da utilização de múltiplos sinais. A primeira destas diferenças é evidenciada na escolha das restrições incorporadas ao problema de otimização. Na nova abordagem optou-se por simplificar o problema e, portanto, não introduzir as restrições temporais, já que interferem diretamente na persistência de excitação dos sinais e podem ser conflitantes na busca de sinais de alta qualidade. Este mesmo argumento também justifica a não incorporação da otimização do volume espacial do experimento via α -constrain, e, assim, permitindo concentrar esforços na otimização da persistência de sinais factíveis ao problema. No âmbito das escolhas dos algoritmos existem mais duas diferenças, as quais foram intencionais pensando na busca de praticidade e facilidade para a replicabilidade do método rSOESGOPE. Neste sentido, optou-se pela utilização do MPI e PSO amplamente difundidos na literatura e disponíveis pelo *software* MATLAB. Ressalta-se que a mudança do algoritmo do MPI do método original³ não influi no resultado final, apenas no tempo de convergência. Quanto a mudança do PSO⁴, a alteração traz os be-

³MPI do método SOESGOPE: *Safety barrier interior-point method* - (OLIVEIRA et al., 2015)

⁴PSO do método SOESGOPE: *Particle Swarm-Like Optimization* - (SILVA; FREIRE; HONÓRIO, 2016)

nefícios da utilização do algoritmo original da meta-heurística, este acessível e robusto, bem como a confiabilidade e robustez apresentada na literatura (PEDERSEN, 2010).

3.5 Algoritmo Geral da Metodologia

Com a finalidade de que o leitor tenha uma visão general do método de identificação proposto, abaixo tem-se sua apresentação em forma de algoritmo.

Algoritmo 1 Método de Identificação rSOESGOPE

Informação de Entrada do Algoritmo:

- Estimacão a priori do sistema: $\mathcal{M}(\hat{\Gamma}^-)$
 - Número total de sinais \mathbf{u}^\oplus ou amostras $\tilde{\Gamma}^p$: k
-

Etapa 01: Geraçao dos Parâmetros de Referência (\mathbf{P}^\oplus): $[\tilde{\Gamma}_1^p, \dots, \tilde{\Gamma}_k^p] = \mathcal{B}(\hat{\Gamma}^-)$

Etapa 02: Projeto dos sinais (\mathbf{U}^\oplus): $[\mathbf{u}_1^\oplus, \dots, \mathbf{u}_k^\oplus] = \mathcal{S}(\mathcal{M}(\hat{\Gamma}^-), \mathcal{M}(\mathbf{P}^\oplus))$

for $k = 1 : N_{sinal}$ **do** $\triangleright N_{sinal} : n^\circ$ total de sinais Projetados

Algoritmo de PSO - Camada de Otimizaçao Externa

Inicializa: $i = 1$, $f_{BEST} = 1e^{10}$ e $\mathbf{u}^\oplus = []$ e **Pop** \triangleright Pop. de indivíduos do PSO

while ($i < N_g$) **do** $\triangleright i : n^\circ$ da geraçao atual, $N_g : n^\circ$ total de Geraçoes

for $id = 1 : N_{pop}$ **do** $\triangleright N_{pop} : n^\circ$ total de indivíduos da Pop

Avalia: $\mathbf{f}_o(\hat{\Gamma}^-, \mathcal{M}(\tilde{\Gamma}_k^p, \mathbf{u}(\Xi_k^{id})))$ \triangleright Camada Interna - MPI Primal-Dual

Avalia: $\mathbf{f}_\delta(\tilde{\Gamma}_k^p, \hat{\Gamma}^+ | \mathbf{f}_o)$ \triangleright Métrica: Recuperabilidade Paramétrica

Avalia: $\Theta(\mathcal{M}(\tilde{\Gamma}_k^p, \mathbf{u}(\Xi_k^{id})))$ \triangleright Métrica: Restriçoes Operacionais

Calcula: $f(\Xi_k^{id}) = k_o \mathbf{f}_o(\cdot) + k_\delta \mathbf{f}_\delta(\cdot | \mathbf{f}_o) + k_\Theta \Theta(\cdot)$

if $f(\Xi_k^{id}) < f_{BEST}$ **then**

$f_{BEST} = f(\Xi_k^{id})$

$\mathbf{u}_k^\oplus = \mathbf{u}(\Xi_k^{id})$

end if

Atualiza: **Pop**

end for

Atualiza: $i = i + 1$

end while

Retorna: \mathbf{u}_k^\oplus

end for

- Definiçao de $\mathbf{U}^\oplus = [\mathbf{u}_1^\oplus, \mathbf{u}_2^\oplus, \dots, \mathbf{u}_k^\oplus]$

Etapa 03: Estimacão Paramétrica $\hat{\Gamma}^+$:

- Excitaçao de $\mathcal{R}(\Gamma + \delta\Gamma)$ por cada $\mathbf{u}_i^\oplus \in \mathbf{U}^\oplus$;

- Soluçao de $\hat{\Gamma}^+ = \mathcal{P}(\mathcal{M}(\hat{\Gamma}^-, \mathbf{U}^\oplus), \mathcal{R}(\Gamma + \delta\Gamma, \mathbf{U}^\oplus))$

4 RESULTADOS EXPERIMENTAIS

Neste capítulo será apresentado o estudo de aplicação do **rSOESGOPE** em uma embarcação real. Por meio deste estudo será possível compreender e analisar cada etapa da metodologia, bem como avaliar sua aplicabilidade e robustez. A seguir, o capítulo segue organizado da seguinte maneira: Seção 4.1 apresenta o **ASV** de estudo, suas características, definição do problema de identificação e estimação inicial; Seção 4.2 descreve a aplicação do método, sua configuração, geração dos sinais e estimação paramétrica; Seção 4.3 confronta os modelos estimados em novos cenários de validação. Ressalta-se que todos os resultados apresentados em sequência são de natureza experimental.

4.1 ASV AERO4River

Figura 10: Visão real do ASV AERO4River.



Fonte: Autor.

O ASV AERO4River é uma embarcação desenvolvida para coletar autonomamente medições hidrológicas em ambientes com obstáculos subaquáticos, fluxos de água rasos e rápidos. Como ilustrado pela Figura 10, a embarcação é do tipo catamarã e possui um sistema de propulsão aérea com controle de azimutal. Esta configuração gera um ASV com 3 DoF superatuado, altamente manobrável e capaz de operar nas situações mencionadas acima. Detalhamentos sobre a embarcação podem ser encontrados nos trabalhos de (SILVA et al., 2020) e (REGINA et al., 2021).

4.1.1 Características Inerciais e Operacionais

Nas Tabelas 4 e 5 encontram-se as principais características inerciais e os limites operacionais, respectivamente. Todas as informações foram extraídas nos períodos de testes iniciais da embarcação.

Tabela 4: Características Inerciais do AERO4River.

Parâmetro	Valor	Unidade
m	33,06	[kg]
I_z	4,12	[kg.m ²]
x_g	-0,05	[m]
y_g	0,00	[m]

Tabela 5: Limites Operacionais do AERO4River.

Variável	Limite Inferior	Limite Superior	Unidade
u	0,00	2,05	[m/s]
v	-0,90	0,90	[m/s]
r	-2,87	2,87	[rad/s]
F_x	0,00	78,0	[N]
F_y	-78,0	78,0	[N]
τ_n	-42,0	42,0	[N.m]
t_{F_x}	0,75	3,15	[s]
t_{F_y}	1,95	5,85	[s]
t_{τ_n}	0,45	2,70	[s]

No que trata da Tabela 5 é válido ressaltar que: $[F_x, F_y, \tau_n]$ representam a capacidade do sistema de propulsão para os movimentos frontal, lateral e de guinada, respectivamente; $[t_{F_x}, t_{F_y}, t_{\tau_n}]$ representam as constantes de tempo relacionadas às dinâmicas dos movimentos frontal, lateral e de guinada, respectivamente; as constantes

de tempo mínima e máxima de cada DoF foram estimadas analisando operações com 10% e 100%, respectivamente.

4.1.2 Definição do Problema de Identificação

O modelo matemático da embarcação $\mathcal{M}(\Gamma)$ seguirá as diretrizes apresentadas no Capítulo 2. Em específico será utilizada a parametrização de Neto et al. (2021) e, deste modo, todos os acoplamentos hidrodinâmicos entre os 3 DoFs serão considerados. Nesta direção, o modelo dinâmico de interesse, sem distúrbio, é definido por:

$$\mathbf{M}_{RB}\dot{\boldsymbol{\nu}} + \mathbf{C}_{RB}(\boldsymbol{\nu}) = \boldsymbol{\tau} - \mathbf{M}_A\dot{\boldsymbol{\nu}} - [\mathbf{C}_A(\boldsymbol{\nu}) + \mathbf{D}(\boldsymbol{\nu})]\boldsymbol{\nu} \quad (4.1)$$

Assumindo que as matrizes \mathbf{M}_{RB} e $\mathbf{C}_{RB}(\boldsymbol{\nu})$ estão relacionadas a variáveis já conhecidas, o problema de identificação é resumido a estimação dos parâmetros das matrizes \mathbf{M}_A , $\mathbf{C}_A(\boldsymbol{\nu})$ e $\mathbf{D}(\boldsymbol{\nu})$. Portanto, a solução encontra-se no espaço dimensional \mathbb{R}^{27} , cujos parâmetros são:

- Massa Adicionada (\mathbb{R}^9): $X_{\dot{u}}, X_{\dot{v}}, X_{\dot{r}}, Y_{\dot{u}}, Y_{\dot{v}}, Y_{\dot{r}}, N_{\dot{u}}, N_{\dot{v}}, N_{\dot{r}}$;
- Coeficientes de Amortecimento Linear (\mathbb{R}^9): $X_u, X_v, X_r, Y_u, Y_v, Y_r, N_u, N_v, N_r$;
- Coeficientes de Amortecimento não-Linear (\mathbb{R}^9): $X_{|u|u}, X_{|v|v}, X_{|r|r}, Y_{|u|u}, Y_{|v|v}, Y_{|r|r}, N_{|u|u}, N_{|v|v}, N_{|r|r}$.

No âmbito do projeto dos sinais, estes deverão contemplar comandos para os 3 DoFs conforme o sistema de atuação da embarcação. Logo, o problema requer a definição de 3 sinais APRBS, ou seja: 1 [sinal/DoF]. Se a solução de $u(\boldsymbol{\Xi}_k)^1$ em 1 dimensão ocorre em $\mathbb{R}^{2 \times k}$, logo para o problema proposto o espaço de solução ocorre em $\mathbb{R}^{6 \times k}$.

A partir desta análise é possível compreender a complexidade do problema proposto, cuja solução paramétrica de $\boldsymbol{\Gamma} \in \mathbb{R}^{27}$ exige a definição de $\boldsymbol{\Xi}_k \in \mathbb{R}^{6 \times k}$. Além disso, também apreende-se que a escolha do número de estágios k é um parâmetro sensível do problema e deve ser feito com parcimônia.

¹Variável k representa o número de estágios ou pares de (Amplitude, intervalo de tempo).

4.1.3 Estimação Paramétrica Inicial

Dada a complexidade do modelo e alta incerteza sobre $\Gamma \in \mathbb{R}^{27}$ (REGINA et al., 2021), a estimação inicial foi dedicada aos principais parâmetros da embarcação, conforme sugere o trabalho de Souza, Honório e Oliveira (2020) em situações cujo número de parâmetros é expressivo e a complexidade de solução é alta. Portanto, a estimação a priori foi dedicada a um modelo simplificado² com um total de 9 parâmetros, matematicamente representado por:

$$(m - X_{\dot{u}}) \cdot \dot{u} + (-X_u - X_{|u|u}|u|) \cdot u = F_x \quad (4.2)$$

$$(m - Y_{\dot{v}}) \cdot \dot{v} + (-Y_v - Y_{|v|v}|v|) \cdot v = F_y \quad (4.3)$$

$$(I_z - N_{\dot{r}}) \cdot \dot{r} + (-N_r - N_{|r|r}|r|) \cdot r = \tau_N \quad (4.4)$$

Para a identificação do modelo simplificado foram realizados 3 ensaios em malha aberta, baseados no sinal APRBS. Cada um dos experimentos foi dedicado à excitação de 1 DoF específico, cujos estados da embarcação foram obtidos da placa controladora³ do ASV via telemetria. Os resultados das estimações paramétricas são apresentados na Tabela 6, os quais foram obtidos utilizando o MPI, descrito na Seção 3.3.4, e a massa de dados experimentais da excitação de cada DoF.

