



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2017/08.07.14.25-TDI

CALIBRAÇÃO E ANÁLISE DE SIMULADORES DE DINÂMICAS DE HELICÓPTEROS POR BRED VECTOR

Ivana Yoshie Sumida

Tese de Doutorado do Curso de
Pós-Graduação em Computação
Aplicada, orientada pelo Dr.
Haroldo Fraga de Campos Velho,
aprovada em 24 de agosto de 2017.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34P/3PDGJ58>

INPE
São José dos Campos
2017

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas
(CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

Dr. Evandro Marconi Rocco - Coordenação de Engenharia e Tecnologia Espacial
(ETE)

Dr. Hermann Johann Heinrich Kux - Coordenação de Observação da Terra (OBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos
Climáticos (CPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Duca Barbedo - Serviço de Informação e Documentação
(SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21b/2017/08.07.14.25-TDI

CALIBRAÇÃO E ANÁLISE DE SIMULADORES DE DINÂMICAS DE HELICÓPTEROS POR BRED VECTOR

Ivana Yoshie Sumida

Tese de Doutorado do Curso de
Pós-Graduação em Computação
Aplicada, orientada pelo Dr.
Haroldo Fraga de Campos Velho,
aprovada em 24 de agosto de 2017.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3PDGJ58>>

INPE
São José dos Campos
2017

Dados Internacionais de Catalogação na Publicação (CIP)

Sumida, Ivana Yoshie.

Su62c Calibração e análise de simuladores de dinâmicas de helicópteros por Bred Vector / Ivana Yoshie Sumida. – São José dos Campos : INPE, 2017.

xxii + 86 p. ; (sid.inpe.br/mte-m21b/2017/08.07.14.25-TDI)

Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

Orientador : Dr. Haroldo Fraga de Campos Velho.

1. Dinâmica de voo. 2. identificação de parâmetros. 3. Bred vector. I.Título.

CDU 681.5.017:533.661



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): *Ivana Yoshie Sumida*

Título: "CALIBRAÇÃO E ANÁLISE DE SIMULADORES DE DINÂMICAS DE HELICÓPTEROS POR BRED VECTOR".

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Doutor(a)** em
Computação Aplicada

Dr. Fernando Manuel Ramos



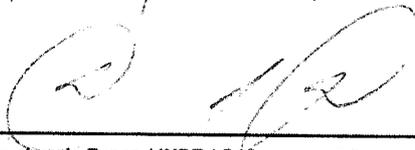
Presidente / INPE / SJC Campos - SP

Dr. Haroldo Fraga de Campos Velho



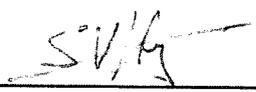
Orientador(a) / INPE / São José dos Campos - SP

Dra. Sandra Aparecida Sandri



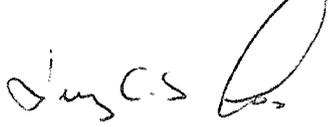
Membro da Banca / INPE / SJC Campos - SP

Dr. Stephan Stephany



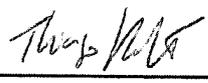
Membro da Banca / INPE / SJC Campos - SP

Dr. Luiz Carlos Sandoval Góes



Convidado(a) / ITA / São José dos Campos - SP

Dr. Thiago Gamboa Ritto



Convidado(a) / UFRJ / Rio de Janeiro - RJ

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 24 de agosto de 2017

*“Tudo tem o seu tempo determinado, e há tempo todo propósito
debaixo do céu: há tempo de nascer e tempo de morrer; tempo de
chorar e tempo de rir; tempo de abraçar e tempo de afastar-se; tempo
de amar e tempo de aborrecer; tempo de guerra e tempo de paz”.*

ECLESIASTES, 3

“Para aquela que sempre esteve a meu lado, dando-me apoio em todos os momentos da minha vida, minha mãe - Odete. E a meu Anjo da Guarda que está ao lado de Deus, por sempre ter sido exemplo e estímulo para a busca de novos desafios e conquistas, meu pai - Luiz”.

AGRADECIMENTOS

Agradeço primeiramente a Deus e a Nossa Senhora Aparecida, amparando-me em todos os momentos desta caminhada.

A meu esposo Lundemarque, pelo seu carinho, amor e compreensão nos momentos difíceis.

A minha amada irmã Michela, ao cunhado Alberto e às sobrinhas Natália e Nayara que mesmo estando longe, sempre estarão junto comigo no meu coração.

Ao meu orientador Haroldo Fraga de Campos Velho, pelo companheirismo, paciência, pelo constante incentivo e inúmeros conselhos que levarei ao longo da minha vida.

Ao Instituto de Pesquisas e Ensaios em Voo (IPEV), por investir no meu aperfeiçoamento profissional. Aos colegas da CTI que me apoiaram, principalmente André e Matheus. Ao Nelson, Moraes, Alex Duarte e Carlos por compartilharem seus conhecimentos de aeronáutica.

Ao Jorge Tadano pelo apoio incondicional, pelos conselhos e por toda compreensão desde a minha chegada ao IPEV.

Ao prof. Luiz Carlos Sandoval Góes (ITA) e Ronaldo Vieira Cruz (DCTA), por cederem o código do modelo dinâmico do helicóptero.

Ao prof. Thiago Gamboa Ritto e Felipe Gonzalez Gonzaga, da Universidade Federal do Rio de Janeiro (UFRJ), por cederem o código de dinâmica de rotor de helicóptero. Ao prof. Americo Barbosa da Cunha Junior, da Universidade do Estado do Rio de Janeiro (UERJ), por ceder o código do Teste 0-1 (dinâmica caótica/regular).

Aos amigos do INPE Wantuir Freitas e Sabrina Sambatti pela amizade e constante incentivo. Aos demais colegas da CAP: Eduardo Luz, Marluce, Wanderson, Juliana Marino, Juliana Lacerda, Phyllipe, Luciano, Reynier e Érica pelas conversas sobre o trabalho e pela amizade.

As minhas queridas amigas, Cicera Iva Pereira, Cristiane Hernandez, Priscila Martins e Priscila Nakao Moro pela eterna amizade, mesmo distantes estavam torcendo pelo meu sucesso.

Aos docentes da CAP pela competência com que atuaram na minha formação e ao

INPE pelo suporte oferecido.

Agradeço aos membros da banca por disporem de seu precioso tempo na leitura deste trabalho.

À Financiadora de Estudos e Projetos (FINEP) pelo apoio financeiro (FINEP-FEV) 01.12.0518.00.

Enfim, o caminho para uma defesa de tese de doutorado é longo e certamente não seria possível chegar até aqui sem a contribuição dessas pessoas. Durante todos esses anos só tenho a agradecer a todos aqueles que me ajudaram direta ou indiretamente para a conclusão deste trabalho.

RESUMO

O setor aeroespacial é fortemente ligado a diversas áreas da computação. São exemplos bem conhecidos: aerodinâmica computacional, controle computadorizado de aeronaves, *softwares* do segmento de solo e simuladores de voo. Há um uso crescente de simuladores de voo com o objetivo de aumentar a segurança das operações. Para que os simuladores tenham uma boa aderência com a realidade é preciso calibrá-los, ou seja, identificar os parâmetros que tornem a simulação o mais próximo possível da dinâmica real. Após determinar tais parâmetros, o simulador estará pronto para ser usado na avaliação de foguetes, aeronaves e no treinamento de pilotos. A identificação de parâmetros, que caracteriza o comportamento aerodinâmico da aeronave, pode ser formulada como um problema de otimização. Um dos objetivos desse trabalho é realizar a calibração de um simulador da dinâmica de helicóptero através da meta-heurística: algoritmo de colisão de múltiplas partículas (MPCA: *Multiple Particle Collision Algorithm*). Os resultados foram comparados com os encontrados pelo algoritmo genético. Entretanto, uma análise da dinâmica também é relevante para que o simulador possa bem representar a resposta da aeronave. O segundo objetivo deste trabalho é realizar a previsibilidade da dinâmica. Nessa etapa, o problema da previsibilidade é formulado como um problema de classificação. Uma técnica baseada em “*bred vectors*” é empregada para avaliar um sistema dinâmico não linear e classificadores neuro-difusos são utilizados para identificação das classes de previsibilidade. Neste trabalho, a aplicação da metodologia de “*bred vectors*” tem foco na dinâmica do rotor de um helicóptero.

Palavras-chave: Dinâmica de voo. Identificação de Parâmetros. *Bred Vector*.

CALIBRATION AND ANALYSIS OF HELICOPTER DYNAMICS SIMULATORS BY BRED VECTOR

ABSTRACT

The aerospace industry is strongly connected to several computing areas, such as computer aerodynamics, computerized control of aircraft, ground segment software, and flight simulators. Flight simulators are being largely used to increase the safety of operations. In order that the simulators have a good adherence to reality, they need to be calibrated, that is, identify the parameters that make the simulation as close as possible to the real dynamic. After these parameters are identified, the simulator is ready to be used to evaluate rockets and aircraft, as well as in pilot training. Determining these parameters, which characterizes the aerodynamic behavior of the aircraft, can be formulated as an optimization problem. One of the goals of this work is to calibrate the simulator of a helicopter dynamics using a new meta-heuristic named MPCA (Multiple Particle Collision Algorithm). The results were compared to the ones found using a genetic algorithm. However, an analysis of the flight dynamics is also relevant so that the simulator can represent the response of the aircraft. The second goal of this work is to predict the flight dynamics of a simulator. At this stage, the problem of predictability was formulated as a classification problem. A bred vector based technique was employed to evaluate a non-linear dynamic system, and neuro-fuzzy classifiers were used to identify predictability classes. The application of bred vectors methodology focused on the dynamics of the rotor of a helicopter.

Keywords: Flight dynamic. Parameter identification. Bred Vector.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Sistema de Coordenadas do Corpo	6
2.2 Comandos de Voo do Helicóptero	6
2.3 Helicóptero Após a Ocorrência do Fenômeno de Ressonância Solo.	12
2.4 Sistema de Coordenadas para o Rotor do Helicóptero.	13
2.5 Posição Angular das Pás	14
3.1 Bred Vectors	20
3.2 Sistema de Lorenz	21
3.3 Regimes no Sistema de Lorenz	22
3.4 Série Temporal $x(t)$ em Função do Número de Passos	23
3.5 Avaliação da Curva Executada por uma Trajetória ("Y"é a coordenada do eixo vertical).	24
4.1 Variável Linguística Febre	29
4.2 Sistema de Inferência Difuso	30
4.3 Arquitetura Básica de um Sistema Neuro-Difuso	33
4.4 Editor do ANFIS <i>Fuzzy Logic Toolbox</i>	35
4.5 Janela Principal do GUAJE	37
4.6 Janela <i>Adding Expert Knowledge</i>	38
5.1 Entrada Sinusoidal Típica	41
5.2 Instrumentação da Aeronave Ensaída	42
5.3 Instrumentação dos Comandos de Voo	42
5.4 Variação da Velocidade Linear no Eixo X	51
5.5 Variação da Velocidade Linear no Eixo Z	51
5.6 Variação da Atitude Horizontal	53
5.7 Variação da Velocidade Angular de Arfagem	53
5.8 Variação do Rolamento	54
5.9 Variação da Velocidade Linear no Eixo Y	54
5.10 Variação da Atitude Lateral	56
5.11 Variação da Velocidade Angular de Guinada	56
6.1 Rotor Principal	59
6.2 Posição do Centro da Cabeça do Rotor	59
6.3 Magnitude do <i>Bred Vector</i> para a Variável X do Modelo da Dinâmica do Rotor	61
6.4 Curva Direita e Esquerda	62

6.5	Amostras de <i>Bred Vector</i> Antecedendo Curvas	63
6.6	Coordenadas Utilizadas para Definir a Extensão de uma Trajetória.	64
6.7	Amostras de <i>Bred Vector</i> antedecendo trajetórias longas.	65
6.8	Exemplo de um amostra de entrada para sistemas <i>neuro-fuzzy</i>	67
6.9	Regras Geradas pelo ANFIS	69
6.10	Regras Geradas pelo GUAJE	70

LISTA DE TABELAS

	<u>Pág.</u>
5.1 Algoritmo PCA.	46
5.2 Função para perturbação no PCA.	46
5.3 Função para exploração no PCA.	47
5.4 Função para espalhamento no PCA.	47
5.5 MPCA: pseudo-código.	48
5.6 Erros Modo Longitudinal AG e MPCA	55
5.7 Erros Modo Látero Direcional AG e MPCA	55
6.1 Resultados com o Teste 0-1 para segunda série temporal ($t \in [1, 89; 2] \times 10^6$). 58	
6.2 Tabela Relacionando Classes (cor) de Magnitudes do <i>Bred Vector</i> (BV).. 61	
6.3 Matriz de Confusão - Dados Não Balanceados (ANFIS).	70
6.4 Matriz de Confusão - Dados Não Balanceados (GUAJE).	71
6.5 Matriz de Confusão - Dados Balanceados (ANFIS).	71
6.6 Matriz de Confusão - Dados Balanceados (GUAJE).	71

LISTA DE ABREVIATURAS E SIGLAS

DOF	–	<i>Degrees of Freedom</i>
Matlab	–	<i>Matrix Laboratory</i>
BV	–	<i>Bred Vector</i>
SAD	–	Sistema de Aquisição de Dados
MPCA	–	<i>Multiple Particle Collision Algorithm</i>
PCA	–	<i>Particle Collision Algorithm</i>
MPI	–	<i>Message Passing Interface</i>
AG	–	Algoritmo Genético
FIS	–	<i>Fuzzy Inference System</i>
SIH	–	Sistemas Inteligentes Híbridos
GUAJE	–	<i>Generating Understandable and Accurate fuzzy models in a Java Environment</i>
HILK	–	<i>Highly Interpretable Linguistic Knowledge</i>
ANFIS	–	<i>Adaptative Neuro-Fuzzy Inference System</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivos	3
1.2 Organização da Tese	3
2 DINÂMICA DE HELICÓPTERO	5
2.1 Modelo Dinâmico do Helicóptero	5
2.1.1 Modelo Linearizado	9
2.2 Modelo do Rotor	12
2.2.1 Teste para Dinâmica Caótica	16
3 BRED VECTOR NO ESTUDO DE SISTEMAS DINÂMICOS	19
3.1 Descrição da Metodologia <i>Bred Vector</i>	19
3.2 Aplicação da Metodologia no Atrator de Lorenz	20
3.3 Análise para dinâmica do rotor de helicóptero	23
4 CLASSIFICADORES DIFUSOS (FUZZY)	27
4.1 Visão Geral sobre Lógica Difusa	27
4.2 Variável Linguística	28
4.3 Sistema de Inferência Difuso	29
4.4 Sistemas Neuro-Difusos	31
4.4.1 <i>Adaptative Neuro-Fuzzy Inference System</i> (ANFIS)	33
4.4.2 <i>Generating Understandable and Accurate fuzzy models in a Java Environment</i> (GUAJE)	35
5 CALIBRAÇÃO DE SIMULADORES DE VOO	39
5.1 Simuladores e Modelo Calibração	39
5.2 Metodologia Quad-M	40
5.2.1 Manobras	40
5.2.2 Medidas	41
5.2.3 Modelo	43
5.2.4 Método: Algoritmos Meta-heurísticos	44
5.2.4.1 Algoritmo de Colisão de Múltiplas Partículas	45
5.2.4.2 Algoritmo Genético	48

5.3	Resultados para Calibração	49
6	ANÁLISE DA DINÂMICA DE ROTOR POR <i>BRED VECTOR</i>	57
6.1	Resultados da Aplicação do Teste 0-1 para Dinâmica do Heli- cóptero	57
6.2	Análise via <i>Bred Vector</i>	58
6.2.1	Análise da dinâmica: tipo de curva	62
6.2.2	Análise da dinâmica: extensão da trajetória	63
6.2.3	Regras para a Dinâmica do Rotor de Helicóptero	65
6.3	Classificação Neuro-Difusa da Dinâmica	66
7	CONCLUSÕES	73
	REFERÊNCIAS BIBLIOGRÁFICAS	77

1 INTRODUÇÃO

A técnica de simulação tem se tornado cada vez mais importante no mundo moderno, devido à necessidade de garantir uma maior segurança, além de levar a redução de custos e tempo. A simulação consiste em construir um modelo da situação real e nele realizar experiências, analisando sua reação diante das influências externas e internas.

No setor aeroespacial, durante a execução de testes integrados de satélites, comandos são enviados simultaneamente para a implementação sob teste e para um simulador. Respostas obtidas por meio de telemetria são comparadas para verificar se há discrepâncias entre valores esperados e medidos, permitindo a verificação das especificações do projeto (TOMINAGA, 2010). No setor aeronáutico, mais especificamente a simulação por pilotagem, o treinamento com simulador de voo proporciona uma redução no custo operacional, além de ser evidente a capacidade de treinar os pilotos com realismo e segurança. O simulador permite ao instrutor comunicar-se com o aluno, controlar as manobras, monitorar os instrumentos e simular situações de emergência.

Porém, para que os simuladores tenham uma boa aderência com a realidade, é preciso calibrá-los, ou seja, identificar os parâmetros que tornem a simulação o mais próxima possível da dinâmica real. Após determinar tais parâmetros, o simulador estará pronto para ser usado para a avaliação seja em foguetes, aeronaves ou no treinamento de pilotos.

Assim, a compreensão da dinâmica é fundamental para os projetos no setor aeroespacial. A utilização de técnicas de identificação na área de dinâmica de voo vem tendo um grande avanço, principalmente pela crescente disponibilidade de computadores cada vez mais rápidos e com maior capacidade de processamento.

Diversos estudos tem sido realizados. Em Maciel et al. (2004) uma técnica de identificação baseada no método de erro na saída (*output error*) com critério de estimação por máxima verossimilhança e algoritmo de otimização de Levenberg-Marquardt foi apresentada. Raisinghni e Ghosh (2000) aplicaram redes neurais ao problema de modelagem e identificação de parâmetros para aeronaves aeroelásticas, sem necessitar de medidas de deflexões elásticas ou de suas derivadas. No trabalho de Machado (2016), foi realizada a identificação de parâmetros de uma aeronave de asas rotativas por filtro de Kalman estendido com a intenção de ser empregado em um simulador de voo.

Um outro aspecto importante no estudo de problemas reais é a realização da análise dos sistemas dinâmicos, principalmente os não lineares. A análise da dinâmica não linear dos modelos matemáticos de aeronaves tem avançado nos últimos tempos, esses estudos concentram-se na estimativa dos modelos aerodinâmicos não lineares e na análise dos efeitos de não linearidades específicas nas aeronaves. Os trabalhos de [Avanzini e Matteis \(1997\)](#) e [Jahnke e Culick \(1994\)](#) utilizaram técnicas de bifurcação para estudar a dinâmica não linear das aeronaves F-16 e F-14, respectivamente.

Em [Pereira \(2007\)](#), foi analisada a dinâmica não linear da aeronave F-8 Crusader em voo longitudinal e foi realizada a análise do comportamentamento bifurcacional onde se estudou o comportamento topológico desta aeronave, tomando-se dois parâmetros de controle: a deflexão do profundor e a alteração da massa da referida aeronave. A grande vantagem do estudo de bifurcação na dinâmica de voo é proporcionar um maior entendimento e a possibilidade de prever possíveis comportamentos não lineares.

Existem vários métodos para caracterizar a dinâmica, por exemplo: diagrama de bifurcação, seção de Poincaré, bacias de atração, entropia de Kolmogorov-Sinai e os expoentes de Lyapunov. Uma técnica conhecida como *bred vector* vem sendo utilizada em assimilação de dados e modelos atmosféricos. Ela consiste em fazer duas simulações de um mesmo modelo. Na primeira simulação, a integração do modelo é realizada com as condições iniciais, por um intervalo de tempo previamente definido. A segunda simulação consiste na integração a partir de condições iniciais com perturbações adicionadas, no mesmo intervalo de tempo. A diferença entre as variáveis de estado do modelo é denominada *bred vector*. A taxa de crescimento (ou magnitude) do *bred vector* é utilizada para caracterização da dinâmica que pode divergir ou convergir, conforme o comportamento do sistema dinâmico em questão ([TOTH; KALNAY, 1997](#); [CORAZZA et al., 2003](#)).

Muitos trabalhos utilizam essa técnica para identificar padrões em sistemas caóticos, e a partir destes padrões, realizar uma previsibilidade sobre o comportamento do sistema. Em [Evans et al. \(2004\)](#), foi realizada a previsão do comportamento no atrator de Lorenz e em [Cintra e Velho \(2008\)](#) foi aplicada a metodologia no modelo de três ondas acopladas. Por fim, [Santos \(2014\)](#) utilizou estes estudos transformando o problema de previsibilidade em sistemas dinâmicos com comportamento caótico em um problema de classificação.

1.1 Objetivos

Este trabalho possui dois objetivos. O primeiro é realizar a calibração de um simulador da dinâmica de helicóptero desenvolvido por Cruz (2009). A calibração é feita através de uma meta-heurística: o algoritmo de colisão de múltiplas partículas (MPCA). Esta primeira fase serve de capacitação para o estudo e conhecimento de veículos do setor aeroespacial.

O segundo objetivo é a caracterização da dinâmica não linear apresentada por veículos e/ou componentes da área de estudo, com emprego de *bred vector* e ferramentas de inteligência computacional. A análise não linear será efetuada sobre a dinâmica do rotor de um helicóptero (GONZAGA, 2013). A caracterização não linear tem a intenção de identificar padrões e quantificar em classes de previsibilidade para o sistema. Deste modo, o problema de previsibilidade em sistemas dinâmicos passa a ser descrito como um problema de classificação. Para realizar a classificação da dinâmica foram utilizadas as ferramentas neuro-difusas ANFIS (JANG, 1993) e GUAJE (ALONSO et al., 2012).

1.2 Organização da Tese

O presente trabalho está organizado nos seguintes capítulos:

- Capítulo 2: são apresentados os modelos matemáticos utilizados neste trabalho. O primeiro modelo simula a dinâmica de um helicóptero (CRUZ, 2009), descrevendo as equações de movimento translacional e rotacional. O segundo modelo descreve uma versão simplificada de um rotor de helicóptero (GONZAGA, 2013).
- Capítulo 3: a metodologia *bred vector* é descrita. Apresenta-se também uma aplicação em sistemas dinâmicos para previsão do comportamento em sistemas não lineares.
- Capítulo 4: são descritos os conceitos básicos dos sistemas difusos como variável linguística e sistema de inferência difuso, bem como seus principais modelos (Mandani e Takagi-Sugeno). Por fim, são abordadas as ferramentas neuro-difusas ANFIS e GUAJE, que foram utilizadas neste trabalho.
- Capítulo 5: neste capítulo, a metodologia para identificação de sistemas conhecida como Quad-M é descrita. Além disso, são apresentados os resultados comparativos da calibração do modelo dinâmico do helicóptero entre

o algoritmo genético e o algoritmo de colisão de múltiplas partículas.

- Capítulo 6: são apresentados os resultados obtidos com a metodologia *breed vector* para identificação dos padrões no sistema dinâmico do rotor do helicóptero. Para realizar a classificação da dinâmica foram utilizadas as ferramentas neuro-difusas ANFIS e GUAJE.
- Capítulo 7: são apresentadas as conclusões e trabalhos futuros.

2 DINÂMICA DE HELICÓPTERO

Neste capítulo, serão apresentados dois modelos de dinâmica utilizados neste trabalho. O primeiro modelo simula a dinâmica do helicóptero (CRUZ, 2009) descrevendo as equações de movimento translacional e rotacional com seis graus de liberdade. Após uma linearização por série de Taylor, são apresentadas em forma matricial os modos longitudinal e látero-direcional contendo as derivadas de estabilidade e controle que serão estimadas no Capítulo 5.

O segundo modelo é uma versão simplificada de um rotor de helicóptero (GONZAGA, 2013). Neste modelo foi aplicado um teste com o objetivo de identificar se a dinâmica é caótica ou regular. Esta verificação foi necessária para a análise da dinâmica do rotor abordada no Capítulo 6.

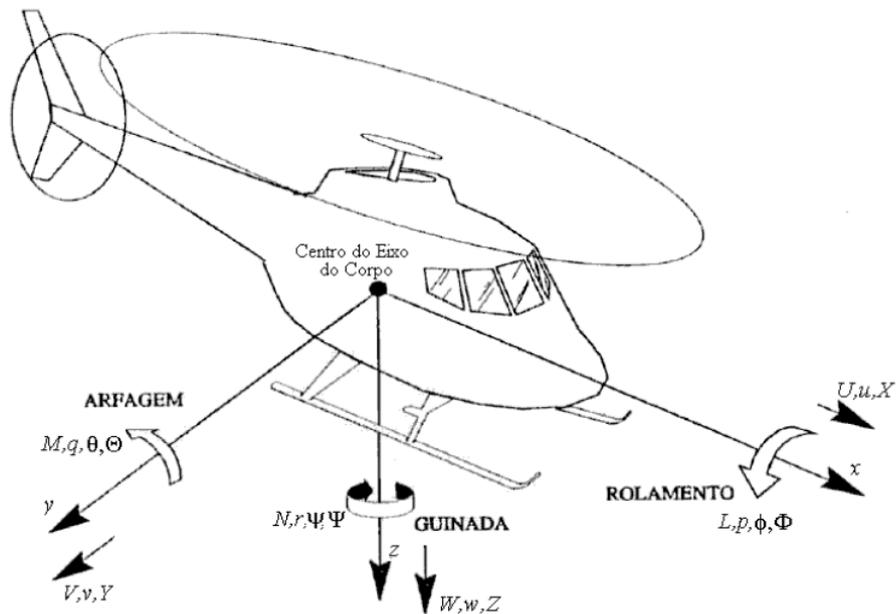
2.1 Modelo Dinâmico do Helicóptero

Os modelos de dinâmica de voo são geralmente descritos por equações diferenciais obtidas através das leis fundamentais da mecânica, o que torna necessária a definição de um conjunto de sistemas de coordenadas que serão utilizados na determinação de posições, de componentes de vetores (forças, velocidades relativas, acelerações, etc.) e de elementos matriciais (derivadas aerodinâmicas, momentos e produtos de inércia, etc.) que descrevem a trajetória da aeronave (CURVO, 2001). Dessa maneira, será utilizado o seguinte sistema de coordenadas do corpo:

O helicóptero possui liberdade de deslocamento nos três eixos espaciais, x , y e z . Considera-se os eixos fixos na própria aeronave (sistema do corpo). Para fins de dinâmica de forças, a origem dos eixos é o centro de massa. O eixo x é coincidente com o eixo longitudinal do helicóptero, sendo comandado pelo cíclico e propicia a mudança de inclinação do disco do rotor principal que permite que a aeronave se movimente para frente ou para trás. O eixo y é coincidente com o eixo lateral e também é comandado pelo cíclico, que permite que a aeronave se movimente para esquerda e para direita. Finalmente, o eixo z é o deslocamento vertical comandado pelo coletivo, o qual permite a subida e descida da aeronave (FIRMINO, 2008). O coletivo atua na velocidade de rotação do rotor principal e no ângulo das pás. Na Figura 2.2 é possível observar os comandos do helicóptero e onde cada um atua na aeronave. Os pedais comandam o ângulo das pás do rotor de cauda.

