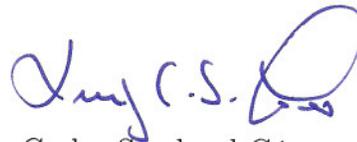


Tese apresentada à Divisão de Pós-graduação do Instituto Tecnológico de Aeronáutica como parte dos requisitos para obtenção do título de Mestre em Ciência no Curso de Engenharia Aeronáutica e Mecânica, Área de Mecânica do Voo.

Nei Salis Brasil Neto

**DESENVOLVIMENTO E OTIMIZAÇÃO DE
MANOBRAS DE ENSAIOS EM VÔO PARA
ESTIMAÇÃO DE DERIVADAS DE ESTABILIDADE
E CONTROLE DE AERONAVES**

Tese aprovada em sua versão final pelos abaixo assinados:



Prof. Dr. Luiz Carlos Sandoval Góes

Orientador

Prof. Dr. Homero Santiago Maciel
Chefe da Divisão de Pós-graduação

Campo Montenegro
São José dos Campos, SP - Brasil

2005

Dados Internacionais de Catalogação-na-Publicação (CIP)

Divisão Biblioteca Central do ITA/CTA

Salis Brasil Neto, Nei

Desenvolvimento e Otimização de Manobras de Ensaios em Vôo Para Estimação de Derivadas de Estabilidade e Controle de Aeronaves / Nei Salis Brasil Neto.

São José dos Campos, 2005.

173f.

Tese de Mestrado – Curso de Engenharia Aeronáutica e Mecânica – Área de Mecânica do Vôo, 2005. Orientador: Prof. Dr. Luiz Carlos Sandoval Góes. .

1. Manobras de Ensaios em Vôo, Estimação de Parâmetros, Derivadas de Estabilidade e Controle, Algoritmo Genético. I. Centro Técnico Aeroespacial. Instituto Tecnológico de Aeronáutica. Divisão de Engenharia Mecânica-Aeronáutica. II. Título.

REFERÊNCIA BIBLIOGRÁFICA

SALIS BRASIL NETO, Nei. **Desenvolvimento e Otimização de Manobras de Ensaios em Vôo Para Estimação de Derivadas de Estabilidade e Controle de Aeronaves**. 2005. 173f. Tese de Mestrado – Instituto Tecnológico de Aeronáutica, São José dos Campos.

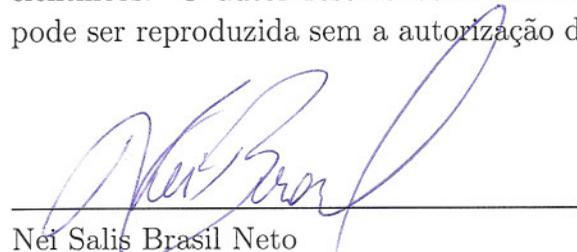
CESSÃO DE DIREITOS

NOME DO AUTOR: Nei Salis Brasil Neto

TÍTULO DO TRABALHO: Desenvolvimento e Otimização de Manobras de Ensaios em Vôo Para Estimação de Derivadas de Estabilidade e Controle de Aeronaves.

TIPO DO TRABALHO/ANO: Tese / 2005

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias desta tese e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese pode ser reproduzida sem a autorização do autor.



Nei Salis Brasil Neto

Av. Dr. Adhemar de Barros, 695/76

CEP 12.245-010 – São José dos Campos-SP

DESENVOLVIMENTO E OTIMIZAÇÃO DE MANOBRAS DE ENSAIOS EM VÔO PARA ESTIMAÇÃO DE DERIVADAS DE ESTABILIDADE E CONTROLE DE AERONAVES

Nei Salis Brasil Neto

Composição da Banca Examinadora:

Prof. Dr. Pedro Paglione	Presidente	-	ITA
Prof. Dr. Luiz Carlos Sandoval Góes	Orientador	-	ITA
Prof. Dr. Maj. Paulo César Pellanda	Membro Externo	-	IME
Prof. Dr. João Carlos Ceschini Hoff	Membro Externo	-	EMBRAER
Prof. Dr. Elder Moreira Hemerly	Membro	-	ITA

Dedico inteiramente esta conquista a meus pais, pelo extremo apoio dado em minhas decisões, pelos intermináveis conselhos, e pela magnífica dedicação dada a seus filhos!

Dedico este trabalho, também, a minha namorada, Hélen, pela sua infindável compreensão pela privação do convívio durante longos período de tempo, pelo apoio sempre demonstrado nas mais difíceis horas e por sua dedicação!

Agradecimentos

Ao meu orientador, Prof. Dr. Luiz Calor Saondoval Góes, pelo integral apoio desprendido e total confiança depositada em minha capacidade.

Ao Prof. Dr. Elder Moreira Hemerly, por suas contribuições e sugestões, as quais certamente ajudaram a estabelecer os caminhos que guiaram este trabalho.

À Fundação de Amparo à Pesquisa do Estado de São Paulo, à EMBRAER e à Fundação Casimiro Montenegro Filho por possibilitarem e apoiarem as atividades de pesquisa e de ensaios em vôo que viabilizaram o presente trabalho.

Ao Prof. Dr. Paulo Henriques Iscold Andrade de Oliveira e ao Centro de Estudos Aeronáuticos da Universidade Federal de Minas Gerais por participarem das atividades de pesquisa, disponibilizando as aeronaves e a estrutura para ensaios em vôo.

*“... Assinalou para sempre o século vinte,
O herói que assombrou o mundo inteiro:
Mais alto do que as nuvens, quase Deus,
É Santos-Dumont - Um brasileiro.*

— EDUARDO NEVES

Resumo

Este trabalho trata da aplicação de técnicas de otimização via algoritmos genéticos para o desenvolvimento de manobras de ensaios em vôo para estimação de parâmetros aerodinâmicos de aeronaves. As manobras otimizadas são necessárias para aumentar a eficiência dos algoritmos de estimação paramétrica, respeitando o envelope operacional das aeronaves quanto à segurança de vôo e quanto às limitações matemáticas dos modelos assumidos. Neste trabalho é feita a comparação entre a eficiência do procedimento de estimação com a aplicação de manobras convencionais e a eficiência do procedimento de estimação com a aplicação das manobras otimizadas. Em ambos os casos, o aumento da eficiência do algoritmos de estimação busca a maximização da sensibilidade das variáveis de saída aos parâmetros do modelo. Para as manobras convencionais, os sinais são especificados de maneira indireta, através da maximização de suas densidades espectrais de potência nas frequências próximas dos modos naturais do sistema dinâmico. A técnica de otimização, entretanto, baseada no conteúdo de informação dos dados de ensaios em vôo, diretamente utiliza-se dos conceitos de matriz de informação e limitantes de Cramer-Rao para compor os critérios de otimização e gerar sinais globalmente ótimos através de algoritmos genéticos que minimizem as incertezas relacionadas com as estimativas dos parâmetros aerodinâmicos. A presente abordagem considera problemas com multi-objetivos, multi-entradas e para o mínimo tempo, tratando os resíduos coloridos nas variáveis de medida. Vários estudos de caso são discutidos com a utilização dos modelos dinâmicos de período curto e oscilatório em derrapagem, incluindo resultados de ensaios em vôo de uma aeronave de pequeno porte. As vantagens e desvantagens das técnicas propostas são apresentadas, enfatizando a facilidade de implementação dos sinais ótimos resultantes. Por fim, considerações e recomendações a respeito da importância das manobras de ensaios em vôo para os procedimentos de estimação de derivadas de estabilidade e controle de aeronaves são feitas.

Abstract

This work deals with the application of genetic optimization techniques to the determination of aircraft flight test input maneuvers for aircraft aerodynamic parameter estimation. The optimum flight test maneuvers are necessary to increase the efficiency of aircraft identification and parameter estimation algorithms, respecting operational restrictions related to flight safety and limits of the assumed mathematical models. In this work we compare the effectiveness of identification processes obtained with conventional aircraft maneuvers and maneuvers defined by a special optimization procedure. In both cases, the increase of the efficiency of the estimation algorithms uses the maximization of sensitivity of output equations to the parameters of the model. For the conventional maneuver signals, however, this is made in an indirect form, by shaping the input signals in a way to increase the power spectral density of the signals in the range of the natural frequencies of the dynamic system of interest. The optimization technique, on the other hand, is based on the concept of flight test data information content, where the sensitivity matrix and Cramer-Rao lower bounds are used to compose the optimization criteria and to generate an optimal signal that minimizes the uncertainties related with the estimation of the aerodynamic parameters. This approach regards multi-objective, multi-input and minimum time problems concerning colored residuals on the measurement variables. Several case studies are discussed with the use of the short period and the dutch-roll dynamic models, including real flight testing analysis and applications. The advantages and disadvantages of the proposed maneuvers are presented, stressing how easy is the implementation of the signals and the strong improvement made possible with the application of the optimized maneuver signals. Considerations and recommendations are made regarding the importance of parameter estimation flight test maneuvers to the identification of aerodynamic stability and control derivatives of aircrafts.

Sumário

LISTA DE FIGURAS	xii
LISTA DE TABELAS	xvii
LISTA DE SÍMBOLOS	xviii
1 INTRODUÇÃO	23
1.1 Generalidades	23
1.2 Objetivo	26
1.3 Histórico	27
1.4 Organização do Trabalho	31
2 ESTIMAÇÃO DE PARÂMETROS	33
2.1 Introdução	33
2.2 Estimador por Máxima Verossimilhança	35
2.3 Acuidade das Estimativas	38
2.3.1 Julgamento de Engenharia no Processo de Estimação Derivadas Aerodinâmicas de Aeronaves	39
2.3.2 Erros de Polarização das Estimativas Paramétricas	40
2.3.3 Erros de Dispersão das Estimativas Paramétricas	40
2.3.4 Desigualdade de Cramer-Rao e Matriz de Informação de Fisher	41

2.3.5	Correção do Cálculo das Covariâncias para a Presença de Ruído Colorido nas Variáveis de Medida	44
3	MANOBRAS DE ENSAIOS EM VÔO	48
3.1	Introdução	48
3.2	Formulação do Problema e Critério de Otimização	51
3.2.1	Consideração de resíduos coloridos no modelo de conhecimento a priori do sistema de aquisição de dados	53
3.2.2	Composição da Função de Aptidão	54
3.2.3	Restrições	56
3.3	Abordagem Para Especificação de Sinais de Excitação no Domínio da Frequência	57
3.4	Algoritmo Genético de Otimização	59
3.4.1	População Inicial	62
3.4.2	Novas Gerações	65
3.4.3	Implementação de Restrições	68
4	RESULTADOS EXPERIMENTAIS	71
4.1	Introdução	71
4.2	Dados Sintéticos e Simulações de Monte Carlo	72
4.2.1	Exemplo 1	72
4.2.2	Exemplo 2	85
4.2.3	Exemplo 3	93
4.3	Dados Experimentais de Ensaios em Vôo	103
4.3.1	Aeronave Ensaçada	104
4.3.2	Sistema de Aquisição de Dados de Ensaios em Vôo	106
4.3.3	Manobras Convencionais	116

4.3.4	Manobras Otimizadas	116
4.3.5	Análise dos Resultados	117
5	CONCLUSÕES	131
	REFERÊNCIAS BIBLIOGRÁFICAS	135
	APÊNDICE A – MODELOS PARA AS EQUAÇÕES DE ESTADO E DE SAÍDA	141
A.1	Introdução	141
A.2	Equações de Estado	142
A.2.1	Sistemas de Referência e Orientação da Aeronave em Relação ao Referencial Inercial	143
A.2.2	Equações de Estado para o Movimento Completo (6-DOF)	146
A.2.3	Modelo Aerodinâmico e Análise das Derivadas de Estabilidade e Controle Adimensionais	148
A.2.4	Equações de Estado Desacopladas	157
A.2.5	Equações de Estado Linearizadas	162
	ANEXO A – ANÁLISE DE RISCOS DOS VÔOS DA CAMPANHA DE ENSAIOS	167
	ANEXO B – PRINCIPAIS CARACTERÍSTICAS DO CURUMIM CEA 205 CB.9	169
	ANEXO C – FLUXOGRAMA DE PROCESSOS BÁSICOS DO ALGO- RÍTMO DE OTIMIZAÇÃO	170

Lista de Figuras

Figura 1.1	Esquema de interação entre o processo de desenvolvimento de manobras e o processo de estimação paramétrica	26
Figura 2.1	Diagrama do Processo de Estimação Paramétrica (Output-Error)	33
Figura 3.1	Sinal de excitação tipo dublê	58
Figura 3.2	PSD para dublês com diferentes valores de δ_t	58
Figura 3.3	Sinal de excitação a ser otimizado	63
Figura 3.4	Exemplo de Indivíduo	63
Figura 3.5	População	64
Figura 3.6	Dupla de parentes selecionados para reprodução	66
Figura 3.7	Vetor binário utilizado para o cruzamento	66
Figura 3.8	Cruzamento escalonado	66
Figura 3.9	Instrumentos de Reprodução	68
Figura 4.1	Exemplo 1 - Sinal otimizado por Mehra	76
Figura 4.2	Exemplo 1 - Sinal otimizado por Chen	77
Figura 4.3	Exemplo 1 - Sinal otimizado por Morelli (Chen)	78
Figura 4.4	Exemplo 1 - Sinal otimizado por Morelli (Mehra)	79
Figura 4.5	Exemplo 1 - Sinal Otimizado 1 - Amplitude Máxima igual a 8.792 graus	80
Figura 4.6	Exemplo 1 - Sinal Otimizado 2 - Amplitude Máxima igual a 12.5 graus	81

Figura 4.7	Exemplo 1/Sinal 1 - Evolução da população em relação à função de aptidão	82
Figura 4.8	Exemplo 1/Sinal 1 - Evolução da população em relação ao objetivo geral	82
Figura 4.9	Exemplo 1/Sinal 1 - Evolução da população em relação ao tempo de execução da manobra	82
Figura 4.10	Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro Z_α	82
Figura 4.11	Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro $Z_{\delta e}$	82
Figura 4.12	Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro M_α	82
Figura 4.13	Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro M_q	83
Figura 4.14	Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro $M_{\delta e}$	83
Figura 4.15	Exemplo 1/Sinal 2 - Evolução da população em relação à função de aptidão	83
Figura 4.16	Exemplo 1/Sinal 2 - Evolução da população em relação ao objetivo geral	83
Figura 4.17	Exemplo 1/Sinal 2 - Evolução da população em relação ao tempo de execução da manobra	83
Figura 4.18	Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro Z_α	83
Figura 4.19	Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro $Z_{\delta e}$	84
Figura 4.20	Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro M_α	84
Figura 4.21	Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro M_q	84
Figura 4.22	Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro $M_{\delta e}$	84

Figura 4.23	Exemplo 2 - Sinal Otimizado por Morelli	88
Figura 4.24	Exemplo 2 - Sinal Ótimo para Multi-Entradas	89
Figura 4.25	Exemplo 2 - Evolução da população em relação à função de aptidão	90
Figura 4.26	Exemplo 2 - Evolução da população em relação ao objetivo geral	90
Figura 4.27	Exemplo 2 - Evolução da população em relação ao parâmetro Y_β	90
Figura 4.28	Exemplo 2 - Evolução da população em relação ao parâmetro L_β	90
Figura 4.29	Exemplo 2 - Evolução da população em relação ao parâmetro Y_p	90
Figura 4.30	Exemplo 2 - Evolução da população em relação ao parâmetro Y_r	90
Figura 4.31	Exemplo 2 - Evolução da população em relação ao parâmetro N_β	91
Figura 4.32	Exemplo 2 - Evolução da população em relação ao parâmetro N_p	91
Figura 4.33	Exemplo 2 - Evolução da população em relação ao parâmetro N_r	91
Figura 4.34	Exemplo 2 - Evolução da população em relação ao parâmetro $Y_{\delta r}$	91
Figura 4.35	Exemplo 2 - Evolução da população em relação ao parâmetro $L_{\delta a}$	91
Figura 4.36	Exemplo 2 - Evolução da população em relação ao parâmetro $L_{\delta r}$	91
Figura 4.37	Exemplo 2 - Evolução da população em relação ao parâmetro $N_{\delta a}$	92
Figura 4.38	Exemplo 2 - Evolução da população em relação ao parâmetro $N_{\delta r}$	92
Figura 4.39	Sinal otimizado levando em consideração R e R_{uu}	95
Figura 4.40	Sinal otimizado levando em consideração apenas R	95
Figura 4.41	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor de α	96
Figura 4.42	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor de q	96
Figura 4.43	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor A_z	96
Figura 4.44	Exemplo 3 - Resultados da estimação de Z_α	97
Figura 4.45	Exemplo 3 - Resultados da estimação de Z_q	98

Figura 4.46	Exemplo 3 - Resultados da estimação de $Z_{\delta e}$	99
Figura 4.47	Exemplo 3 - Resultados da estimação de M_{α}	100
Figura 4.48	Exemplo 3 - Resultados da estimação de $M_{\delta e}$	101
Figura 4.49	Exemplo 3 - Resultados da estimação de M_q	102
Figura 4.50	Três vistas do CEA-205 CB.9 Curumim	105
Figura 4.51	Componentes principais do sistema de aquisição de dados	107
Figura 4.52	Instalação dos principais componentes do sistema de aquisição de dados na aeronave Curumim	110
Figura 4.53	Gráfico de Calibração dos Sensores de Ângulo de Ataque	112
Figura 4.54	Gráfico de Calibração do Sensor de Velocidade de Arfagem	112
Figura 4.55	Gráfico de Calibração do Sensor de Aceleração Vertical	113
Figura 4.56	Gráfico de Calibração do Sensor de Velocidade Verdadeira	113
Figura 4.57	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor de α	115
Figura 4.58	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor de q	115
Figura 4.59	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor A_z	115
Figura 4.60	Densidade Espectral de Potência e Função de Autocorrelação do Resí- duo do Sensor A_z	119
Figura 4.61	Simulação de Planejamento Para o Sinal <i>Doublet</i>	119
Figura 4.62	Simulação de Planejamento Para o Sinal 2-1-1	120
Figura 4.63	Simulação de Planejamento Para o Sinal 3-2-1-1	120
Figura 4.64	Resposta temporal da aeronave para as 15 melhores corridas do <i>Doublet</i>	121
Figura 4.65	Resposta temporal da aeronave para as 15 melhores corridas do 2-1-1 .	121
Figura 4.66	Resposta temporal da aeronave para as 15 melhores corridas do 3-2-1-1	122
Figura 4.67	Simulação de Planejamento Para o Sinal Otimizado	122

Figura 4.68 Resposta temporal da aeronave para as 15 melhores corridas do sinal otimizado	123
Figura 4.69 Densidade Espectral de Potência dos Sinais Estudados	123
Figura 4.70 Comparação das Manobras - Resultados da estimação de Z_α	124
Figura 4.71 Comparação das Manobras - Resultados da estimação de Z_q	125
Figura 4.72 Comparação das Manobras - Resultados da estimação de $Z_{\delta e}$	126
Figura 4.73 Comparação das Manobras - Resultados da estimação de M_α	127
Figura 4.74 Comparação das Manobras - Resultados da estimação de M_q	128
Figura 4.75 Comparação das Manobras - Resultados da estimação de $M_{\delta e}$	129
Figura A.1 Orientação do Eixo do Corpo em Relação ao Referencial Inercial	144
Figura A.2 Eixo do Vento	144

Lista de Tabelas

Tabela 4.1	Exemplo 1 - Valores dos parâmetros do modelo de período curto	73
Tabela 4.2	Exemplo 1 - Limites de Cramer-Rao (relativos)	75
Tabela 4.3	Exemplo 2 - Valores dos parâmetros do modelo oscilatório em derrapagem	86
Tabela 4.4	Exemplo 2 - Limites de Cramer-Rao (relativos)	92
Tabela 4.5	Exemplo 3 - Objetivos para otimização	93
Tabela 4.6	Exemplo 3 - Resultados da Otimização dos Sinais e da Simulação de Monte Carlo	94
Tabela 4.7	Fatores de Escala e Erros Sistemáticos	111
Tabela 4.8	Covariâncias dos resíduos de medida (α, q, A_z)	114
Tabela 4.9	Limites inferiores dos desvios-padrão relativos para as sinais de exci- tação estudados	130

Lista de Símbolos

X_b, Y_b, Z_b	Eixos X, Y e Z do sistema fixo ao corpo
J_{xy}, J_{yz}, J_{xz}	Produtos de inércia da aeronave
I_x, I_y, I_z	Momentos de inércia da aeronave
ϕ	Ângulo de rolamento
θ	Ângulo de arfagem
ψ	Ângulo de guinda (proa verdadeira)
α	Ângulo de ataque
β	Ângulo de derrapagem
u, v, w	Componentes x, y e z da velocidade verdadeira descritas no sistema do corpo
V_{tas}	Velocidade verdadeira
p, q, r	Componentes x, y e z da velocidade angular do sistema do corpo em relação ao referencial inercial
\bar{q}	Pressão Dinâmica: $\bar{q} = \frac{1}{2}\rho V_{tas}^2$
S	Área da asa
l_s	Comprimento de referência para o movimento latero-direcional: normalmente é a envergadura da asa
l_u	Comprimento de referência para o movimento longitudinal: normalmente é a corda da asa
e	Fator de Oswald
Λ	Alongamento da asa
F_T	Tração propulsiva
V_0	Velocidade de referência
C_D	Coefficiente de arrasto
C_Y	Coefficiente de força lateral

C_L	Coeficiente de sustentação
C_l	Coeficiente de momento de rolamento
C_m	Coeficiente de momento de arfagem
C_n	Coeficiente de momento de guinada
C_X	Coeficiente de força aerodinâmica no eixo x do corpo
C_Z	Coeficiente de força aerodinâmica no eixo z do corpo
C_{D_0}	Coeficiente de arrasto para sustentação nula
C_{L_0}	Coeficiente de sustentação para ângulo de ataque nulo
C_{Y_β}	Coeficiente de força lateral em função do ângulo de derrapagem
C_{Y_p}	Coeficiente de força lateral em função da velocidade de rolamento
C_{Y_r}	Coeficiente de força lateral em função da velocidade de guinada
$C_{Y_{\delta a}}$	Coeficiente de força lateral em função da deflexão do aileron
$C_{Y_{\delta r}}$	Coeficiente de força lateral em função da deflexão do leme de direção
C_{L_α}	Inclinação da curva do coeficiente de sustentação em função do ângulo de ataque
C_{L_q}	Coeficiente de sustentação em função da velocidade de arfagem
$C_{L_{\dot{\alpha}}}$	Coeficiente de sustentação em função da taxa da variação temporal do ângulo de ataque
$C_{L_{\delta e}}$	Coeficiente de sustentação em função da deflexão do profundor
$C_{L_{\delta ih}}$	Coeficiente de sustentação em função da deflexão do estabilizador horizontal
C_{l_β}	Coeficiente de momento de rolamento em função do ângulo de derrapagem
C_{l_p}	Coeficiente de momento de rolamento em função da velocidade de rolamento
C_{l_r}	Coeficiente de momento de rolamento em função da velocidade de guinada
$C_{l_{\delta a}}$	Coeficiente de momento de rolamento em função da deflexão do aileron
$C_{l_{\delta r}}$	Coeficiente de momento de rolamento em função da deflexão do leme de direção
C_{m_α}	Inclinação da curva do coeficiente de momento de arfagem em função do ângulo de ataque
C_{m_q}	Coeficiente de momento de arfagem em função da velocidade de arfagem
$C_{m_{\dot{\alpha}}}$	Coeficiente de momento de arfagem em função da taxa da variação temporal do ângulo de ataque
$C_{m_{\delta e}}$	Coeficiente de momento de arfagem em função da deflexão do profundor

$C_{m_{\delta ih}}$	Coeficiente de momento de arfagem em função da deflexão do estabilizador horizontal
$C_{n_{\beta}}$	Coeficiente de momento de guinada em função do ângulo de derrapagem
C_{n_p}	Coeficiente de momento de guinada em função da velocidade de rolamento
C_{n_r}	Coeficiente de momento de guinada em função da velocidade de guinada
$C_{n_{\delta a}}$	Coeficiente de momento de guinada em função da deflexão do aileron
$C_{n_{\delta r}}$	Coeficiente de momento de guinada em função da deflexão do leme de direção
C_l^{RP}	Coeficiente de momento de rolamento em relação ao ponto de referência aerodinâmica
C_m^{RP}	Coeficiente de momento de arfagem em relação ao ponto de referência aerodinâmica
C_n^{RP}	Coeficiente de momento de guinada em relação ao ponto de referência aerodinâmica
Z_{α}	Coeficiente dimensional da força no eixo Z em função do ângulo de ataque
Z_q	Coeficiente dimensional da força no eixo Z em função da velocidade de arfagem
$Z_{\delta e}$	Coeficiente dimensional da força no eixo Z em função da deflexão do profundor
M_{α}	Coeficiente dimensional do momento de arfagem em função do ângulo de ataque
M_q	Coeficiente dimensional do momento de arfagem em função da velocidade de arfagem
$M_{\delta e}$	Coeficiente dimensional do momento de arfagem em função da deflexão do profundor
Y_{β}	Coeficiente dimensional da força no eixo y em função do ângulo de derrapagem
$Y_{\delta a}$	Coeficiente dimensional da força no eixo y em função deflexão do aileron
$Y_{\delta r}$	Coeficiente dimensional da força no eixo y em função deflexão do leme

L_β	Coeficiente dimensional do momento de rolamento em função do ângulo de derrapagem
L_p	Coeficiente dimensional do momento de rolamento em função da velocidade de rolamento
L_r	Coeficiente dimensional do momento de rolamento em função da velocidade de guinada
L_{δ_a}	Coeficiente dimensional do momento de rolamento em função da deflexão do aileron
L_{δ_r}	Coeficiente dimensional do momento de rolamento em função da deflexão do leme
N_β	Coeficiente dimensional do momento de guinada em função do ângulo de derrapagem
N_p	Coeficiente dimensional do momento de guinada em função da velocidade de rolamento
N_r	Coeficiente dimensional do momento de guinada em função da velocidade de guinada
N_{δ_a}	Coeficiente dimensional do momento de guinada em função da deflexão do aileron
N_{δ_r}	Coeficiente dimensional do momento de guinada em função da deflexão do leme
x_{arp}	Coordenada ao longo do eixo x do corpo da posição do ponto de referência aerodinâmica em relação ao cento de massa da aeronave
y_{arp}	Coordenada ao longo do eixo y do corpo da posição do ponto de referência aerodinâmica em relação ao cento de massa da aeronave
z_{arp}	Coordenada ao longo do eixo z do corpo da posição do ponto de referência aerodinâmica em relação ao cento de massa da aeronave
x	Vetor de variáveis de estado
u	Vetor de entradas de controle
y	Vetor de variáveis de saída
y_m	Vetor de variáveis de medida

y_m	Vetor de variáveis de medida
θ	Vetor de parâmetros do modelo
$\hat{\theta}$	Vetor de parâmetros estimados
v	Ruído de medida
E	Operador de esperança matemática
R	Matriz de covariância do ruído de medida
R_{uu}	Matriz de correlação dos resíduos de medida
M	Matriz de Informação de Fisher
D	Matriz de dispersão: $D = M^{-1}$
S	Matriz de sensibilidade das equações de saída aos parâmetros do modelo
ε	Energia máxima do sinal de excitação
I	Matriz identidade
*	Operador para matriz e vetor transposto
∇_{θ}	Gradiente em função de θ : equivalente a $\frac{\partial}{\partial \theta}$
cov	Operador para covariância
μ	Restrição de variável de entrada
γ	Restrição de variável de saída
ς	Objetivo de otimização

Capítulo 1

Introdução

1.1 Generalidades

A especificação de manobras de ensaios em vôo para estimação de derivadas de estabilidade e controle tem como objetivo aumentar a eficiência dos algoritmos de estimação, diminuindo as incertezas associadas ao processo. Basicamente, o foco é colocado sobre o conteúdo de informação dos dados de ensaios em vôo, baseando-se no conceito de que quanto maior for o nível de informação contido nos dados, maior será o nível de identificabilidade dos parâmetros e menores serão as incertezas associadas às suas estimativas.

Em contra partida, a execução de ensaios em vôo requer a especificação de manobras que não venham a exceder limites operacionais das aeronaves. Este ponto constitui uma importante consideração no que tange a segurança de vôo e ao sucesso das campanhas de ensaios. Ainda no campo operacional, o sinal de excitação especificado deve ser de possível implementação manual pelo piloto ou por sistemas automáticos. Também devem ser levadas em conta as restrições que dizem respeito aos limites impostos pelos modelos matemáticos assumidos nos algoritmos de estimação.

A especificação de uma manobra de ensaios em vôo para estimação paramétrica, portanto, deve ser uma solução de compromisso entre a eficiência dos algoritmos, através dos níveis de incerteza das estimativas, entre os limites operacionais, no que tange à segurança de vôo e à implementabilidade dos sinais de excitação, bem como entre os limites impostos pelos modelos matemáticos assumidos.

O conteúdo de informação dos dados de ensaios em vôo pode ser acessado através da chamada matriz de informação, a qual teoricamente determina o quão confiável são as estimativas paramétricas. A matriz de informação é calculada através da sensibilidade das equações de saída aos parâmetros do modelo, e leva em consideração os níveis de ruído nas variáveis de medida. Mais adiante é visto que a sensibilidade das equações de saída aos parâmetros do modelo depende dos sinais de excitação aplicados. A inversa da matriz de informação é chamada matriz de dispersão, também tida como matriz dos limitantes inferiores de Cramer-Rao para a covariância dos parâmetros. Esta propriedade da matriz de dispersão é válida desde que o algoritmo de estimação utilizado seja assintoticamente não polarizado e eficiente, tal qual o algoritmo de estimação por máxima verossimilhança. Através dos elementos dessa matriz, são calculados os desvios-padrão das estimativas de cada parâmetro, bem como os índices de correlação estatística entre os mesmos.

Uma vez que este trabalho trata do desenvolvimento e especificação de manobras de ensaios em vôo que maximizem a eficiência dos algoritmos de estimação através da minimização das incertezas associadas às estimativas paramétricas, pode-se assumir, portanto, como critério de desenvolvimento e otimização de sinais de excitação alguma norma da matriz de informação ou da matriz de dispersão.

As restrições de ordem operacional, no que tange à manutenção da segurança de vôo para garantir o sucesso das campanhas de ensaios, as características de implementabilidade, bem como as limitações oriundas dos modelos matemáticos devem ser consideradas paralelamente no processo de desenvolvimento e especificação das manobras de ensaios em vôo para estimação paramétrica. Neste contexto, o principal ponto diz respeito à amplitude de variação das variáveis envolvidas no vôo, tais como: ângulo de ataque ou de derrapagem, velocidade verdadeira, aceleração vertical, entre outros. Algumas variáveis, como as citadas acima, podem ser de grande importância para a manutenção do vôo dentro de limites do envelope operacional, bem como para não extrapolar limites matemáticos. É de suma importância, portanto, que as técnicas de desenvolvimento e de especificação de manobras de ensaios em vôo para estimação de parâmetros tenham mecanismos que restrinjam a amplitude de variação de variáveis de saída para que não sejam excedidos os limites existentes. Este mecanismo deve fazer parte do algoritmo de desenvolvimento e otimização de sinais de excitação, garantindo assim que os resultados não extrapolem as restrições impostas.

O desenvolvimento, otimização e especificação de manobras de ensaios em vôo para estimação paramétrica deve ter uma interface interativa com o próprio processo de estimação paramétrica, de preferência em tempo quase real, e em vôo.

Os critérios de desenvolvimento dos sinais de excitação levam em consideração um modelo a priori do sistema dinâmico. Desta maneira, fica claro que quanto mais próximo este modelo a priori está da realidade, mais eficiente será a otimização dos sinais de excitação. É levantado aqui um importante ponto a respeito das técnicas de desenvolvimento de experimentos para estimação paramétrica: as mesmas são dependentes do modelo a priori, e quanto melhor ele for, mais eficientemente o experimento será desenvolvido.

Estas observações aumentam a necessidade de robustez para as técnicas, no sentido de possibilitar o adequado acesso às estimativas paramétricas, mesmo que os modelos de conhecimento a priori estejam defasados. Estas características motivam a abordagem do desenvolvimento, otimização e especificação de manobras de ensaios em vôo como um processo interativo com a própria estimação paramétrica.

De acordo com o esquematizado na figura 1.1, verifica-se que o modelo a priori deve ser composto pelas equações que regem a dinâmica de aeronaves, por dados de geometria e massa da aeronave, por dados do sistema de aquisição de dados e pelos parâmetros aerodinâmicos, os quais são os objetos do processo de estimação paramétrica. Estes dados podem ser oriundos de ensaios em túnel de vento, ou de estimativas obtidas de tabelas e de banco de dados aerodinâmicos. Em contra partida, os objetivos específicos do processo de estimação paramétrica são analisados, o que possibilita visualizar quais são os parâmetros de maior interesse e quais são os níveis de certeza aceitáveis para o usuário final. Toda esta informação deve ser levada em consideração no desenvolvimento e otimização do sinal de excitação para as manobras de ensaios em vôo.

No processo de otimização propriamente dito, será gerado um sinal de excitação que maximize a acuidade das estimativas, levando em consideração as informações obtidas anteriormente. Este sinal deve ser avaliado, quanto à sua implementabilidade (através do piloto ou de sistemas automáticos), e quanto a resposta da aeronave. Neste ponto é que o respeito às restrições necessárias deve ser confirmado. Caso houver necessidade, deve-se voltar ao processo de otimização, e providenciar que o sinal de excitação a ser gerado respeite as restrições e possua implementação prática. Feito isso, o ensaio em vôo e a

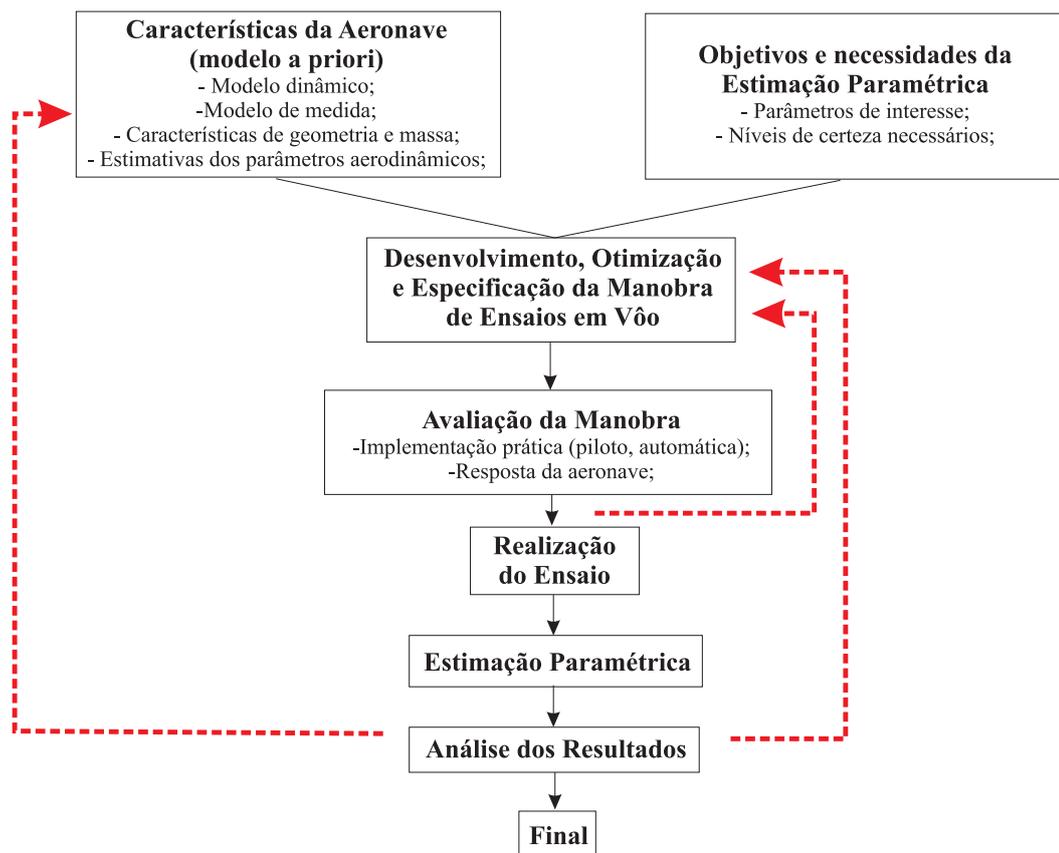


Figura 1.1: Esquema de interação entre o processo de desenvolvimento de manobras e o processo de estimativa paramétrica

aquisição dos dados deve ser realizada, seguido da própria estimativa paramétrica.

A análise dos resultados da estimativa paramétrica deve ser feita considerando os objetivos e necessidades impostas pelo usuário final. Caso necessário, o *feedback* introduzido pela atualização do modelo a priori possibilita que o experimento seja desenvolvido com cada vez mais eficiência e que os resultados convirjam mais facilmente para o objetivo.

1.2 Objetivo

O presente trabalho aborda o problema da especificação de manobras de ensaios em voo para estimativa de parâmetros aerodinâmicos de aeronaves.

O principal objetivo é demonstrar a necessidade e viabilidade da aplicação das técnicas apresentadas para o sucesso dos procedimentos de estimativa de parâmetros aplicados à modelagem de aeronaves, deixando claro as vantagens quanto à confiabilidade do processo como um todo e quanto à economia de recursos.

Além disso, objetiva-se estabelecer uma abordagem prática que envolva grande parte dos fenômenos envolvidos no processo e que resulte em uma ferramenta que auxilie no planejamento e execução de campanhas de ensaios para modelagem aerodinâmica de aeronaves, fazendo a comunicação entre as necessidades de engenharia e os aspectos operacionais, principalmente, de segurança de vôo.

1.3 Histórico

A análise de dados de ensaios em vôo sob o ponto de vista de estabilidade e controle deu seus primeiros passos no início do século, não muito tempo após o primeiro vôo do mais pesado que o ar sob meios próprios, em 1906, realizado pelo brasileiro Alberto Santos Dumont. Entre 1910 e 1920, alguns conceitos básicos a respeito de estabilidade e controle de aeronaves foram estabelecidos, principalmente, por pesquisadores da Inglaterra e do Massachusetts Institute of Technology (MIT, Estados Unidos da América). Nesta época, também foram estabelecidos os conceitos de derivadas de estabilidade e realizados ensaios em túneis de vento, enfocando aspectos de dinâmica e estabilidade de vôo.

Poucos anos depois, pesquisadores do National Advisory Committee for Aeronautics (NACA), (NORTON, 1923a) (NORTON, 1923b), vieram a publicar alguns dos primeiros trabalhos levando em consideração equações aproximadas da dinâmica de aeronaves para analisar aspectos de estabilidade de vôo através de dados de ensaios em vôo. Estes anos foram muito importantes para o desenvolvimento de sistemas de aquisição de dados, das técnicas de ensaios em vôo e dos métodos de análises de dados (NORTON; BROWN, 1923) (NORTON; CARROLL, 1923). Posteriormente, foram utilizadas técnicas manuais e de abordagem gráfica. Destacou-se neste contexto a técnica chamada de *Analog Matching*, a qual consistia em um ajuste manual da curva de saída do modelo matemático aos dados observados em vôo. Esta tarefa era realizada através de computadores analógicos, por meio de tentativa e erro.

No início dos anos 50, as análises de dados de ensaios em vôo tomaram abordagens próximas às teorias de Identificação de Sistemas. O conceito de mínimos quadrados foi utilizado por Greenberg (GREENBERG, 1951), e Shinbrot (SHINBROT, 1951), entre outros pesquisadores. Neste período, a técnica de *Analog Matching* foi otimizada por Shinbrot

(SHINBROT, 1954), depois vindo a ser chamada de erro de saída, ou *Output-Error*.

Os anos 60 foram marcados pelo desenvolvimento dos filtros lineares por Kalman. Neste período, Gerlach, na Universidade de Delft, Holanda, aplicou a estimação de estados a problemas de dinâmica de aeronaves, chamando-a de reconstrução da trajetória de vôo. O então chamado NASA Flight Research Center também estava fortemente engajado nas campanhas de ensaio em vôo da aeronave X-15 e das asas voadoras M2. Neste contexto, a estimação paramétrica através da técnica *Analog Matching* apresentou importante papel, principalmente no que diz respeito a abertura do envelope operacional destas aeronaves (MORELLI; KLEIN, 2005) (WANG; ILIFF, 2004).

No meio da década de 60, pesquisadores do Dryden Flight Research Center observaram a grande necessidade de incrementação das técnicas de identificação de sistemas aplicadas à análise de dados de ensaios em vôo. O interesse estava principalmente voltado para o método de máxima verossimilhança. Nesta ocasião, Taylor, Iliff e Balakrishnan (ILIFF; TAYLOR, 1972) (BALAKRISHNAN, 1968) trabalharam juntos para o desenvolvimento de técnicas e programas de estimação paramétrica via máxima verossimilhança.

No início da década de 70, Iliff e Maine (MAINE; ILIFF, 1985) (MAINE; ILIFF, 1986) fizeram grandes avanços na aplicação de algoritmos *Output-Error* com a aplicação do critério de máxima verossimilhança para a estimação de derivadas de estabilidade e controle de aeronaves. Esta abordagem, entretanto, não suporta ruídos de estado, o que veio a incentivar o desenvolvimento de algoritmos híbridos para a estimação de estados e de parâmetros. Estes algoritmos vieram a ser chamados de *Filter-Error* e são uma combinação do *Output-Error* e do Filtro de Kalman.

Os anos 80 e 90 foram reservados a forte consolidação dos algoritmos de *Output-Error* e *Filter-Error* para a aplicação das técnicas de Identificação de Sistemas em problemas de dinâmica de aeronaves e análises de dados de ensaios em vôo, em destaque neste contexto se encontram pesquisadores do instituto alemão DLR (JATEGAONKER; PLAETSCHKE, 1989)(JATEGAONKAR; PLAETSCHKE, 1983)(JATEGAONKAR; PLAETSCHKE, 1987), onde tem sido desenvolvida uma das principais ferramentas de identificação de sistemas com aplicações aeroespaciais (JATEGAONKAR, 2001). Nos dias de hoje, os algoritmos de *Output-Error* aliados aos critérios de máxima verossimilhança ainda são bastante utilizados para a estimação de parâmetros aerodinâmicos de aeronaves através de dados de

ensaios em vôo. Estes algoritmos, geralmente, são utilizados em conjunto com as técnicas de reconstrução de trajetória de vôo e estimação de estados.

Em âmbito nacional, as técnicas de identificação de sistemas com aplicações na dinâmica de vôo de aeronaves estão em pleno desenvolvimento. Iniciativas do setor aeroespacial têm incentivado a formação de pesquisadores nesta área e têm possibilitado o desenvolvimento das tecnologias citadas acima (NETO; GOES, 2005)(MENDONÇA; HEMERLY; GOES, 2005)(VASCONCELOS, 2002)(CURVO, 2000)(MACIEL; GOES; VASCONCELOS, 2004).

Quanto aos sinais de excitação para manobras de ensaios em vôo para estimação paramétrica, especificamente, as preocupações vieram já no final da década de 60. Os primeiros trabalhos relevantes que envolveram técnicas para especificação de sinais de excitação com aplicações aeronáuticas são do início da década de 70 (MEHRA, 1974a)(STEPNER; MEHRA, 1973)(MEHRA, 1974b)(GUPTA; JR., 1975). Estes trabalhos preocupavam-se com a minimização dos limitantes inferiores de Cramer-Rao para a estimativa dos parâmetros em função do sinal de excitação. Também foi observado a aplicação de técnicas no domínio da frequência (MARCHAND, 1977). Estas técnicas são de fácil acesso e suas aplicações persistem até os dias de hoje. A idéia é, a partir de sinais de excitação pré-estabelecidos, maximizar a densidade espectral de potência nas frequências próximas aos modos naturais do sistema em estudo.

Todos os trabalhos citados acima não se preocuparam em introduzir nos critérios de otimização o tempo de realização da manobra de ensaio. O tempo disponível era mantido fixo, escolhido através da experiência e do julgamento de engenharia. O primeiro a abordar este problema e colocar o tempo de realização do sinal de excitação na função custo, no sentido de minimizá-lo, foi Chen (CHEN, 1975). Posteriormente, Morelli (MORELLI, 1990) também buscou a otimização de manobras com o menor tempo possível. Neste caso, os limitantes de Cramer-Rao são minimizados até um objetivo e o tempo de aplicação é reduzido ao máximo. Morelli também demonstrou extrema preocupação com aplicações práticas em ensaios em vôo.

Em paralelo com as atividades e aplicações das técnicas de identificação de sistemas aos problemas de modelagem da dinâmica de aeronaves, sempre houve uma grande preocupação com o acesso à confiabilidade das estimativas paramétricas (ILIFF; MAINE, 1976) (ILIFF; MAINE, 1977) (MAINE; ILIFF, 1981a) (MAINE; ILIFF, 1981b). Grande desconforto

ocorria quando os cálculos dos limitantes de Cramer-Rao para as estimativas eram muito otimistas em comparação com as dispersões observadas nos experimentos. Os limitantes de Cramer-Rao, calculados a partir da teoria da informação (GOODWIN; PAYNE, 1977) (BALAKRISHNAN, 1968), não levam em conta ruídos coloridos nas variáveis de medida, o que ocasionava tais discrepâncias. Já em (MORELLI; KLEIN, 1994), o autor propõe uma técnica para corrigir os cálculos. Esta técnica é baseada na autocorrelação dos resíduos de medida e se mostrou bastante eficiente.

Claramente, as técnicas de estimação de parâmetros aerodinâmicos de aeronaves apresentaram um gargalo quanto à confiabilidade do processo, o que motivou o desenvolvimento de técnicas analíticas para o desenvolvimento e especificação de sinais de excitação para os experimentos. A comprovação da eficiência destas técnicas em ensaios em vôo pode ser verificada em (MORELLI, 1997) (MORELLI, 1998).

O presente trabalho procura a abordagem do problema de otimização de sinais de excitação para manobras de ensaios em vôo de uma maneira bastante prática, que envolva os principais problemas encontrados pelos pesquisadores citados acima. São apresentados alguns pontos de originalidade, principalmente no que diz respeito à consideração de resíduos coloridos nas variáveis de medida e ao método de otimização utilizado. Os seguintes pontos são de maior relevância:

- **Restrições de ordem prática:** o algoritmo desenvolvido neste estudo possibilita que as restrições impostas ao procedimento de otimização de sinais de excitação sejam de ordem prática, limitando diretamente as variáveis de saída de interesse e as variáveis de entrada. É possível que uma ou mais variáveis sejam restringidas simultaneamente.
- **Preocupação com implementação prática:** os sinais resultantes do procedimento de otimização podem ser submetidos a restrições que permitem garantir, de antemão, que serão implementáveis, tanto pelo piloto, quanto por sistemas automáticos.
- **Multi-objetividade e sinais com o mínimo de tempo:** a função de aptidão do procedimento de otimização pode ser formulada de maneira a atender um ou mais objetivos e ainda otimizar o tempo de execução da manobra.

- **Consideração de resíduos coloridos nas variáveis de medida:** o cálculo da covariância das estimativas pode ser corrigido para levar em consideração a contaminação das variáveis de medida com ruídos coloridos.
- **Ponderação e seleção de parâmetros de interesse:** a necessidade de desenvolvimento de manobras de ensaios que possibilitem o acesso preferencial a determinado parâmetro ou a determinado grupo de parâmetros pode ser suprida através de uma matriz de ponderação, ou através da seleção de parâmetros a serem levados em consideração no processo.
- **Seleção de objetivos relativos:** a função de aptidão pode levar em consideração as covariâncias relativas das estimativas paramétricas, o que pode substituir o uso de matrizes de ponderação.
- **Soluções globais:** a ferramenta de desenvolvimento e otimização de manobras de ensaios em vóo apresentada neste estudo tende a alcançar soluções globais, uma vez que utiliza, para a minimização da função de aptidão, um algoritmo genético.

1.4 Organização do Trabalho

No capítulo 2, os principais aspectos do método de erro de saída e do critério de estimação por máxima verossimilhança são apresentados. Além disso, são abordados os problemas que envolvem erros de estimação paramétrica, principalmente polarizações e dispersões. Em um segundo momento, alguns aspectos teóricos da desigualdade de Cramer-Rao e da matriz de informação de Fisher são abordados, possibilitando o entendimento dos critérios de otimização de sinais de excitação para manobras de ensaios em vóo discutidos neste estudo.

No capítulo 3, as principais características da técnica de otimização de sinais de excitação são mostradas. A formulação do problema e os critérios de otimização propostos para compor a função custo são apresentados. Além disso, é feita uma introdução ao algoritmo genético de otimização, o qual é utilizado para a resolução do problema. Suas principais virtudes e idealizações são mostradas.

O capítulo 4 é dedicado a análise de resultados. Cada exemplo mostrado neste capítulo

possui um objetivo fundamental, o qual envolve a abordagem das principais virtudes das técnicas de especificação de manobras de ensaios em vôo para estimação de parâmetros. Primeiramente, são mostrados estudos de caso com dados simulados, envolvendo comparações com resultados obtidos em trabalhos anteriores. Em um segundo momento, são apresentados resultados experimentais obtidos através de uma campanha de ensaios em vôo dedicada a análise das manobras de ensaios em vôo.

O capítulo 5 apresenta as conclusões e comentários a respeito dos principais pontos do trabalho. Através da análise dos resultados mostrados no capítulo 4, fica clara a necessidade da utilização de sinais de excitação otimizados para um acesso mais acurado das estimativas paramétricas. Além de disso, torna-se, também, evidente, por parte do algoritmo de otimização dos sinais de excitação, a necessidade de consideração de resíduos coloridos nas variáveis de medida para acessar problemas práticos, principalmente os que envolvem objetivos específicos.

Capítulo 2

Estimação de Parâmetros

2.1 Introdução

Este estudo utiliza-se da estimação de parâmetros de aeronaves através da aplicação do algoritmo *Output-Error* em conjunto com o critério de máxima verossimilhança. A metodologia de abordagem deste processo, basicamente, pode ser dividida em cinco grandes grupos: Manobras, Modelos, Medidas, Métodos e Validação, de acordo com o mostrado na figura 2.1.