Tabela 6: Resumo da Estimação Inicial $\mathcal{M}(\hat{\Gamma}^-)$

Parâmetro	Valor	Unidade
$X_{\dot{u}}$	-34,72	[kg]
X_u	-0,00	[kg · s ⁻¹]
$X_{ u u}$	-15,51	[kg · m ⁻¹]
$Y_{\dot{v}}$	-33,78	[kg]
Y_v	-0,00	[kg · s ⁻¹]
$Y_{ v v}$	-86,87	[kg · m ⁻¹]
$N_{\dot{r}}$	-8,58	[kg · m ² · rad ⁻¹]
N_r	-5,44	[kg · m ² · rad ⁻¹ · s ⁻¹]
$N_{ r r}$	-1,01	[kg · m ² · rad ⁻²]

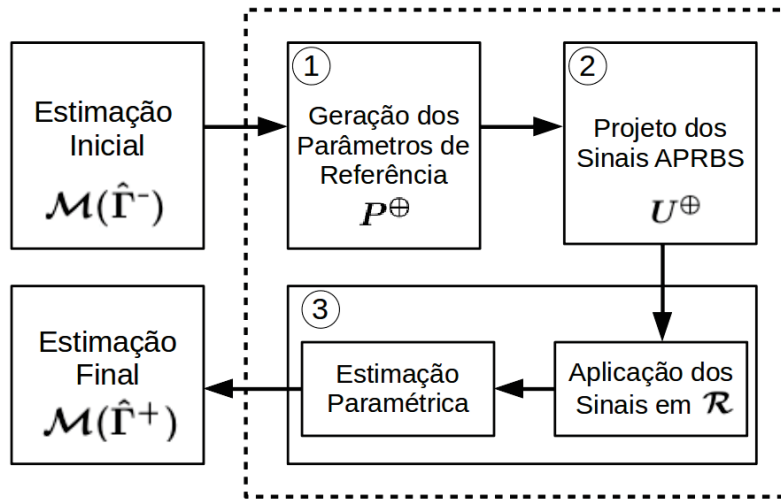
²Modelo simplificado possui todos os DoFs desacoplados.

³A placa controladora fornece dados através da fusão de sensores (*Global Positioning System* (GPS) e *Inertial Measurement Units* (IMUs)) via Filtro de Kalman Extendido. Mais informação, recomenda-se a leitura do trabalho de Silva et al. (2020).

4.2 Aplicação do Método rSOESGOPE

Conforme o Capítulo 3, a aplicação do método rSOESGOPE possui 3 etapas bem definidas: (1) Geração dos Parâmetros de Referência, (2) Projeto dos Sinais e (3) Estimação Paramétrica. Essas etapas são desenvolvidas em sequência e também são esquematicamente representadas pela Figura 11.

Figura 11: Diagrama de Aplicação do rSOESGOPE.



Fonte: Autor.

4.2.1 Geração dos Parâmetros de Referência

Para definir $P^\oplus = [\tilde{\Gamma}_1^p, \tilde{\Gamma}_2^p, \dots, \tilde{\Gamma}_n^p]$, primeiramente, é necessário determinar o número de caracteres n que compõem U^\oplus . Este número deve ser suficiente para minimizar as incertezas sobre $\hat{\Gamma}^-$ e garantir a subsequente robustez do método. Para este estudo de caso será investigado o uso de até 5 sinais na composição U^\oplus . Portanto, P^\oplus também é composto por 5 conjuntos de parâmetros $\tilde{\Gamma}^p$.

A Tabela 7 apresenta o conjunto de parâmetros P^\oplus gerados de forma aleatória em uma região de incerteza de 50% em torno de $\hat{\Gamma}^-$.

4.2.2 Projeto dos Sinais

O primeiro passo para projetar os sinais APRBS é a definição do número de estágios do sinal e do tamanho da população do PSO. Estas variáveis de controle são fundamentais para a metodologia, já que produzem grande impacto na capacidade de busca

Tabela 7: Parâmetros de Referência Gerados - P^\oplus

-	$\tilde{\Gamma}_1^p$	$\tilde{\Gamma}_2^p$	$\tilde{\Gamma}_3^p$	$\tilde{\Gamma}_4^p$	$\tilde{\Gamma}_5^p$
$X_{\dot{u}}$	-43,91	-35,65	-36,58	-23,74	-25,58
X_u	-0,00	-0,00	-0,00	-0,00	-0,00
$X_{ u u}$	-15,47	-19,05	-20,75	-13,09	-12,67
$Y_{\dot{v}}$	-42,95	-47,91	-21,63	-37,81	-25,32
Y_v	-0,00	-0,00	-0,00	-0,00	-0,00
$Y_{ v v}$	-124,59	-59,43	-84,87	-112,75	-87,77
$N_{\dot{r}}$	-11,66	-12,58	-6,56	-10,88	-6,41
N_r	-7,89	-4,71	-7,55	-4,43	-5,13
$N_{ r r}$	-0,85	-0,91	-1,33	-1,33	-1,26

do PSO e também nas propriedades de persistência da excitação dos sinais gerados.

Neste contexto foi desenvolvido um estudo para encontrar a melhor configuração utilizando as seguintes definições:

- **PSO**: análise da população de partículas (N_{pop}) de 5 a 20; codificação de cada partícula Ξ_i com estágios de 3 a 24 ($\Xi_3, \Xi_6, \Xi_{12}, \Xi_{24}$); 100 gerações como critério de parada;
- Algoritmo dos Pontos-Interiores: $f_o < 10^{-2}$ e $\mu < 0,001^4$ critério de parada;
- Ponderações da função objetivo: $k_o = 1, k_{\hat{\delta}} = 20, k_{\Theta} = 0$;
- Ponderações de erro: apenas as velocidades no referencial de corpo rígido $[u, v, r]$ foram adotadas para o processo de otimização, ponderadas pelo inverso da variância. Portanto, Q_x foi descartado e Q_y foi definido por:

$$Q_y = \text{diag}(1/\hat{\sigma}_u^2, 1/\hat{\sigma}_v^2, 1/\hat{\sigma}_r^2) \quad (4.5)$$

onde $\hat{\sigma}_u = 0,05$ [m/s], $\hat{\sigma}_v = 0,05$ [m/s] e $\hat{\sigma}_r = 0,01$ [rad/s] são os desvios padrões definidos para as velocidades frontal, lateral e de guinada, respectivamente.

- Codificação do Sinal: o problema de **OSD** consiste na determinação de $\mathbf{u}(\Xi_k)$, sendo que Ξ_k é definido por:

$$\Xi_n = \begin{bmatrix} t_{Fx}^1, & \dots, & t_{Fx}^k, & F_x^1, & \dots, & F_x^k \\ t_{Fy}^1, & \dots, & t_{Fy}^k, & F_y^1, & \dots, & F_y^k \\ t_{\tau_n}^1, & \dots, & t_{\tau_n}^k, & \tau_n^1, & \dots, & \tau_n^k \end{bmatrix} \quad (4.6)$$

⁴ μ : parâmetro de barreira usado com critério de convergência no método de pontos interiores.

onde k é o número do estágio, $[F_x^k, F_y^k, \tau_n^k]$ são as amplitudes e $[t_{F_x}^k, t_{F_y}^k, t_{\tau_n}^k]$ os tempos de permuta do APRBS.

A Tabela 8 apresenta os resultados do estudo a partir da análise de 50 rodadas (“50 sinais”) para cada configuração estudada. Os resultados são representados pela média (av) e desvio padrão (std) de $f(\Xi)$. Todas as simulações utilizam os mesmos conjuntos de parâmetros iniciais $\hat{\Gamma}^-$ (ver Tabela 6) e referência $\tilde{\Gamma}^p$ (ver Equação 3.12), bem como as mesmas condições iniciais para gerar os primeiros sinais.

Tabela 8: Análise do número de estágios e indivíduos.

N_{pop}	Ξ_3		Ξ_6		Ξ_{12}		Ξ_{24}	
	av	std	av	std	av	std	av	std
05	0,63	0,24	0,57	0,13	2,12	0,36	1,58	0,41
10	0,48	0,15	0,47	0,10	1,24	0,43	1,26	0,31
15	0,43	0,11	0,43	0,13	0,83	0,37	1,28	0,41
20	0,40	0,10	0,39	0,11	0,64	0,20	1,12	0,36


É possível observar na Tabela 8 o aprimoramento na persistência do sinal à medida que o número de partículas aumenta. Este fato é observado de 5 a 20 partículas, onde a redução da média de $f(\Xi_i)$ mostra-se bem significativa. Verifica-se também que há uma melhora na qualidade do sinal em até 6 estágios. Acima desse valor, a persistência do sinal se degrada, demonstrando que o aumento na codificação do sinal não é mais benéfico. Assim, conforme o *framework* proposto, a melhor configuração é a utilização de 20 partículas e 6 estágios.

Com base nessas conclusões, cada sinal $\mathbf{u}_i^\oplus \in \mathbf{U}^\oplus = [\mathbf{u}_1^\oplus, \mathbf{u}_2^\oplus, \dots, \mathbf{u}_5^\oplus]$ foi projetado de acordo com seu respectivo parâmetro de referência $\tilde{\Gamma}_i^p \in \mathbf{P}^\oplus = [\tilde{\Gamma}_1^p, \tilde{\Gamma}_2^p, \dots, \tilde{\Gamma}_5^p]$. Matematicamente este processo é representado por:

$$\mathbf{u}_i^\oplus = \mathcal{S}(\mathcal{M}(\hat{\Gamma}^-), \mathcal{M}(\tilde{\Gamma}_i^p)) \quad (4.7)$$

A Figura 12 apresenta os sinais APRBS gerados, enquanto a Tabela 9 expõe as propriedades dos sinais: precisão de saída f_o , recuperabilidade paramétrica f_δ , penalizações das restrições operacionais f_Θ , persistência de excitação f_Ξ e tempo de simulação T_s . Ressalta-se que as restrições operacionais descritas na Tabela 5 foram impostas de modo a produzir sinais realizáveis e adequados à realidade do ASV. A ponderação das restrições foi definida empiricamente por $k_\theta = 2 \cdot 10^5$.

Figura 12: Sinais APRBS Projetados pelo rSOESGOPE.



Fonte: Autor.

Tabela 9: Desempenho dos Sinais Projetados U^{\oplus} .

-	f_o	f_{δ}	f_{Θ}	f_{Ξ}	T_s [s]
\mathbf{u}_1^{\oplus}	0,44	0,40	0,00	8,35	26,7
\mathbf{u}_2^{\oplus}	1,15	0,80	0,00	17,23	24,1
\mathbf{u}_3^{\oplus}	0,53	0,10	0,00	2,55	27,7
\mathbf{u}_4^{\oplus}	0,28	0,65	0,00	13,30	26,2
\mathbf{u}_5^{\oplus}	0,38	0,16	0,00	3,54	22,0

Analisando a Tabela 9 é possível extrair as seguintes conclusões sobre os sinais projetados:

- Diversidade de dinâmicas: nota-se que os parâmetros de referência $\tilde{\Gamma}_i^p$ impõem diferentes graus de dificuldade à metodologia, como observado pelas amostras $\tilde{\Gamma}_2^p$ e $\tilde{\Gamma}_4^p$. Demonstrando que o conjunto dos experimentos gerados por U^{\oplus} proporcionam dinâmicas diversas;

- Persistência de excitação: nota-se que o valor médio de f_{δ} é 0,4220 para um total de 9 parâmetros, o que exprime um erro médio de recuperabilidade paramétrica de 0,0469/parâmetro ou de apenas 4,69%/parâmetro. Portanto, demonstrando aceitáveis características de persistência de excitação;
- Tempo de experimento: verifica-se que o tempo médio dos experimentos é de 25,3 [s] e o de experimento total é de 126,70 [s]. Conclui-se que apesar dos experimentos não incluírem o tempo na otimização, este também é minimizado admitindo que sinais mais longos são naturalmente penalizados pelas métricas f_o e f_e .

4.2.3 Estimação Paramétrica

Após o projeto de U^{\oplus} , a próxima etapa da metodologia é aplicá-lo no [ASV](#) para, posteriormente, realizar a Estimação Paramétrica ([EP](#)) de $\Gamma \in \mathbb{R}^{27}$ com os dados experimentais obtidos. Neste estudo de caso o problema será investigado utilizando até 5 sinais sub-ótimos propostos pelo [rSOESGOPE](#). Matematicamente, as estimativas a posteriori $\hat{\Gamma}^+$ são calculadas a partir de:

$$\hat{\Gamma}_n^+ = \mathcal{P}(\mathcal{M}(\hat{\Gamma}^-, U_n^{\oplus}), \mathcal{R}(\Gamma, U_n^{\oplus})) \quad (4.8)$$

sendo que n representa o número de sinais de $U_n^{\oplus} = [\mathbf{u}_1^{\oplus}, \dots, \mathbf{u}_n^{\oplus}]$ e \mathcal{P} representa o [MPI](#) responsável por resolver o problema de estimação paramétrica.