As forças externas atuantes na aeronave \vec{F}_B (no sistema do corpo) provém das forças aerodinâmicas (representadas pelas componentes X, Y e Z) e da força gravitacional

Figura 2.1 - Sistema de Coordenadas do Corpo



Fonte: Cruz (2009)

Figura 2.2 - Comandos de Voo do Helicóptero



Fonte: Hangar33 (2015)

$\vec{W} = mg$, medida no referencial terrestre. As equações do movimento translacional

são obtidas da segunda Lei de Newton usando a seguinte notação matricial:

$$\vec{F}_B = m\vec{a}_B = m(\dot{\vec{V}}_B + \vec{\omega}_B \times \vec{V}_B) \quad (2.1)$$

onde:

$$\vec{V}_B = [u \quad v \quad w]^T \quad (2.2)$$

$$\vec{\omega}_B = [p \quad q \quad r]^T \quad (2.3)$$

$$\vec{F}_B = [X - mg \sin \theta \quad Y + mg \cos \theta \sin \phi \quad Z + mg \cos \theta \cos \phi]^T \quad (2.4)$$

Expandindo a [Equação 2.1](#) e rearranjando termos, resulta que:

$$\begin{bmatrix} X - mg \sin \theta \\ Y + mg \cos \theta \sin \phi \\ Z + mg \cos \theta \cos \phi \end{bmatrix} = m \begin{bmatrix} \dot{u} + qw - rv \\ \dot{v} + ru - pw \\ \dot{w} + pv - uq \end{bmatrix} \quad (2.5)$$

$$\dot{u} = rv - qw + \frac{X}{m} - g \sin \theta \quad (2.6)$$

$$\dot{v} = pq - ru + \frac{Y}{m} + g \cos \theta \sin \phi \quad (2.7)$$

$$\dot{w} = qu - pv + \frac{Z}{m} + g \cos \theta \cos \phi \quad (2.8)$$

As equações do movimento rotacional são obtidas a partir da expressão do momento angular:

$$\vec{G}_B = \frac{d}{dt} I_B \vec{\omega}_B \quad (2.9)$$

$$\vec{G}_B = \frac{d}{dt} I_B \vec{\omega}_B + \vec{\omega}_B \times I_B \vec{\omega}_B \quad (2.10)$$

onde: $\vec{G}_B = [L \quad M \quad N]^T$ representa o momento total atuando no helicóptero decorrente apenas das forças externas; e abaixo tem-se a matriz de inércia do corpo:

$$I_B = \begin{bmatrix} I_{xx} & 0 & -I_{zx} \\ 0 & I_{yy} & 0 \\ -I_{zx} & 0 & -I_{zz} \end{bmatrix} \quad (2.11)$$

Os zeros resultam dos produtos de inércia em planos onde um dos eixos considerados

é de simetria. Assim, derivando o primeiro termo da [Equação 2.10](#) obtém-se:

$$I_B \vec{\omega}_B = \begin{bmatrix} I_{xx} & 0 & -I_{zx} \\ 0 & I_{yy} & 0 \\ -I_{zx} & 0 & -I_{zz} \end{bmatrix} \begin{bmatrix} p & 0 & 0 \\ 0 & q & 0 \\ 0 & 0 & r \end{bmatrix} = \begin{bmatrix} pI_{xx} & 0 & -rI_{zx} \\ 0 & qI_{yy} & 0 \\ -pI_{zx} & 0 & +rI_{zz} \end{bmatrix} \quad (2.12)$$

$$\frac{d}{dt} I_B \vec{\omega}_B = \begin{bmatrix} \dot{p}I_{xx} & 0 & -\dot{r}I_{zx} \\ 0 & \dot{q}I_{yy} & 0 \\ -\dot{p}I_{zx} & 0 & +\dot{r}I_{zz} \end{bmatrix} \quad (2.13)$$

O produto vetorial da [Equação 2.10](#) pode ser expandido para:

$$\begin{aligned} \vec{\omega}_B \times I_B \vec{\omega}_B &= \begin{bmatrix} \vec{i} & \vec{j} & \vec{k} \\ p & q & r \\ pI_{xx} - rI_{zz} & qI_{yy} & -pI_{zx} + rI_{zz} \end{bmatrix} \\ &= (-qpI_{zx} + qrI_{zz} - rqI_{yy})\vec{i} \\ &+ rpI_{xx} - r^2I_{zx} + p^2I_{zx} + prI_{zz})\vec{j} \\ &+ (pqI_{yy} - pqI_{xx} + qrI_{zx})\vec{k} \end{aligned} \quad (2.14)$$

Assim, a equação do movimento rotacional de forma explícita é dado por:

$$\begin{aligned} \vec{G}_B = \begin{bmatrix} L \\ M \\ N \end{bmatrix} &= \begin{bmatrix} \dot{p}I_{xx} - \dot{r}I_{zx} - qpI_{zx} + qrI_{zz} - rqI_{yy} \\ \dot{q}I_{yy} + rpI_{xx} - r^2I_{zx} + p^2I_{zx} - prI_{zz} \\ -\dot{p}I_{zx} + \dot{r}I_{zz} + pqI_{yy} - qpI_{xx} + qrI_{zx} \end{bmatrix} \\ &= \begin{bmatrix} I_{xx}\dot{p} - (\dot{r} + qp)I_{zx} + (I_{zz} - I_{yy})qr \\ \dot{q}I_{yy} - I_{zx}(r^2 - p^2) - (I_{zz} - I_{xx})rp \\ \dot{r}I_{zx} - I_{zx}(\dot{p} - qr) - (I_{xx} - I_{yy})pq \end{bmatrix} \end{aligned} \quad (2.15)$$

Rearranjando alguns termos da [Equação 2.15](#), resulta que:

$$L = I_{xx}\dot{p} - I_{zx}(\dot{r} + pq) - (I_{yy} - I_{zz})qr \quad (2.16)$$

$$M = I_{yy}\dot{q} - I_{zx}(r^2 - p^2) - (I_{zz} - I_{xx})rp \quad (2.17)$$

$$N = I_{zz}\dot{r} - I_{zx}(\dot{p} - qr) - (I_{xx} - I_{yy})pq \quad (2.18)$$

As equações de [2.6](#) a [2.8](#) e de [2.16](#) a [2.18](#) formam o sistema de equações diferenciais ordinárias não-lineares que descreve o movimento de seis graus de liberdade de um helicóptero com estrutura rígida. Para o desenvolvimento dessas equações, levou-se em consideração que o centro de gravidade coincide com a origem do sistema de eixos

do helicóptero, e que os eixos x e z pertencem ao plano de simetria da aeronave, ou seja, $I_{yz} = I_{yx} = 0$. Por fim, as rotações que relacionam o sistema inercial (fixo) com o sistema de coordenadas ligado ao corpo são obtidas pelos ângulos de Euler:

$$\dot{\phi} = p + q \sin \phi \tan \theta + r \cos \phi \tan \theta \quad (2.19)$$

$$\dot{\theta} = q \cos \phi - r \sin \phi \quad (2.20)$$

$$\dot{\psi} = q \sin \phi \sec \theta + r \cos \phi \sec \theta \quad (2.21)$$

2.1.1 Modelo Linearizado

A linearização das equações do movimento por série de Taylor das equações 2.6 a 2.8 e de 2.16 a 2.18 é apresentado a seguir e os detalhes desse procedimento estão em (PROUTY, 1995) e (COOKE; FITZPATRICK, 2002). Considera-se que os deslocamentos de comando, a partir da condição inicial estabilizada, são dados por δ_B (comando cíclico longitudinal), δ_C (comando de passo coletivo), δ_A (comando de cíclico lateral) e δ_P (comando de pedal).

$$\begin{aligned} X_u \Delta u + X_v \Delta v + X_w \Delta w + X_q \Delta q + X_p \Delta p + X_r \Delta r + X_{\delta_C} \Delta \delta_C + \\ X_{\delta_P} \Delta \delta_P + X_{\delta_A} \Delta \delta_A + X_{\delta_B} \Delta \delta_B = m(\Delta \dot{u} + \Delta q w_0) \end{aligned} \quad (2.22)$$

$$\begin{aligned} Y_u \Delta u + Y_v \Delta v + Y_w \Delta w + Y_q \Delta q + Y_p \Delta p + Y_r \Delta r + Y_{\delta_C} \Delta \delta_C + \\ Y_{\delta_P} \Delta \delta_P + Y_{\delta_A} \Delta \delta_A + Y_{\delta_B} \Delta \delta_B = m(\Delta \dot{v} - \Delta p w_0 + \Delta r u_0) \end{aligned} \quad (2.23)$$

$$\begin{aligned} Z_u \Delta u + Z_v \Delta v + Z_w \Delta w + Z_q \Delta q + Z_p \Delta p + Z_r \Delta r + Z_{\delta_C} \Delta \delta_C + \\ Z_{\delta_P} \Delta \delta_P + Z_{\delta_A} \Delta \delta_A + Z_{\delta_B} \Delta \delta_B = m(\Delta \dot{w} - \Delta q u_0) \end{aligned} \quad (2.24)$$

$$\begin{aligned} L_u \Delta u + L_v \Delta v + L_w \Delta w + L_q \Delta q + L_p \Delta p + L_r \Delta r + L_{\delta_C} \Delta \delta_C + \\ L_{\delta_P} \Delta \delta_P + L_{\delta_A} \Delta \delta_A + L_{\delta_B} \Delta \delta_B = I_{xx} \Delta \dot{p} - I_{zx} \Delta \dot{r} \end{aligned} \quad (2.25)$$

$$\begin{aligned} M_u \Delta u + M_v \Delta v + M_w \Delta w + M_q \Delta q + M_p \Delta p + M_r \Delta r + \\ M_{\delta_C} \Delta \delta_C + M_{\delta_P} \Delta \delta_P + M_{\delta_A} \Delta \delta_A + M_{\delta_B} \Delta \delta_B = I_{yy} \Delta \dot{q} \end{aligned} \quad (2.26)$$

$$N_u \Delta u + N_v \Delta v + N_w \Delta w + N_q \Delta q + N_p \Delta p + N_r \Delta r + N_{\delta_C} \Delta \delta_C + N_{\delta_P} \Delta \delta_P + N_{\delta_A} \Delta \delta_A + N_{\delta_B} \Delta \delta_B = I_{zz} \Delta \dot{r} - I_{zx} \Delta \dot{p} \quad (2.27)$$

onde se utiliza a notação de $X_u = \frac{\partial X}{\partial u}$ e, assim sucessivamente, para as derivadas de estabilidade e controle e Δ representa a variação incremental em termo de uma condição inicial estabilizada. Finalmente, as equações linearizadas escritas na forma matricial:

$$\dot{x} = Ax + B\delta \quad (2.28)$$

onde x representa as perturbações a partir do equilíbrio das variáveis de estado e δ representa os deslocamentos de comando de voo:

$$x = [\Delta u \quad \Delta w \quad \Delta q \quad \Delta \theta \quad \Delta v \quad \Delta p \quad \Delta \phi \quad \Delta r]^T \quad (2.29)$$

$$\delta = [\Delta \delta_B \quad \Delta \delta_C \quad \Delta \delta_A \quad \Delta \delta_P]^T \quad (2.30)$$

$$A = \begin{bmatrix} \frac{X_u}{m} & \frac{X_w}{m} & \frac{X_q}{m} - w_0 & -g \cos \theta_0 & \frac{X_v}{m} & \frac{X_p}{m} & 0 & \frac{X_r}{m} + v_0 \\ \frac{Z_u}{m} & \frac{Z_w}{m} & \frac{Z_q}{m} + u_0 & -g \cos \phi_0 \sin \theta_0 & \frac{Z_v}{m} & \frac{Z_p}{m} - v_0 & -g \sin \phi_0 \cos \theta_0 & \frac{Z_r}{m} \\ \frac{M_u}{I_{yy}} & \frac{M_w}{I_{yy}} & \frac{M_q}{I_{yy}} & 0 & \frac{M_v}{I_{yy}} & \frac{M_p}{I_{yy}} & 0 & \frac{M_r}{I_{yy}} \\ 0 & 0 & \cos \phi_0 & 0 & 0 & 0 & 0 & -\sin \phi_0 \\ \frac{Y_u}{m} & \frac{Y_w}{m} & \frac{Y_q}{m} & -g \sin \phi_0 \sin \theta_0 & \frac{Y_v}{m} & \frac{Y_p}{m} + w_0 & g \cos \phi_0 \cos \theta_0 & \frac{Y_r}{m} - u_0 \\ L'_u & L'_w & L'_q & 0 & L'_v & L'_p & 0 & L'_r \\ 0 & 0 & \sin \phi_0 \tan \theta_0 & 0 & 0 & 1 & 0 & \cos \phi_0 \tan \theta_0 \\ N'_u & N'_w & N'_q & 0 & N'_v & N'_p & 0 & N'_r \end{bmatrix} \quad (2.31)$$

$$B = \begin{bmatrix} \frac{X_{\delta_B}}{m} & \frac{X_{\delta_C}}{m} & \frac{X_{\delta_A}}{m} & \frac{X_{\delta_P}}{m} \\ \frac{Z_{\delta_B}}{m} & \frac{Z_{\delta_C}}{m} & \frac{Z_{\delta_A}}{m} & \frac{Z_{\delta_P}}{m} \\ \frac{M_{\delta_B}}{I_{yy}} & \frac{M_{\delta_C}}{I_{yy}} & \frac{M_{\delta_A}}{I_{yy}} & \frac{M_{\delta_P}}{I_{yy}} \\ 0 & 0 & 0 & 0 \\ \frac{Y_{\delta_B}}{m} & \frac{Y_{\delta_C}}{m} & \frac{Y_{\delta_A}}{m} & \frac{Y_{\delta_P}}{m} \\ L'_{\delta_B} & L'_{\delta_C} & L'_{\delta_A} & L'_{\delta_P} \\ 0 & 0 & 0 & 0 \\ N'_{\delta_B} & N'_{\delta_C} & N'_{\delta_A} & N'_{\delta_P} \end{bmatrix} \quad (2.32)$$

As matrizes A e B correspondem, respectivamente, a matriz que contém as derivadas de estabilidade e a matriz de controle. Pode-se entender por estabilidade a tendência da aeronave retornar a sua posição de equilíbrio após qualquer perturbação sofrida. Para o caso de uma aeronave, a garantia da estabilidade está diretamente relacionada ao conforto, controlabilidade (habilidade da aeronave em responder os comandos do piloto) e segurança de voo (RODRIGUES, 2015).

Assim, o modelo completo com os modos acoplados (longitudinais: curto-período e fugíde e látero-direcionais: rolamento, espiral e *dutch-roll*) pode ser obtido substituindo as equações 2.29 a 2.32 em 2.28 resultando em:

$$\begin{bmatrix} \Delta \dot{u} \\ \Delta \dot{w} \\ \Delta \dot{q} \\ \Delta \dot{\theta} \\ \Delta \dot{v} \\ \Delta \dot{p} \\ \Delta \dot{\phi} \\ \Delta \dot{r} \end{bmatrix} = \begin{bmatrix} \frac{X_u}{m} & \frac{X_w}{m} & \frac{X_q}{m} - w_0 & -g \cos \theta_0 & \frac{X_v}{m} & \frac{X_p}{m} & 0 & \frac{X_r}{m} + v_0 \\ \frac{Z_u}{m} & \frac{Z_w}{m} & \frac{Z_q}{m} + u_0 & -g \cos \phi_0 \sin \theta_0 & \frac{Z_v}{m} & \frac{Z_p}{m} - v_0 & -g \sin \phi_0 \cos \theta_0 & \frac{Z_r}{m} \\ \frac{M_u}{m} & \frac{M_w}{m} & \frac{M_q}{m} & 0 & \frac{M_v}{m} & \frac{M_p}{m} & 0 & \frac{M_r}{m} \\ \frac{I_{yy}}{m} & \frac{I_{yy}}{m} & \frac{I_{yy}}{m} & 0 & \frac{I_{yy}}{m} & \frac{I_{yy}}{m} & 0 & \frac{I_{yy}}{m} \\ 0 & 0 & \cos \phi_0 & 0 & 0 & 0 & 0 & -\sin \phi_0 \\ \frac{Y_u}{m} & \frac{Y_w}{m} & \frac{Y_q}{m} & -g \sin \phi_0 \sin \theta_0 & \frac{Y_v}{m} & \frac{Y_p}{m} + w_0 & g \cos \phi_0 \cos \theta_0 & \frac{Y_r}{m} - u_0 \\ \frac{L'_u}{m} & \frac{L'_w}{m} & \frac{L'_q}{m} & 0 & \frac{L'_v}{m} & \frac{L'_p}{m} & 0 & \frac{L'_r}{m} \\ 0 & 0 & \sin \phi_0 \tan \theta_0 & 0 & 0 & 1 & 0 & \cos \phi_0 \tan \theta_0 \\ N'_u & N'_w & N'_q & 0 & N'_v & N'_p & 0 & N'_r \end{bmatrix} \begin{bmatrix} \Delta u \\ \Delta w \\ \Delta q \\ \Delta \theta \\ \Delta v \\ \Delta p \\ \Delta \phi \\ \Delta r \end{bmatrix} + \begin{bmatrix} \frac{X_{\delta_B}}{m} & \frac{X_{\delta_C}}{m} & \frac{X_{\delta_A}}{m} & \frac{X_{\delta_P}}{m} \\ \frac{Z_{\delta_B}}{m} & \frac{Z_{\delta_C}}{m} & \frac{Z_{\delta_A}}{m} & \frac{Z_{\delta_P}}{m} \\ \frac{M_{\delta_B}}{m} & \frac{M_{\delta_C}}{m} & \frac{M_{\delta_A}}{m} & \frac{M_{\delta_P}}{m} \\ \frac{I_{yy}}{m} & \frac{I_{yy}}{m} & \frac{I_{yy}}{m} & \frac{I_{yy}}{m} \\ 0 & 0 & 0 & 0 \\ \frac{Y_{\delta_B}}{m} & \frac{Y_{\delta_C}}{m} & \frac{Y_{\delta_A}}{m} & \frac{Y_{\delta_P}}{m} \\ \frac{L'_{\delta_B}}{m} & \frac{L'_{\delta_C}}{m} & \frac{L'_{\delta_A}}{m} & \frac{L'_{\delta_P}}{m} \\ 0 & 0 & 0 & 0 \\ N'_{\delta_B} & N'_{\delta_C} & N'_{\delta_A} & N'_{\delta_P} \end{bmatrix} \begin{bmatrix} \delta_B \\ \delta_C \\ \delta_A \\ \delta_P \end{bmatrix} \quad (2.33)$$

O modo longitudinal possui o curto período que é tipicamente uma oscilação amortecida de arfagem em torno do eixo Y, e a fugíde que, na grande maioria dos casos, trata-se de uma oscilação de baixa frequência ligeiramente amortecida na velocidade u , acoplada com a atitude longitudinal θ e com a altitude h . Enquanto, no modo látero-direcional apresenta o rolamento que é um movimento lateral de caráter não oscilatório, sendo, de uma maneira geral, substancialmente desacoplado dos modos *dutch-roll* e espiral. O modo espiral desenvolve-se de forma lenta, envolvendo um movimento de acoplamento complexo entre o rolamento, a guinada e a derrapagem. Por fim, o *dutch-roll* é uma oscilação clássica amortecida de guinada em torno do eixo Z. Fundamentalmente, o modo *dutch-roll* é o equivalente látero-direcional do modo longitudinal de curto período (VIANA, 2011).

Finalmente, a Equação 2.33 quando desacoplada apresenta respectivamente os modos longitudinal (Equação 2.34) e látero-direcional (Equação 2.35) que serão utili-

zados no Capítulo 5, conforme abaixo:

$$\begin{bmatrix} \Delta \dot{u} \\ \Delta \dot{w} \\ \Delta \dot{q} \\ \Delta \dot{\theta} \end{bmatrix} = \begin{bmatrix} \frac{X_u}{m} & \frac{X_w}{m} & \frac{X_q}{m} - w_0 & -g \cos \theta_0 \\ \frac{Z_u}{m} & \frac{Z_w}{m} & \frac{Z_q}{m} + u_0 & -g \cos \phi_0 \sin \theta_0 \\ \frac{M_u}{I_{yy}} & \frac{M_w}{I_{yy}} & \frac{M_q}{I_{yy}} & 0 \\ 0 & 0 & \cos \phi_0 & 0 \end{bmatrix} \begin{bmatrix} \Delta u \\ \Delta w \\ \Delta q \\ \Delta \theta \end{bmatrix} + \begin{bmatrix} \frac{X_{\delta_B}}{m} & \frac{X_{\delta_C}}{m} \\ \frac{Z_{\delta_B}}{m} & \frac{Z_{\delta_C}}{m} \\ \frac{M_{\delta_B}}{I_{yy}} & \frac{M_{\delta_C}}{I_{yy}} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \delta_B \\ \delta_C \end{bmatrix} \quad (2.34)$$

$$\begin{bmatrix} \Delta \dot{v} \\ \Delta \dot{p} \\ \Delta \dot{\phi} \\ \Delta \dot{r} \end{bmatrix} = \begin{bmatrix} \frac{Y_v}{m} & \frac{Y_p}{m} + w_0 & g \cos \phi_0 \cos \theta_0 & \frac{Y_r}{m} - u_0 \\ L'_v & L'_p & 0 & L'_r \\ 0 & 1 & 0 & \cos \phi_0 \tan \theta_0 \\ N'_v & N'_p & 0 & N'_r \end{bmatrix} \begin{bmatrix} \Delta v \\ \Delta p \\ \Delta \phi \\ \Delta r \end{bmatrix} + \begin{bmatrix} \frac{Y_{\delta_A}}{m} & \frac{Y_{\delta_P}}{m} \\ L'_{\delta_A} & L'_{\delta_P} \\ 0 & 0 \\ N'_{\delta_A} & N'_{\delta_P} \end{bmatrix} \begin{bmatrix} \delta_A \\ \delta_P \end{bmatrix} \quad (2.35)$$

2.2 Modelo do Rotor

Os helicópteros, assim como os aviões, possuem sua sustentação gerada pelo efeito do fluxo de ar em uma superfície aerodinâmica. Enquanto os aviões precisam de velocidade à frente para gerar sustentação nas asas, o vento relativo nos helicópteros é criado pela rotação das pás. Essa característica permite aos helicópteros levantarem voo sem se deslocarem. A rotação das pás é tão importante para os helicópteros quanto a velocidade é para os aviões (SILVA, 2013). Entretanto, o rotor é a principal fonte de vibração, devido às suas dimensões e espectro de emissão vibratória.

Figura 2.3 - Helicóptero Após a Ocorrência do Fenômeno de Ressonância Solo.



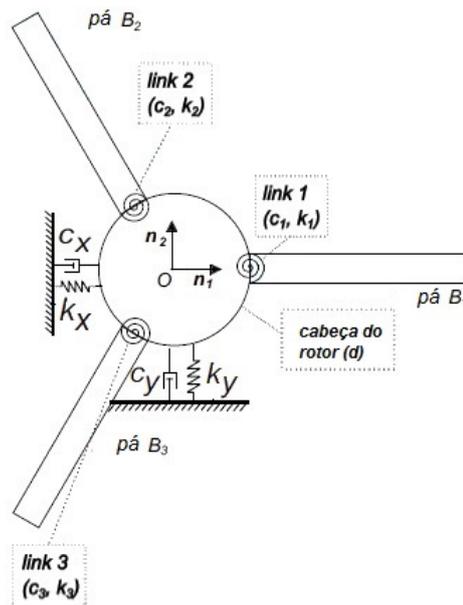
Fonte: Hangar33 (2015)

A vibração no rotor principal pode levar a um fenômeno conhecido como ressonância solo, que pode ser responsável por causar a destruição total da aeronave, como ilustra a Figura 2.3. Este fenômeno ocorre geralmente durante o pouso, decolagem e

manobras próximas ao solo e é causado pela interação entre as pás do rotor principal e a estrutura da fuselagem (LEE; KIM, 2010).

A seguir, será apresentado o modelo do rotor de um helicóptero com três pás que foi utilizado neste trabalho (GONZAGA, 2013). Para a dedução das equações são feitas as seguintes hipóteses simplificadoras: o movimento ocorre apenas no plano (x, y) , (2) as pás são barras rígidas, (3) a cabeça do rotor é um cilindro rígido com velocidade de rotação constante, e (4) apenas os primeiros modos axial/lateral do helicóptero são levados em consideração. Com tais hipóteses, o sistema possui cinco graus de liberdade (DOF): os deslocamentos x e y do centro de massa da cabeça do rotor e os ângulos das pás β_i ($i = 1, \dots, N$), onde N é o número de pás, neste trabalho $N = 3$. A Figura 2.4 mostra o esquema geral do modelo proposto.

Figura 2.4 - Sistema de Coordenadas para o Rotor do Helicóptero.



Fonte: Gonzaga (2013)

As pás estão ligadas na cabeça do rotor através de um ponto chamado de *link* e distante d da origem O que é o centro geométrico da cabeça do rotor. Em cada *link*, existe uma mola de torção linear e amortecimento.

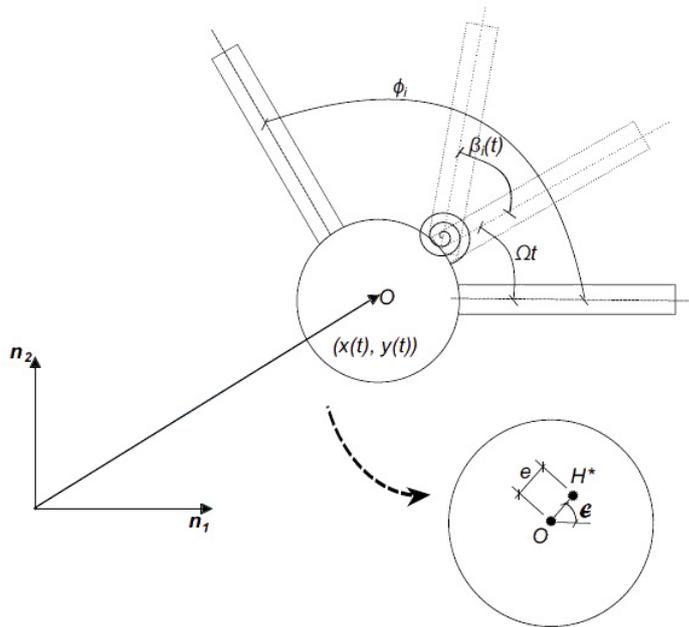
Considerando um referencial inercial, com base fixa $\{\mathbf{n}_1, \mathbf{n}_2\}$, e um sistema de coordenadas cartesianas com origem O . A posição do centro de massa da cabeça do

rotor H^* em relação à origem (O) pode ser escrita como:

$$OrH^*(t) = [x(t) + e \cos(\epsilon + \Omega t)]\mathbf{n}_1 + [y(t) + e \sin(\epsilon + \Omega t)]\mathbf{n}_2 \quad (2.36)$$

onde x é o deslocamento do centro geométrico da cabeça do rotor na direção de \mathbf{n}_1 , y é o deslocamento do centro geométrico da cabeça do rotor na direção de \mathbf{n}_2 , Ω é a velocidade de rotação constante da cabeça do rotor, e é a excentricidade da cabeça do rotor, ϵ é o ângulo da excentricidade (Figura 2.5).

Figura 2.5 - Posição Angular das Pás



Fonte: Gonzaga (2013)

Considerando que cada pá tem um ângulo de fase (ϕ_i), ou azimute, a posição do centro de massa da pá B_i em relação a O pode ser escrita como:

$$\begin{aligned} OrB_i(t) = & [x(t) + d \cos(\phi + \Omega t) + \left(\frac{hB_i}{2}\right) \cos(\phi + \Omega t + \beta_i(t))]\mathbf{n}_1 \\ & + [y(t) + d \sin(\phi + \Omega t) + \left(\frac{hB_i}{2}\right) \sin(\phi + \Omega t + \beta_i(t))]\mathbf{n}_2 \end{aligned} \quad (2.37)$$

onde h_{B_i} é o comprimento da pá i -th e β_i é o ângulo da pá i -th na direção de \mathbf{n}_3 .