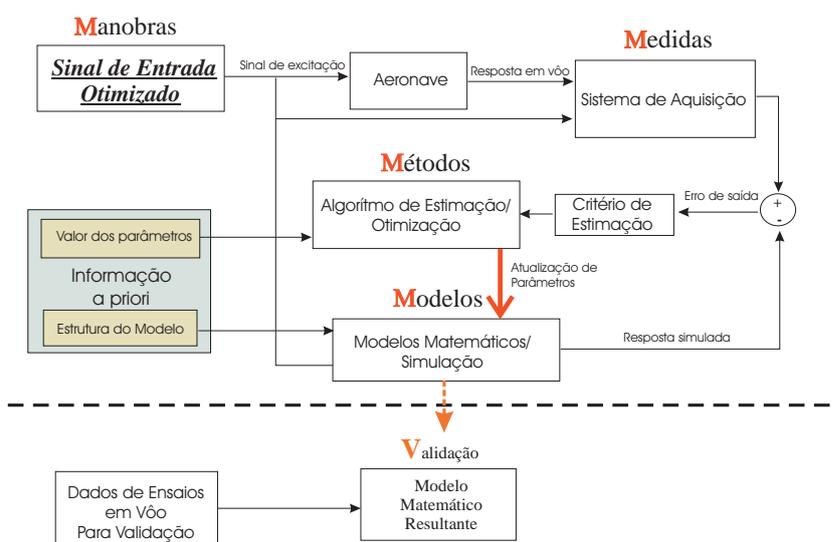


Figura 2.1: Diagrama do Processo de Estimação Paramétrica (Output-Error)

As manobras de ensaios em voo para estimação paramétrica são o objeto deste estudo. Basicamente, o que se busca no momento em que se especifica as manobras de ensaio

para estimação de parâmetros de aeronaves é o aumento da eficiência dos algoritmos. No capítulo 3 deste trabalho, serão abordados maiores detalhes a respeito do desenvolvimento sinais de excitação otimizados para manobras de ensaios em vôo dedicadas a estimação paramétrica.

Os modelos são as representações matemáticas das dinâmicas que estão sob análise. Hoje em dia, os modelos matemáticos que descrevem a dinâmica de aeronaves estão bem estabelecidos na literatura e estão descritos no Apêndice A deste trabalho. São utilizados em larga escala modelos não lineares no espaço de estados, os quais podem descrever os seis graus de liberdade das aeronaves, ou modelos desacoplados, os quais descrevem dinâmicas longitudinais e latero-direcionais em separado. Geralmente, também são utilizados modelos lineares para pequenas perturbações. Nestes modelos, encontram-se os parâmetros a serem estimados. Geralmente, existe um conhecimento a priori a respeito dos dados de geometria e massa do veículo aéreo em ensaio e a respeito de seus parâmetros aerodinâmicos. Este conhecimento pode ser oriundo de estimativas tabeladas, de ensaios em túnel de vento, ou até mesmo de ensaios em vôo realizados previamente.

As medidas estão relacionadas com os modelos através das equações de saída dos mesmos. As equações de saída descrevem variáveis que podem ser estados ou não. As mesmas podem ser medidas pelos sistemas de aquisição de dados, os quais introduzem os ruídos de medida. As equações de saída são as ligações entre os parâmetros do modelo a serem estimados e a resposta temporal da aeronave.

Os métodos dizem respeito ao processo de estimação propriamente dito. Neste bloco, devem ser definidos os critérios que compõe a função custo para o processo de otimização, bem como os métodos de otimização. O presente estudo utiliza o critério de máxima verossimilhança para compor a função custo através do erro de saída, a qual é minimizada através do método Gauss-Newton. A idéia básica do método *Output-Error* está mostrada no esquema da figura 2.1.

Um sinal de excitação otimizado para a manobra de ensaio em vôo é selecionado e aplicado à aeronave. A resposta temporal da aeronave e o sinal de excitação são gravados pelo sistema de aquisição de dados. O mesmo sinal de excitação é aplicado ao modelo matemático, o que gera a resposta temporal simulada do conjunto de variáveis de saída. Esta história temporal é comparada com as variáveis medidas em vôo, o que gera o

erro de saída, ou *Output-Error*. Este erro de saída deve ser minimizado pelo algoritmo de estimação em função dos parâmetros do modelo a serem estimados. Este processo gera uma atualização para as estimativas iniciais dos parâmetros. O procedimento é repetido iterativamente, até que algum critério de parada seja atingido. É interessante salientar que o método de *Output-Error* leva em consideração apenas o ruído de medida, diferentemente do método *Filter-Error*, que considera ruído de estado e de medida.

Pode-se dizer que a última etapa no processo é a validação dos dados. Neste procedimento, dados de entrada e de saída que não foram utilizados no processo de estimação são utilizados para verificar se a resposta temporal do sistema com os parâmetros estimados é adequada, e se realmente reproduz a resposta temporal da aeronave em vôo.

Neste capítulo, serão abordados alguns aspectos do estimador por máxima verossimilhança. Algumas propriedades estatísticas dos estimadores, tais como, polarização, eficiência, inequação de Cramer-Rao, entre outras, também serão discutidos. Estes conceitos são de suma importância para o entendimento do acesso a acuidade das estimativas, e para o posterior entendimento das técnicas de desenvolvimento e otimização de sinais de excitação para manobras de ensaios em vôo utilizadas para estimação paramétrica.

2.2 Estimador por Máxima Verossimilhança

A abordagem do estimador por máxima verossimilhança em separado se faz necessária neste estudo, uma vez que este método possui propriedades bastante significativas no que tange a confiabilidade das suas estimativas. Estas propriedades serão abordadas ao longo do texto, principalmente durante a apresentação da desigualdade de Cramer-Rao e da Matriz de Informação de Fisher.

A abordagem a respeito do estimador por máxima verossimilhança feita neste estudo é bastante sucinta, principalmente porque o método de estimação não é objeto da presente dissertação. Maiores detalhes do método são abordados e podem ser encontrados em (CRAMÉR, 1946), (GOODWIN; PAYNE, 1977) e (LJUNG, 1987). Além disso, as aplicações do estimador por máxima verossimilhança no meio aeronáutico, mais especificamente no que tange a estimação de parâmetros aerodinâmicos de aeronaves, podem ser encontrados em (MAINE; ILIFF, 1986), (??) e (JATEGAONKAR; PLAETSCHKE, 1983).

Os modelos dinâmicos utilizados para estimação paramétrica podem, na maioria dos casos, serem descritos pelas seguintes equações de estado:

$$\dot{x}(t) = f(x(t), u(t), \theta) \quad (2.1)$$

Com $x(0) = 0$ e x sendo o vetor de estado, o qual possui dimensão n_x . Além disso u é o vetor de variáveis de controle.

As estimativas paramétricas não são oriundas diretamente das equações de estado, mas sim das variáveis de saída. Os parâmetros do modelo estão relacionados com as variáveis de saída através do vetor de equações de observação:

$$y(t) = h(x(t), u(t), \theta) \quad (2.2)$$

onde y é o vetor de variáveis observadas, com dimensão n_y .

Além disso, é necessário considerar que as variáveis de observação são contaminadas com ruído de medida, formando o vetor de variáveis de medida y_m , que pode ser expresso por:

$$y_m(i) = y(i) + v(i) \quad (2.3)$$

onde $i = 1, 2, 3, \dots, N$ e N é a dimensão do vetor de medida. $v(i)$ é o ruído de medida. Na formulação do estimador por máxima verossimilhança é assumido que o ruído de medida é gaussiano, de média zero (ruído branco):

$$E\{v(i)\} = 0 \quad (2.4)$$

$$E\{v(i)v^*(j)\} = R \cdot \delta_{ij} \quad (2.5)$$

onde $i = j = 1, 2, 3, \dots, N$, R é a matriz de covariância do ruído e E denota o operador de esperança matemática. A matriz R pode também ser estimada através de:

$$\hat{R} = \frac{1}{N} \sum_{i=1}^N [y_m(i) - y(i)][y_m(i) - y(i)]^* \quad (2.6)$$

A hipótese do ruído de medida ser branco implica que o erro preditivo nos diferentes pontos da curva temporal não são correlacionados, ou seja, são independentes.

Assim sendo, considerando a distribuição do ruído de medida, é possível determinar a função de densidade probabilidade da ocorrência do vetor de variáveis de medida, condicionada ao vetor de parâmetros do modelo, ou seja, $p(Y|\theta)$, onde Y denota o conjunto de variáveis de medida:

$$p(Y|\theta) = \left[(2\pi)^{-\frac{q}{2}} |R|^{-\frac{1}{2}} \right]^N \exp \left\{ -\frac{1}{2} \sum_{i=1}^N [y_m(i) - y(i)]^* R^{-1} [y_m(i) - y(i)] \right\} \quad (2.7)$$

A função $p(Y|\theta)$, chamada de função de verossimilhança, descreve a densidade de probabilidade para a ocorrência do vetor de medida Y dado o vetor de parâmetros θ . O método, portanto, é chamado de método por máxima verossimilhança por tentar maximizar (2.7) em função de θ . Ou seja, o método de máxima verossimilhança procura o vetor de parâmetros θ que maximiza a probabilidade de ocorrência das variáveis de medida do sistema dinâmico ensaiado.

Por motivos computacionais, é conveniente que os algoritmos de estimação por máxima verossimilhança trabalhem no sentido de minimizar o logaritmo negativo de (2.7), o que equivale a maximizar $p(Y|\theta)$. Desta maneira, a função custo fica:

$$J(\theta) = -L(p(Y|\theta)) = \frac{N}{2} \ln [(2\pi)^q |R|] + \frac{1}{2} \sum_{i=1}^N [y_m(i) - y(i)]^* R^{-1} [y_m(i) - y(i)] \quad (2.8)$$

Por fim, assumindo que R é conhecida, o primeiro termo de (2.8) é uma constante, a qual não influencia no processo de minimização, podendo ser desconsiderada, assim sendo, a função custo passa a ser:

$$J(\theta) = \frac{1}{2} \sum_{i=1}^N [y_m(i) - y(i)]^* R^{-1} [y_m(i) - y(i)] \quad (2.9)$$

Três são as propriedades do estimador por máxima verossimilhança de especial interesse neste estudo. O estimador por máxima verossimilhança é assintoticamente não

polarizado e eficiente, bem como apresenta a distribuição de suas estimativas assintoticamente de forma normal. A importância destas propriedades para o presente trabalho ficará clara mais a frente, à medida que as mesmas forem abordadas com maiores detalhes.

2.3 Acuidade das Estimativas

A análise da acuidade das estimativas no processo de identificação paramétrica de aeronaves é de fundamental importância para acessar os níveis de confiabilidade do processo como um todo. As ferramentas de acesso aos níveis de incerteza tem sido objetos de intensa pesquisa e aperfeiçoamento no campo da identificação de sistemas aplicada a extração de derivadas de estabilidade e controle de aeronaves (MAINE; ILIFF, 1981b) (MAINE; ILIFF, 1981a) (ILIFF; MAINE; MONTGOMERY, 1979) (MORELLI; KLEIN, 1994).

Neste estudo, serão tratadas algumas ferramentas que podem auxiliar na avaliação qualitativa das estimativas. Primeiramente, serão abordados os conceitos de julgamento de engenharia, polarização e dispersão de estimativas. Em um segundo momento, será apresentada a desigualdade de Cramer-Rao e alguns aspectos a respeito da matriz de informação de Fisher. Os conceitos apresentados neste capítulo são de fundamental importância para o entendimento dos critérios de desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica apresentados no capítulo 4. Além disso, considerando a utilização do estimador por máxima verossimilhança, será mostrada uma técnica de correção do cálculo das covariâncias teóricas devido à presença de ruído colorido nas variáveis de medida.

Existem outros instrumentos de acesso teórico à confiabilidade das estimativas, tais como a sensibilidade, elipsóide de incerteza, correlação paramétrica e limites de Cramer-Rao. Todos eles de alguma forma estão relacionados com o conceito de desigualdade de Cramer-Rao, e não serão objetos de análise neste estudo, uma vez que a análise da desigualdade de Cramer-Rao é suficiente para a composição dos critérios de desenvolvimento e otimização propostos.

2.3.1 Julgamento de Engenharia no Processo de Estimação Derivadas Aerodinâmicas de Aeronaves

O julgamento de engenharia no processo de identificação de sistemas é de fundamental importância, pois a análise dos resultados da estimação paramétrica contribui fortemente para a qualidade do processo. Isso é justificado porque neste ponto algumas discrepâncias podem ser detectadas, fornecendo ajuda para que problemas sejam corrigidos a tempo, antes que os resultados sejam utilizados em suas aplicações.

Em um primeiro momento, é interessante fazer referência à modelagem dinâmica do sistema em estudo. Os erros contidos nos modelos matemáticos acarretam incertezas ao processo de estimação paramétrica e, principalmente, introduzem erros sistemáticos nos estimadores. É de suma importância ter em mente que os modelos matemáticos empregados sempre haverão de ter limitações e que a representação dos fenômenos físicos envolvidos é válida apenas quando as mesmas são respeitadas. Neste ponto também pode-se salientar que através do julgamento de engenharia podem ser detectadas dinâmicas que não são levadas em consideração nos modelos de predição, mas que podem estar influenciando no processo. Através desta análise de engenharia, os erros ou hipóteses assumidas podem ser corrigidos, bem como pode-se tomar cuidado para que dinâmicas não modeladas não sejam excitadas durante os experimentos.

O julgamento de engenharia a respeito da dispersão e da polarização de estimativas também introduz um fator diferencial no que tange ao incremento da confiabilidade do processo de identificação de sistemas. Através do conhecimento a priori das características e dos fenômenos físicos associados aos sistemas em estudo, pode-se verificar resultados das estimativas paramétricas que não condizem com o significado físico dos parâmetros em questão. Estas características podem apontar principalmente para erros de modelagem. Além disso, a análise da dispersão de estimativas, quando possível, é bastante significativa no que tange ao acesso aos níveis de incerteza associados ao processo. A alta dispersão pode apontar para a não adequação dos dados experimentais utilizados para estimação paramétrica e para a necessidade de desenvolvimento de novos experimentos.

2.3.2 Erros de Polarização das Estimativas Paramétricas

A polarização, ou bias, estatisticamente, pode ser definida como um erro sistemático das estimativas paramétricas (GOODWIN; PAYNE, 1977) (MAINE; ILIFF, 1981a). Vamos considerar que as estimativas sejam feitas através de G , que é uma função das variáveis de medida contidas no vetor Y , ou seja:

$$\hat{\theta} = G(Y) \quad (2.10)$$

onde $\hat{\theta}$ denota o vetor de parâmetros estimados. Além disso, Y é função da entrada de controle, do vetor dos parâmetros do modelo, e do ruído de medida:

$$Y = Y(\theta, u, v) \quad (2.11)$$

Assim sendo, a polarização é definida como:

$$b(\theta) = E\{\hat{\theta} - \theta\} = E\{G(Y, u, v)\} - \theta \quad (2.12)$$

Ou seja, a polarização das estimativas é a esperança matemática da estimativa menos o valor real dos parâmetros, ou melhor, é o erro sistemático da estimativa. Nota-se que a polarização é função do vetor de parâmetros θ e do vetor de entradas u .

É interessante salientar que após algumas hipóteses assumidas pode-se provar que o estimador por máxima verossimilhança é um estimador assintoticamente não polarizado (BALAKRISHNAN, 1968). Mesmo que esta propriedade indique que a polarização será nula apenas quando o tempo tender ao infinito, pode-se considerar que a mesma se torna desprezível quando são utilizadas curvas temporais contendo pelo menos alguns ciclos do modo natural mais lento do sistema dinâmico em questão.

2.3.3 Erros de Dispersão das Estimativas Paramétricas

Considerando que seja possível realizar um experimento inúmeras vezes nas mesmas condições para estimar o mesmo parâmetro, a dispersão observada das estimativas pode ser uma importante ferramenta para o acesso à eficiência do processo como um todo.

A dispersão observada possui grande vantagem sobre os métodos teóricos de cálculo de confiabilidade de estimativas, uma vez que apresenta, na prática, os reais intervalos de confiança das estimativas. A grande desvantagem desta abordagem, entretanto, é a necessidade de um grande número de estimativas para que a análise venha a ter valor estatístico.

Outro ponto interessante a salientar, é que a dispersão observada, por si só, não pode ser tida como o único instrumento de análise, pois as estimativas podem possuir baixa dispersão, demonstrando acuidade no processo, mas em torno de um valor polarizado, devido, principalmente, a erros de modelagem. É importante, nestes casos, que o julgamento de engenharia seja utilizado para analisar se os valores das estimativas, mesmo possuindo baixa dispersão, possuem significado físico e condizem com valores de conhecimento a priori.

2.3.4 Desigualdade de Cramer-Rao e Matriz de Informação de Fisher

A desigualdade de Cramer-Rao, assumindo a existência de $p(Y|\theta)$ e que o estimador é assintoticamente não polarizado, define como o limite inferior para covariância das estimativas paramétricas a inversa da matriz de informação (LJUNG, 1987) (BALAKRISHNAN, 1968) (GOODWIN; PAYNE, 1977) (MAINE; ILIFF, 1981a), ou seja:

$$\text{cov}(\hat{\theta}) \geq M(\theta)^{-1} \quad (2.13)$$

onde M é a matriz de informação que, por definição, é:

$$M(\theta) = E \{ [\nabla_{\theta} \ln p(Y|\theta)] [\nabla_{\theta} \ln p(Y|\theta)]^* | \theta \} \quad (2.14)$$

Para mostrar que a inequação (2.13) é verdadeira, deve-se lançar mão do seguinte **Lema** (MAINE; ILIFF, 1985): tendo x e y como dois vetores aleatórios, sabe-se que:

$$E \{ xx^* \} \geq E \{ xy^* \} [E \{ yy^* \}]^{-1} E \{ yx^* \} \quad (2.15)$$

A partir de (2.15), sabendo-se que $\hat{\theta}$ é uma função de Y e fazendo-se com que:

$$x = \hat{\theta}(Y) - \theta \quad (2.16)$$

$$y = \nabla_{\theta} \ln p(Y|\theta) \quad (2.17)$$

Tem-se:

$$E \{xy^*|\theta\} = E \left\{ \left(\hat{\theta}(Y) - \theta \right) [\nabla_{\theta} \ln p(Y|\theta)]^* | \theta \right\} \quad (2.18)$$

$$E \{xy^*|\theta\} = \int_{-\infty}^{\infty} \left(\hat{\theta}(Y) - \theta \right) [\nabla_{\theta} \ln p(Y|\theta)]^* p(Y|\theta) dY \quad (2.19)$$

Sabendo-se que:

$$\nabla_{\theta} \ln p(Y|\theta) = \frac{\nabla_{\theta} p(Y|\theta)}{p(Y|\theta)} \quad (2.20)$$

e que, da definição de densidade de probabilidade, $\int_{-\infty}^{\infty} p(Y|\theta) dY$ é igual a I , tem-se:

$$E \{xy^*|\theta\} = \int_{-\infty}^{\infty} \left(\hat{\theta}(Y) - \theta \right) \left[\frac{\nabla_{\theta} p(Y|\theta)}{p(Y|\theta)} \right]^* p(Y|\theta) dY \quad (2.21)$$

$$E \{xy^*|\theta\} = \int_{-\infty}^{\infty} \left(\hat{\theta}(Y) - \theta \right) [\nabla_{\theta}^* p(Y|\theta)] dY \quad (2.22)$$

Fazendo-se a expansão da integral acima, chega-se à:

$$E \{xy^*|\theta\} = \int_{-\infty}^{\infty} \hat{\theta}(Y) [\nabla_{\theta}^* p(Y|\theta)] dY - \int_{-\infty}^{\infty} \theta [\nabla_{\theta}^* p(Y|\theta)] dY \quad (2.23)$$

Uma vez que $\hat{\theta}$ é apenas função de Y , o primeiro termo da expressão acima fica:

$$\int_{-\infty}^{\infty} \hat{\theta}(Y) [\nabla_{\theta}^* p(Y|\theta)] dY = \nabla_{\theta}^* \int_{-\infty}^{\infty} \hat{\theta}(Y) p(Y|\theta) dY = \nabla_{\theta}^* E \left\{ \hat{\theta}(Y) | \theta \right\} \quad (2.24)$$

Da definição de polarização, onde $b(\theta) = E \{ \hat{\theta}(Y) | \theta \} - \theta$, observa-se que:

$$\theta + b(\theta) = E \{ \hat{\theta}(Y) | \theta \} \quad (2.25)$$

e:

$$\nabla_{\theta} [\theta + b(\theta)] = \nabla_{\theta} \left[E \{ \hat{\theta}(Y) | \theta \} \right] \quad (2.26)$$

Logo:

$$\int_{-\infty}^{\infty} \hat{\theta}(Y) [\nabla_{\theta}^* p(Y|\theta)] dY = \nabla_{\theta}^* [\theta + b(\theta)] = I + \nabla_{\theta}^* b(\theta) \quad (2.27)$$

Passando agora a analisar o segundo termo da equação 2.23, tem-se:

$$- \int_{-\infty}^{\infty} \theta [\nabla_{\theta}^* p(Y|\theta)] dY = -\theta \nabla_{\theta}^* \int_{-\infty}^{\infty} p(Y|\theta) dY = -\theta \nabla_{\theta}^* I = 0 \quad (2.28)$$

uma vez que θ não é função de Y . Assim sendo, substituindo-se (2.27) e (2.28) na equação (2.23), tem-se:

$$E \{ xy^* | \theta \} = I + \nabla_{\theta} b(\theta) \quad (2.29)$$

Por definição, tem-se que a matriz de informação é:

$$M(\theta) \equiv E \{ (\nabla_{\theta} \ln [p(Y|\theta)]) (\nabla_{\theta}^* \ln [p(Y|\theta)]) | \theta \} \quad (2.30)$$

Que, para este caso, equivale a $E \{ yy^T | \theta \}$. Além disso, $E \{ xy^T \} = E \{ yx^T \}$. Substituindo-se, portanto, (2.29) e (2.30) no lema (2.15), tem-se:

$$\text{cov}(\hat{\theta}) = E \left\{ (\hat{\theta} - \theta) (\hat{\theta} - \theta)^* | \theta \right\} \geq [I + \nabla_{\theta} b(\theta)] M(\theta)^{-1} [I + \nabla_{\theta} b(\theta)]^* \quad (2.31)$$

A equação acima denota a desigualdade de Cramer-Rao para estimadores com po-

larização finita. Para estimadores assintoticamente não polarizados, entretanto, pode-se assumir que:

$$\text{cov}(\hat{\theta}) \geq M(\theta)^{-1} \quad (2.32)$$

A desigualdade acima é verdadeira apenas para estimadores assintoticamente não polarizados, tais como o estimador por máxima verossimilhança. Além disso, por definição, para que a igualdade em (2.32) exista, o estimador deve ser eficiente. São raros os estimadores eficientes; é possível, entretanto, demonstrar que o estimador por máxima verossimilhança, para grandes períodos de dados temporais, o é. É importante salientar também que, para o sistema descrito em (2.1) - (2.5), considerando (2.10) e tendo em mente que y_m não é função de θ , a matriz de informação pode ser descrita por (MAINE; ILIFF, 1981a)(MAINE; ILIFF, 1985)(MORELLI, 1990):

$$M = \left[\sum_{i=1}^N \frac{\partial y(i)^*}{\partial \theta} R^{-1} \frac{\partial y(i)}{\partial \theta} \right] \quad (2.33)$$

A matriz de informação na forma (2.33) será largamente utilizada neste estudo para compor os critérios de desenvolvimento e otimização de manobras de ensaios em vôo para estimação de derivadas de estabilidade e controle de aeronaves.

2.3.5 Correção do Cálculo das Covariâncias para a Presença de Ruído Colorido nas Variáveis de Medida

O acesso aos níveis de incerteza de estimativa por máxima verossimilhança são, tradicionalmente, obtidos através da matriz de informação de Fisher e da desigualdade de Cramer-Rao, conforme discutido anteriormente.

Em trabalhos anteriores (ILIFF; MAINE, 1976), entretanto, nota-se grande desconforto com estas abordagens, uma vez que os níveis de incerteza de estimativas paramétricas oriundas de dados de ensaios em vôo e calculados da forma tradicional se mostraram muito otimistas, não representando adequadamente a dispersão observada nas estimativas. Propunha-se então, sem abordagem formal, a utilização de um fator de correção entre 5 e 10 que, quando aplicado ao limite de Cramer-Rao, dava acesso aos níveis corrigidos de

incerteza. Este fator era altamente dependente do julgamento de engenharia.

Ilyff e Maine (ILIFF; MAINE, 1977) (MAINE; ILIFF, 1981a) (MAINE; ILIFF, 1981b), depois de extensa discussão, chegaram à conclusão que a discrepância entre a dispersão observada nas estimativas e os níveis de incerteza calculados através dos limites inferiores de Cramer-Rao é causada pela introdução de resíduos coloridos nas variáveis de medida. Nesta oportunidade já foram propostas metodologias formais de correção do cálculo dos intervalos de confiança. Posteriormente, Morelli e Klein (MORELLI; KLEIN, 1994) voltaram a abordar o assunto. Os autores propuseram uma abordagem para correção mais abrangente do que aquela proposta por Ilyff e Maine. Esta abordagem será utilizada neste estudo e introduzida nas técnicas de desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica.

Observa-se, basicamente, que a discrepância é oriunda da natureza do estimador por máxima verossimilhança e da teoria que envolve a determinação da matriz de informação. O estimador por máxima verossimilhança definido anteriormente, por sua natureza, não leva em consideração resíduos coloridos. Esta hipótese também é levada em consideração na teoria que envolve o cálculo da matriz de informação de Fisher e, por conseguinte, dos limites inferiores de Cramer-Rao (GOODWIN; PAYNE, 1977) (BALAKRISHNAN, 1968). Geralmente, os limites de Cramer-Rao levam a níveis de incerteza muito otimistas quando os dados de ensaios em vôo contêm resíduos coloridos.

A técnica desenvolvida por Morelli e Klein propõe a introdução de um termo que considera a correlação temporal dos resíduos de medida. Considerando-se que, quando a estimativa dos parâmetros estiver próxima dos valores reais, a saída preditiva pode ser linearizada em relação ao vetor de parâmetros:

$$y(i) = \hat{y}(i) + S(i) (\theta - \hat{\theta}) \quad (2.34)$$

onde $S(i)$ é a matriz de sensibilidade das equações de saída aos parâmetros do sistema:

$$S(i) = \left. \frac{\partial y(i)}{\partial \theta} \right|_{\theta=\hat{\theta}} \quad (2.35)$$

e $\hat{y}(i)$ denota o vetor de saídas computado a partir do vetor de parâmetros estimados, $\hat{\theta}$, no instante $(i-1)\Delta t$ e $i = 1, 2, 3, \dots, N$.

Pode-se, aplicando-se a equação (2.34) na equação (2.9) e fazendo-se o gradiente da função custo em relação ao vetor de parâmetros igual a zero, chegar a:

$$\nabla_{\theta} J(\theta) = - \sum_{i=1}^N S(i)^* R^{-1} \left[y_m(i) - \hat{y}(i) - S(i) (\theta - \hat{\theta}) \right] \quad (2.36)$$

A equação (2.36) pode ser escrita da seguinte maneira:

$$\nabla_{\theta} J(\theta) = - \sum_{i=1}^N S(i)^* R^{-1} [y_m(i) - \hat{y}(i)] + \sum_{i=1}^N S(i)^* R^{-1} S(i) (\theta - \hat{\theta}) \quad (2.37)$$

Resolvendo a (2.37) para $(\theta - \hat{\theta})$, tem-se:

$$\Delta \hat{\theta} \equiv \theta - \hat{\theta} = \left[\sum_{i=1}^N S(i)^* R^{-1} S(i) \right]^{-1} \sum_{i=1}^N S(i)^* R^{-1} [y_m(i) - \hat{y}(i)] \quad (2.38)$$

onde o resíduo pode ser definido como $v(i) = y_m(i) - \hat{y}(i)$. A covariância das estimativas pode ser expressa utilizando a equação (2.39):

$$\begin{aligned} cov(\hat{\theta}) &= E \left\{ (\hat{\theta} - \theta) (\hat{\theta} - \theta)^* \right\} \\ &= E \left\{ \sum_{i=1}^N \sum_{j=1}^N DS(i)^* R^{-1} v(i) v(j)^* R^{-1} S(j) D \right\} \end{aligned} \quad (2.39)$$

A matriz de sensibilidade, a matriz de dispersão e a matriz de covariância do ruído na equação (2.39) são oriundas da formulação convencional do estimador por máxima verossimilhança (MLE). Se for assumido que a dependência destes termos às estimativas do MLE for desprezível, (2.39) pode ser reescrita:

$$cov(\hat{\theta}) = D \left[\sum_{i=1}^N \sum_{j=1}^N S(i)^* R^{-1} E \{ v(i) v(j)^* \} R^{-1} S(j) \right] D \quad (2.40)$$

Nota-se que, se o resíduo for considerado como gaussiano de média zero, $E \{ v(i) v(j)^* \} = R \cdot \delta_{ij}$ e a equação 2.40 é reduzida a matriz de dispersão D .

Para resíduos coloridos, entretanto, $E \{v(i)v(j)^T\}$ pode ser estimada através da matriz de autocorrelação dos resíduos, definida por (BENDAT; PIERSON, 2000):

$$R_{vv}(k) = \frac{1}{N} \sum_{i=1}^N v(i)v(i+k)^* = R_{vv}(-k) \quad (2.41)$$

Desta maneira, a covariância das estimativas com ruído colorido pode ser determinada através de (2.40), aplicando-se (2.41), ou seja:

$$\text{cov}(\hat{\theta}) = D \left[\sum_{i=1}^N S(i)^* R^{-1} \sum_{j=1}^N R_{vv}(i-j) R^{-1} S(j) \right] D \quad (2.42)$$

A equação (2.42) é a aplicação proposta em (MORELLI; KLEIN, 1994) para a correção do cálculo dos intervalos de confiança quando ocorrer resíduos coloridos nos dados. Esta técnica pode ser aplicada no pós-processamento dos resultados das estimativas por máxima verossimilhança, não interferindo diretamente no algoritmo de estimação.

A técnica de desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica apresentada neste estudo leva em consideração resíduos coloridos. A correção nos critérios de otimização é feita através da inclusão da equação 2.42 na função custo, considerando que R_{vv} compõe o modelo de conhecimento a priori. Isto será visto com maiores detalhes no capítulo 4.

Capítulo 3

Manobras de Ensaio em Vôo Para Estimação Paramétrica

3.1 Introdução

A otimização dos sinais de excitação para manobras de ensaios em vôo para estimação paramétrica assume que existe uma estrutura de modelo dinâmico conhecida através da física do processo. Esta estrutura deve conter os parâmetros estimados a priori e as características do modelo de medida. Também é conveniente assumir que a estimação se faz através de um estimador assintoticamente não polarizado e eficiente.

A acuidade das estimações pode ser acessada através do desvio-padrão das mesmas. De acordo com o demonstrado no capítulo 2, o limite inferior teórico para o desvio padrão das estimativas depende apenas do conteúdo de informação dos dados de ensaios em vôo. Estes limites são chamados de limites inferiores de Cramer-Rao e são independentes do algoritmo de estimação utilizado.

O critério utilizado para otimização leva em conta, portanto, os limites inferiores de Cramer-Rao. Desta maneira, sabe-se que o experimento está sendo desenvolvido de maneira que a acuidade das estimativas seja maximizada. Algumas abordagens indiretas podem ser utilizadas para, de certa forma, encontrar sinais de excitação que minimizem os limites de Cramer-Rao, principalmente, no domínio da frequência ([MULDER; BREEMAN, 1994](#))([MARCHAND, 1977](#)). Neste caso, a idéia é utilizar sinais de ondas quadradas

pré-estabelecidos (*doublet*, 2-1-1, 3-2-1-1) e sintonizá-los de maneira a maximizar a densidade espectral de potência dos mesmos nas frequências próximas aos modos naturais do sistema dinâmico em estudo. Desta maneira, espera-se aumentar os níveis de excitação do sistema, o que vem a ocasionar o aumento da sensibilidade das equações de saída aos parâmetros do modelo e, indiretamente, reduzir os limites de Cramer-Rao.

Por outro lado, pode-se buscar diretamente a minimização dos limites de Cramer-Rao em função do sinal de excitação. Esta abordagem já foi feita em trabalhos anteriores (STEPNER; MEHRA, 1973) (GUPTA; JR., 1975) (MEHRA, 1974b) (MEHRA, 1974a) (MULDER; BREEMAN, 1994). Nestas oportunidades, os autores geralmente utilizaram sistemas lineares para pequenas perturbações. Para a composição dos critérios de otimização, alguma norma da matriz de informação, denotada por M , foi utilizada. Em alguns casos, a maximização do traço de M , ou do determinante de M foram utilizados. Da mesma forma, verifica-se a minimização do traço de M^{-1} ou do determinante de M^{-1} , entre outras normas. Independentemente da norma utilizada, todos os critérios buscavam a minimização dos limites inferiores de Cramer-Rao para a estimativa dos parâmetros.

Geralmente se observa que em um sistema dinâmico existem parâmetros ou grupos de parâmetros de maior interesse, dependendo da aplicação e das necessidades do usuário final da estimação paramétrica. Neste sentido, também se observa a utilização de uma matriz de ponderação, a qual possibilita a otimização de um sinal de excitação para melhorar o acesso à parâmetros julgados de maior interesse.

Todos os trabalhos citados acima não se preocuparam em introduzir nos critérios de otimização o tempo de realização da manobra de ensaio. O tempo disponível era mantido fixo, escolhido através da experiência e do julgamento de engenharia. O primeiro a abordar este problema e colocar o tempo de realização do sinal de excitação na função custo, no sentido de minimizá-lo, foi Chen (CHEN, 1975). Posteriormente, Morelli (MORELLI, 1990) também buscou a otimização de manobras com o menor tempo possível. Neste caso, o critério de otimização é composto por valores objetivos para os limites de Cramer-Rao e pelo tempo de aplicação do sinal de excitação. Ou seja, os limites de Cramer-Rao são minimizados até um certo valor e o tempo de aplicação é reduzido ao máximo. De certa forma, esta abordagem elimina a necessidade da utilização de uma matriz de ponderação, pois especifica os objetivos para cada parâmetro. Estes objetivos devem ser determinados

pelo usuário final da estimação paramétrica.

Quanto às restrições impostas no processo de otimização, o mais encontrado nos trabalhos anteriores é a imposição de restrições à amplitude e à energia do sinal de excitação. Esta abordagem permite o acesso indireto à limitação das variáveis de saída. No trabalho de Morelli, nota-se a preocupação de restringir diretamente as variáveis de saída, uma vez que estas são de fundamental importância para a manutenção do experimento dentro dos níveis de segurança e para o respeito às hipóteses assumidas no modelo matemático. A imposição de restrições indiretas às variáveis de saída através da limitação da energia e da amplitude do sinal de excitação facilita consideravelmente o processo de otimização e diminui o custo computacional do mesmo. Com esta abordagem, entretanto, o processo se torna dependente da análise das saídas a posteriori e conseqüente verificação quanto ao respeito das restrições indiretas.

Outro ponto interessante de salientar é quanto ao tipo de sinais de excitação levados em consideração. Em alguns casos, os sinais de excitação otimizados são gerados através de funções contínuas (MEHRA, 1974b) (STEPNER; MEHRA, 1973) (GUPTA; JR., 1975), geralmente senoidais. Em outros trabalhos, os sinais otimizados são compostos de ondas quadradas (MORELLI, 1990). Os sinais de ondas quadradas apresentam vantagens no que tange à facilidade de implementação. Além disso, sinais de ondas quadradas apresentam espectros de frequência mais abrangentes do que sinais senoidais, principalmente considerando o tempo de aplicação dos mesmos. Esta característica facilita a estimação paramétrica, pois possibilita a excitação mais abrangente de modos naturais dos sistemas em estudo.

Quanto ao modelo de medida, todos os trabalhos anteriores assumem que o ruído que contamina as variáveis medidas é Gaussiano de média zero e covariância determinada por uma matriz denotada, normalmente, por R . Não foi verificado nenhum tipo de abordagem para desenvolvimento e otimização de sinais de excitação para experimentos objetivando estimação paramétrica que levassem em consideração resíduos coloridos nas variáveis de medida. Sinais de excitação gerados através de modelos que não possuem resíduos coloridos nas variáveis de medida, podem ser ineficientes no acesso a problemas reais, os quais freqüentemente são afetados por fenômenos que causam a contaminação de variáveis de medida com ruídos coloridos. A desconsideração de resíduos coloridos certamente oca-

siona estimativas dos limites de Cramer-Rao demasiadamente otimistas, o que se torna um problema, principalmente, quando a sinal de excitação deve ser desenvolvido para atender objetivos específicos.

Nota-se, entre os trabalhos citados, que o trabalho de Morelli ([MORELLI, 1990](#)) apresenta características de maior complexidade, abrangência e aplicabilidade à problemas que envolvem o desenvolvimento de sinais de excitação para manobras de ensaios em vôo para estimação paramétrica. (A técnica desenvolvida pelo referido autor acessa problemas de desenvolvimento para múltiplas entradas de excitação, com a imposição de restrições às variáveis de saídas do sistema, para sistemas em malha fechada, no mínimo de tempo, se preocupando com a implementabilidade dos sinais resultantes.) Além disso, o algoritmo de otimização implementado através de programação dinâmica permite soluções globais. Morelli, entretanto, não considera resíduos coloridos nas variáveis de medida para o desenvolvimento de sinais de excitação.

3.2 Formulação do Problema e Critério de Otimização

Em geral, as técnicas de desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica levam em consideração sistemas lineares sob a teoria de pequenas perturbações. Considera-se que os modelos dinâmicos de aeronaves mostrados nas equações ([A.95-A.97](#)) e ([A.98-A.111](#)) podem ser descritos por:

$$\dot{x} = A(\theta) x(t) + B(\theta) u(t) \quad (3.1)$$

$$x(0) = 0 \quad (3.2)$$

$$y(t) = F(\theta) x(t) + G(\theta) u(t) \quad (3.3)$$

$$y_m = y(i) + v(i) \quad (3.4)$$

onde o vetor de estado x tem dimensão n_x , o vetor de saídas y tem dimensão n_y , o vetor de entradas u tem dimensão n_u , e as matrizes A , B , F e G são funções do vetor de parâmetros do modelo, θ , de dimensão n_θ .

É assumido que o sistema de aquisição de dados contamina o vetor de variáveis de medida, y_m , com o ruído Gaussiano $v(i)$, cuja média é zero e a covariância determinada pela matriz R , ou seja:

$$E \{v(i)\} = 0 \quad (3.5)$$

$$E \{v(i)v(j)^*\} = R \cdot \delta_{ij} \quad (3.6)$$

Onde $i = 1, 2, 3, \dots, N$ e $j = 1, 2, 3, \dots, N$, com N sendo o número de pontos do vetor de variáveis de medida.

O critério de desenvolvimento e otimização pode levar em consideração a matriz de dispersão, abordada no capítulo 2, a qual é definida como:

$$D = M^{-1} \quad (3.7)$$

onde:

$$M = \sum_{i=1}^N S_i^* R^{-1} S_i \quad (3.8)$$

e:

$$S_i = \frac{\partial y_l(i)}{\partial \theta_k} \quad (3.9)$$

Com $l = 1, 2, 3, \dots, n_y$ e $k = 1, 2, 3, \dots, n_\theta$.

A sensibilidade da n-ésima saída aos parâmetros do modelo está na n-ésima linha da matriz S . Da mesma forma, a sensibilidade das saídas ao n-ésimo parâmetro aparece na n-ésima coluna de S . A matriz de sensibilidade é obtida através da diferenciação das equações de saída em função dos parâmetros do modelo:

$$\frac{d}{dt} \left[\frac{\partial x}{\partial \theta_k} \right] = A \frac{\partial x}{\partial \theta_k} + \frac{\partial A}{\partial \theta_k} x + \frac{\partial B}{\partial \theta_k} u \quad (3.10)$$

$$\frac{\partial x}{\partial \theta_k}(0) = 0 \quad (3.11)$$

$$\left[\frac{\partial y}{\partial \theta_k} \right] = F \frac{\partial x}{\partial \theta_k} + \frac{\partial F}{\partial \theta_k} x + \frac{\partial G}{\partial \theta_k} u \quad (3.12)$$

Onde $k = 1, 2, 3, \dots, n_\theta$.

As equações (3.10) - (3.12) são oriundas da diferenciação parcial das equações (3.1) - (3.3) em relação ao vetor de parâmetros do modelo. Observa-se a partir de (3.10) - (3.12) que a sensibilidade das equações de saída aos parâmetros do modelo são influenciadas pelo vetor de entradas de controle, u , tanto diretamente, como função forçante das saídas, quanto indiretamente, através dos estados.

Os limites inferiores para a covariância dos parâmetros são computados a partir da diagonal principal da matriz D da seguinte maneira:

$$cov_k = d_{kk} \quad (3.13)$$

onde $k = 1, 2, 3, \dots, n_\theta$.

O desvio padrão para a estimativa de cada parâmetro é, portanto:

$$\sigma_k = \sqrt{cov_k} = \sqrt{d_{kk}} \quad (3.14)$$

Onde d denota o elemento da matriz de dispersão.

Os limites inferiores para a covariância das estimativas, ou para o desvio-padrão das mesmas, podem ser minimizados em função dos sinais de excitação. Conforme será visto mais à frente, isso pode ser feito diretamente, através da formulação do problema de otimização, ou indiretamente, através da análise dos sinais de excitação no domínio da frequência.

3.2.1 Consideração de resíduos coloridos no modelo de conhecimento a priori do sistema de aquisição de dados

Conforme mostrado no capítulo 2, os limites inferiores de Cramer-Rao calculados a partir da matriz de informação não levam em conta resíduos coloridos nas variáveis de medida. Geralmente, quando o problema de estimação paramétrica de aeronaves passa

a ser tratado com dados reais de ensaios em vôo, o cálculo dos limites de Cramer-Rao, desconsiderando resíduos coloridos nas variáveis de medida, é extremamente otimista no acesso a confiabilidade das estimativas. Para o desenvolvimento de experimentos que possuem necessidades e objetivos claros quanto aos limites de Cramer-Rao, é extremamente importante que se tenha acesso direto à dispersão das estimativas que realmente se deve esperar.

Nesta seção, será mostrado como a técnica proposta por Morelli e Klein ([MORELLI; KLEIN, 1994](#)) para a correção do cálculo da covariância quando houver resíduo colorido nas variáveis de medida pode ser introduzida no algoritmo de desenvolvimento e otimização de sinais de excitação para manobras de ensaios em vôo para estimação paramétrica.

De acordo com a equação (2.42), a covariância das estimativas paramétricas levando em consideração a existência de resíduos coloridos nas variáveis de medida é dada por:

$$\text{cov}(\hat{\theta}) = D_{col} = D \left[\sum_{i=1}^N S(i)^* R^{-1} \sum_{j=1}^N R_{vv}(i-j) R^{-1} S(j) \right] D \quad (3.15)$$

Na equação (3.15), a matriz de autocorrelação dos resíduos de medida, R_{vv} , é tida como parte do modelo de conhecimento a priori do sistema de aquisição de dados, e deve ser informada para o cálculo da função custo.

3.2.2 Composição da Função de Aptidão

A função custo para o procedimento de otimização dos sinais de excitação para estimação paramétrica deve levar em consideração a covariância das estimativas paramétricas. Algumas normas da matriz D (ou D_{col}) podem ser utilizadas. Em trabalhos anteriores, foram utilizadas, basicamente, normas contendo o traço ou o determinante da matriz de covariância. Neste estudo, o traço da matriz de covariância foi uma das opções consideradas para seleção da função de aptidão:

$$J = \text{tr}[D] \quad (3.16)$$

A função (3.16) leva em consideração todos os parâmetros do modelo sem ponderações. É interessante, entretanto, considerar que em alguns casos existe a necessidade

de otimização de sinais de excitação para a estimação de apenas um parâmetro, ou de um grupo de parâmetros. Este problema pode ser acessado através da utilização de uma matriz de ponderação, W , a qual possibilita a atribuição de maior peso a certos parâmetros que, eventualmente, necessitem ou venham a ser de maior interesse no processo de estimação, 3.17.

$$J = tr[WD] \quad (3.17)$$

Este instrumento é bastante importante para o desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica, pois nos modelos dinâmicos de aeronaves existem parâmetros aos quais as equações de saída são muito sensíveis, ao passo que também existem parâmetros cuja sensibilidade das equações de saída é extremamente reduzida. Desta maneira, caso haja necessidade de acesso a parâmetros cuja influência nas equações de saída seja reduzida, pode-se atribuir maior peso aos mesmos, sem que a otimização do sinal de excitação deixe de considerar o restante dos parâmetros do modelo.

O problema descrito acima pode ser agravado pelo fato de que a função de aptidão, tanto da equação (3.16), quanto na equação (3.17), é formada pelas covariâncias absolutas, o que significa que se existir um parâmetro, consideravelmente, menor que outro, o mesmo será prejudicado, mesmo que seja de forte interesse. Para se amenizar este problema, pode-se utilizar um valor relativo do desvio padrão da estimativa em função do valor de cada parâmetro do modelo a priori:

$$J = \sum_{k=1}^{n_{\theta}} \frac{\sigma_k}{\theta_k} \quad (3.18)$$

A função de aptidão (3.18) pode ser utilizada em conjunto com a matriz de ponderação W . Desta maneira, a ponderação recebe maior sentido, pois realmente consegue atuar aumentando a importância de parâmetros de maior interesse.

A minimização das funções (3.16), (3.17) e (3.18) configuram um problema de apenas um objetivo: a máxima redução das covariâncias. Pode-se utilizar uma função multi-objetivo, no entanto, que possibilite a seleção de objetivos diferentes para cada parâmetro de interesse. Neste caso, a função custo implementada é:

$$J = \sum_{k=1}^{n_\theta} \frac{\sigma_k}{\theta_k} - \varsigma_k \quad (3.19)$$

A utilização de multi-objetivos ganha especial importância quando é de interesse minimizar o tempo de execução da manobra (MORELLI, 1990). Esta abordagem faz com que o sinal otimizado seja aquele com o mínimo período de execução, T , e que atinge os objetivos estabelecidos. Para isso, a função de aptidão (3.19) deve ser implementada em conjunto com:

$$J = T \quad (3.20)$$

quando $\frac{\sigma_k}{\theta_k} \leq \varsigma_k$ para todo k .

3.2.3 Restrições

Trabalhos anteriores normalmente tratavam as restrições para o procedimento de otimização de sinais de excitação para manobras de ensaios em vôo através da limitação da energia do sinal de entrada:

$$\int_0^T u(t)^* u(t) dt = \varepsilon \quad (3.21)$$

onde T é o período de aplicação do sinal. O valor máximo da energia do sinal de entrada, ε , normalmente era escolhido através de experiências prévias e por tentativa e erro.

A restrição imposta através de (3.21) é indireta, pois, na prática, o que realmente possui limitações operacionais e matemáticas são as amplitudes das entradas de controle e das variáveis de saída. Sendo, assim, mais interessante aplicar restrições que levem em consideração, diretamente, os batentes das deflexões das superfícies de controle, as limitações da malha de controle, as limitações do envelope operacional de vôo, e as limitações dos modelos matemáticos assumidos nos algoritmos de estimação de parâmetros. Estas restrições podem ser atendidas da seguinte maneira:

$$|u_j(t)| \leq \mu_j \quad (3.22)$$

onde $j = 1, 2, 3, \dots, n_u$ e:

$$|y_l(t)| \leq \gamma_l \quad (3.23)$$

onde $l = 1, 2, 3, \dots, n_y$.

As restrições colocadas nas formas (3.22) e (3.23) possibilitam o acesso direto a viabilidade e segurança de execução do ensaio resultante, pois garante que todas as entradas e saídas estarão dentro dos limites especificados.

Outra restrição muito importante a ser levada em consideração é o tempo mínimo que deverá ser respeitado entre os instantes de comutação. Principalmente quando o sinal de excitação será aplicado manualmente pelo piloto, é necessário que o intervalo entre as mudanças de tudo positivo para tudo negativo, ou vice-versa, seja adequado. A implementação desta restrição será tratada, mais detalhadamente, no decorrer da apresentação do algoritmo de otimização.

3.3 Abordagem Para Especificação de Sinais de Excitação no Domínio da Frequência

Sinais de excitação para estimação de parâmetros aerodinâmicos podem ser especificados através de análises no domínio da frequência (MULDER; BREEMAN, 1994)(MARCHAND, 1977). Esta abordagem é bastante simples e tira proveito de sinais com características previamente estabelecidas, sinais também chamados nestes estudo de sinais convencionais. Os sinais convencionais são tradicionalmente conhecidos na literatura, como pulsos, *doublets*, 3-2-1-1. Estes sinais têm sido amplamente utilizados em experimentos de identificação de sistemas e possuem uma concepção bastante simples. Considerando, por exemplo, que o *Doublet(1-1)* possui um período de $2\delta_t$, figura 3.1, os instantes de comutação são definidos como segue: $1\delta_t$, $2\delta_t$. Assim sendo, verifica-se que os sinais convencionais são definidos por apenas duas variáveis: sua amplitude, e seu δ_t .

É através do valor de δ_t que os sinais de entrada convencionais devem ser sintonizados para disponibilizarem o máximo de energia na frequência natural da dinâmica de interesse. Esta análise deve ser feita através da densidade espectral de potência dos sinais para

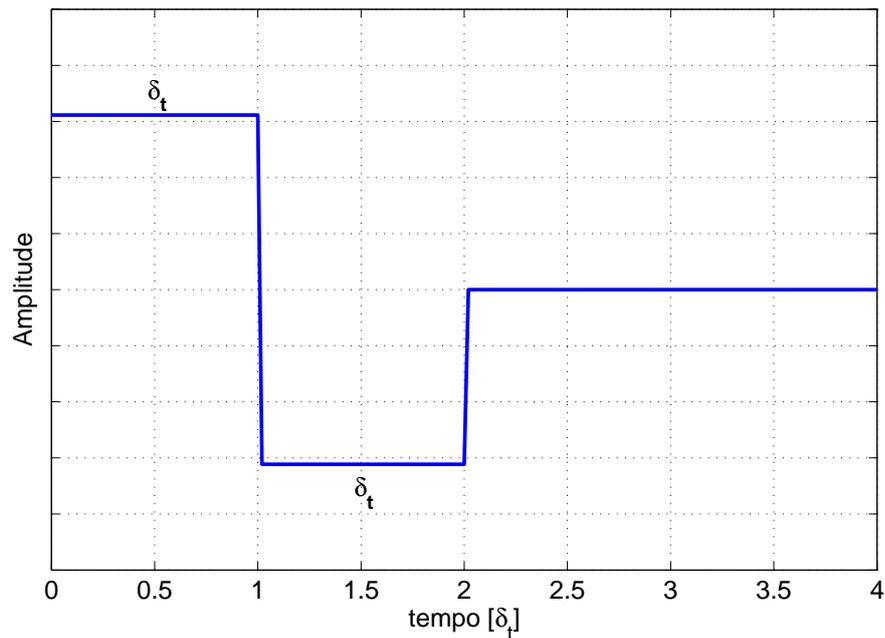
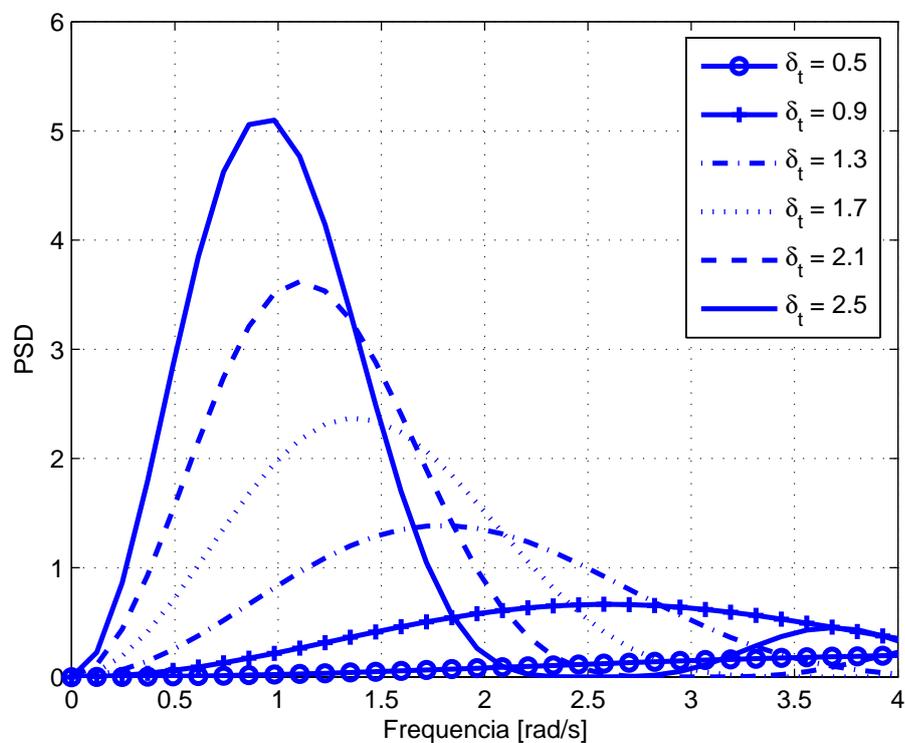


Figura 3.1: Sinal de excitação tipo dublê

diferentes valores de δ_t .