O resultado das parametrizações estimadas encontram-se na Tabela 10. Para fins de comparação, as soluções $\hat{\Gamma}^+$ obtidas foram inicialmente avaliadas em relação aos cenários fornecidos por: (1) $\mathcal{R}(\Gamma_n^+, \mathbf{u}_1^{\oplus})$, (2) $\mathcal{R}(\Gamma_n^+, \mathbf{u}_2^{\oplus})$, (3) $\mathcal{R}(\Gamma_n^+, \mathbf{u}_3^{\oplus})$, (4) $\mathcal{R}(\Gamma_n^+, \mathbf{u}_4^{\oplus})$ e (5) $\mathcal{R}(\Gamma_n^+, \mathbf{u}_5^{\oplus})$. A análise de desempenho são apresentadas pela Tabela 11 utilizando o *Root-Mean Square Error* ([RMSE](#)) como critério.

Tabela 10: Estimações Paramétricas obtidas com $U_1^\oplus, U_2^\oplus, U_3^\oplus, U_4^\oplus$ e U_5^\oplus .

-	$\hat{\Gamma}_1^+$	$\hat{\Gamma}_2^+$	$\hat{\Gamma}_3^+$	$\hat{\Gamma}_4^+$	$\hat{\Gamma}_5^+$
$X_{\dot{u}}$	-39,98	-43,66	-50,71	-47,73	-27,04
X_u	-0,00	-0,00	-0,00	-0,00	-0,00
X_v	0,01	0,01	0,01	0,01	0,00
X_r	-0,01	-0,01	-0,01	-0,01	-0,03
$X_{ u u}$	-19,39	-16,85	-17,48	-16,05	-17,33
$Y_{\dot{v}}$	-39,02	-43,79	-55,91	-57,14	-48,34
Y_u	-0,02	-0,02	-0,01	-0,01	-0,00
Y_v	-0,00	-0,00	-0,00	-0,00	-0,00
Y_r	-0,01	-0,01	-0,01	-0,01	-0,05
$Y_{ v v}$	-194,28	-193,18	-192,79	-193,96	-287,65
$N_{\dot{r}}$	-3,07	-10,63	-28,26	-32,50	-9,24
N_u	0,00	0,00	0,00	0,00	0,00
N_v	0,02	0,01	0,01	0,01	0,02
N_r	-28,78	-23,13	-39,12	-44,89	-0,02
$N_{ r r}$	-4,17	-2,37	-6,15	-7,07	-82,08
$\bar{X}_{\dot{v}}$	0,01	0,01	0,01	0,01	0,00
$\bar{X}_{\dot{r}}$	-0,00	-0,00	-0,00	-0,00	-0,00
$\bar{Y}_{\dot{u}}$	-0,00	-0,00	-0,00	-0,00	-0,00
$\bar{Y}_{\dot{r}}$	-0,02	-0,02	-0,02	-0,02	-0,01
$\bar{N}_{\dot{u}}$	-0,03	-0,03	-0,03	-0,03	-5,51
$\bar{N}_{\dot{v}}$	0,02	0,02	0,04	0,04	0,00
$\bar{X}_{ u v}$	0,01	0,01	0,01	0,01	0,06
$\bar{X}_{ u r}$	-0,01	-0,01	-0,01	-0,01	-7,67
$\bar{Y}_{ v u}$	-0,01	-0,01	-0,01	-0,01	-0,00
$\bar{Y}_{ v r}$	-0,00	-0,00	-0,00	-0,00	-0,00
$\bar{Y}_{ r u}$	0,01	0,01	0,00	0,00	0,00
$\bar{Y}_{ r v}$	0,01	0,02	0,02	0,03	50,00

Tabela 11: Análise de desempenho geral de $\mathcal{M}(\hat{\Gamma}_n^+)$.

Γ_n^+	$\mathcal{R}(\Gamma_n^+, \mathbf{u}_1^\oplus)$	$\mathcal{R}(\Gamma_n^+, \mathbf{u}_2^\oplus)$	$\mathcal{R}(\Gamma_n^+, \mathbf{u}_3^\oplus)$	$\mathcal{R}(\Gamma_n^+, \mathbf{u}_4^\oplus)$	$\mathcal{R}(\Gamma_n^+, \mathbf{u}_5^\oplus)$	Σ
1	0,430	0,594	0,513	0,428	0,538	2,504
2	0,445	0,638	0,538	0,414	0,537	2,572
3	0,420	0,583	0,483	0,429	0,517	2,431
4	0,427	0,590	0,452	0,437	0,519	2,424
5	0,497	0,534	0,404	0,506	0,469	2,409

É possível constatar na Tabela 11 que em todos os cinco cenários o uso de 2 ou mais sinais mostrou-se superior à utilização de apenas um único sinal. Em negrito são evidenciados todos os resultados superiores ao método com um único sinal. De forma geral, compreende-se que a partir de 3 sinais os modelos obtidos já denotam uma melhor capacidade de generalização que justifique a utilização de múltiplos sinais. Este fato torna-se mais evidente analisando individualmente os DoFs, como apresenta a Tabela 12.

Tabela 12: Análise de desempenho geral de cada DoF de $\mathcal{M}(\hat{\Gamma}_n^+)$.

Γ_n^+	u [m/s]	v [m/s]	r [rad/s]
1	0,275	0,304	0,291
2	0,296	0,319	0,282
3	0,281	0,296	0,267
4	0,285	0,294	0,262
5	0,305	0,283	0,246

Nota-se na Tabela 12 que os modelos com múltiplos sinais promoveram aprimoramentos nos movimentos lateral e de guinada. Por exemplo, comparando os modelos $\mathcal{M}(\hat{\Gamma}_1^+)$ e $\mathcal{M}(\hat{\Gamma}_5^+)$ verifica-se uma redução do RMSE em 6,9% e 15,46% para os movimentos lateral e de guinada, respectivamente, em relação a $\mathcal{M}(\hat{\Gamma}_1^+)$. Demonstrando, portanto, o aumento da persistência de excitação proporcionado pelas dinâmicas dos sinais adicionados ao experimento de identificação.

Em sequência são apresentadas os resultados dos modelos estimados. Em específico, serão expostos o comportamento dos modelos $\mathcal{M}(\hat{\Gamma}_1^+)$, $\mathcal{M}(\hat{\Gamma}_3^+)$ e $\mathcal{M}(\hat{\Gamma}_5^+)$, favorecendo a análise da técnica conforme os sinais são adicionados ao experimento de identificação. Ressalta-se ao leitor que todos os resultados a seguir são de cunho experimental e foram obtidos em ensaios no lago da Universidade Federal de Juiz de Fora (UFJF), em


condições tranquilas de operação. Em sequência, a Figura 13 apresenta a localização geográfica dos ensaios, enquanto as Figuras 14 a 18 as trajetórias desenvolvidas pelo *ASV* e estados estimados pelos modelos.

Figura 13: Localização do ensaios de estimação.




Fonte: Google earth.

Figura 14: Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_1^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_1^\oplus)$.




Fonte: Autor.

Figura 15: Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_2^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_2^\oplus)$.




Fonte: Autor.

Figura 16: Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_3^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_3^\oplus)$.




Fonte: Autor.

Figura 17: Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_4^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_4^\oplus)$.



Fonte: Autor.

Figura 18: Trajetórias dos estados de $\mathcal{R}(\Gamma, \mathbf{u}_5^\oplus)$ e $\mathcal{M}(\hat{\Gamma}_n^+, \mathbf{u}_5^\oplus)$.

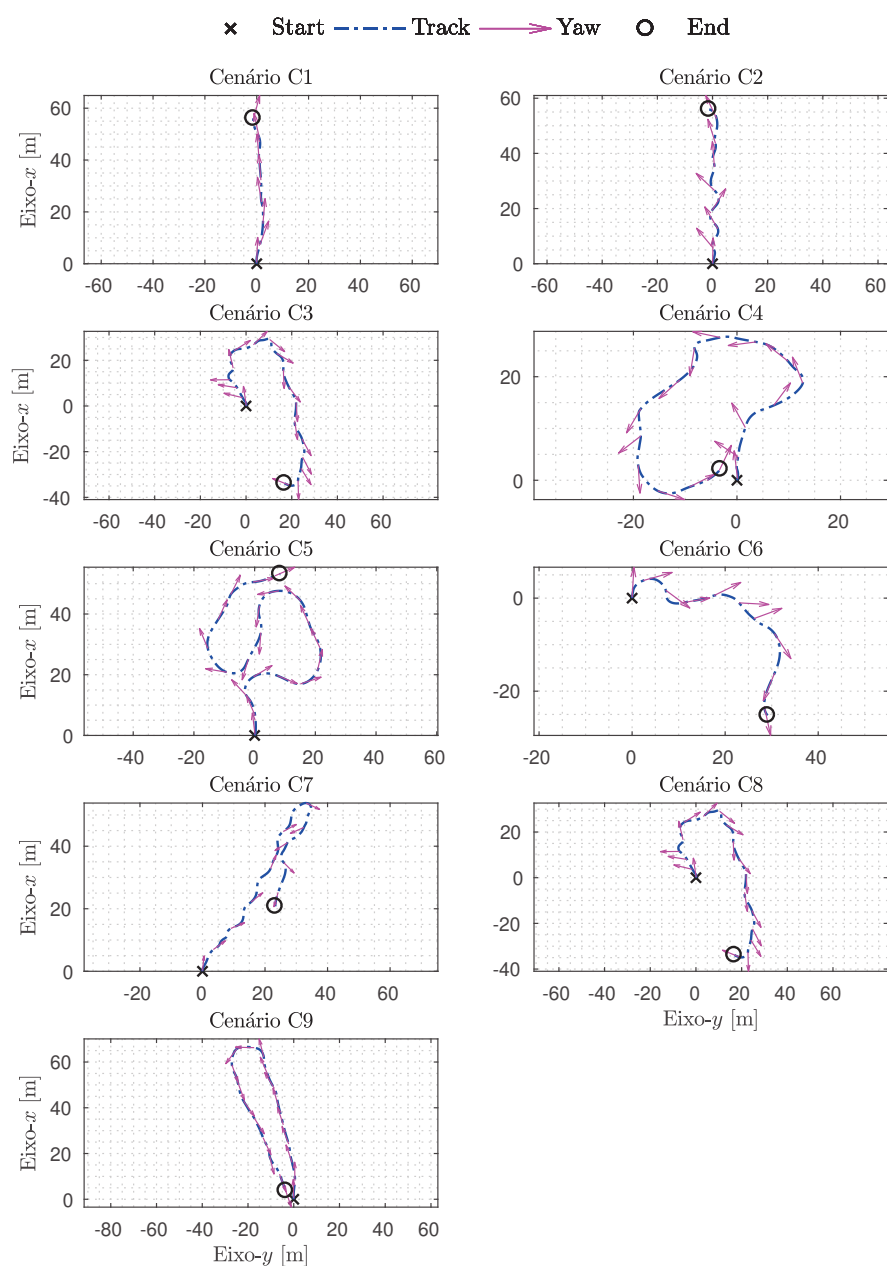


Fonte: Autor.

4.3 Validação dos Modelos

Com o intuito de verificar a robustez dos modelos estimados, estes foram avaliados por novos experimentos⁵, também, desenvolvidos no lago da UFJF. Ao todo, 9 cenários foram analisados, todos descrevendo dinâmicas similares à operação do AERO4River. Na Figura 19 tem-se as trajetórias desenvolvidas pelo ASV nos cenários de validação (C1 a C9).

Figura 19: Trajetórias no plano- xy : C1 a C9.




Fonte: Autor.

⁵A aquisição de dados segue o mesmo padrão dos ensaios apresentados na etapa de estimação paramétrica. Todos os resultados em sequência são de cunho prático.

Pode-se verificar pela Figura 19 que os comandos aplicados à embarcação proporcionaram movimentos diversos, excitando acoplamentos entre os 3 DoFs com amplitudes e frequências variadas. No cenário 1 (C1), o ASV é submetido ao movimento frontal com pequenas correções de guinada, enquanto no cenário 2 (C2) a embarcação é submetida ao tradicional movimento de *zig-zag*. Nos demais cenários (C3 a C9), a embarcação é estimulada para excitar os acoplamentos entre os movimentos frontal, lateral e de guinada.

No que remete aos estados de velocidade do ASV, estes são apresentados com os modelos estimados nas Figuras 20 a 28.