A partir das definições descritas acima tem-se que o momento linear total é composto pelo momento linear da cabeça do rotor mais o momento linear das pás que é dado

por:

$$\mathbf{G}_H = m_H \mathbf{v}_{H^*} \quad (2.38)$$

onde \mathbf{v}_{H^*} é a velocidade do centro de massa da cabeça do rotor, que é a derivada da posição O_{H^*} em relação à estrutura inercial de referência. E o momento linear da pá i -th é dado por:

$$\mathbf{G}_{B_i} = m_{B_i} \mathbf{v}_{B_i} \quad (2.39)$$

onde \mathbf{v}_{B_i} é a velocidade do centro de massa da pá i -th, que é a derivada da posição O_{rB_i} em relação à estrutura inercial de referência. O momento linear total do sistema, se todas as pás tiverem a mesma massa, é então definido por:

$$\mathbf{G}_T = \mathbf{G}_H + \sum_{n=1}^N \mathbf{G}_{B_i} = m_H \mathbf{v}_{H^*} + m_B \sum_{n=1}^N \mathbf{v}_{B_i} \quad (2.40)$$

Depois de algumas manipulações, as duas primeiras equações de movimento do sistema são:

$$\begin{aligned} (Nm_B + m_H)\ddot{x}(t) + c_x \dot{x}(t) + k_x x(t) = em_H \Omega^2 \cos(\epsilon + \Omega t) + \\ dm_B \Omega^2 \sum_{n=1}^N \cos(\phi_i + \Omega t) + m_B \left(\frac{h_B}{2}\right) \sum_{n=1}^N [\ddot{\beta}_i(t) \sin(\phi_i + \Omega t + \beta_i(t)) + \\ (\Omega + \dot{\beta}_i(t))^2 \cos(\phi_i + \Omega t + \beta_i(t))] \end{aligned} \quad (2.41)$$

$$\begin{aligned} (Nm_B + m_H)\ddot{y}(t) + c_y \dot{y}(t) + k_y y(t) = em_H \Omega^2 \sin(\epsilon + \Omega t) + \\ dm_B \Omega^2 \sum_{n=1}^N \sin(\phi_i + \Omega t) + m_B \left(\frac{h_B}{2}\right) \sum_{n=1}^N [-\ddot{\beta}_i(t) \cos(\phi_i + \Omega t + \beta_i(t)) + \\ (\Omega + \dot{\beta}_i(t))^2 \sin(\phi_i + \Omega t + \beta_i(t))] \end{aligned} \quad (2.42)$$

Como o sistema possui $N+2$ graus de liberdade ($x(t)$, $y(t)$, $\beta(t)$) é necessário obter as demais equações. Como nessa modelagem não há o interesse nas forças de interação entre os corpos rígidos, será calculado o momento angular em relação a cada *link*. A dificuldade é que o *link* é um ponto móvel não coincidente com o centro de massa. Assim, aplicando a lei de Euler:

$$\mathbf{M}_{L_i}^{B_i} = \frac{d\mathbf{I}_{L_i}^{B_i} \boldsymbol{\omega}}{dt} + (m_{B_i}) L_i \mathbf{r}_{B_i^*} \times \mathbf{a}_{L_i} \quad (2.43)$$

onde $\mathbf{M}_{L_i}^{B_i}$ é o vetor de momentos externos atuando na pá i -th com relação ao link L_i . O tensor de inércia angular da pá i -th em relação ao link L_i é $\mathbf{I}_{L_i}^{B_i}$, $L_i \mathbf{r}_{B_i}$ é a

posição do centro de massa da pá i -th com relação a L_i e \mathbf{a}_{L_i} é a aceleração de L_i . Observe que o termo adicional à direita da equação acima aparece porque o ponto L_i tem uma aceleração que não é zero. O vetor de momentos externos que atuam sobre a pá i é dado por:

$$\mathbf{M}_{L_i}^{B_i} = [-c_i \dot{\beta}_i(t) - k_i \beta_i(t) - m_{B_i} g \left(\frac{h_{B_i}}{2} \right) \cos(\phi_i + \Omega(t) + \beta_i(t))] \mathbf{b}_3 \quad (2.44)$$

onde k_i e c_i são i -th rigidez da pá e coeficientes de amortecimento. A posição do centro de massa da pá i -th em relação a L_i pode ser escrita como:

$$L_i r_{B_i}(t) = \left[\left(\frac{h_{B_i}}{2} \right) \cos(\phi_i + \Omega(t) + \beta_i(t)) \right] \mathbf{n}_1 + \left[\left(\frac{h_{B_i}}{2} \right) \sin(\phi_i + \Omega(t) + \beta_i(t)) \right] \mathbf{n}_2 \quad (2.45)$$

e a aceleração do *link* é dada por:

$$\mathbf{a}_{L_i}(t) = [\ddot{x}(t) - d\Omega^2 \cos(\phi_i + \Omega(t))] \mathbf{n}_1 + [\ddot{y}(t) - d\Omega^2 \sin(\phi_i + \Omega(t))] \mathbf{n}_2 . \quad (2.46)$$

Finalmente, após algumas manipulações, as N equações de movimento adicionais do sistema ($i = 1, \dots, N$) são:

$$\begin{aligned} \frac{1}{3} m_{B_i} h_{B_i}^2 \ddot{\beta}_i(t) + c_i \dot{\beta}_i(t) + k_i \beta_i(t) + m_{B_i} \frac{h_{B_i}}{2} d\Omega^2 \sin \beta_i + \\ m_{B_i} g \frac{h_{B_i}}{2} \cos(\phi_i + \Omega t + \beta_i(t)) = m_{B_i} \frac{h_{B_i}}{2} [\ddot{x}(t) \sin(\phi_i + \Omega t + \beta_i(t)) - \\ \ddot{y}(t) \cos(\phi_i + \Omega t + \beta_i(t))] \end{aligned} \quad (2.47)$$

Definindo $N = 3$ (sistema de três pás), as cinco equações de movimento do modelo proposto são dadas pelas Eqs. 2.41, 2.42 e 2.47, que formam um conjunto de equações diferenciais ordinárias não lineares, de segunda ordem acopladas, que devem ser resolvidas numericamente.

2.2.1 Teste para Dinâmica Caótica

Os sistemas não lineares são amplamente utilizados para modelar diversos tipos de sistemas reais desde fenômenos epidemiológicos, movimentos populacionais e sociais e problemas de engenharia (CHANG, 2013; MORAES, 2012; YAMASHITA, 2014; THOMAS et al., 2005). Em 1963, Edward Lorenz (LORENZ, 1963) estudou equações não lineares que descrevem a formação de ventos na atmosfera. Ele descobriu que uma pequena alteração nas condições iniciais leva a resultados muito diferentes na resposta do sistema. Esta propriedade é chamada de dependência sensível das condições iniciais e é uma das características mais importantes dos sistemas caóticos.

Uma das abordagens mais utilizada para identificar se a dinâmica é regular ou

caótica é realizada através do cálculo do expoente de Lyapunov; o sistema é caótico se o expoente for positivo (TAKENS, 1981; WOLF et al., 1985). Na teoria de caos determinístico, há outras técnicas/ferramentas para caracterização de um regime caótico, como a entropia de Kolmogorov-Sinai e o cálculo da dimensão fractal do atrator, dentre outros (FIEDLER-FERRARA; PRADO, 1994).

Recentemente, uma abordagem para detectar a presença de caos em sistemas dinâmicos foi proposta por Gottwald e Melbourne (2004), Gottwald e Melbourne (2005), que tornou-se conhecida como Teste 0-1. Trata-se de um dos métodos mais simples para detectar o caos e foi testado com sucesso para vários sistemas discretos ou contínuos (DEVI et al., 2013; LITAK; SAWICKI, 2013; PICCIRILLO et al., 2015). No Teste 0-1, a entrada é uma série temporal e a saída é um valor real entre 0 e 1. A resposta do teste com valores próximos de zero (0) correspondem a uma dinâmica regular ou periódica e valores próximos de 1 para dinâmica caótica.

Dada a entrada do teste uma série temporal $\phi(n)$ para $n = 1, 2, \dots, N$, as variáveis de translação p_c e q_c (GOTTWALD; MELBOURNE, 2009):

$$\begin{aligned} p_c(n) &= \sum_{j=1}^n \phi(j) \cos(jc), \\ q_c(n) &= \sum_{j=1}^n \phi(j) \sin(jc), \end{aligned} \quad (2.48)$$

para $c \in (0, 2\pi)$. Por hipótese as funções $p_c(n)$ e $q_c(n)$ são limitadas se o sistema dinâmico for regular e caso a dinâmica seja caótica, $p_c(n)$ e $q_c(n)$ se comportam assintoticamente como um movimento browniano. O crescimento das funções $p_c(n)$ e $q_c(n)$ pode ser determinado através do desvio médio quadrático $M_c(n)$ dado por:

$$M_c(n) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{j=1}^N [(p_c(j+n) - p_c(j))]^2 + [(q_c(j+n) - q_c(j))]^2 \quad (2.49)$$

E para verificar se o sistema dinâmico tem comportamento regular ou caótico, no Teste 0-1 emprega-se a taxa de crescimento assintótica K do desvio médio quadrático $M(n)$ dado por:

$$K = \lim_{N \rightarrow \infty} \frac{\log M(n)}{\log n} \quad (2.50)$$

Para uma série de tempo discreta proveniente de um sistema contínuo no tempo, tem $x(j) = \phi(t_j) = \phi(j\delta t)$, sendo $\delta t > 0$ é o tempo de amostragem. A sobreamostragem ocorre quando δt é muito pequeno. Isto pode levar a resultados de K errados, pois a convergência de K pode se tornar lenta e como o tempo da série é finito isso se torna um problema. Um bom método para se evitar a sobreamostragem é discretizar a série de tal forma que δt seja igual ao valor do primeiro mínimo da informação mútua da série em questão (GOTTWALD; MELBOURNE, 2009).

Há vantagens deste teste sobre outras técnicas. Por exemplo, o Teste 0-1 não requer a reconstrução do espaço de fase, ele é aplicado diretamente aos dados da série temporal. Este teste não requer portanto o conhecimento das equações matemáticas do sistema dinâmico e pode ser aplicado tanto para dados obtidos por modelos matemáticos, como para dados de experimentos; pode ser aplicado em sistemas de tempo contínuo ou discreto, e é um teste simples onde a saída é um valor real entre 0 e 1 (para uma entrada do tipo série temporal), tornando simples a interpretação do resultado (GOTTWALD; MELBOURNE, 2005).

3 *BRED VECTOR* NO ESTUDO DE SISTEMAS DINÂMICOS

Este capítulo descreve a metodologia *bred vector* que foi desenvolvida por Toth e Kalnay (1993) no início dos anos 90. Além disso, será abordado seu funcionamento e uma aplicação em sistemas dinâmicos para previsão do comportamento em sistemas caóticos será apresentado.

3.1 Descrição da Metodologia *Bred Vector*

A técnica de *bred vector* ou *breeding method* foi formulada e implementada por Toth e Kalnay (1993) e tem sido muito utilizada em assimilação de dados, modelos atmosféricos (TOTH; KALNAY, 1997; CORAZZA et al., 2003) etc.

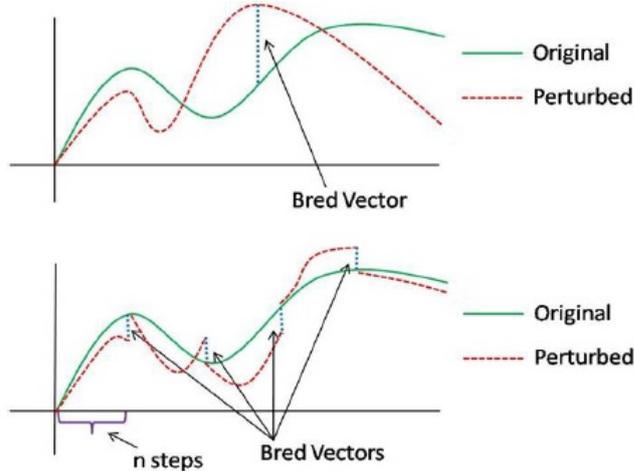
Nesta metodologia, os *bred vectors* são calculados dinamicamente a partir do modelo não linear que é executado duas vezes. Na primeira vez, o modelo é executado com os dados originais (*control run*), em seguida, outra execução é realizada com uma pequena perturbação adicionada aos dados do modelo. Após um número fixo de passos de tempo, a diferença entre as duas execuções é o *bred vector* ou a magnitude do *bred vector*. O algoritmo que descreve essa metodologia é composto pelos seguintes passos:

- a) Adicionar uma perturbação pequena e arbitrária para a análise do sistema (estado inicial), sendo t_0 o tempo inicial;
- b) Integrar ambos os modelos, o que sofreu a perturbação e o que não sofreu para um intervalo de tempo $(t_1 - t_0)$;
- c) Subtrair os resultados obtidos entre os modelos (este resultado é o *bred vector*);
- d) Reduzir o campo de diferença de modo que tenha a mesma norma como perturbação inicial. (Normalização do *bred vectors*);
- e) Adicionar esta perturbação à próxima análise (tempo t_1);
- f) Repetir (b) - (e) nos tempos subsequentes.

Nota-se que, uma vez que a perturbação inicial é introduzida no passo (a), o desenvolvimento do campo de perturbação é determinado dinamicamente pelo fluxo de evolução do sistema (TOTH; KALNAY, 1997). Através das sucessivas aplicações e comparações com os resultados esperados (sem perturbação) é possível inferir alguns

padrões e até mesmo algumas regras sobre o comportamento do sistema. A Figura 3.1 ilustra as trajetórias original e perturbada e a diferença entre as duas após n passos de tempo que são os *bred vectors*.

Figura 3.1 - Bred Vectors



Fonte: Evans et al. (2004)

3.2 Aplicação da Metodologia no Atrator de Lorenz

No trabalho desenvolvido em Evans et al. (2004), os autores utilizaram a metodologia de *bred vector* para realizar a previsão do comportamento no atrator de Lorenz. Em 1963, o meteorologista americano Edward Lorenz apresentou um modelo matemático para descrever a formação de ventos na atmosfera. Em sua pesquisa, ele usou três equações para representar graficamente o comportamento dinâmico, e verificou que a partir de estados iniciais ligeiramente diferentes, o sistema de equações diferenciais resultava em soluções completamente diferentes entre si (LORENZ, 1963).

A partir deste trabalho Lorenz dedicou-se a entender o que estava acontecendo e percebeu que pequenas variações nos valores iniciais das variáveis de seu modelo resultavam em valores muito divergentes. Em sistemas dinâmicos, estes resultados dizem respeito à evolução temporal como função de seus parâmetros e variáveis. Assim, o sistema de Lorenz consiste nas seguintes três equações diferenciais ordinárias

de primeira ordem, acopladas (LORENZ, 1963):

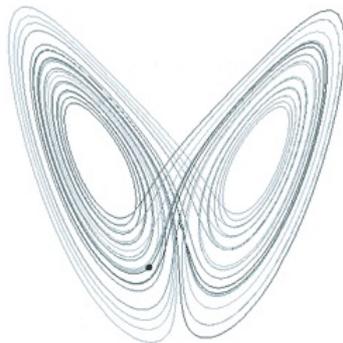
$$\frac{dx}{dt} = -\sigma x - y \quad (3.1)$$

$$\frac{dy}{dt} = -\rho x - y - xz \quad (3.2)$$

$$\frac{dz}{dt} = xy - \beta z \quad (3.3)$$

Nas equações acima, utilizando os parâmetros $\sigma = 10$, $\rho = 28$ e $\beta = 8/3$, suas soluções numéricas levam a um atrator imerso em um espaço tridimensional com coordenadas (x, y, z) , como mostra a Figura 3.2.

Figura 3.2 - Sistema de Lorenz

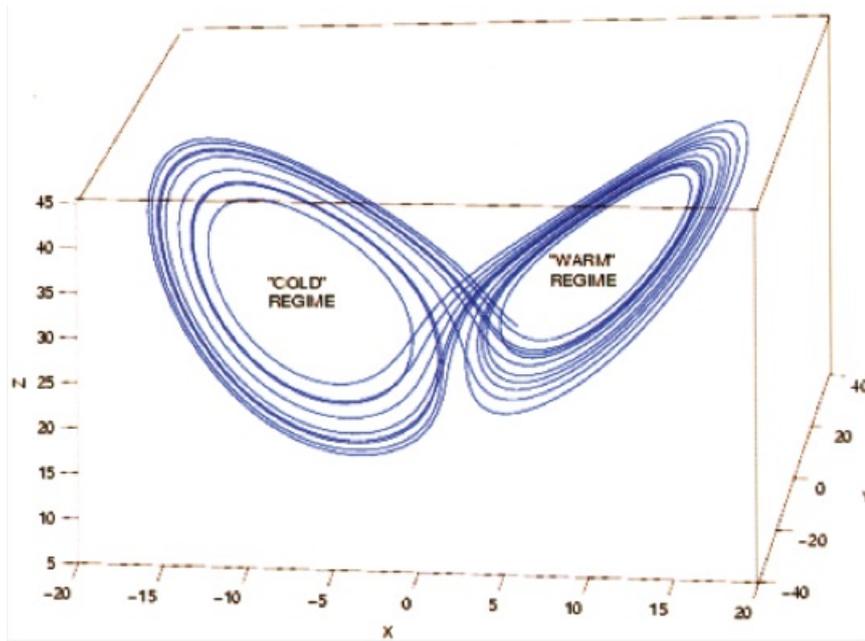


Analisando a Figura 3.2 os autores Evans et al. (2004) identificaram a formação de duas regiões nesse sistema as quais foram denominadas de Regime Quente (*Warm Regime*) e Regime Frio (*Cold Regime*) como mostra a Figura 3.3.

Após essa análise foi aplicada a metodologia de *bred vector* como mostra a Figura 3.4. Nesta Figura (3.4), cada estrela colorida é uma amostra do tamanho do *bred vector* após 8 passos (pontos), ou seja, a distância do ponto com perturbação em relação ao ponto da trajetória original. Cada cor significa a magnitude do *bred vector* nas seguintes faixas de valores:

- Azul: *bred vector* menor que 0. Neste caso significa que a trajetória perturbada está se aproximando da trajetória original;
- Verde: *bred vector* maior que 0 e menor ou igual 0,032;
- Amarelo: *bred vector* maior que 0,032 e menor ou igual 0,064;

Figura 3.3 - Regimes no Sistema de Lorenz



Fonte: Evans et al. (2004)

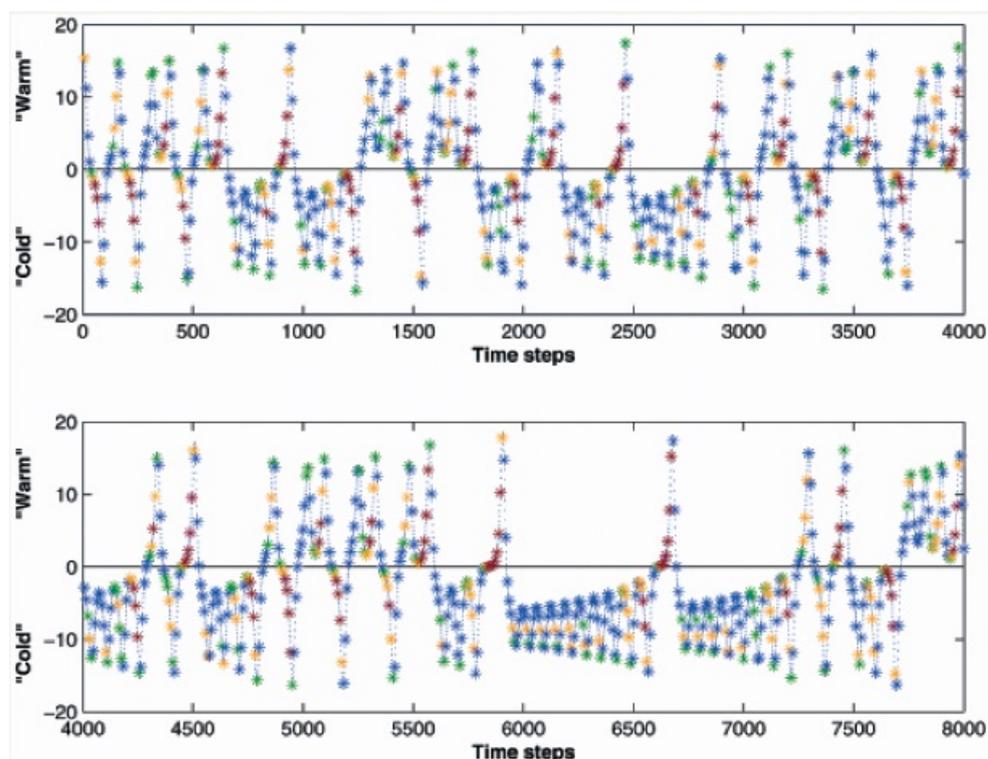
- Vermelho: *bred vector* maior que 0,064.

Um pico no gráfico na Figura 3.4 é a representação de um volta na órbita no atrator (Figura 6.4). Os autores, através da observação e contando manualmente o número de estrelas em cada volta, conseguiram identificar padrões e definiram as seguintes regras:

Regra 1: A presença de uma ou mais estrelas vermelhas (Figura 3.4), ou seja, a taxa de crescimento é superior a 0,064 após um período de 8 passos, indica que o atual regime terminará após completar a órbita atual.

Regra 2: O comprimento do novo regime é proporcional ao número de estrelas vermelhas. Por exemplo, a presença de cinco ou mais estrelas no antigo regime, implica que o novo regime vai durar quatro órbitas ou mais.

Figura 3.4 - Série Temporal $x(t)$ em Função do Número de Passos



Fonte: Evans et al. (2004)

Outros trabalhos desenvolvidos nesta área foram Cintra e Velho (2008) que aplicaram a metodologia de *bred vector* no modelo de três ondas acopladas onde foram identificados padrões para realizar a previsibilidade sobre o comportamento desse sistema e Santos (2014) que utilizou esse estudo transformando o problema de previsibilidade em sistemas dinâmicos com comportamento caótico para um problema de classificação e reconhecimento de padrões. No trabalho de Romero (2017), a técnica de *breeding* foi utilizada com algoritmos de inteligência computacional para avaliar a qualidade da previsão do modelo de circulação atmosférica global do CPTEC-INPE.

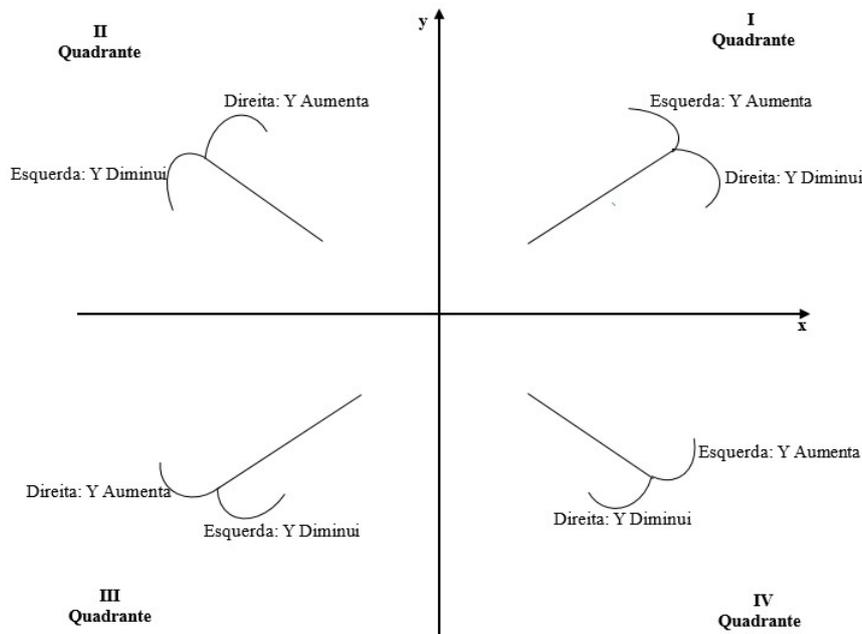
O objetivo desse trabalho é ampliar essa metodologia para investigar a previsibilidade do sistema dinâmico do rotor do helicóptero.

3.3 Análise para dinâmica do rotor de helicóptero

Serão mostrados no Capítulo 6 exemplos da dinâmica do rotor com visualização de trajetórias no espaço de fase. A análise é realizada observando-se o comportamento das trajetórias: seguindo curva à direita ou a esquerda, ou da extensão da trajetória.

Para uma identificação automática da curva executada pela trajetória, é realizada uma análise baseada na derivada da trajetória em 2 etapas. Primeiramente, a cada dois (2) pontos, a derivada é calculada por diferença finita avançada $(x(t_i + \Delta t) - x(t_i)/\Delta t)$. Se 2 derivadas calculadas de forma consecutiva alteram o sinal, isto indica que a trajetória teve sua direção alterada. Para identificar se a direção seguida pela trajetória foi esquerda ou direita, a análise depende do quadrante. Esta é a segunda etapa. A Figura 3.5 mostra como é identificada o tipo de curva (direita ou esquerda) em cada quadrante. Utilizou-se somente a coordenada y para análise de curva de trajetória. Trajetórias perpendiculares ao eixo y (paralela ao eixo horizontal) não foram registradas. Deste modo, não foi necessário informações da coordenada x (horizontal).

Figura 3.5 - Avaliação da Curva Executada por uma Trajetória ("Y" é a coordenada do eixo vertical).



Para identificar o tipo de curva, primeiramente localiza-se o quadrante do ponto. Em seguida faz-se uma análise, conforme descrição abaixo:

- I Quadrante:
 - se a trajetória virar para a direita a coordenada $y_{n+1} < y_n$;

- se a trajetória virar para a esquerda a coordenada $y_{n+1} > y_n$;
- II Quadrante:
 - se a trajetória virar para a direita a coordenada $y_{n+1} > y_n$;
 - se a trajetória virar para a esquerda a coordenada $y_{n+1} < y_n$;
- III Quadrante:
 - se a trajetória virar para a direita a coordenada $y_{n+1} > y_n$;
 - se a trajetória virar para a esquerda a coordenada $y_{n+1} < y_n$;
- IV Quadrante:
 - se a trajetória virar para a direita a coordenada $y_{n+1} < y_n$;
 - se a trajetória virar para a esquerda a coordenada $y_{n+1} > y_n$;

Além do tipo de curva da trajetória, a extensão da trajetória também é outro atributo usado para caracterizar a dinâmica sob estudo. Assim, define-se que a trajetória tem 2 classes de extensão: trajetória longa e trajetória curta. Como a definição de *longa* e *curta* é dependente do problema, a definição quantitativa será dada no [Capítulo 6 \(Seção 6.2\)](#).

4 CLASSIFICADORES DIFUSOS (*FUZZY*)

Neste capítulo, são apresentados os conceitos básicos dos sistemas difusos como variável linguística e sistema de inferência difuso bem como seus principais modelos (Mandani e Takagi-Sugeno). Por fim, serão descritos os sistemas neuro-difusos ANFIS e GUAJE que foram utilizados nesse trabalho por se tratarem de uma alternativa particularmente interessante na modelagem de sistemas, uma vez que conseguem extrair o aprendizado das redes neurais com as vantagens do nível de interpretabilidade da lógica difusa.

4.1 Visão Geral sobre Lógica Difusa

A lógica *fuzzy* ou difusa surgiu da teoria dos conjuntos difusos que foi desenvolvida por Zadeh (1965) com o objetivo de dar um tratamento matemático a conceitos imprecisos, vagos, incompletos, enfim informações que contém incerteza associada (“muito”, “pouco”, “alto”, “baixo”, “quente”, “frio”, etc). Ela aborda uma classe de elementos com graus ou níveis contínuos de pertinência que traduzem em termos matemáticos a informação imprecisa descrita por um conjunto de regras do mundo real.

Enquanto a teoria dos conjuntos clássica está baseada na função característica, dada por:

$$x_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases}$$

onde um elemento x em um conjunto universo X , pertence a um conjunto A ou não. Note que essa pertinência é binária e o conceito de pertinência de um elemento a um conjunto fica bem definido, ou seja, os elementos deste universo simplesmente pertencem ou não pertencem aquele conjunto (TANSCHKEIT, 2009).

A teoria dos conjuntos difusos não possuem limites bem definidos. Nestes conjuntos, a fronteira entre pertencer e não pertencer ao conjunto é feita de forma gradual, sendo caracterizada por uma determinada função, denominada função de pertinência $\mu_A(x)$ (TANSCHKEIT, 2009; NOBRE, 2011). Ela que define o grau de pertinência de um determinado elemento em um conjunto difuso, levando em consideração o seu universo de discurso e indica o grau de compatibilidade entre x e o conceito expresso por A (SANDRI; CORREA, 1999):

- $\mu_A(x) = 1$ indica que x é completamente compatível com A ;

- $\mu_A(x) = 0$ indica que x é completamente incompatível com A ;
- $0 < \mu_A(x) < 1$ indica que x é parcialmente compatível com A , com grau $\mu_A(x)$.

Por exemplo, um dia com temperatura de 39 °C e outro dia com 42 °C são membros do conjunto quente, embora o dia com 42 °C tenha um grau de pertinência maior neste conjunto.