Figura 3.2: PSD para dublês com diferentes valores de δ_t

No gráfico acima, figura 3.2, estão mostradas seis curvas de densidade espectral de

potência para o sinal duplê. Cada uma para um valor diferente de δ_t (entre 0.5 e 2.5 segundos). Claramente nota-se que a energia dos sinais passa a ser concentrada em uma frequência de pico. Para a especificação de uma entrada de excitação com esta abordagem, o δ_t escolhido deve ser aquele que maximiza a densidade espectral do sinal convencional na frequência de interesse.

Caso a frequência de interesse estiver em torno de 1.0 rad/s, por exemplo, o sinal mais apropriado, ou que mais energia oferece, é o de $\delta t = 2.5s$. Em contra partida, se a frequência de interesse for 3.0 rad/s, o sinal mais indicado passa a ser o de $\delta t = 0.9s$. Basicamente, esta é uma análise que pode ser feita para a especificação de sinais de excitação convencionais. Vale salientar que esta sintonia é de suma importância para garantir a identificabilidade dos parâmetros envolvidos no processo.

Deve-se enfatizar que através desta abordagem os parâmetros que se encontram em B , F e G não são levados em consideração, uma vez que a frequência natural do sistema depende apenas de matriz A . Além disso, as restrições que eventualmente devem ser impostas à especificação do sinal de excitação deverão ser verificadas a posteriori. Em um procedimento iterativo que permita retornar à análise acima para especificar novos sinais caso houver algum desrespeito das restrições.

3.4 Algoritmo Genético de Otimização

Nos anos 50 e 60, muitos pesquisadores se concentraram em simulações computacionais de sistemas genéticos. Neste contexto, John Holland ([HOLLAND, 1975](#)) apresentou trabalhos de maior impacto, vindo a idealizar o algoritmo genético na década de 70, baseando-se em princípios da evolução e seleção natural propostos por Charles Darwin no século 17 ([DARWIN, 1859](#)). Mais tarde, em meados da década de 80, David Goldberg ([GOLDBERG, 1989](#)) aplicou com sucesso o algoritmo genético em problemas de busca e otimização.

O algoritmo genético utiliza conceitos trazidos das ciências biológicas, tais como: população, indivíduo, adaptação, migração e aptidão ao meio, entre outros. O seu funcionamento baseia-se na evolução e seleção natural das espécies de acordo com a aptidão dos indivíduos ao meio. Partindo-se de uma população pré-estabelecida, são realizados casamentos e cruzamentos, os quais geram novos indivíduos que irão compor uma nova geração.

A seleção dos indivíduos que permanecem ou não, e que reproduzem ou não, é feita de acordo com sua aptidão ao meio. Isto é, os indivíduos que possuem maior aptidão possuem maiores chances de permanecerem para novas gerações e de reproduzirem, gerando descendentes que carregarão suas cargas genéticas. Os novos indivíduos podem então entrar em competição natural com seus antepassados. Outro instrumento natural observado é a mutação, ou seja, os genes dos indivíduos de uma população podem sofrer alterações. Basicamente, o algoritmo genético trabalha no sentido de melhorar ao máximo a genética dos indivíduos que compõe a população, conduzindo, através de migrações, cruzamentos e mutações, as características genéticas dos mesmos para aumentar sua aptidão ao meio.

A aptidão de um indivíduo pode ser calculada a partir de uma função objetivo. A função objetivo pode representar o meio natural e os indivíduos mais aptos a sobreviver e reproduzir seriam aqueles que a maximizassem ou a minimizassem. Cada indivíduo representa um ponto no espaço de busca, e os seus genes representam cada variável da função custo incluída no espaço de busca multi-dimensional.

O algoritmo genético utiliza, além de operadores lógicos e determinísticos, operadores estocásticos, os quais podem conduzir o processo de otimização por diferentes caminhos. Além disso, o algoritmo genético não necessita de informações complementares para realizar sua busca, tais como as derivadas da função objetivo.

Alguns conceitos e nomenclaturas utilizadas no algoritmo genético devem ficar claros. Normalmente, a função custo é chamada de função de aptidão. A função de aptidão é a função que se quer minimizar. Outro conceito utilizado é o conceito de indivíduo. No algoritmo genético, indivíduo é qualquer ponto no espaço de busca em que a função custo é avaliada. O indivíduo é um vetor, cuja dimensão é igual ao número de variáveis da função custo. Cada indivíduo possui um score, o qual é o valor da função custo avaliada no respectivo ponto. Em alguns casos, o indivíduo é chamado de genoma, e seus elementos de genes. Os indivíduos compõem a população. A população é representada por uma matriz, na qual cada indivíduo ocupa uma linha. Em alguns casos, subpopulações podem ser utilizadas. Quando isso acontecer, os indivíduos das subpopulações podem migrar entre as mesmas. A cada interação, o algoritmo genético realiza diversas operações na população atual no sentido de produzir uma nova população. Cada nova população pode ser chamada de nova geração.

Outro conceito muito importante é o conceito de diversidade. A diversidade em um algoritmo genético pode ser acessada através da distância média entre os indivíduos de uma mesma população. A diversidade é essencial em algoritmos genéticos, uma vez que define a abrangência do espaço de busca.

O escore de cada indivíduo de uma população é utilizado para selecionar os indivíduos da população atual que irão proporcionar a composição da nova geração. Os indivíduos selecionados são chamados de parentes e os indivíduos da nova geração são chamados de indivíduos novos, ou *children*. Normalmente, os parentes são aqueles que obtiveram os melhores escores.

O funcionamento de um algoritmo genético é iterativo, ou seja, a solução é buscada através de diversas interações do mesmo processo. Neste caso, o processo pode ser dividido em quatro etapas básicas:

- **População inicial:** a população inicial deve ser criada com o auxílio de operadores estocásticos. Deve-se levar em consideração, entretanto, critérios de conhecimento a priori do problema, os quais possibilitam que os indivíduos da população inicial não extrapolem, por exemplo, restrições do problema. É importante se ter em mente que o algoritmo genético proporcionará uma busca tão global quanto diversa for a população inicial;
- **Avaliação da aptidão dos indivíduos:** depois de composta a população inicial, a aptidão de seus indivíduos é avaliada segundo os critérios introduzidos na função custo. Feito isso, são atribuídos escores a cada indivíduo;
- **Migração:** caso houver sub-populações, os indivíduos mais aptos de uma sub-população migram para outras sub-populações, tomando o lugar de indivíduos menos aptos;
- **Seleção dos parentes:** a seleção dos parentes que passarão pelos processos de reprodução é feita segundo critérios pré-definidos que levam em consideração o escore de cada indivíduo. Geralmente, os indivíduos com melhor escore possuem mais condições de sobreviver e reproduzir;
- **Reprodução:** depois de selecionados os parentes, os mesmos são submetidos aos operadores de cruzamento e mutação para que a nova população seja gerada. Além

disso, pode-se selecionar os parentes mais aptos para, automaticamente, sobreviverem para a próxima geração.

A seguir serão mostrados os principais aspectos a respeito das etapas do funcionamento do algoritmo genético. Em paralelo, será mostrado como a aplicação deste algoritmo foi feita para solucionar o problema de otimização de sinais de excitação para manobras de ensaios em vôo para estimação paramétrica.

3.4.1 População Inicial

No presente trabalho, considera-se que os sinais de excitação são ondas quadradas do tipo *bang-bang*, ou seja, ou tudo positivo, ou tudo negativo, ou zero. Este tipo de sinal pode ser completamente determinado através de uma amplitude e dos seus instantes de comutação. Os instantes de comutação são os instantes de tempo em que as trocas entre tudo positivo, tudo negativo ou zero são feitas. Estes sinais serão separados em dois grupos: sinais convencionais ou previamente estabelecidos, e sinais otimizados. Os sinais convencionais já foram abordados anteriormente considerando a análise no domínio da frequência. A especificação dos sinais convencionais pode ser colocada na forma do problema de otimização proposto neste estudo ao invés de ser tratada no domínio da frequência. As variáveis de projeto, neste caso, seriam apenas duas: a amplitude do sinal, e seu δ_t . Neste estudo, entretanto, será enfatizado um tipo de sinal cujos instantes de comutação são definidos explicitamente, o que ocasiona maior complexidade, mas também maior flexibilidade para o tratamento de problemas mais complexos, figura 3.3.

O tratamento dos sinais convencionais através do problema de otimização colocado anteriormente é bastante simples, pois basta a especificação de duas variáveis. Esta abordagem pode ter grande utilidade, principalmente, quando o custo computacional envolvido no procedimento de otimização de sinais de excitação para manobras de ensaios em vôo para estimação paramétrica é relevante, como em aplicações de estimação em vôo e em tempo real.

A abordagem de sinais com instantes de comutação explicitamente definidos pode tornar o problema de otimização mais complexo, pois o número de variáveis de projeto é diretamente afetado pelo número de instantes de comutação escolhidos pelo usuário, o

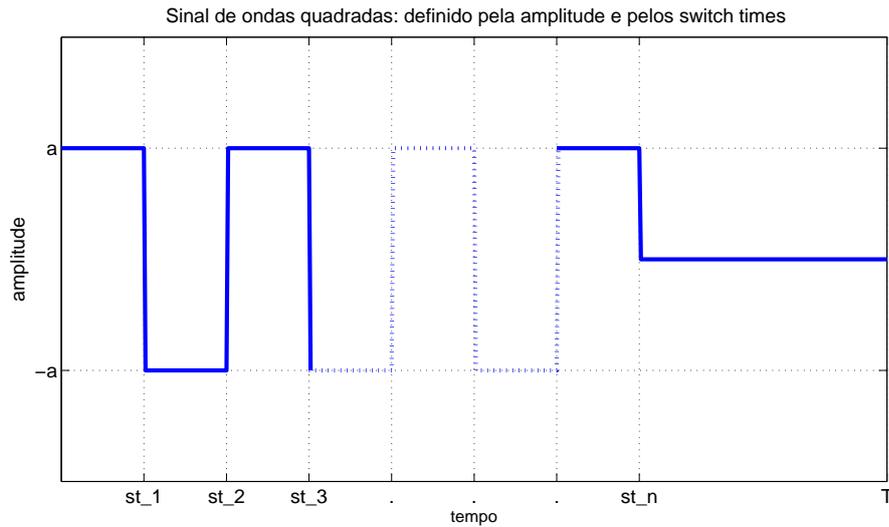


Figura 3.3: Sinal de excitação a ser otimizado

que acarreta maior custo computacional. Na otimização através do algoritmo genético, o primeiro passo seguido pelo algoritmo genético é criar a população inicial. A geração da população inicial é feita utilizando-se operadores aleatórios, mas respeitando certas restrições e levando em considerações informações de conhecimento a priori. A população inicial é de fundamental importância para estabelecer a eficiência do algoritmo genético, pois estabelece a diversidade do espaço de busca. Em primeiro lugar, deve-se definir quantos indivíduos deverão ser incluídos na população, ou em cada sub-população, caso houver. A dimensão dos indivíduos e o número de sub-populações deve ser definido. A partir da população inicial, o algoritmo genético trabalha no sentido de criar uma nova geração com o mesmo número de indivíduos, os quais terão o mesmo número de genes.

Os indivíduos, portanto, são compostos pelos genes referentes a amplitude do sinal e aos instantes de comutação. Cada indivíduo da população é composto por $(n_{st} + 1)$ genes, onde n_{st} é o número selecionado de switch times do sinal de excitação. O primeiro gene de cada indivíduo é a amplitude do sinal de excitação e o restante são os instantes de comutação. O i -ésimo indivíduo da k -ésima sub-população com n_{st} instantes de comutação pode ser representado por:

a	st	st	st	\cdot	\cdot	\cdot	st
$_{1,k}$	$_{1,1,k}$	$_{1,2,k}$	$_{1,3,k}$				$_{1,n_{st},k}$

Figura 3.4: Exemplo de Indivíduo

O número de indivíduos que devem compor a população, ou cada sub-população,

função de geração da população inicial, pois, neste caso, Δst determina a diferença mínima temporal entre os respectivos instantes de comutação. O valor de Δst deve ser selecionado levando em consideração a implementabilidade do sinal de excitação resultante.

Existem outras duas restrições que, quando necessárias, devem ser levadas em consideração na função de geração da população inicial, são elas: variação máxima das variáveis de saída, e tempo máximo de aplicação do sinal de excitação.

De acordo com (3.23), uma ou mais variáveis de saída do sistema podem ser restringidas no processo de otimização dos sinais de excitação. Estas restrições devem ser levadas em consideração para a geração da população inicial. Assim sendo, há a necessidade de integração das equações dinâmicas do modelo para cada sinal de entrada representados por cada indivíduo.

Ao término do processo de geração da população inicial todos os indivíduos que serão submetidos a avaliação da função custo respeitam as restrições impostas ao processo.

3.4.2 Novas Gerações

Tendo criado a população inicial, o algoritmo genético avalia os seus indivíduos em relação a função custo para determinar o escore individual. O escore é o valor numérico da função custo atribuído para cada indivíduo. Os indivíduos que apresentarem os menores escores demonstram maior aptidão a minimizar a função custo e terão maior probabilidade de sobrevivência e reprodução. O prosseguimento é dado com a substituição de indivíduos menos aptos de uma sub-população por indivíduos mais aptos de outra, operação chamada de migração. Feito isso, os parentes são selecionados e os critérios de reprodução são aplicados aos mesmos, criando uma nova população. Este processo é repetido até que os critérios de parada sejam atendidos.

A reprodução é, basicamente, feita através de três instrumentos. O primeiro pode ser chamado de elite. A elite é formada pelos indivíduos que apresentaram os melhores escores dentro de uma população e que devem, automaticamente, sobreviver para a próxima geração, ou para a próxima população. O segundo instrumento pode ser tido como a função de cruzamento. Esta função define como os parentes serão cruzados para gerar novos indivíduos que irão compor a nova geração. O terceiro instrumento é manifestado

através da função de mutação. Esta função aplica pequenas mudanças aos genes dos parentes antes de gerar os novos indivíduos. É interessante ressaltar que todo o processo de reprodução é realizado em cima dos parentes selecionadas de acordo com critérios que levam em consideração os escores individuais.

No presente trabalho, a elite representa entre 5 e 20% dos indivíduos mais aptos da geração atual. Estes indivíduos são selecionados e automaticamente sobrevivem para a próxima geração. O restante dos indivíduos da nova geração são gerados a partir do cruzamento dos parentes. O cruzamento dos parentes pode ser feito de várias formas. Neste estudo, o cruzamento é realizado escalonadamente, ou a partir de um gene escolhido randomicamente. No primeiro caso, a partir de um par de parentes:

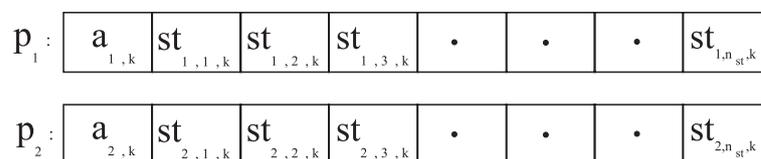


Figura 3.6: Dupla de parentes selecionados para reprodução

e com o auxílio de um vetor binário criado randomicamente, como por exemplo:

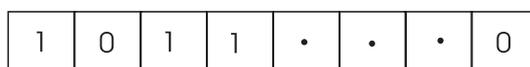


Figura 3.7: Vetor binário utilizado para o cruzamento

o novo indivíduo é criado da seguinte forma:

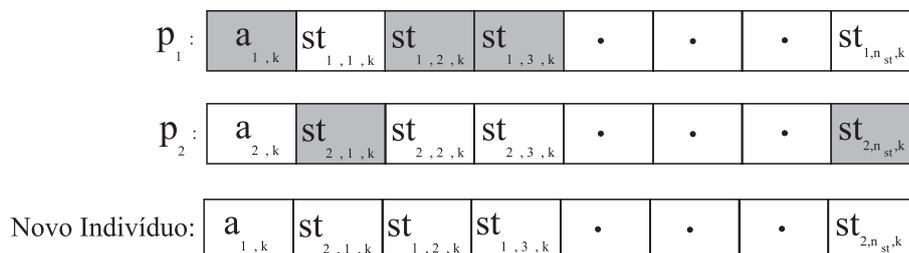


Figura 3.8: Cruzamento escalonado

A operação acima foi feita de maneira que os genes contendo o operador 1 no vetor binário fossem associados com o primeiro pai e que os genes contendo o operador binário 0 fossem associados com o segundo pai. As combinações genéticas feitas entre os parentes podem gerar novos descendentes mais bem adaptados ao meio. Esta melhora vem a ser gradual com o passar das gerações. O cruzamento, portanto, é um instrumento de

aumento da aptidão da população ao meio, fazendo com que as futuras gerações sejam mais capazes de sobreviver e reproduzir. Este processo é semelhante ao processo de evolução biológica, cada vez mais os indivíduos se apresentam de forma mais adaptada ao meio. Analogamente, os indivíduos são cada vez mais capazes de reduzir a função custo.

Para o caso do cruzamento ser realizado a partir de um gene randomicamente selecionado, tendo-se o par de parentes mostrado anteriormente, gera-se um número randômico que deve representar a posição de um dos genes dos indivíduos (Desde que não seja o primeiro e nem o último gene de cada indivíduo, para que não seja configurada a operação de elite.). Este número representa o número do gene até o qual o novo indivíduo será composto por genes do primeiro parente e a partir do qual o novo indivíduo será composto por genes do segundo indivíduo.

O terceiro instrumento de reprodução mencionado é a mutação. As operações de mutação determinam pequenas mudanças genéticas nos indivíduos para prover diversidade e possibilitar que o algoritmo genético estabeleça um maior espaço amostral.

A estratégia de mutação utilizada neste estudo adiciona valores aleatórios distribuídos conforme uma distribuição Gaussiana de média zero aos genes dos indivíduos. Esta operação é feita antes da reprodução de novos indivíduos, ou seja, ela é feita nos dados genéticos dos parentes selecionados para reprodução. A covariância da distribuição utilizada para mutação é determinada da seguinte maneira:

$$cov = \left[1 - \left(\frac{gen}{n_{gen}} \right) \right] \quad (3.27)$$

Onde gen denota a geração atual e n_{gen} é o número de gerações a serem estudadas. Este artifício faz com que a mutação genética seja diminuída ao longo das gerações.

É através destes três instrumentos de reprodução - cruzamento, mutação e elite -, portanto, que o algoritmo genético utilizado neste estudo procura a evolução da espécie a partir da população inicial, a idéia básica dos mesmos pode ser verificada na figura 3.9.

Por fim, deve-se abordar alguns aspectos a respeito das operações de migração. A migração ocorre quando o número definido de sub-populações for maior que um. Quando ocorre, indivíduos menos aptos de uma sub-população são substituídos por indivíduos mais aptos de outra sub-população. Esta operação é feita de maneira que os indivíduos

mais aptos não sejam excluídos de suas sub-populações originais. Neste estudo, a migração foi realizada em uma única direção, isto é, os indivíduos mais aptos da sub-população k migram para a sub-população $k + 1$, e assim por diante.

Também deve ser definido um intervalo de migração e a fração de indivíduos de cada sub-população que deve migrar. Se o intervalo de migração for Δgen , as migrações ocorrerão de Δgen em Δgen gerações.

A reprodução será aplicada até que algum critério de parada seja alcançado. O critério de parada mais utilizado neste estudo é o número máximo de gerações. Desta maneira, o algoritmo genético é finalizado apenas quando o número máximo de gerações definido é avaliado.

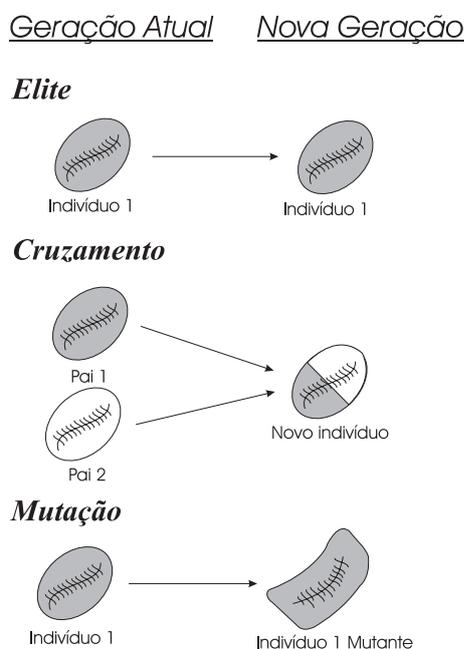


Figura 3.9: Instrumentos de Reprodução

3.4.3 Implementação de Restrições

A implementação das restrições neste trabalho é realizada através de uma função chamada pelo algoritmo genético após a avaliação de todos os indivíduos da população atual. As restrições são impostas ou indiretamente na forma de penalidades no score, ou diretamente nas operações de reprodução, não permitindo o nascimento de indivíduos que não respeitam as restrições. As restrições impostas na forma de penalidades resultam na diminuição das chances do indivíduo ser selecionado como parente e participar do processo

de reprodução. Conseqüentemente, os genes do indivíduo penalizado não farão parte dos indivíduos da nova geração.

As restrições que se fazem necessárias no processo de otimização de sinais de excitação para manobras de ensaios em vôo são as seguintes:

- **Limites de variação das saídas:** esta restrição garante que o sinal de excitação resultante do processo de otimização não causará variações das variáveis de saída que ultrapassem valores pré-estabelecidos;
- **Limites de variação da(s) deflexão(ões) de controle:** esta restrição garante que a deflexão das superfícies de controle não ultrapasse limites pré-estabelecidos;
- **Intervalo mínimo entre instantes de comutação:** esta restrição garante que o instante de comutação imediatamente posterior tenha pelo menos o intervalo temporal especificado por Δst em relação ao seu instante de comutação antecessor. Esta característica é bastante importante no que tange a implementabilidade do sinal de excitação resultante, uma vez que pode levar em conta o atraso ou a velocidade de aplicação do sinal de controle por parte do piloto ou de sistemas automáticos;
- **Tempo máximo de aplicação do sinal de excitação:** esta restrição garante que o sinal de excitação resultante seja aplicado em um tempo menor ou igual ao tempo máximo pré-definido, denotado por T ;

A restrição na variação das variáveis de saída ocasiona a necessidade de integração das equações do movimento a cada novo processo de reprodução. Este processo é feito para cada indivíduo da população e deve respeitar a relação (3.23). Da mesma maneira, a restrição das variáveis de entrada é feita de acordo com (3.22).

A restrição quanto ao intervalo mínimo entre os instantes de comutação é feita de acordo com:

$$\delta st_{i,1,k} = st_{i,1,k} \geq \Delta st \quad (3.28)$$

$$\delta st_{i,j,k} = st_{i,j,k} - st_{i,j-1,k} \geq \Delta st \quad (3.29)$$

Onde $j = 2, 3, 4, \dots, n_{st}$.

Na equação acima, Δst é um valor pré-definido para o intervalo mínimo entre os instantes de comutação e deve ser respeitado por todos os indivíduos da população.

Por fim, a restrição que diz respeito ao tempo máximo de aplicação do sinal de excitação. Esta restrição é imposta de forma que:

$$st_{i,n_{st},k} \leq T \quad (3.30)$$

A expressão acima faz com que o último instante de comutação de cada indivíduo seja igual ou menor ao tempo máximo disponível para o desenvolvimento do sinal de excitação. O valor de T deve ser selecionado previamente.

No caso da utilização de penalidades, as restrições descritas acima são impostas de forma acumulativa. A cada restrição desrespeitada por um indivíduo, o score do mesmo será multiplicado por um termo penalizador. Este termo penalizador é proporcional ao valor excedido da respectiva restrição. Assim sendo, permite-se que um indivíduo que tenha ferido de forma amena uma restrição seja menos penalizado que um indivíduo que tenha ferido a mesma restrição de forma muito significativa.

Capítulo 4

Resultados Experimentais

4.1 Introdução

Este capítulo de resultados possui o objetivo de validar as técnicas de otimização de manobras de ensaios em vôo e mostrar a necessidade e viabilidade de implementação das mesmas.

A primeira parte é dedicada à análise de casos simulados. O exemplo 1 trata de um estudo da dinâmica de período curto já realizado por diversos autores. O principal objetivo é comparar os resultados obtidos neste trabalho com aqueles obtidos anteriormente, no intuito de validar o algoritmo utilizado. O exemplo 2, da mesma forma, trata da otimização de sinais de excitação para a dinâmica oscilatório em derrapagem já bordada em (MORELLI, 1990). Neste caso, entretanto, o principal objetivo é demonstrar a capacidade de tratamento de problemas com mais de uma entrada de controle e com vários parâmetros. Por fim, ainda trabalhando com dados simulados, o exemplo 3 apresenta uma simulação de Monte Carlo do procedimento de estimação paramétrica. O principal objetivo deste exemplo é demonstrar a necessidade de consideração dos resíduos coloridos nas variáveis de medida durante o procedimento de otimização de sinais de excitação para manobras de ensaios em vôo.

Na segunda parte deste capítulo, são tratados dados experimentais oriundos de uma campanha de ensaios em vôo dedicada à análise de manobras de ensaios em vôo para estimação paramétrica. O planejamento dos vôos é abordado, seguido de uma breve apre-

sentação da aeronave ensaiada e dos sistemas de aquisição de dados de ensaios em vôo. O principal objetivo deste estudo é a comparação de sinais otimizados com sinais convencionais para a excitação do modo de período curto. São abordados aspectos que tangem à segurança de vôo e a implementabilidade do sinal otimizado, chegando a demonstrar a viabilidade de utilização das técnicas apresentadas neste estudo para o planejamento e execução de campanhas de ensaios em vôo para estimação de parâmetros de aeronaves.

É importante salientar que os modelos dinâmicos utilizados neste capítulo são extremamente simplificados. Os mesmos foram utilizados para possibilitar a comparação com resultados anteriores existentes na literatura à respeito da otimização de manobras de ensaios em vôo para estimação de parâmetros. Adotar modelos menos simplificados e até modelos não-lineares pode ser de fundamental importância para o sucesso da modelagem dinâmica de aeronaves.

4.2 Dados Sintéticos e Simulações de Monte Carlo

4.2.1 Exemplo 1

O primeiro exemplo da aplicação da técnica de otimização de manobras trata da comparação entre resultados obtidos com a aplicação das técnicas abordadas neste estudo e resultados anteriores encontrados na literatura (CHEN, 1975)(MEHRA, 1974b)(MORELLI, 1990). O problema está em desenvolver um sinal de excitação para a estimação dos parâmetros da dinâmica de período curto, descrita nas equações (4.1)-(4.4), e deduzida na Apêndice A:

$$\begin{bmatrix} \dot{\alpha} \\ \dot{q} \end{bmatrix} = \begin{bmatrix} Z_{\alpha} & 1 \\ M_{\alpha} & M_q \end{bmatrix} \begin{bmatrix} \alpha \\ q \end{bmatrix} + \begin{bmatrix} Z_{\delta e} \\ M_{\delta e} \end{bmatrix} \delta e \quad (4.1)$$

onde α é o ângulo de ataque e q é a velocidade de arfagem. Os valores nominais dos parâmetros do modelo estão descritos na tabela 4.1.

As equações de saída são descritas por:

Tabela 4.1: Exemplo 1 - Valores dos parâmetros do modelo de período curto

Parâmetro	Valor Nominal
Z_α	-0.737
$Z_{\delta e}$	0.005
M_α	-0.562
M_q	-1.588
$M_{\delta e}$	-1.660

$$\begin{bmatrix} y_1(t) \\ y_2(t) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \alpha \\ q \end{bmatrix} \quad (4.2)$$

e o modelo de medida é:

$$\begin{bmatrix} y_{m_1}(i) \\ y_{m_2}(i) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} y_1(i) \\ y_2(i) \end{bmatrix} + \begin{bmatrix} v_1(i) \\ v_2(i) \end{bmatrix}, i = 1, 2, 3, \dots, N \quad (4.3)$$

onde N é o número de pontos do vetor de saída. É considerado que o ruído de medida $v(i)$ é gaussiano de média zero com variância definida por:

$$R = \begin{bmatrix} 2.0 & 0.0 \\ 0.0 & 1.0 \end{bmatrix} \quad (4.4)$$

Este problema foi primeiramente abordado por Mehra ([MEHRA, 1974b](#)). Nesta oportunidade o autor desenvolveu um sinal de excitação com tempo de vôo fixo e maximizou o traço da matriz de informação, submetendo a otimização à restrição da energia máxima do sinal. O sinal resultante e a resposta temporal simulada está na figura 4.1. Chen ([CHEN, 1975](#)) resolveu o mesmo problema aplicando a mesma restrição de energia máxima do sinal de excitação. Este autor, entretanto, desenvolveu seu sinal de maneira a minimizar o tempo de aplicação com o objetivo de atingir os mesmos limites de Cramer-rao atingidos por Mehra, o sinal utilizado foi do tipo *bang-bang* e os resultados podem ser visualizados na figura 4.2. Posteriormente, Morelli ([MORELLI, 1990](#)) desenvolveu sua técnica de otimização de sinais de excitação e a aplicou no mesmo problema. Nesta oportunidade, foram desenvolvidos dois sinais, figuras 4.3 e 4.4, um com a mesma amplitude máxima do sinal de Mehra e outro com a mesma amplitude máxima do sinal de Chen. Os sinais eram ondas quadradas do tipo *bang-bang*, e foram desenvolvidos de maneira a

minimizar o tempo de aplicação, atingindo objetivos quanto aos limites de Cramer-Rao pré-estabelecidos.

Os limites de Cramer-Rao para os sinais citados foram recalculados utilizando o mesmo algoritmo do presente trabalho. Os resultados podem ser vistos na segunda, terceira, quarta e quinta colunas da tabela 4.2.

As técnicas abordadas no presente trabalho foram utilizadas para gerar novos sinais otimizados para a estimação dos parâmetros do modelo (4.1)-(4.4). Para prover adequada comparação, os dois sinais foram gerados de maneira semelhante à abordagem dada por Morelli, o primeiro, com a amplitude máxima do sinal de Mehra (± 12.5 graus), e o segundo com a amplitude máxima do sinal de Chen (± 8.792 graus). Para os dois casos a otimização foi feita de maneira multi-objetiva para o mínimo tempo, ou seja, a função de aptidão descrita em (??). Para o primeiro, os objetivos selecionadas foram os limites relativos de Cramer-Rao obtidos com a aplicação do sinal do Morelli com amplitude máxima ± 12.5 graus. Para o segundo, os objetivos selecionados foram os limites relativos de Cramer-Rao obtidos com a aplicação do sinal do Morelli com a amplitude máxima ± 8.792 graus.

As curvas temporais dos sinais resultantes e das respostas simuladas podem ser visualizadas nas figuras 4.5 - 4.6.

Os resultados da otimização genética podem ser verificados nas duas últimas colunas da tabela 4.2. Nas figuras 4.7 - 4.14, pode-se verificar a evolução do algoritmo genético em relação à função de aptidão e em relação às variâncias relativas dos parâmetros para o primeiro sinal otimizado (amplitude máxima igual a 8.792 graus). Da mesma maneira, as figuras 4.15 - 4.22 mostram a evolução da população para o segundo sinal otimizado (amplitude máxima igual a 12.5 graus).

Observando a evolução das populações para a função de aptidão e para o objetivo geral (soma dos multi-objetivos), verifica-se que os indivíduos ao longo das gerações convergiram para uma solução muito próxima dos objetivos. É interessante salientar que desde as primeiras gerações nota-se indivíduos abaixo do objetivo geral. A grande maioria, entretanto, está acima. Nota-se que, para o segundo sinal, os indivíduos tiveram maior facilidade de evoluir para um resultado abaixo do objetivo geral. A evolução da função de aptidão, neste caso, mostra que a grande maioria dos indivíduos das últimas gerações foram avaliados apenas em função do tempo de execução. Do contrário aconteceu para

o primeiro sinal, onde todos os indivíduos das últimas gerações foram avaliados também em função dos limites de Cramer-Rao. Os gráficos mostram um degrau em cada geração, justamente, entre aqueles indivíduos que estão abaixo do objetivo e aqueles que estão acima. Os indivíduos abaixo do degrau são aqueles que estão sendo avaliados apenas em função do tempo de execução da manobra. No problema para o mínimo tempo, estes indivíduos são beneficiados ao longo das gerações. A evolução do tempo de execução da manobra indica que as populações evoluíram para o menor tempo possível que viabilizasse o atendimento dos objetivos.

Analisando-se a tabela 4.2, nota-se que os resultados obtidos com a otimização genética são muitos parecidos com aqueles obtidos por Morelli e por Chen, além de ser, consideravelmente, superior àqueles obtidos por Mehra, principalmente, no que tange ao tempo de execução.

Tabela 4.2: Exemplo 1 - Limites de Cramer-Rao (relativos)

Parâmetro	Fig. 4.1 Mehra	Fig. 4.2 Chen	Fig. 4.3 Morelli 1 (Chen)	Fig. 4.4 Morelli 2 (Mehra)	Fig. 4.5 Sinal Ótimo (Chen)	Fig. 4.6 Sinal Ótimo (Mehra)
Z_α	0.038	0.049	0.050	0.038	0.050	0.037
$Z_{\delta e}$	0.028	0.026	0.029	0.023	0.030	0.023
M_α	0.069	0.055	0.057	0.050	0.054	0.049
M_q	0.164	0.075	0.069	0.063	0.063	0.064
$M_{\delta e}$	0.097	0.049	0.047	0.042	0.044	0.042
Amp. Máxima (°)	12.5	8.792	8.792	12.5	8.792	12.5
Tempo	4.0 s	3.96 s	3.4 s	2.5 s	3.5 s	2.5 s

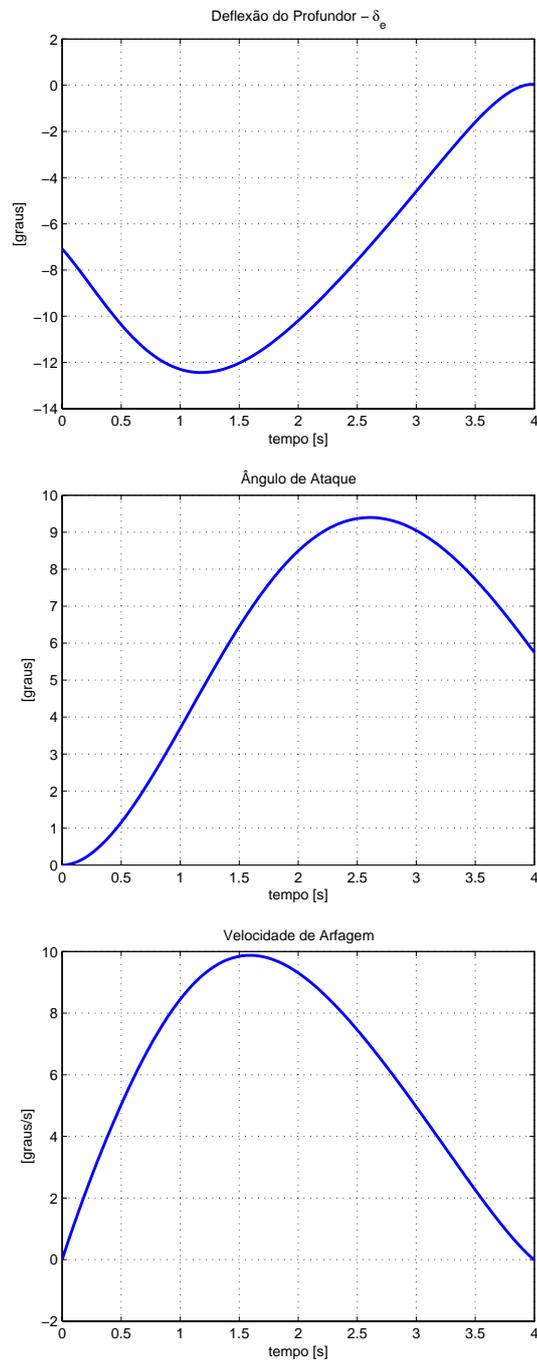


Figura 4.1: Exemplo 1 - Sinal otimizado por Mehra

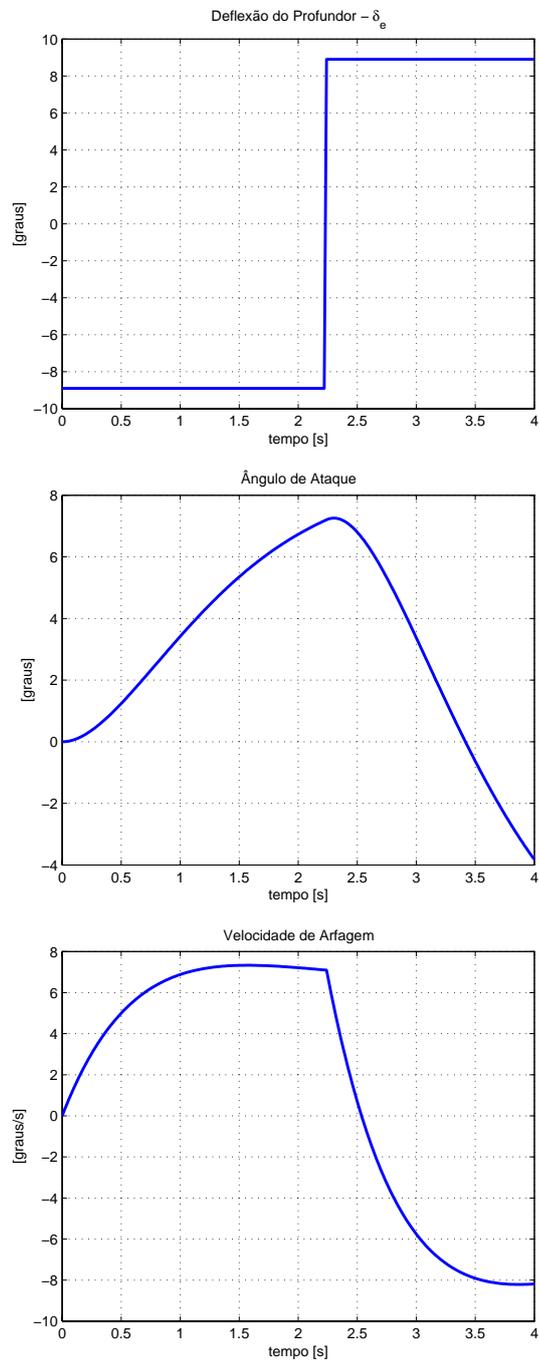


Figura 4.2: Exemplo 1 - Sinal otimizado por Chen

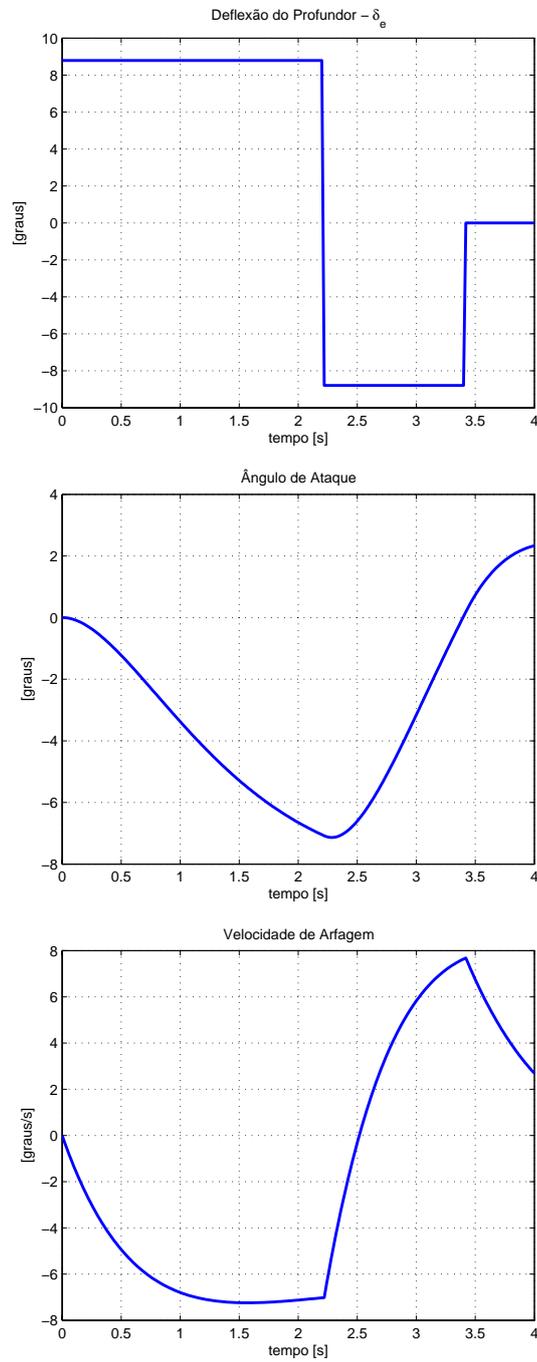


Figura 4.3: Exemplo 1 - Sinal otimizado por Morelli (Chen)

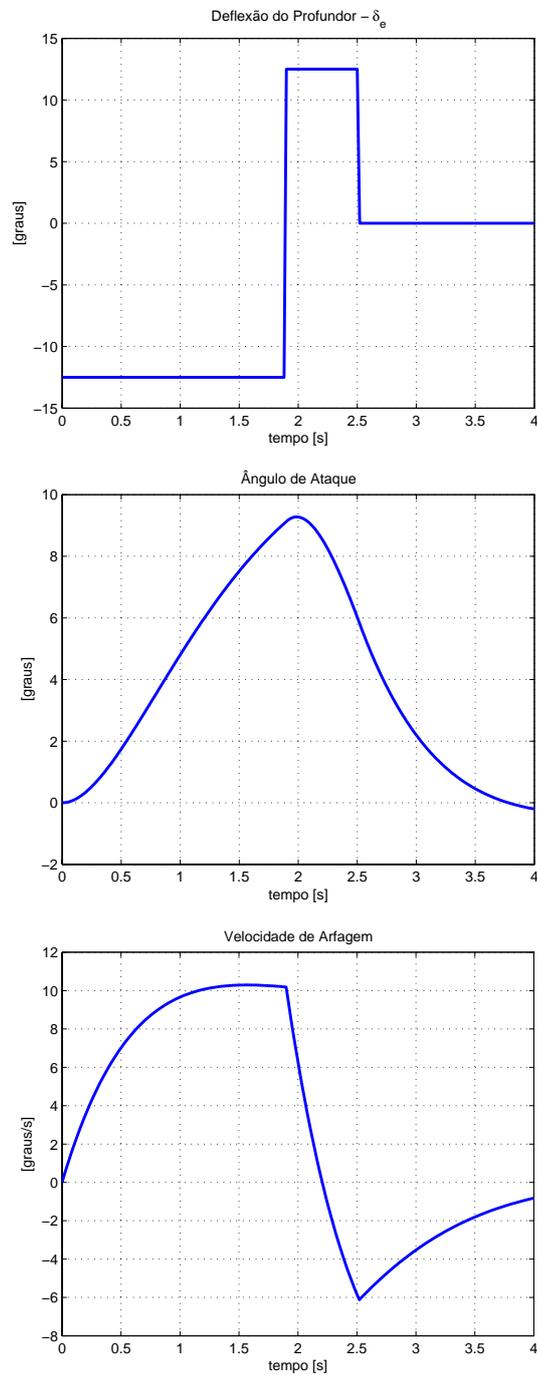


Figura 4.4: Exemplo 1 - Sinal otimizado por Morelli (Mehra)

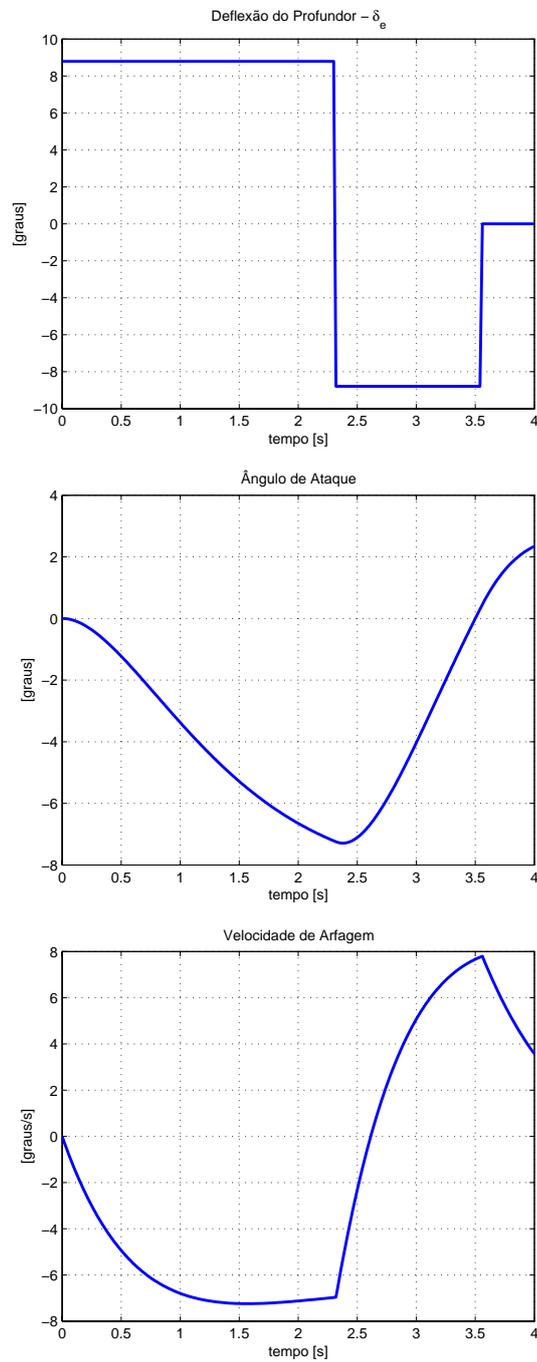


Figura 4.5: Exemplo 1 - Sinal Otimizado 1 - Amplitude Máxima igual a 8.792 graus

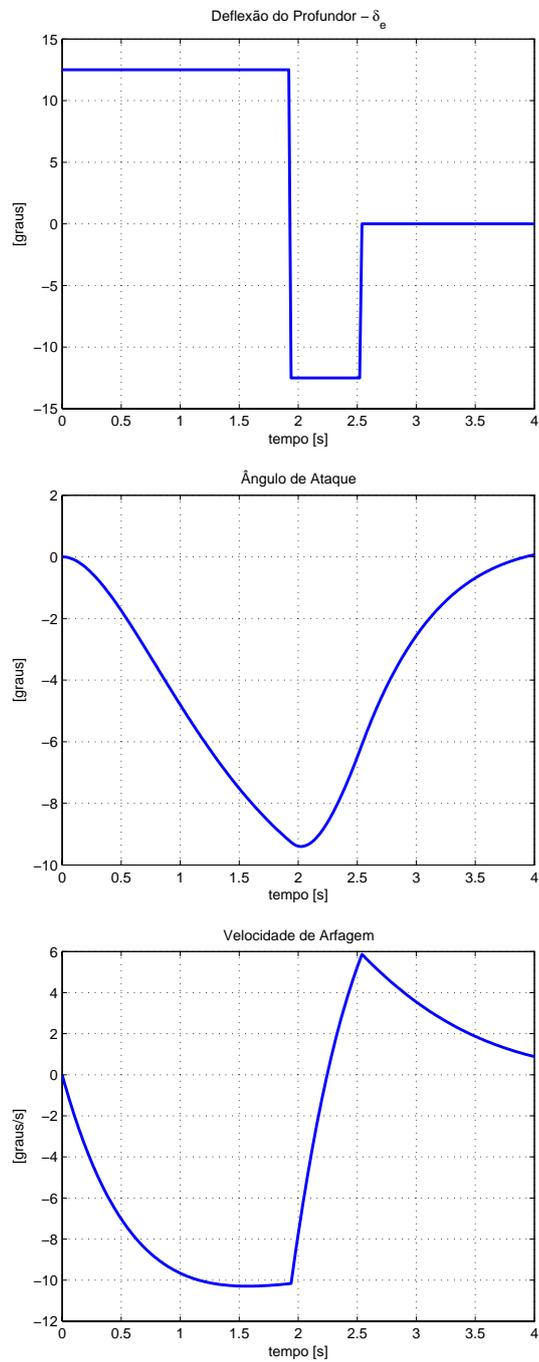


Figura 4.6: Exemplo 1 - Sinal Otimizado 2 - Amplitude Máxima igual a 12.5 graus

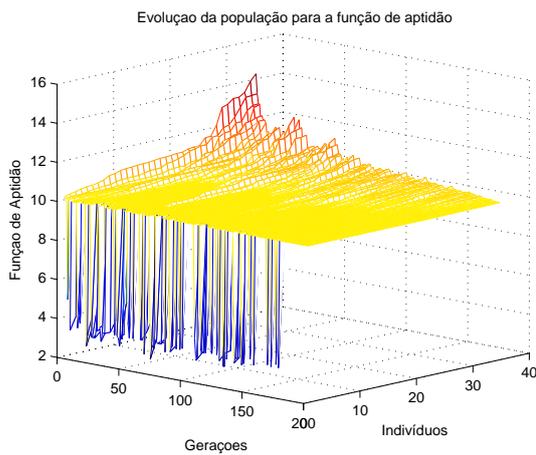


Figura 4.7: Exemplo 1/Sinal 1 - Evolução da população em relação à função de aptidão