Figura 20: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1.




Fonte: Autor.

Analisando o 1º cenário, nota-se que foi dedicado ao movimento frontal com suaves correções de guinada. Apesar da leve divergência no início do experimento, observa-se que no restante do ensaio os modelos demonstraram grande similaridade com o ASV.

Este fato pode ser principalmente observado em *surge* cujas amplitudes de velocidade são bem consideráveis. Dentre os modelos, é perceptível que $\mathcal{M}(\hat{\Gamma}_1^+)$ possui maiores divergências que os demais. Fato que pode ser observado principalmente em *sway*.


Figura 21: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C2.



Fonte: Autor.

No cenário C2 é possível perceber que os modelos apresentaram comportamentos muito coerentes ao movimento do ASV. Dentre os DoFs, o movimento em *sway* foi o que proporcionou as maiores dificuldades aos modelos, principalmente para $\mathcal{M}(\hat{\Gamma}_1^+)$ cujas velocidades demonstram uma oscilação maior que os demais modelos. Nos outros DoFs observa-se um comportamento muito próximo da dinâmica real.


Figura 22: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C3.



Fonte: Autor.

No cenário C3 observa-se o primeiro experimento com a excitação de movimentos laterais e acoplados. É possível apreender que os modelos conseguiram representar satisfatoriamente as dinâmicas de *surge* e *sway* com leves divergências. Quanto aos movimentos de guinada, nota-se que os modelos também produziram resultados coerentes, apesar de pouco solicitados e com caráter ruidoso.


Figura 23: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C4.



Fonte: Autor.

Em C4 observam-se as situações mais desafiadoras à prova da robustez dos modelos. O ASV é exposto a movimentos altamente acoplados com excitações laterais variadas. Mesmo nessas condições, nota-se que os modelos demonstraram boa capacidade de generalização das principais dinâmicas do ASV. É perceptível que as maiores divergências ocorrem em *surge*, o que pode ser resultado da inconsistência de algumas medidas em virtude do baixo perfil de velocidade apresentado no experimento.


Figura 24: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C5.



Fonte: Autor.

No cenário C5 tem-se a excitação do movimento frontal da embarcação com movimentos amplos de guinada. Nota-se o bom comportamento dinâmico dos modelos, mas com algumas divergências em *sway* que resultam assimetrias da embarcação não absorvidas pelos modelos. Neste caso, $\mathcal{M}(\hat{\Gamma}_5^+)$ mostrou-se superior apresentando menos equívocos. Nos demais DoFs os modelos demonstraram coerentes capacidades de generalização.


Figura 25: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C6.



Fonte: Autor.

No cenário C6 observam-se movimentos derivados da mescla da excitação frontal e lateral. Os resultados demonstram alta similaridade entre os modelos e o ASV. Apreende-se, neste cenário, que todos os modelos demonstraram coerência e ótima capacidade de generalização.

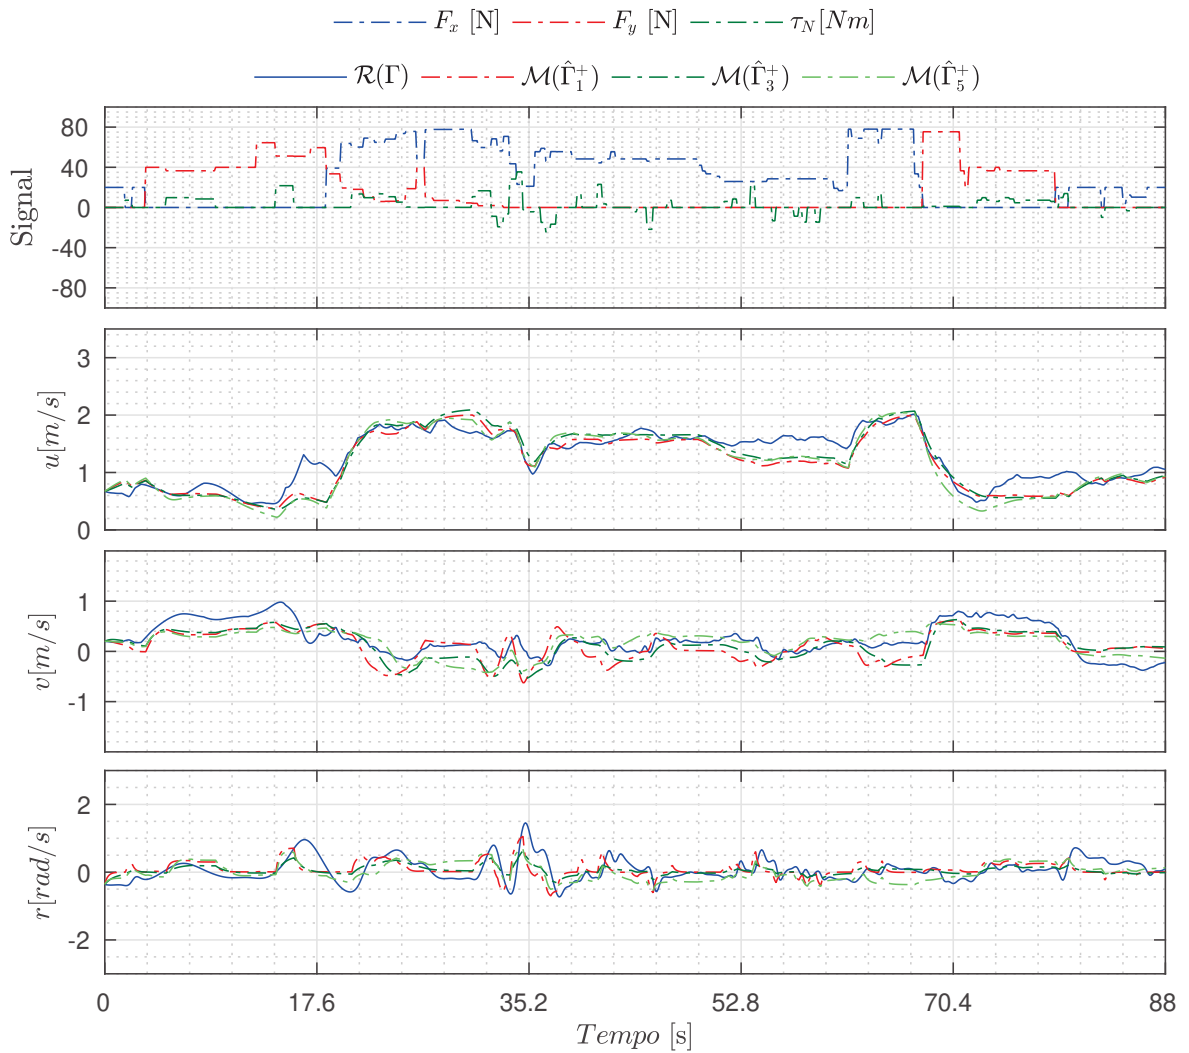
Figura 26: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C7.



Fonte: Autor.

No cenário C7 é possível observar um experimento composto por movimentos frontais de alta velocidade, tradicional *zig-zag* e deslocamentos laterais de alta intensidade. É possível apreender que os modelos possuem comportamentos muito similares à embarcação. Em geral, demonstraram dificuldades de captar dinâmicas muito rápidas em *yaw*, como observadas no início do experimento. Também é possível compreender que em baixos perfis de velocidade de *surge*, os modelos perdem qualidade como ocorrido na parte final do ensaio. Em *sway* percebe-se que $\mathcal{M}(\hat{\Gamma}_1^+)$ apresenta novamente comportamentos oscilatórios quando estimulado o movimento *zig-zag*.

Figura 27: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C8.




Fonte: Autor.

Analisando o cenário C8 nota-se novamente um experimento desafiador com estímulos do sistema de propulsão bem acoplados. De modo geral, os modelos alcançaram comportamentos semelhantes e demonstraram coerência com as velocidades do ASV.

Por fim, em C9 (Figura 28) é possível reafirmar a capacidade de generalização dos modelos, principalmente para grandes variações de velocidades em *surge*. Em *sway* nota-se novamente as pequenas divergências de velocidades, mas o que é razoável em vista da baixa amplitude e possíveis inconsistências proporcionadas pelo sistema de medidas.

Figura 28: Sinais de manobras, trajetória dos estados do ASV e $\mathcal{M}(\hat{\Gamma}_n^+)$ - C9.



Fonte: Autor.

4.3.1 Análise Geral dos Modelos

Na Tabela 13 são exibidos os desempenhos dos modelos $\mathcal{M}(\hat{\Gamma}_n^+)$ para cada cenário proposto, cuja métrica de análise foi o RMSE.

Tabela 13: Análise de desempenho geral de $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1 a C9.


Γ_n^+	C1	C2	C3	C4	C5	C6	C7	C8	C9	Σ
1	0.481	0.490	0.495	0.589	0.429	0.385	0.553	0.495	0.370	4.287
2	0.494	0.434	0.453	0.571	0.429	0.376	0.472	0.453	0.381	4.063
3	0.387	0.456	0.431	0.551	0.422	0.383	0.496	0.431	0.397	3.953
4	0.367	0.520	0.450	0.556	0.446	0.375	0.514	0.450	0.378	4.056
5	0.443	0.524	0.479	0.615	0.433	0.501	0.512	0.479	0.422	4.407

É possível aprender da Tabela 13 que os modelos obtidos com 2 ou mais sinais

mostraram-se superiores ao modelo obtido com apenas um único sinal. Em negrito são evidenciados os melhores resultados de cada cenário. Percebe-se que o desempenho de $\mathcal{M}(\hat{\Gamma}_1^+)$ é o melhor apenas no cenário C9, mas que ainda se mostra menos eficiente que os demais modelos na análise forma geral dos cenários.

Segundo os cenários de análise, o melhor desempenho foi do modelo $\mathcal{M}(\hat{\Gamma}_3^+)$, que inclusive mostrou-se superior aos modelos $\mathcal{M}(\hat{\Gamma}_4^+)$ e $\mathcal{M}(\hat{\Gamma}_5^+)$. Portanto, não sendo válido e indicado a utilização de modelos estimados com mais do que 3 sinais. Esta conclusão torna-se mais evidente na Figura 29, que apresenta o gráfico de distribuição e dispersão do **RMSE**, demonstrando a robustez alcançada por $\mathcal{M}(\hat{\Gamma}_3^+)$, como também a tendência do aprimoramento e deterioração do desempenho dos modelos.

Figura 29: *Boxplot* detalhando o RMSE geral dos modelos $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1 a C9.



Fonte: Autor.

Em sequência a Tabela 14 expõe o **RMSE** dos $\mathcal{M}(\hat{\Gamma}_n^+)$ em cada **DoF**. Nota-se novamente a maior eficiência dos modelos obtidos por múltiplos sinais. Analisando a redução do erro obtida por $\mathcal{M}(\hat{\Gamma}_3^+)$ em relação a $\mathcal{M}(\hat{\Gamma}_1^+)$, verificam-se reduções de 3,73% em *surge*, 3,46% em *sway* e 13,81% em *yaw*. Portanto, demonstrando o aprimoramento provocado pelo aumento da persistência de excitação no experimento de identificação. Neste caso, o **DoF** de guinada foi o que mais se beneficiou.

Tabela 14: Análise de desempenho geral de cada DoF de $\mathcal{M}(\hat{\Gamma}_n^+)$ - C1 a C9.

$\mathcal{M}(\hat{\Gamma}_n^+)$	u [m/s]	v [m/s]	r [rad/s]
1	0.268	0.260	0.304
2	0.249	0.272	0.266
3	0.258	0.251	0.262
4	0.263	0.259	0.271
5	0.277	0.241	0.324

4.3.2 Impacto do número de Sinais: rSOESGOPE x SOESGOPE

A Tabela 15 apresenta a análise do impacto da aplicação de múltiplos sinais projetados pelo método rSOESGOPE. Os modelos estimados com 2 ou mais sinais são comparados com o modelo $\mathcal{M}(\hat{\Gamma}_1^+)$, que sintetiza a metodologia SOESGOPE. Nesta análise foram utilizados a soma do RMSE dos 9 cenários de validação.

Tabela 15: Análise do impacto do número de sinais para a estimação de $\mathcal{M}(\hat{\Gamma}_n^+)$.