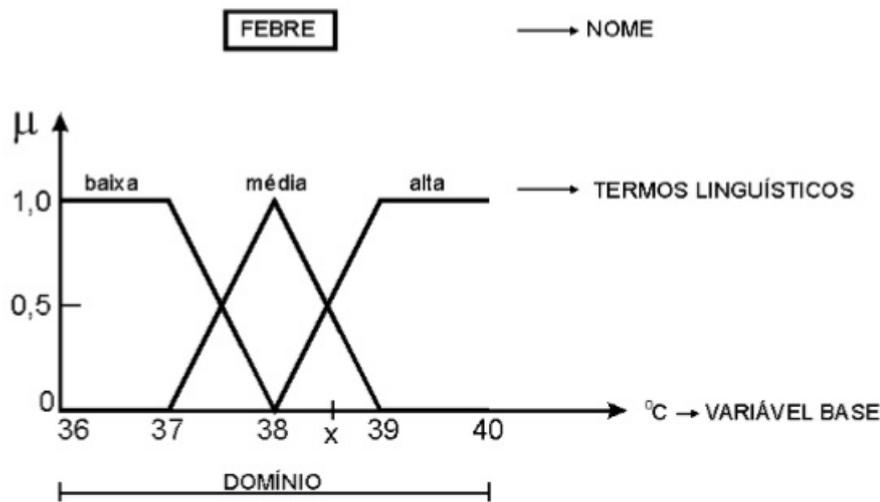
Note que um conjunto clássico é um caso particular de um conjunto difuso, denominado de *crisp* e assumindo valores exclusivamente em $\{0, 1\}$, ou seja, a pertinência é do tipo tudo ou nada, sim ou não, e não gradual como para os conjuntos difusos (SANDRI; CORREA, 1999).

4.2 Variável Linguística

Um termo relacionado com conjuntos difusos é o da variável linguística. A ideia é expressar a capacidade humana de classificar de modo impreciso as variáveis de um problema, em termos de conceitos qualitativos e não quantitativos. Dessa maneira, uma variável linguística é definida como uma entidade utilizada para representar de modo impreciso um conceito. As variáveis linguísticas admitem como valores apenas expressões linguísticas, como “fraco”, “muito grande”, “aproximadamente “perto”, “alto”, “médio”, entre outros (EVSUKOFF, 2005).

Deste modo, uma variável linguística tem por característica assumir valores dentro de um conjunto de termos linguísticos, ou seja, palavras ou frases. Ao invés de assumir instâncias numéricas, uma variável linguística assume instâncias linguísticas. Por exemplo, na Figura 4.1 a variável linguística *Febre* poderá assumir como valor um dos membros do conjunto {baixa, média, alta}. Para se atribuir um significado aos termos linguísticos, associa-se cada um destes a um conjunto difuso definido sobre um universo de discurso comum (GOMIDE; GUDWIN, 1994).

Figura 4.1 - Variável Linguística Febre



Fonte: Ortega (2001)

4.3 Sistema de Inferência Difuso

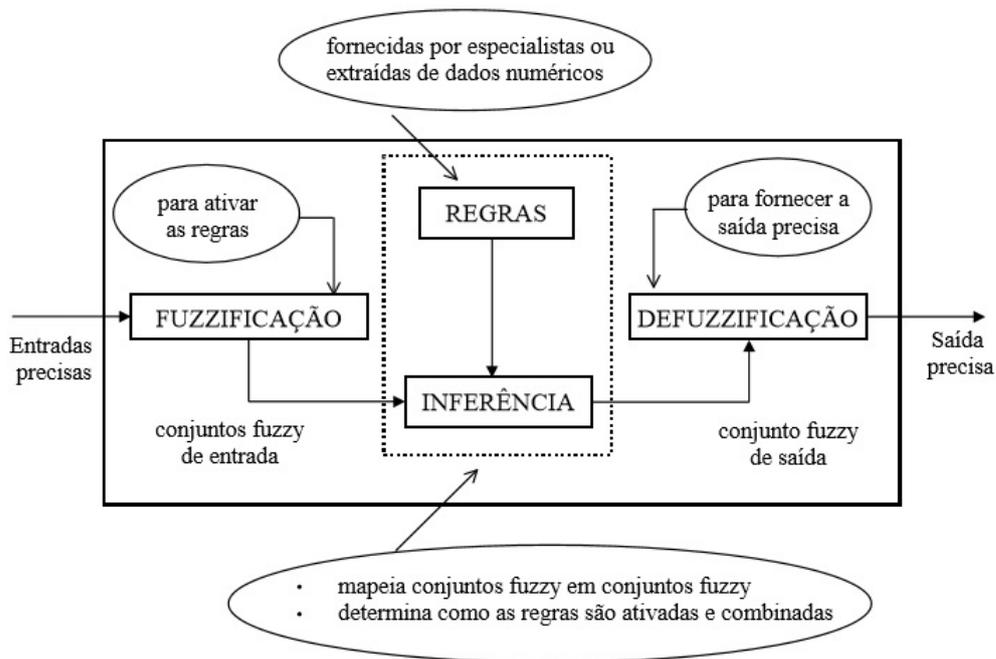
O sistema de inferência difuso (*Fuzzy Inference System* (FIS)) fornece um modo no tratamento e na manipulação de informações imprecisas, as quais são expressas de forma qualitativa e representadas por uma série de conjuntos difusos. O processo de um sistema de inferência difuso pode ser basicamente dividido em três etapas (Figura 4.2): fuzzificação, conjunto de regras e inferência e defuzzificação. Esta estrutura representa a transformação que ocorre no domínio de aplicações do mundo real para o domínio difuso. Durante esse processo, um conjunto de regras é utilizado para tomada de decisões, sendo que, em seguida, procede-se com uma transformação inversa do domínio difuso para o domínio do mundo real (OES; SHAW, 2007).

Na fase de Fuzzificação, o sistema difuso transforma os valores de entrada precisos, que podem ser provenientes por exemplo de medições, em valores difusos. Isso é feito a partir das funções de pertinência definidas para cada um dos conjuntos difusos participantes do sistema (LIMA, 2011; ROMERO, 2017).

Para simular a tomada de decisão humana, o processo de inferência se utiliza de regras difusas. A base de regras é implementada de acordo com o conhecimento do especialista e é formada por estruturas do tipo **Se** <antecedente> **Então** <consequente>. O antecedente é composto por um conjunto de condições que, quando

satisfeitas, determinam o processamento do conseqüente da regra. Este processo é denominado disparo de uma regra. Já o conseqüente é formado por um conjunto de ações que são geradas com o disparo da regra. Os conseqüentes das regras disparadas são processados em conjunto, gerando assim uma resposta determinística para cada variável de saída.

Figura 4.2 - Sistema de Inferência Difuso



Fonte: Tanscheit (2009)

É importante que existam tantas regras quantas forem necessárias para mapear totalmente as combinações dos termos das variáveis, isto é, que a base seja completa, garantindo que exista sempre ao menos uma regra a ser disparada para qualquer entrada. Assim, o processo de inferência tem como objetivo final obter um conjunto difuso de saída. Para tal, no mesmo encontra todas as regras ativadas e determina suas individuais contribuições difusas, as quais serão então combinadas a fim de produzir a respectiva saída difusa (PRUCOLE, 2006; PENTEADO, 2009).

A última etapa do processo denominada Defuzificação é responsável por converter o conjunto difuso de saída inferido a partir das regras ativadas em um único valor de saída que representa as contribuições das regras ativadas. Para isso, existem

diversos métodos na literatura que podem ser empregados tais como: Centróide (ou centro de massa), Princípio da máxima associação, Método da média ponderada, etc (PENTEADO, 2009; SANTOS, 2014).

Existem vários modelos que implementam um sistema de inferência, os mais conhecidos são: Mamdani e Takagi-Sugeno. O modelo de inferência difuso do tipo Mamdani é o método mais comum e foi proposto inicialmente por Mamdani e Assilian (1975) para um problema de controle. O modelo Mamdani tem a vantagem de operar com variáveis difusas tanto na entrada como na saída do sistema. O exemplo abaixo mostra uma regra difusa do método Mamdani que tem como variáveis de entrada a altura e o peso de uma pessoa e como variável de saída o cálculo de seu índice de massa corporal (IMC).

“se (**altura** é baixa e **peso** é alto) então **IMC** é ruim”

Já o modelo de inferência do tipo Takagi-Sugeno (TAKAGI; SUGENO, 1985) é similar ao modelo Mamdani. Ele também é baseado na utilização de uma base de regras condicionais e possui variáveis difusas como entrada. A grande diferença para o método Mamdani está em sua saída, as variáveis difusas de saída foram substituídas por equações paramétricas relacionando as entradas e saídas do sistema. O exemplo abaixo mostra uma regra difusa do modelo Sugeno.

“se (**altura** é baixa e **peso** é alto) então **IMC** = $altura * a + peso * b + c$ ”

onde a , b e c são valores constantes que devem ser ajustados para o problema. A parte consequente do conjunto de regras passou a ser uma função em vez de valores lingüísticos (ISHIBASHI, 2013).

4.4 Sistemas Neuro-Difusos

A motivação para a criação de Sistemas Inteligentes Híbridos (SIHs) surge do fato de que diferentes técnicas podem ser adequadas para resolver determinados tipo de problemas mas podem apresentar deficiências na resolução de outros. Assim, a ideia principal do desenvolvimento de SIHs é combinar várias técnicas com o intuito de superar as desvantagens que cada uma apresenta individualmente na resolução de um problema de interesse (LUDERMIR et al., 2003).

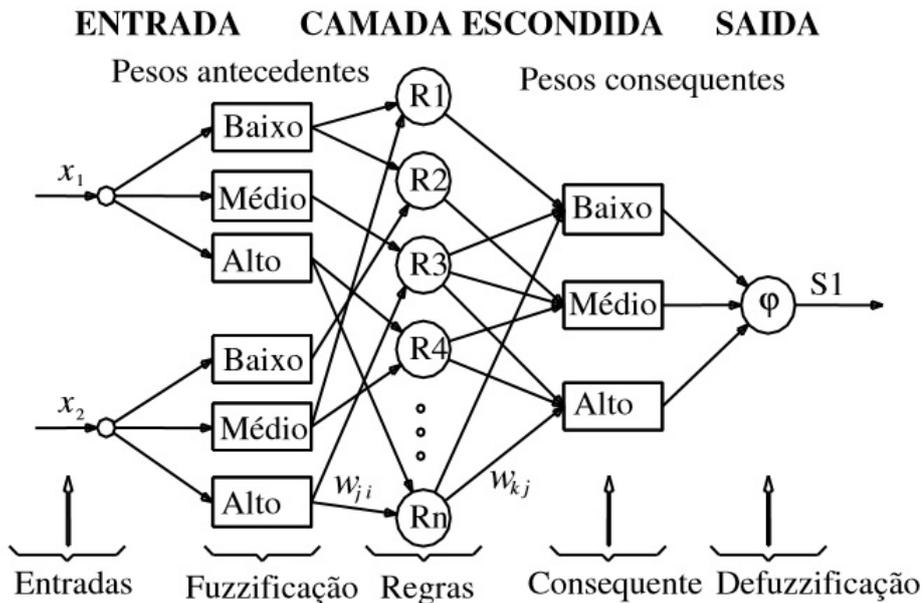
Os sistemas difusos são apropriados para a modelagem a partir do conhecimento explícito fornecido pelo especialista, nos quais o desempenho depende da experiência do especialista. E as rede neurais são adequadas na criação baseada no conheci-

mento implícito embutido em um conjunto de dados, entretanto o desempenho das redes neurais é afetado pelo ajuste de seus parâmetros (número de neurônios em cada camada, número de camadas escondidas, etc). Deste modo, um sistema neuro-difuso integra estas duas técnicas gerando um sistema inteligente híbrido que possa aproveitar as vantagens de cada uma delas e minimizar suas deficiências (SANCHEZ, 2009).

O sistema híbrido neuro-difuso apresenta-se como uma alternativa particularmente interessante na modelagem de sistemas pois permite a extração do conhecimento baseado na forma de regras de inferência difusas, mediante a integração do conhecimento explícito gerado pela experiência do especialista e do conhecimento implícito obtido a partir de um conjunto de dados. Assim, estes sistemas associam a capacidade de aprendizado e de tolerância a falhas das redes neurais, com a facilidade da interpretabilidade dos sistemas difusos.

A ideia básica é a construção de um Sistema de Inferência Difuso, numa estrutura paralela distribuída de tal forma que os algoritmos de aprendizado das redes neurais possam ser aproveitados nestes sistemas híbridos para ajustar os parâmetros do FIS. A Figura 4.3 apresenta a estrutura de um sistema neuro-difuso que é dividido em 5 camadas. A primeira camada representa as variáveis de entrada, a segunda camada é a etapa de fuzzificação. A terceira camada (escondida) representa as regras difusas e a quarta camada é determinada pelos consequentes das regras, por fim a quinta camada é a etapa de defuzzificação onde se calcula o valor numérico de saída. A seguir serão apresentados os sistemas neuro-difusos utilizados neste trabalho.

Figura 4.3 - Arquitetura Básica de um Sistema Neuro-Difuso



Fonte: Sanchez (2009)

4.4.1 Adaptive Neuro-Fuzzy Inference System (ANFIS)

O ANFIS proposto por Jang (1993) é um dos sistemas neuro-difuso mais conhecido e utilizado, ele implementa o modelo de sistema de inferência Takagi-Sugeno, ou seja, consiste na implementação de um modelo híbrido capaz de transformar o conhecimento ou experiência em base de regras, que através de um algoritmo de aprendizado adequado é capaz de construir automaticamente um conjunto de regras difusas a partir de um conjunto de informações. Os sistemas de regras resultantes utilizam regras difusas do tipo proposto por Takagi-Sugeno.

A possibilidade de aprendizado, como encontrado nas redes neurais, é o que torna o ANFIS um sistema diferenciado dos demais. É através do aprendizado que ele ajusta seus pesos e otimiza sua atuação sobre os dados de treinamento do ambiente. Em uma rede neural, o aprendizado é dado pelos ajustes dos pesos que interligam os neurônios. No ANFIS, o aprendizado atua sobre os parâmetros ajustáveis das funções de pertinência das variáveis difusas de entrada do sistema - os parâmetros de premissa.

Assim como na rede neural, o ANFIS possui certa heterogeneidade de métodos para

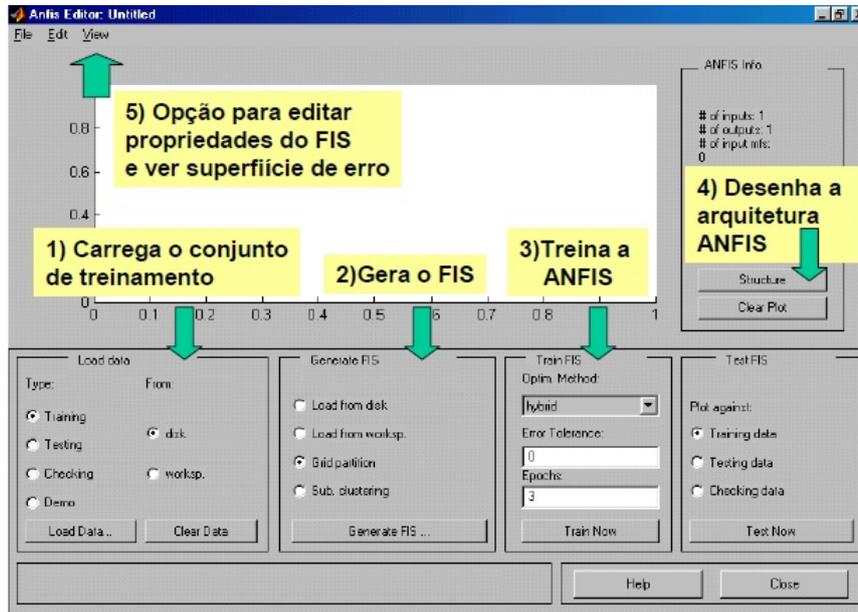
o seu processo de aprendizado. Tem-se o *backpropagation* e um método híbrido que consiste na combinação da estimação dos mínimos quadrados com *backpropagation*, para estimar os parâmetros da função de pertinência.

O *Fuzzy Logic Toolbox* é uma coleção de funções implementadas na plataforma MATLAB que provê ferramentas para a criação e edição de sistemas de inferência difusos. Esta toolbox é altamente baseada em interfaces gráficas que auxiliam o trabalho de criação e edição dos sistemas difusos, mas também pode ser utilizada através de linhas de comando.

O módulo denominado ANFIS do *Matlab* versão R2015b foi utilizado neste trabalho. Este módulo faz parte do utilitário de lógica difusa *Fuzzy Logic Toolbox*, que consiste em uma implementação do método proposto por Roger Jang (JANG, 1993).

A Figura 4.4 mostra o editor gráfico do ANFIS para criação, treinamento e teste de sistemas difusos. Primeiramente, deve-se carregar o conjunto de treinamento. Após o carregamento dos dados, deve-se gerar o sistema difuso de inferência que será ajustado pela rede, determinando o número e do tipo das funções de pertinência das entradas e da saída, permitindo que o ANFIS desenvolva o modelo da estrutura Neuro-Difuso. Por fim, define-se o algoritmo de treinamento da rede neural que será utilizado até que o número de épocas ou o erro sobre o conjunto dos dados de treinamento seja atingido.

Figura 4.4 - Editor do ANFIS *Fuzzy Logic Toolbox*



4.4.2 *Generating Understandable and Accurate fuzzy models in a Java Environment (GUAJE)*

O GUAJE é um *software* livre desenvolvido em JAVA que implementa uma metodologia chamada HILK (*Highly Interpretable Linguistic Knowledge*), que trata-se de um procedimento para a construção de bases de conhecimento linguístico altamente interpretáveis através de processos de integração, análise de consistência, simplificação e otimização, sob o formalismo da lógica difusa (ALONSO; MAGDALENA, 2011). Para isso, ele implementa um sistema de extração de conhecimento através de uma combinação de diversas ferramentas como por exemplo o FisPro (GUILLAUME; CHARNOMORDIC, 2011) que é uma ferramenta de código aberto para criar sistemas de inferência e o Xfuzzy (IMSE-CNM, 2003) que é um *software* livre composto de várias ferramentas gráficas as quais abrangem as diferentes etapas do processo de concepção de um sistema difuso, desde a sua descrição inicial até a execução final. Suas principais características são a capacidade de desenvolvimento de sistemas e a flexibilidade de extensão das funções disponíveis.

O GUAJE foi projetado e desenvolvido com o objetivo de produzir sistemas altamente interpretáveis e manter uma boa relação entre interpretabilidade e acurácia.

O processo de modelagem é constituído pelas seguintes etapas (ALONSO et al., 2012):

- Pré-processamento dos dados: inclui visualização dos dados, análise e amostragem;
- Seleção de características: com o foco em identificar as variáveis de entrada mais significativas;
- Particionamento: consiste em caracterizar cada variável de entrada como uma variável linguística com um número justificável de termos linguísticos. Sua semântica deve ser compatível com o conhecimento do especialista e é descrita por meio de partições difusas com o objetivo de maximizar a interpretabilidade;
- Definição da base de regras: uma vez definidas todas as variáveis de entrada, o passo seguinte é definir uma semântica global como base das regras. Como resultado, todas as regras compartilham os mesmos termos linguísticos previamente definidos. Assim, o comportamento do sistema pode ser descrito como um conjunto de regras linguísticas do tipo “se-então”. As regras podem ser criadas automaticamente com técnicas de aprendizado de máquina e/ou fornecidas diretamente por um especialista;
- Verificação da base de regras: esta etapa de modelagem é responsável por verificar a consistência da base de regras previamente definida;
- Melhoria da base de conhecimento: o objetivo desta fase é melhorar a relação entre interpretabilidade e acurácia. A primeira etapa consiste em uma simplificação linguística com o objetivo de aumentar a interpretabilidade, preservando a acurácia já alcançada, em seguida é feito um refinamento na partição destinada a aumentar a acurácia, porém sem comprometer a interpretabilidade;
- Validação da base de conhecimento: verifica se o sistema difuso gerado satisfaz as expectativas;
- Avaliação da qualidade: avalia os resultados quanto a interpretabilidade e acurácia.

A Figura 4.5 mostra a janela principal do GUAJE pode-se observar as principais entradas para configuração:

- *Problem Context Configuration*: configura o nome do arquivo, o número de entradas e o número de classes de saída;
- *FIS (Fuzzy Inference System) Configuration*: configura os processos de conjunção, disjunção e defuzzyficação, também é possível exportar um arquivo FIS para outras plataformas como Matlab, etc;
- *Knowledge Base*: configura a base de conhecimento, divide-se em duas partes: *Adding Expert Knowledge* fornece diversas opções de configuração as mais utilizadas são: *Simplification*, *Inference* e *Quality* (Figura 4.6). Em *simplification* é possível diminuir a quantidade de regras gerando um novo conjunto menor de regras com a mesma equivalência, em *inference* permite-se inferir uma saída utilizando um novo conjunto de dados de entrada, e no *quality* são realizados testes de acurácia e interpretabilidade. No teste de acurácia é gerada automaticamente a matriz de confusão. Finalmente, o *Extracting Knowledge from Data* extrai o conhecimento, ou seja, cria as regras da base automaticamente.

Figura 4.5 - Janela Principal do GUAJE

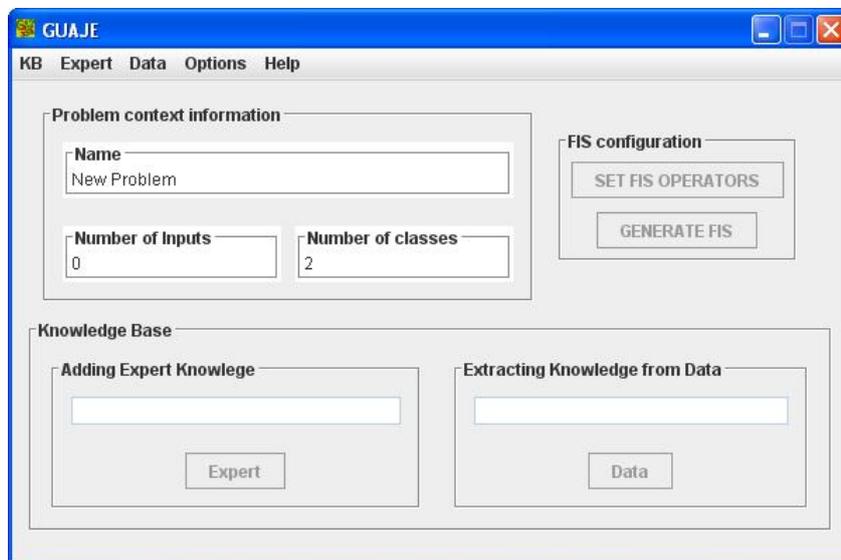
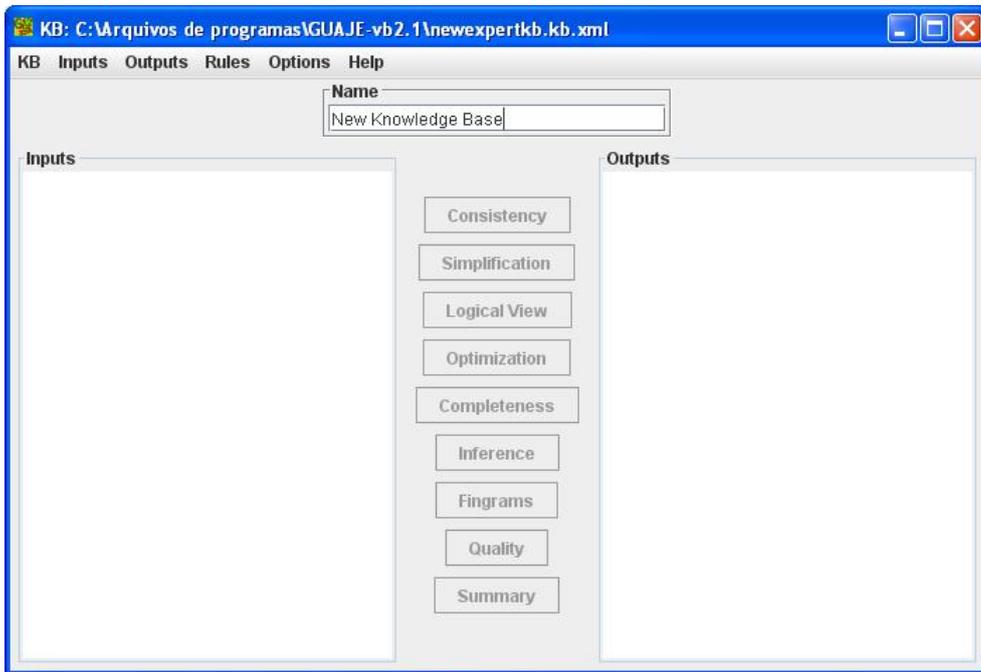


Figura 4.6 - Janela *Adding Expert Knowledge*



5 CALIBRAÇÃO DE SIMULADORES DE VOO

Neste capítulo, será apresentada a metodologia para identificação de sistemas conhecida como Quad-M. Além disso, serão apresentados os resultados comparativos da calibração do modelo de dinâmico (Seção 2.1) entre o algoritmo genético e o algoritmo de colisão de múltiplas partículas.

5.1 Simuladores e Modelo Calibração

De acordo com Shannon (1975), simulação é o processo de elaborar um modelo de um sistema real e conduzir experimentos com este modelo tendo como propósito a compreensão ou a avaliação do comportamento do sistema. Além disso, outros motivos que impulsionam o uso de simulação são a segurança (usar o mundo real pode envolver muitos riscos), tempo e custo.

O setor aeroespacial é fortemente ligado a diversas áreas da computação tais como: aerodinâmica computacional, controle computadorizado de aeronaves e simuladores de voo são exemplos bem conhecidos. Há um uso crescente de simuladores de voo com o objetivo de aumentar a segurança das operações. Para que os simuladores tenham uma boa aderência com a realidade, é preciso calibrar os simuladores, ou seja, identificar os parâmetros que tornem a simulação o mais próximo possível da dinâmica real. Após determinar tais parâmetros, o simulador estará pronto para ser usado para a avaliação de foguetes, aeronaves e no treinamento de pilotos.

A calibração corresponde a um tipo de problema inverso – problema inverso de estimação de parâmetros –, no qual, partindo-se dos efeitos (dados observados), tenta-se chegar às causas (parâmetros). A estratégia é ajustar os parâmetros desconhecidos de forma a se ter o melhor ajuste de um modelo matemático do fenômeno com as observações.

Na verdade, há vários tipos de classificação de problemas inversos. Uma delas foi proposta por Beck e Arnold (1977), que classifica problemas inversos como sendo de 2 tipos: estimação de parâmetros ou estimação de funções (BECK et al., 1985). James Beck atualizou a discussão desta classificação em um tutorial no International Conference on Inverse Problems in Engineering (ICIPE) de 1999 (<http://www.me.ua.edu/3icipe/tutorial/beck/BeckTutorial.pdf>). Outros tipos de classificação são apresentadas por Neto (2005), ver também (CAMPOS VELHO, 2008).

5.2 Metodologia Quad-M

A identificação de sistemas pode ser definida como o processo de determinar um modelo matemático adequado, cujos parâmetros desconhecidos devem ser determinados indiretamente a partir dos dados medidos. Os passos para iniciar a identificação de um sistema são: realização de medidas, escolha de métodos e modelos, decisão das manobras a serem realizadas e, ao final, a verificação dos resultados. Uma metodologia que vem sendo empregada e que leva em consideração os passos descritos acima é a metodologia conhecida como Quad-M que provém das iniciais em inglês: *Method*, *Maneuver*, *Model* e *Measurements* e foi proposta por Hamel e Jategaonkar (1996). Esta abordagem é estruturada e subdividida nas seguintes atividades:

- Manobras: representam a forma da entrada de controle de modo a excitar diferentes modos da dinâmica da aeronave;
- Medidas: seleção dos sistemas de aquisição de dados que serão utilizados pela instrumentação para se obter medidas com alto grau de acuracidade;
- Modelos: definição do modelo matemático da aeronave que será estudada;
- Métodos: escolha e desenvolvimento de algoritmos de estimação dos parâmetros mais adequados para o problema estudado.