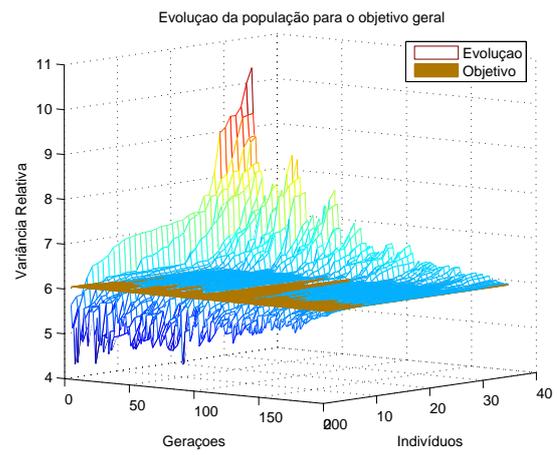


Figura 4.8: Exemplo 1/Sinal 1 - Evolução da população em relação ao objetivo geral

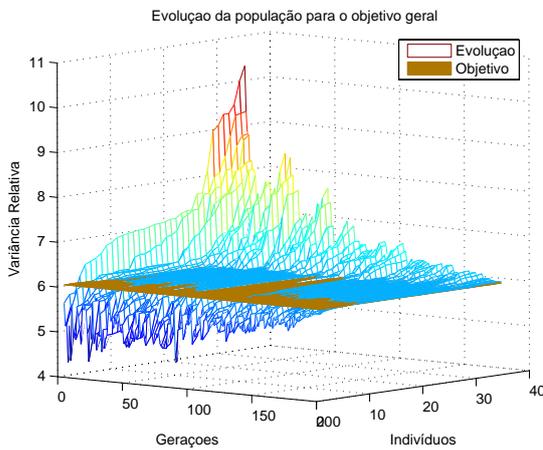


Figura 4.9: Exemplo 1/Sinal 1 - Evolução da população em relação ao tempo de execução da manobra

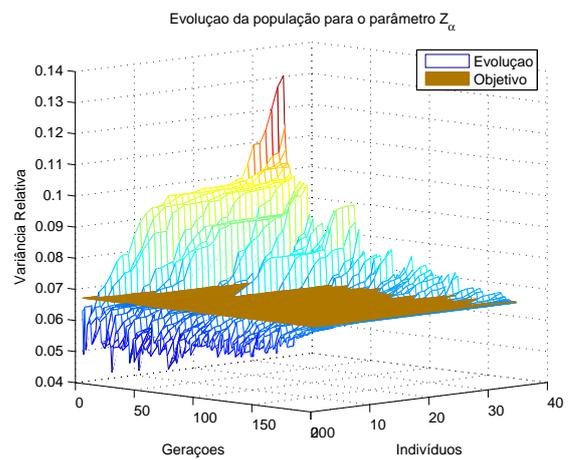


Figura 4.10: Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro Z_α

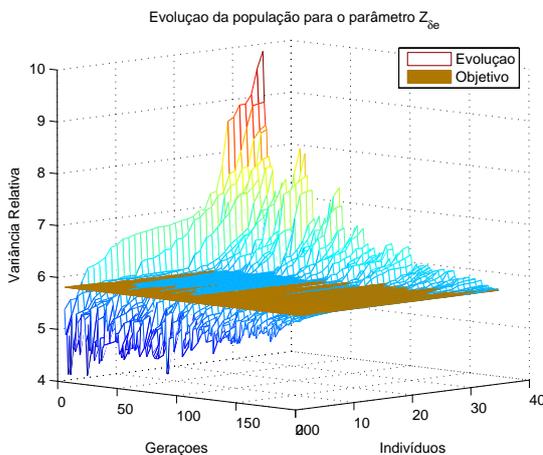


Figura 4.11: Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro Z_{δ_e}

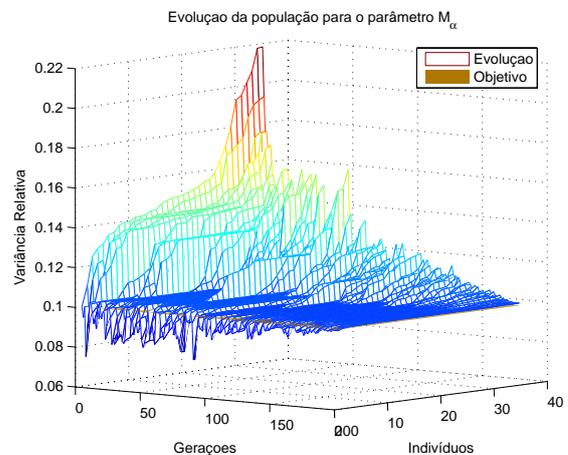


Figura 4.12: Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro M_α

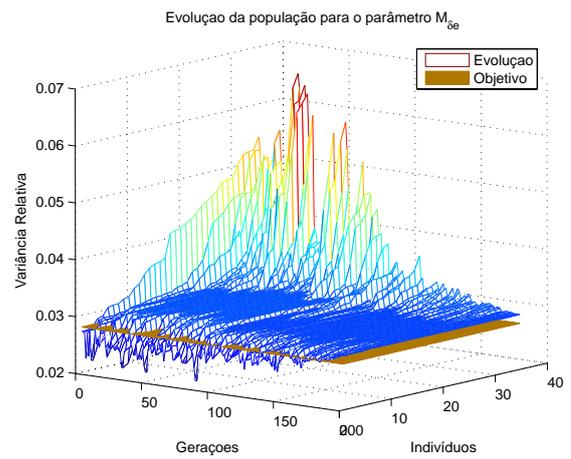
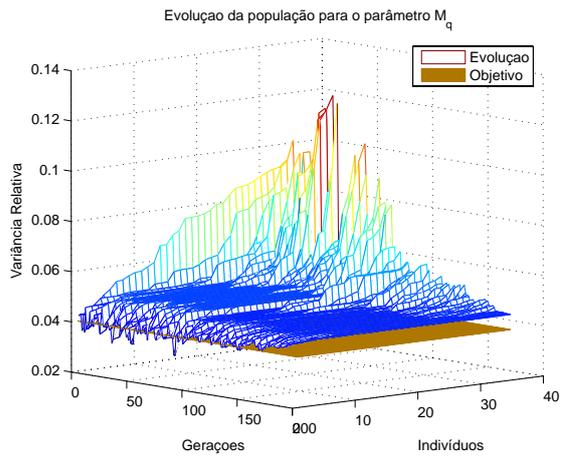


Figura 4.13: Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro M_q

Figura 4.14: Exemplo 1/Sinal 1 - Evolução da população em relação ao parâmetro M_{δ_e}

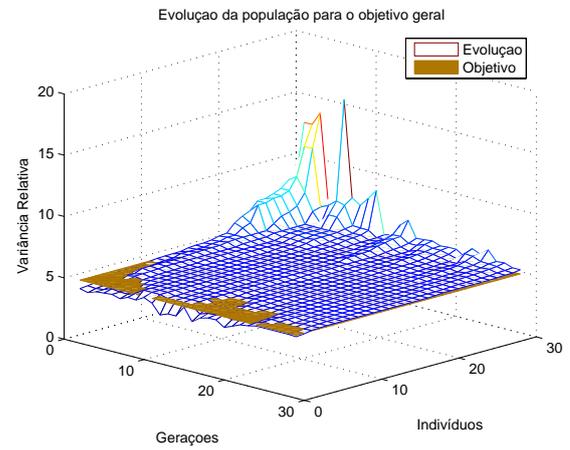
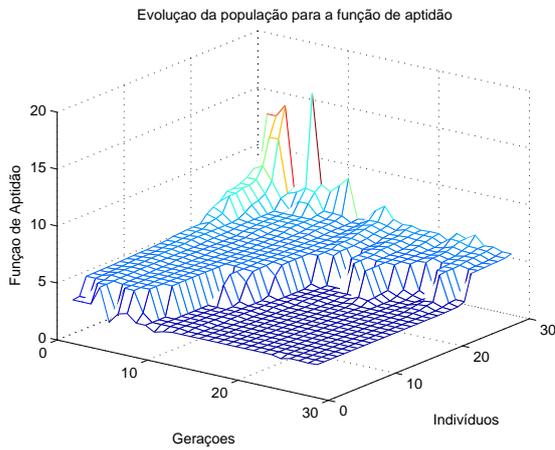


Figura 4.15: Exemplo 1/Sinal 2 - Evolução da população em relação à função de aptidão

Figura 4.16: Exemplo 1/Sinal 2 - Evolução da população em relação ao objetivo geral

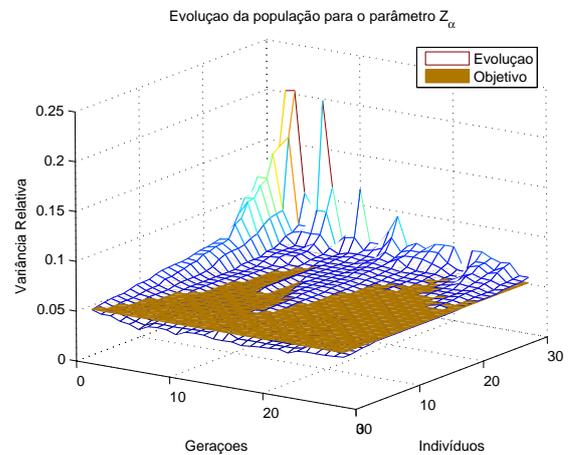
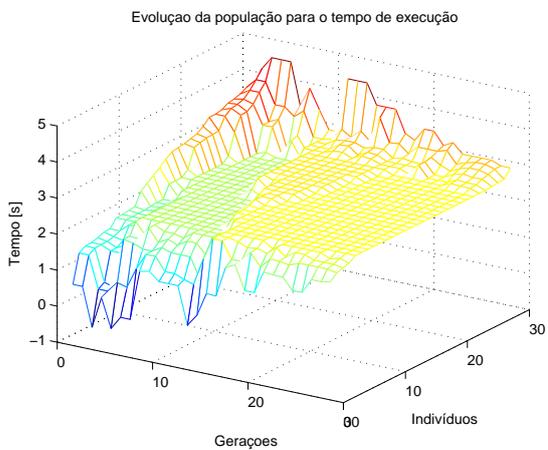


Figura 4.17: Exemplo 1/Sinal 2 - Evolução da população em relação ao tempo de execução da manobra

Figura 4.18: Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro Z_{α}

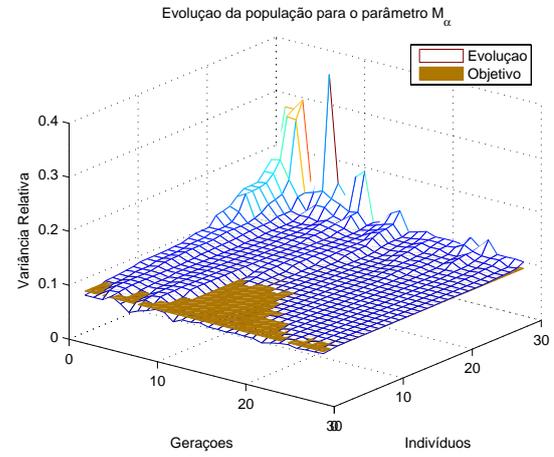
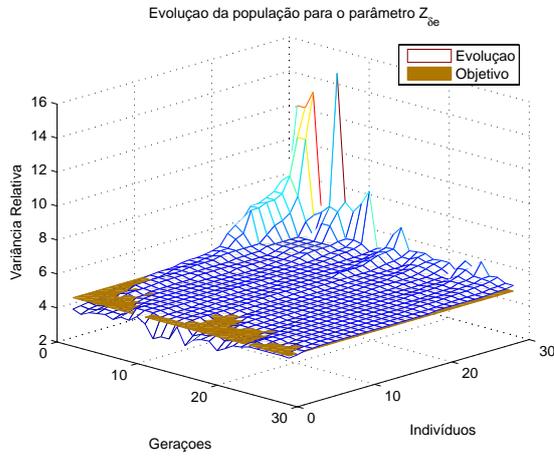


Figura 4.19: Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro Z_{δ_e} Figura 4.20: Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro M_{α}

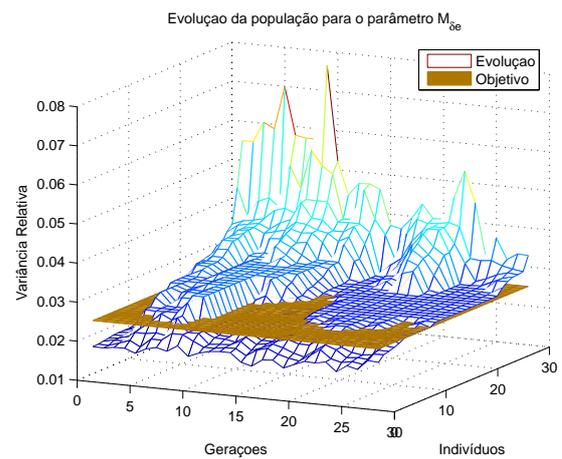
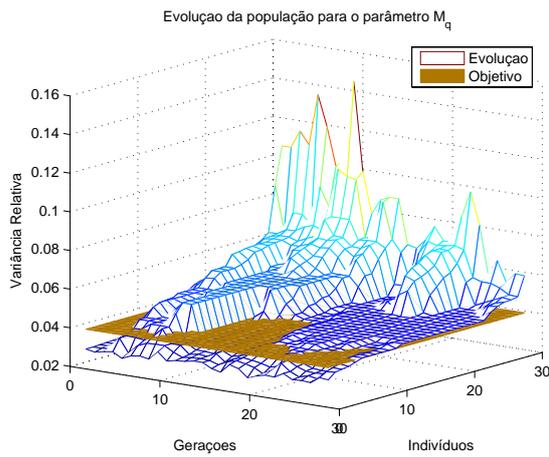


Figura 4.21: Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro M_q Figura 4.22: Exemplo 1/Sinal 2 - Evolução da população em relação ao parâmetro M_{δ_e}

4.2.2 Exemplo 2

Este exemplo tem como objetivo demonstrar a capacidade da técnica de desenvolvimento e otimização de manobras para acessar problemas que envolvem um número elevado de parâmetros, bem como exemplificar o seu uso para problemas que envolvem duas ou mais entradas de controle. Este exemplo também demonstra a viabilidade das técnicas de otimização de sinais de excitação levando em consideração os modelos de atuação na malha de controle.

Trata-se de um problema, já estudado em (MORELLI, 1990), para desenvolver sinais ótimos para aplicação simultânea através da deflexão do leme de direção e do aileron com o intuito de excitar a dinâmica oscilatória de derrapagem. Nesta oportunidade, o referido autor realizou, com sucesso, comparações do sinal otimizado com sinais convencionais, demonstrando vantagens e desvantagens. O presente estudo aproveitou a análise já feita, e apenas compara o sinal otimizado por Morelli e o sinal otimizado através das técnicas aqui abordadas.

O modelo látero-direcional deste exemplo está descrito nas equações (4.5) e (4.8), e foi desenvolvido no Apêndice A. Trata-se da dinâmica de uma aeronave de alta performance mantendo uma velocidade de 179.7 m/s e vôo nivelado a 10000 m. Assim como no estudo de Morelli, foram introduzidos atuadores de primeira ordem com constantes de tempo igual a 0.1 s nas superfícies de controle. O sinal de excitação neste exemplo, portanto, não é diretamente a deflexão da superfície aerodinâmica.

$$\begin{bmatrix} \Delta\dot{\beta}(t) \\ \Delta\dot{p}(t) \\ \Delta\dot{r}(t) \\ \Delta\dot{\phi}(t) \\ \Delta\dot{\delta}_a(t) \\ \Delta\dot{\delta}_r(t) \end{bmatrix} = \begin{bmatrix} Y_\beta & 0 & -1 & \frac{g}{V_0} & Y_{\delta_a} & Y_{\delta_r} \\ L'_\beta & L'_p & L'_r & 0 & L'_{\delta_a} & L'_{\delta_r} \\ N'_\beta & N'_p & N'_r & 0 & N'_{\delta_a} & N'_{\delta_r} \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & -10 & 0 \\ 0 & 0 & 0 & 0 & 0 & -10 \end{bmatrix} \begin{bmatrix} \Delta\beta(t) \\ \Delta p(t) \\ \Delta r(t) \\ \Delta\phi(t) \\ \Delta\delta_a(t) \\ \Delta\delta_r(t) \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 10 & 0 \\ 0 & 10 \end{bmatrix} \begin{bmatrix} u_a \\ u_r \end{bmatrix} \quad (4.5)$$

O modelo de saída é:

$$\begin{bmatrix} \Delta\beta_y(t) \\ \Delta p_y(t) \\ \Delta r_y(t) \\ \Delta\phi_y(t) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \Delta\beta(t) \\ \Delta p(t) \\ \Delta r(t) \\ \Delta\phi(t) \end{bmatrix} \quad (4.6)$$

Os parâmetros do modelo estão descritos na tabela 4.3.

Tabela 4.3: Exemplo 2 - Valores dos parâmetros do modelo oscilatório em derrapagem

Parâmetro	Valor Nominal
Y_β	-0.1095
L_β	-14.4240
L_p	-1.2039
L_r	0.9029
N_β	2.8640
N_p	-0.0090
N_r	-0.2241
$Y_{\delta r}$	0.0219
$L_{\delta a}$	-16.8280
$L_{\delta r}$	2.4040
$N_{\delta a}$	-0.3580
$N_{\delta r}$	-1.7900

Por fim, o modelo de medida é:

$$\begin{bmatrix} \beta_m(i) \\ p_m(i) \\ r_m(i) \\ \phi_m(i) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \Delta\beta(i) \\ \Delta p(i) \\ \Delta r(i) \\ \Delta\phi(i) \end{bmatrix} + \begin{bmatrix} v_1(i) \\ v_2(i) \\ v_3(i) \\ v_4(i) \end{bmatrix}, i = 1, 2, 3, \dots, N \quad (4.7)$$

onde $v(i)$ é o ruído de medida gaussiano, com média zero e matriz de covariância definida por:

$$R = \begin{bmatrix} 0.000361 & 0 & 0 & 0 \\ 0 & 0.04 & 0 & 0 \\ 0 & 0 & 0.0064 & 0 \\ 0 & 0 & 0 & 0.0059 \end{bmatrix} \quad (4.8)$$

Um dos sinais de excitação desenvolvidos por Morelli para este problema está ilustrado na figura 4.23, a otimização foi feita para o tempo máximo de execução fixo em 10 segundos e a amplitude máxima, tanto para o aileron, quanto para o leme, em 0.07 rad. Os objetivos para otimização foram selecionados em zero. Para a presente análise, os sinais para excitação através do leme de direção e do aileron, figura 4.24, foram otimizados utilizando a função de aptidão descrita por (3.18), selecionando os mesmos objetivos e restrições citadas anteriormente.

Os sinais mostrados neste exemplo se tornam bastante complexos do ponto de vista de implementabilidade quando houver a necessidade de aplicação simultânea. Em alguns casos, a aplicação dos mesmos pode vir a ser inviável através do piloto. Conforme o caso, pode haver a necessidade de impor ao algoritmo de otimização restrições que façam com que os sinais sejam aplicados em instantes diferentes.

A evolução da otimização genética está ilustrada nas figuras 4.25-4.38. Nestes gráficos, os indivíduos cujas covariâncias possuem valores fora de escala foram omitidos. Claramente, observa-se que ao longo das gerações, enquanto a função de aptidão tende a diminuir, em busca do objetivo, a evolução de alguns parâmetros tende a níveis mais baixos, em detrimento da evolução de outros, que tendem a níveis mais altos. Essas características são típicas de problemas com muitos parâmetros, nos quais é muito difícil chegar a soluções ótimas para todos.

Na tabela 4.4, os resultados da otimização genética estão sintetizados em conjunto com os resultados do sinal desenvolvido em (MORELLI, 1990). Os limites de Cramer-Rao relativos para os doze parâmetros demonstram que a técnica abordada no presente estudo para o tratamento de problemas com número elevado de parâmetros e com duas ou mais entradas chegou a resultados bastante parecidos com aqueles encontrados por Morelli.

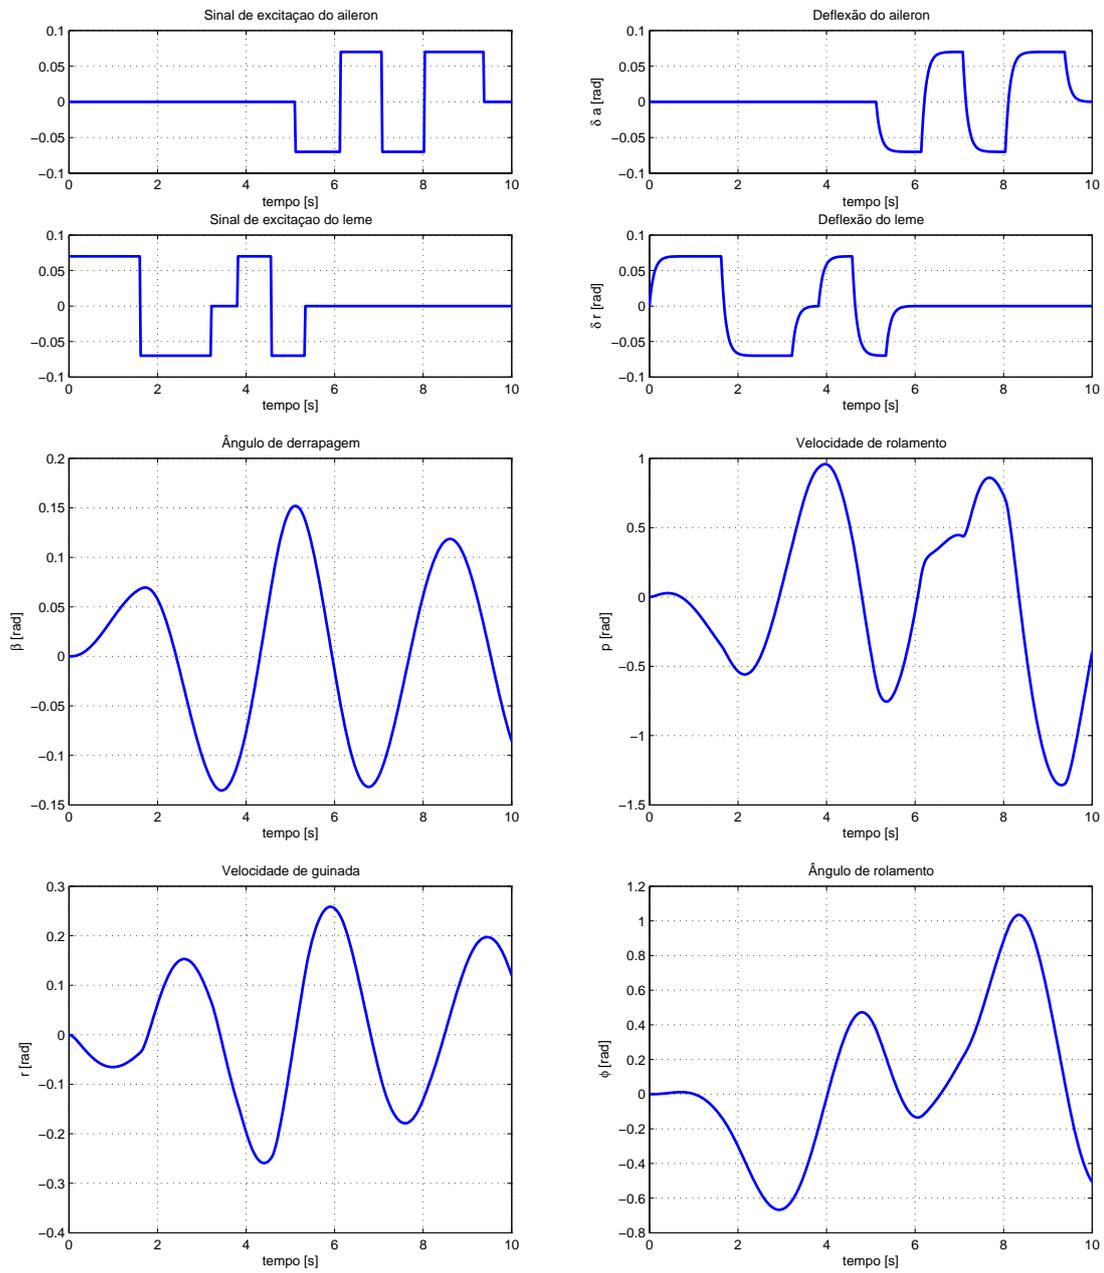


Figura 4.23: Exemplo 2 - Sinal Otimizado por Morelli

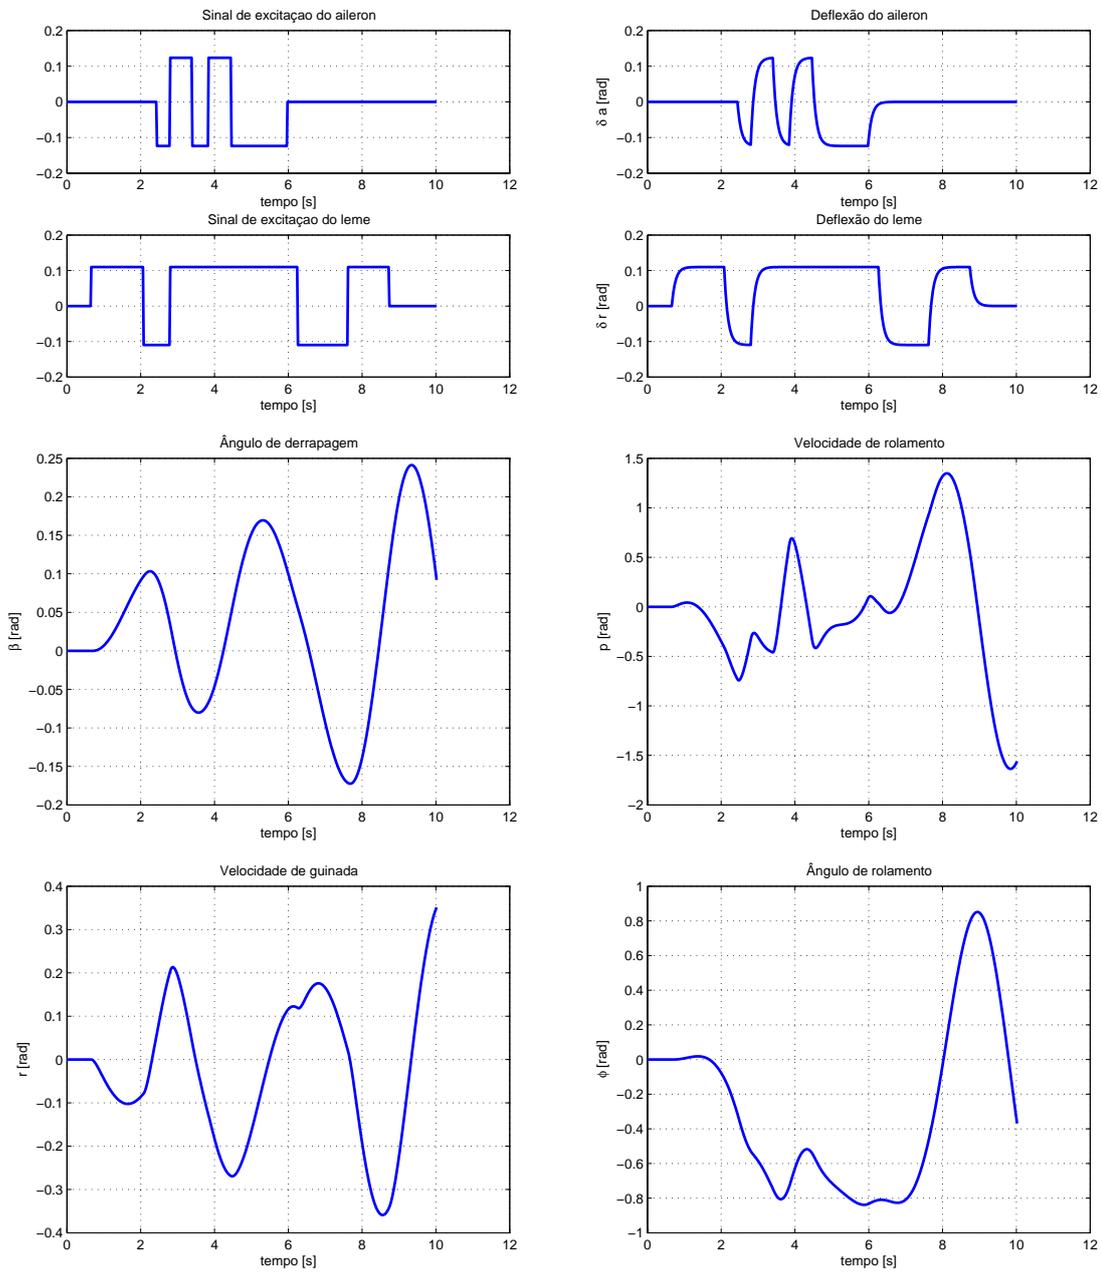


Figura 4.24: Exemplo 2 - Sinal Ótimo para Multi-Entradas

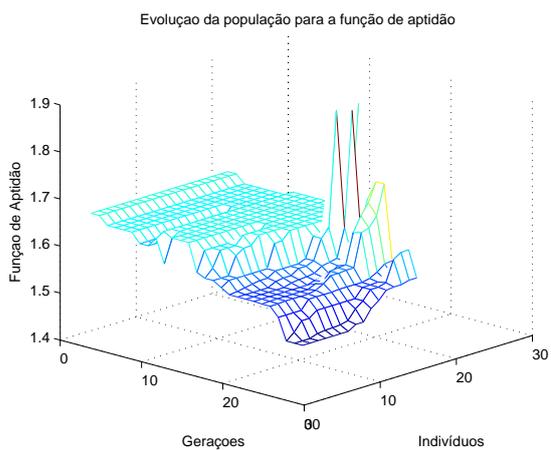


Figura 4.25: Exemplo 2 - Evolução da população em relação à função de aptidão

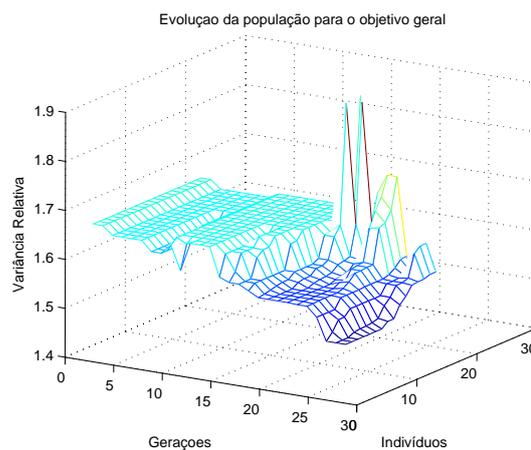


Figura 4.26: Exemplo 2 - Evolução da população em relação ao objetivo geral

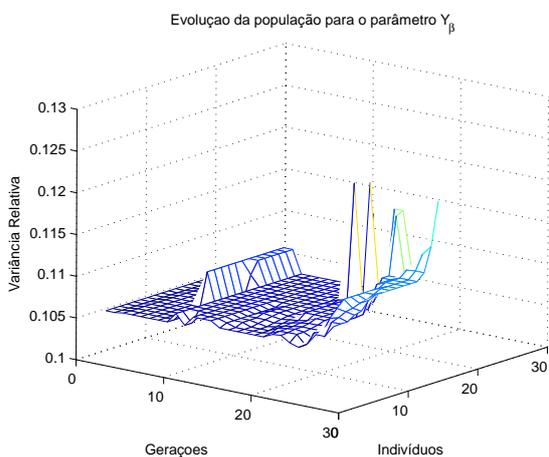


Figura 4.27: Exemplo 2 - Evolução da população em relação ao parâmetro Y_β

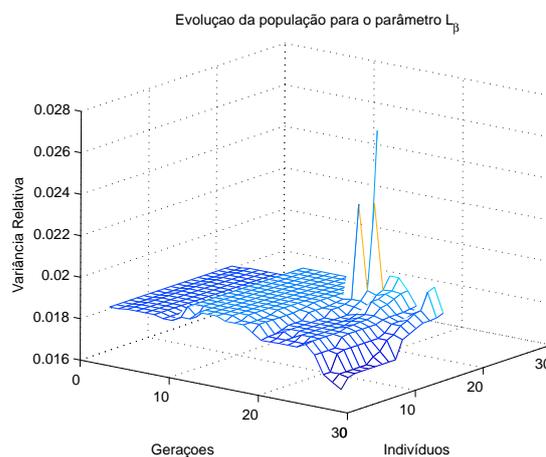


Figura 4.28: Exemplo 2 - Evolução da população em relação ao parâmetro L_β

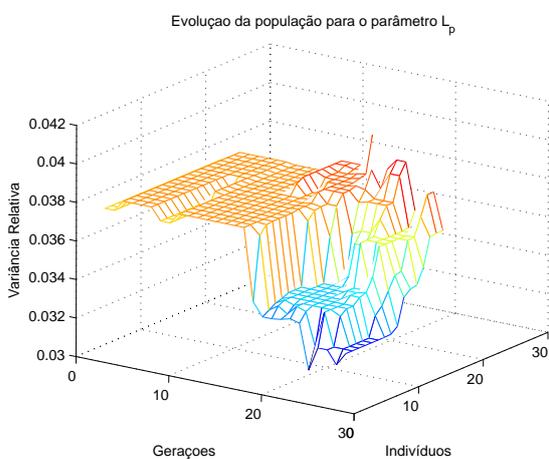


Figura 4.29: Exemplo 2 - Evolução da população em relação ao parâmetro Y_p

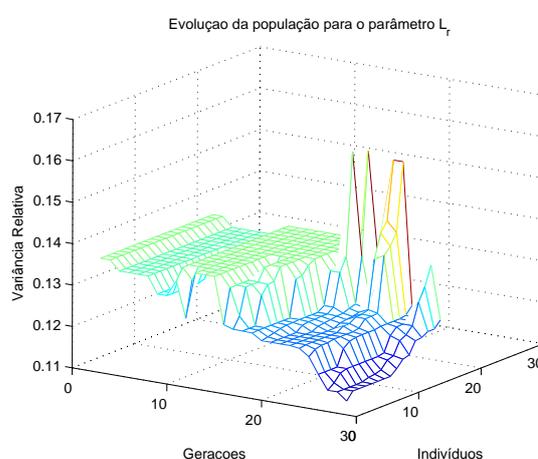


Figura 4.30: Exemplo 2 - Evolução da população em relação ao parâmetro Y_r

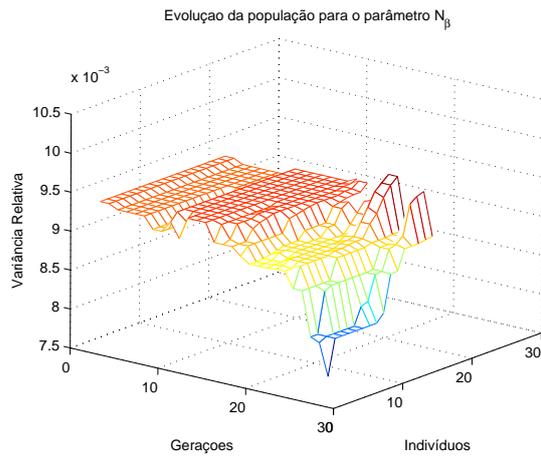


Figura 4.31: Exemplo 2 - Evolução da população em relação ao parâmetro N_β

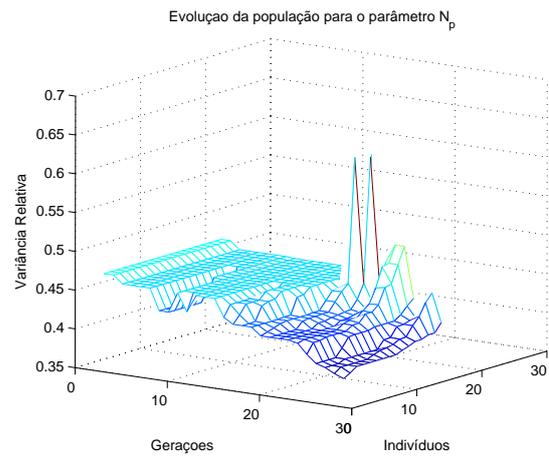


Figura 4.32: Exemplo 2 - Evolução da população em relação ao parâmetro N_p

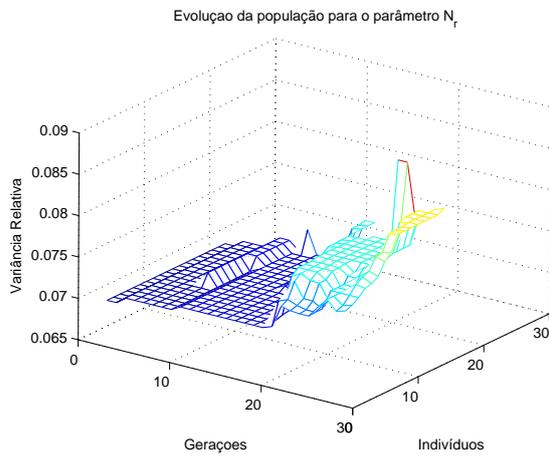


Figura 4.33: Exemplo 2 - Evolução da população em relação ao parâmetro N_r

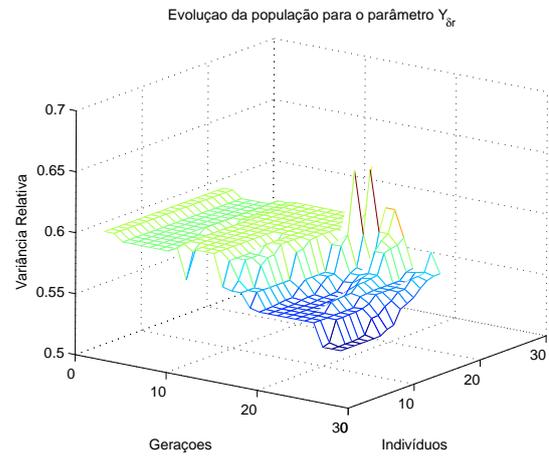


Figura 4.34: Exemplo 2 - Evolução da população em relação ao parâmetro Y_{δ_r}

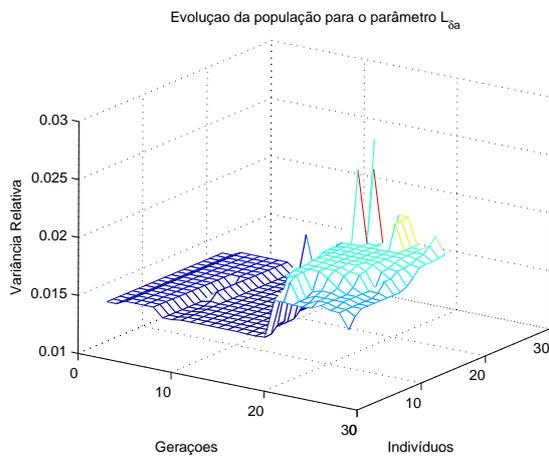


Figura 4.35: Exemplo 2 - Evolução da população em relação ao parâmetro L_{δ_a}

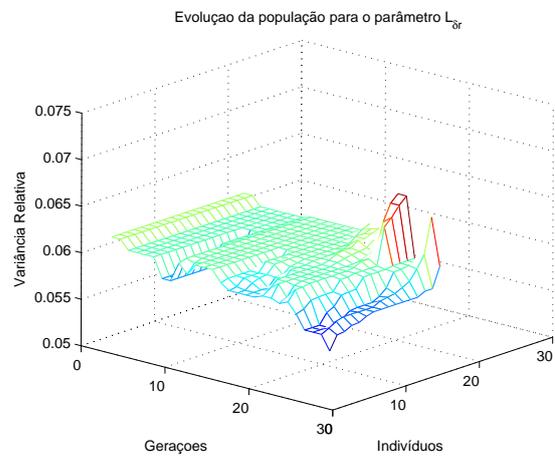


Figura 4.36: Exemplo 2 - Evolução da população em relação ao parâmetro L_{δ_r}

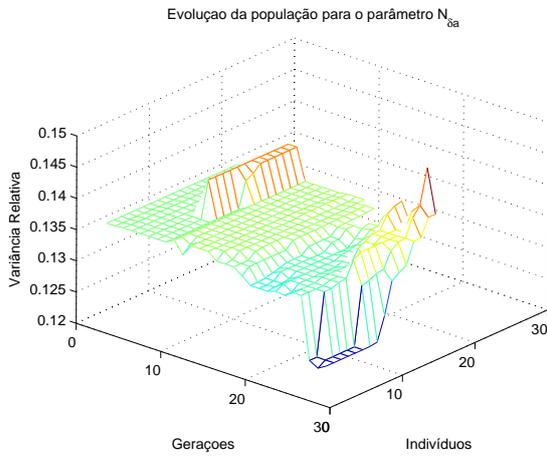


Figura 4.37: Exemplo 2 - Evolução da população em relação ao parâmetro $N_{\delta a}$

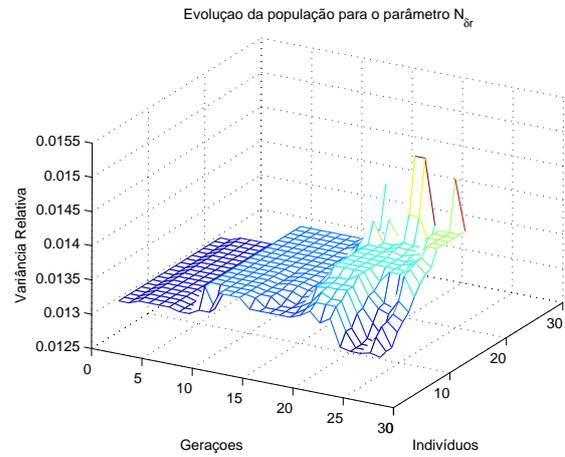


Figura 4.38: Exemplo 2 - Evolução da população em relação ao parâmetro $N_{\delta r}$

Tabela 4.4: Exemplo 2 - Limites de Cramer-Rao (relativos)

Parâmetro	Figura 4.23 Morelli	Figura 4.24 Sinal Ótimo
Y_{β}	0.218	0.119
L_{β}	0.016	0.015
L_p	0.019	0.030
L_r	0.155	0.103
N_{β}	0.005	0.007
N_p	0.274	0.339
N_r	0.131	0.083
$Y_{\delta r}$	0.793	0.529
$L_{\delta a}$	0.026	0.015
$L_{\delta r}$	0.110	0.053
$N_{\delta a}$	0.177	0.122
$N_{\delta r}$	0.018	0.013
Amplitude do sinal para o aileron	0.07	0.12
Amplitude do sinal para o leme	0.07	0.10
Tempo Total	10.0 s	8.72 s

4.2.3 Exemplo 3

O presente exemplo é uma análise introdutória aos experimentos apresentadas a seguir e envolve a consideração de resíduos coloridos no modelo de medida para a otimização do sinal de excitação. A dinâmica em estudo é o período curto excitado através da deflexão do profundor. O modelo utilizado está descrito nas equações (4.9)-(4.10). O principal objetivo é demonstrar a necessidade de considerar resíduos coloridos nas variáveis de medida para a otimização dos sinais de excitação, principalmente quando se trabalha com multi-objetivos.

Primeiramente, foi desenvolvido um sinal de excitação levando em consideração apenas a matriz de covariância dos resíduos de medida, R . Em um segundo momento, foi gerado um sinal de excitação que levasse em conta, também, a matriz de autocorrelação dos mesmos, R_{uu} . A função de aptidão utilizada foi (3.18) e os objetivos selecionados para os dois procedimentos foram os mesmos:

Tabela 4.5: Exemplo 3 - Objetivos para otimização

Parâmetro	Objetivo
Z_α	3 %
Z_q	12 %
$Z_{\delta e}$	14 %
M_α	2 %
M_q	6 %
$M_{\delta e}$	3 %

Foram impostas duas restrições:

- **Amplitude máxima da deflexão do profundor** = ± 0.36 rad;
- **Variação máxima da aceleração vertical** = ± 0.6 G.

As figuras 4.39 e 4.40 mostram os sinais de excitação resultantes e a respectivas respostas simuladas.

Os resíduos coloridos foram gerados a partir de um filtro Chebychev de quinta ordem. O objetivo foi representar as características que geralmente se encontra nos sistemas de aquisição de dados de ensaios em vôo. As características espectrais dos mesmos estão ilustradas nas figuras 4.41 - 4.43.

Como pode ser visto, a potência dos resíduos está concentrada nas baixas frequências, o que geralmente ocorre quando são analisados dados reais de ensaios em vôo. Para a presente análise, foram preparadas cinquenta corridas, adicionando uma amostra dos resíduos às variáveis de saída para cada sinal de excitação. Feito isso, uma simulação de Monte Carlo do procedimento de estimação dos parâmetros listados na tabela 4.5 foi realizada, disponibilizando a distribuição das estimativas paramétricas. Os histogramas, as funções de densidade de probabilidade e as dispersões resultantes para cada parâmetro estão ilustradas nas figuras 4.44 - 4.49.

Verifica-se, para todos os parâmetros, que as estimativas oriundas da aplicação do sinal otimizado levando em consideração resíduos coloridos nas variáveis de medida são menos dispersas, em especial, para os parâmetros Z_α , $Z_{\delta e}$ e Z_q . Analisando-se a tabela 4.6 nota-se que os dois sinais em estudo, praticamente, alcançaram os objetivos no que tange aos limites de Cramer-Rao durante o procedimento de otimização. Os resultados da otimização sem a consideração de resíduos coloridos, entretanto, são muito otimistas e podem ser prejudicados quando as variáveis de medida são contaminadas com este tipo de ruído. Já a otimização do sinal de excitação levando em consideração R e R_{uu} é mais robusta e, realmente, chega em objetivos próximos àqueles observados na estimação dos parâmetros. Isso fica claro quando se tem acesso ao desvio padrão relativo das distribuições das estimativas, tabela 4.6. Nota-se que os resultados da simulação de Monte Carlo para o sinal otimizado levando em consideração os resíduos coloridos estão muito próximos dos limites de Cramer-Rao esperados no desenvolvimento do sinal.