-	$\mathcal{M}(\hat{\Gamma}_1^+)$	$\mathcal{M}(\hat{\Gamma}_2^+)$	$\mathcal{M}(\hat{\Gamma}_3^+)$	$\mathcal{M}(\hat{\Gamma}_4^+)$	$\mathcal{M}(\hat{\Gamma}_5^+)$
\sum_{RMSE}	4,2869	4,0628	3,9526	4,0564	4,4067
Redução (%)	—	5,2260	7,7969	5,3768	-2,7952

Os resultados da Tabela 15 demonstram que o método rSOESGOPE foi mais eficiente que o SOESGOPE em 3 dos 4 modelos analisados. Os modelos estimados com 2, 3 e 4 sinais mostraram-se mais eficientes com uma redução do RMSE entre 5,22% a 7,79% aproximadamente. O melhor modelo no estudo foi o modelo $\mathcal{M}(\hat{\Gamma}_3^+)$. O modelo $\mathcal{M}(\hat{\Gamma}_5^+)$ foi o único com desempenho inferior ao modelo do SOESGOPE, o que indica que o acréscimo do 5º sinal não trouxe dinâmicas novas e, sim, reafirmou dinâmicas já excitadas pelos demais sinais projetados.

Em síntese é possível ressaltar os seguintes pontos:

1. A utilização de múltiplos sinais U^\oplus proporcionou modelos mais robustos do que a proposta SOESGOPE;
2. A aplicação de múltiplos sinais de identificação deve ser feita com cautela. O excesso de sinais pode ser prejudicial à eficiência do modelo e promover a excitação de dinâmicas redundantes;
3. O número ideal de sinais é definido quando o acréscimo destes não promove mais melhorias ao desempenho do modelo estimado;
4. Os sinais projetados e o *framework* definido devem ser utilizados apenas em contextos semelhantes. Portanto, alterado o problema novos sinais devem ser projetados e um novo estudo sobre o número de sinais também deve ser realizado.

5 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi apresentada a metodologia **rSOESGOPE**, proposta para a identificação de sistemas sujeitos a incertezas. O método traz uma nova perspectiva para solução do problema a partir do uso de múltiplos sinais de identificação. Através deste artifício busca-se ampliar a capacidade de excitação do experimento e, portanto, proporcionar a estimação de modelos paramétricos mais robustos e confiáveis.

Para alcançar este objetivo, a metodologia foi desenvolvida por três estágios bem definidos. O primeiro estágio ① é dedicado à geração de amostras no torno da estimação inicial do sistema. Possui a finalidade de minimizar as incertezas iniciais sobre o sistema, permitindo a expansão da região de excitação no seu entorno. Posteriormente, o segundo estágio ② é responsável pelo projeto dos sinais **APRBS** que compõe o experimento de identificação. Cada sinal é projetado para excitar uma das amostras específicas do primeiro estágio. Neste caso, o projeto busca otimizar a característica de persistência de excitação e o atendimento às peculiaridades operacionais do sistema. Por fim, o terceiro e último estágio ③ tem a incumbência de aplicar os sinais no sistema real e, posteriormente, realizar a estimação paramétrica a partir dos dados coletados.

Para avaliar o desempenho da metodologia foi utilizado um problema de modelagem do **ASV AERO4River** do tipo catamarã. Esta embarcação ofereceu um cenário propício à avaliação do método, composto por dinâmicas altamente não lineares, forte acoplamento entre os 3 **DoFs** e suscetível a assimetrias estruturais. Logo, constituindo um cenário de incertezas muito oportuno e também desafiador no âmbito do espaço de solução dos sinais e parâmetros.

Analisando os resultados apresentados no Capítulo 4, alguns pontos podem ser enfatizados sobre a aplicabilidade do método **rSOESGOPE**:

1. Configuração do sinal: “demonstrou-se que o estudo para a definição das características do sinal **APRBS** desempenha um papel fundamental na qualidade do sinal projetado. Este estudo permite definir o *trade-off* entre a persistência de

excitação e a resolutividade do problema”;

2. Dimensão dos sinais: “embora sinais APRBS longos com vários estágios forneçam características de excitação mais ricas, o espaço de solução não linear cresce exponencialmente, o que o torna complexo, custoso ou mesmo intratável”;
3. Tempo do experimento: “observa-se que naturalmente os sinais projetados também otimizam o tempo de experimento. Verifica-se que nenhum deles ultrapassa o valor de 30 [s], o que é vantajoso do ponto de vista prático”;
4. Escolha do número de sinais: “a aplicação de múltiplos sinais de identificação deve ser feita com cautela e de forma gradativa. O excesso de sinais pode ser prejudicial à eficiência do modelo e promover a excitação de dinâmicas redundantes”;
5. Desempenho geral dos modelos: “nota-se uma grande semelhança entre os modelos estimados pelo rSOESGOPE e o sistema real. Este fato foi recorrente para todos os modelos, cujo mais eficiente foi o estimado com 3 sinais. Fato que reafirma a conclusão anterior e demonstra que o excesso de sinais pode ser prejudicial”;
6. SOESGOPE x rSOESGOPE: “os resultados demonstraram que o rSOESGOPE foi mais eficiente que o SOESGOPE em 3 dos 4 modelos analisados. Os modelos estimados com 2, 3 e 4 sinais demonstraram uma redução do RMSE entre 5,22% a 7,79% aproximadamente. O modelo com 5 sinais foi o único com desempenho inferior ao modelo do SOESGOPE, o que indica que o acréscimo do 5º sinal não acrescentou dinâmicas novas e, sim, reafirmou dinâmicas já excitadas pelos demais sinais projetados”.
7. Análise de Robustez: “confirma-se pela similaridade entre os modelos estimados com múltiplos sinais e o ASV que o método rSOESGOPE assegurou a robustez prometida. Nota-se que o RMSE do melhor modelo obtido não ultrapassa o valor de 0,258 [m/s] e 0,262 [rad/s], o que é muito satisfatório para os resultados em ambientes abertos sem controle das condições do experimento”.

Por fim, é possível compreender a validade do conceito rSOESGOPE, cujos modelos produzidos no estudo de caso mostraram-se confiáveis em cenários diversos. Nota-se que o método permitiu minimizar o impacto das incertezas iniciais sobre o sistema e projetar um experimento de identificação que resultasse na estimação de modelos robustos. Logo, os modelos são capazes de projetar estratégias de controle robustas e

sistemas tolerantes a falhas para o uso de ASVs em ambientes mais hostis e exigentes. Um vídeo esquemático da aplicação da técnica está disponível em: <<https://www.youtube.com/watch?v=OG0gr67YMNg>>.

5.1 Trabalhos Futuros

O êxito do método rSOESGOPE promove o ensejo pelo desenvolvimento de novos trabalhos na área de Identificação de Sistemas e da Teoria de Controle Robusto. Neste intuito são propostos os seguintes estudos como continuidade do método:

- **Estudo 1:** Aplicação da metodologia na identificação de outros sistemas sujeitos a incertezas;
- **Estudo 2:** Desenvolvimento de novas estratégias de identificação a partir do conceito rSOESGOPE;
- **Estudo 3:** Comparação de meta-heurísticas aplicadas no conceito rSOESGOPE para solução de problemas reais;
- **Estudo 4:** Desenvolvimento de estratégias de controle robusto a partir do conceito rSOESGOPE;

APÊNDICE A - SISTEMAS DE COORDENADAS


Para a descrição do comportamento dinâmico de um corpo-rígido vários sistemas de coordenadas são necessários para a adequada representação do posicionamento e orientação do corpo no espaço e no tempo.

Basicamente necessita-se de: um referencial inercial fixo (\mathcal{F}^i) e um referencial fixo no veículo (\mathcal{F}^v), ambos relacionados por uma translação que permite a descrição do posicionamento do corpo; três referenciais (\mathcal{F}^{v2} , \mathcal{F}^{v1} e \mathcal{F}^b) relacionados a \mathcal{F}^v por rotações a fim descrever a orientação do corpo através dos ângulos (BEARD; MCLAIN, 2012).

Os ângulos que definem as orientações relativas aos *frames* \mathcal{F}^b , \mathcal{F}^{v2} e \mathcal{F}^{v1} são os ângulos de rolagem (ϕ), arfagem (θ) e guinada (ψ), respectivamente. Estes descrevem a orientação do corpo-rígido e são comumente conhecidos como ângulos de Euler (BEARD; MCLAIN, 2012). Ao longo da tese assumi-se que a Terra é plana e não rotativa, uma suposição válida para as embarcações marinhas de modo geral (FOSSEN, 2011).

A.1 Referencial Inercial: \mathcal{F}^i

O sistema de coordenadas inercial é um sistema de coordenadas de “Terra-fixa” com sua origem no local de residência definido. Como representado na Figura 30, o vetor \mathbf{i}^i é direcionado para o Norte, \mathbf{j}^i para o Leste, enquanto \mathbf{k}^i é direcionado para o centro da Terra ou para abaixo. Este sistema de coordenadas é por vezes referido como um sistema de coordenadas de referência *North-East-Down* (NED) (BEARD; MCLAIN, 2012).

Figura 30: *Frames* Inercial e do Veículo

Fonte: Autor.

No contexto de veículos marinhos é comum adotar que a direção Norte seja referida à direção x inercial, a Leste referida à direção inercial y , e a direção para baixo referida como o inercial na direção z (FOSSSEN, 2011).

A.2 Referencial do Veículo: \mathcal{F}^v

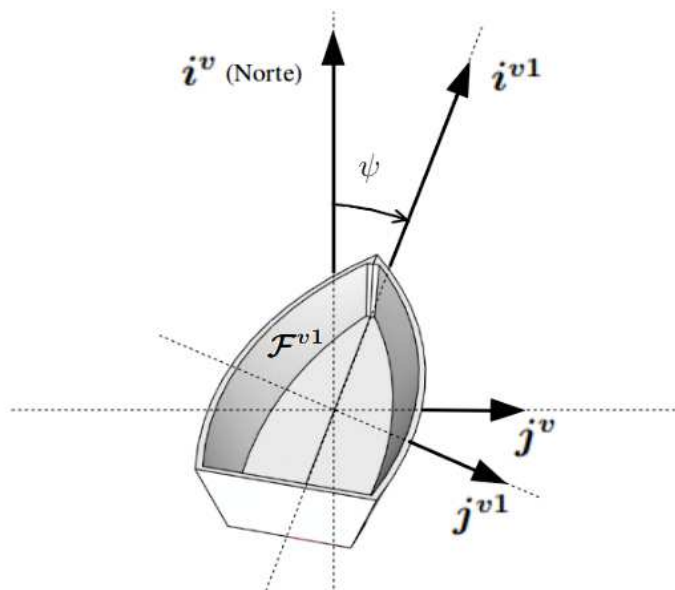
A origem do sistema de coordenadas do veículo \mathcal{F}^v está no centro de massa do corpo-rígido. No entanto, os eixos de \mathcal{F}^v estão alinhados com o eixo do referencial inercial \mathcal{F}^{i1} . Em outras palavras, o vetor unitário i^v aponta para o Norte, j^v aponta para o Leste e k^v para o centro da Terra, como apresenta a Figura 30.

A.3 Referencial do Corpo-rígido: \mathcal{F}^{v1}

A origem da estrutura do sistema de coordenadas \mathcal{F}^{v1} é idêntica à estrutura de \mathcal{F}^v , com o detalhe de que é rotacionado no sentido positivo da mão-direita sobre k_b pelo ângulo de guinada (ψ).

Na ausência de rotações adicionais, i^{v1} aponta a proa da embarcação, j^{v1} aponta a estibordo da embarcação e k^{v1} está alinhado com k^v e aponta para à Terra. Enfim, a Figura 31 apresenta o *frame* do veículo 1.


¹Os *frames* inercial e do veículo estão relacionados por uma translação, enquanto os demais *frames* (\mathcal{F}^{v1} , \mathcal{F}^{v2} e \mathcal{F}^b) estão relacionados por rotações.

Figura 31: Sistema de Coordenadas: \mathcal{F}^{v1} 

Fonte: Autor.

A.4 Referencial do Corpo-rígido: \mathcal{F}^{v2}

A origem do sistema de coordenadas \mathcal{F}^{v2} também encontra-se no centro de massa do corpo-rígido. Este *frame* é obtido rotacionando \mathcal{F}^{v1} sobre o eixo j^{v1} pelo ângulo de inclinação θ . O vetor unitário i^{v2} aponta o nariz do corpo-rígido, j^{v2} aponta a ala direita, e k^{v2} indica a região inferior do veículo, como mostra a Figura 32.


Figura 32: Sistema de Coordenadas: \mathcal{F}^{v2} 

Fonte: Autor.

A.5 Referencial do Corpo-rígido: \mathcal{F}^b

Por fim, tem-se o sistema de coordenadas do corpo \mathcal{F}^b obtido rotacionando a estrutura \mathcal{F}^{v2} para a direita sobre i^{v2} pelo ângulo de rotação ϕ . Portanto, a origem é o centro de massa, i^b aponta o nariz da estrutura do corpo-rígido, j^b aponta o lado direita e k^b a região inferior do veículo. A estrutura do corpo é apresentada na Figura 33.