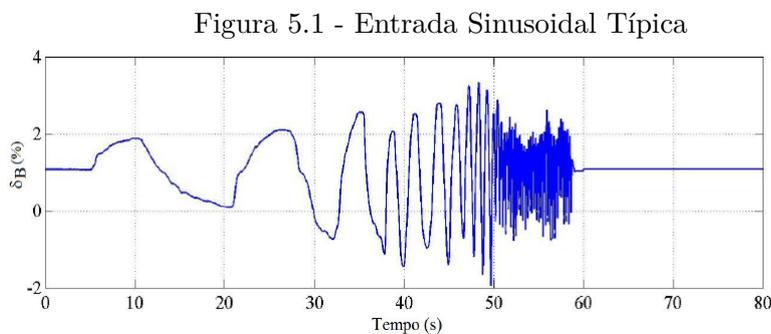
Esta metodologia tem sido utilizada em diversos trabalhos (MACIEL et al., 2004; NETO, 2005; LICHOTA; LASEK, 2013; MACHADO, 2016). A seguir será apresentada cada uma dessas etapas, sendo que três delas (manobras, medidas e modelo (Seção 2.1)) foram realizadas no trabalho de Cruz (2009). Na última etapa - métodos - Cruz (2009) utilizou um algoritmo genético, enquanto que neste trabalho será aplicado o algoritmo de colisão de múltiplas partículas.

5.2.1 Manobras

A especificação de manobras de ensaios em voo 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 voo, 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 (NETO, 2005).

Em geral, a resposta dinâmica é excitada a partir da aplicação de entradas como pulso, degrau, *doublet*, *multistep*, sinusoidal, 3-2-1-1, entre outras. Uma grande variedade de manobras pode ser especificada, desde que seja considerado o seguinte princípio básico em identificação de sistemas: os registros dos dados do voo de ensaio devem conter as informações das características dinâmicas que se deseja obter no modelo.

No trabalho de Cruz (2009), foram utilizadas duas manobras: sinusoidal e 3-2-1-1. Neste trabalho, foi utilizada apenas a entrada sinusoidal (Figura 5.1), que é uma manobra fácil de ser executada e é apropriada para uma identificação precisa da dinâmica de aeronaves de asas fixa e rotativa.

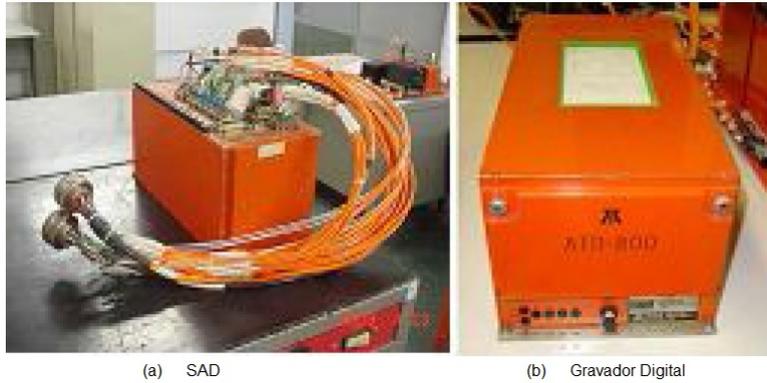


5.2.2 Medidas

O sistema de medição é composto por transdutores que são colocados na aeronave para monitorar sua resposta aos sinais de comando. Esse sistema é uma parte importante no processo de identificação de parâmetros pois suas características podem modificar consideravelmente os dados coletados.

Neste trabalho, a aeronave utilizada foi um helicóptero esquilo AS355-F2 da Força Aérea Brasileira, ele foi equipado com um sistema de aquisição de dados (SAD) *Aydin Vector* PCU-816-I, que fornece 35 parâmetros diferentes, e com o gravador digital ATD-800, de capacidade de 4 GB de informação. Ambos os sistemas foram instalados no bagageiro lateral direito.

Figura 5.2 - Instrumentação da Aeronave Ensaaiada



Fonte: Cruz (2009)

Também foram instalados transdutores potenciométricos nas hastes de comando. As medidas destes sensores foram registradas no SAD e apresentadas nos mostradores analógicos instalados na parte superior do painel frontal (para os comandos de cíclico longitudinal, lateral e pedal) e na porção inferior central do painel frontal (para o comando coletivo) (CRUZ, 2009).

Figura 5.3 - Instrumentação dos Comandos de Voo



Fonte: Cruz (2009)

Para a determinação das velocidades angulares (p , q e r), foi instalado um girômetro próximo ao giro vertical. As velocidades do corpo (u , v e w) também foram obtidas por meio do GPS diferencial (DGPS) Z12. Por fim, deve-se ressaltar que o AS355-F2 não possui sensores para medir os deslocamentos verticais e as inclinações do prato cíclico (*swashplate*) do rotor principal e, dessa maneira, não foi possível obter de

forma adequada os três graus de liberdade do rotor (conicidade e basculamentos longitudinal e lateral) (CRUZ, 2009). Essa é a razão da dinâmica do helicóptero ter sido modelada com seis graus de liberdade, conforme descrito em Seção 2.1.

5.2.3 Modelo

O modelo utilizado foi apresentado na Seção 2.1 e as equações linearizadas do modo longitudinal (Equação 2.34) e látero-direcional (Equação 2.35) desacoplados e podem ser representadas como:

$$\dot{x} = Ax + BU(t - \tau) + \dot{x}_{bias} \quad (5.1)$$

onde a matriz A representa as derivadas de estabilidade e a matriz B as derivadas de controle, τ são os atrasos associados às dinâmicas não-modeladas (os servocomandos, as hastes de comando de passo e os transientes do rotor principal). Além disso, observa-se, o acréscimo do vetor de tendência (bias), x_{bias} , que é constante e desconhecido. Ele é inserido no modelo matemático para, conforme (TISCHLER; REMPLE, 2006), fornecer uma correção de primeira ordem para os erros aleatórios devido a entradas não medidas como a turbulência, imprecisões nas medidas devido a ruídos nos transdutores e na instrumentação, erros na estrutura do modelo e ruído computacional nos cálculos digitais.

As equações 5.2 e 5.3 apresentam os vetores dos parâmetros do modo longitudinal (Θ_{long}) e do modo látero-direcional (Θ_{lat}):

$$\Theta_{long} = \left[\begin{array}{c} \frac{X_u}{m}, \frac{X_w}{m}, \frac{X_q}{m}, \frac{Z_u}{m}, \frac{Z_w}{m}, \frac{Z_q}{m}, \frac{M_u}{I_{yy}}, \frac{M_w}{I_{yy}}, \frac{M_q}{I_{yy}}, \frac{X_{\delta_B}}{m}, \frac{X_{\delta_C}}{m}, \frac{Z_{\delta_B}}{m}, \frac{Z_{\delta_C}}{m}, \frac{M_{\delta_B}}{I_{yy}}, \frac{M_{\delta_C}}{I_{yy}}, \\ \Delta \dot{u}_{bias}, \Delta \dot{w}_{bias}, \Delta \dot{q}_{bias}, \Delta \dot{\theta}_{bias}, \tau_c, \tau_b \end{array} \right] \quad (5.2)$$

$$\Theta_{lat} = \left[\begin{array}{c} \frac{Y_v}{m}, \frac{Y_p}{m}, \frac{Y_r}{m}, L'_v, L'_p, L'_r, N'_v, N'_p, N'_r, \frac{Y_{\delta_A}}{m}, \frac{Y_{\delta_P}}{m}, L'_{\delta_A}, L'_{\delta_P}, N'_{\delta_A}, N'_{\delta_P}, \\ \Delta \dot{v}_{bias}, \Delta \dot{p}_{bias}, \Delta \dot{r}_{bias}, \Delta \dot{r}_{bias}, \tau_a, \tau_p \end{array} \right] \quad (5.3)$$

A ideia principal consiste em calibrar interativamente o vetor de parâmetros a fim de minimizar o erro entre as respostas medidas em voo (saída do sistema) e os resultados estimados a partir do modelo matemático submetido às mesmas entradas observadas. Assim, o processo de minimização é realizado em função dos parâmetros do modelo dinâmico que está sendo identificado (CRUZ, 2009).

Para tanto, define-se uma função custo que mede a concordância entre o dado real e o simulado com um determinado conjunto de parâmetros ajustáveis (os elementos dos vetores das equações 5.2 e 5.3), de tal forma que um valor baixo significa boa similaridade. Em seguida, aplica-se um método de otimização que varia os elementos do vetor de parâmetros com o objetivo de minimizar a função custo.

Assim, seja f a função custo, Θ o vetor com M parâmetros ajustáveis que se deseja estimar, y o vetor de observações (valores de saída dos sensores da instrumentação da aeronave) e N o número total de amostras medidas. Considera-se ainda que $y_{sim}(x_i, \Theta_1 \dots \Theta_m), i = 1, \dots, N$ é a saída do modelo proposto para um determinado conjunto de parâmetros Θ , então, o problema de otimização consiste em determinar o vetor de parâmetros ajustáveis Θ que minimiza a função custo dada por $f = f(y_{sim}(x_i, \Theta_1 \dots \Theta_m, y))$.

Diferentes funções custos podem ser adotadas, neste trabalho foi utilizado os mínimos quadrados:

$$f = \sum_{i=1}^N [y_i - y_{sim}(x_i; \vec{\Theta})][y_i - y_{sim}(x_i; \vec{\Theta})]^T \quad (5.4)$$

Portanto, o problema de otimização descrito anteriormente passa a ser minimizar a Equação 5.4 com respeito ao vetor $\vec{\Theta}$, que será resolvido através da meta-heurística: algoritmo de colisão de múltiplas partículas.

5.2.4 Método: Algoritmos Meta-heurísticos

Uma vez que o problema de otimização foi formulado, é preciso encontrar sua solução. A resolução deste tipo de problema consiste na busca das melhores soluções para determinados objetivos. Existem diversas técnicas destinadas a tarefa de resolver problemas de otimização baseadas em meta-heurística tais como: algoritmos genéticos (HOLLAND, 1975), colônia de formigas (DORIGO, 1992; GOLDBERG, 1989), recozimento simulado (*simulated annealing*) (KIRKPATRICK et al., 1983) dentre outros.

Uma meta-heurística é uma estratégia de busca, não específica para um determinado problema, que tenta explorar eficientemente o espaço das soluções viáveis desse problema. São algoritmos aproximados que incorporam mecanismos para evitar o confinamento em mínimos ou máximos locais. Conhecimentos específicos do problema podem ser utilizados para auxiliar no processo de busca (por exemplo, na busca de um possível bom vizinho de um determinado ponto). As meta-heurísticas

são mecanismos de alto nível para explorar espaços de busca, cada uma usando um determinado tipo de estratégia (BECCENERI et al., 2012; SILVA NETO et al., 2016).

A seguir será apresentada uma descrição detalhada da meta-heurística utilizada nesse trabalho: o algoritmo de colisão de múltiplas partículas. Além disso, será realizada uma breve descrição do algoritmo genético, um estudo aprofundado sobre esse algoritmo pode ser encontrado em Linden (2012).

5.2.4.1 Algoritmo de Colisão de Múltiplas Partículas

O algoritmo de colisão de múltiplas partículas – MPCA (*Multiple Particle Collision Algorithm*) foi proposto por Luz (2012). Trata-se de um método de otimização que foi desenvolvido a partir da formulação básica do PCA – *Particle Collision Algorithm* (SACCO; OLIVEIRA, 2005) a qual teve sua inspiração nas raízes da física das reações de colisão de partículas nucleares, com grande ênfase nos comportamentos de espalhamento (*scattering*) e absorção (*absorption*).

O algoritmo do PCA tem apresentado bons resultados em diversos casos de otimização incluindo problemas de teste e aplicações reais (SACCO; OLIVEIRA, 2005) (SACCO et al., 2009). Como o MPCA foi inspirado no PCA a seguir será apresentada a estrutura de funcionamento do PCA.

O primeiro passo consiste na geração de uma solução inicial (*Old-Config*), que é modificada por uma perturbação estocástica (*Perturbation*{.}), levando à construção de uma nova solução (*New-Config*). A nova solução é comparada (função *Fitness*{.}), e pode ou não ser aceita. Se a nova solução não é aceita, o processo de espalhamento (*Scattering*{.}) é usado. A exploração em torno de posições mais próximas é garantida usando as funções *Perturbation*{.} e *Small-Perturbation*{.}. Se a nova solução é melhor que a anterior, esta nova solução é absorvida. Se uma solução pior é achada, a partícula pode ser enviada para uma posição diferente no espaço de busca, permitindo que o algoritmo escape do mínimo local (LUZ et al., 2008; LUZ, 2012). A Tabela 5.1 mostra o principal trecho do algoritmo PCA.

Para garantir que as perturbações impostas ao algoritmo não levem à construção de uma solução, na qual um de seus pontos esteja fora do espaço válido de buscas, uma verificação destes limites é realizada constantemente para evitar esse contratempo, tal como descrito na Tabela 5.2:

Na função exploração (*Exploration*), pequenas perturbações estocásticas são aplicadas à solução através da função (*Small-Perturbation*) com objetivo de executar uma

Tabela 5.1 - Algoritmo PCA.

Gera uma solução inicial: *Old-Config*
 $Best-Fitness = Fitness(Old-Config)$
Para $n = 0$ **até** # de iterações
 Perturbation(.)
 Se $Fitness(New-Config) > Fitness(Old-Config)$
 Se $Fitness(New-Config) > Best-Fitness$
 $Best-Fitness = Fitness(New-Config)$
 Fim-se
 $Old-Config = New-Config$
 Exploration(.)
 Senão
 Scattering(.)
 Fim-se
Fim-Para

Tabela 5.2 - Função para perturbação no PCA.

Perturbation(.)
 Para $i = 0$ **até** (Dimensões-1)
 Superior = Limite-superior[i]
 Inferior = Limite-inferior[i]
 Aleatório = *Random*(0, 1)
 $New-Config[i] = Old-Config[i] + ((Superior - Old-Config[i] * Aleatório) - ((Old-Config[i] - Inferior) * (1 - Aleatório)))$
 Se $New-Config[i] > Superior$
 $New-Config[i] = Limite-superior[i]$
 Senão
 Se $New-Config[i] > Inferior$
 $New-Config[i] = Limite-inferior[i]$
 Fim-se
 Fim-se
Fim-Para
Retorna

pequena exploração local, a fim de verificar a existência de uma possível solução ainda melhor de uma determinada vizinhança, como apresentada na Tabela 5.3.

A Tabela 5.4 demonstra o procedimento de espalhamento (*Scattering*), um esquema estocástico que tenta evitar a prisão do algoritmo em uma região de ótimo local no espaço de buscas.

Os parâmetros que regulam o funcionamento do algoritmo PCA são: número de

Tabela 5.3 - Função para exploração no PCA.

Exploration(.)
Para $n = 0$ **até** # de iterações
 Small-Perturbation(.)
Se $Fitness(New-Config) > Fitness(Old-Config)$
 $Old-Config = New-Config$
Fim-se
Fim-Para
Retorna

Tabela 5.4 - Função para espalhamento no PCA.

Scattering(.)
 $Pscattering = 1 - Fitness(New-Config) / Best-Fitness$
Se $Pscattering > Random(0, 1)$
 $Old-Config =$ Solução aleatória
Senão
 Exploration(.)
Fim-Se
Retorna

iterações do algoritmo, número de iterações da busca local, tamanho do raio de perturbação, tamanho do raio de perturbação da busca local e a função de probabilidade usada no cálculo do espalhamento.

O algoritmo MPCA é similar ao PCA, porém foi introduzido o conceito e o uso de múltiplas partículas, equivalente a uma população de soluções candidatas. Portanto, com um conjunto de n partículas a exploração é feita de forma independente e colaborativa no mesmo espaço de soluções, com isso torna-se necessário a implementação de um mecanismo de comunicação entre as partículas. Uma técnica, denominada *blackboard* foi adotada, a informação *Best-Fitness*, que corresponde ao melhor resultado obtido pelas partículas, é compartilhada entre todas envolvidas no processo de busca. Este processo foi implementado usando o *Message Passing Interface* (MPI) para a aplicação em máquinas com memória distribuída (LUZ et al., 2008; LUZ, 2012).

No algoritmo MPCA, os parâmetros a serem ajustados são os mesmos do PCA, no entanto é necessário incluir o número de partículas a serem usadas na busca e o número de processadores que serão utilizados. O pseudo-código para o MPCA é apresentado na Tabela 5.5.

Tabela 5.5 - MPCA: pseudo-código.

Solução inicial gerada: *Old-Config*
 $Best-Fitness = Fitness(Old-Config)$
 Atualiza *Blackboard*
Para $n = 0$ até # de partículas
 Para $n = 0$ até # iterações
 Atualiza *Blackboard*
 Perturbation(.)
 Se $Fitness(New-Config) > Fitness(Old-Config)$
 Se $Fitness(New-Config) > Best-Fitness$
 $Best-Fitness = Fitness(New-Config)$
 Fim-se
 $Old-Config = New-Config$
 Exploration(.)
 Senão
 Scattering(.)
 Fim-se
 Fim-para
Fim-para

Outra característica relevante do MPCA é a capacidade de escape de ótimos locais. A busca cooperativa, ou seja, a troca de informação entre as partículas, auxilia o processo de convergência, uma vez que o processo de espalhamento leva em consideração a informação que está sendo compartilhada entre as partículas. A principal vantagem do MPCA está no aproveitamento do poder computacional provido por múltiplos processadores na tarefa de explorar o espaço de soluções através da troca de informação, que é peça central deste mecanismo melhorado de escape de ótimos locais. Luz (2012) apresentou melhoras significativas em precisão e tempo computacional na resolução de problemas de otimização contínua com uso do algoritmo MPCA, garantindo bons resultados.

Outros trabalhos que demonstraram a eficiência do MPCA foram: Sambatti et al. (2012) na identificação dos perfis de temperatura, Anochi e Campos Velho (2014) na previsão climática de precipitação e Torres et al. (2015) na solução de um problema inverso radiativo.

5.2.4.2 Algoritmo Genético

Em 1975, Holland (1975) desenvolveu uma teoria que deu origem ao primeiro algoritmo genético (AG). Esta técnica tem como base os princípios da evolução Darwiniana, declarado em 1859 por Charles Darwin em seu livro A Origem das Espécies,

onde “Quanto melhor um indivíduo se adaptar ao seu meio ambiente, maior ser a sua chance de sobreviver e gerar descendentes”. Assim, os algoritmos genéticos são métodos de busca inspirados nos mecanismos de evolução de populações de seres vivos, utilizados para achar soluções em problemas de otimização (LINDEN, 2012).

O primeiro passo do algoritmo é a geração de uma população inicial, formada por um conjunto aleatório de cromossomos ou indivíduos que representam uma possível solução para o problema. Durante o processo evolutivo, esta população é avaliada e cada cromossomo recebe uma nota que mede a qualidade da solução que ele representa. Com base nesses valores é aplicado um operador de seleção, onde os mais aptos sobrevivem (elitismo) (LACERDA; CARVALHO, 1999), evitando a perda da melhor solução. Os indivíduos selecionados podem sofrer alterações através da aplicação dos operadores genéticos: cruzamento (*crossover*) e mutação, gerando descendentes para a nova geração. Esse processo é repetido até que uma solução satisfatória é encontrada ou um limite máximo de iterações é atingido (SAMBATTI, 2004).

5.3 Resultados para Calibração

Neste trabalho, a estimação de parâmetros do modelo dinâmico proposto por Cruz (2009) foi realizada utilizando o algoritmo de colisão de múltiplas partículas (LUZ, 2012). Os resultados obtidos são comparados com os gerados pelo algoritmo genético.

Os experimentos foram implementados em *Matlab* versão R2011b e os testes foram conduzidos no sistema operacional *Linux*, com processador *Intel Core I5 2.27GHz* e 3GB de memória.

Foi utilizado o *Genetic Algorithm and Direct Search Toolbox* do *Matlab* com os seguintes parâmetros: 100 número de gerações e 200 tamanho da população. Cada nova geração é composta por dois indivíduos com melhor valor de ajuste (elite) e o resto da população é formada a partir do cruzamento e da mutação, na proporção de 80 e 20, respectivamente (CRUZ, 2009).

Os parâmetros utilizados pelo MPCA foram: 2 partículas; 10 iterações para busca local (*exploration*). Foi adotado como critério de parada o número total de iterações (30). Os resultados apresentados levam em consideração a média de 4 experimentos com diferentes sementes para gerar números aleatórios. Como entrada para excitar a dinâmica do sistema foi utilizada a manobra sinusoidal.

Os resultados da calibração para o modo longitudinal são mostrados nas Figuras 5.4, 5.5, 5.6, 5.7. Para todos os gráficos, a curva vermelha corresponde aos dados reais

obtidos durante o ensaio, a curva pontilhada em azul é resultado da identificação produzida pelo algoritmo genético e os resultados alcançados pelo MPCA são representados pela a curva pontilhada em rosa.

Dados observacionais da dinâmica são comparados com dados experimentais. Os resultados para este modo foram publicados num congresso internacional de problemas inversos (SUMIDA et al., 2014b) – ver também (SUMIDA et al., 2015b). Os valores numéricos obtidos na calibração são dados a seguir:

$$\Theta_{long} = \begin{bmatrix} \frac{X_u}{m}, \frac{X_w}{m}, \frac{X_q}{m}, \frac{Z_u}{m}, \frac{Z_w}{m}, \frac{Z_q}{m}, \frac{M_u}{I_{yy}}, \frac{M_w}{I_{yy}}, \frac{M_q}{I_{yy}}, \frac{X_{\delta_B}}{m}, \frac{X_{\delta_C}}{m}, \frac{Z_{\delta_B}}{m}, \frac{Z_{\delta_C}}{m}, \frac{M_{\delta_B}}{I_{yy}}, \frac{M_{\delta_C}}{I_{yy}}, \\ \Delta \dot{u}_{bias}, \Delta \dot{w}_{bias}, \Delta \dot{q}_{bias}, \Delta \dot{\theta}_{bias}, \tau_c, \tau_b \end{bmatrix} = \begin{bmatrix} -0,8954; 0,4982; 0,4717; -0,6520; -0,3899; 1,0014; 0,0983; -0,0558; \\ -2,9974; -0,2636; -0,3666; -2,5242; -2,3805; 0,5357; 0,3936; \\ 0,0461; -0,0995; 0,0588; 0,156; -0,7042; 0,8281 \end{bmatrix}$$

A Figura 5.4 é a variação da velocidade linear Δu na direção horizontal- x do modo longitudinal para a janela de medidas após a manobra, bem como os resultados do simulador calibrado com AG e MPCA. Nota-se que até um pouco mais de 100 segundos a intensidade de variação da velocidade observada é maior do que os resultados da simulação. Esta discrepância entre a observação e a simulação provavelmente está ligada a processos não modelados, que perdem influência quando a dinâmica evolui, quando se verifica uma boa concordância da simulação com os dados medidos.

A discrepância entre os dados medidos e dados simulados também é verificada no modo longitudinal da componente vertical da variação da velocidade linear Δw , como mostrado na Figura 5.5. Porém, a intensidade na discrepância não só é mais reduzida, como também a influência de processos não modelos é menor, visto que o acoplamento entre observação e simulação se dá para o intervalo de tempo de aproximadamente 95 segundos.

A Figura 5.6 mostra a evolução da variável de variação da atitude horizontal $\Delta \theta$ com o tempo. Esta variável também registra um diferença entra a observação e a simulação. A diferença é da ordem do que se verifica com a variação da velocidade linear Δu . Entretanto, a influência deste tipo de processos é ainda menor, pois a concordância da simulação com os dados de medida ocorre após 80 segundos.

Diferentemente das variáveis citadas acima, a variação da velocidade angular de arfagem Δq tem melhor concordância dos resultados da simulação com as medidas.

Figura 5.4 - Variação da Velocidade Linear no Eixo X

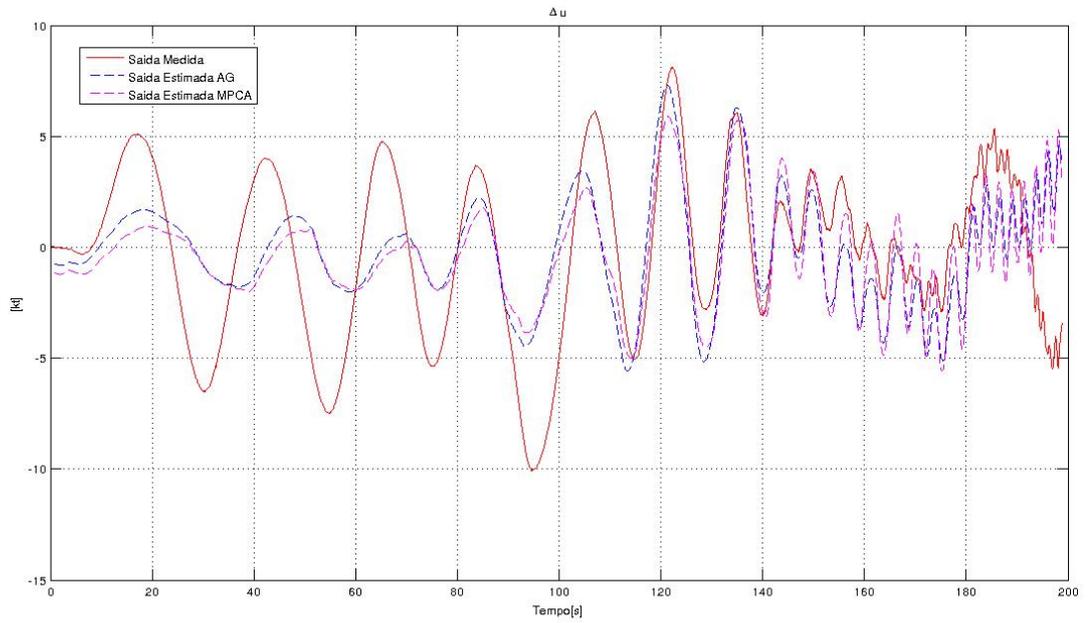
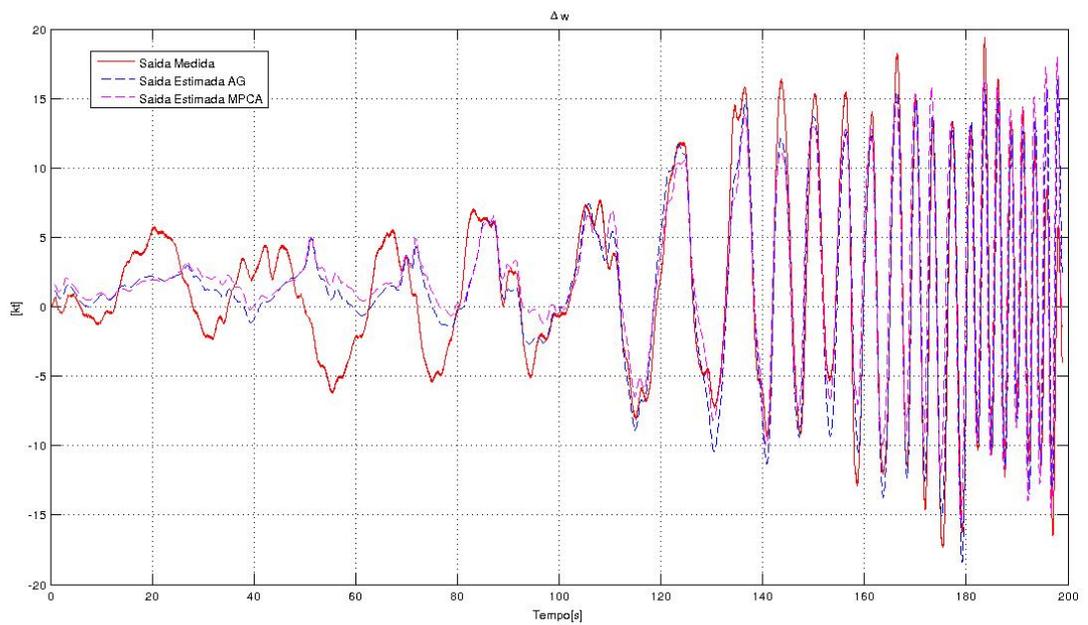


Figura 5.5 - Variação da Velocidade Linear no Eixo Z



Isto permite concluir que os processos não modelados não tem influência significativa para esta variável.