Tabela 4.6: Exemplo 3 - Resultados da Otimização dos Sinais e da Simulação de Monte Carlo

Parâmetro	Consideração de R		Consideração de R e R_{uu}	
	Monte Carlo σ observado	Otimização do Sinal σ teórico	Monte Carlo σ observado	Otimização do Sinal σ teórico
Z_α	5.8%	2.2%	3.7%	3.1%
Z_q	34.0%	12.8%	19.1%	11.7%
$Z_{\delta e}$	23.6%	14.1%	11.1%	14.7%
M_α	3.6%	1.5%	2.9%	2.1%
M_q	10.2%	3.7%	8.2%	5.7%
$M_{\delta e}$	4.4%	2.5%	3.4%	3.2%

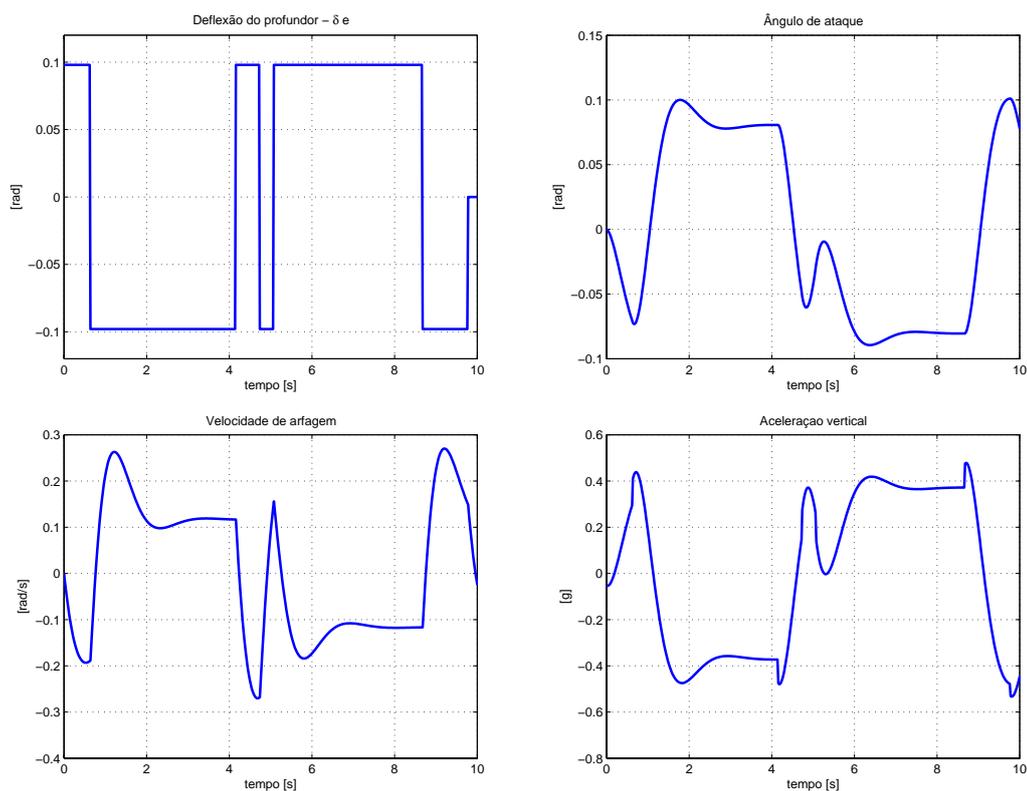


Figura 4.39: Sinal otimizado levando em consideração R e R_{uu}

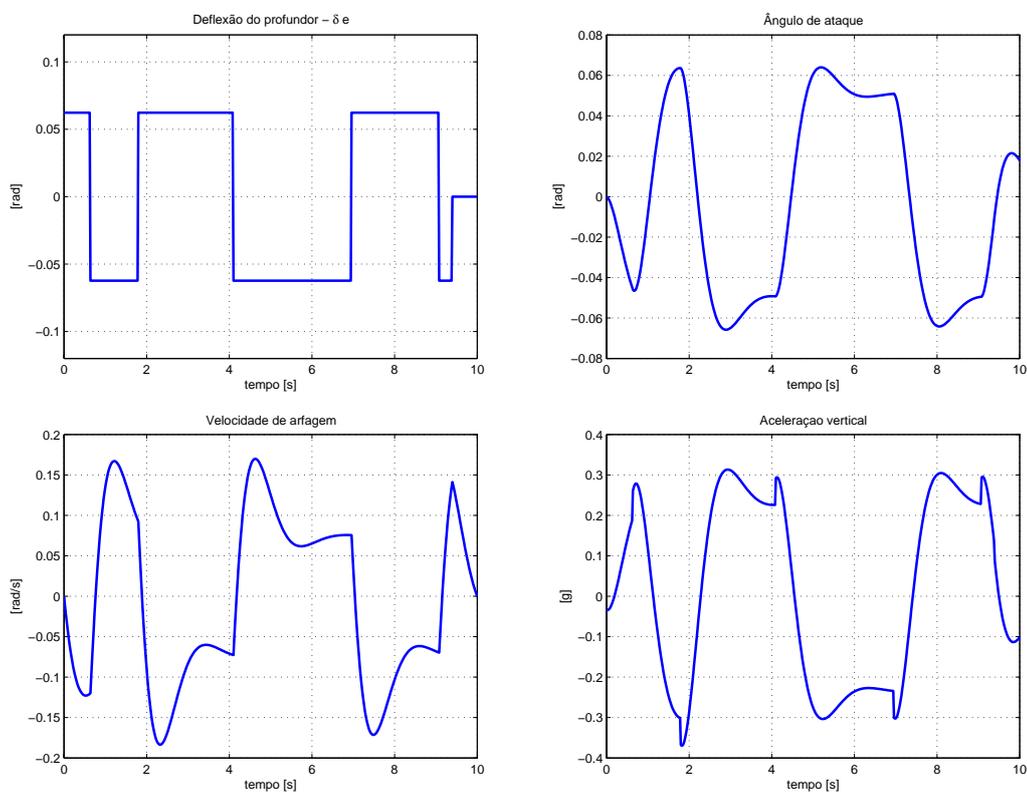


Figura 4.40: Sinal otimizado levando em consideração apenas R

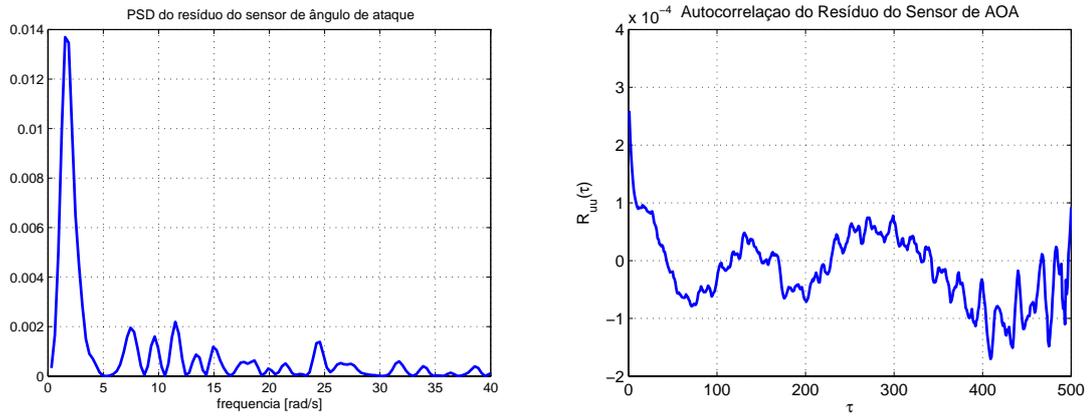


Figura 4.41: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor de α

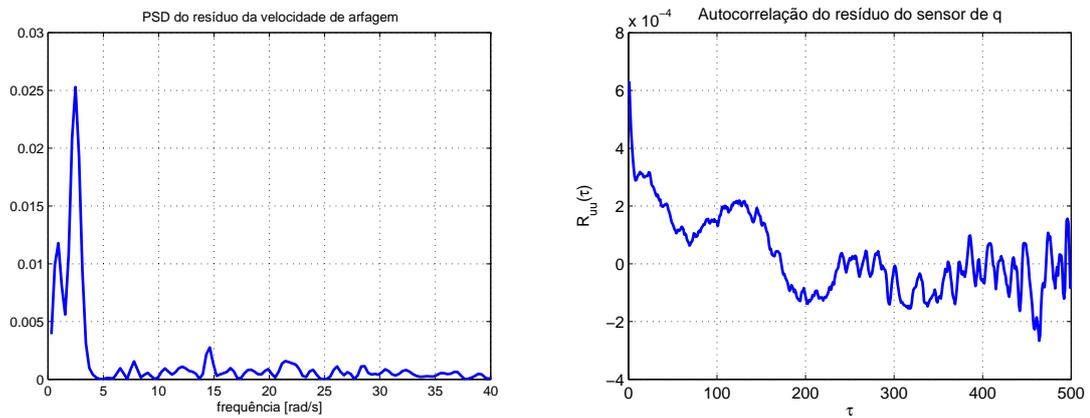


Figura 4.42: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor de q

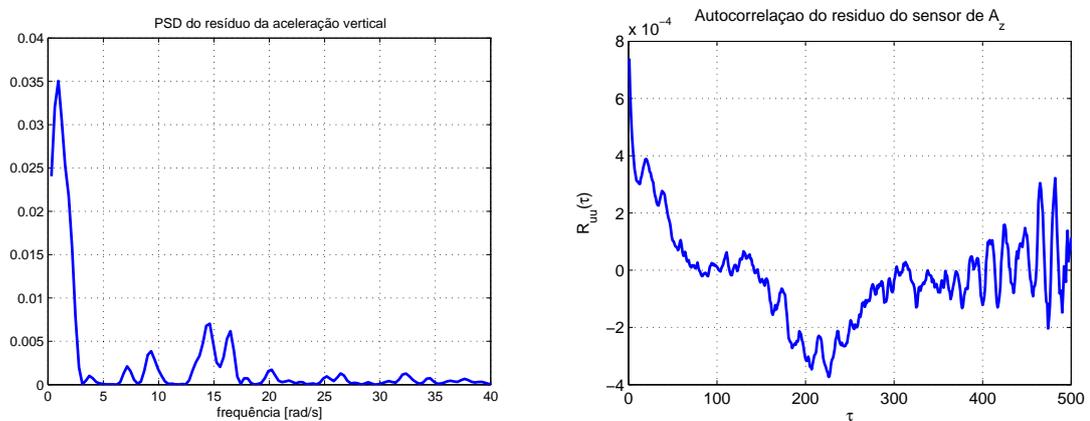


Figura 4.43: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor A_z

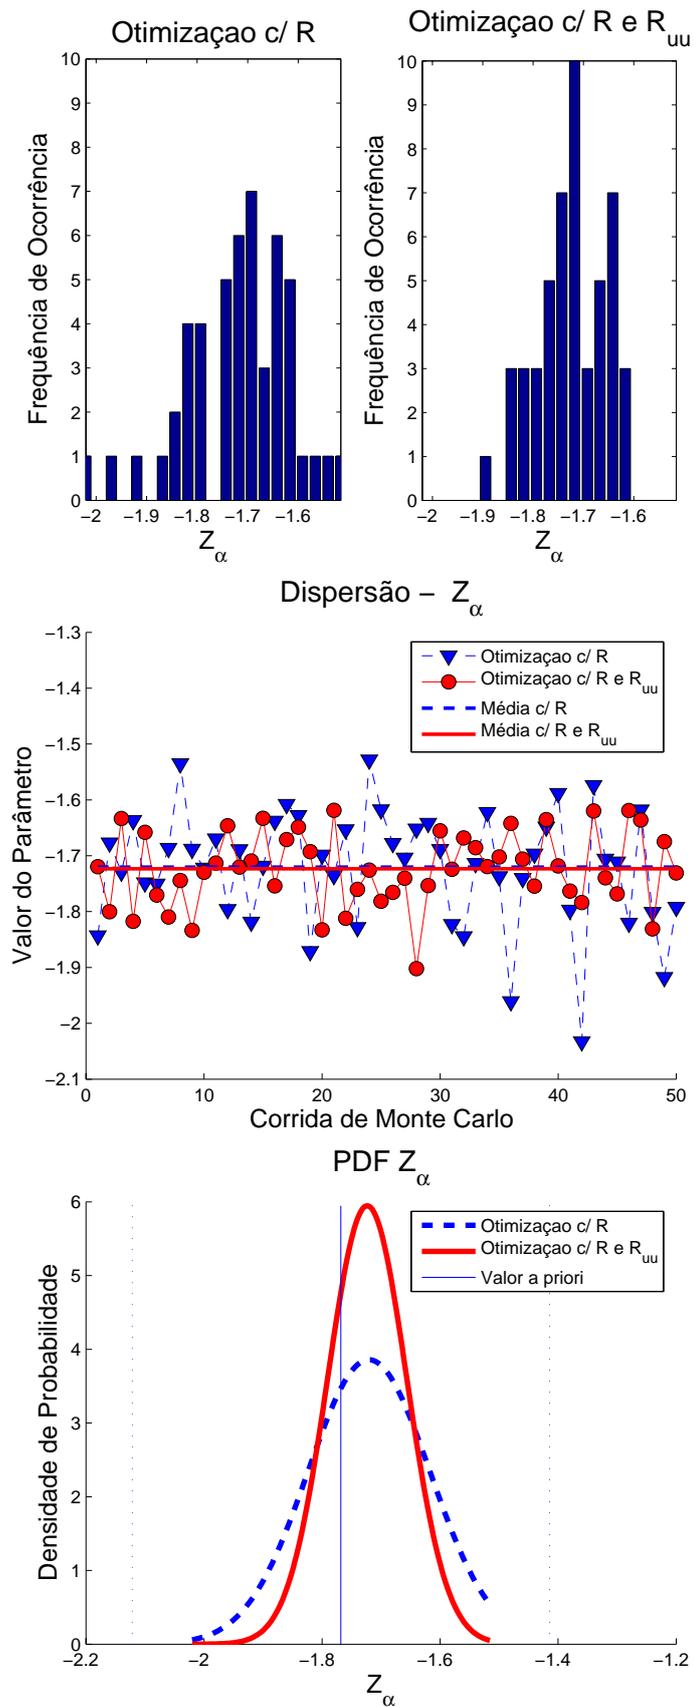


Figura 4.44: Exemplo 3 - Resultados da estimação de Z_α

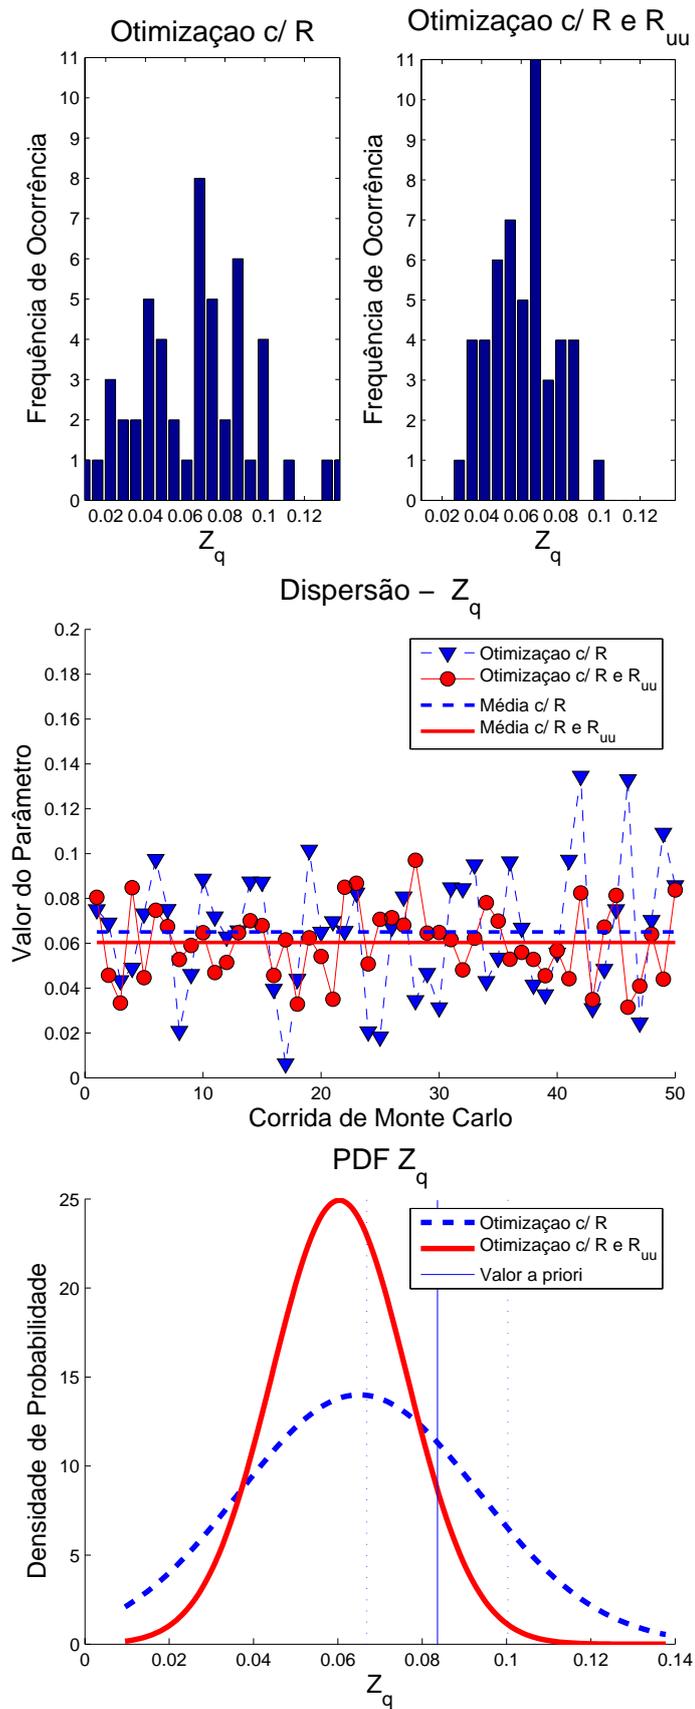


Figura 4.45: Exemplo 3 - Resultados da estimação de Z_q

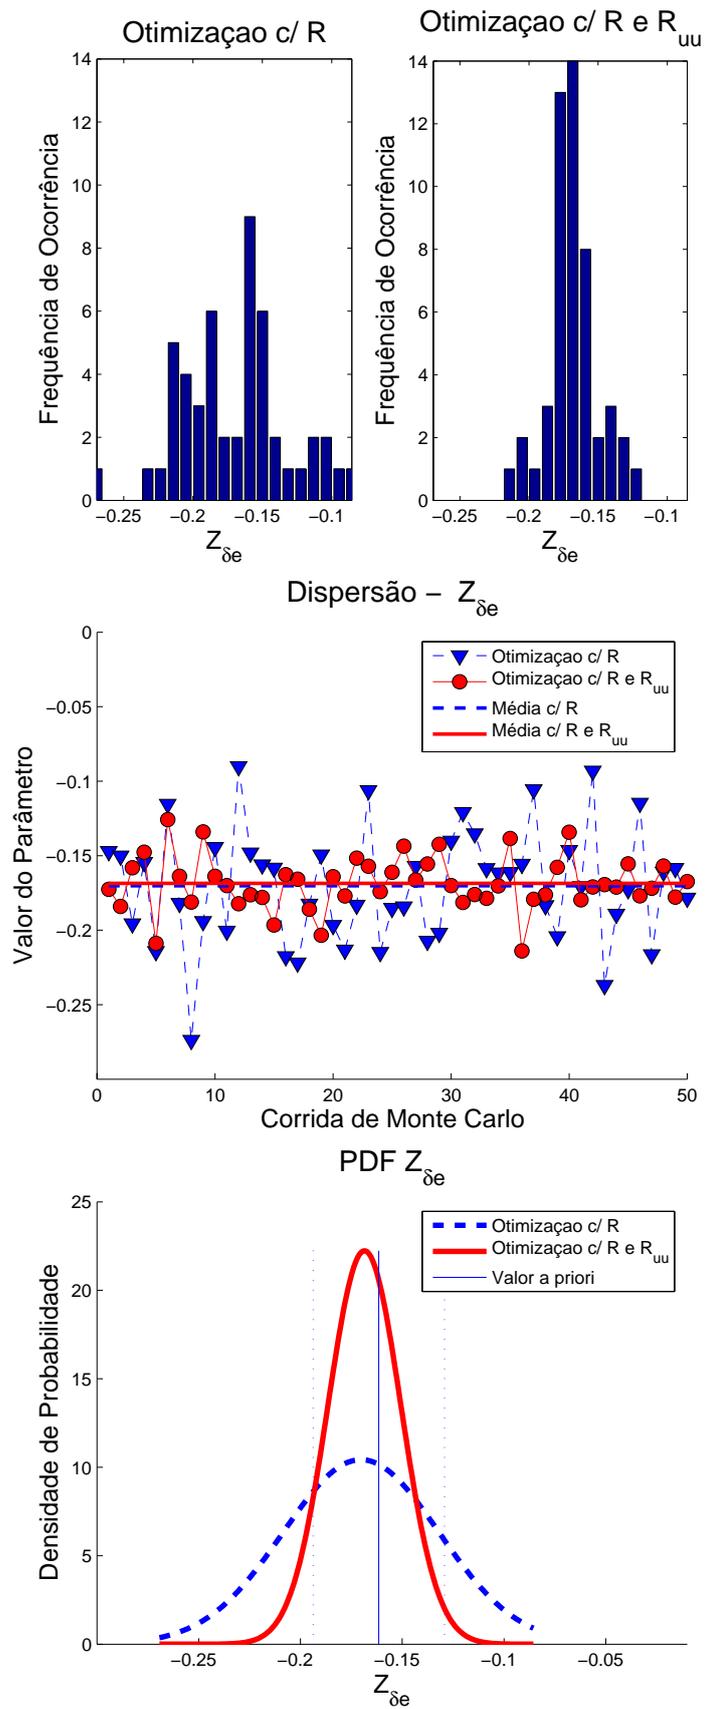


Figura 4.46: Exemplo 3 - Resultados da estimação de $Z_{\delta e}$

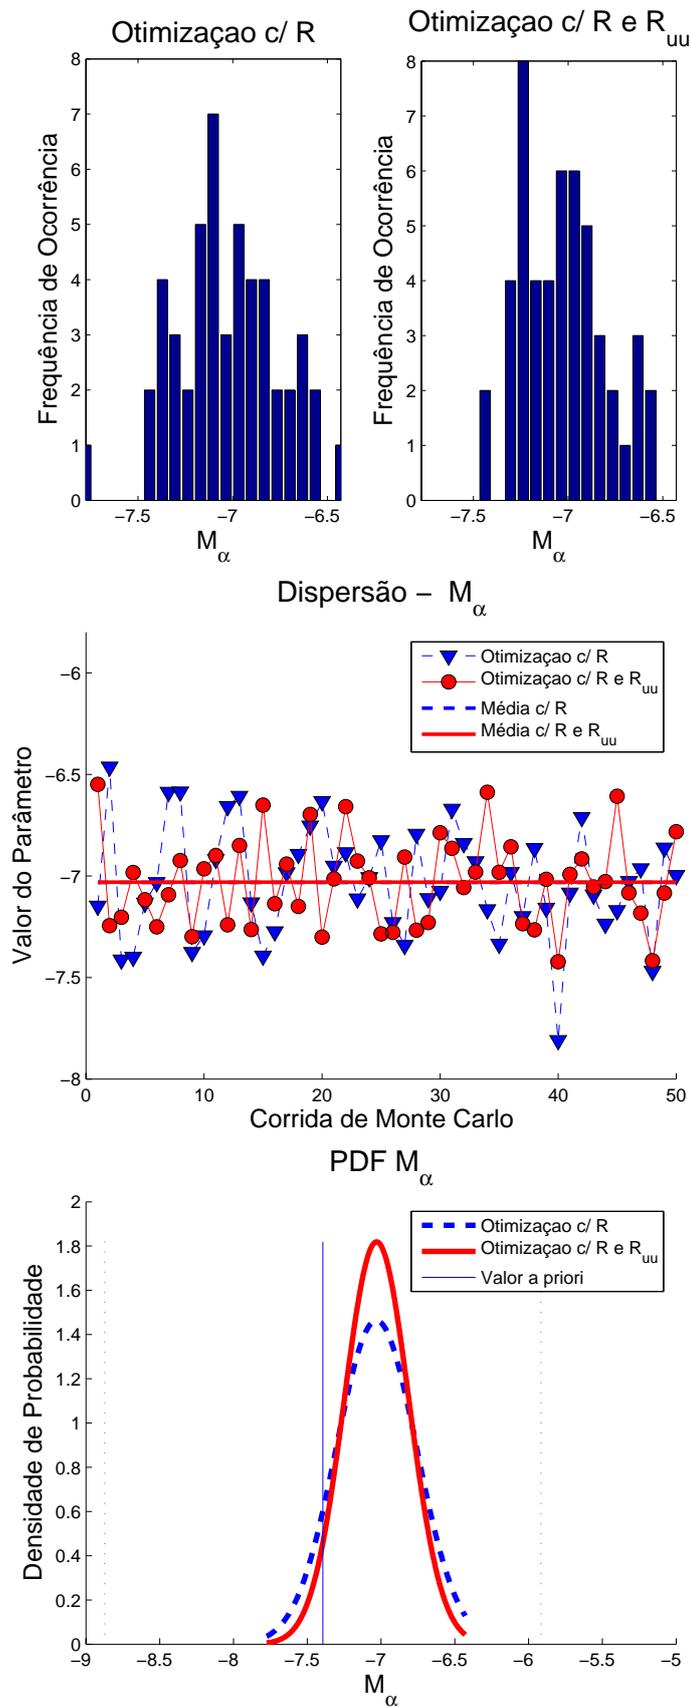


Figura 4.47: Exemplo 3 - Resultados da estimação de M_α

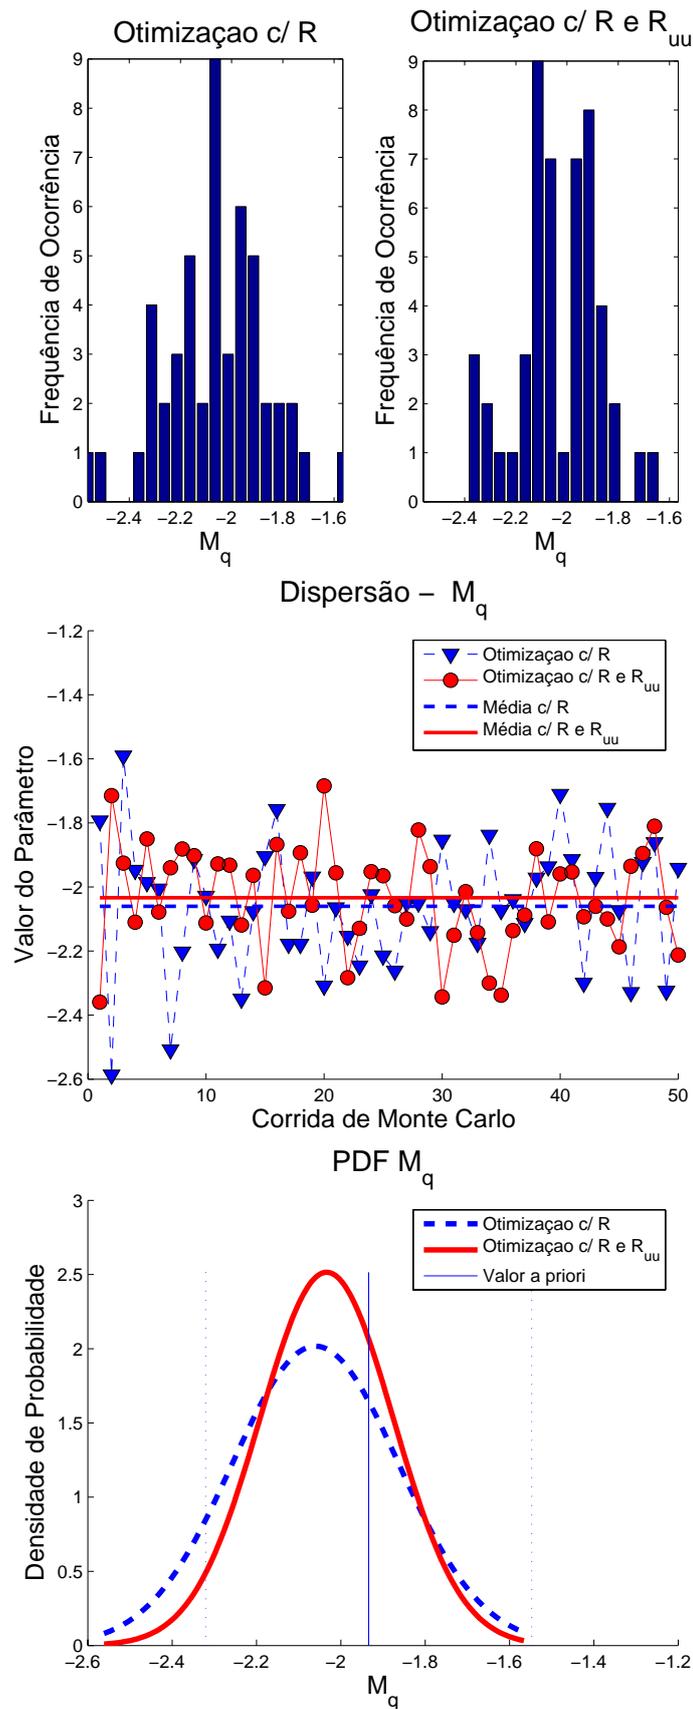


Figura 4.48: Exemplo 3 - Resultados da estimação de M_{δ_e}

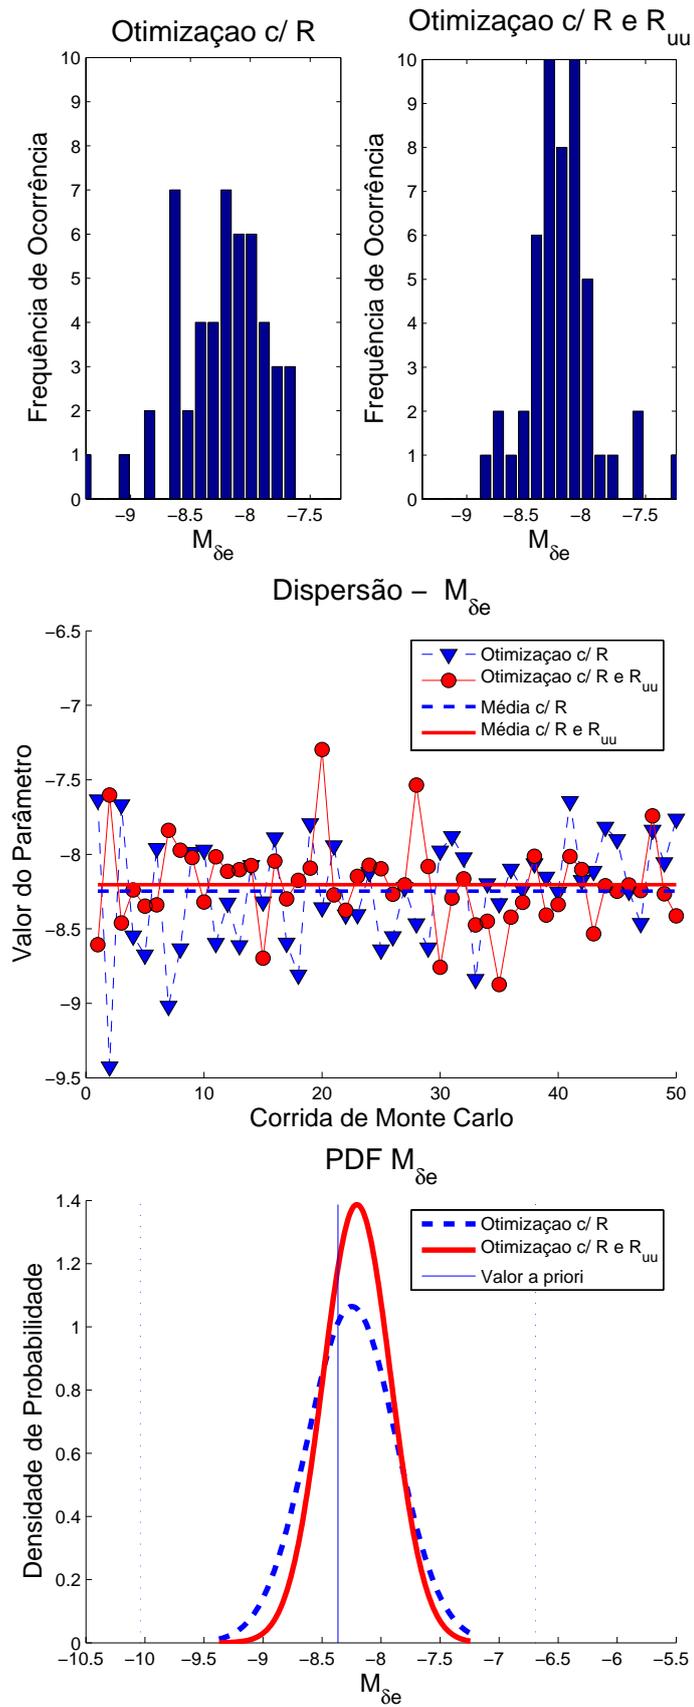


Figura 4.49: Exemplo 3 - Resultados da estimação de M_q

4.3 Dados Experimentais de Ensaio em Vôo

Os dados de ensaios em vôo colhidos para este experimento são oriundos de uma campanha de ensaios em vôo dedicada à análise das técnicas de desenvolvimento de otimização de manobras para estimação de parâmetros. Nesta oportunidade, foram analisadas manobras convencionais, especificadas em função da análise espectral dos sinais de excitação, e manobras otimizadas, desenvolvidas de acordo com as técnicas de otimização em função dos limites inferiores de Cramer-Rao. O objetivo é comparar as manobras convencionais com as manobras otimizadas, e verificar vantagens e desvantagens das diferentes abordagens.

Em um primeiro momento, na chamada pré-campanha de ensaios, foram realizados vôos para calibração e modelagem dos ruídos de medida dos sensores do sistema de aquisição de dados. Além disso, este vôo também serviu para abordagens iniciais no que tange a estimação dos parâmetros de interesse. Em suma, os vôos iniciais foram utilizados para gerar todo o modelo de conhecimento a priori necessário para o desenvolvimento e otimização das manobras, incluindo modelo de medida (covariâncias dos resíduos e matriz de autocorrelação dos mesmos) e estimativas iniciais dos parâmetros do modelo dinâmico (derivadas de estabilidade e controle). Em um segundo momento, após ter especificado manobras convencionais e manobras otimizadas em função do modelo a priori, foram realizados os vôos de avaliação dos sinais de excitação.

Para que este estudo fosse possível e uma abordagem estatística fosse viabilizada, foi planejado que para cada manobra estudada seriam executadas trinta corridas de ensaio, todas nas mesmas condições de vôo:

- **Altitude Pressão, h :** 1371 m;
- **Velocidade Verdadeira, V_{tas} :** 31.3 m/s.

Das trinta corridas de ensaio executadas para cada manobra, foram escolhidas as quinze melhores para a comparação estatística. O critério de escolha das quinze melhores corridas foi estabelecido de maneira a descartar as corridas de ensaios que propiciaram estimativas mais distantes das médias para cada parâmetro.

Os sinais de excitação foram aplicados manualmente pelo mesmo piloto. A análise

dos efeitos causados pelas diferenças entre os sinais aplicados e os sinais especificados não é abordada neste estudo. Foi estabelecido que o intervalo entre a aplicação dos sinais de excitação deveria ser suficiente para estabelecer o equilíbrio de vôo, principalmente, porque os modelos utilizados neste estudo são modelos lineares de pequenas perturbações.

Para cada manobra de ensaio, foi dedicado um vôo. Dentro do possível, todos os vôos foram realizados com a mesma quantidade de combustível e com o mesmo peso em equipamentos e tripulação. Foi considerado que a variação de massa devido ao consumo de combustível entre a primeira e a última corrida de ensaio para cada manobra é desprezível e que não é suficiente para polarizar as estimativas paramétricas.

No planejamento de cada vôo de ensaio, foi realizada uma análise de riscos, nela foram estabelecidos procedimentos de emergência e de minimização de riscos. Em especial, como pode ser visto no Anexo A, os procedimentos de minimização de riscos estão diretamente ligados com as técnicas de otimização, desenvolvimento e especificação de manobras de ensaios em vôo através da imposição de restrições. As restrições impostas ao procedimento de otimização levaram em consideração limites operacionais da aeronave ensaiada. No presente estudo, a restrição operacional utilizada foi a variação máxima da aceleração vertical, a qual deveria ficar entre $\pm 0.6 G$.

A seguir, são feitas as descrições da aeronave ensaiada, dos procedimentos de calibração dos sensores e dos procedimentos de especificação das manobras de ensaios em vôo estudados nesta campanha.

4.3.1 Aeronave Ensaída

A aeronave ensaiada é o CEA 205 CB.9 Curumim. Este equipamento é uma aeronave leve, bi-place lado-à-lado, desenvolvida e fabricada pelo Centro de Estudos Aeronáuticos da Universidade Federal de Minas Gerais, (OLIVEIRA, 2004). As três vistas do Curumim podem ser visualizadas na figura 4.50. Algumas de suas principais características estão descritas no Anexo B.

A cadeia de controle entre o manche e a deflexão do leme de profundidade (profundor) é mecânica, através de cabos e tubos. Neste estudo, não está sendo levado em consideração um modelo de atuação. Foi considerado, portanto, que a deflexão angular do leme de

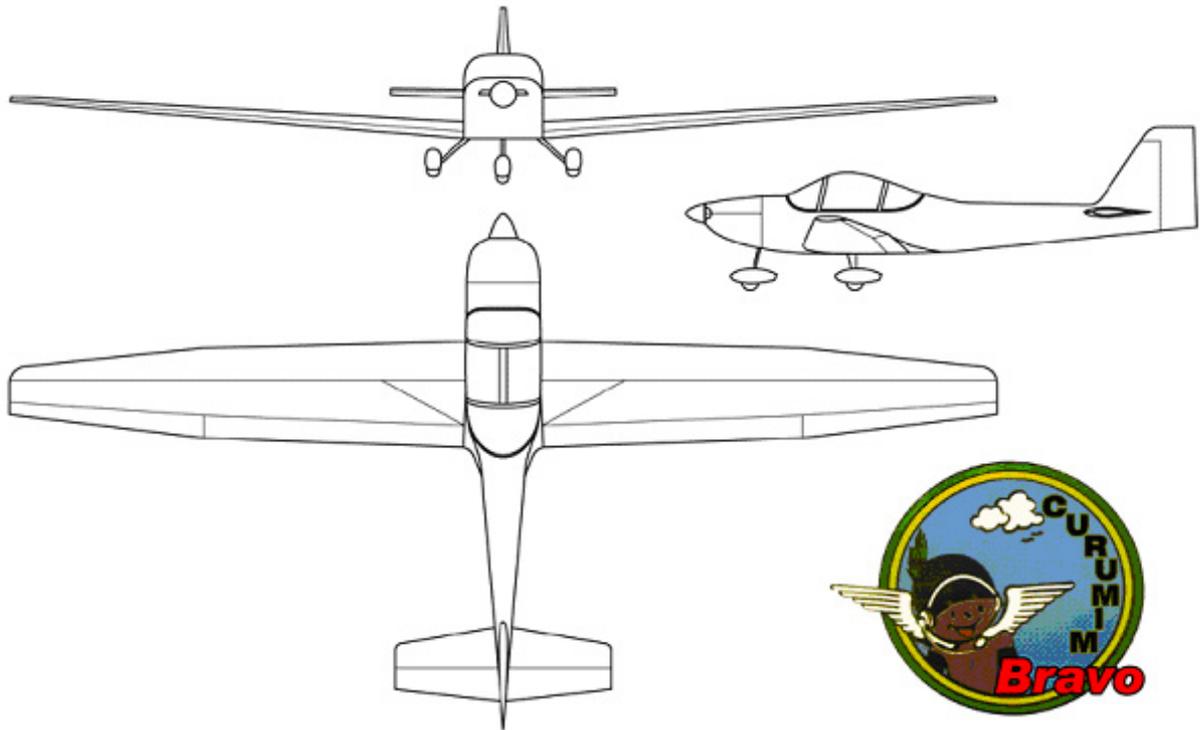


Figura 4.50: Três vistas do CEA-205 CB.9 Curumim

profundidade é apenas uma função direta da deflexão angular do manche.

Considerando características de projeto e ensaios anteriores de estimação paramétrica, as estimativas iniciais das derivadas aerodinâmicas dimensionais do modelo de período curto foram calculadas, respeitando as condições de vôo citadas anteriormente:

- $Z_\alpha = -1.768$;
- $Z_q = 0.08$;
- $Z_{\delta_e} = -0.16$;
- $M_\alpha = -7.394$;
- $M_q = -1.934$;
- $M_{\delta_e} = -8.360$.

Resultando no seguinte modelo de conhecimento a priori:

$$\dot{x} = \begin{bmatrix} \dot{\alpha} \\ \dot{q} \end{bmatrix} = \begin{bmatrix} -1.768 & 1 + 0.080 \\ -7.394 & -1.934 \end{bmatrix} \begin{bmatrix} \alpha \\ q \end{bmatrix} + \begin{bmatrix} -0.160 \\ -8.360 \end{bmatrix} \delta e \quad (4.9)$$

$$\begin{bmatrix} \alpha_m \\ q_m \\ a_z \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ -1.768 \frac{31.3}{9.8} & 0.080 \frac{31.3}{9.8} \end{bmatrix} \begin{bmatrix} \alpha \\ q \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ -0.160 \frac{31.3}{9.8} \end{bmatrix} \delta e \quad (4.10)$$

O modelo descrito acima foi o utilizado para especificar e otimizar os sinais de excitação.

4.3.2 Sistema de Aquisição de Dados de Ensaio em Vôo

O sistema de aquisição de dados de ensaios em vôo utilizado na aeronave, basicamente, é dividido em cinco componentes principais: a plataforma inercial, o sensor anemométrico, o sensor de GPS, os sensores de posição das colunas de controle e a unidade de aquisição e gravação de dados, figura 4.51.

A unidade de aquisição e gravação de dados, basicamente, consiste em um computador TRM/916 equipado com um teclado e com uma interface gráfica que permite o acompanhamento do procedimento de aquisição de dados em tempo real. Este dispositivo é equipado com um cartão de memória *compact flash* de 128MB de capacidade, o que permite a gravação dos dados a bordo. O sistema também possui uma interface para rede com protocolo TCP/IP que permite o *download* dos dados. O sistema operacional utilizado é o Linux em tempo real.

A plataforma inercial utilizada é uma Crossbow, modelo AHRS400CC. Esta central inercial trabalha com acelerômetros lineares, sensores de velocidade rotacional e magnetômetros. Através da utilização de acelerômetros e girômetros nos três eixos a dinâmica completa pode ser medida. Além disso, através dos magnetômetros, a proa magnética pode ser obtida. As principais características deste equipamento estão listadas abaixo (CROSSBOW,):

1. **Taxa de aquisição:** até 60Hz;
2. Atitude
 - **Medida de ângulo de rolamento e ângulo de arfagem(°):** ±180, ±90;
 - **Acurácia Estática(°)/Dinâmica(°rms):** até ±0.5, ±2.0;



Figura 4.51: Componentes principais do sistema de aquisição de dados

3. Proa Magnética

- **Faixa ($^{\circ}$):** ± 180 ;
- **Medida de ângulo de rolamento e ângulo de arfagem($^{\circ}$):** ± 180 , ± 90 ;
- **Acurácia Estática($^{\circ}$)/Dinâmica($^{\circ}rms$):** até ± 1.5 , ± 3.0 ;

4. Velocidade Angulares - Rolamento, Arfagem e Guinada

- **Faixa ($^{\circ}/s$):** ± 100 ;
- **Não-linearidade (% FS):** < 0.3 ;

5. Acelerações Lineares - X, Y, Z

- **Faixa (G):** ± 10 ;
- **Não-linearidade (% FS):** < 1.0 ;

6. Alimentação

- **Voltagem de entrada (VDC):** $9.0 - 30.0$;
- **Corrente (mA):** até 300 ;
- **Consumo com 12 VDC(W):** até 4.0 ;

7. Dimensões

- **Tamanho (cm):** $7.63 \times 9.53 \times 10.42$;
- **Peso (kg):** menor que 0.77 ;
- **Consumo com 12 VDC(W):** até 4.0 .

O sensor anemométrico é desenvolvido pela ICASIM (ICASIM Smart Air Data Boom). Este sensor é responsável pelo fornecimento do ângulo de ataque, do ângulo de derrapagem, da velocidade de vôo, da altitude de vôo e da temperatura ambiente, através das suas tomadas de pressão total e pressão estática. Suas principais características são:

1. **Taxa de aquisição:** até $30Hz$;

2. Pressão Estática

- **Faixa (mbar):** $0 - 1034$;
- **Linearidade e Histerese (%):** ± 0.1 ;

3. Pressão Dinâmica

- **Faixa (mbar):** $0 - 50$;
- **Linearidade e Histerese (%):** ± 0.1 ;

4. Temperatura

- **Faixa ($^{\circ}C$):** $-40 - +70$;
- **Linearidade e Histerese ($^{\circ}C$):** ± 0.5 ;

5. Ângulo de Ataque e Ângulo de Derrapegem

- **Faixa ($^{\circ}$):** ± 20 ;
- **Linearidade e Histerese ($\%$):** ± 0.1 ;

6. Limitações Operacionais

- **Altitude:** 0 - 8500m;
- **Velocidade verdadeira (MSL):** até 325km/h;
- **Velocidade verdadeira (2000 m):** até 358km/h;
- **Velocidade verdadeira (2000 m):** até 398km/h;
- **Velocidade verdadeira (2000 m):** até 440km/h;
- **Velocidade verdadeira (2000 m):** até 497km/h;

7. Dimensões

- **Comprimento (cm):** 0.52;
- **Diâmetro (cm):** 0.12/0.40;
- **Peso (kg):** menor que 0.490;

O receptor de GPS além de prover os dados de navegação, é o responsável pela base de tempo utilizada por todo o sistema de aquisição. A taxa de aquisição deste sensor é de 1Hz. As principais variáveis adquiridas são: posição horizontal, velocidade em relação ao solo, trajetória verdadeira, velocidade vertical e altitude.

Por fim, as posições angulares das superfícies de controle foram obtidas através de potenciômetros lineares (GEFRAN PZ12). Estes potenciômetros foram instalados nos tubos e cabos entre as colunas de controle e as superfícies de controle aerodinâmico.

A instalação dos sensores na aeronave Curumim foi feita de maneira a minimizar os erros sistemáticos e simplificar a análise dos dados, figura 4.52. Os aspectos mais importantes dizem respeito ao posicionamento do sensor anemométrico, ao posicionamento do sensor inercial e ao posicionamento da antena do sensor de GPS. O sensor anemométrico é muito suscetível aos efeitos aerodinâmicos ao redor da asa (*downwash*, *upwash*, *sidewash*, por exemplo), os quais podem ocasionar erros sistemáticos, principalmente, nas medidas

do ângulo de ataque e do ângulo de derrapagem. Procurou-se, portanto, instalar o sensor anemométrico de maneira a possibilitar o maior afastamento possível do fluxo aerodinâmico influenciado pela asa, a melhor posição encontrada foi a ponta da asa esquerda. Quanto ao sensor inercial, para evitar a necessidade de grandes correções oriundas do *off-set* entre a posição de instalação e o centro de gravidade da aeronave, procurou-se instalá-lo no centro de gravidade estimado. Já quanto à antena do receptor de GPS, procurou-se instalá-la em uma posição que evitasse interferências eletromagnéticas oriundas do motor da aeronave e dos equipamentos de cabine, além de possibilitar uma melhor linha de visada com a constelação de satélites. A mesma foi instalada, portanto, externamente, na extremidade superior da fuselagem, entre a cabine de comando e a empenagem.

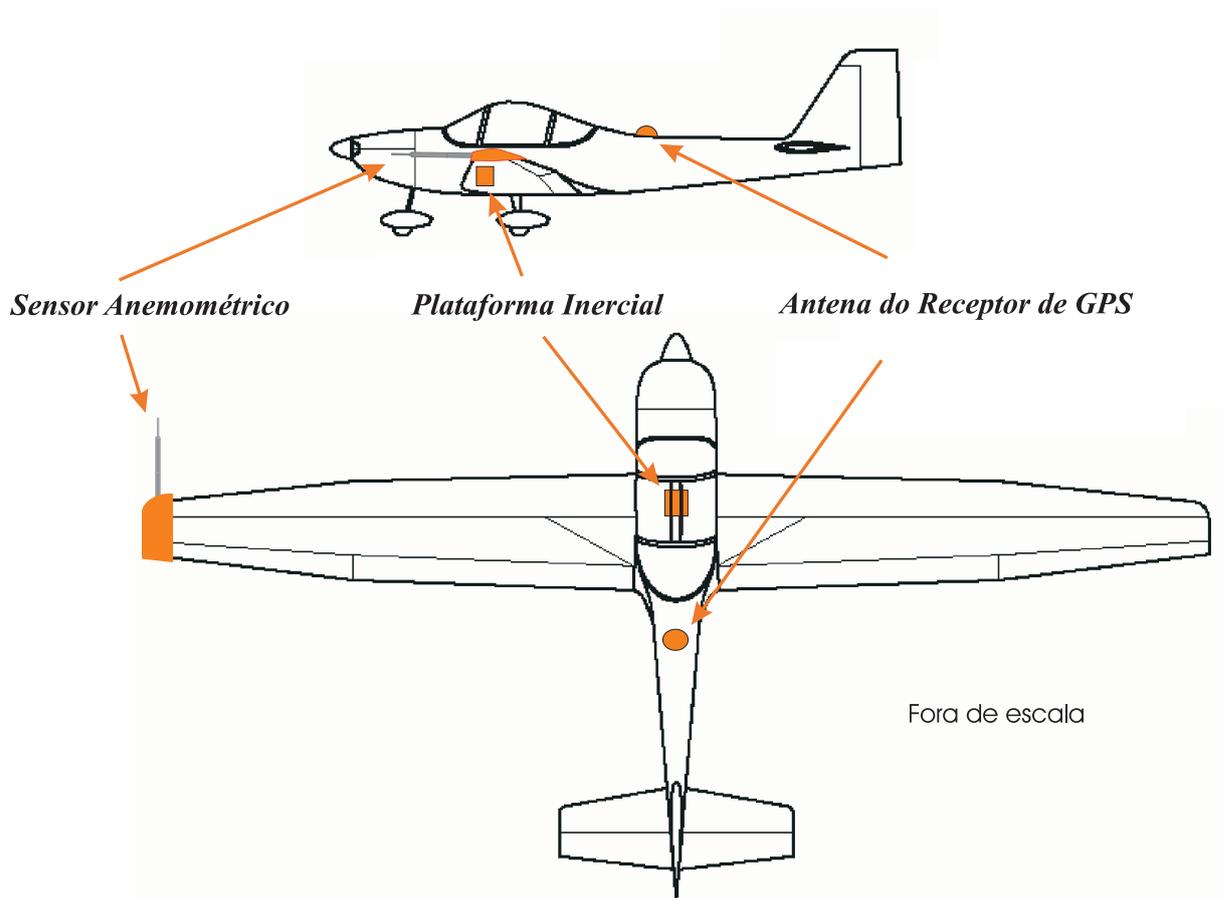


Figura 4.52: Instalação dos principais componentes do sistema de aquisição de dados na aeronave Curumim

Tabela 4.7: Fatores de Escala e Erros Sistemáticos

Sensor	Fator de Escala	Erro Sistemático
α_1	1.4672	-0.0470 <i>rad</i>
q_1	1.1090	0.0047 <i>rad/s</i>
A_{z_1}	1.0520	0.0483 <i>G</i>
V_{tas_1}	1.0000	-2.2430 <i>m/s</i>

4.3.2.1 Calibração dos Sensores Anemométricos e Sensores Inerciais via Compatibilização de Dados

A calibração dos sensores foi feita através da aplicação de técnicas de compatibilização de dados, ou *Flight Path Reconstruction*, (JATEGAONKAR, 2001)(MENDONCA; HEMERLY; GOES, 2005). O modelo cinemático utilizado foi um modelo não-linear completo, incluindo as variáveis látero-direcionais. Os resultados mostrados aqui, entretanto, dizem respeito às variáveis de interesse para este estudo, as quais influenciam no modelo de período curto utilizado. Maior ênfase, portanto, é dada às seguintes variáveis: ângulo de ataque, velocidade de arfagem, aceleração vertical e velocidade de vôo. Os resultados da calibração dos sensores destas variáveis estão mostrados na tabela 4.7.

Os dados utilizados para este procedimento correspondem à trinta segundos de dados selecionados de um dos vôos da pré-campanha de ensaio. Nesta oportunidade foram aplicados sinais de excitação que garantiram adequada excitação das variáveis longitudinais, principalmente daquelas correspondentes ao período curto. Nas figuras 4.53 - 4.56 estão ilustradas as curvas temporais dos dados medidos e dos dados preditos através da compatibilização. Os parâmetros da tabela 4.7 foram utilizados para a correção dos dados de medida na análise de manobras de ensaios em vôo que se segue.