Figura 33: Sistema de Coordenadas: \mathcal{F}^b



Fonte: Autor.

APÊNDICE B - CINEMÁTICA E DINÂMICA DE CORPO RÍGIDO

B.1 Cinemática do Corpo Rígido

A cinemática é um ramo da mecânica clássica que descreve o movimento de pontos, corpos e sistemas de corpos sem considerar as forças que os levam a mover-se (BEARD; MCLAIN, 2012).

De forma sucinta, o estudo da cinemática permite a obtenção de transformações que resultem em equações que relacionam taxas de variação entre os *frames* \mathcal{F}^b e \mathcal{F}^i . Portanto, com a finalidade de expressar a relação entre as velocidades nos *frames* \mathcal{F}^b e \mathcal{F}^i , será necessário obter as relações entre as velocidades linear e angular.

Matematicamente esta relações podem ser expressas pela seguinte notação para embarcações marinhas (FOSSEN et al., 1994):

$$\dot{\boldsymbol{\eta}} = \mathbf{J}(\boldsymbol{\eta})\boldsymbol{\nu}, \quad (\text{B.1})$$

onde $\boldsymbol{\eta}$ representa os estados de posição e atitude angular da embarcação, $\boldsymbol{\nu}$ os estados de velocidade; $\mathbf{J}(\boldsymbol{\eta})$ a matriz Jacobiana que relaciona os estados de \mathcal{F}^b a \mathcal{F}^i .

Especificamente tratando $\boldsymbol{\eta} = [\boldsymbol{\eta}_1 \ \boldsymbol{\eta}_2]^T$ e $\boldsymbol{\nu} = [\boldsymbol{\nu}_1 \ \boldsymbol{\nu}_2]^T$ a Equação B.1 torna-se:

$$\begin{bmatrix} \dot{\boldsymbol{\eta}}_1 \\ \dot{\boldsymbol{\eta}}_2 \end{bmatrix} = \begin{bmatrix} \mathbf{J}_1(\boldsymbol{\eta}_2) & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{J}_2(\boldsymbol{\eta}_2) \end{bmatrix} \begin{bmatrix} \boldsymbol{\nu}_1 \\ \boldsymbol{\nu}_2 \end{bmatrix}, \quad (\text{B.2})$$

onde $\mathbf{J}_1(\boldsymbol{\eta}_2)$ e $\mathbf{J}_2(\boldsymbol{\eta}_2)$ são as matrizes que relacionam os *frames* e serão especificadas em sequência. Adicionalmente: $\boldsymbol{\nu}_1$ e $\boldsymbol{\nu}_2$ representam as velocidades lineares e angulares, respectivamente; $\boldsymbol{\eta}_1$ as posições do corpo no *frame* \mathcal{F}^i e $\boldsymbol{\eta}_2$ os ângulos de Euler em \mathcal{F}^b .

B.1.1 Transformação da Velocidade Linear

A relação entre as velocidades lineares de \mathcal{F}^b a \mathcal{F}^i , segundo a literatura é representada por (FOSSSEN et al., 1994):

$$\dot{\eta}_1 = \mathbf{J}_1(\eta_2)\nu_1, \quad (\text{B.3})$$

onde $\mathbf{J}_1(\eta_2)$ consiste na seguinte expressão:

$$\mathbf{J}_1(\eta_2) = \begin{pmatrix} c_\theta c_\psi & s_\phi s_\theta c_\psi - c_\phi s_{psi} & c_\phi s_\theta c_\psi + s_\phi s_{psi} \\ c_\theta s_\psi & s_\phi s_\theta s_\psi + c_\phi c_{psi} & c_\phi s_\theta s_\psi - s_\phi c_{psi} \\ -s_\theta & s_\phi c_\theta & c_\phi s_\theta \end{pmatrix} \quad (\text{B.4})$$

onde $c_x = \cos(x)$ e $s_x = \sin(x)$.

Expandindo a Equação B.3 tem-se a relação entre velocidades em:

$$\begin{pmatrix} \dot{x} \\ \dot{y} \\ \dot{z} \end{pmatrix} = \begin{pmatrix} c_\theta c_\psi & s_\phi s_\theta c_\psi - c_\phi s_{psi} & c_\phi s_\theta c_\psi + s_\phi s_{psi} \\ c_\theta s_\psi & s_\phi s_\theta s_\psi + c_\phi c_{psi} & c_\phi s_\theta s_\psi - s_\phi c_{psi} \\ -s_\theta & s_\phi c_\theta & c_\phi s_\theta \end{pmatrix} \begin{pmatrix} u \\ v \\ w \end{pmatrix}. \quad (\text{B.5})$$

Para mais informações orienta-se recorrer à literatura: (FOSSSEN, 2011).

B.1.2 Transformação da Velocidade Angular

Quanto à transformação das velocidades angulares entre os *Frames*, esta é expressa por (FOSSSEN et al., 1994):

$$\dot{\eta}_2 = \mathbf{J}_2(\eta_2)\nu_2, \quad (\text{B.6})$$

onde $\mathbf{J}_2(\eta_2)$ consiste em:

$$\mathbf{J}_2(\eta_2) = \begin{pmatrix} 1 & \sin(\phi)\tan(\theta) & \cos(\phi)\tan(\theta) \\ 0 & \cos(\phi) & -\sin(\phi) \\ 0 & \sin(\phi)\sec(\theta) & \cos(\phi)\sec(\theta) \end{pmatrix} \quad (\text{B.7})$$

Por fim, expandindo a Equação B.6 tem-se a equação diferencial que expressa a


relação entre as velocidades angulares:

$$\begin{pmatrix} \dot{\phi} \\ \dot{\theta} \\ \dot{\psi} \end{pmatrix} = \begin{pmatrix} 1 & \sin(\phi)\tan(\theta) & \cos(\phi)\tan(\theta) \\ 0 & \cos(\phi) & -\sin(\phi) \\ 0 & \sin(\phi)\sec(\theta) & \cos(\phi)\sec(\theta) \end{pmatrix} \begin{pmatrix} p \\ q \\ r \end{pmatrix}. \quad (\text{B.8})$$

B.2 Dinâmica do Corpo Rígido

Para derivar as equações dinâmicas de movimento de um corpo rígido, a literatura apresenta duas metodologias: a mecânica newtoniana e lagrangiana (FOSSSEN et al., 1994). Neste trabalho, a mecânica newtoniana foi utilizada para este desenvolvimento. A seguir na Figura 34 tem-se a exemplificação de um corpo-rígido genérico.

Figura 34: Ilustração do Corpo rígido



Fonte: Autor.

Antes da derivação das equações admite-se que: (X_0, Y_0, Z_0) é o centro de coordenadas do corpo-rígido deslocado do centro de gravidade (X_{CG}, Y_{CG}, Z_{CG}) por \mathbf{r}_G ; o corpo-rígido desloca-se com movimento angular ω ao entorno do centro de coordenadas Terra-fixa (X, Y, Z) do tipo inercial.

B.2.1 Movimento de Translação

As equações relativas ao movimento de translação são obtidas através da aplicação a segunda lei de Newton (FOSSSEN et al., 1994):

$$m \frac{d\mathbf{v}_c}{dt_i} = \mathbf{f}_0, \quad (\text{B.9})$$

em que m representa a massa do corpo-rígido, \mathbf{v}_c o vetor de velocidades em \mathcal{F}^b , $\frac{d}{dt_i}$ a derivada no tempo em \mathcal{F}^i e \mathbf{f}_0 o somatório de forças externas atuantes no corpo-rígido.

Para obter a expressão geral de translação deve-se considerar duas questões primordiais: a necessidade da consideração do deslocamento do centro de coordenadas do corpo e que o vetor de velocidades baseia-se no *frame* do corpo.

Primeiramente, como as velocidades são tomadas em \mathcal{F}^b e a Equação B.9 se refere a \mathcal{F}^i , deve-se mudar o sistema de coordenadas da derivada da velocidade tomada em \mathcal{F}^i para o referencial do corpo (FOSSSEN et al., 1994):

$$\frac{d\mathbf{v}_c}{dt_i} = \frac{d\mathbf{v}_c}{dt_b} + \boldsymbol{\omega}_{b/i} \times \mathbf{v}_c, \quad (\text{B.10})$$

que substituindo a nova relação na Equação B.9 chega-se a

$$m \left(\frac{d\mathbf{v}_c}{dt_b} + \boldsymbol{\omega}_{b/i} \times \mathbf{v}_c \right) = \mathbf{f}_0, \quad (\text{B.11})$$

onde $\boldsymbol{\omega}_{b/i}$, nas Equações B.10 e B.11, se refere à velocidade angular do corpo-rígido em relação a \mathcal{F}^i .

Ademais, como o centro de coordenadas do corpo está deslocado do centro de gravidade, logo é necessário considerar a seguinte relação (FOSSSEN et al., 1994):

$$\dot{\mathbf{v}}_c = \dot{\mathbf{v}}_0 + \boldsymbol{\omega}_{b/i} \times \mathbf{r}_G + \boldsymbol{\omega} \times \dot{\mathbf{r}}_G. \quad (\text{B.12})$$

Por fim, combinando a Equação B.12 a Equação B.13, chega-se à expressão do movimento de translação geral de um corpo rígido:

$$m(\dot{\mathbf{v}}_0 + \boldsymbol{\omega}_{b/i} \times \mathbf{r}_G + \boldsymbol{\omega} \times \dot{\mathbf{r}}_G) = \mathbf{f}_0 \quad (\text{B.13})$$

B.2.2 Movimento de Rotação

Quanto ao equacionamento do movimento de rotação, similar metodologia pode utilizada. Partindo da segunda lei de Newton:

$$m \frac{d\mathbf{h}}{dt_i} = \mathbf{m}_0, \quad (\text{B.14})$$

em que \mathbf{h} representa o vetor de momento angular e \mathbf{m}_0 a soma de todos os momentos externos aplicados ao corpo-rígido, é possível obter a expressão que representa o movimento rotacional de um corpo rígido (FOSSEN et al., 1994):

$$\mathbf{I}_0 \dot{\boldsymbol{\omega}} + \boldsymbol{\omega} \times (\mathbf{I}_0 \boldsymbol{\omega}) + m \mathbf{r}_G \times (\dot{\mathbf{v}}_0 + \boldsymbol{\omega} \times \mathbf{v}_0) = \mathbf{m}_0. \quad (\text{B.15})$$

Adiciona-se que \mathbf{I}_0 na Equação B.15 representa o tensor de inércia referido ao centro de coordenada com origem em $(X_0 Y_0 Z_0)$ referida na Figura 34.

$$\mathbf{I}_0 = \begin{bmatrix} I_{xx} & I_{xy} & I_{xz} \\ I_{yx} & I_{yy} & I_{yz} \\ I_{zx} & I_{zy} & I_{zz} \end{bmatrix} \quad (\text{B.16})$$

B.3 Equações Dinâmicas de um Corpo Rígido

Fundamentalmente, as equações dos movimentos de translação e rotação permitem a descrição da relação entre forças e momentos aplicados ao corpo e, por consequência, a descrição do movimento produzido. Deste modo, associando as equações B.13 e B.15, tem-se a representação do movimento dinâmico geral de um corpo-rígido expresso por (FOSSEN, 2011):

$$\begin{aligned} m(\dot{\mathbf{v}}_0 + \boldsymbol{\omega}_{b/i} \times \mathbf{r}_G + \boldsymbol{\omega} \times \dot{\mathbf{r}}_G) &= \mathbf{f}_0 \\ \mathbf{I}_0 \dot{\boldsymbol{\omega}} + \boldsymbol{\omega} \times (\mathbf{I}_0 \boldsymbol{\omega}) + m \mathbf{r}_G \times (\dot{\mathbf{v}}_0 + \boldsymbol{\omega} \times \mathbf{v}_0) &= \mathbf{m}_0. \end{aligned} \quad (\text{B.17})$$

A fim de que o conjunto de equações expressos em (B.17) seja mais palpável e adequada ao contexto do trabalho, basta aplicar notações típicas do meio (FOSSEN, 2011):

- $\mathbf{f}_0 = [X, Y, Z]^T$ e $\mathbf{m}_0 = [K, M, N]^T$
- $\mathbf{v}_0 = [u, v, w]^T$ e $\boldsymbol{\omega} = [p, q, r]^T$
- $\mathbf{r}_G = [x_G, y_G, z_G]^T$.