As Figuras 5.8, 5.9, 5.10 e 5.11 mostram o resultado da calibração para o modo látero-direcional (SUMIDA et al., 2014a; SUMIDA et al., 2015a). Os valores dos parâmetros calculados na calibração são:

$$\Theta_{lat} = \left[\begin{array}{c} \frac{Y_v}{m}, \frac{Y_p}{m}, \frac{Y_r}{m}, L'_v, L'_p, L'_r, N'_v, N'_p, N'_r, \frac{Y_{\delta_A}}{m}, \frac{Y_{\delta_P}}{m}, L'_{\delta_A}, L'_{\delta_P}, N'_{\delta_A}, N'_{\delta_P}, \\ \Delta\dot{v}_{bias}, \Delta\dot{p}_{bias}, \Delta\dot{\phi}_{bias}, \Delta\dot{r}_{bias}, \tau_a, \tau_p \end{array} \right] =$$

$$\left[\begin{array}{c} -0,1348; -2,1647; 0,3043; -0,5327; -1,86; 0,2563; 0,1466; -0,1486; \\ -1,1913; 0,0863; 0,7291; 1,899; -0,7018; 0,0074; 0,7395; 0,2467; 0,3415; \\ 0,0152; 0,0028; 0,019; 0,0237 \end{array} \right]$$

No modo látero-direcional, pode-se observar na Figura 5.8, que representa a evolução da variável de variação de rolamento Δp , uma boa aderência entre os dados de observados e simulados com a calibração através do algoritmo MPCA. A concordância para Δp foi muito melhor do que a registrada para as variáveis mencionadas/simuladas à cima. Entretanto, há um pequeno erro de fase. Nota-se que em todo período de tempo da manobra o acoplamento do MPCA foi melhor do que o gerado pelo AG. A calibração com AG tem uma erro de fase menor, mas há uma discordância na amplitude de $\Delta p(t)$.

O melhor desempenho do MPCA também pode ser verificado na Figura 5.9, que mostra a variação da velocidade linear Δv . Novamente, observa-se que os processos não negligenciados no processo de modelagem não tiveram influência significativa para esta variável. A calibração com MPCA produz uma aderência de Δv dos dados do modelo próxima aos dados medidos, de forma similar ao registrado para Δp . A similaridade também é verificada para o erro de fase, em relação as variáveis Δv e Δp . Somente ao final da simulação a concordância de Δp foi melhor do que a de Δv .

A Figura 5.10 mostra a evolução da variável de variação da atitude lateral $\Delta\phi$ com o tempo. A calibração com MPCA registra uma diferença menor entre a observação e a simulação do que o modelo ajustado com AG. A discordância entre o modelo calibrado com AG é particularmente pronunciada a partir de $t > 35$, onde a simulação torna-se bastante distinta dos dados observados.

Por fim, a Figura 5.11 representa a variação da velocidade angular de guinada $\Delta r(t)$. A calibração com as diferentes técnicas MPCA e AG apresentou uma menor discre-

Figura 5.6 - Variação da Atitude Horizontal

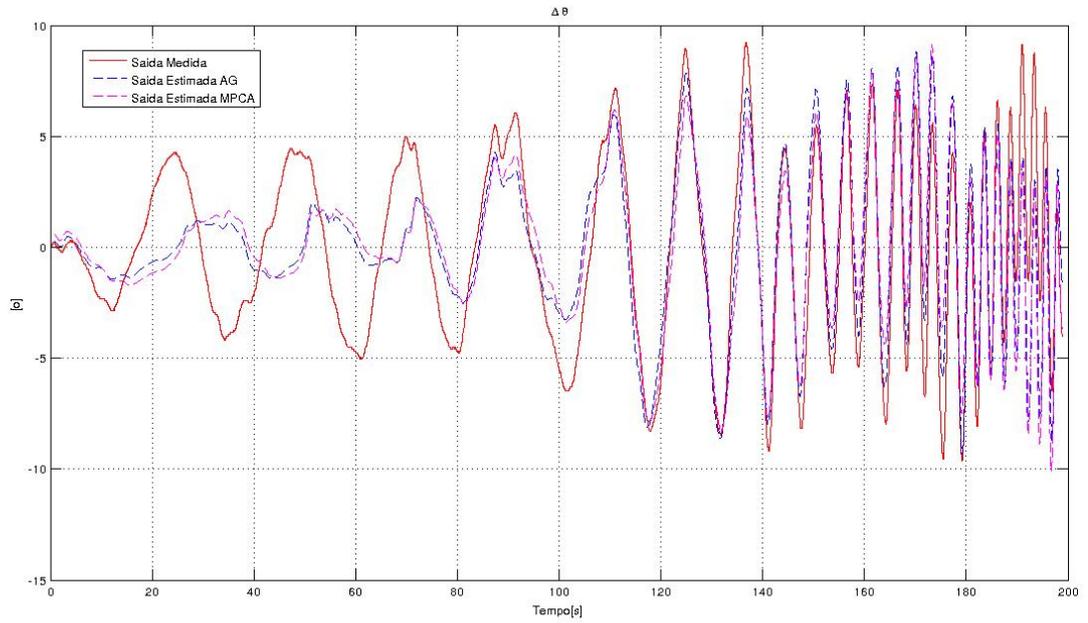


Figura 5.7 - Variação da Velocidade Angular de Arfagem

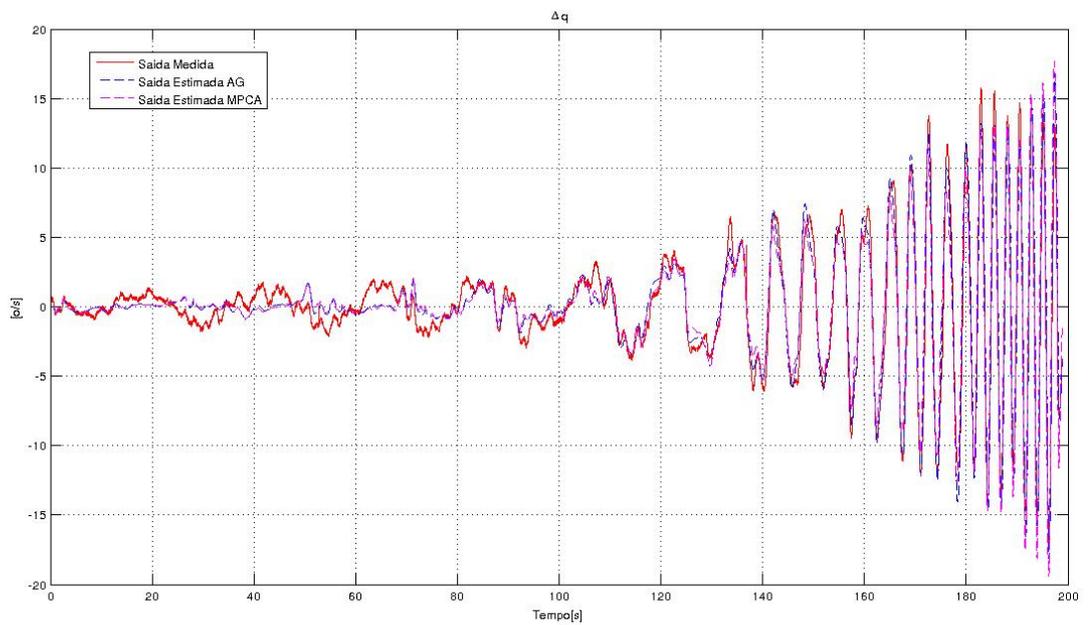


Figura 5.8 - Variação do Rolamento

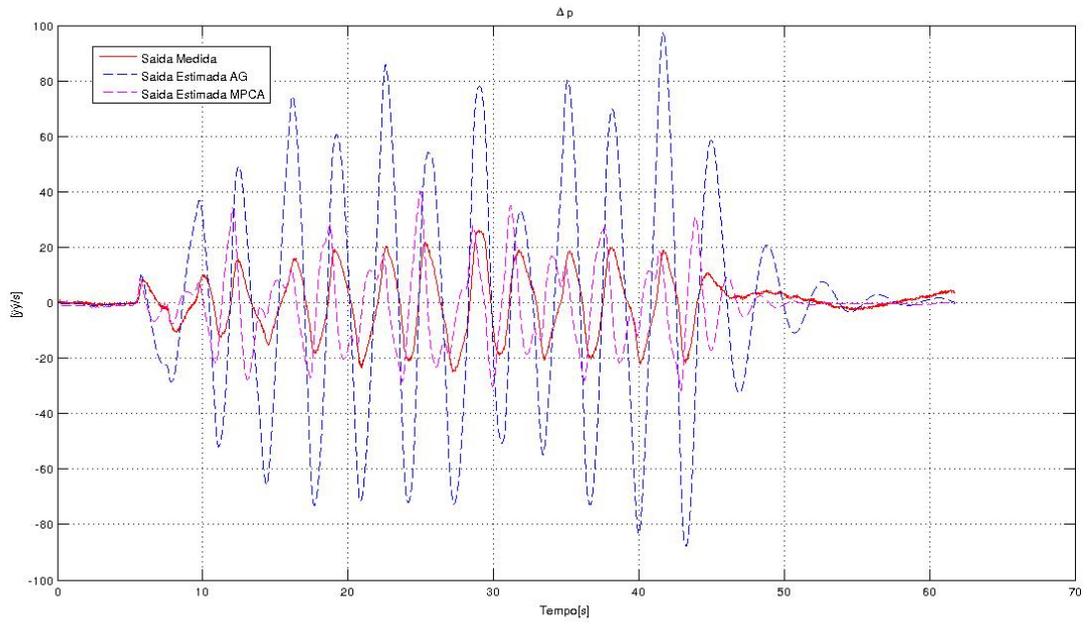
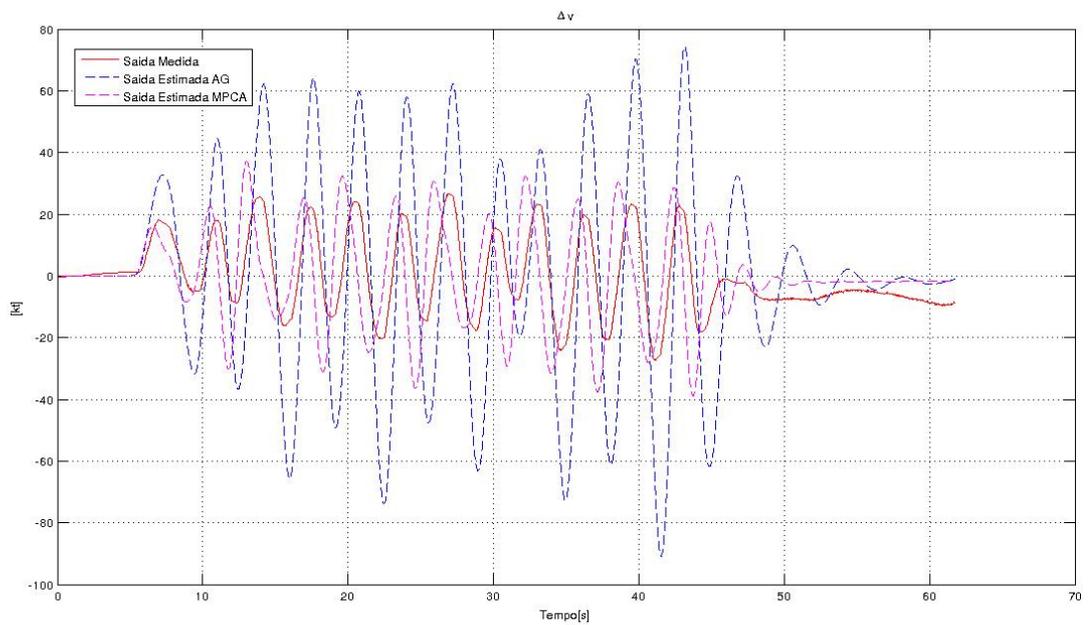


Figura 5.9 - Variação da Velocidade Linear no Eixo Y



pância entre os dois métodos do que registrado para as variáveis Δq , Δp e Δv . Em alguns pontos, a amplitude de Δr simulado com calibração por MPCA torna-se mais pronunciada do que os resultados mostrados nas Figuras 5.7, 5.8 e 5.9. Contudo, a calibração com MPCA foi melhor do que com AG em relação a amplitude, e gerou um erro de fase mais pronunciado do que os registrados para as variáveis Δp e Δv .

De modo geral, os resultados observados no modo látero-direcional mostram que houve uma melhora significativa na calibração produzida pelo MPCA superando os resultados obtidos pelo AG, em todos os gráficos. Provavelmente existem efeitos transientes que não estão representados no modelo. Esta falha na modelagem refletiu-se no desacoplamento entre a dinâmica observada e a dinâmica simulada, mesmo após a calibração com duas meta-heurísticas AG e MPCA empregadas.

As Tabelas 5.6 e 5.7 mostram os erros absolutos de cada algoritmo (AG e MPCA) com relação aos dados medidos. Os resultados da calibração para o modo Longitudinal são aproximadamente equivalentes. Contudo, há um desempenho melhor do MPCA em relação ao AG para o modo látero-direcional.

Tabela 5.6 - Erros Modo Longitudinal AG e MPCA

Estados	Erro - AG	Erro - MPCA
u	11,7650	10,8413
w	18,5301	16,8120
q	37,9712	34,4037
θ	6,0056	5,1544

Tabela 5.7 - Erros Modo Látero Direcional AG e MPCA

Estados	Erro - AG	Erro - MPCA
p	1435,9	157,72
ϕ	1294,7	198,08
v	1132,9	242,98
r	1206,0	377,71

Figura 5.10 - Variação da Atitude Lateral

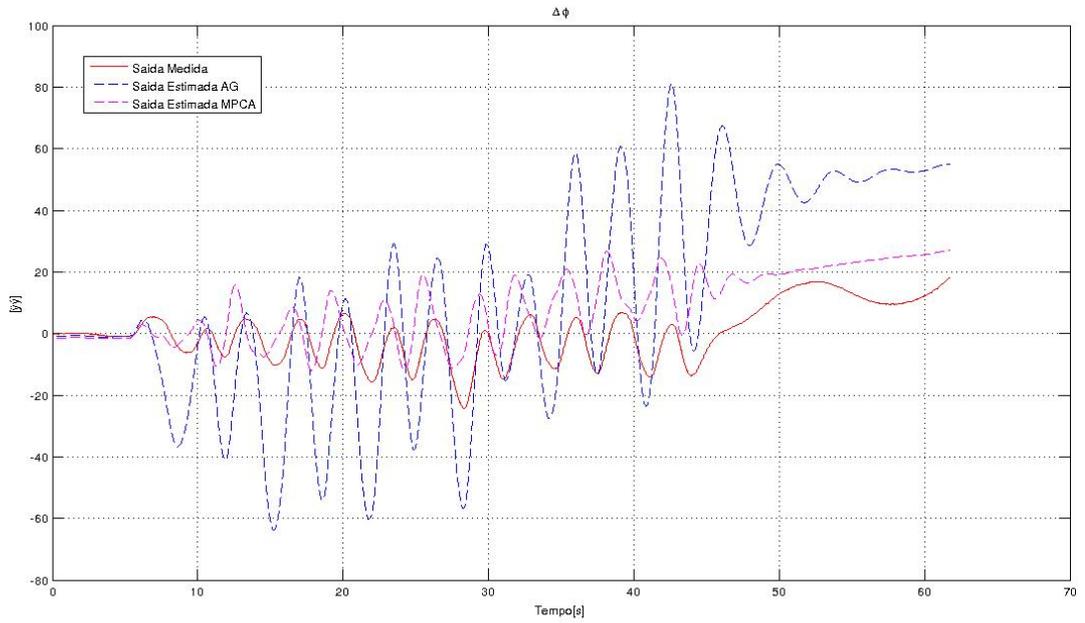
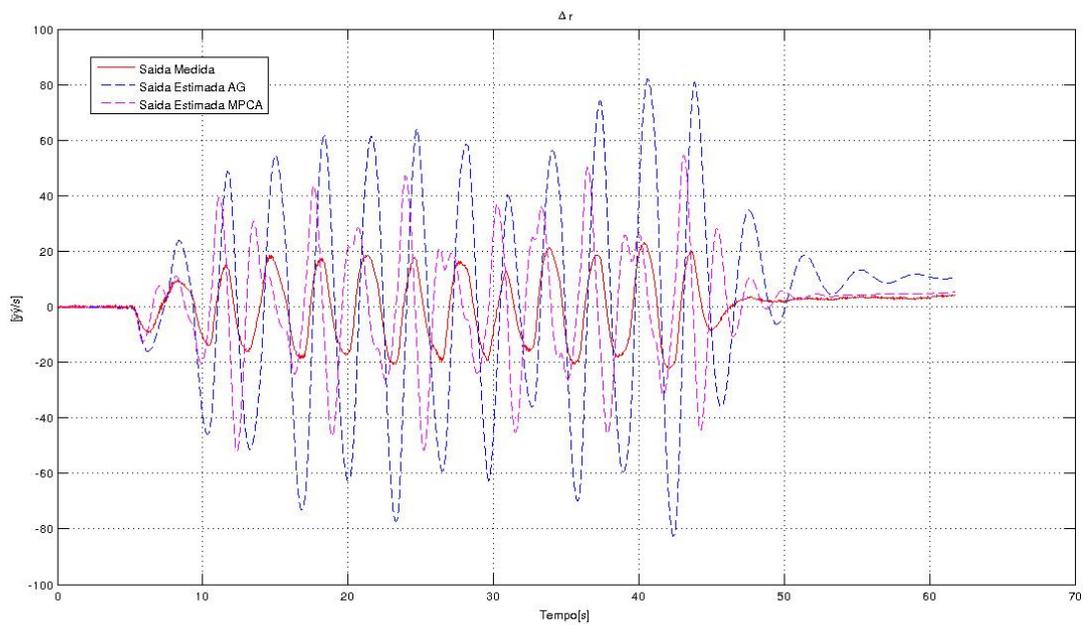


Figura 5.11 - Variação da Velocidade Angular de Guinada



6 ANÁLISE DA DINÂMICA DE ROTOR POR *BRED VECTOR*

Neste capítulo, primeiramente será apresentado o resultado da aplicação do Teste 0-1 para a dinâmica do rotor do helicóptero em seguida, os resultados obtidos com a metodologia *bred vector* para identificação dos padrões deste sistema serão mostrados. Para realizar a classificação da dinâmica, foram utilizadas as ferramentas neuro-difusas ANFIS e GUAJE descritas nas seções 4.4.1 e 4.4.2 e os resultados da classificação serão apresentados ao final deste capítulo.

6.1 Resultados da Aplicação do Teste 0-1 para Dinâmica do Rotor do Helicóptero

O Teste 0-1 foi utilizado para identificar se a dinâmica do rotor é caótica ou regular (periódica). O método foi codificado por [Matthews \(2009\)](#) e os seguintes parâmetros foram definidos para utilização do programa: o tamanho total da série temporal para a variável $x(t)$ possui 110.000 elementos. Tomou-se uma amostra da série temporal com 2000 elementos, onde a cada 50 passos de tempo toma-se o primeiro elemento desta amostra. Há um limite do número de entrada no código – nos nossos testes, utilizou-se 2000 pontos –, a restrição deve-se a um problema de sobreamostragem ([SILVA, 2012](#)). A sobreamostragem ocorre quando δt é muito pequeno. Também foram utilizados limite inferior para c igual a 0 e o limite superior igual 2π .

Inicialmente, o teste foi realizado com o período de simulação foi com 110.000 passos de tempo, com a amostra de 2000 elementos, resultando no valor de 0,0157 que caracteriza uma dinâmica regular. Como há geração de números aleatórios no processo do Teste 0-1, um total de 100 realizações foram executadas com a amostra de 2000 pontos. Realizou-se 100 execuções do teste e o resultado foi uma média 0,0679 com desvio padrão de 0,1914, indicando que a dinâmica do rotor do helicóptero é regular.

Para uma melhor avaliação, os testes de caracterização de regime regular ou caótico foram ampliados para um tempo de simulação $t \in [0; 2 \times 10^6 \Delta t]$. Assim, uma nova série temporal de 110.000 pontos foi obtida com pontos indexados de $1,89 \times 10^6$ até 2×10^6 . Novamente, amostrou-se 2000 pontos da segunda série temporal, da mesma forma como mencionado acima. Na aplicação do Teste 0-1, fez-se novamente 100 realizações e observou-se um comportamento diferente: a dinâmica apresentou propriedades não regulares para algumas das realizações. Ou seja, ampliando o tempo de simulação, os resultados com o Teste 0-1 oscilaram entre zero (a maioria dos casos) e resultados próximo de um. A Tabela 6.1 mostra parte dos resultados com o Teste

0-1 para a segunda série temporal. A resposta do teste nas realizações indexadas com 4 e 5 resultam em 0,9026 e 0,9693 – respectivamente.

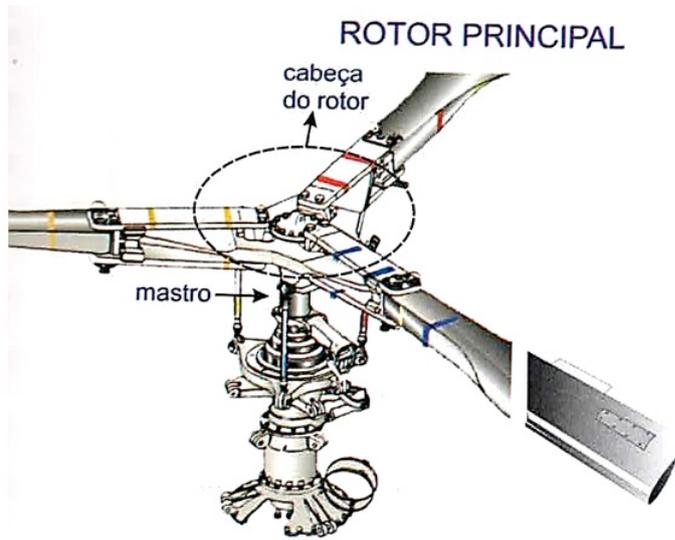
Tabela 6.1 - Resultados com o Teste 0-1 para segunda série temporal ($t \in [1, 89; 2] \times 10^6$).

Execução	K
1	0,0101
2	0,0078
3	0,0270
4	0,9026
5	0,9693
6	0,0780
7	0,0109
8	0,0035
9	0,0357
10	0,0083

6.2 Análise via *Bred Vector*

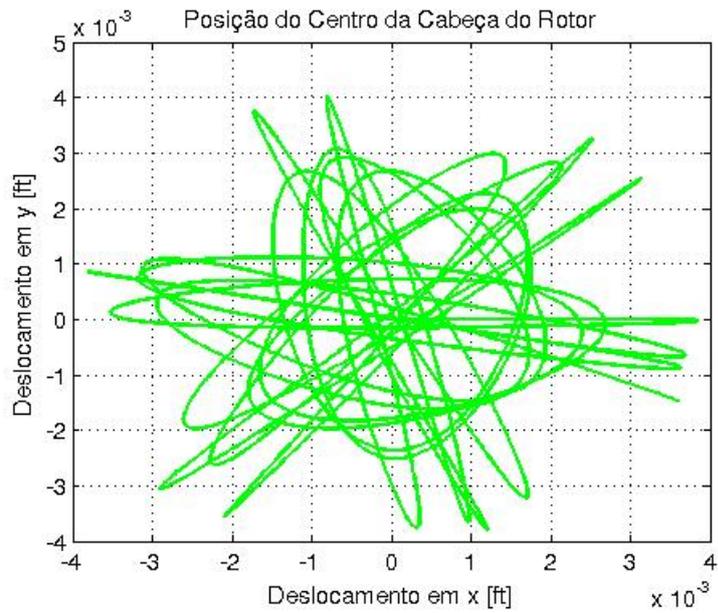
Um dos objetivos deste trabalho foi identificar os padrões que ocorrem no sistema dinâmico do rotor principal do helicóptero (Figura 6.1) e a partir destes padrões, realizar uma previsibilidade sobre o comportamento do sistema. Para isso, o modelo descrito na Seção 2.2 foi implementado em *Matlab* versão R2011b e os experimentos foram realizados no sistema operacional *Linux*, com processador *Intel Core I5* 2.27GHz e 3GB de memória. Os parâmetros utilizados no modelo foram: k_x e k_y como 113 lb/ft, $m_{B_i} = 0,1$ slug, $m_H = 6,8$ slug, $\Omega = 90$ rad/s e $h_B = 10$ ft. O sistema de equações foi integrado numericamente usando o método Runge-Kutta de quarta ordem com um passo de tempo de $\Delta t = 0,0001$, a Figura 6.2 ilustra a trajetória gerada que representa o deslocamento da cabeça do rotor.

Figura 6.1 - Rotor Principal



Fonte: Almanaque... (2008)

Figura 6.2 - Posição do Centro da Cabeça do Rotor



Ideia semelhante foi aplicada em Evans et al. (2004) apresentado no Capítulo 3 com o modelo de Lorenz no qual os autores chamaram de “*warm regime*” e “*cold regime*”. Observando a Figura 6.2, a dinâmica do rotor foi separada em dois regimes, referente à trajetória:

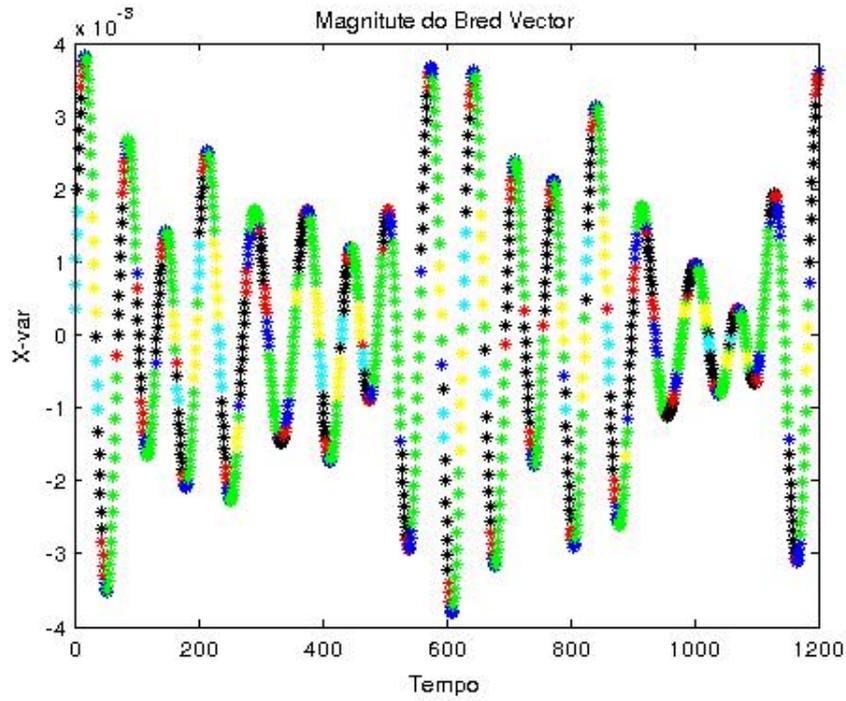
- a) **Quanto a curva:** virar à direita virar à esquerda.
- b) **Quanto a extensão:** trajetória longa ou curta.

Embora aparentemente simples, é difícil identificar nesses sistemas quando ocorre uma mudança de regime.

A técnica de *bred vector* foi aplicada no modelo descrito na Seção 2.2, o sistema de equações foi integrado usando o passo de tempo $\Delta t = 10^{-4}$, e em seguida foi adicionada uma pequena perturbação aos dados do modelo $\delta x_0 = 0,5$. A cada 8 passos de tempo, foi calculada a diferença entre as duas execuções (magnitude do *bred vector*).

A magnitude do *bred vector* serve tanto para estabelecer padrões identificar ou prever se a trajetória vai realizar uma curva a direita ou a esquerda, bem como estabelecer regras para expressar se a trajetória será longa ou curta. Na Figura 6.3, cada estrela colorida representa a magnitude do *bred vector*.

Figura 6.3 - Magnitude do *Bred Vector* para a Variável X do Modelo da Dinâmica do Rotor



A magnitude do *bred vector* é particionada para a análise da dinâmica. O particionamento adotado é dado na Tabela 6.2.

Tabela 6.2 - Tabela Relacionando Classes (cor) de Magnitudes do *Bred Vector* (BV).