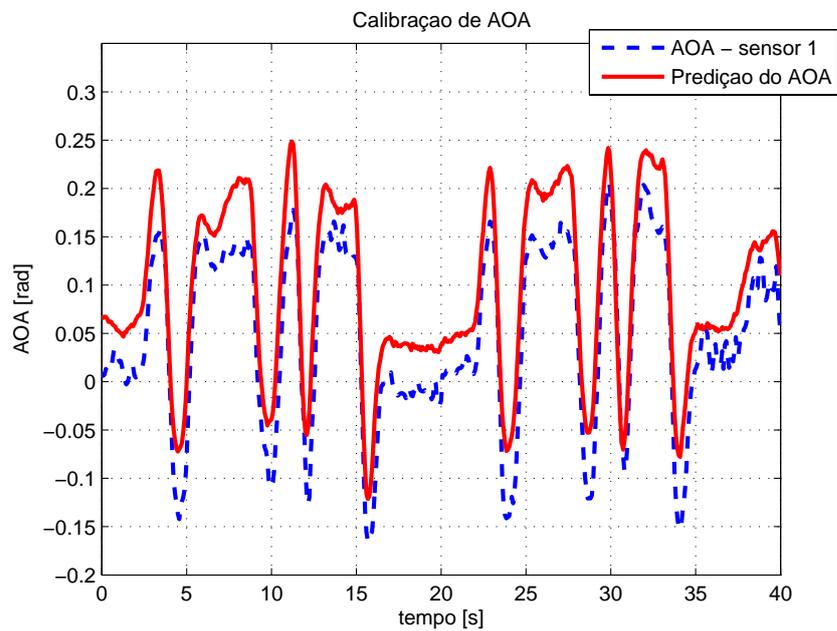


Figura 4.53: Gráfico de Calibração dos Sensores de Ângulo de Ataque

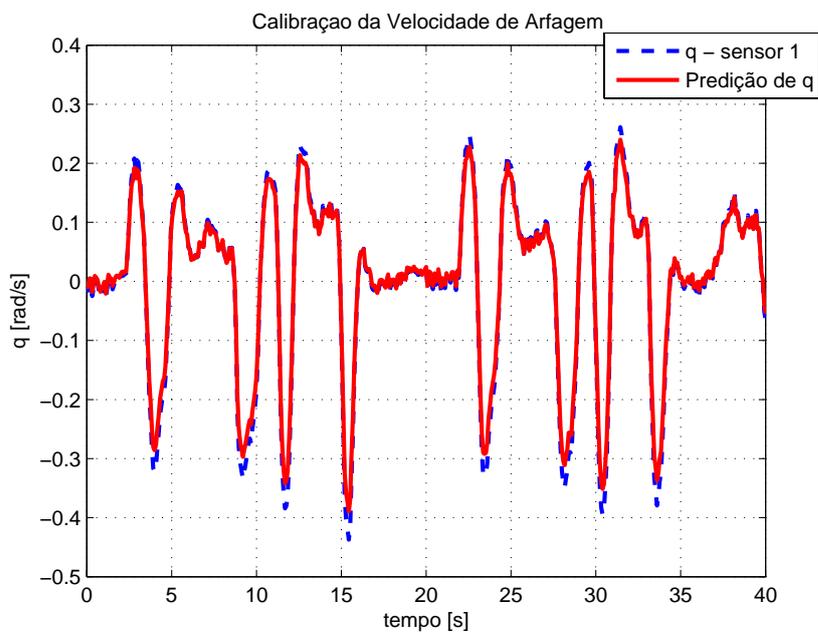


Figura 4.54: Gráfico de Calibração do Sensor de Velocidade de Arfagem

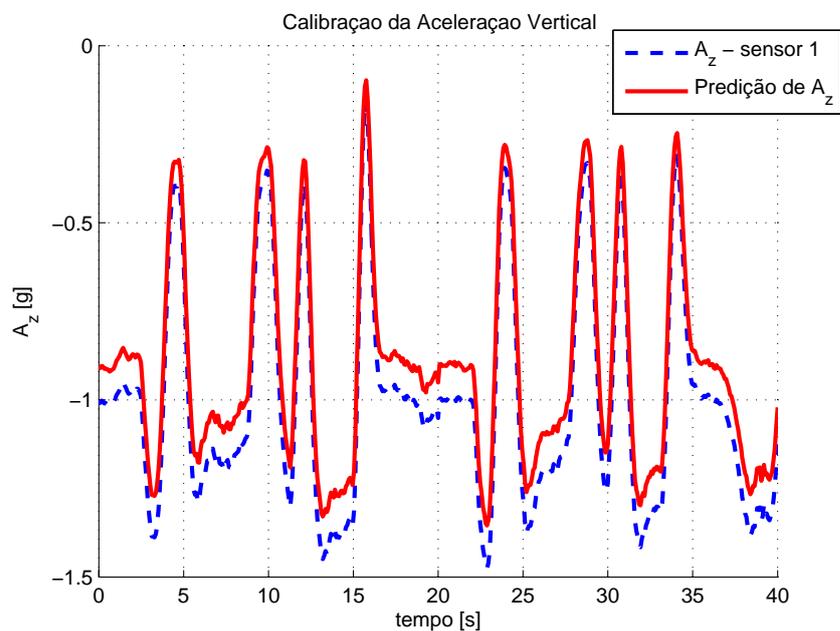


Figura 4.55: Gráfico de Calibração do Sensor de Aceleração Vertical

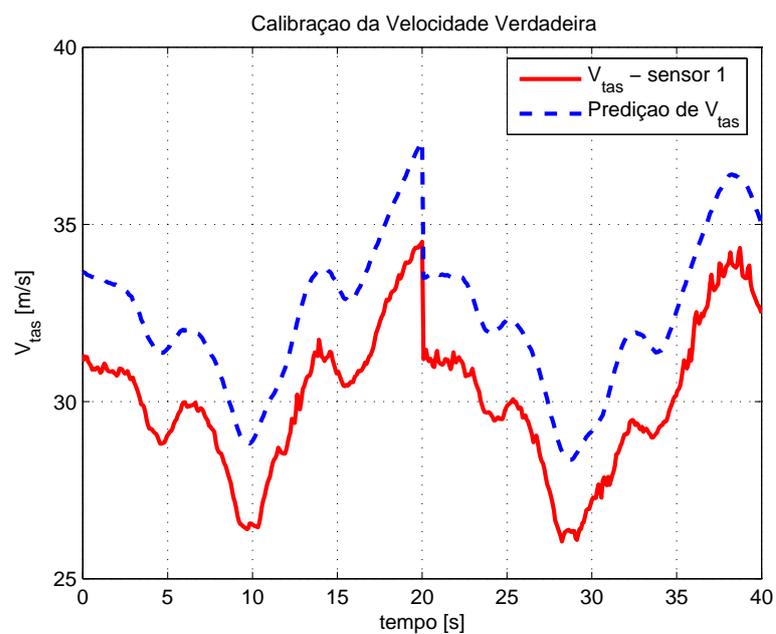


Figura 4.56: Gráfico de Calibração do Sensor de Velocidade Verdadeira

4.3.2.2 Modelagem dos Resíduos de Medida do Sistema de Aquisição de Dados

Um componente importante do algoritmo de otimização de sinais de excitação é o modelo de medida. Neste modelo devem ser consideradas as covariâncias e as funções de autocorrelação dos resíduos de medida. Os resíduos de medida considerados neste estudo são os referentes aos sensores de ângulo de ataque, velocidade de arfagem e aceleração vertical, uma vez que são apenas essas as variáveis consideradas no modelo de período curto adotado.

Os resíduos foram obtidos através do ajuste das curvas de saída aplicando o procedimento de estimação paramétrica. Os dados considerados correspondem à primeira metade (15 s) dos dados utilizados para calibração dos sensores. O modelo utilizado é o próprio modelo adotado para análise de manobras, ou seja, o modelo de período curto. Espera-se incluir na modelagem dos resíduos de medida, entre outros efeitos, as não-linearidades da dinâmica de vôo, pois as mesmas não estão modeladas e certamente irão influenciar no cálculo dos limites de Cramer-Rao. Em suma, a modelagem dos resíduos de medida será utilizada para avaliar e otimizar os sinais de excitação em relação do modelo linear de período curto; é desejável, portanto, que os mesmos sejam obtidos levando em consideração este modelo, pois, caso contrário, a otimização dos sinais de excitação seria muito otimista.

Na tabela 4.8, estão descritas as covariâncias dos resíduos de medida dos sensores de ângulo de ataque, velocidade verdadeira e aceleração vertical.

Tabela 4.8: Covariâncias dos resíduos de medida (α, q, A_z)

Sensor	Covariância
α_1	0.0010
q	0.0013
A_z	0.0053

Nas figuras 4.57 - 4.59, estão descritos a densidade espectral de potência e a função de autocorrelação dos mesmos sensores.

Nota-se que os resíduos possuem fortes características de resíduos coloridos, principalmente os resíduos de ângulo de ataque e de aceleração vertical. De acordo com o mostrado nas densidades espectrais de potência, grande parte da energia dos mesmos está

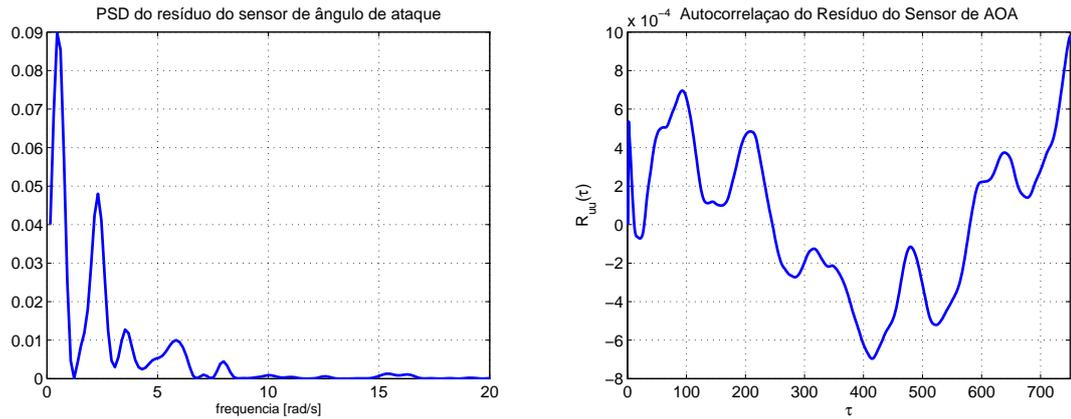


Figura 4.57: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor de α

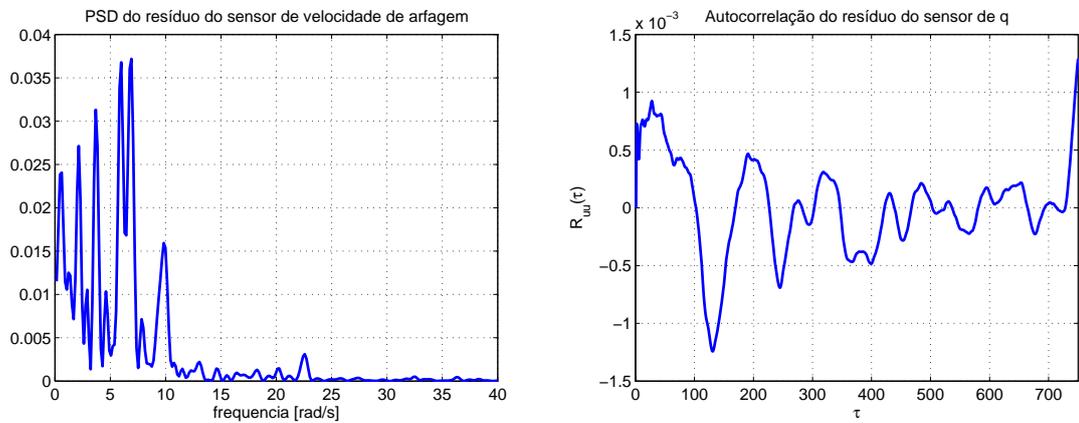


Figura 4.58: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor de q

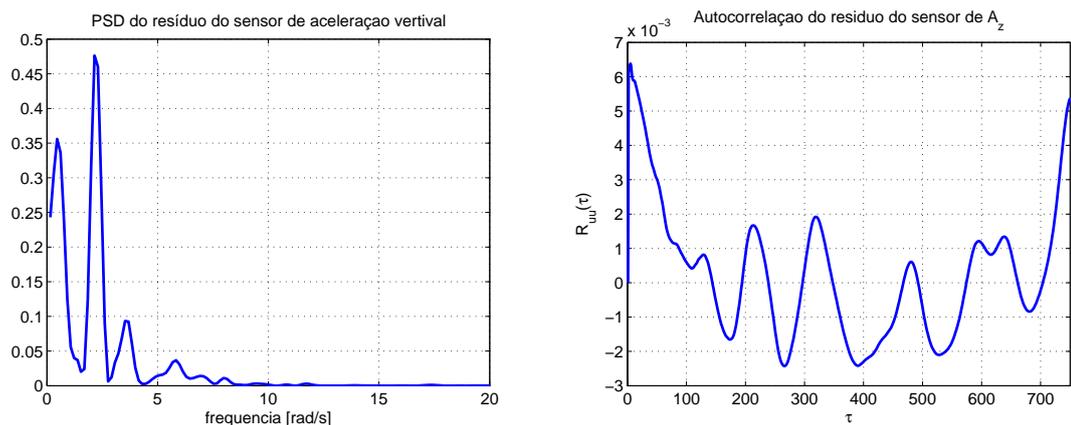


Figura 4.59: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor A_z

concentrada nas baixas frequências. É interessante salientar que estas são, realmente, as características dos resíduos que serão encontrados na análise dos dados neste estudo e, portanto, é importante levá-las em consideração no desenvolvimento e otimização dos

sinais de excitação para que o algoritmo de cálculo da dispersão das estimativas não seja demasiadamente otimista.

4.3.3 Manobras Convencionais

As manobras convencionais estudadas nesta oportunidade são o *Doublet*(ou 1-1), o 2-1-1 e o 3-2-1-1. O ajuste destes sinais foi feito em função das suas densidades espectrais de potência. O objetivo é maximizá-las nas frequências próximas a frequência natural do período curto do Curumim, 3.31 rad/s, levando em consideração o modelo de conhecimento a priori. A figura 4.60 mostra as densidades espectrais de potência dos três sinais citados acima já com suas amplitudes ajustadas.

Pode-se notar que o δt de 0.7s é adequado para concentrar a energia dos sinais de excitação nas frequências próximas à 3.31 rad/s. O ajuste das amplitudes dos sinais foi realizado por tentativa e erro, considerando o modelo de conhecimento a priori, de maneira a manter a variação da aceleração vertical entre $\pm 0.6G$. Conforme pode ser visto nas figuras 4.61 - 4.63, foi considerado que o *Doublet* deveria ser aplicado com uma amplitude de 10 graus, que o 2-1-1 deveria ser aplicado com uma amplitude de 8 graus, e que o 3-2-1-1 deveria ser aplicado com uma amplitude de 7 graus.

Como já foi dito, para cada manobra, foi dedicado um voo no qual foram realizadas trinta corridas de ensaio. Foram selecionadas as quinze melhores corridas. A resposta temporal do Curumim (em período curto) para as quinze melhores corridas de cada manobra estudada está ilustrada nas figuras 4.64 - 4.66.

O procedimento de estimação de parâmetros foi realizado para cada corrida de ensaio. Os resultados estão mostrados em função dos histogramas e das função de densidade de probabilidade das respectivas distribuições, figuras 4.70 - 4.75. Maiores detalhes a respeito da análise dos resultados serão dados mais adiante, em conjunto com a análise dos resultados das manobras otimizadas.

4.3.4 Manobras Otimizadas

Para avaliar as técnicas de otimização de manobras abordadas neste estudo, foi desenvolvido um sinal de excitação otimizado para estimar os seis parâmetros do modelo

de período curto da aeronave Curumim. A função de aptidão utilizada foi (3.18). Assim como para os sinais convencionais, a principal restrição do procedimento de otimização foi a variação máxima da aceleração vertical, ± 0.6 G. Outra restrição imposta diz respeito à amplitude da deflexão do profundor, neste procedimento foi estabelecido que a variação do profundor deveria ser no máximo $|10|$ graus. O período máximo de duração do sinal foi de 15 segundos. Por fim, por questões de implementabilidade por parte do piloto, foi estabelecido que a mínima diferença entre os *switching times* deveria ser de 0.5 segundos e o número selecionado de *switching times* foi 8. Os objetivos estabelecidos para a otimização foram a minimização das covariâncias individuais.

É interessante salientar que neste procedimento foram levados em consideração os resíduos coloridos dos sensores de medida do ângulo de ataque, da velocidade de arfagem e da aceleração vertical, de acordo com o mostrado anteriormente, figuras 4.57 - 4.59. O sinal resultante e a resposta temporal simulada estão mostrados na figura 4.67.

Na figura 4.68, estão os dados das quinze corridas de ensaio selecionadas para comparação estatística. Pode-se observar o sinal de excitação aplicado e as respostas temporais da aeronave em ângulo de ataque, velocidade de arfagem e aceleração vertical.

Para se estabelecer comparação entre o sinal otimizado e os sinais especificados em função da densidade espectral de potência, estes também foram avaliados em função dos limites inferiores de Cramer-Rao levando em consideração os resíduos coloridos dos sensores, tabela 4.9. Em contra partida, a densidade espectral de potência do sinal otimizado também foi avaliada, figura 4.69.

4.3.5 Análise dos Resultados

Na tabela 4.9, pode-se verificar que o sinal otimizado realmente reduz a dispersão das estimativas para todos os parâmetros do modelo de período curto. Entre os sinais especificados em função da densidade espectral de potência, nota-se que para os parâmetros Z_α , M_α , M_q e $M_{\delta e}$ o 3-2-1-1 é superior, já para Z_q e $Z_{\delta e}$ o *Doublet* é superior.

Observando-se as densidade espectrais, figura 4.69, nota-se que o sinal otimizado oferece maior energia. Isso se dá devido ao maior tempo de duração do mesmo. É interessante salientar que, mesmo com energia superior, o sinal otimizado respeita as restrições im-

postas. A tendência observada é que o sinal otimizado tende a aumentar a densidade espectral de potência em regiões espectrais bem definidas, mantendo suas bandas relativamente largas. O sinal otimizado concentra elevada densidade espectral de potência não só nas frequências próximas a 3.31 rad/s, mas também em frequências entre 1 e 2 rad/s e entre 2 e 2.5 rad/s. Essa característica certamente ocasiona a maior excitação de frequências pouco excitadas pelos sinais convencionais, o que pode propiciar melhores resultados na estimação paramétrica.

As figuras 4.70 - 4.75 mostram os histogramas, as dispersões e as funções de densidade de probabilidade das estimativas paramétricas para os seis parâmetros do modelo de período curto adotado. Estes resultados são referentes às quinze melhores corridas de ensaio de cada manobra estudada. A tendência observada é que o sinal otimizado melhorou consideravelmente a confiabilidade das estimativas, pois os resultados obtidos com sua aplicação tenderam a menores dispersões e menores *bias*, principalmente quando são observados os parâmetros Z_α , Z_q , $Z_{\delta e}$ e M_q . Este resultado é o esperado, uma vez que, claramente, o sinal otimizado minimiza os limites de Cramer-Rao e ainda apresenta maior potência nas frequências de interesse. Além disso, uma vez que a frequência natural do sistema apenas depende dos parâmetros contidos na matriz A , o sinal especificado em função da análise espectral não considera as derivadas de controle e outros eventuais parâmetros que venham a estar fora da mesma.

Outro aspecto a ser considerado é que o sinal otimizado possui maior complexidade do que os sinais convencionais estudados. Essa maior complexidade pode prejudicar a implementação em vôo, principalmente quando o sinal está sendo aplicado manualmente, como neste estudo. Este ponto é preocupante, pois os sinais com maior complexidade estão mais sujeitos a não serem implementados adequadamente. Embora o presente experimento tenha demonstrado robustez quanto ao disposto acima, acredita-se que dispositivos para aplicação automática dos sinais de excitação sejam fundamentais em alguns casos.

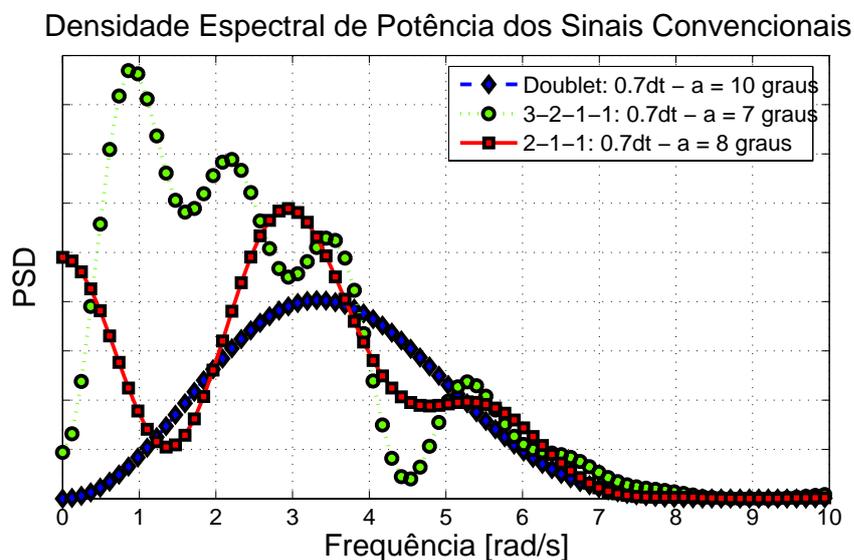


Figura 4.60: Densidade Espectral de Potência e Função de Autocorrelação do Resíduo do Sensor A_z

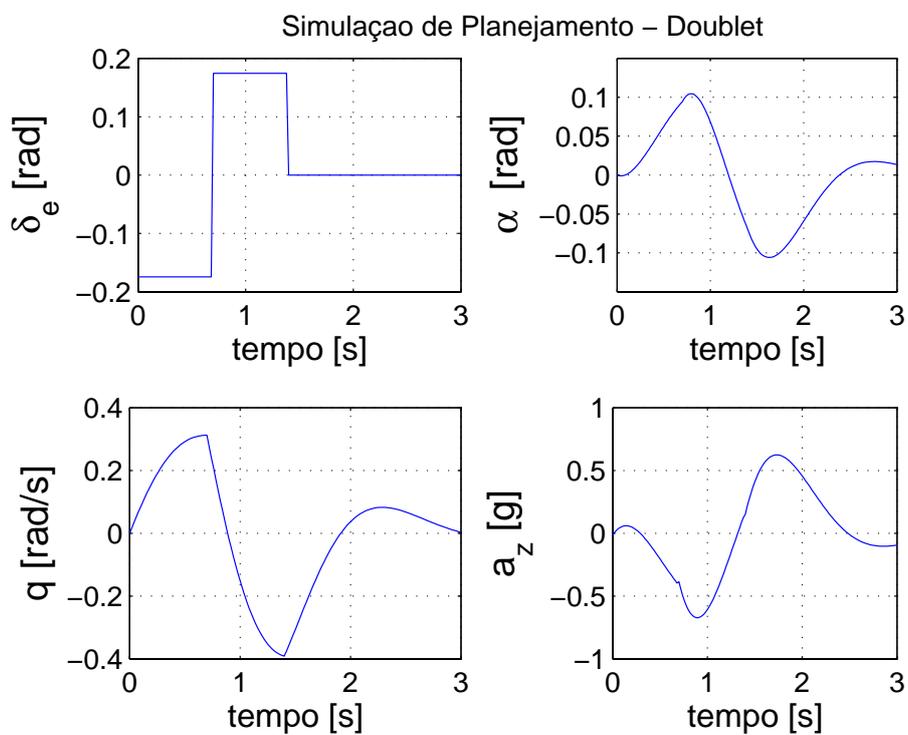


Figura 4.61: Simulação de Planejamento Para o Sinal *Doublet*

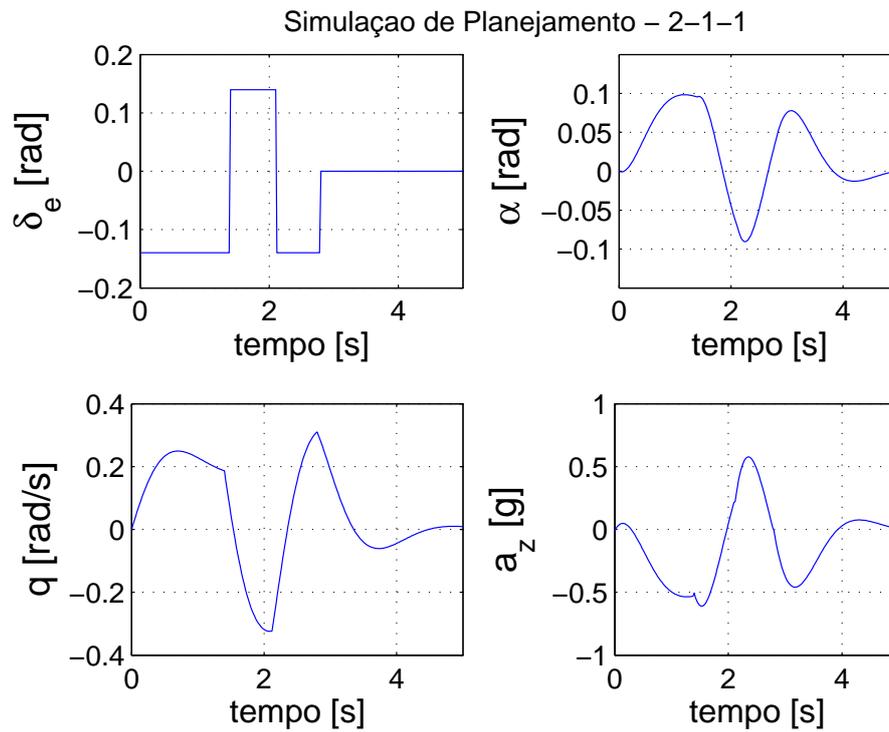


Figura 4.62: Simulação de Planejamento Para o Sinal 2-1-1

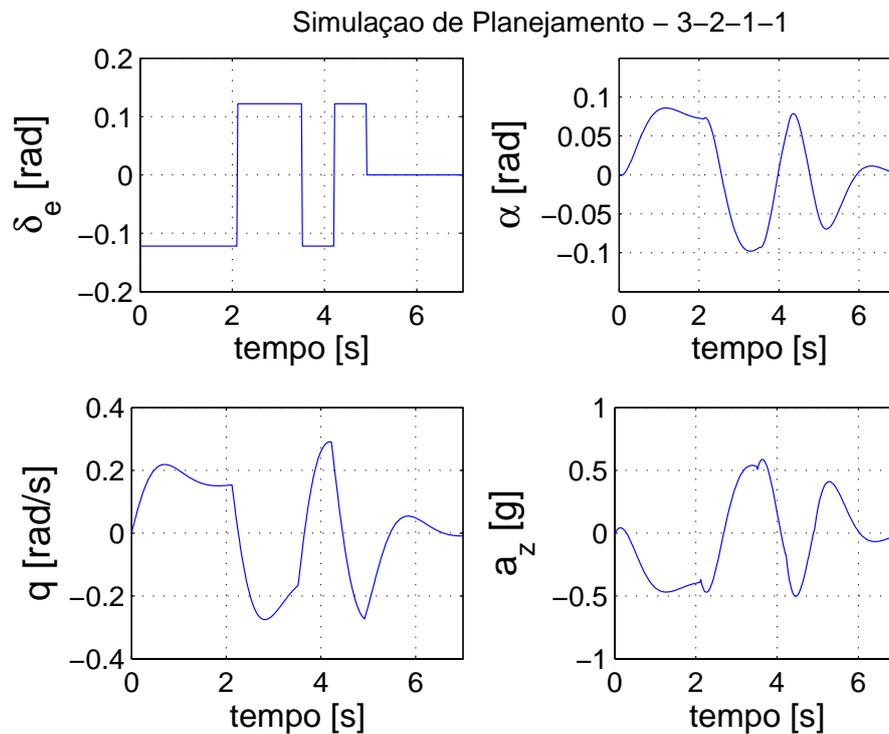


Figura 4.63: Simulação de Planejamento Para o Sinal 3-2-1-1

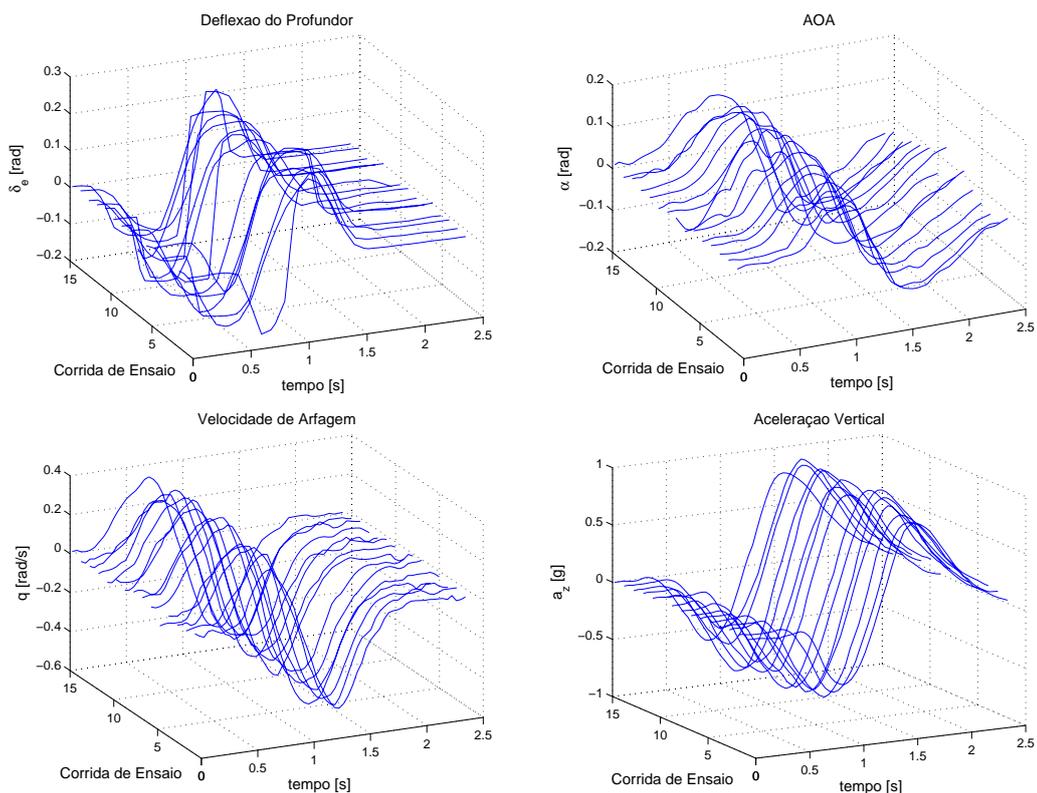


Figura 4.64: Resposta temporal da aeronave para as 15 melhores corridas do *Doublet*

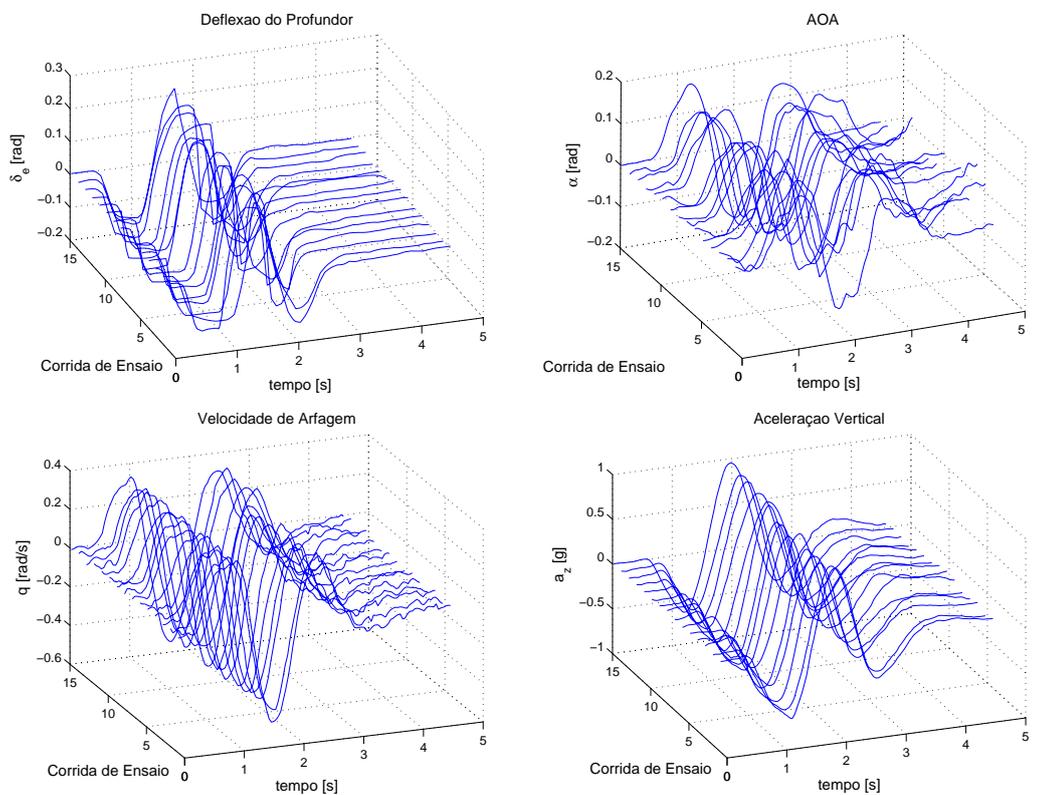


Figura 4.65: Resposta temporal da aeronave para as 15 melhores corridas do 2-1-1

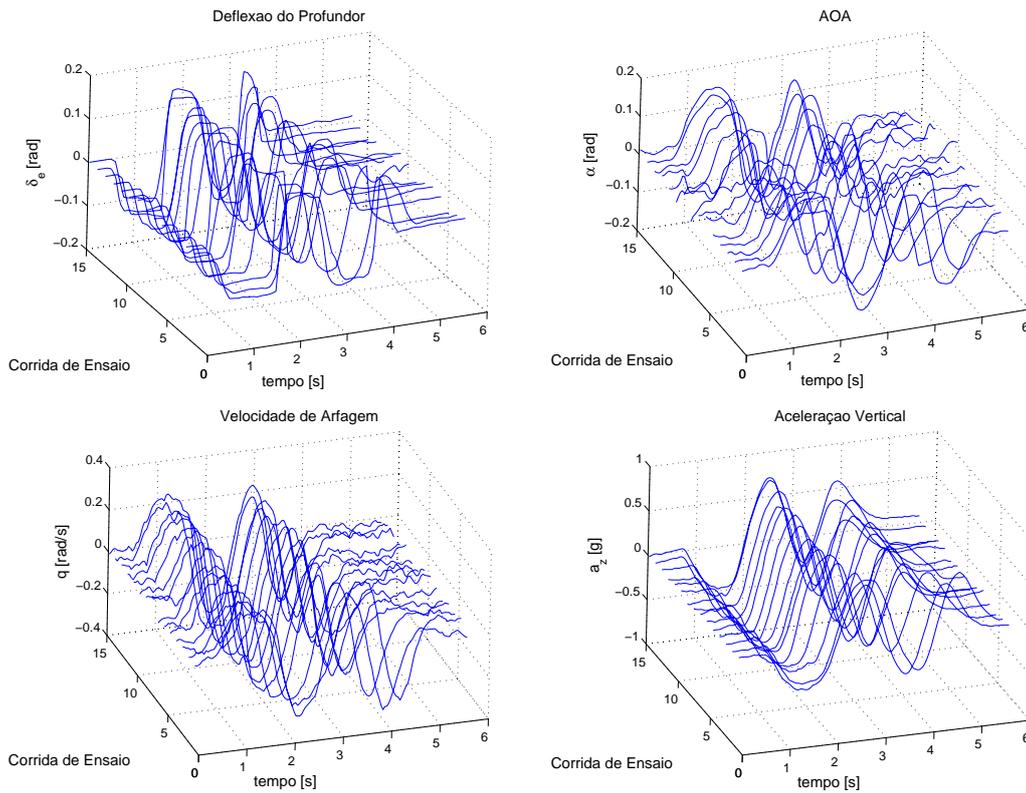


Figura 4.66: Resposta temporal da aeronave para as 15 melhores corridas do 3-2-1-1

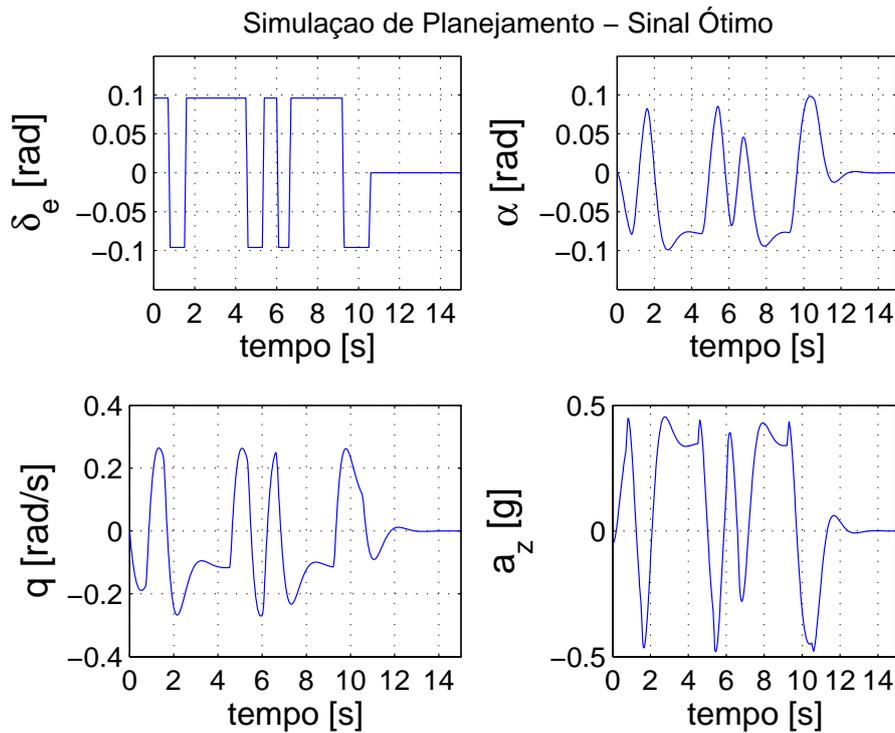


Figura 4.67: Simulação de Planeamento Para o Sinal Otimizado

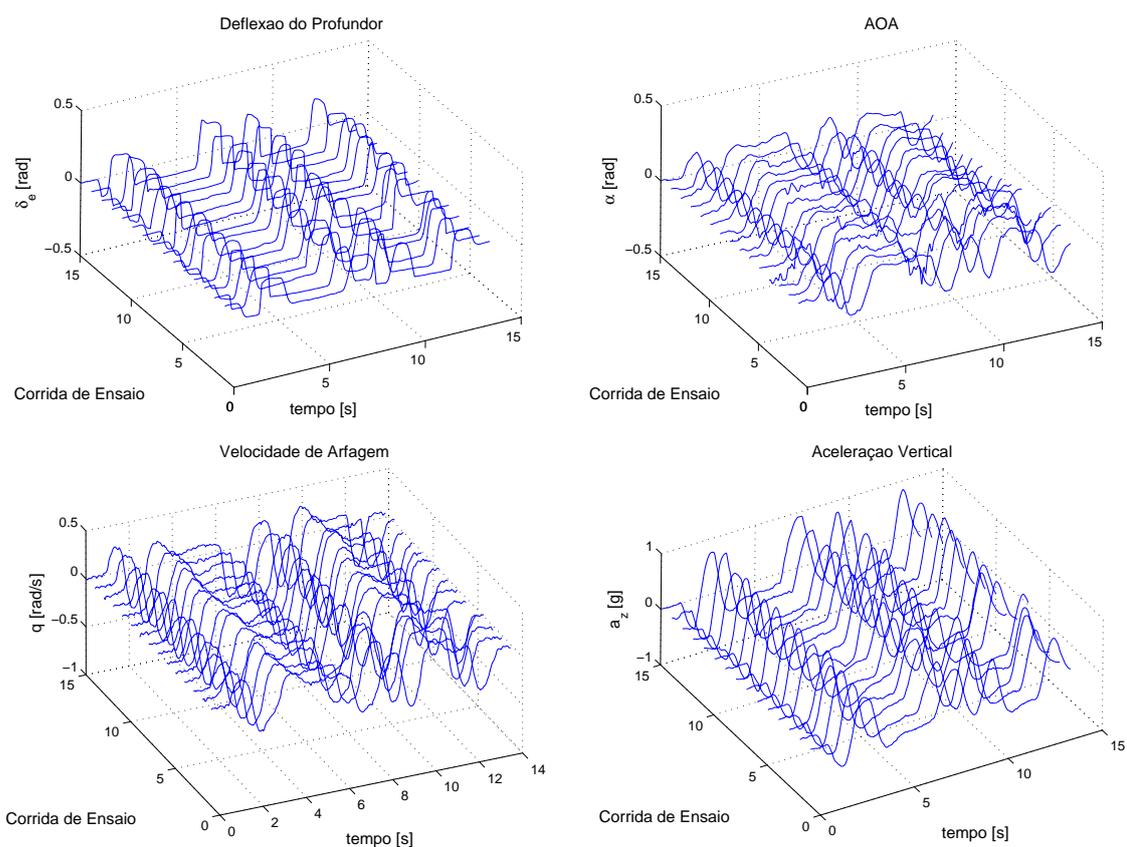


Figura 4.68: Resposta temporal da aeronave para as 15 melhores corridas do sinal otimizado