Assim, realizando algumas manipulações chega-se ao seguinte conjunto de equações representando a dinâmica geral do corpo rígido, no contexto desejado (LEWIS, 1988):

$$\begin{aligned}
m[\dot{u} - vr + wq - x_G(q^2 + r^2) + y_G(pq - \dot{r}) + z_G(pr + \dot{q})] &= X \\
m[\dot{v} - wp + ur - y_G(r^2 + p^2) + z_G(qr - \dot{p}) + x_G(qp + \dot{r})] &= Y \\
m[\dot{w} - uq + vp - z_G(p^2 + q^2) + x_G(rp - \dot{q}) + y_G(rq + \dot{p})] &= Z \\
I_x \dot{p} + (I_z - I_y)qr - (\dot{r} - pq)I_{xz} + (r^2 - q^2)I_{yz} + (pr - \dot{q})I_{xy} \\
&\quad + m[y_G(\dot{w} - uq + vp) - z_G(\dot{v} - wp + ur)] = K \\
I_y \dot{q} + (I_x - I_z)rp - (p + qr)I_{xy} + (p^2 - r^2)I_{zx} + (qp - \dot{r})I_{yz} \\
&\quad + m[z_G(\dot{u} - vr + wq) - x_G(\dot{w} - uq + vp)] = M \\
I_z \dot{r} + (I_y - I_x)pq - (q + rp)I_{yz} + (q^2 - p^2)I_{xy} + (rq - \dot{p})I_{zx} \\
&\quad + m[x_G(\dot{v} - wp + ur) - y_G(\dot{u} - vr + wq)] = N
\end{aligned} \tag{B.18}$$

Especificamente, as três primeiras equações representam o movimento de translação, enquanto as três últimas o movimento de rotação. As forças externas ao corpo-rígido são apresentadas por $[X, Y, Z]$, enquanto os momentos externos aplicados são expressos por $[K, M, N]$.

APÊNDICE C - METAHEURÍSTICA APLICADA NO OSD

Este Apêndice é dedicado a apresentação de aspectos gerais para a aplicação das metaheurísticas no conceito **rSOESGOPE**: seção (C.1) apresenta em detalhes a representação do sinal **APRBS**, seção (C.2) descreve critérios para o ajuste da configuração do sinal; seção (C.3) apresenta o algoritmo do **PSO** utilizado no método **rSOESGOPE**.

C.1 Representação do Sinal

Um passo fundamental para aplicar qualquer meta-heurística em um problema de **OSD** é a definição do sinal e sua representação. Essas definições determinam a composição dos indivíduos na técnica e também a dimensão do espaço de busca.

No método **rSOESGOPE**, o sinal escolhido foi o *Amplitude-Modulated Pseudo-Random Binary Signal* (**APRBS**) que permite a incorporação de restrições operacionais, ou de segurança, com a otimização da persistência de excitação (**HONÓRIO et al., 2018; NOURI; VALADI; ASGHARIAN, 2018; LUO et al., 2013**). É um fato que, em princípio, sinais não planejados não podem garantir.

Nesta estratégia o **APRBS** gera um vetor de codificação $\Xi_k \in \mathbb{R}^{2 \times k}$, definido por k estágios ou pares de (amplitude, intervalo de tempo). Matematicamente, representado por (**NOURI; VALADI; ASGHARIAN, 2018**):

$$\Xi_k = \left[t_1, t_2, \dots, t_k, A_1, A_2, \dots, A_k \right] \quad (\text{C.1})$$

onde $[A_1, A_2, \dots, A_k]$ são as amplitudes e $[t_1, t_2, \dots, t_k]$ os tempos de permuta de cada respectiva amplitude A_i . Portanto, um sinal **APRBS** com 6 estágios produz um sinal codificado $\Xi_6 \in \mathbb{R}^{12}$ ou $\Xi_6 = [A_1, \dots, A_6, t_1, \dots, t_6]$. A Figura 35 mostra um exemplo deste, onde a realização desses parâmetros $\mathbf{u}(\Xi_6)$ é marcada pela linha preta.




Figura 35: Exemplo de Parametrização do Sinal APRBS.

C.2 Configuração do Sinal e População da Metaheurística

Conforme a Equação (C.1), o desafio proposto às metaheurísticas em geral é a determinação dos elementos de Ξ_k , cuja dimensão depende do número de estágios k .

Definir o número de estágios não é uma tarefa trivial. Como o objeto de estudo pode ser variado, estabelecer uma regra geral é uma tarefa difícil. Além disso, sabe-se que quanto maior o número de estágios do sinal, maior a oportunidade de produzir sinais com ampla faixa de amplitude e frequência. Porém, quanto maior o espaço de solução, maior o esforço exigido pela meta-heurística e, deste modo, maior deve ser o número de indivíduos na população.

Para fazer frente a esta situação, aconselha-se realizar testes sistemáticos como o apresentado na Tabela 16. A análise da composição do número de cenários e indivíduos é fundamental para a solução do problema. Atitudes como esta permitem analisar o comportamento das configurações e estabelecer uma relação de compromisso realizável. Fato que conduz a definições mais assertivas e adequadas ao problema, auxiliando o emprego da meta-heurística da solução do OSD.

Tabela 16: Análise do número de estágios e indivíduos.

N_{pop}	Ξ_1	Ξ_2	...	Ξ_n
05	a	b	...	c
10	d	e	...	f
...
N	g	h	...	i

C.3 Particle Swarm Optimization

O método *Particle Swarm Optimization* (PSO) foi uma proposta desenvolvida por James Kennedy (psicólogo social) e Russell Eberhart (engenheiro eletricitista) em 1995

(KENNEDY; EBERHART, 1995). Nesta proposta, o objetivo inicial era produzir inteligência computacional explorando análogos simples da interação social, ao invés de puramente habilidades cognitivas (POLI; KENNEDY; BLACKWELL, 2007).

As primeiras simulações do método foram influenciadas pelo trabalho de Heppner e Grenander (HEPPNER; GRENANDER, 1990) que propuseram um modelo não linear estocástico do comportamento de um bando de pássaros à procura de milho. Baseado neste comportamento, logo as primeiras simulações culminaram no método conhecido como Otimização de Enxame de Partículas (POLI; KENNEDY; BLACKWELL, 2007).

Conceito do Método

O método desenvolvido basicamente utiliza a capacidade de busca de uma população de partículas que voam pelo hiperespaço do problema. Cada partícula do enxame, em específico, representa uma solução do problema e possui velocidade própria que a permite movimentar-se pelo domínio de estudo. Em busca pela melhor solução, a cada iteração a velocidade das partículas é ajustada estocasticamente conforme a melhor solução da própria partícula e de sua vizinhança. Esta mensuração da qualidade da população de partículas é derivada da avaliação de uma função de aptidão definida pelo usuário. Acrescenta-se que o movimento de cada partícula evolui naturalmente para uma solução mínima ou quase ótima. A palavra “enxame” vem dos movimentos irregulares das partículas no espaço problemático, agora mais parecido com um enxame de mosquitos do que com um rebanho de pássaros ou um cardume de peixes (POLI; KENNEDY; BLACKWELL, 2007; VALLE et al., 2008).

Algoritmo do Método

A representação do método sofreu algumas modificações desde a proposta inicial. O algoritmo apresentado a seguir consiste na versão original com as modificações sugeridas por Mezura-Montes e Coello (2011) e Pedersen (2010). A versão apresentada possui cinco etapas bem definidas e admite uma população com n indivíduos de dimensão m (PEDERSEN, 2010):

1. Distribuição (inicialização) das partículas $\vec{x} = [\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n]$ pelo espaço de busca e definição das velocidades $\vec{v} = [\vec{v}_1, \vec{v}_2, \dots, \vec{v}_n]$ iniciais de cada partícula;
2. Avaliação das partículas do enxame através da função objetivo. Esta avaliação determina a aptidão (*fitness*) de cada indivíduo e proporciona uma base para o

movimento de todo o enxame. Nesta etapa também são atualizadas a posição dos melhores vizinhos $\vec{p} \in \mathbb{R}^m$ de cada partícula e melhor partícula de todo o enxame $\vec{g} \in \mathbb{R}^m$;

3. Determinação de novas velocidades às partículas com base: na velocidade atual, nas melhores localizações individuais e de seus vizinhos. Nesta etapa também ocorre a verificação e manutenção da velocidade calculada nos limites estabelecidos;
4. Movimentação de cada partícula ou deslocamento no espaço de busca. Nesta etapa também ocorre a verificação e manutenção da localização das partículas dentro dos limites estabelecidos;
5. Retorno à etapa ② até que o algoritmo atinja um critério de parada estabelecido (Ex.: número de iterações, *fitness* mínimo atingido, etc.).

Do ponto de vista matemático as etapas ③ e ④ ainda carecem de mais informações. O cálculo das novas velocidades na etapa ③ é realizado da seguinte maneira (PEDERSEN, 2010):

$$\vec{v}_i \leftarrow \omega \cdot \vec{v}_i + \mathbf{y}_1 \cdot \phi_1 \cdot (\vec{p}_i - \vec{x}_i) + \mathbf{y}_2 \cdot \phi_2 \cdot (\vec{p}_i - \vec{x}_i) \quad (\text{C.2})$$

É possível observar na Equação (C.2) que o cálculo das velocidades da partícula é dependente da: velocidade atual ponderada por $\omega \in \mathbb{R}^n$, denominado peso de inércia; diferença entre a posição atual e a melhor posição obtida pela partícula; diferença entre a posição atual e a melhor posição das partículas vizinhas. Também é possível notar a presença de ϕ_1 e $\phi_2 \in \mathbb{R}^m$ que são vetores aleatórios com distribuição normal entre [0,1] e das ponderações \mathbf{y}_1 e $\mathbf{y}_2 \in \mathbb{R}^m$ que representam a ponderação da dinâmica social entre a partícula e sua vizinhança.

Quanto ao cálculo da etapa ④ a atualização é feita pela seguinte expressão (PEDERSEN, 2010):

$$\vec{x}_i \leftarrow \vec{x}_i + \vec{v}_i \quad (\text{C.3})$$

Configuração do PSO

O PSO descrito acima antes de aplicado necessita ser configurado, ajustando parâmetros básicos e definindo o critério de parada. Observando o algoritmo nota-se que o número de parâmetros é pequeno. Basicamente é necessário definir: o tamanho da população n , peso de inércia ω , fatores de aceleração y_1 e y_2 , bem como o critério de parada. Na Tabela 17 têm-se as informações da configuração do PSO utilizadas durante o trabalho.

Tabela 17: Configuração PSO

Parâmetro	Definição
n° de Partículas	Estudo empírico
y_1 (Peso do auto-ajuste)	1,49
y_2 (Peso do Ajuste Social)	1,49
ω (Peso de Inércia)	Ajuste adaptativo
Critério de Parada	n° de Iterações

Conforme já descrito, recomenda-se definir o número de partículas através de um estudo empírico, como apresentado no Capítulo 4. Neste caso, as partículas foram definidas analisando o comportamento do algoritmo conforme o aumento do número de partículas e influência no número de estágios k .

No que trata dos pesos y_1 e y_2 adotou-se o valor de 1,49. De acordo com (VALLE et al., 2008) $y_1 + y_2$ não deve ultrapassar 4,0, o que pode trazer problemas de convergência e oscilação excessiva.

Quanto ao peso de inércia ω adotou-se a técnica de ajuste adaptativo. Esta abordagem é muito útil, pois permite a utilização de um valor inicialmente mais alto, aumentando a movimentação às partículas e, portanto, as chances de encontrar a vizinhança do ótimo global mais rápido. Uma vez que a região ideal é encontrada, o valor do peso da inércia pode ser reduzido, restringindo a busca (VALLE et al., 2008). Em nosso caso, utilizou o intervalo de variação de ω de $[0.1,1.1]$.

Enfim, a definição do critério de parada foi determinada analisando o comportamento do algoritmo. Após algumas observações percebeu-se que 100 iterações mostrou-se um valor adequado para a metodologia em geral.