Cor	Magnitude BV
Amarelo:	$[-0,0930 ; -0,0196]$
Verde:	$(-0,0196 ; -0,0013]$
Azul:	$(-0,0013 ; 0,0033]$
Vermelho:	$(0,0033 ; 0,0075]$
Preto:	$(0,0075 ; 0,0250]$
Azul claro:	$(0,0250 ; 0,2006]$

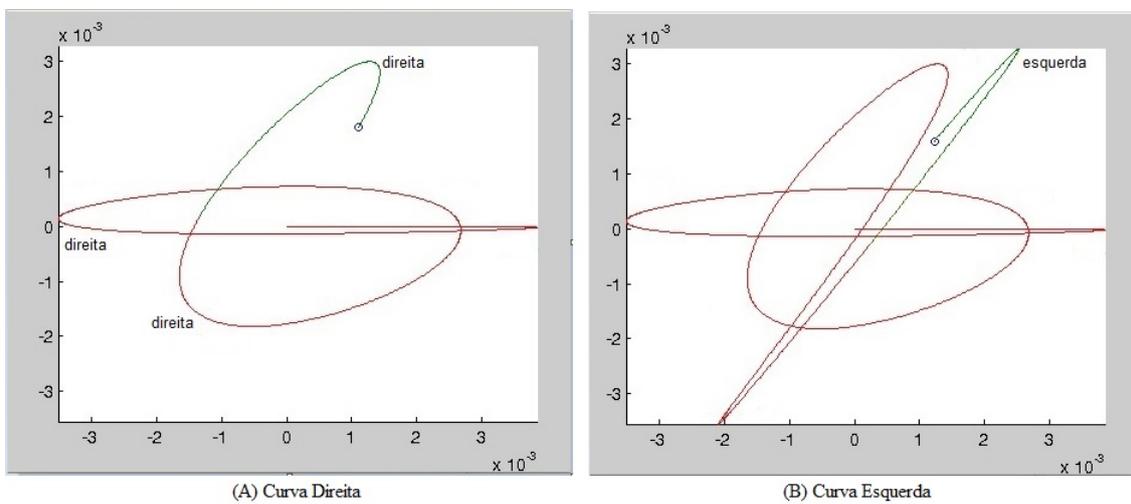
Adotou-se distintas cores em cada partição somente para tornar mais simples a análise realizada pelo analista, usada para estabelecer regras de caracterização da dinâmica. O uso de um sistema baseado em técnicas da inteligência artificial tem

por objetivo realizar este tipo de análise de forma automática.

6.2.1 Análise da dinâmica: tipo de curva

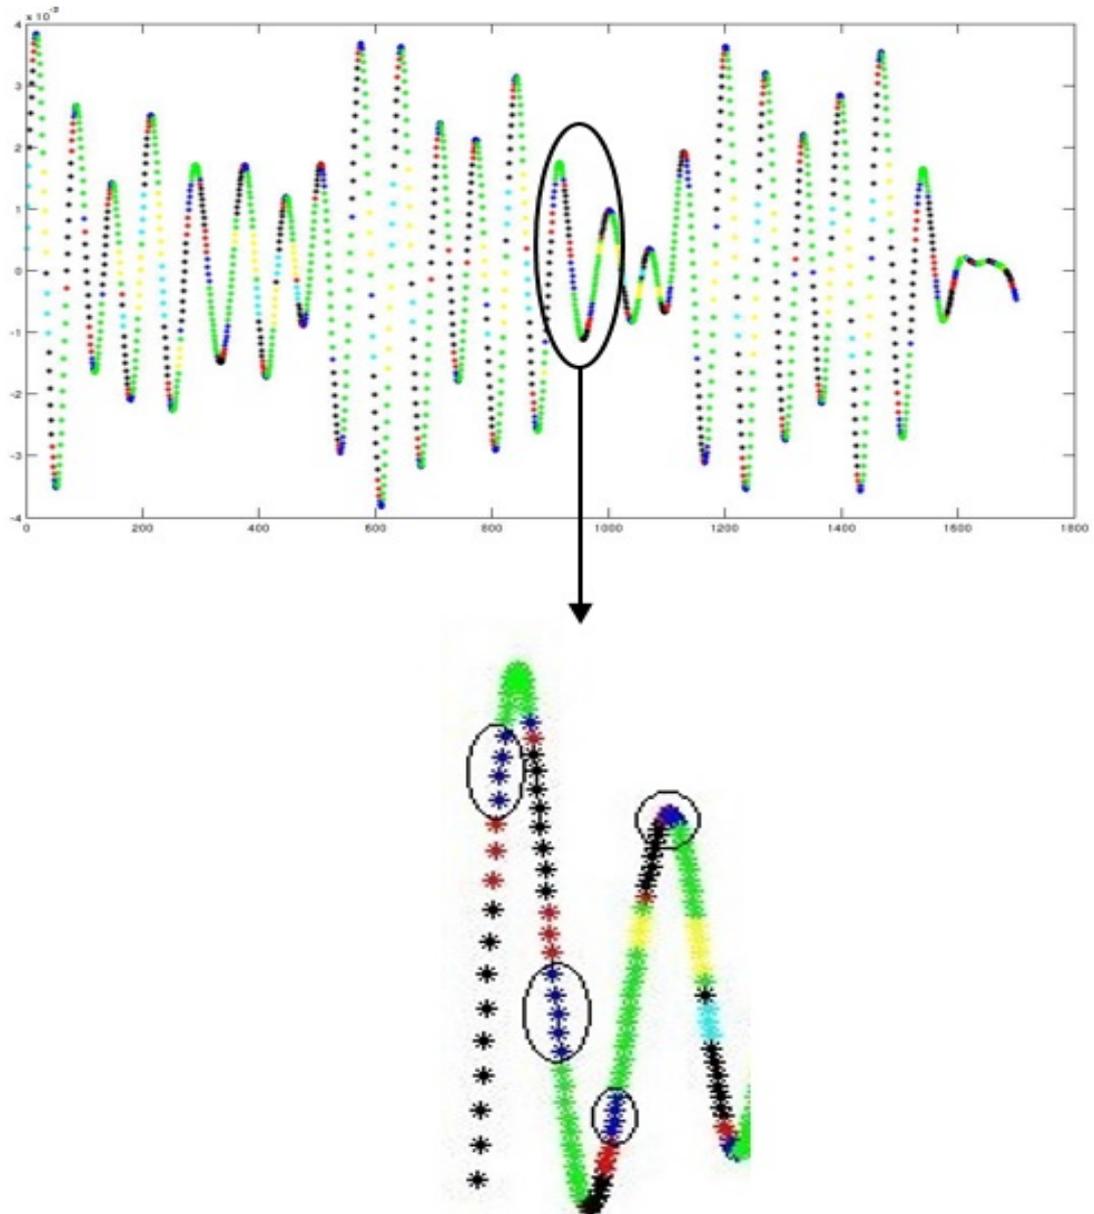
A Figura 6.4 ilustra as trajetórias do modelo e algumas curvas a direita e esquerda. Utilizando o método para identificação do tipo de curva apresentado na Seção 3.3, verificou-se que após a execução de 110.000 passos de tempo os regimes mudam 470 vezes, 365 à direita e 105 à esquerda.

Figura 6.4 - Curva Direita e Esquerda



Observou-se que em todas as ocorrências de um conjunto de 4 ou 5 *bred vectors* de magnitude azul escuro (Figura 6.5) a trajetória faz uma curva para direita ou esquerda. Essa identificação motivou a criação da regra para esta dinâmica para identificar/prever o momento que a trajetória faz uma curva.

Figura 6.5 - Amostras de *Bred Vector* Antecedendo Curvas



6.2.2 Análise da dinâmica: extensão da trajetória

Analisando o comportamento do sistema observou-se a necessidade de estabelecer um termo chamado “trajetória longa” que será usado nas regras observadas, o qual

é definido por:

$$TL \geq \alpha d_0 \quad (6.1)$$

onde d_0 é a distância entre dois pontos (x_1, y_1) e (x_2, y_2) (ver Figura 6.6) e α é expresso por:

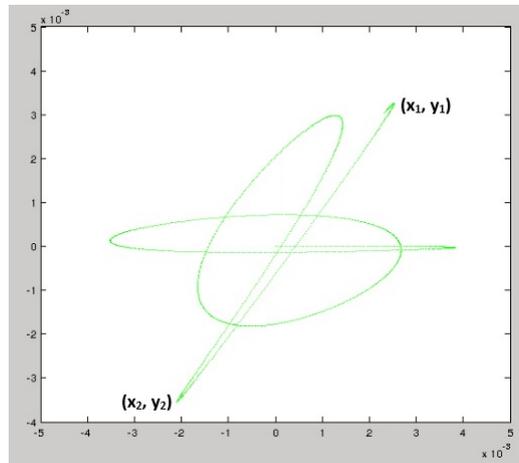
$$\alpha = \frac{\gamma}{v_\gamma} \quad (6.2)$$

onde γ é um parâmetro livre definido pelo usuário – aqui foi utilizado $\gamma = 0.007$, v_γ um parâmetro associado à dinâmica. O parâmetro v_γ foi fixado em 0.0083, que corresponde a maior distância entre dois desvios consecutivos de uma dada trajetória da dinâmica, calculado através da fórmula:

$$v_d = \max \left\{ \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \right\} \quad (6.3)$$

onde os pontos (x_i, y_i) e (x_j, y_j) são pontos que representam dois desvios consecutivos da trajetória no espaço de fase.

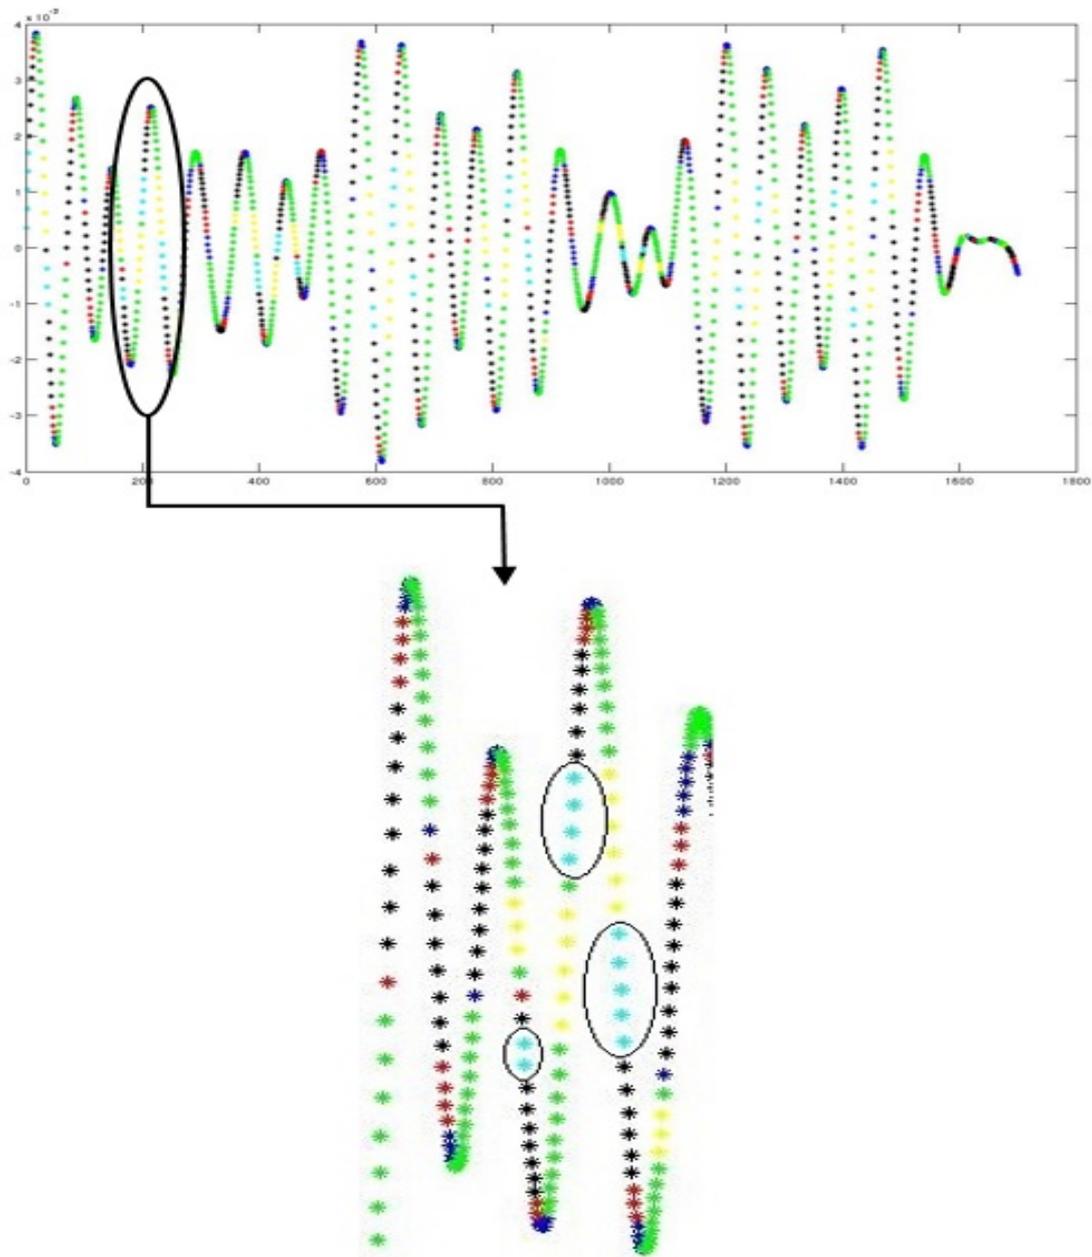
Figura 6.6 - Coordenadas Utilizadas para Definir a Extensão de uma Trajetória.



Após a execução de 110.000 passos de tempo foi identificado o total de 245 trajetórias longas. A Figura 6.7 ilustra as amostras da dinâmica que antecedem trajetórias longas no espaço de fase. Nota-se que um conjunto de *bred vectors* de diferentes magnitudes estão presentes. Entretanto, o *bred vector* de magnitude azul claro está sempre presente. A identificação deste comportamento motivou a criação da regra

para esta dinâmica para identificar/prever o início de trajetórias longas.

Figura 6.7 - Amostras de *Bred Vector* antedecedendo trajetórias longas.



6.2.3 Regras para a Dinâmica do Rotor de Helicóptero

A partir das definições apresentadas do tipo de curva, de trajetória longa e da magnitude do *bred vector*. Pode-se identificar empiricamente as seguintes regras:

- a) A presença de 4 ou 5 estrelas azuis escuro indicam que a trajetória irá virar (direita ou esquerda)
- b) Após uma sequência de 4 viradas à direita, a trajetória pode virar à esquerda uma ou duas vezes consecutivas no 5 ou 6 ciclo
- c) Toda trajetória longa possui pelo menos uma estrela azul claro
- d) Após uma sequência de 3 trajetórias longas, ocorre 2 viradas à esquerda
- e) Após uma sequência de 2 trajetórias longas, ocorre 1 virada à esquerda
- f) Após uma sequência de 2 viradas à esquerda consecutiva certamente a próxima virada sera à direita

Usando as regras descritas acima foram geradas as diferentes classes de dinâmica, que são representadas pela magnitude do *bred vector* e que serão as entradas para um classificador neuro-difuso.

6.3 Classificação Neuro-Difusa da Dinâmica

Estabelecer as regras para uma determinada dinâmica requer conhecimento e tempo do analista, pois não é uma tarefa fácil. Uma forma de liberar parte do tempo do analista é automatizar as regras que possam caracterizar a dinâmica.

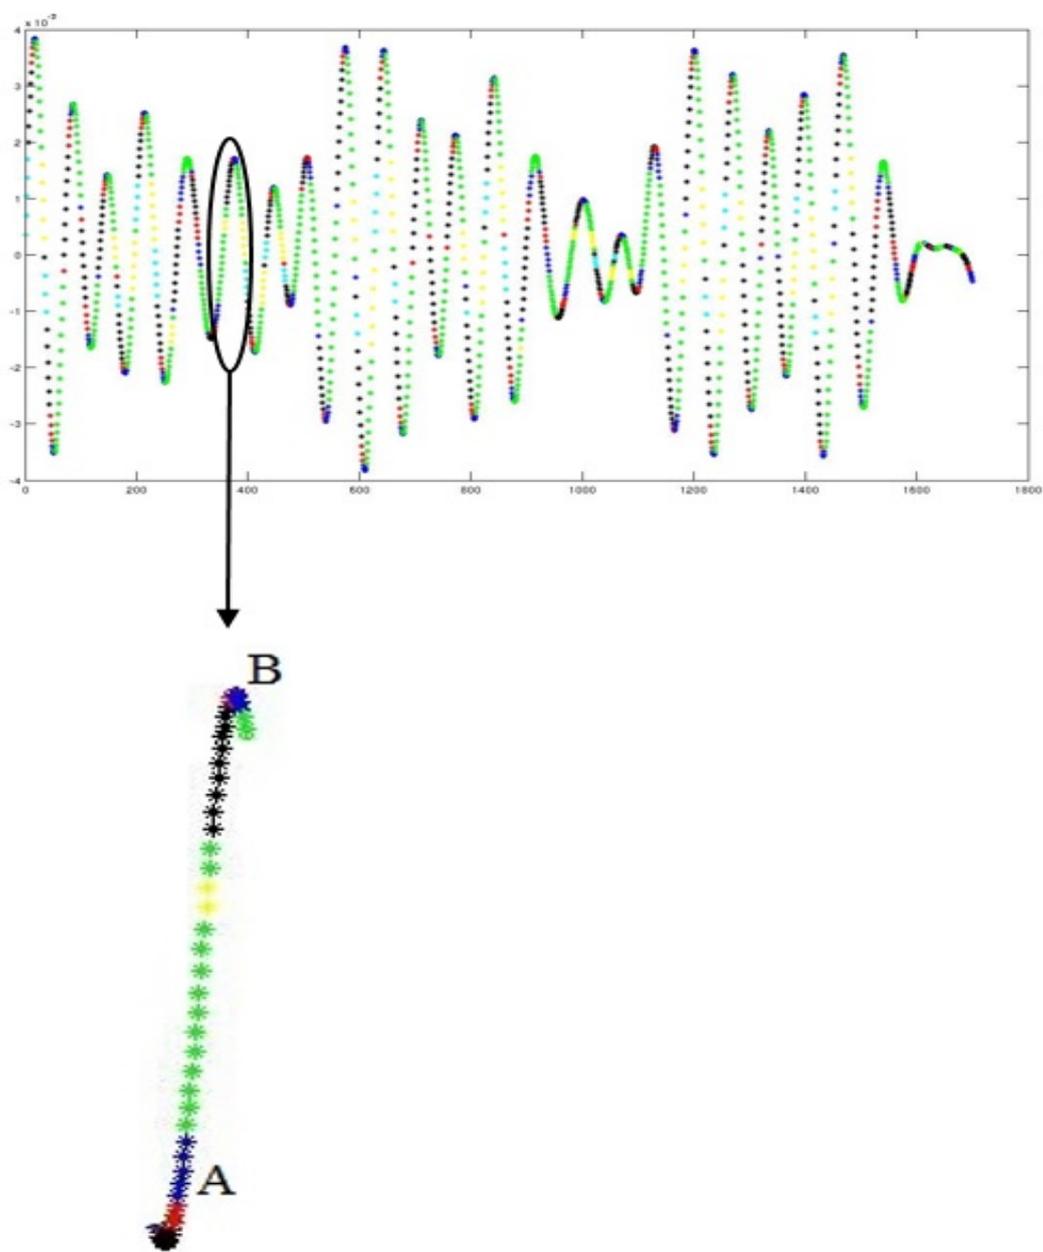
Técnicas de inteligência artificial podem ser aplicadas no estudo de automatização da criação de regras. O emprego de sistemas difusos (*fuzzy*) ou neuro-difusos são particularmente adequados para este propósito. Deste modo, é possível utilizar os padrões de *bred vector* (magnitudes) para estabelecer as regras da dinâmica.

A análise com ferramentas neuro-difusas será exemplificada com a identificação da dinâmica referente ao tipo de curva realizada por uma trajetória no espaço de fase. Para este caso, seleciona-se o conjunto de entradas (atributos: seqüência de *bred vectors*) obtidos da dinâmica para identificar o tipo de *curva – padrão*, ou ainda, *classe*. Após a correta configuração do sistema neuro-difuso, a resposta (saída) deverá corresponder ao tipo de curva/trajetória a ser seguida pela dinâmica do rotor.

Cada padrão possui 6 entradas, sendo cada entrada o número de estrelas de uma determinada cor que representam a magnitude (intervalo de valores) do *bred vector*. O início e o fim de cada amostra ocorre quando é identificado o começo/fim de uma curva (4 ou 5 *bred vectors* azul escuro). Por exemplo, na Figura 6.8 a amostra tem

início em A e fim em B. Após o conjunto de BV azul escuro é inicializada a contagem do BV de cada cor: verde(13), amarelo(2), azul claro(0), preto(10), vermelho(4) e azul escuro(4). Se na amostra não aparecer alguma das magnitudes é assumido o valor zero (0) para a cor não encontrada, neste exemplo não apresenta a magnitude azul claro.

Figura 6.8 - Exemplo de um amostra de entrada para sistemas *neuro-fuzzy*



A saída desejada foi definida de acordo com a mudança do regime virar à esquerda (saída 0) ou virar à direita (saída 1) apresentado na [Seção 3.3](#). Assim, serão utilizadas duas classes de saída :

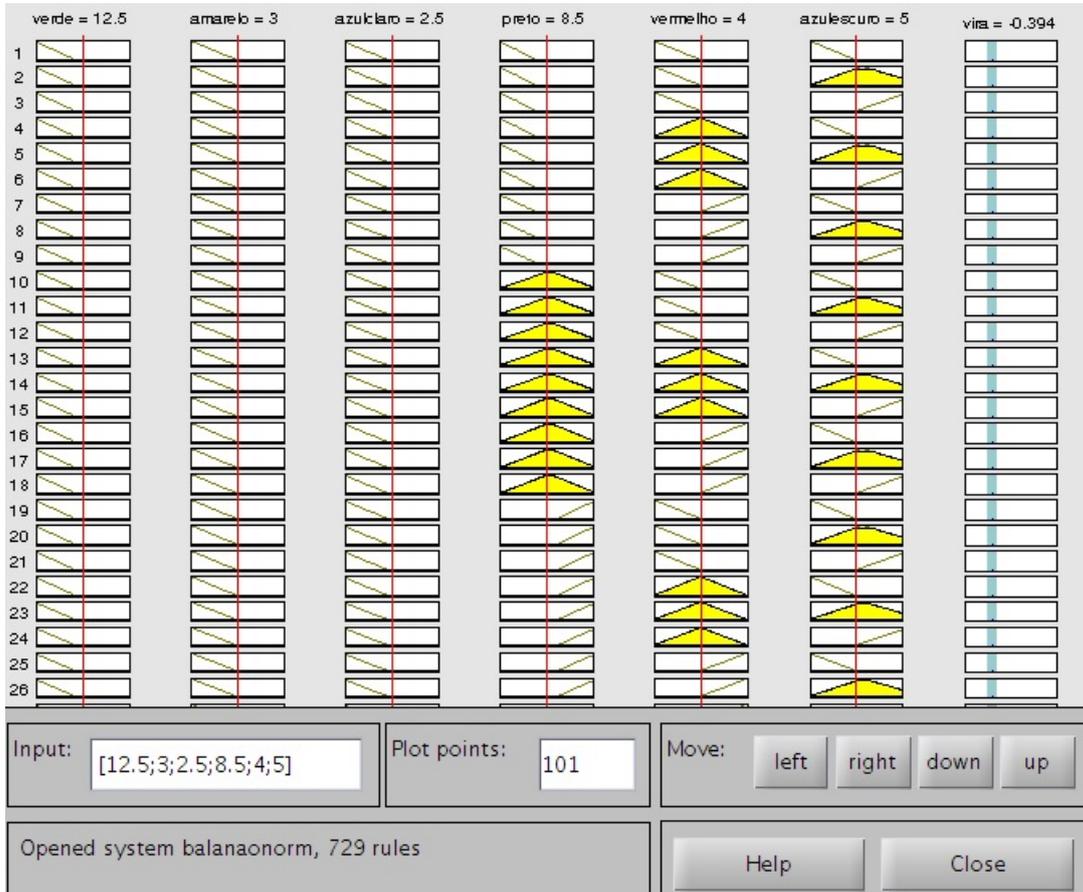
- **Classe 0:** A trajetória vira à esquerda
- **Classe 1:** A trajetória vira à direita

O modelo foi executado por 110.000 passos de tempo, resultando em uma amostra com 470 padrões. A amostra foi dividida em dois arquivos: treinamento (329 padrões, corresponde a 70% do total), validação (141 padrões, corresponde a 30% do total).

Foram realizados oito experimentos diferentes para os arquivos de treinamento e validação. Os dados foram divididos em balanceados e não balanceados e normalizados e não normalizados. As variáveis de entrada utilizadas foram normalizadas com o objetivo de manter um formato uniforme e diminuir a grande variabilidade dos dados, mantendo-os em uma escala de 0 a 1. E o balanceamento dos dados foi realizado para evitar o problema de ter classes desbalanceadas, isto é, quando existe uma grande desproporção entre o número de amostras de cada classe, essa situação frequentemente faz com os exemplos da classe minoritária sejam classificados incorretamente.

Os testes com o classificador neuro difuso ANFIS (apresentado na [Seção 4.4.1](#)) foram realizados com o *software* Matlab versão R2011b, o qual possui uma implementação que trabalha com arquivos de treinamento e validação com pares de entradas/saídas desejadas e que ao final do treinamento gera um arquivo com extensão “.fis”, que é um sistema difuso do tipo Takagi-Sugeno utilizado no MATLAB. Entretanto, ele gera regras que não são facilmente interpretáveis como ilustra a [Figura 6.9](#).

Figura 6.9 - Regras Geradas pelo ANFIS



Para fins de comparação e também para gerar um classificador com regras mais facilmente interpretáveis, o *software* GUAJE (apresentado na Seção 4.4.2) foi utilizado. O sistema GUAJE permite criar um sistema difuso do tipo Mamdani, gerando regras (Figura 6.10) automaticamente através de seus algoritmos.

Figura 6.10 - Regras Geradas pelo GUAJE

Rule	Type	If Verde	AND Amarelo	AND AzulClaro	AND Preto	AND Vermelho	AND AzulEscuro	THEN Vira
1				0.0				1.0
2			3.0	1.0				0.0
3			4.0	1.0				1.0
4				2.0	8.0	3.0		1.0
5				2.0	9.0	3.0		0.0
6				2.0		4.0		0.0
7				3.0			4.0	1.0
8				3.0	6.0		5.0	1.0
9				3.0	7.0		5.0	1.0
10				3.0	8.0		5.0	0.0
11				3.0			6.0	0.0
12				4.0	6.0	3.0		1.0
13		10.0		4.0	6.0	4.0		1.0
14		11.0		4.0	6.0	4.0		0.0
15				4.0	6.0	5.0		0.0
16				4.0	7.0			0.0
17				5.0				0.0

A seguir, será apresentada a matriz de confusão para cada experimento. Nesta matriz, as linhas representam a saída calculada e as colunas a saída desejada. Desta forma, a diagonal principal representa os acertos do sistema. O conjunto de validação foi apresentado ao classificador somente uma vez, para testar a sua capacidade de generalização, ou seja, responder corretamente a um conjunto de entradas fora do conjunto de treinamento.

Utilizando as 141 amostras de validação, obteve-se o mesmo percentual de 77,3% de acertos com o ANFIS (Tabela 6.3) para os experimentos com os dados não balanceados e não normalizados e normalizados. A diferença ocorreu na classificação das classes com os dados não balanceados e não normalizados que teve um acerto maior da classe-0, enquanto com os dados não balanceados e normalizados ocorreu um acerto maior da classe-1. Os mesmos experimentos para o GUAJE (Tabela 6.4) produziram um acerto de 84,4% com os dados não balanceados e não normalizados e de 85,1% para os dados não balanceados e normalizados.

Tabela 6.3 - Matriz de Confusão - Dados Não Balanceados (ANFIS).

		Não normalizados		Normalizados	
Classes	0	1	Classes	0	1
0	25	8	0	23	10
1	24	84	1	22	86

Tabela 6.4 - Matriz de Confusão - Dados Não Balanceados (GUAJE).