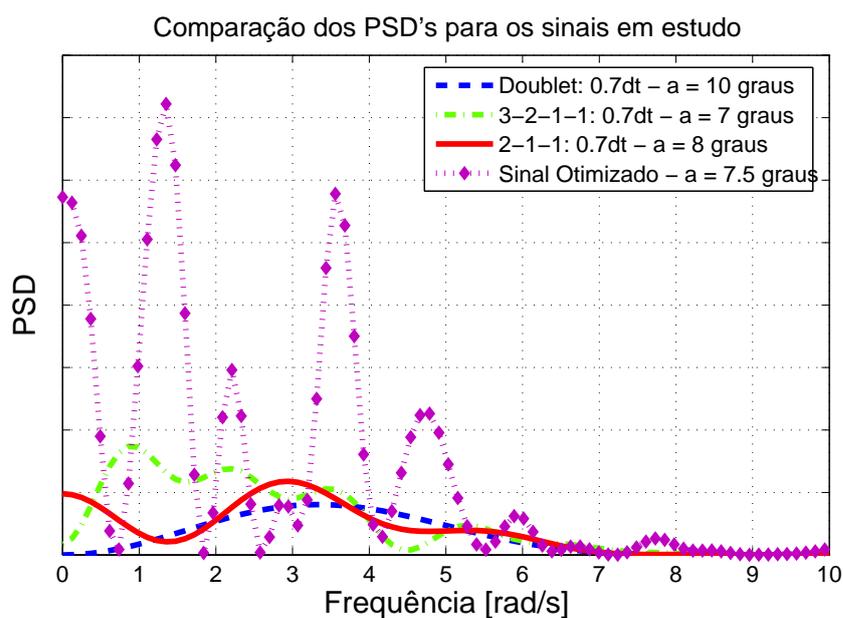


Figura 4.69: Densidade Espectral de Potência dos Sinais Estudados

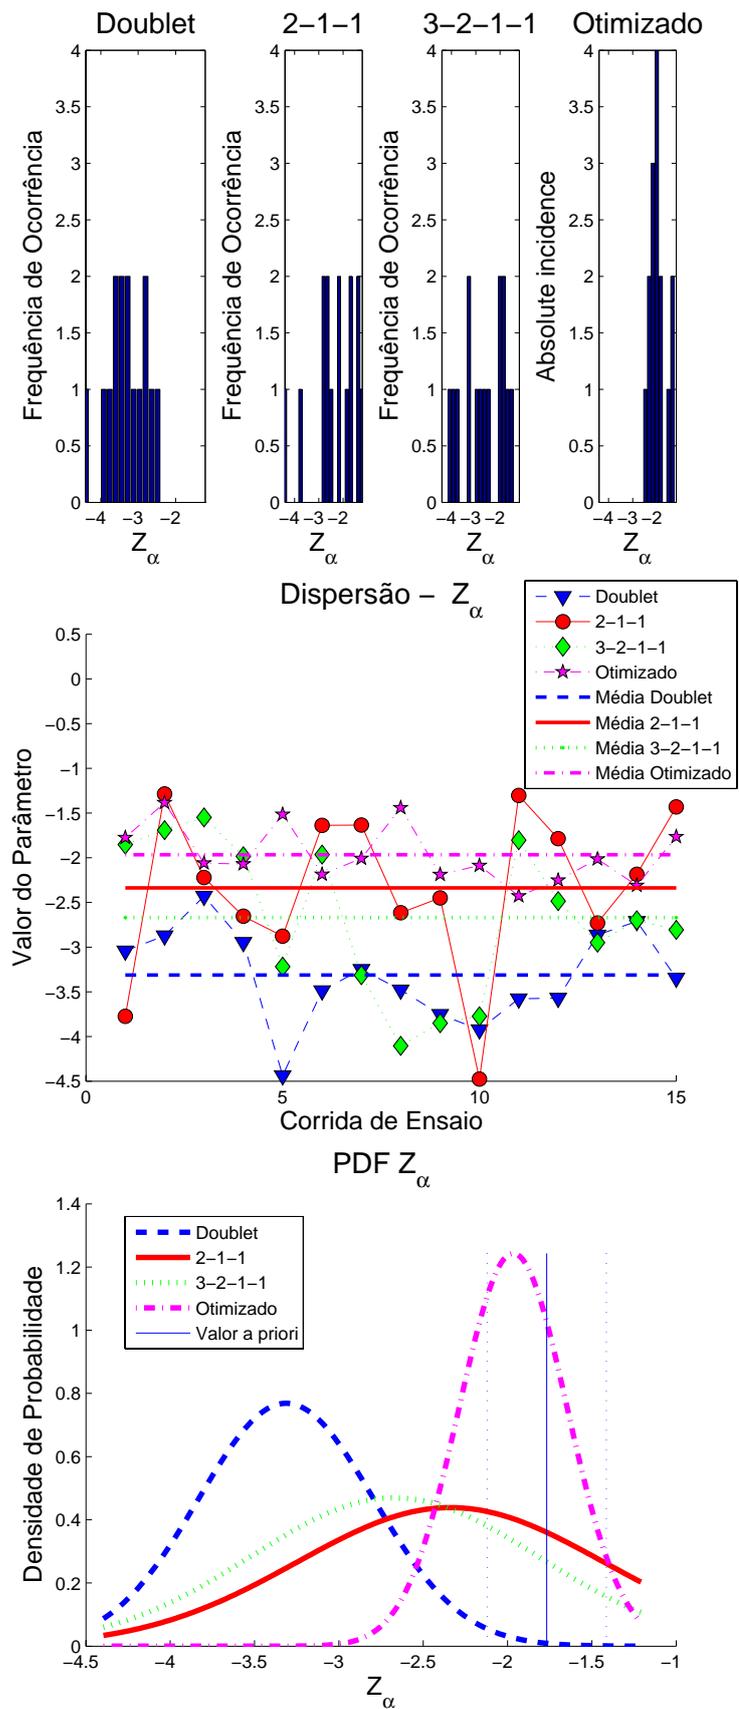


Figura 4.70: Comparação das Manobras - Resultados da estimação de Z_α

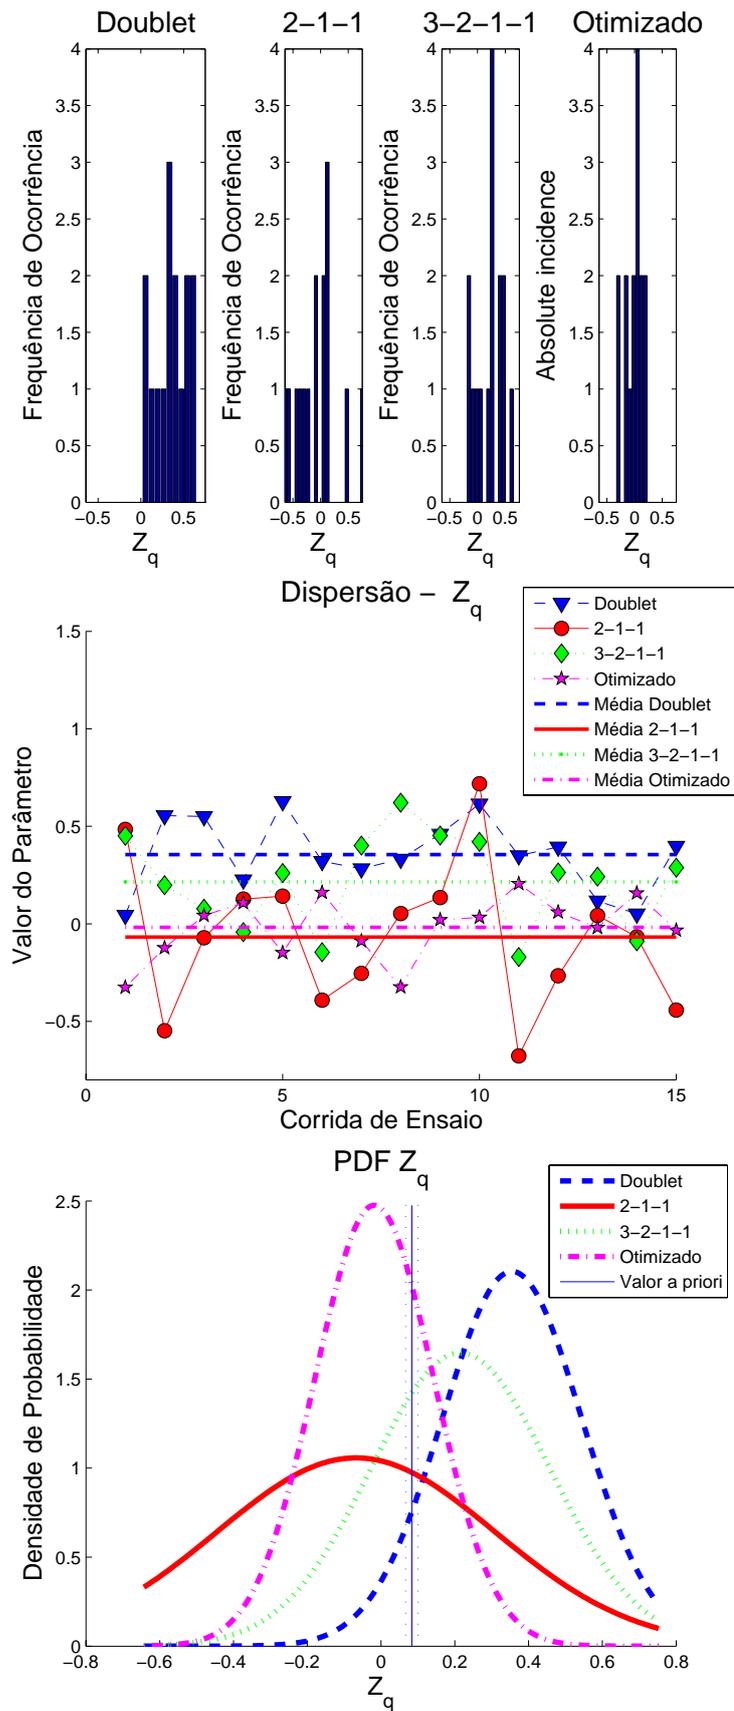


Figura 4.71: Comparação das Manobras - Resultados da estimação de Z_q

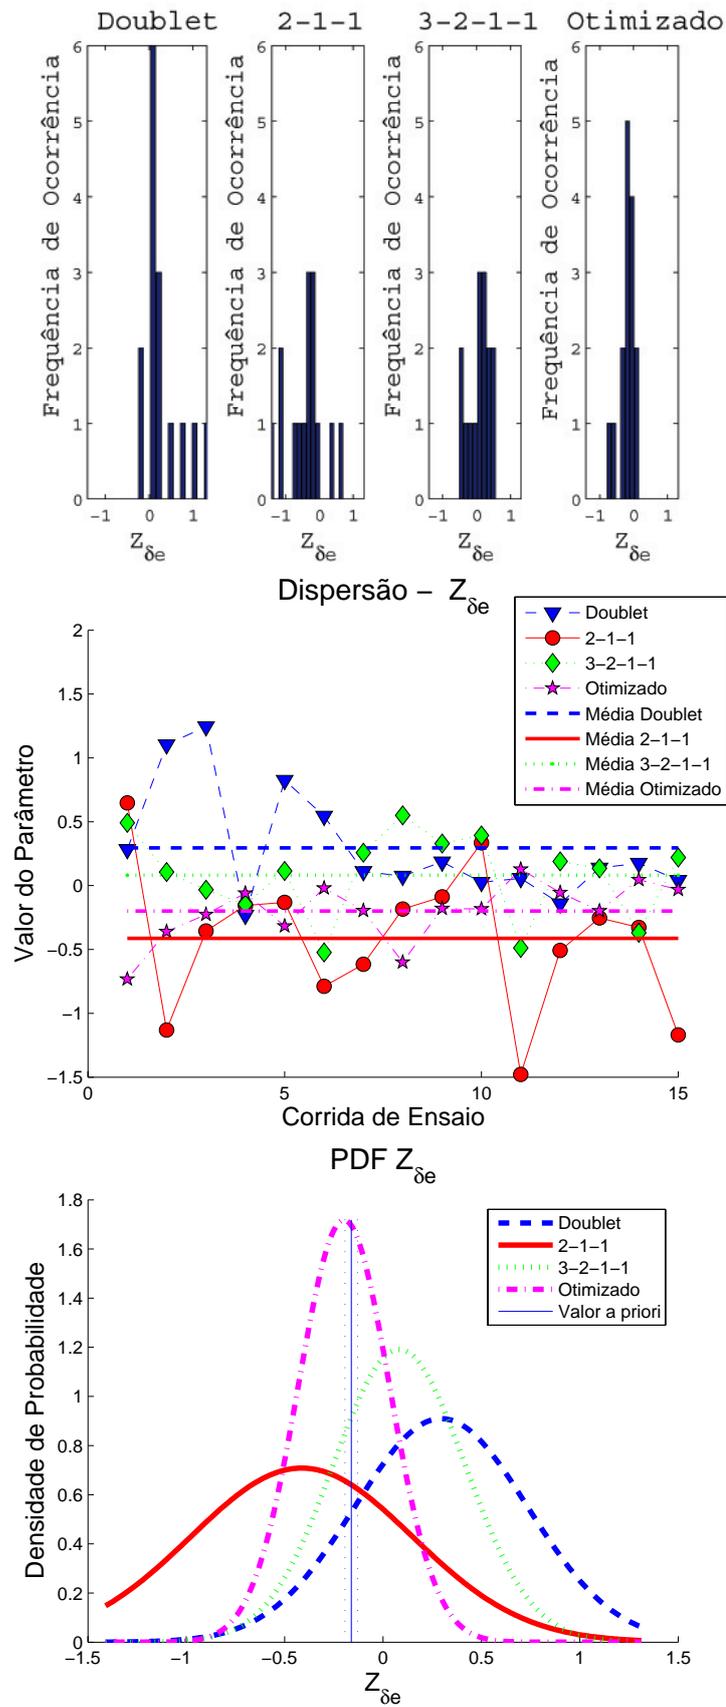


Figura 4.72: Comparação das Manobras - Resultados da estimação de $Z_{\delta e}$

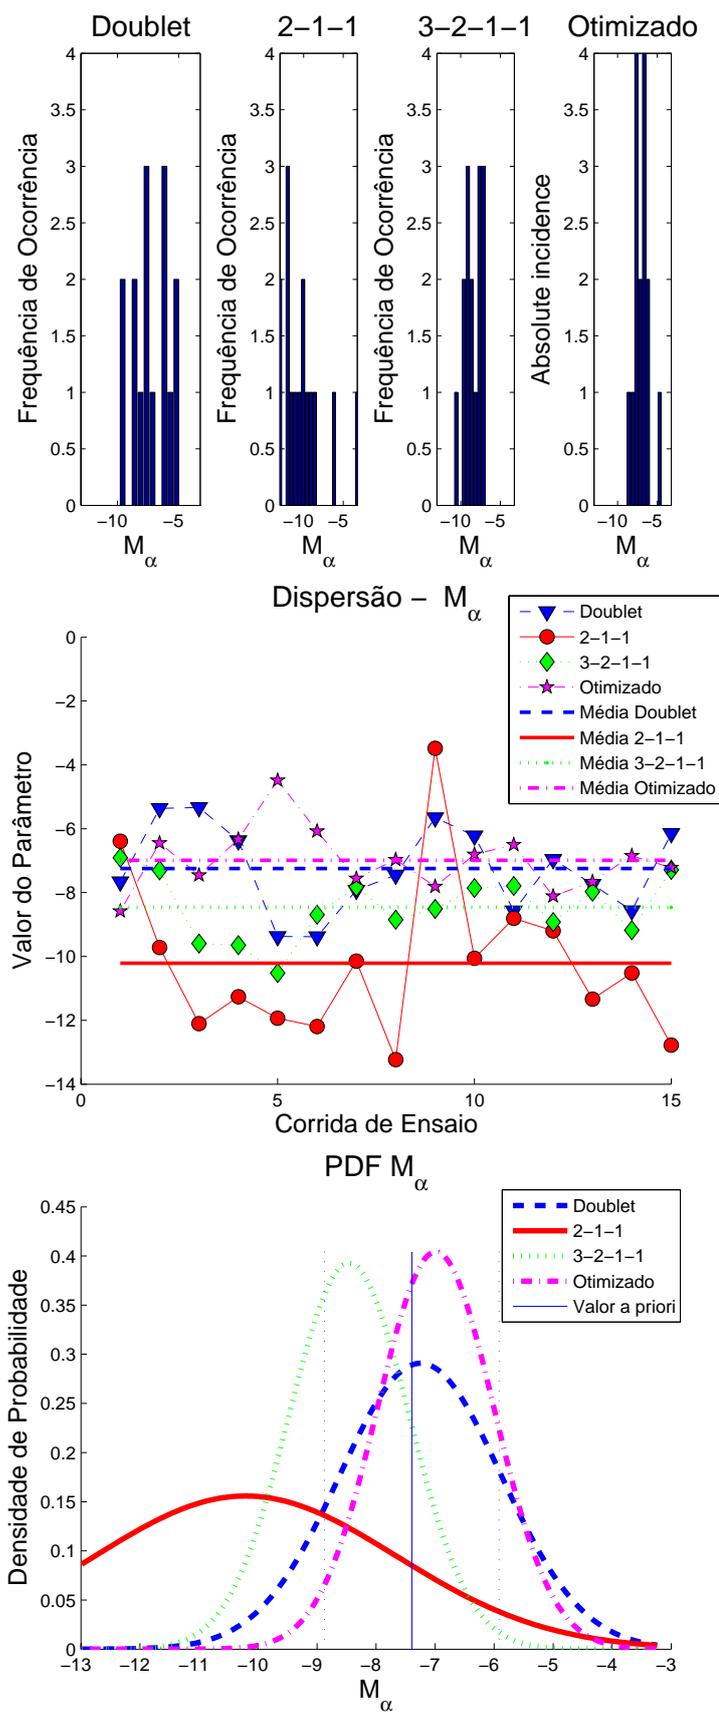


Figura 4.73: Comparação das Manobras - Resultados da estimação de M_α

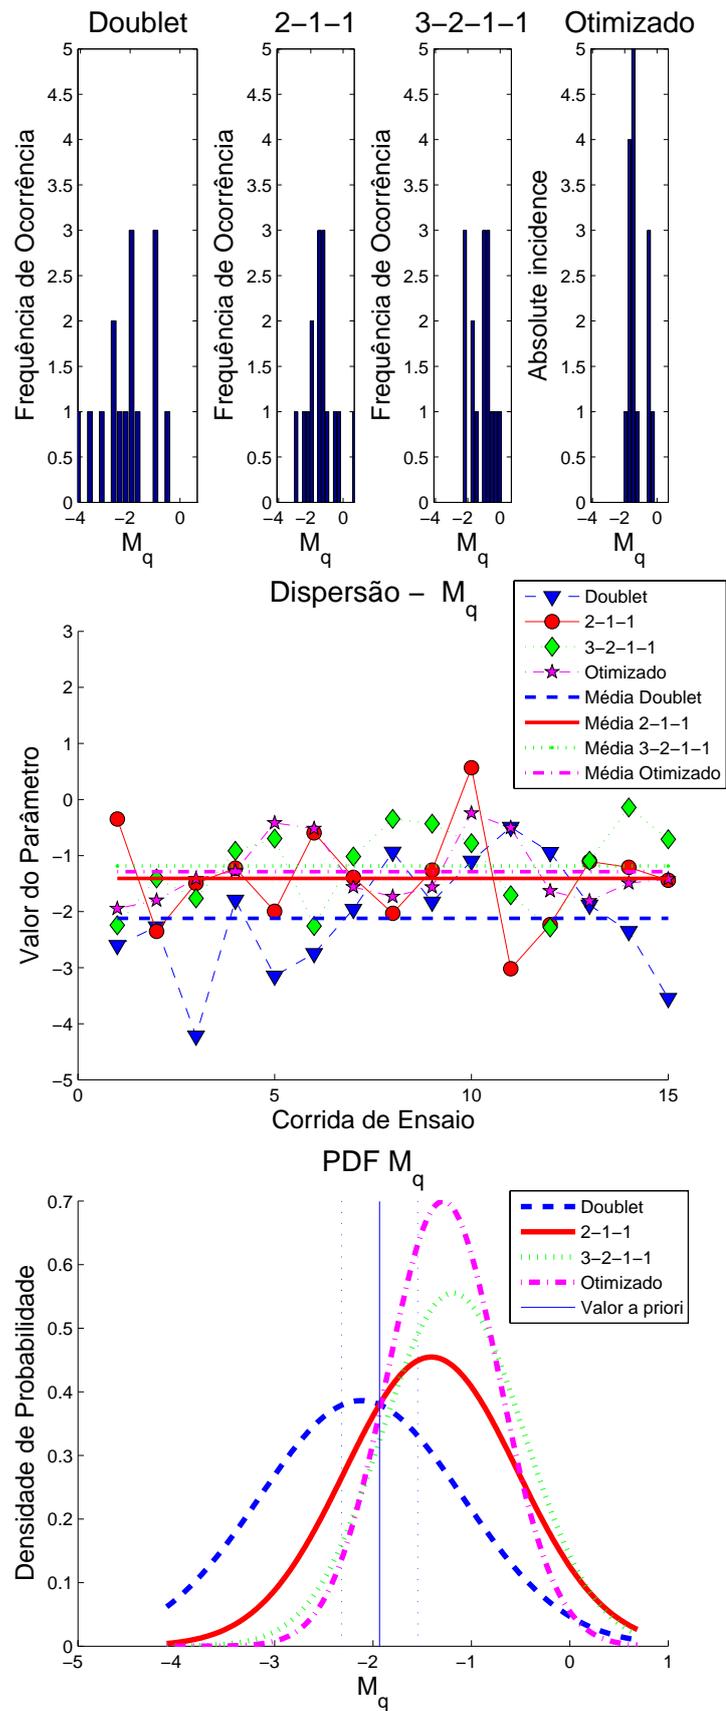


Figura 4.74: Comparação das Manobras - Resultados da estimação de M_q

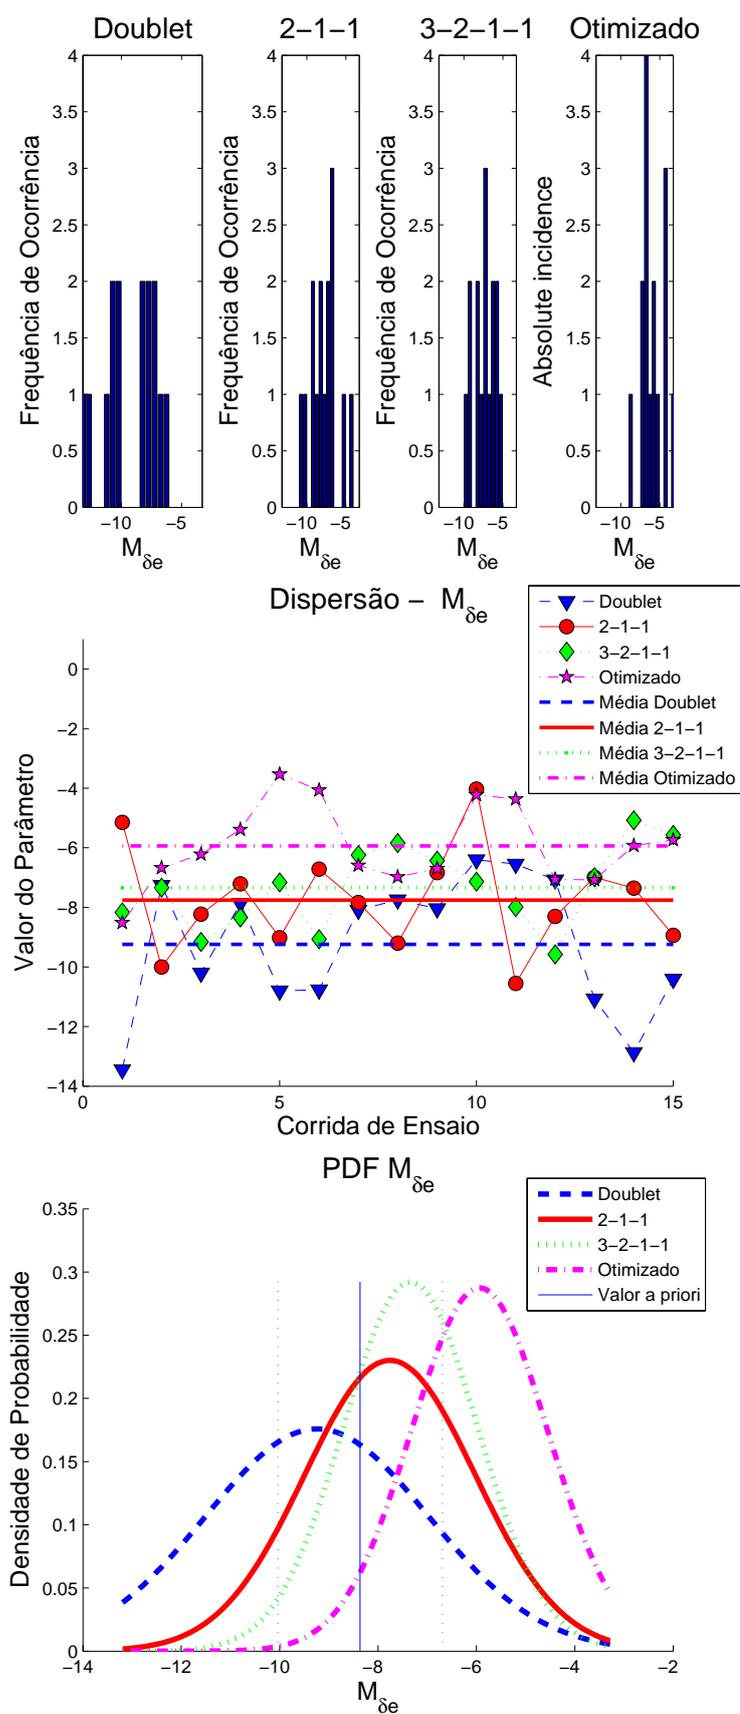


Figura 4.75: Comparação das Manobras - Resultados da estimação de $M_{\delta e}$

Tabela 4.9: Limites inferiores dos desvios-padrão relativos para as sinais de excitação estudados

Parâmetro	Z_α	Z_q	$Z_{\delta e}$	M_α	M_q	$M_{\delta e}$
Sinal	-1.768	0.080	-0.160	-7.394	-1.934	-8.360
Otimizado	8.08%	62.49%	71.45%	5.17%	7.31%	5.07%
3-2-1-1	12.10%	91.25%	110.10%	9.54%	11.16%	7.43%
2-1-1	16.38%	101.65%	95.84%	11.78%	11.39%	10.50%
<i>Doublet</i>	14.03%	89.36%	79.53%	9.58%	12.44%	9.80%

Capítulo 5

Conclusões

Este estudo apresentou algumas técnicas de desenvolvimento, otimização e especificação de manobras de ensaios em vôo para estimação de derivadas de estabilidade e controle de aeronaves. Resultados foram obtidos através da análise de dados sintéticos e de dados reais. A conclusão mais clara que se pode tirar é que o processo de identificação e estimação de derivadas de estabilidade e controle tem se mostrado um problema muito mais abrangente do que apenas a especificação de métodos e algoritmos de identificação. A eficiência deste processo depende fortemente da manobra de ensaio em vôo aplicada. Além disso, a viabilidade da aplicação em problemas práticos é evidenciada na análise da campanha de ensaios em vôo da aeronave Curumim.

Os principais aspectos a respeito dos critérios de otimização dos sinais de excitação foram mostrados no capítulo 2, onde os principais erros de estimação de parâmetros foram abordados em conjunto com os conceitos de limites inferiores de Cramer-Rao e Matriz de Informação de Fisher, os quais foram utilizados para a composição dos critérios de otimização. Foi apresentada uma técnica de correção do cálculo das incertezas levando em consideração resíduos coloridos nas variáveis de medida, o que viabilizou o desenvolvimento de manobras de maneira mais realística. Em um segundo momento foi formulado o problema de otimização dos sinais de excitação, apresentando também alguns aspectos do algoritmo genético utilizado para a solução. Por fim, foram apresentados alguns resultados que viabilizaram a comparação entre os resultados obtidos através dos algoritmos propostos neste estudo e resultados anteriores.

Os seguintes aspectos se tornaram mais relevantes:

1. Quanto à implementação de restrições de ordem prática, foi verificada a grande importância do acesso direto às restrições que dizem respeito às variáveis de entrada e de saída das dinâmicas de vôo de aeronaves. Estas restrições permitem, de forma eficiente, a especificação de manobras de ensaios em vôo otimizados que respeitam os limites operacionais do envelope de vôo, significando forte vantagem quanto à segurança do vôo.
2. Quanto à preocupação com implementação prática, ficou clara que as técnicas abordadas nestes estudo permitem o desenvolvimento de sinais de excitação otimizados passíveis de serem implementados manualmente pelo piloto.
3. Quanto à otimização multi-objetivo e no mínimo tempo, as principais conclusões dizem respeito a grande vantagem de utilizar objetivos explícitos para os níveis de incerteza das estimativas paramétricas para que as manobras de ensaios possam ser otimizadas em função do tempo de execução. Os resultados obtidos levam a crer que os sinais otimizados para o mínimo tempo podem aumentar a produtividade e eficiência das campanhas de ensaio em vôo para estimação paramétrica, principalmente quando é considerada a necessidade de ensaios em múltiplos pontos do envelope de vôo.
4. Quanto à consideração de resíduos coloridos, corroborando com o disposto acima, é clara a sua necessidade, pois só assim o planejamento das manobras de ensaios em vôo poderá ter acesso realista aos objetivos estabelecidos no procedimento de otimização, possibilitando adequada avaliação dos sinais resultantes.
5. Quanto ao algoritmo genético de otimização, verifica-se que suas soluções tenderam a ser globais, principalmente quando os resultados são comparados com resultados anteriores obtidos através de programação dinâmica. Este algoritmo possibilitou de forma eficiente o acesso às diversas peculiaridades práticas que envolvem a otimização de sinais de excitação para manobras de ensaios em vôo para estimação de parâmetros, com especial ênfase para restrições operacionais e de implementabilidade.

A principal contribuição deste trabalho é a sua formulação prática, realista, e de direta aplicação para o planejamento e execução de campanhas de ensaios em vôo para estimação

de parâmetros. Ficou evidenciada a sua necessidade, a sua viabilidade e, principalmente, as vantagens de sua aplicação. Sejam diretas, através da melhora nos níveis de incerteza associados aos procedimentos de estimação de parâmetros e a diminuição do tempo de execução das manobras, sejam indiretas, através da capacidade de apoiar o planejamento das campanhas, principalmente, no que tange à segurança de vôo e aos procedimentos de minimização de riscos.

Para futuros trabalhos, são identificados diversos tópicos, incluindo:

1. O estudo mais aprofundado a respeito das implementações manuais através do piloto dos sinais otimizados, enfocando a aceitabilidade dos sinais otimizados em comparação com sinais convencionais.
2. A formulação de problemas de otimização que envolvam parâmetros dos sistemas de aquisição de dados, tais como: fatores de escala, erros sistemáticos, atrasos de transporte. Essa abordagem seria de fundamental importância para o perfeito desenvolvimento das técnicas de calibração de sensores via reconstrução de trajetória de vôo.
3. A formulação de problemas envolvendo outros critérios de otimização, tais como: índice de correlação entre parâmetros, uma vez que estas informações são de fácil acesso também através da matriz de informação.
4. O estudo dos efeitos da robustez das técnicas apresentadas neste trabalho em relação aos modelos de conhecimento a priori.
5. O desenvolvimento de sinais de excitação para sistemas dinâmicos em malha fechada e para sistemas instáveis.
6. A consideração de modelos dinâmicos não-lineares, que permitam realizar o planejamento do vôo de maneira mais completa e adequada.
7. A integração de outras técnicas naturais de otimização com o algoritmo genético, tais como, colônia de pássaros, colônia de peixes, colônia de formigas. Estes algoritmos em conjunto podem fornecer soluções mais eficientes, principalmente no que tange à busca global e ao custo computacional.

8. A implementação de técnicas de diferenciação automática, as quais permitem maior eficiência dos algoritmos que necessitam de diferenciação numérica das equações do movimento de aeronaves.
9. A implementação do algoritmo de otimização de manobras em conjunto com o algoritmo de identificação de sistemas em tempo real, englobando métodos de erro de saída e de erro filtrado, possibilitando a realização de abordagens em vôo, principalmente com o intuito de aumentar a produtividade das campanhas de ensaios.

Referências Bibliográficas

BALAKRISHNAN, A. V. **Communication Theory**. New York, NY: McGraw-Hill Book Co., 1968.

BENDAT, J. S.; PIERSON, A. G. **Random Data Analysis and Measurement Procedures**. Third edition. New York, NY: Wiley Inter-Science, 2000.

BLAKELOCK, J. H. **Automatic Control of Aircraft and Missiles**. New York, NY: John Wiley and Sons, Inc., 1965.

BRYAN, G. H. **Stability in Aviation**. London: McMillan, 1911.

CHEN, R. T. N. Input design for aircraft parameter identification: Using time-optimal control formulation. **AGARD-CP-172**, 1975.

CRAMÉR, H. **Mathematical Methods of Statistics**. Princeton: Princeton University Press, 1946.

CROSSBOW. **AHRS400 Series User's Manual**. San Jose, CA.

CURVO, M. Estimation of aircraft aerodynamic derivatives using extended kalman filter. **Journal of the Brazilian Society of Mechanical Sciences**, v. 22, n. 2, p. 133–148, 2000. ISSN 0100-7386.

DARWIN, C. **The Origin of Species**. London: John Murray, 1859.

DUKE, E. L.; ANTONIEWICZ, R. F.; KRAMBEER, K. D. **Derivation and Definition of a Linear Aircraft Model**. Edwards, Calif., USA, 1988.

ETKIN, B. **Dynamics of Flight: Stability and Control**. New York: John Wiley and Sons, Inc., 1965.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Reading, MA: Addison-Wesley Longman, Inc., 1989.

GOODWIN, G. C.; PAYNE, R. L. **Dynamic System Identification: Experiment Design and Data Analysis**. New York: Academic Press Inc., 1977.

GREENBERG, H. **A Survey of Methods For Determining Stability Parameters of an Airplane From Dynamic Flight Measurements**. Langley, 1951.

GUPTA, N. K.; JR., W. E. H. **Input Design for Identification of Aircraft Stability and Control Derivatives**. Palo Alto, Calif., USA, 1975.

HOLLAND, J. H. **Adaption in Nature and Artificial Systems**, Ann Arbor. Michigan: University of Michigan, 1975.

ILIFF, K. W.; MAINE, R. E. **Practical Aspects of Using a Maximum Likelihood Estimation Method to Extract Stability and Control Derivatives from Flight Data**. Edwards, Calif., USA, 1976.

ILIFF, K. W.; MAINE, R. E. Further observations on maximum likelihood estimates of stability and control characteristics obtained from flight data. In: **Atmospheric Flight Mechanics Conference**. Hollywood, Fla.: AIAA, 1977. p. 100–112.

ILIFF, K. W.; MAINE, R. E.; MONTGOMERY, T. D. **Important Factors in the Maximum Likelihood Analysis of Flight Test Maneuvers**. Edward, Calif., USA, April 1979.

ILIFF, K. W.; TAYLOR, L. W. **Determination of Stability Derivatives From Flight Data Using a Newton-Raphson Minimization Technique**. Edwards, Calif., 1972.

JATEGAONKAR, R.; PLAETSCHKE, E. **Maximum Likelihood Parameter Estimation from Flight Test Data for General Non-Linear Systems**. Braunschweig, 1983.

JATEGAONKAR, R.; PLAETSCHKE, E. **Maximum Likelihood Estimation of Parameters in Linear Systems with Process and Measurement Noise**. Braunschweig, 1987.

JATEGAONKAR, R. V. **ESTIMA A Modular and Integrated Software Tool for Parameter Estimation and Simulation of Dynamics Systems - User's Manual, Version 1.0.** Braunschweig, 2001.

JATEGAONKER, R. V.; PLAESTSCHKE, E. Algorithms for aircraft estimation accounting for process and measurement noise. **Journal of Aircraft**, v. 26, n. 4, p. 360–372, 1989. ISSN 0021-8669.

LJUNG, L. **System Identification: Theory for the User.** Englewood Cliffs, NJ: Prentice-Hall, Inc., 1987.

MACIEL, B. C. de O.; GOES, L. C. S.; VASCONCELOS, L. J. H. Identificação paramétrica das derivadas de estabilidade e controle do movimento longitudinal da aeronave xavante at-26. In: **XV Congresso Brasileiro de Automática.** Gramado, RS: SBA, 2004.

MAINE, R. E.; ILIFF, K. W. **The Theory and Practice of Estimating the Accuracy of Dynamic Flight-Determined Coefficients.** Edwards, Calif., USA, July 1981.

MAINE, R. E.; ILIFF, K. W. Use of cramer-rao bounds on flight data with colored residuals. **Journal of Guidance and Control**, v. 4, n. 2, p. 207–213, 1981. ISSN 0731-5090.

MAINE, R. E.; ILIFF, K. W. **Identification of Dynamic System: Theory and Formulation.** Edwards, Calif., USA, February 1985.

MAINE, R. E.; ILIFF, K. W. **Application of Parameter Estimation to Aircraft Stability and Control: The Output-Error Approach.** Edwards, Calif., USA, June 1986.

MARCHAND, M. **Untersuchung der Bestimmbarkeit der Flugmechanischen Derivative des CCV-Versuchsträgers F-104 G.** Braunschweig, 1977.

MCRUER, D.; ASHKENAS, I.; GRAHAM, D. **Aircraft Dynamics and Automatic Control.** Princeton: Princeton University Press, 1973.

MEHRA, R. K. Optimal input signals for parameter estimation in dynamic systems - survey and new results. **IEEE Transactions on Automatic Control**, AC-19, n. 6, p. 753–768, 1974. ISSN 0018-9286.

MEHRA, R. K. Optimal inputs for linear system identification. **IEEE Transactions on Automatic Control**, AC-19, n. 3, p. 192–200, June 1974. ISSN 0018-9286.

MENDONÇA, C. B. de; HEMERLY, E. M.; GOES, L. C. S. Noise influence on aircraft state estimation using output error and extended kalman filter approach. In: **4.o Congresso Temático de Dinâmica, Controle e Aplicações - DINCON**. Bauru, SP: SBMAC, 2005.

MORELLI, E. A. **Practical Input Optimization for Aircraft Parameter Estimation Experiments**. Tese (Doutorado) — The George Washington University, Hampton, Virginia, 1990.

MORELLI, E. A. Flight test of optimal inputs and comparison to conventional inputs. **Journal of Aircraft**, Hampton, Virginia, USA, v. 36, n. 2, p. 389–397, 1997. ISSN 0021-8669.

MORELLI, E. A. Advances in experiment design for high performance aircraft. In: **RTO Meeting Proceedings on System Identification for Integrated Aircraft Development and Flight Testing**. Hampton, Virginia: RTO, 1998. p. 16.1–16.13.

MORELLI, E. A.; KLEIN, V. **Determining the Accuracy of Maximum Likelihood Parameter Estimates With Colored Residuals**. Hampton, Virginia, USA, 1994.

MORELLI, E. A.; KLEIN, V. Application of system identification to aircraft at nasa langley research center. **Journal of Aircraft**, v. 42, n. 1, p. 12–25, 2005. ISSN 0021-8669.

MULDER, J. A.; BREEMAN, J. H. **Identification of Dynamic Systems - Applications to Aircraft Part 2: Nonlinear Analysis and Manoeuvre Design**. France, May 1994.

NELSON, R. C. **Flight Stability and Automatic Control**. New York: McGraw-Hill, Inc., 1989.

NETO, N. S. B.; GOES, L. C. S. Optimization of flight test maneuvers for aerodynamic derivatives inverse problem. In: **6.o World Congress of Structural and Multidisciplinary Optimization**. Rio de Janeiro, RJ: International Society for Structural and Multidisciplinary Optimization, 2005.

- NORTON, F. H. **The Measurement of the Damping in Roll on a JN4h in FLight**. Langley, 1923.
- NORTON, F. H. **A Study of Longitudinal Dynamic Stability in Flight**. Langley, 1923.
- NORTON, F. H.; BROWN, W. G. **Complete Study of Longitudinal Oscillation of a VE-7 Airplane**. Langley, 1923.
- NORTON, F. H.; CARROLL, T. **The Vertical, Longitudinal, and Lateral Accelerations Experienced by an S. E. 5A Air-plane While Maneuvering**. Langley, 1923.
- OLIVEIRA, P. H. I. A. de. **Manual de Operação CEA205 CB.9 Curumim**. Belo Horizonte - MG, 2004.
- ROSKAM, J. **Airplane Flight Dynamics and Automatic Flight Controls - Part I**. Lawrence, KS: Roskam Aviation and Engineering Corporation, 1979.
- SHINBROT, M. **A Least Squares Curve Fitting Method With Applications to the Calculation os Stability Coefficients from Transient-Response Data**. Washington, DC, 1951.
- SHINBROT, M. **On the Analysis of Linear and Nonlinear Dynamic Systems from Transient Response Data**. Washington, DC, 1954.
- STEPNER, D. E.; MEHRA, R. K. **Maximum Likelihood Identification and Optimal Input Design for Identifying Aircraft Stability and Control Derivatives**. Palo Alto, Calif., USA, 1973.
- STEVENS, B. L.; LEWIS, F. L. **Aircraft Control and Simulation**. New York: John Wiley and Sons, Inc., 1992.
- VASCONCELOS, L. J. de H. **Identificação Paramétrica de Derivadas de Estabilidade e Controle Longitudinais da Aeronave Xavante AT-26: uma aplicação do método da verossimilhança**. 2002. 189 f. Dissertação (Mestrado em Engenharia Aeronáutica e Mecânica) — Instituto Tecnológico de Aeronáutica, São José dos Campos - SP - Brasil, 2002.

WANG, K. C.; ILIFF, K. W. Retrospective and recent examples of aircraft parameter identification at nasa dryden flight research center. **Journal of Aircraft**, v. 41, n. 4, p. 752764, 2004. ISSN 0021-8669.

Apêndice A

Modelos para as Equações de Estado e de Saída

A.1 Introdução

Os modelos matemáticos utilizados para estimação paramétrica envolvem a dinâmica de vôo das aeronaves e as equações de observação.

A formulação das equações que regem a dinâmica de vôo aeronaves é bem conhecida na literatura. Basicamente, é aplicada a Segunda Lei de Newton para que um conjunto de equações não lineares de seis graus de liberdade seja deduzido. Este conjunto de equações é suficiente para as análises de estabilidade e controle de aeronaves e para os procedimentos de estimação paramétrica.

Nas equações da dinâmica de aeronaves, aparecem termos que levam em consideração as forças e momentos externos que agem sobre o processo. Estas forças e momentos podem ser divididos em três famílias: gravitacionais, propulsivas, e aerodinâmicas. As forças e momentos aerodinâmicos são de particular interesse para estimação paramétrica. A modelagem dos mesmos é feita através dos coeficientes aerodinâmicos de força e de momento. Estes coeficientes são compostos pelas derivadas de estabilidade e controle, as quais são o objeto da estimação paramétrica no que tange a dinâmica de aeronaves.

As equações de observação são a ligação entre os parâmetros aerodinâmicos a serem estimados e a resposta temporal das aeronaves. Normalmente, o que se busca é a mini-

mização do erro entre a resposta lida da aeronave em vôo e as variáveis de saída dos modelos. Esta minimização deve ser feita em função dos parâmetros de interesse para o procedimento de estimação.

Neste capítulo, serão apresentadas as equações de estado para o movimento de seis graus de liberdade de aeronaves. O modelo aerodinâmico considerado será discutido quanto ao problema de estimação paramétrica. Em seguida, serão aplicadas simplificações, as quais possibilitam o desacoplamento do movimento completo em movimento longitudinal e movimento látero-direcional, bem como serão apresentados os modelos linearizados que serão utilizados neste estudo para o desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica.

As principais características das equações de observação serão mostradas. Algumas peculiaridades do sistema de aquisição de dados utilizado nos ensaios em vôo também serão discutidas. O objetivo é deixar clara a importância de uma adequada modelagem das equações de saída para levar em consideração erros sistemáticos e fatores de escala dos sensores.

A.2 Equações de Estado

As equações do movimento de uma aeronave podem ser derivadas da Segunda Lei de Newton, que demonstra que a soma das forças externas agindo sobre um corpo deve ser igual à taxa de variação temporal do seu momento linear, e a soma dos momentos externos agindo sobre o corpo deve ser igual à taxa de variação temporal do seu momento angular. No caso de aeronaves, é frequente na literatura que as seguintes hipóteses sejam assumidas:

- **A massa da aeronave é constante:** apesar de haver realmente variação da massa, principalmente pelo consumo de combustível, o período temporal assumido para a análise de estabilidade e controle de aeronaves é curto o bastante para que esta hipótese seja viável;
- **A aeronave é um corpo rígido:** ao desconsiderar os efeitos aeroelásticos, este trabalho assume que o movimento da aeronave é inteiramente regido pela translação

do centro de gravidade da aeronave e pela rotação em torno do mesmo;

- **A terra é o referencial inercial e a atmosfera é fixa em relação a ela:** embora esta hipótese não seja viável para o estudo de movimentos de longa duração, para a aplicação das técnicas de identificação de sistemas, controle e estabilidade de aeronaves a mesma pode ser aplicada, uma vez que os análises se limitam a curtos intervalos de tempo;
- **O plano formado entre o eixo X e o eixo Z da aeronave é o seu próprio plano de simetria:** os produtos de inércia J_{xy} e J_{yz} , portanto, são iguais a zero;

A dedução completa das equações da dinâmica de aeronaves é feita por (STEVENS; LEWIS, 1992), (BLAKELOCK, 1965), (NELSON, 1989) e (DUKE; ANTONIEWICZ; KRAMBEER, 1988), entre outros autores. Neste trabalho, entretanto, a mesma não será feita, uma vez que este não é o objeto desta dissertação.

Em um primeiro momento serão mostrados os eixos de referência utilizados neste estudo. Logo após serão abordadas as equações de estado para o movimento completo. Partindo delas, serão feitas simplificações para se chegar a modelos desacoplados, os quais podem ser utilizados para estimação paramétrica. Por fim, serão mostrados os modelos dinâmicos que serão utilizados neste estudo para demonstrar as técnicas de desenvolvimento e otimização de manobras de ensaios em vôo e para estimação paramétrica.

A.2.1 Sistemas de Referência e Orientação da Aeronave em Relação ao Referencial Inercial

Para o entendimento das equações de estado utilizadas neste trabalho, será necessária a abordagem de três sistemas de referência. Os primeiros dois, dizem respeito à orientação da aeronave em relação a terra. Um terceiro sistema de eixos de referência é utilizado para descrever a direção do vento relativo em relação ao sistema fixo no corpo.

Para a determinação da atitude da aeronave em relação a terra são utilizados um sistema de eixos fixo ao corpo e outro sistema de eixos como referência inercial. Ambos são representados por vetores ortogonais ao longo das direções x , y e z . O sistema de referência inercial é solidário à terra e seus vetores apontam para o norte, para o leste e

para baixo, respectivamente. O sistema fixo ao corpo, chamado neste estudo de sistema do corpo, possui seus vetores apontando para a frente da aeronave, X_b , para a asa direita, Y_b , e para baixo, Z_b . A origem deste sistema é o centro de gravidade da aeronave.

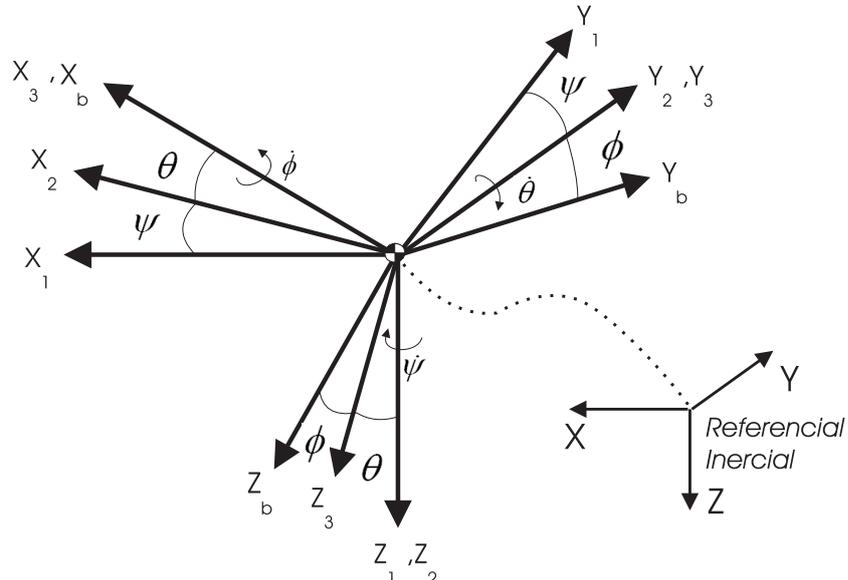


Figura A.1: Orientação do Eixo do Corpo em Relação ao Referencial Inercial

Conforme pode ser visto na figura A.1, a orientação da aeronave em relação ao referencial inercial é descrita por três rotações. A primeira é do ângulo ψ em torno do eixo Z_1 , a segunda é do ângulo θ em torno do eixo Y_2 , a terceira rotação é do ângulo ϕ em torno do eixo X_3 , o qual coincide com o eixo X_b .

Os três ângulos citados acima são chamadas de ângulos de Euler. As equações cinemáticas que os descrevem são obtidas através da projeção de $\dot{\psi}$, $\dot{\theta}$ e $\dot{\phi}$ nos eixos X_1 , Y_1 e Z_1 , o que denota a velocidade angular do eixo do corpo em relação ao referencial inercial.

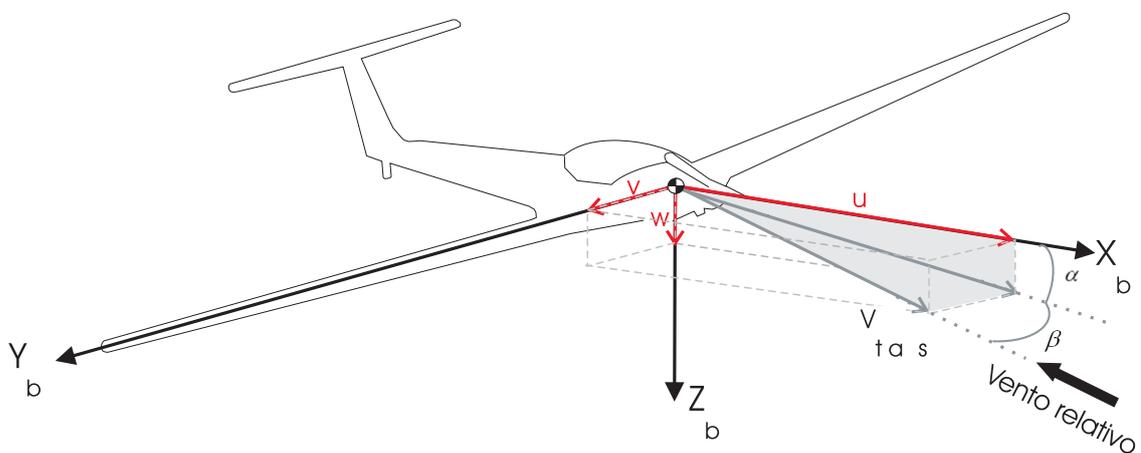


Figura A.2: Eixo do Vento

O terceiro sistema, chamado neste estudo como sistema do vento, descreve a direção em que o vento relativo atinge o sistema do corpo, figura A.2. Esta direção é dada pelo ângulo de ataque, α , e pelo ângulo de derrapagem, β .

Como pode ser visto, a velocidade verdadeira, a qual aponta para a trajetória do vôo, é dada por:

$$V_{tas} = \sqrt{u^2 + v^2 + w^2} \quad (\text{A.1})$$

Além disso:

$$\alpha = \tan^{-1} \left(\frac{w}{u} \right) \quad (\text{A.2})$$

$$\beta = \sin^{-1} \left(\frac{v}{V_{tas}} \right) \quad (\text{A.3})$$

Tem-se, portanto, que:

$$u = V_{tas} \cos \alpha \cos \beta \quad (\text{A.4})$$

$$v = V_{tas} \sin \beta \quad (\text{A.5})$$

$$w = V_{tas} \sin \alpha \cos \beta \quad (\text{A.6})$$

Além disso:

$$\dot{V}_{tas} = \frac{u\dot{u} + v\dot{v} + w\dot{w}}{V_{tas}} \quad (\text{A.7})$$

$$\dot{\alpha} = \frac{u\dot{w} - w\dot{u}}{u^2 + w^2} \quad (\text{A.8})$$

$$\dot{\beta} = \frac{(u^2 + w^2)\dot{v} - vw\dot{w} - vu\dot{u}}{v^2\sqrt{(u^2 + w^2)}} \quad (\text{A.9})$$

As relações a respeito do sistema do vento mostradas nas equações A.1-A.9 são importantes e serão utilizadas na análise das equações de observação para os modelos da dinâmica de aeronaves.

A.2.2 Equações de Estado para o Movimento Completo (6-DOF)

As equações de estado para o movimento completo de aeronaves (6-DOF) descritas no sistema do corpo estão mostradas abaixo (BLAKELOCK, 1965), (NELSON, 1989), (STEVENS; LEWIS, 1992).

$$\dot{p} = \frac{-(-I_y I_z + I_z^2 + I_{xz}^2)qr + I_z(I_{xz}pq + \bar{q}Sl_u C_l) + I_{xz}((I_x - I_y)pq + \bar{q}Sl_u C_n)}{I_x I_z - I_{xz}^2} \quad (\text{A.10})$$

$$\dot{q} = \frac{(-I_x + I_z)pr + I_{xz}(-p^2 + r^2) + \bar{q}S\bar{l}_s C_m}{I_y} \quad (\text{A.11})$$

$$\dot{r} = \frac{I_{xz}(I_{xz}pq - (I_x - I_y + I_z)qr + \bar{q}Sl_u C_l) + I_x((I_x - I_y)pq + \bar{q}Sl_u C_n)}{I_x I_z - I_{xz}^2} \quad (\text{A.12})$$

$$\dot{u} = -g \sin \theta + \frac{\bar{q}SC_X + F_T}{m} - wq + vr \quad (\text{A.13})$$

$$\dot{v} = g \sin \phi \cos \theta + \frac{\bar{q}SC_Y}{m} - ur + pw \quad (\text{A.14})$$

$$\dot{w} = g \cos \phi \cos \theta + \frac{\bar{q}SC_Z}{m} - pv + qu \quad (\text{A.15})$$

$$\dot{\phi} = p + \tan \theta (q \sin \phi + r \cos \phi) \quad (\text{A.16})$$

$$\dot{\theta} = q \cos \phi - r \sin \phi \quad (\text{A.17})$$

$$\dot{\psi} = \frac{q \sin \phi + r \cos \phi}{\cos \theta} \quad (\text{A.18})$$

Os coeficientes C_l , C_m e C_n nas equações A.10-A.18 são todos relacionados ao centro de massa da aeronave. Além disso, é assumido que a tração propulsiva passa pelo centro de gravidade da aeronave e está alinhada com o eixo X_b .

Em alguns casos, há o interesse e a necessidade da utilização das equações do movimento no sistema do vento, uma vez que as variáveis α , β e V_{tas} podem ser diretamente medidas, o que não acontece com u , v e w . Para isso, é necessário substituir as equações A.13, A.14 e A.15 pelas relações A.7, A.8 e A.9. Desta maneira, os estados referentes as velocidades lineares u , v e w são substituídos pelas variáveis no sistema do vento α , β e V_{tas} . As equações de estado para estas variáveis ficam:

$$\begin{aligned} \dot{V}_{tas} = & g (\cos \phi \cos \theta \sin \alpha \cos \beta + \sin \phi \cos \theta \sin \beta - \sin \theta \cos \alpha \cos \beta) \\ & + \frac{F_T}{m} \cos \alpha \cos \beta - \frac{\bar{q}S}{m} C_{D_{WIND}} \end{aligned} \quad (\text{A.19})$$

$$\begin{aligned} \dot{\alpha} = & -\frac{\bar{q}S}{mV_{tas} \cos \beta} C_L + q - \tan \beta (p \cos \alpha + r \sin \alpha) \\ & + \frac{g}{V_{tas} \cos \beta} (\cos \phi \cos \theta \cos \alpha + \sin \theta \sin \alpha) - \frac{F_T \sin \alpha}{mV_{tas} \cos \beta} \end{aligned} \quad (\text{A.20})$$

$$\begin{aligned} \dot{\beta} = & \frac{\bar{q}S}{mV_{tas}} C_{Y_{WIND}} + p \sin \alpha - r \cos \alpha + \frac{g}{V_{tas}} \cos \beta \sin \phi \cos \theta \\ & + \frac{\sin \beta}{V_{tas}} \left(g \cos \alpha \sin \theta - g \sin \alpha \cos \phi \cos \theta + \frac{F_T}{m} \cos \alpha \right) \end{aligned} \quad (\text{A.21})$$

Onde:

$$C_L = -C_Z \cos \alpha + C_X \sin \alpha \quad (\text{A.22})$$

$$C_D = -C_X \cos \alpha - C_Z \sin \alpha \quad (\text{A.23})$$

Além disso, para simplificar as equações, são aplicadas as seguintes relações:

$$C_{D_{WIND}} = C_D \cos \beta - C_Y \sin \beta \quad (\text{A.24})$$

$$C_{Y_{WIND}} = C_Y \cos \beta + C_D \sin \beta \quad (\text{A.25})$$

A próxima seção será dedicada a descrição do modelo aerodinâmico considerado neste estudo para compor os coeficientes C_D , C_Y , C_L , C_l , C_m e C_n . Além disso, será feita uma análise das derivadas de estabilidade e controle que nele aparecem no que tange a influência e importância das mesmas para as equações de observação dos respectivos modelos. Esta análise traz consigo o conceito de sensibilidade das equações de saída às derivadas de estabilidade e controle, o qual será discutido mais detalhadamente no decorrer deste trabalho.

A.2.3 Modelo Aerodinâmico e Análise das Derivadas de Estabilidade e Controle Adimensionais

O modelo aerodinâmico descrito tem como objetivo expandir os coeficientes C_D , C_Y , C_L , C_l , C_m e C_n em suas componentes. A composição dos coeficiente aerodinâmicos será feita através do conceito de derivadas de estabilidade e controle, o qual está bem estabelecido na literatura (ETKIN, 1965) (ROSKAM, 1979) (STEVENS; LEWIS, 1992) (MCRUER; ASHKENAS; GRAHAM, 1973). As derivadas de estabilidade e controle também são chamadas, neste estudo, de parâmetros aerodinâmicos. Os parâmetros aerodinâmicos são objetos da estimação paramétrica e compõem o chamado vetor de parâmetros do modelo e vetor de parâmetros a serem estimados, os quais serão abordados mais a frente.

O modelo aerodinâmico mostrado nas equações A.26 - A.31 traz consigo apenas os

termos considerados neste estudo. Podem ser incluídos termos de maior ordem, termos cruzados e termos que modelem, por exemplo, efeitos do número de mach e efeitos aeroelásticos.

É assumido que a composição dos coeficientes aerodinâmicos pode ser modelada por:

$$C_D = C_{D_0} + \frac{1}{\pi e \Lambda} C_L^2 \quad (\text{A.26})$$

$$C_Y = C_{Y_0} + C_{Y_\beta} \beta + C_{Y_p} \frac{pl_S}{V_0} + C_{Y_r} \frac{rl_S}{V_0} + C_{Y_{\delta_a}} \delta_a + C_{Y_{\delta_r}} \delta_r \quad (\text{A.27})$$

$$C_L = C_{L_0} + C_{L_\alpha} \alpha + C_{L_q} \frac{ql_\mu}{V_0} + C_{L_{\delta_e}} \delta_e \quad (\text{A.28})$$

$$C_l^{RP} = C_{l_0} + C_{l_\beta} \beta + C_{l_p} \frac{pl_S}{V_0} + C_{l_r} \frac{rl_S}{V_0} + C_{l_{\delta_a}} \delta_a + C_{l_{\delta_r}} \delta_r \quad (\text{A.29})$$

$$C_m^{RP} = C_{m_0} + C_{m_\alpha} \alpha + C_{m_q} \frac{ql_\mu}{V_0} + C_{m_{\delta_e}} \delta_e \quad (\text{A.30})$$

$$C_n^{RP} = C_{n_0} + C_{n_\beta} \beta + C_{n_p} \frac{pl_S}{V_0} + C_{n_r} \frac{rl_S}{V_0} + C_{n_{\delta_a}} \delta_a + C_{n_{\delta_r}} \delta_r \quad (\text{A.31})$$

A equação A.26 é a chamada polar de arrasto, a qual é uma equação parabólica em função do coeficiente de sustentação. O primeiro termo de A.26 é o coeficiente de arrasto para sustentação nula. O segundo termo é o coeficiente de arrasto induzido, o qual é a parcela do coeficiente de arrasto introduzido pela sustentação. Este termo leva em consideração o alongamento da asa, denotado por Λ , e o Fator de Oswald, denotado por e .

Os coeficientes relacionados com o movimento látero-direcional, C_Y , C_l^{RP} e C_n^{RP} , levam em consideração o ângulo de derrapagem, as velocidades de rolamento e de guinada e a deflexão das superfícies de controle. As superfícies de controle neste caso são, tradicionalmente, os ailerons e o leme de direção. É introduzida, porém, uma terceira deflexão de superfície para o movimento látero-direcional, a qual pode modelar a influência de alguma

outra deflexão de interesse, como, por exemplo, a deflexão dos *spoilers*.

Além disso, os coeficientes C_{Y_0} , C_{l_0} e C_{n_0} modelam uma parcela independente das variáveis β , p , r , δ_a , δ_r e δ_{3lat} para o coeficiente de força lateral, para o coeficiente de momento de rolamento e para o coeficiente de momento de guinada, respectivamente.