REFERÊNCIAS

- ABKOWITZ, M. A. *Lectures on Ship Hydrodynamics - Steering and Maneuverability*. [S.l.]: TechnicalReport Hy-5, Hydro- and Aerodynamic's Laboratory, Lyngby, Denmark, 1964.
- ANNERGREN, M. et al. Application-oriented input design in system identification: Optimal input design for control [applications of control]. *IEEE Control Systems Magazine*, IEEE, v. 37, n. 2, p. 31–56, 2017.
- ÅSTRÖM, K. J.; HÄGGLUND, T. Pid control. *IEEE Control Systems Magazine*, v. 1066, n. 033X/06, 2006.
- ÅSTRÖM, K. J.; WITTENMARK, B. *Adaptive control*. [S.l.]: Courier Corporation, 2013.
- BANKS, J. et al. A stable partitioned fsi algorithm for rigid bodies and incompressible flow. part i: Model problem analysis. *Journal of Computational Physics*, 11 2016.
- BEARD, R. W.; MCLAIN, T. W. *Small unmanned aircraft: Theory and practice*. [S.l.]: Princeton university press, 2012.
- BECK, E. et al. SeaWASP: A small waterplane area twin hull autonomous platform for shallow water mapping. *Marine Technology Society Journal*, Marine Technology Society, v. 43, n. 1, p. 6–12, 2009.
- BRUNETTI, F. *Mecânica dos fluidos* . [S.l.]: Pearson Educación, 2008.
- BYRD, R. H.; GILBERT, J. C.; NOCEDAL, J. A trust region method based on interior point techniques for nonlinear programming. *Mathematical programming*, Springer, v. 89, n. 1, p. 149–185, 2000.
- CACCIA, M.; BRUZZONE, G.; BONO, R. A practical approach to modeling and identification of small autonomous surface craft. *IEEE Journal of Oceanic Engineering*, IEEE, v. 33, n. 2, p. 133–145, 2008.
- CHNIB, E. et al. Decoupled control of a twin hull-based unmanned surface vehicle using a linear parameter varying approach. In: *10th International Conference on Mechatronics and Control Engineering*. [S.l.: s.n.], 2021.
- CRUZ, N. et al. Zarco-an autonomous craft for underwater surveys. *7th Geomatic Week*, 2007.
- CURCIO, J.; LEONARD, J.; PATRIKALAKIS, A. Scout-a low cost autonomous surface platform for research in cooperative autonomy. In: IEEE. *Proceedings of OCEANS 2005 MTS/IEEE*. [S.l.], 2005. p. 725–729.

- DENG, F.; YANG, H.-L.; WANG, L.-J. Adaptive unscented kalman filter based estimation and filtering for dynamic positioning with model uncertainties. *International Journal of Control, Automation and Systems*, Springer, v. 17, n. 3, p. 667–678, 2019.
- DONG, Z. et al. Parameter identification of unmanned marine vehicle manoeuvring model based on extended kalman filter and support vector machine. *International Journal of Advanced Robotic Systems*, SAGE Publications Sage UK: London, England, v. 16, n. 1, p. 1729881418825095, 2019.
- FANG, K.; SHENTON, A. Constrained optimal test signal design for improved prediction error. *IEEE Transactions on Automation Science and Engineering*, IEEE, v. 11, n. 4, p. 1191–1202, 2013.
- FEDYAEVSKY, K.; SOBOLEV, G. Control and stability in ship design. 1964.
- FERNANDES, D. d. A. et al. Output feedback motion control system for observation class rovs based on a high-gain state observer: Theoretical and experimental results. *Control Engineering Practice*, Elsevier, v. 39, p. 90–102, 2015.
- FOSSSEN, T. I. *Nonlinear modelling and control of underwater vehicles*. [S.l.]: Fakultet for informasjonsteknologi, matematikk og elektroteknikk, 1991.
- FOSSSEN, T. I. Marine control systems—guidance, navigation, and control of ships, rigs and underwater vehicles. *Marine Cybernetics, Trondheim, Norway, Org. Number NO 985 195 005 MVA, www.marinecybernetics.com, ISBN: 82 92356 00 2*, 2002.
- FOSSSEN, T. I. *Handbook of marine craft hydrodynamics and motion control*. [S.l.]: John Wiley & Sons, 2011.
- FOSSSEN, T. I. et al. *Guidance and control of ocean vehicles*. [S.l.]: Wiley New York, 1994. v. 199.
- GIANNAKIS, G. B.; SERPEDIN, E. A bibliography on nonlinear system identification. *Signal Processing*, Elsevier, v. 81, n. 3, p. 533–580, 2001.
- HAN, J. et al. Precision navigation and mapping under bridges with an unmanned surface vehicle. *Autonomous Robots*, Springer, v. 38, n. 4, p. 349–362, 2015.
- HEPPNER, F.; GRENDER, U. A stochastic nonlinear model for coordinated bird flocks. *The ubiquity of chaos*, AAAs Publications Washington, DC, v. 233, p. 238, 1990.
- HERRERO, E. R.; GONZALEZ, F. J. V. Two-step identification of non-linear manoeuvring models of marine vessels. *Ocean Engineering*, Elsevier, v. 53, p. 72–82, 2012.
- HOLZAPFEL, F. Online parameter estimation and optimal input design.
- HOLZAPFEL, F. Online parameter estimation and optimal input design. In: *Mathematical Modeling and Scientific Computing: Focus on Complex Processes and Systems 2020*. [S.l.: s.n.], 2020. p. 128–139.

- HONÓRIO, L. M. et al. Persistently-exciting signal generation for optimal parameter estimation of constrained nonlinear dynamical systems. *ISA transactions*, Elsevier, v. 77, p. 231–241, 2018.
- ISERMANN, R.; MÜNCHHOF, M. *Identification of dynamic systems: an introduction with applications*. [S.l.]: Springer Science & Business Media, 2010.
- JAUBERTHIE, C. et al. Optimal input design for aircraft parameter estimation. *Aerospace science and technology*, Elsevier, v. 10, n. 4, p. 331–337, 2006.
- JORGE, V. A. et al. A survey on unmanned surface vehicles for disaster robotics: Main challenges and directions. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 19, n. 3, p. 702, 2019.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. *Proceedings of ICNN'95-International Conference on Neural Networks*. [S.l.], 1995. v. 4, p. 1942–1948.
- KIMBALL, P. et al. The whoi jetyak: An autonomous surface vehicle for oceanographic research in shallow or dangerous waters. In: IEEE. *OES Autonomous Underwater Vehicles (AUV)*. [S.l.], 2014. p. 1–7.
- KRAGELUND, S. et al. Adaptive speed control for autonomous surface vessels. In: IEEE. *2013 OCEANS-San Diego*. [S.l.], 2013. p. 1–10.
- KUMAR, A.; NARASIMHAN, S. Optimal input signal design for identification of interactive and ill-conditioned systems. *Industrial & Engineering Chemistry Research*, ACS Publications, v. 55, n. 14, p. 4000–4010, 2016.
- LEWIS, E. V. Principles of naval architecture second revision. *Jersey: SNAME*, v. 2, 1988.
- LI, Z.; BACHMAYER, R. Modelling and identification of a robust autonomous surface craft for deployment in harsh ocean environment. In: IEEE. *2014 Oceans-St. John's*. [S.l.], 2014. p. 1–6.
- LICITRA, G. et al. Optimal input design for autonomous aircraft. *Control Engineering Practice*, Elsevier, v. 77, p. 15–27, 2018.
- LIU, Z. et al. Unmanned surface vehicles: An overview of developments and challenges. *Annual Reviews in Control*, Elsevier, v. 41, p. 71–93, 2016.
- LUO, C. et al. Uav position estimation and collision avoidance using the extended kalman filter. *IEEE Transactions on Vehicular Technology*, IEEE, v. 62, n. 6, p. 2749–2762, 2013.
- MAHACEK, P. Dynamic analysis of a SWATH vessel. *MBARI Internship Report*, p. 1–13, 2005.
- MANLEY, J. E. Unmanned surface vehicles, 15 years of development. In: IEEE. *OCEANS 2008*. [S.l.], 2008. p. 1–4.

- MANLEY, J. E.; HINE, G. Unmanned surface vessels (usvs) as tow platforms: Wave glider experience and results. In: IEEE. *OCEANS 2016 MTS/IEEE Monterey*. [S.l.], 2016. p. 1–5.
- MARTINS, A. et al. Roaz and roaz ii autonomous surface vehicle design and implementation. In: *International Lifesaving Congress 2007*. [S.l.: s.n.], 2007.
- MEZURA-MONTES, E.; COELLO, C. A. C. Constraint-handling in nature-inspired numerical optimization: past, present and future. *Swarm and Evolutionary Computation*, Elsevier, v. 1, n. 4, p. 173–194, 2011.
- Neto, A. F. D. S. et al. Development of optimal parameter estimation methodologies applied to a 3dof autonomous surface vessel. *IEEE Access*, p. 1–1, 2021.
- NOURI, N. M.; VALADI, M. Robust input design for nonlinear dynamic modeling of auv. *ISA transactions*, Elsevier, v. 70, p. 288–297, 2017.
- NOURI, N. M.; VALADI, M.; ASGHARIAN, J. Optimal input design for hydrodynamic derivatives estimation of nonlinear dynamic model of auv. *Nonlinear Dynamics*, Springer, v. 92, n. 2, p. 139–151, 2018.
- NOWAK, R. D. Nonlinear system identification. *Circuits, Systems and Signal Processing*, Springer, v. 21, n. 1, p. 109–122, 2002.
- OBERPEILSTEINER, S. et al. Optimal input design for multibody systems by using an extended adjoint approach. *Multibody system dynamics*, Springer, v. 40, n. 1, p. 43–54, 2017.
- OLIVEIRA, E. J. et al. An optimal power flow based on safety barrier interior point method. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 64, p. 977–985, 2015.
- PARAVISI, M. et al. Unmanned surface vehicle simulator with realistic environmental disturbances. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 19, n. 5, p. 1068, 2019.
- PEDERSEN, M. E. H. Good parameters for particle swarm optimization. *Hvass Lab., Copenhagen, Denmark, Tech. Rep. HL1001*, p. 1551–3203, 2010.
- PENG, Z. et al. An overview of recent advances in coordinated control of multiple autonomous surface vehicles. *IEEE Transactions on Industrial Informatics*, IEEE, v. 17, n. 2, p. 732–745, 2020.
- POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization. *Swarm intelligence*, Springer, v. 1, n. 1, p. 33–57, 2007.
- REGINA, B. A. et al. Hull and aerial holonomic propulsion system design for optimal underwater sensor positioning in autonomous surface vessels. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 21, n. 2, p. 571, 2021.
- SCHRANGL, P.; TKACHENKO, P.; RE, L. D. Iterative model identification of nonlinear systems of unknown structure: Systematic data-based modeling utilizing design of experiments. *IEEE Control Systems Magazine*, IEEE, v. 40, n. 3, p. 26–48, 2020.

- SILVA, A. M. L. da; FREIRE, M. R.; HONÓRIO, L. M. Transmission expansion planning optimization by adaptive multi-operator evolutionary algorithms. *Electric Power Systems Research*, Elsevier, v. 133, p. 173–181, 2016.
- SILVA, M. F. da et al. Project and control allocation of a 3 dof autonomous surface vessel with aerial azimuth propulsion system. *IEEE Access*, IEEE, 2020.
- SOUZA, M. B.; HONÓRIO, L. de M.; OLIVEIRA, E. J. de. Innovative analysis for parameter estimation quality. *International Journal of Control, Automation and Systems*, Springer, p. 1–9, 2020.
- SOUZA, M. B. et al. Recursive approach of sub-optimal excitation signal generation and optimal parameter estimation. *International Journal of Control, Automation and Systems*, Springer, p. 1–10, 2020.
- TECHET, A. 2.016 hydrodynamics. *Lecture Notes*, 2005.
- USNA. *Lectures Notes - Chapter 7: Resistance and Powering of Ships*. 2019. Disponível em: <<http://web.archive.org/web/20080207010024/http://www.808multimedia.com/winnt/kernel.htm>>.
- VALLE, Y. D. et al. Particle swarm optimization: basic concepts, variants and applications in power systems. *IEEE Transactions on evolutionary computation*, IEEE, v. 12, n. 2, p. 171–195, 2008.
- WANG, N. et al. Fast and accurate trajectory tracking control of an autonomous surface vehicle with unmodeled dynamics and disturbances. *IEEE Transactions on Intelligent Vehicles*, IEEE, v. 1, n. 3, p. 230–243, 2016.
- WANG, Z.; SOARES, C. G.; ZOU, Z. Optimal design of excitation signal for identification of nonlinear ship manoeuvring model. *Ocean Engineering*, Elsevier, v. 196, p. 106778, 2020.
- WIRTENSOHN, S. et al. Modelling and identification of a twin hull-based autonomous surface craft. In: IEEE. *2013 18th International Conference on Methods & Models in Automation & Robotics (MMAR)*. [S.l.], 2013. p. 121–126.
- WIRTENSOHN, S. et al. Parameter identification and validation analysis for a small usv. In: IEEE. *2015 20th International Conference on Methods and Models in Automation and Robotics (MMAR)*. [S.l.], 2015. p. 701–706.
- ZHOU, K.; DOYLE, J. C. *Essentials of robust control*. [S.l.]: Prentice hall Upper Saddle River, NJ, 1998. v. 104.