Não normalizados			Normalizados		
Classes	0	1	Classes	0	1
0	22	11	0	22	11
1	11	97	1	10	98

Para o experimento com os dados balanceados, obteve-se o mesmo percentual de acertos de 83,68% para os dados não normalizados e 85,1% para os normalizados com o ANFIS (Tabela 6.5). O GUAJE (Tabela 6.6) produziu resultados melhores para ambos os experimentos, para os dados não normalizados teve um acerto de 85,8% e para os normalizados 87,2%.

Tabela 6.5 - Matriz de Confusão - Dados Balanceados (ANFIS).

Não normalizados			Normalizados		
Classes	0	1	Classes	0	1
0	58	12	0	61	9
1	11	60	1	12	59

Tabela 6.6 - Matriz de Confusão - Dados Balanceados (GUAJE).

Não normalizados			Normalizados		
Classes	0	1	Classes	0	1
0	67	3	0	66	4
1	17	54	1	14	57

7 CONCLUSÕES

O processo de calibração consiste em ajustar os parâmetros desconhecidos de forma a se ter o melhor ajuste de um modelo matemático com as observações do fenômeno. O problema pode ser formulado como um problema de otimização. Há várias técnicas para determinar a solução ótima de um funcional: técnicas deterministas – como o método de máxima descida, método de Newton, gradiente conjugado, entre outras (GILL et al., 1981) – e métodos estocásticos. Muitos métodos de solução de um problema de otimização são inspirados em processos da natureza: simulação de recozimento de estruturas cristalinas (*simulated annealing*), processo de especiação de seres vivos (*algoritmos genéticos*), formigas em busca de comida (*sistema de colônia de formigas*), fissão nuclear (*particle collision*), entre outros. Algoritmos que emulam um processo que são empregados para resolver problemas de otimização são chamados de *meta-heurísticas*.

A meta-heurística conhecida como MPCA foi a estratégia adotada para realizar o ajuste dos parâmetros do modelo de dinâmica do helicóptero, pois tem demonstrado eficiência em problemas como identificação dos perfis de temperatura (SAMBATTI et al., 2012), previsão climática de precipitação (ANOCHI; CAMPOS VELHO, 2014) e na solução de um problema inverso radiativo (TORRES et al., 2015). Assim sendo, na primeira fase deste trabalho foram realizadas as seguintes tarefas: implementar o MPCA em *Matlab*, compreender a dinâmica de helicópteros e aplicar meta-heurísticas para resolver o problema de calibração de parâmetros para um simulador de voo.

Apesar das discrepâncias de amplitude, especialmente da velocidade u e de θ , o MPCA apresentou resultados relativamente equivalentes ao AG para o Modo Longitudinal – ver Tabela 5.6. Para o modo Látero Direcional, os resultados com MPCA tiveram erros significativamente menores do que os obtidos com o AG – ver Tabela 5.7. As simulações obtidas com o modelo calibrado foram satisfatórias, mas não reproduziram as observações de toda a dinâmica simulada. A falta de aderência entre os dados simulados e as medidas pode ser explicada por erros de modelagem e pelo uso de um modelo linearizado.

O modelo de um rotor de helicóptero foi representado por uma dinâmica não linear. A análise desta dinâmica foi o tópico da fase seguinte da tese. Primeiramente, aplicou-se o Teste 0-1 para uma amostra de tamanho 110.000, com o objetivo de identificar se a dinâmica do rotor era caótica ou periódica (regular). O resultado obtido constatou um comportamento periódico. Porém, ao se ampliar o tempo de simulação e obtendo uma nova série temporal, os resultados do Teste 0-1 foram diferentes. Ou seja, ao

se ampliar o tempo de simulação, alguns testes (a maioria dos casos) indicam uma dinâmica regular, mas outros casos têm resultados próximo de 1, associado a uma dinâmica caótica. A Tabela 6.1 mostra os resultados com o Teste 0-1 para a segunda série temporal $t \in [1, 89 \times 10^6 \Delta t, 2 \times 10^6 \Delta t]$. Desta forma, a partir dos resultados, é difícil asseverar de forma categórica, a luz do Teste 0-1, que se trata de uma dinâmica totalmente periódica ou regular.

Após a realização dessa análise, a técnica de *bred vector* foi empregada com o objetivo de selecionar padrões e identificar a dinâmica em classes de previsibilidade. Para tanto, foram gerados pares de entrada-saída desejada de acordo com os valores dos *bred vectors*. Dois aspectos foram considerados para tipificar a dinâmica: referente ao tipo de curva e a extensão da trajetória. O uso de *bred vector* permitiu a criação de um conjunto de regras que caracterizam a dinâmica do rotor.

Bred vectors também foram empregados para alimentar os classificadores ANFIS e GUAJE. Estes sistemas estão baseados em técnicas da inteligência computacional. As classes identificam se a trajetória no espaço de fase seguirá com uma curva à direita ou curva à esquerda. Como a curva à direita (classe-1) ocorre com maior frequência nesta dinâmica, os sistemas de classificação tiveram um maior índice de acerto para esta classe: o ANFIS obteve 79,62% e o GUAJE 90,74%. Para a classe-0, o acerto foi de 75,75% para o ANFIS e 66,68% para o GUAJE. Nota-se que a normalização não apresentou melhoras significativas com os dados não balanceados (ver Tabelas 6.3 e 6.4).

Para os dados balanceados, houve uma melhora com classificador ANFIS para classe-1 83,09% e para classe-0 87,14% com os dados normalizados. Com o GUAJE obteve-se um acerto de 80,28% para classe-1 com os dados normalizados e 95,71% para classe-0 com os dados não normalizados. Apesar de ter obtido um percentual maior para classe-0 com os dados não normalizados, o melhor resultado geral foi alcançado com os dados balanceados e normalizados: 87,2% com o GUAJE. Isto ressalta a importância para o classificador que os conjuntos de amostras de treinamento e validação sejam bem distribuídos. Em uma avaliação geral, os classificadores foram satisfatórios, alcançando a acurácia acima dos 80% de acertos com o ANFIS e GUAJE.

Sistemas neuro-difusos são capazes de gerar regras de forma automática. O sistema GUAJE gera regras mais facilmente interpretáveis do que o sistema ANFIS e a acurácia ficou em geral acima dos 80%, em todos os experimentos realizados com a utilização do GUAJE.

A primeira motivação de aplicar os sistemas neuro-difusos foi, de fato, para gerar regras automáticas. Contudo, o sistema fornece outras informações pertinentes à análise. Por exemplo, o sistema GUAJE mostra que o *bred vector* de magnitude *amarela* não tem influência sobre o tipo de curva a ser seguida pela trajetória. Esta informação indica que esta partição não é necessária. Pode-se associar as informações para agrupar os intervalos de magnitude do *bred vector*, o que pode facilitar ainda mais a análise.

Como sugestões para trabalhos futuros propõe-se:

- calibração com o MPCA para um modelo mais completo de aeronaves e com mais graus de liberdade, além de aplicação em simuladores de voo de veículos espaciais (foguetes);
- aplicar um outro método para afirmar de forma mais definitiva se a dinâmica do rotor de helicóptero é de fato não caótica;
- com o aumento do tempo de simulação, descobriu-se outros padrões identificados (como três curvas à esquerda consecutivas) que poderiam ser tipificados como uma classe distinta ou usar uma classificação de nível diferenciado – uso de sub-classes¹, desta forma o estudo deve ser ampliado;
- incluir outros atributos para caracterizar a dinâmica do rotor e gerar regras, em futuro imediato poderia ser o estudo de caracterização de trajetória longa/curta, pois o estudo preliminar já foi realizado;
- redimensionar as partições da magnitude do *bred vector*, algumas partipartição podem ser agrupadas. É possível que o tipo de partição tenha uma implicação positiva na classificação, alterando a análise;
- utilizar outras ferramentas computacionais para classificação da dinâmica, como por exemplo redes neurais artificiais, classificação hierárquica (com a adoção de subclasses, citadas no item acima), árvores de decisão, entre outras técnicas.

¹Um exemplo de sub-classe seria: tomando-se somente as curvas à direita, poder-se-ia subdividir em 3 sub-classes: sub-classe-1 (com menos de 4 giros simultâneos à direita), sub-classe-2 (com 4 giros simultâneos à direita), sub-classe-3 (com mais de 4 giros simultâneos à direita).

REFERÊNCIAS BIBLIOGRÁFICAS

- ALMANAQUE Pilots Help. [S.l.]: Pilots Help Editora, 2008. 59
- ALONSO, J. M.; MAGDALENA, L. Hilk++: an interpretability-guided fuzzy modeling methodology for learning readable and comprehensible fuzzy rule-based classifiers. **Soft Computing**, v. 15, n. 10, p. 1959–1980, 2011. 35
- ALONSO, J. M.; PANCHO, D. P.; MAGDALENA, L. Enhancing the fuzzy modeling tool guaje with a new module for frigrams-based analysis of fuzzy rule bases. In: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE (WCCI), Brisbane, Australia. **Proceedings...** Brisbane: IEEE, 2012. p. 1082–1089. 3, 36
- ANOCHI, J. A.; CAMPOS VELHO, H. F. Optimization of feedforward neural network by multiple particle collision algorithm. In: FOUNDATIONS OF COMPUTATIONAL INTELLIGENCE, Orlando, FL. **Proceedings...** Orlando: IEEE, 2014. p. 128–134. 48, 73
- AVANZINI, G.; MATTEIS, G. de. Bifurcation analysis of a highly augmented aircraft model. **Journal of Guidance, Control, and Dynamics**, v. 20, n. 4, p. 754 – 759, 1997. 2
- BECCENERI, J. C.; RAMOS, F. M.; CAMPOS VELHO, H. F.; SILVA, J. D. S. d.; LORENA, L. A. N.; VIJAYKUMAR, N. L.; SANTOS, R.; ROSA, R. R.; TRAVELHO, J. d. S. Meta-heurísticas e otimização combinatória: Aplicações em problemas ambientais. In: **Computação e matemática aplicada as ciências e tecnologias espaciais**. São José dos Campos: INPE, 2012. p. 65–81. 45
- BECK, J. V.; ARNOLD, K. **Parameter estimation in engineering and science**. [S.l.]: John Wiley Sons Inc, 1977. 39
- BECK, J. V.; BLACKWELL, B.; JR, C. R. S. C. **Inverse heat conduction: Ill-posed problems**. [S.l.]: Wiley-Interscience, 1985. 39
- CAMPOS VELHO, H. F. Problemas inversos em pesquisa espacial (mini-curso). **Congresso Nacional de Matemática Aplicada e Computacional**, São Carlos (SP), 2008. 39
- CHANG, Y.-F. Social thermodynamics, social hydrodynamics and some

mathematical applications in social sciences. **International Journal of Modern Social Sciences**, p. 94–108, 2013. 16

CINTRA, R. S.; VELHO, H. F. d. C. Predictability for a chaotic chaotic solar plasma system. In: IBERIAN LATIN AMERICAN CONGRESS IN COMPUTATIONAL METHODS IN ENGINEERING, 29. (CILAMCE)., 2008, Maceió, AL, 4-7 November,. **Proceedings...** [S.l.], 2008. Setores de Atividade: Aeronáutica e espaço. Acesso em: 25 set. 2017. 2, 23

COOKE, A.; FITZPATRICK, E. **Helicopter test and evaluation**. [S.l.]: AIAA Education Series, 2002. 9

CORAZZA, M.; ; KALNAY, E.; PATIL, D. J.; YANG, S.-C.; MORRS, R.; CAI, M.; SZUYOGH, I.; HUNT, B. R.; YORKE, J. A. Use of the breeding technique to estimate the structure of the analysis errors of the day. **Nonlinear Processes in Geophysics**, p. 1–11, 2003. 2, 19

CRUZ, R. V. **Desenvolvimento de um modelo dinâmico para simuladores de helicóptero**. Tese (Tese de Doutorado) — Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 2009. 3, 5, 6, 40, 41, 42, 43, 49

CURVO, M. **Modelagem aerodinâmica e controle estocástico adaptativo de aeronaves de alto desempenho por redes neurais artificiais e estimação de parâmetros**. Tese (Tese de Doutorado) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2001. 5

DEVI, P. D.; SINGH, S.; SHARMA, S. A. Deterministic dynamics of the magnetosphere: results of the 0?1 test. **Nonlinear Processes in Geophysics**, v. 20, p. 11–18, 2013. 17

DORIGO, M. **Ottimizzazione, apprendimento automatico, ed algoritmi basati su metafora naturale**. Tese (Ph.D. Dissertation) — Politécnico di Milano, 1992. 44

EVANS, E.; BHATTI, N.; KINNEY, J.; PANN, L.; PEÑA, M.; YANG, S.-C.; KALNAY, E.; HANSEN, J. Rise undergraduates find that regime changes in lorenz’s model are predictable. **Bulletin of the American Meteorological Society**, v. 85, p. 521–524, 2004. 2, 20, 21, 22, 23, 60

EVSUKOFF, P. E. M. de Almeida e A. G. **Sistemas *fuzzy* In: Sistemas**

- Inteligentes: Fundamentos e Aplicações.** [S.l.]: Editora Manole, 2005. 28
- FIEDLER-FERRARA, N.; PRADO, C. P. C. do. **Caos: uma introdução.** [S.l.]: Edgard Blucher, 1994. 17
- FIRMINO, F. L. **Simulação e controle de um helicóptero a partir de modelos linearizados em sete pontos de linearização.** Dissertao (Mestrado) — Instituto Militar de Engenharia, Rio de Janeiro, 2008. 5
- GILL, P. E.; MURRAY, W.; WRIGHT, M. H. **Practical optimization.** [S.l.]: Academic press, 1981. 73
- GOLDBERG, D. **Genetic algorithms in search, optimization and machine learning.** 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. 44
- GOMIDE, F. A. C.; GUDWIN, R. R. Modelagem, controle, sistemas e lógica fuzzy. **Revista da SBA Controle & Automação**, v. 4, n. 3, p. 97 – 115, September 1994. 28
- GONZAGA, F. G. **Modelos computacionais para análise da vibração acoplada rotor-pás com aplicação em turbinas eólicas e ressonância de solo de helicópteros.** Dissertao (Projeto de Graduação) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013. 3, 5, 13, 14
- GOTTWALD, G. A.; MELBOURNE, I. A new test for chaos in deterministic systems. **Proceedings of the Royal Society of London A**, v. 460, p. 603–611, 2004. 17
- _____. Testing for chaos in deterministic systems with noise. **Physica D**, v. 212, p. 100–101, 2005. 17, 18
- _____. On the implementation of the 0-1 test for chaos,. **SIAM Journal on Applied Dynamical Systems**, v. 1, n. 8, p. 129–145, 2009. 17, 18
- GUILLAUME, S.; CHARNOMORDIC, B. Learning interpretable fuzzy inference systems with fispro. **International Journal of Information Sciences**, v. 181, n. 20, p. 4409–4427, 2011. Special Issue on Interpretable Fuzzy Systems. 35
- HAMEL, P. G.; JATEGAONKAR, R. V. Evolution of flight vehicle system identification. **Journal of Aircraft**, v. 33, n. 1, p. 9–28, 1996. 40

HANGAR33. **Princípio aerodinâmico das asas rotativas**. 2015. Disponível em: <blog.hangar33.com.br/principios-aerodinamicos-das-asas-rotativas>. 6, 12

HOLLAND, J. H. **Adaptation in natural and artificial systems**. [S.l.]: University of Michigan Press, 1975. 44, 48

IMSE-CNM. **Fuzzy logic design tools: XFuzzy 3.0**. 2003. Disponível em: <http://www2.imse-cnm.csic.es/Xfuzzy/Xfuzzy_3.0/Xfuzzy3.0_en.pdf>. 35

ISHIBASHI, R. **Extração de conhecimentos com interpretabilidade aumentada utilizando modelagem *fuzzy* e otimização multi-objetivo**. Dissertao (Tese de Doutorado) — Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 2013. 31

JAHNKE, C. C.; CULICK, F. E. C. Application of bifurcation theory to the high-angle-of-attack dynamics of the f-14. **Journal of Aircraft**, v. 31, n. 1, p. 26 – 34, 1994. 2

JANG, J.-S. R. Anfis: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 23, n. 3, p. 665 – 685, 1993. 3, 33, 34

KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by simulated annealing. **Science**, v. 220, n. 4598, p. 671 – 680, 1983. 44

LACERDA, E. G. M.; CARVALHO, A. C. P. L. F. Introdução aos algoritmos genéticos. In: CONGRESSO NACIONAL DA SOCIEDADE BRASILEIRA DE COMPUTACÃO, Rio de Janeiro, RJ. **Anais**. PUC-Rio: SBC, 1999. p. 52–126. 49

LEE, Y. kyu; KIM, K. joon. Ground resonance analysis for an eight-degrees-of-freedom rotorcraft with double-stage oleo-pneumatic shock absorbers. **Journal of a Aircraft**, v. 47, n. 5, p. 65 – 91, 2010. 13

LICHOTA, P.; LASEK, M. Maximum likelihood estimation for identification of aircraft aerodynamic derivatives. **Archive of Mechanical Engineering**, v. 60, p. 219 – 230, June 2013. 40

LIMA, D. C. **Um framework *fuzzy* para priorização de requisitos de *software***. Dissertao (Dissertação de Mestrado) — Universidade Estadual do

Ceará, Ceará, 2011. 29

LINDEN, R. **Algoritmos genéticos**. 3. ed. [S.l.]: Editora Ciência Moderna, 2012. 45, 49

LITAK, G.; SAWICKI, J. Regular and chaotic vibrations in the rub impact model of a jeffcott rotor with a fractional restore force. **Eur Phys J Appl Phys**, v. 64, p. 31303, 2013. 17

LORENZ, E. N. Deterministic non-periodic flow. **Journal of the Atmospheric Sciences**, v. 20, p. 130–141, 1963. 16, 20, 21

LUDERMIR, T. B.; CARVALHO, A. P. de Leon F. de; BRAGA, A. de P.; SOUTO, M. C. P. de. **Sistemas inteligentes híbridos**. In **Sistemas Inteligentes: Fundamentos e Aplicações**. New Jersey: Manole Ltda, 2003. 31

LUZ, E. F. P.; BECCENERI, J. C.; CAMPOS VELHO, H. F. de. A new multi-particle collision algorithm for optimization in a high-performance environment. **Journal of Computacional Interdisciplinary Sciences**, v. 1, n. 1, p. 3 – 10, 2008. 45, 47

LUZ, E. F. P. d. **Meta-heurísticas paralelas na solução de problemas inversos**. 155 p. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011-03-08 2012. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m19/2012/02.22.17.13>>. Acesso em: 31 jul. 2017. 45, 47, 48, 49

MACHADO, E. A. **Estimação das derivadas de estabilidade e controle do modelo Dinâmico longitudinal de um helicóptero**. Dissertao (Dissertação de Mestrado) — Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 2016. 1, 40

MACIEL, B. C. de O.; GÓES, L. C. S.; VASCONCELOS, L. J. de H. Identificação das derivadas de estabilidade e controle do movimento longitudinal da aeronave xavante at-26. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, Gramado, RS. **Anais**. Gramado: UFRGS, 2004. 1, 40

MAMDANI, E. H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-Machine Studies**, v. 7, n. 1, p. 1 – 13, 1975. 31

- MATTEWS, P. **Código de programa: teste 0-1**. 2009. Disponível em:
<http://www.mathworks.com/matlabcentral/fileexchange/25050-0-1-test-for-chaos/all_files>. 57
- MORAES, F. de H. **Comportamento dinâmico não linear de um sistema mecânico com vibrações associadas a uma transição brusca na rigidez**. Dissertao (Dissertação de Mestrado) — Universidade Estadual Paulista (Unesp), Bauru, 2012. 16
- NETO, N. S. B. **Desenvolvimento e otimização de manobras de ensaio em voo para estimação de derivadas de estabilidade e controle de aeronaves**. Dissertao (Dissertação de Mestrado) — Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 2005. 39, 40
- NOBRE, J. ao C. S. **Modelo computacional para valoração e avaliação de redações baseado em lógica *fuzzy***. Dissertao (Tese de Doutorado) — Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 2011. 27
- OES, M. S.; SHAW, I. **Controle e modelagem *fuzzy***. [S.l.]: Editora Blucher, 2007. 29
- ORTEGA, N. R. S. **Aplicação da teoria de conjuntos *fuzzy* a problemas da biomedicina**. Dissertao (Tese de Doutorado) — Universidade de São Paulo (USP), São Paulo, 2001. 29
- PENTEADO, F. B. L. **Método de filtragem *fuzzy* para avaliação de bases de dados relacionais**. Dissertao (Dissertação de Mestrado) — Universidade de São Paulo, São Carlos, 2009. 30, 31
- PEREIRA, D. C. **Dinâmica não linear e controle de uma aeronave em voo longitudinal**. Tese (Tese de Doutorado) — Universidade Estadual de Campinas, Campinas, Julho 2007. 2
- PICCIRILLO, V.; BALTHAZAR, J. M.; TUSSET, A. M. Chaos control and impact suppression in rotor-bearing system using magnetorheological fluid. **Eur Phys J Appl Phys**, v. 224, p. 3023–3040, 2015. 17
- PROUTY, R. W. **Helicopter performance, stability and control**. [S.l.]: Krieger Publishing Company, 1995. 9
- PRUCOLE, E. dos S. **Avaliação de combinações de classificadores *fuzzy***.

Dissertao (Dissertação de Mestrado) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006. 30

RAISINGHNI, S. C.; GHOSH, A. K. Parameter estimation of an aeroelastic aircraft using neural networks. *Sãdhãna*, v. 25, n. 20, p. 181–191, 2000. 1

RODRIGUES, L. E. M. J. **Fundamentos da engenharia aeronáutica**. [S.l.]: Cengage Learning, 2015. 11

ROMERO, L. F. S. **Classificação de previsibilidade do modelo global do CPTEC utilizando breeding e inteligência computacional**. 135 p. Dissertao (Mestrado) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2017-05-23 2017. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m21b/2017/05.12.20.32>>. Acesso em: 31 jul. 2017. 23, 29

SACCO, W. F.; C., K. D.; LUZ, E. F. P.; NETO, A. J. da S. Algoritmo de colisão de partículas. **Técnicas de Inteligência Computacional Inspiradas na Natureza Aplicação em Problemas Inversos em Transferência Radiativa**, p. 79 – 90, 2009. 45

SACCO, W. F.; OLIVEIRA, C. R. E. D. **A new stochastic optimization algorithm based on a particle collision metaheuristic**. 2005. 45

SAMBATTI, S. B. M. **Diferentes estratégias de paralelização de um algoritmo genético epidêmico aplicadas na solução de um problema inverso em transferência de calor**. Dissertao (Mestrado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004-12-17 2004. Acesso em: 31 jul. 2017. 49

SAMBATTI, S. B. M.; ANOCHI, J. A.; LUZ, E. F. P. d.; CARVALHO, A. R.; SHIGUEMORI, E. H.; CAMPOS VELHO, H. F. Automatic conguration for neural network applied to atmospheric temperature prole identication. In: INTERNATIONAL CONFERENCE ON ENGINEERING OPTIMIZATION (ENGOPT)., 2012, Rio de Janeiro - RJ. **Proceedings...** [S.l.], 2012. Acesso em: 31 jul. 2017. 48, 73

SANCHEZ, E. C. M. **Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência**. Dissertao (Dissertação de Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro (PUC), Rio de

Janeiro, 2009. 32, 33

SANDRI, S. A.; CORREA, C. **Lógica nebulosa**. 1999. Disponível em: <http://www.gta.ufrj.br/ensino/cpe717-2011/curso_ERN99_fuzzy.pdf>. 27, 28

SANTOS, P. L. B. d. **Previsibilidade em sistemas caóticos utilizando sistemas neuro-difusos**. 114 p. Dissertao (Mestrado) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014-04-15 2014. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m21b/2014/06.12.01.41>>. Acesso em: 31 jul. 2017. 2, 23, 31

SHANNON, R. **System simulation: the art and science**. New Jersey: Prentice-Hall, 1975. 39

SILVA NETO, A. J.; BECCENERI, J. C.; CAMPOS VELHO, H. F. **Inteligência computacional aplicada a problemas inversos em transferência radiativa**. 1a. edição. ed. [S.l.]: Editora da UERJ, 2016. 45

SILVA, R. D. da. **Estudo numérico e experimental da dinâmica não linear de um giroscópio**. Dissertao (Mestrado) — Universidade Estadual do Oeste do Paraná, Foz do Iguaçu, 2012. 57

SILVA, R. E. P. **Teoria de voo**. [S.l.], 2013. 12

SUMIDA, I. Y.; CAMPOS VELHO, H. F.; LUZ, E. F. P. d.; CRUZ, R. V.; GÓES, L. C. S. Iterative estimation for flight dynamic helicopter simulator. In: **3rd Conference of Computational Interdisciplinary Science**. [S.l.: s.n.], 2014. p. 264–266. 52

_____. MPCA for flight dynamics parameters determination. In: 8TH INTERNATIONAL CONFERENCE ON INVERSE PROBLEMS IN ENGINEERING (ICIPE), Gliwice-Krakow, Poland. **Book of Abstracts**. Institute of Thermal Technology Silesian University of Technology, 2014. p. 363–372. 50

_____. Flight dynamics parameter estimation of a rotary wing aircraft using the output error minimization with natural and meta heuristic methods. In: PAN-AMERICAN CONGRESS ON COMPUTATIONAL MECHANICS (PANACM), Buenos Aires, Argentina. **Proceedings...** Barcelona, Spain: CIMNE, 2015. p. 1435–1445. 52

_____. Iterative estimation for flight dynamic helicopter simulator. **Journal of Mathematics and System Science**, v. 5, p. 501 – 508, 2015. 50

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 15, n. 1, p. 116 – 132, 1985. 31

TAKENS, F. Detecting strange attractors in turbulence. **Springer Berlin Heidelberg**, p. 366 – 381, 1981. 17

TANSCHHEIT, R. **Sistemas fuzzy**. 2009. Disponível em: <<http://www.dainf.cefetpr.br/~myriam/PastaWeb/Fuzzy/ApostilaFuzzy.pdf>>. 27, 30

THOMAS, S.; BAJPAI, G.; KWATNY, H. G.; CHANG, B.-C. Nonlinear dynamics, stability & bifurcation in aircraft: simulation and analysis tools. In: AIAA GUIDANCE, NAVIGATION, AND CONTROL CONFERENCE AND EXHIBIT, San Francisco, California. **Proceedings...** Reston, VA: AIAA, 2005. 16

TISCHLER, M. B.; REMPLE, R. K. **Aircraft and rotorcraft system identification**. [S.l.]: AIAA Education Series, 2006. 43

TOMINAGA, J. **Simulador de satélites para verificação de planos de operações em voo**. 174 p. Dissertao (Mestrado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010-04-16 2010. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m19@80/2010/05.24.18.55>>. Acesso em: 31 jul. 2017. 1

TORRES, R. H.; LUZ, E. F. P. d.; CAMPOS VELHO, H. F. Multi-particle collision algorithm for solving an inverse radiative problem. In: **Integral Methods in Science and Engineering: Theoretical and Computational Advances**. New York (USA): Birkhäuser, 2015. p. 309–319. ISBN 9783319167268. Disponível em: <<http://www.springer.com/us/book/9783319167268>>. Acesso em: 31 jul. 2017. 48, 73

TOTH, Z.; KALNAY, E. Ensemble forecasting at ncep: the generation of perturbations. **Bulletin of the American Meteorological Society**, v. 74, p. 2317–2330, 1993. 19

_____. Ensemble forecasting at ncep and the breeding method. **Monthly**

Weather Review, v. 126, p. 3292–3302, 1997. 2, 19

VIANA, M. V. P. **Aplicação da teoria de estabilidade de aeronaves para certificação de integração de cargas externas em aeronaves militares**. Dissertao (Mestrado) — Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos, 2011. 11

WOLF, A.; SWIFT, J.; SWINNEY, H.; VASTANO, J. Determining lyapunov exponents from a time series. **Physica D**, v. 16, p. 285 – 317, 1985. 17

YAMASHITA, W. M. S. **Estudo de modelos dispersivos da dinâmica de populações**. Dissertao (Dissertação de Mestrado) — Universidade Federal de Juiz de Fora, Juiz de Fora, 2014. 16

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 33, p. 338 – 353, 1965. 27