Os coeficientes C_L e C_m^{RP} são relacionados com o movimento longitudinal. Os mesmos levam em consideração para sua composição o ângulo de ataque, a taxa de variação temporal do ângulo de ataque, a velocidade de arfagem e as deflexões das superfícies de controle. As superfícies de controle, neste caso, são tradicionalmente o profundor e o estabilizador horizontal. Além disso, podem ser modeladas como δ_{3lon} a deflexão de superfícies, tais como, *flaps* ou freios aerodinâmicos.

Nas equações A.28 e A.30, os coeficientes C_{L_0} e C_{m_0} modelam o coeficiente de sustentação e o coeficiente de momento de arfagem para ângulo de ataque nulo.

Os coeficiente de momento de rolamento, momento de arfagem e momento de guinada estão descritos em relação ao ponto de referência aerodinâmica. Para que estes coeficientes sejam utilizados nas equações de estado, A.10-A.18, é necessária a tranposição dos mesmos para o centro de gravidade da aeronave:

$$C_l = C_l^{RP} - C_Y \frac{z_{arp}}{l_s} + C_Z \frac{y_{arp}}{l_s} \quad (\text{A.32})$$

$$C_m = C_m^{RP} + C_X \frac{z_{arp}}{l_\mu} - C_Z \frac{x_{arp}}{l_\mu} \quad (\text{A.33})$$

$$C_n = C_n^{RP} - C_X \frac{y_{arp}}{l_s} + C_Y \frac{x_{arp}}{l_s} \quad (\text{A.34})$$

Na análise que segue abaixo, as derivadas de estabilidade e controle serão analisadas individualmente. A importância de cada uma na composição das coeficientes aerodinâmicos e a facilidade de extração das mesmas através das técnicas de estimação paramétrica serão abordadas. A análise é bastante sucinta, mencionando apenas o nível de sensibilidade que normalmente ocorre das equações de saída dos respectivos modelos aos parâmetros em análise. Será visto mais adiante que a sensibilidade das equações de saída às derivadas de estabilidade e controle é de fundamental importância para a eficiente estimação das mes-

mas. Este conceito é levado em consideração nos critérios de desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica apresentados neste estudo.

A.2.3.1 Derivadas de estabilidade relacionadas com o ângulo de ataque

No modelo aerodinâmico apresentado anteriormente, as derivadas de estabilidade relacionadas com o ângulo de ataque são C_{L_α} e C_{m_α} . Estes dois parâmetros modelam a variação do coeficiente de sustentação e do coeficiente de momento de arfagem em função da variação do ângulo de ataque, ou seja:

$$C_{L_\alpha} = \frac{\partial C_L}{\partial \alpha} \quad (\text{A.35})$$

$$C_{m_\alpha} = \frac{\partial C_m}{\partial \alpha} \quad (\text{A.36})$$

Estas duas derivadas de estabilidade são de fundamental importância no modelo longitudinal, C_{L_α} modela a inclinação da curva de sustentação em função do ângulo de ataque e C_{m_α} determina a estabilidade estática longitudinal da aeronave.

Geralmente, as equações de saída dos modelos longitudinais são fortemente sensíveis a estes parâmetros. Assim sendo, é comum que a estimação de C_{L_α} e C_{m_α} seja bastante confiável, com intervalos de incerteza bastante reduzidos.

A.2.3.2 Derivadas de estabilidade relacionadas com o ângulo de derrapagem

As derivadas de estabilidade relacionados com o ângulo de derrapagem são C_{Y_β} , C_{l_β} e C_{n_β} . Estes parâmetros modelam a variação da força lateral, do momento de rolamento e do momento de guinada em função da variação do ângulo de derrapagem:

$$C_{Y_\beta} = \frac{\partial C_Y}{\partial \beta} \quad (\text{A.37})$$

$$C_{l_\beta} = \frac{\partial C_l}{\partial \beta} \quad (\text{A.38})$$

$$C_{n_\beta} = \frac{\partial C_n}{\partial \beta} \quad (\text{A.39})$$

O parâmetro C_{Y_β} é geralmente de pequena importância no modelo látero-direcional. Normalmente, a sensibilidade das equações de saída a C_{Y_β} é baixa, o que reduz a capacidade de sua adequada estimação.

A derivada C_{l_β} modela o chamado efeito diedro. Este parâmetro é de fundamental importância para a dinâmica látero-direcional de aeronaves. Normalmente, a sensibilidade das equações de saída a C_{l_β} é alta, proporcionando adequados níveis de incerteza para a sua estimação.

Da mesma forma, a derivada de estabilidade C_{n_β} apresenta grande importância para o movimento látero-direcional no que tange a estabilidade estática direcional de aeronaves. O valor de C_{n_β} é muito aproximado do valor de C_{m_α} , as equações de saída da dinâmica látero-direcional normalmente apresentam forte sensibilidade a C_{n_β} .

A.2.3.3 Derivadas de estabilidade relacionadas com a velocidade de rolamento

As derivadas de estabilidade relacionadas com a velocidade de rolamento são C_{Y_p} , C_{l_p} e C_{n_p} , as quais denotam, respectivamente, a variação da força lateral, do momento de rolamento e do momento de guinada em função da variação da velocidade de rolamento:

$$C_{Y_p} = \frac{\partial C_Y}{\partial p} \quad (\text{A.40})$$

$$C_{l_p} = \frac{\partial C_l}{\partial p} \quad (\text{A.41})$$

$$C_{n_p} = \frac{\partial C_n}{\partial p} \quad (\text{A.42})$$

O parâmetro C_{Y_p} é geralmente desprezível e apresenta baixa influência nas equações de saída do modelo látero-direcional.

A derivada de estabilidade C_{l_p} é de fundamental importância no que tange a estabi-

lidade dinâmica de rolamento de aeronaves. Este parâmetro modela o efeito de amortecimento de rolamento e geralmente apresenta forte influência nas equações de saída do modelo látero-direcional, o que possibilita que sua estimação seja geralmente realizada com bons níveis de confiança.

A derivada C_{n_p} é uma das derivadas chamadas de derivadas cruzadas, pois modela o incremento do momento de guinada em função da variação da velocidade de rolamento. São as derivadas cruzadas que possibilitam o surgimento dos efeitos acoplados na dinâmica látero-direcional. Geralmente a sensibilidade das equações de saída a este parâmetro é boa, possibilitando a sua estimação de maneira adequada.

A.2.3.4 Derivadas de estabilidade relacionadas com a velocidade de arfagem

As derivadas de estabilidades relacionadas com a velocidade de arfagem são C_{L_q} e C_{m_q} . Estes parâmetros modelam os efeitos aerodinâmicos oriundos do rolamento da aeronave em torno do eixo Y_b , os quais afetam a sustentação e o momento de arfagem independentemente da variação do ângulo de ataque:

$$C_{L_q} = \frac{\partial C_L}{\partial q} \quad (\text{A.43})$$

$$C_{m_q} = \frac{\partial C_m}{\partial q} \quad (\text{A.44})$$

O parâmetro C_{L_q} é, geralmente, de baixa importância para o movimento longitudinal, apresentando pouca influência nas equações de saída. Em contra partida, o parâmetro C_{m_q} é de suma importância no que tange a estabilidade dinâmica longitudinal, pois modela o amortecimento em arfagem. A estimação deste parâmetro normalmente apresenta bons níveis de confiança.

A.2.3.5 Derivadas de estabilidade relacionadas com a velocidade de guinada

As derivadas de estabilidade relacionadas com a velocidade de guinada são C_{Y_r} , C_{l_r} e C_{n_r} . Estes parâmetros modelam a variação da força lateral, do momento de rolamento e do momento de guinada em função da variação da velocidade de guinada:

$$C_{Y_r} = \frac{\partial C_Y}{\partial r} \quad (\text{A.45})$$

$$C_{l_r} = \frac{\partial C_l}{\partial r} \quad (\text{A.46})$$

$$C_{n_r} = \frac{\partial C_n}{\partial r} \quad (\text{A.47})$$

A estimação da derivada C_{Y_r} é geralmente prejudicada pela baixa sensibilidade que as equações de saída apresentam a este parâmetro.

A derivada C_{l_r} é mais uma das chamadas derivadas cruzadas. Este parâmetro aerodinâmico, geralmente, apresenta influência mediana nas equações de saída. A sua estimação, normalmente, é adequada, apresentando bons níveis de confiança.

A mais importante das derivadas relacionadas com a velocidade de guinada é C_{n_r} . Este parâmetro é de fundamental importância no que tange a estabilidade dinâmica direcional, pois é responsável pelo amortecimento do movimento de guinada. A estimação deste parâmetro, normalmente, é beneficiada pela alta sensibilidade que as equações de saída apresentam a ele.

A.2.3.6 Derivadas de estabilidade relacionadas com a taxa de variação temporal do ângulo de ataque

As derivadas de estabilidade relacionadas com a taxa de variação temporal do ângulo de ataque são $C_{L_{\dot{\alpha}}}$ e $C_{m_{\dot{\alpha}}}$. Estes parâmetros modelam os efeitos aerodinâmicos que causam variação no coeficiente de sustentação e no coeficiente de momento de arfagem em relação a $\dot{\alpha}$:

$$C_{L_{\dot{\alpha}}} = \frac{\partial C_L}{\partial \dot{\alpha}} \quad (\text{A.48})$$

$$C_{m_{\dot{\alpha}}} = \frac{\partial C_m}{\partial \dot{\alpha}} \quad (\text{A.49})$$

O parâmetro $C_{L\dot{\alpha}}$ é, geralmente, de baixa influência na dinâmica longitudinal de aeronaves, propiciando, portanto, baixa sensibilidade das equações de saída.

Já no que se refere a $C_{m\dot{\alpha}}$ pode-se dizer que os seus efeitos são importantes no que tange a estabilidade dinâmica longitudinal. Normalmente, os efeitos no momento de arfagem causados pela taxa de variação temporal do ângulo de ataque são muito correlacionados com os efeitos causados pela velocidade de arfagem. Os dois possuem características de amortecimento. É extremamente difícil a separação dos dois fenômenos para efeitos de estimação paramétrica. Em alguns casos, é adequado que os efeitos do $C_{m\dot{\alpha}}$ sejam estimados em conjunto e somados com os efeitos de $C_{m\dot{q}}$.

A.2.3.7 Derivadas de controle

As derivadas de controle são aquelas relacionadas com as deflexões das superfícies de controle. Em configurações tradicionais, as superfícies de controle que são utilizadas na dinâmica longitudinal são o profundor e o estabilizador horizontal. No caso da dinâmica látero-direcional, as superfícies mais conhecidas são os ailerons e o leme de direção.

No caso do controle aerodinâmico longitudinal o objetivo principal da deflexão das superfícies de controle é a variação do momento de arfagem. Esta variação no momento de arfagem é possibilitada pela deflexão do profundor, que normalmente é uma parte do estabilizador horizontal, ou pela deflexão de todo o estabilizador horizontal. A deflexão destas superfícies causa variações tanto no coeficiente de sustentação, quanto no coeficiente de momento de arfagem. Normalmente, estas superfícies não tem por finalidade causar incrementos na sustentação, mas sim no momento de arfagem.

A variação da sustentação em função da deflexão do profundor é bastante pequena em comparado com a variação da sustentação em função da deflexão do estabilizador horizontal. Esta característica faz com que a sensibilidade das equações de saída ao parâmetro $C_{L\delta_e}$ seja inferior a sensibilidade das equações de saída ao parâmetro $C_{L\delta_{ih}}$. Normalmente, a sensibilidade das equações de saída a $C_{L\delta_e}$ é reduzida, causando dificuldades no processo de estimação do mesmo. No que diz respeito a $C_{L\delta_{ih}}$, a sua estimação é sensivelmente beneficiada pela aumento de sua influência nas equações de saída.

Já no que diz respeito aos parâmetros $C_{m\delta_e}$ e $C_{m\delta_{ih}}$, sabe-se que as equações de saída possuem alta sensibilidade aos mesmos, uma vez que as superfícies de controle longitu-

dinais possuem como principal atribuição gerar incrementos no momento de arfagem. A estimação destes parâmetros normalmente é bem sucedida no que tange aos intervalos de confiança resultantes.

No que tange à dinâmica látero-direcional, as derivadas de controle são $C_{Y_{\delta a}}$, $C_{l_{\delta a}}$, $C_{n_{\delta a}}$, $C_{Y_{\delta r}}$, $C_{l_{\delta r}}$ e $C_{n_{\delta r}}$. Estes parâmetros são os relacionados com a deflexão das tradicionais superfícies de controle látero-direcional: aileron, δa , e leme de direção, δr .

A deflexão do aileron é basicamente utilizada para o controle lateral da aeronave. Sua principal função é o incremento do momento de rolamento. Este efeito é modelado através da derivada $C_{l_{\delta a}}$, a qual é de fundamental importância neste contexto. É natural observar, portanto, que as equações de saída apresentam alta sensibilidade a este parâmetro, e que a estimação do mesmo seja, normalmente, bem sucedida no que tange aos intervalos de confiança resultantes. Por outro lado, as derivadas $C_{Y_{\delta a}}$ e $C_{n_{\delta a}}$ modelam efeitos aerodinâmicos secundários da deflexão do aileron. O parâmetro $C_{Y_{\delta a}}$ representa a variação da força lateral oriunda da deflexão do aileron. Este efeito é geralmente desprezível e as equações de saída geralmente apresentam baixa sensibilidade a $C_{Y_{\delta a}}$. O parâmetro $C_{n_{\delta a}}$, por sua vez, modela a chamada guinada adversa. Este efeito é bastante significativo em alguns casos, podendo propiciar alta sensibilidade das equações de saída do modelo látero-direcional a $C_{n_{\delta a}}$.

A deflexão do leme de direção, por sua vez, é basicamente utilizada para o controle direcional. A principal função desta superfície de controle é possibilitar o incremento do momento de guinada. Este efeito é modelado através da derivada $C_{n_{\delta r}}$, a qual apresenta forte influência nas equações de saída do modelo, viabilizando assim, a sua adequada estimação. A derivada $C_{Y_{\delta r}}$ modela a variação da força lateral em função da deflexão do leme de direção. Este parâmetro, em raros casos, pode possuir um influência tal nas equações de saída que possibilite a sua estimação com adequados níveis de confiança. Este efeito é análogo aos efeitos de $C_{L_{\delta e}}$ e $C_{L_{\delta ih}}$ e, normalmente, é bastante reduzido. A derivada $C_{l_{\delta r}}$ modela a introdução de momento de rolamento através da deflexão do leme de direção. Este efeito pode ser bastante significativo em alguns casos, o que, eventualmente, possibilita adequada estimação do parâmetro $C_{l_{\delta r}}$.

A.2.4 Equações de Estado Desacopladas

O desacoplamento das equações de estado da dinâmica completa de aeronaves pode ser feita considerando que o plano formado pelos eixos X_b e Z_b é o próprio plano de simetria das aeronaves. Além disso, é necessário assumir que as perturbações das variáveis do movimento látero-direcional são pequenas e podem ser desconsideradas na composição das equações de estado longitudinais. Da mesma maneira, as variações das variáveis longitudinais são assumidas pequenas, ao ponto de poderem ser desconsideradas para a composição das equações de estado látero-direcionais.

No problema de estimação paramétrica, o desacoplamento entre o movimento longitudinal e o movimento látero-direcional é bastante desejável, uma vez que sua resolução se torna mais fácil, pois o número de parâmetros envolvidos no processo e o número de equações de estado a serem integradas são reduzidos consideravelmente. Além desta vantagem, a especificação de manobras de ensaios em vôo específicas para cada modo dinâmico é mais simples e costuma ser mais eficiente, o que também contribui para a abordagem de estimação paramétrica com os modos da dinâmica de aeronaves desacoplados.

É interessante salientar, entretanto, que para que as hipóteses consideradas sejam respeitadas, é fortemente desejável que, no momento das manobras de ensaios em vôo, a excitação seja feita exatamente nos modos dinâmicos modeladas para estimação e que não haja perturbações em variáveis que estão sendo desconsideradas. O problema citado acima é bastante significativo e não é raro que as hipóteses assumidas sejam muito restritivas, a ponto de prejudicar o processo de estimação paramétrica. Assim sendo, em alguns casos é aconselhável que as equações de estado não sejam completamente desacopladas, mas sim levem em consideração as variáveis das dinâmicas de não interesse para estimação paramétrica como entradas de controle a serem medidas durante os ensaios.

A.2.4.1 Movimento Longitudinal

O movimento longitudinal é caracterizado pela rotação em torno do eixo Y_b e a translação ao longo dos eixo x e z (BLAKELOCK, 1965) e (MAINE; ILIFF, 1985). As equações de estado do movimento longitudinal são A.11, A.13, A.15 e A.17:

$$\dot{q} = \frac{(-I_x + I_z)pr + I_{xz}(-p^2 + r^2) + \bar{q}S\bar{l}_s C_m}{I_y} \quad (\text{A.50})$$

$$\dot{u} = -g \sin \theta + \frac{\bar{q}SC_X + F_T}{m} - wq + vr \quad (\text{A.51})$$

$$\dot{w} = g \cos \phi \cos \theta + \frac{\bar{q}SC_Z}{m} - pv + qu \quad (\text{A.52})$$

$$\dot{\theta} = q \cos \phi - r \sin \phi \quad (\text{A.53})$$

Além das equações A.50-A.53, uma quinta equação de estado pode ser introduzido ao modelo longitudinal. A variável de estado a ser introduzida é a altitude pressão (h), descrita pela seguinte equação:

$$\dot{h} = u \sin \theta - v \cos \theta \sin \phi - w \cos \theta \cos \phi \quad (\text{A.54})$$

As equações acima podem ser utilizadas para estimação paramétrica da dinâmica longitudinal, tendo no vetor de controle as variáveis medidas do movimento látero-direcional: p , r , ϕ e v . Desta maneira, o problema da estimação paramétrica é simplificado, pois a integração das equações látero-direcionais e a estimação dos parâmetros látero-direcionais é eliminada, o que representa ganho computacional e simplificação numérica.

No sistema do vento, as equações A.51 e A.52 podem ser substituídas pelas equações A.19 e A.20, neste caso, as equações de estado ficam:

$$\begin{aligned} \dot{\alpha} = & -\frac{\bar{q}S}{mV_{tas} \cos \beta} C_L + q - \tan \beta (p \cos \alpha + r \sin \alpha) \\ & + \frac{g}{V_{tas} \cos \beta} (\cos \phi \cos \theta \cos \alpha + \sin \theta \sin \alpha) - \frac{F_T \sin \alpha}{mV_{tas} \cos \beta} \end{aligned} \quad (\text{A.55})$$

$$\dot{q} = \frac{(-I_x + I_z)pr + I_{xz}(-p^2 + r^2) + \bar{q}S\bar{l}_s C_m}{I_y} \quad (\text{A.56})$$

$$\dot{\theta} = q \cos \phi - r \sin \phi \quad (\text{A.57})$$

$$\begin{aligned} \dot{V}_{tas} = & g (\cos \phi \cos \theta \sin \alpha \cos \beta + \sin \phi \cos \theta \sin \beta - \sin \theta \cos \alpha \cos \beta) \\ & + \frac{F_T}{m} \cos \alpha \cos \beta - \frac{\bar{q}S}{m} C_{D_{WIND}} \end{aligned} \quad (\text{A.58})$$

Para se chegar a uma dinâmica longitudinal simplificada através do sistema descrito nas equações A.55 - A.58, pode-se considerar que um vôo longitudinal desacoplado é aquele na qual as variáveis β , p , r e ϕ são constantes e iguais a zero. Assim sendo, as equações A.55 - A.58 são reduzidas a:

$$\dot{\alpha} = -\frac{\bar{q}S}{mV_{tas}} C_L + q + \frac{g}{V_{tas}} \cos(\theta - \alpha) - \frac{F_T \sin \alpha}{mV_{tas}} \quad (\text{A.59})$$

$$\dot{q} = \frac{\bar{q}S \bar{c} C_m}{I_y} \quad (\text{A.60})$$

$$\dot{\theta} = q \quad (\text{A.61})$$

$$\dot{V}_{tas} = -\frac{\bar{q}S}{m} C_D + g \sin(\alpha - \theta) + \frac{F_T}{m} \cos \alpha \quad (\text{A.62})$$

O modelo descrito acima descreve a dinâmica longitudinal completa e ainda aceita algumas simplificações. Este modelo pode ser separado em dois modos tradicionais e conhecidos na literatura: modo de curto período e modo fugoidal. O modo fugoidal é normalmente uma dinâmica de baixa frequência e baixo amortecimento, envolvendo a variação da velocidade e da altitude de vôo. O modo de curto período é normalmente caracterizado por apresentar alta frequência natural e alto amortecimento. Esta dinâmica basicamente descreve o movimento da aeronave em torno do eixo Y_b do corpo.

O modo de curto período pode ser modelado através da eliminação da equação da velocidade, equação A.62. Esta modificação tira a necessidade de integração da equação

de \dot{V}_{tas} e diminui o número de parâmetros a serem estimados. Além disso, pode-se considerar que θ é igual a α e que o termo que leva em consideração a tração propulsiva é desprezível. Desta maneira, chega-se ao modelo de curto período mais simplificado, com duas equações de estado:

$$\dot{\alpha} = -\frac{\bar{q}S}{mV_{tas}}C_L + q + \frac{g}{V_{tas}} \quad (\text{A.63})$$

$$\dot{q} = \frac{\bar{q}S\bar{c}C_m}{I_y} \quad (\text{A.64})$$

Neste modelo, ainda é necessária a utilização da variável medida V_{tas} como uma entrada de controle.

A.2.4.2 Movimento Látero-Direcional

O movimento látero-direcional é caracterizado pela dinâmica de rotação em torno dos eixos X_b e Z_b e pelo movimento de translação ao longo do eixo y . As equações de estado diretamente relacionadas com esta dinâmica são [A.10](#), [A.12](#), [A.14](#), [A.16](#) e [A.18](#):

$$\dot{p} = \frac{-(-I_y I_z + I_z^2 + I_{xz}^2)qr + I_z(I_{xz}pq + \bar{q}Sl_u C_l) + I_{xz}((I_x - I_y)pq + \bar{q}Sl_u C_n)}{I_x I_z - I_{xz}^2} \quad (\text{A.65})$$

$$\dot{r} = \frac{I_{xz}(I_{xz}pq - (I_x - I_y + I_z)qr + \bar{q}Sl_u C_l) + I_x((I_x - I_y)pq + \bar{q}Sl_u C_n)}{I_x I_z - I_{xz}^2} \quad (\text{A.66})$$

$$\dot{v} = g \sin \phi \cos \theta + \frac{\bar{q}SC_Y}{m} - ur + pw \quad (\text{A.67})$$

$$\dot{\phi} = p + \tan \theta (q \sin \phi + r \cos \phi) \quad (\text{A.68})$$

$$\dot{\psi} = \frac{q \sin \phi + r \cos \phi}{\cos \theta} \quad (\text{A.69})$$

As equações acima podem ser utilizadas para estimação paramétrica, tendo no vetor de controle as variáveis do movimento longitudinal: q , θ , u e w . Esta abordagem permite que a estimação paramétrica seja feita na dinâmica látero-direcional sem que as informações da dinâmica longitudinal sejam perdidas. Além disso, o custo computacional relacionado com a integração das equações de estado longitudinais e com a estimação dos parâmetros longitudinais é evitado.

O desacoplamento do movimento látero-direcional é fisicamente menos palpável do que o desacoplamento do movimento longitudinal. Isso se dá devido aos termos pr e $r^2 - p^2$ contidos na equação A.11, os quais de qualquer maneira excitam a velocidade de arfagem em função da velocidade de guinada e da velocidade de rolamento, a menos que $I_z = I_x$ e que $I_{xz} = 0$, as quais são condições remotas para aeronaves. Além disso, através das equações A.17 e A.20, α e θ são excitados. Este tipo de problema não ocorre para o movimento longitudinal. Pode-se, entretanto, considerar que para excitações não muito significativas das variáveis látero-direcionais a excitação das variáveis longitudinais é desprezível.

A partir das equações A.65 - A.69 e utilizando-se a equação A.21, pode-se chegar a um sistema látero-direcional simplificado descrito no sistema do vento. Para isso, é necessário aproximar $C_{Y_{WIND}}$ por C_Y na equação A.21. Esta aproximação restringe o sistema, uma vez que para que ela seja respeitada β tem que ser pequeno. Na maioria das vezes esta aproximação é respeitada, pois, normalmente, é difícil atingir elevados ângulos de derrapagem. A equação A.67 deve ser substituída pela equação A.21 e a equação A.18 pode ser desconsiderada, pois não agrega informação ao sistema. Desta maneira, o sistema de equações de estado resultante é:

$$\begin{aligned} \dot{\beta} = & \frac{\bar{q}S}{mV_{tas}} C_Y + p \sin \alpha - r \cos \alpha + \frac{g}{V_{tas}} \cos \beta \sin \phi \cos \theta \\ & + \frac{\sin \beta}{V_{tas}} \left(g \cos \alpha \sin \theta - g \sin \alpha \cos \phi \cos \theta + \frac{F_T}{m} \cos \alpha \right) \end{aligned} \quad (\text{A.70})$$

$$\dot{p} = \frac{-(-I_y I_z + I_z^2 + I_{xz}^2)qr + I_z(I_{xz}pq + \bar{q}SbC_l) + I_{xz}((I_x - I_y)pq + \bar{q}SbC_n)}{I_x I_z - I_{xz}^2} \quad (\text{A.71})$$

$$\dot{r} = \frac{I_{xz}(I_{xz}pq - (I_x - I_y + I_z)qr + \bar{q}SbC_l) + I_x((I_x - I_y)pq + \bar{q}SbC_n)}{I_x I_z - I_{xz}^2} \quad (\text{A.72})$$

$$\dot{\phi} = p + \tan \theta (q \sin \phi + r \cos \phi) \quad (\text{A.73})$$

Estas equações utilizam as variáveis do movimento longitudinal, as quais podem ser medidas e informadas no vetor de controle.

Mais a frente, os modelos de curto período e látero-direcional simplificados serão utilizados para gerar modelos linearizados segundo a teoria de pequenas perturbações. Os modelos para pequenas perturbações serão utilizados neste estudo para demonstrar as técnicas de desenvolvimento e otimização de manobras de ensaios em vôo para estimação paramétrica.

A.2.5 Equações de Estado Linearizadas

A avaliação do desempenho de uma aeronave e seus sistemas de controle, através de simulação computacional, deve ser preferencialmente realizada empregando-se modelos dinâmicos completos e não-lineares. Entretanto, como as equações de estado não-lineares são mais difíceis de tratar, a maioria dos estudos sobre o comportamento dinâmico das aeronaves, incluindo estudos de estabilidade do movimento e projeto de sistemas de controle, vem sendo realizadas através de modelos lineares, calculados por pequenas perturbações do equilíbrio da aeronave.

A idéia de perturbações nas forças e momentos aerodinâmicos com respeito a uma condição de vôo em regime é uma abordagem até hoje utilizada (BRYAN, 1911). As equações para pequenas perturbações são equações lineares calculadas algebricamente a partir das equações não-lineares. Estas equações serão utilizadas nos estudos de otimização

de manobras de ensaios em vôo apresentados neste estudo. Serão mostradas as equações para pequenas perturbações do modelo longitudinal de curto período, derivadas de (A.63 - A.64), e do modelo látero-direcional de *dutch-roll*, derivadas das equações (A.70 - A.73).

Os modelos mostrados estão descritos em função de derivadas de estabilidade dimensionais (STEVENS; LEWIS, 1992). As derivadas dimensionais são descritas em função das derivadas adimensionais apresentadas anteriormente, como segue:

$$Z_\alpha = -\frac{\bar{q}SC_{L\alpha}}{mV_0} \quad (\text{A.74})$$

$$Z_q = -\frac{\bar{q}SC_{Lq}}{mV_0^2} \quad (\text{A.75})$$

$$Z_{\delta e} = -\frac{\bar{q}SC_{L\delta e}}{mV_0} \quad (\text{A.76})$$

$$M_\alpha = \frac{l_u \bar{q}SC_{m\alpha}}{I_y} \quad (\text{A.77})$$

$$M_q = \frac{l_u^2 \bar{q}SC_{mq}}{V_0 I_y} \quad (\text{A.78})$$

$$M_{\delta e} = \frac{l_u \bar{q}SC_{m\delta e}}{I_y} \quad (\text{A.79})$$

As equações (A.74-A.79) descrevem as derivadas dimensionais do modo de curto período. As derivadas dimensionais do modo látero-direcionais são:

$$Y_\beta = \frac{\bar{q}SC_{Y\beta}}{m} \quad (\text{A.80})$$

$$Y_p = \frac{\bar{q}Sl_s C_{Yp}}{2mV_0} \quad (\text{A.81})$$

$$Y_r = \frac{\bar{q}Sl_s C_{Yr}}{2mV_0} \quad (\text{A.82})$$

$$Y_{\delta a} = \frac{\bar{q}SC_{Y\delta a}}{m} \quad (\text{A.83})$$

$$Y_{\delta r} = \frac{\bar{q}SC_{Y\delta r}}{m} \quad (\text{A.84})$$

$$L_\beta = \frac{\bar{q}Sl_s C_{l\beta}}{I_x} \quad (\text{A.85})$$

$$L_p = \frac{\bar{q}Sl_s^2 C_{lp}}{2I_x V_0} \quad (\text{A.86})$$

$$L_r = \frac{\bar{q}Sl_s^2C_{l_r}}{2I_xV_0} \quad (\text{A.87})$$

$$L_{\delta a} = \frac{\bar{q}Sl_sC_{l_{\delta a}}}{I_x} \quad (\text{A.88})$$

$$L_{\delta r} = \frac{\bar{q}Sl_sC_{l_{\delta r}}}{I_x} \quad (\text{A.89})$$

$$N_\beta = \frac{\bar{q}Sl_sC_{n_\beta}}{I_z} \quad (\text{A.90})$$

$$N_p = \frac{\bar{q}Sl_s^2C_{n_p}}{2I_zV_0} \quad (\text{A.91})$$

$$N_r = \frac{\bar{q}Sl_s^2C_{n_r}}{2I_zV_0} \quad (\text{A.92})$$

$$N_{\delta a} = \frac{\bar{q}Sl_sC_{n_{\delta a}}}{I_z} \quad (\text{A.93})$$

$$N_{\delta r} = \frac{\bar{q}Sl_sC_{n_{\delta r}}}{I_z} \quad (\text{A.94})$$

A.2.5.1 Modelo de Período Curto

As equações de estado do modelo de curto período para pequenas perturbações descritas em função das derivadas dimensionais e oriundas da linearização das equações (A.63 - A.64) é:

$$\begin{bmatrix} \Delta\dot{\alpha}(t) \\ \Delta\dot{q}(t) \end{bmatrix} = \begin{bmatrix} Z_\alpha & 1 + Z_q \\ M_\alpha & M_q \end{bmatrix} \begin{bmatrix} \Delta\alpha(t) \\ \Delta q(t) \end{bmatrix} + \begin{bmatrix} Z_{\delta e} \\ M_{\delta e} \end{bmatrix} \Delta\delta e(t) \quad (\text{A.95})$$

Além das equações de estado acima descritas, é interessante levar em consideração como uma variável de observação a aceleração vertical. A aceleração vertical no modelo de curto período agrega informação aos dados, é possibilita maior facilidade na estimação de parâmetros. A aceleração vertical é dada por:

$$a_z^{CG} = \frac{\bar{q}SC_Z}{m} \quad (\text{A.96})$$

Incorporando a equação (A.96) à equação (A.95) para gerar um conjunto de equações de observação para o modo de curto período, tem-se:

$$\begin{bmatrix} \Delta\alpha_y(t) \\ \Delta q_y(t) \\ \Delta a_{z_y}(t) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ Z_\alpha \frac{V_0}{g} & Z_q \frac{V_0}{g} \end{bmatrix} \begin{bmatrix} \Delta\alpha(t) \\ \Delta q(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ Z_{\delta e} \frac{V_0}{g} \end{bmatrix} \Delta\delta e(t) \quad (\text{A.97})$$

onde a variação do ângulo de ataque deve ser suficiente para assumir que $\text{sen}(\alpha) = 0$ e $\text{cos}(\alpha) = 1$.

A.2.5.2 Modelo Dutch Roll

As equações de estado do modelo látero-direcional (dutch-roll) para pequenas perturbações oriundas da linearização das equações (A.70 - A.73) são:

$$\begin{bmatrix} \Delta\dot{\beta}(t) \\ \Delta\dot{p}(t) \\ \Delta\dot{r}(t) \\ \Delta\dot{\phi}(t) \end{bmatrix} = \begin{bmatrix} Y_\beta & 0 & -1 & \frac{g}{V_0} \\ L'_\beta & L'_p & L'_r & 0 \\ N'_\beta & N'_p & N'_r & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta\beta(t) \\ \Delta p(t) \\ \Delta r(t) \\ \Delta\phi(t) \end{bmatrix} + \begin{bmatrix} Y_{\delta_a} & Y_{\delta_r} \\ L'_{\delta_a} & L'_{\delta_r} \\ N'_{\delta_a} & N'_{\delta_r} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \delta a(t) \\ \delta r(t) \end{bmatrix} \quad (\text{A.98})$$

onde é assumido que o ângulo de ataque, o ângulo de rolamento e o ângulo de arfagem de equilíbrio são nulos e que a variação do ângulo de derrapagem é pequena o suficiente para considerar que $\text{sen}(\beta) = 0$ e $\text{cos}(\beta) = 1$. Além disso, tem-se que:

$$L'_\beta = \mu L_\beta + \sigma N_\beta \quad (\text{A.99})$$

$$L'_p = \mu L_p + \sigma N_p \quad (\text{A.100})$$

$$L'_r = \mu L_r + \sigma N_r \quad (\text{A.101})$$

$$L'_{\delta_a} = \mu L_{\delta_a} + \sigma N_{\delta_a} \quad (\text{A.102})$$

$$L'_{\delta_r} = \mu L_{\delta_r} + \sigma N_{\delta_r} \quad (\text{A.103})$$

$$N'_\beta = \mu N_\beta + \sigma L_\beta \quad (\text{A.104})$$

$$N'_p = \mu N_p + \sigma L_p \quad (\text{A.105})$$

$$N'_r = \mu N_r + \sigma L_r \quad (\text{A.106})$$

$$N'_{\delta a} = \mu N_{\delta a} + \sigma L_{\delta a} \quad (\text{A.107})$$

$$N'_{\delta r} = \mu N_{\delta r} + \sigma L_{\delta r} \quad (\text{A.108})$$

onde:

$$\mu = \frac{I_x I_z}{(I_z I_x - I_{xz}^2)} \quad (\text{A.109})$$

$$\sigma = \frac{I_{xz} I_z}{(I_z I_x - I_{xz}^2)} \quad (\text{A.110})$$

As relações (A.99 - A.108) são utilizados para simplificar a descrição do modelo de *dutch-roll*, considerando os termos cruzados entre velocidade de rolamento e velocidade de guinada.

As equações de observação para o modelo de *dutch-roll* assumidas neste estudo são:

$$\begin{bmatrix} \Delta\beta_y(t) \\ \Delta p_y(t) \\ \Delta r_y(t) \\ \Delta\phi_y(t) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \Delta\beta(t) \\ \Delta p(t) \\ \Delta r(t) \\ \Delta\phi(t) \end{bmatrix} \quad (\text{A.111})$$

Anexo A

Análise de Riscos dos Vôos da Campanha de Ensaios

Planilha de Análise de Riscos dos Vôos da Campanha de Ensaios					
Procedimento de Ensaio:	Potencial de Perigo	Probabilidade de Ocorrência			
		alta	provável	incerta	remota
Análise Dinâmica	Catastrófico	Alta			
Aeronave: CEA 205 CB.9 CURUMIM	Critico	Alta			
	Marginal		Média		Baixa
	Negligível				
Perigo:					
<ul style="list-style-type: none"> • Impacto da aeronave com o solo; • Carregamento excessivo da aeronave. 					
Causa:					
<ul style="list-style-type: none"> • Perda de controle; • Aplicação demasiada de controle; • Situação de atitude anormal. 					
Efeito:					
<ul style="list-style-type: none"> • Perda da aeronave / tripulação. 					
Procedimentos de minimização:					
<ul style="list-style-type: none"> • Desenvolvimento de sinais de excitação levando em consideração os limites do envelope operacional segundo: Ângulo de ataque, ângulo de derrapagem, ângulo de rolamento, fator de carga e velocidade de vôo; • Desenvolvimento de sinais de excitação levando em consideração os limites operacionais para a deflexão das superfícies de controle; • Não executar manobras de ensaios abaixo de 2000ft MSL; • Abortar o ensaio caso a aeronave atingir 45 graus de rolamento ou 20 graus de arfagem. 					
Procedimentos de emergência:					
<ul style="list-style-type: none"> • Caso houver perda de controle, imediatamente reduzir o motor e neutralizar os controles de vôo; • Caso ocorrer entrada em parafuso, imediatamente proceder com os procedimentos de recuperação. 					
Nível de risco após os procedimentos de minimização:					
		ALTO	MÉDIO	BAIXO	
		X			

Anexo B

Principais Características do Curumim CEA 205 CB.9

Características Básicas:

Envergadura:	14.00 <i>m</i>	Comprimento:	7.40 <i>m</i>
Área alar:	16.40 <i>m</i> ²	Alongamento:	12
Peso Vazio:	325 <i>kgf</i>	Peso Máximo:	580 <i>kgf</i>
Carga Alar:	28 <i>kgf/m</i> ²	Motor	Limbach L2000 EB1

Limites de Carga:

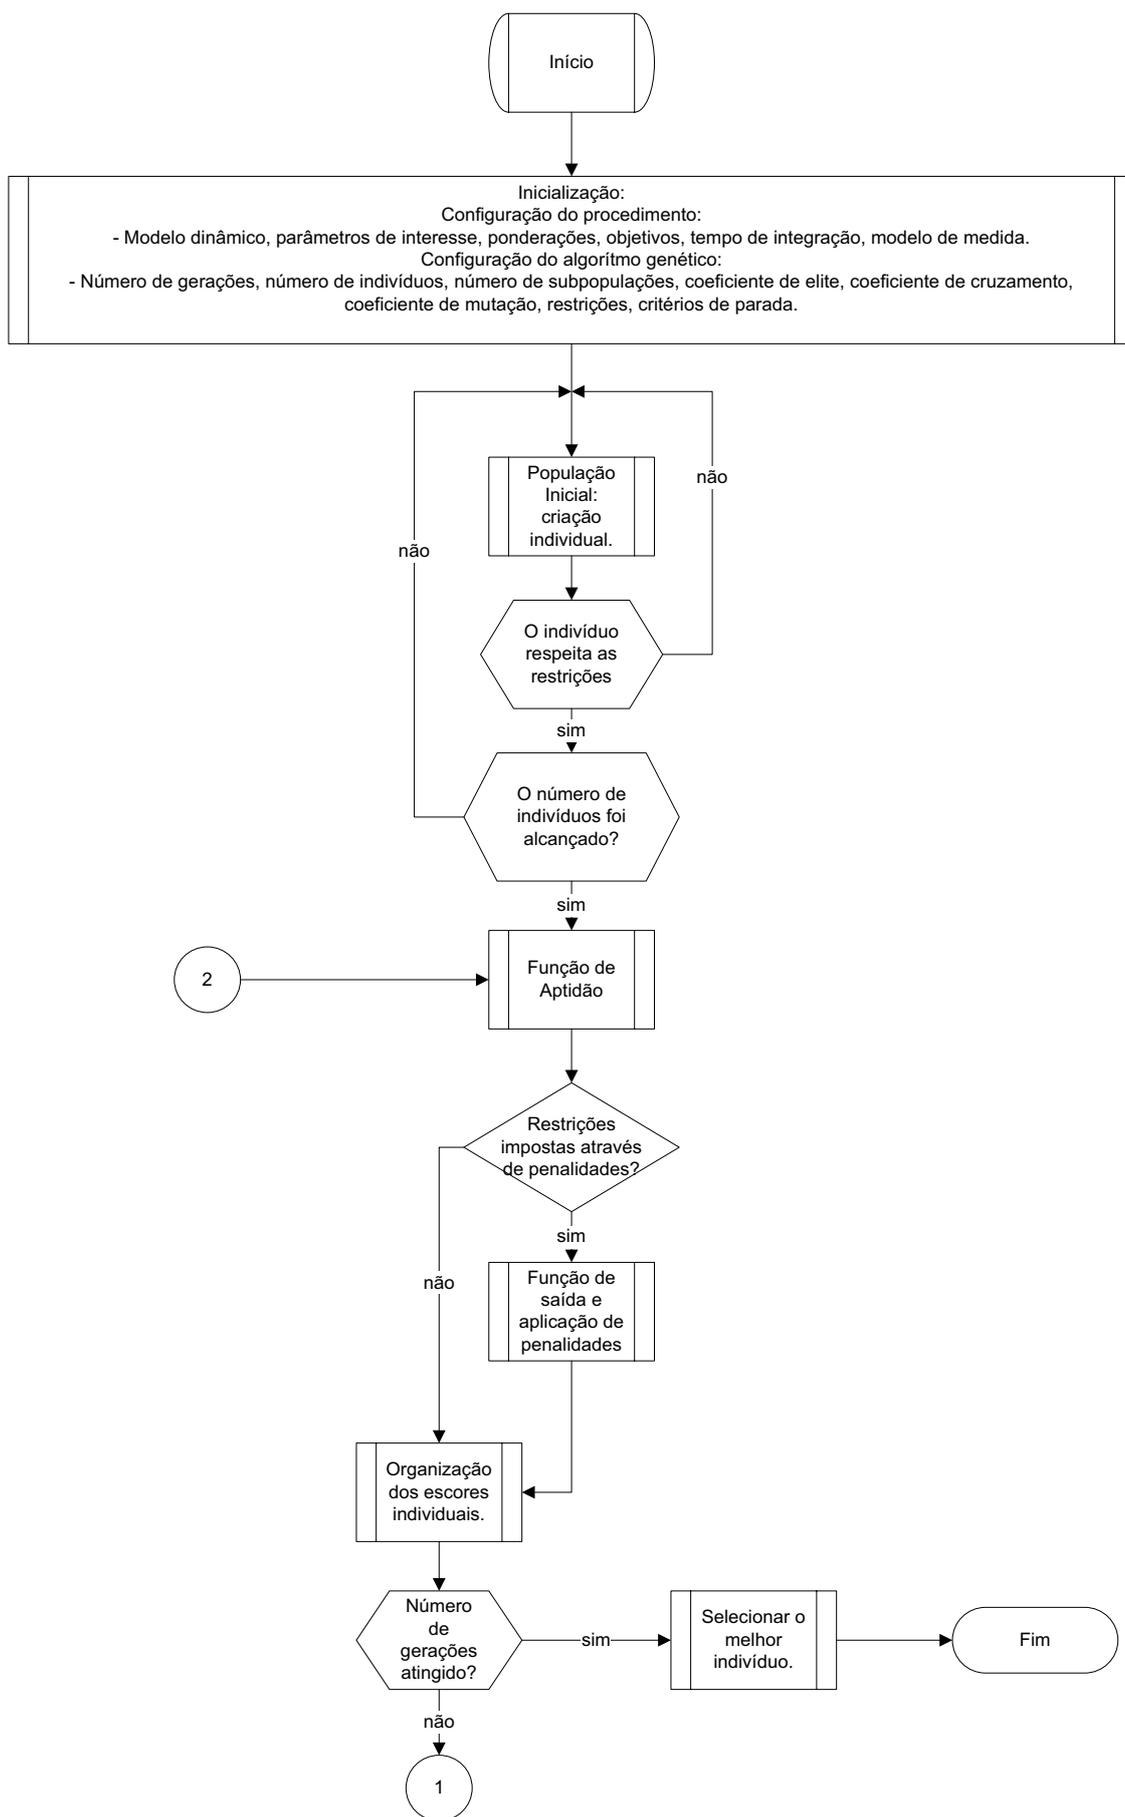
Peso de Decolagem	Limite Positivo	Limite Negativo
410 <i>kgf</i>	+4.0	-2.0
465 <i>kgf</i> (1 tripulante 90 <i>kgf</i> + 70 litros comb.)	+3.5	-1.8
555 <i>kgf</i> (2 tripulantes 90 <i>kgf</i> + 70 litros comb.)	+2.9	-1.5

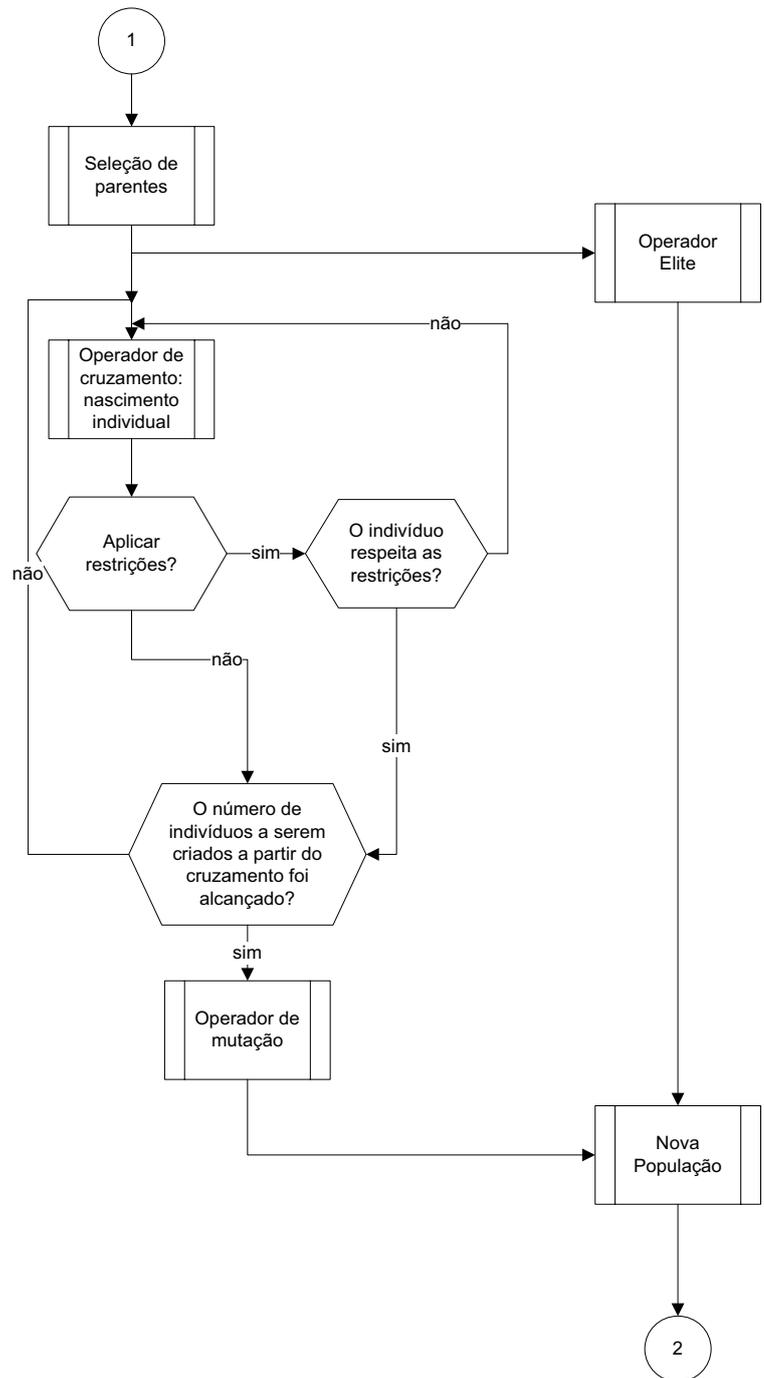
Limites de Velocidade:

Velocidade Máxima de Flaps	85 <i>km/h</i>	53 <i>mph</i>
Velocidade de Manobra	120 <i>km/h</i>	75 <i>mph</i>
Velocidade Nunca Exceder	160 <i>km/h</i>	100 <i>mph</i>

Anexo C

Fluxograma de Processos Básicos do Algoritmo de Otimização





FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO TM	2. DATA 12 de agosto de 2005	3. DOCUMENTO Nº CTA/ITA-IEM/TM-008/2005	4. Nº DE PÁGINAS 173
5. TÍTULO E SUBTÍTULO: Desenvolvimento e otimização de manobras de ensaios em vô para estimação de derivadas de estabilidade e controle de aeronaves			
6. AUTOR(ES): Nei Salis Brasil Neto			
7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica. Divisão de Engenharia Mecânica e Aeronáutica – ITA/IEM			
8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: Manobras de ensaios em vô; Estimação de parâmetros; Derivadas de estabilidade e controle de aeronaves; Algoritmo genético			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Manobras de aeronaves; Ensaios em vô; Estimação de sistemas; Identificação de parâmetros; Derivadas de estabilidade; Controle de aeronaves; Algoritmos genéticos; Controle; Engenharia aeronáutica			
10. APRESENTAÇÃO: X Nacional Internacional ITA, São José dos Campos, 2005, 173 páginas			
11. RESUMO: <p>Este trabalho trata da aplicação de técnicas de otimização via algoritmos genéticos para o desenvolvimento de manobras de ensaios em vô para estimação de parâmetros aerodinâmicos de aeronaves. As manobras otimizadas são necessárias para aumentar a eficiência dos algoritmos de estimação paramétrica, respeitando o envelope operacional das aeronaves quanto à segurança de vô e quanto às limitações matemáticas dos modelos assumidos. Neste trabalho é feita a comparação entre a eficiência do procedimento de estimação com a aplicação de manobras convencionais e a eficiência do procedimento de estimação com a aplicação das manobras otimizadas. Em ambos os casos, o aumento da eficiência do algoritmo de estimação busca a maximização da sensibilidade das variáveis de saída aos parâmetros do modelo. Para as manobras convencionais, os sinais são especificados de maneira indireta, através da maximização de suas densidades espectrais de potência nas frequências próximas dos modos naturais do sistema dinâmico. A técnica de otimização, entretanto, baseada no conteúdo de informação dos dados de ensaios em vô, diretamente utiliza-se dos conceitos de matriz de informação e limitantes de Cramer-Rao para compor os critérios de otimização e gerar sinais globalmente ótimos através de algoritmos genéticos que minimizem as incertezas relacionadas com as estimativas dos parâmetros aerodinâmicos. A presente abordagem considera problemas com multi-objetivos, multi-entradas e para o mínimo tempo, tratando os resíduos coloridos nas variáveis de medida. Vários estudos de caso são discutidos com a utilização dos modelos dinâmicos de período curto e oscilatório em derrapagem, incluindo resultados de ensaios em vô de uma aeronave de pequeno porte. As vantagens e desvantagens das técnicas propostas são apresentadas, enfatizando a facilidade de implementação dos sinais ótimos resultantes. Por fim, considerações e recomendações a respeito da importância das manobras de ensaios em vô para os procedimentos de estimação de derivadas de estabilidade e controle de aeronaves são feitas.</p>			
12. GRAU DE SIGILO: (X) OSTENSIVO () RESERVADO () CONFIDENCIAL () SECRETO			