

UNIVERSIDADE DE SÃO PAULO  
ESCOLA DE ENGENHARIA DE SÃO CARLOS  
ÁREA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

Serviço de Pós-Graduação EESC/USP  
EXEMPLAR REVISADO  
Data de entrada no Serviço: 23.107.03  
Ass.: *Kawafku*

OTIMIZAÇÃO DE PARÂMETROS DE CONTROLADORES  
DIFUSOS PARA ESTRUTURAS INTELIGENTES

Édson Mulero Gruppioni

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Flávio Donizeti Marques

DEDALUS - Acervo - EESC



31100043537

São Carlos

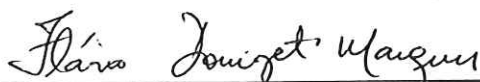
2003



**FOLHA DE JULGAMENTO**

Candidato: Engenheiro **ÉDSON MULERO GRUPPIONI**

Dissertação defendida e julgada em 23-04-2003 perante a Comissão Julgadora:




Prof. Dr. **FLÁVIO DONIZETI MARQUES (Orientador)**  
(Escola de Engenharia de São Carlos/USP)

APROVADO



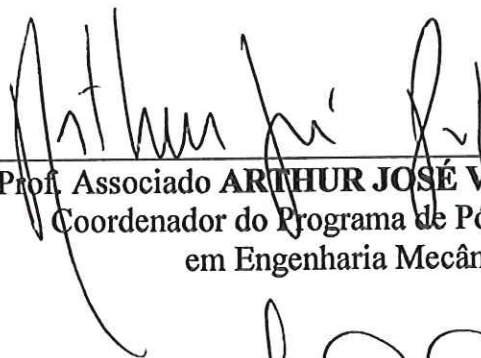
Prof. Assoc. **EDUARDO MORGADO BELO**  
(Escola de Engenharia de São Carlos/USP)

APROVADO



Prof. Dra. **VILMA ALVES DE OLIVEIRA**  
(Escola de Engenharia de São Carlos/USP)

APROVADO



Prof. Associado **ARTHUR JOSÉ VIEIRA PORTO**  
Coordenador do Programa de Pós-Graduação  
em Engenharia Mecânica



Prof. Assoc. **MARIA DO CARMO CALIJURI**  
Presidente da Comissão de Pós-Graduação

## AGRADECIMENTOS

Ao meu orientador Prof. Flávio Marques pela competência, paciência, dedicação e incentivo para a realização deste trabalho.

À Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela bolsa de estudo concedida.

Ao Prof. Eduardo Belo pelas dicas e colaboração.

Aos amigos Renato, Luciane, Elizângela, Márcio, Alexandre, Carlos, Daniela, Cláudio, Valdinei, Guilherme, Gasparini e todos amigos do Laboratório de Dinâmica de Vôo e Controle e da pós-graduação, pela colaboração, incentivo, amizade e pelos momentos de convívio e descontração.

A todos os colegas, professores e funcionários do Departamento de Engenharia Mecânica da EESC/USP que permitiram a elaboração deste trabalho.

## SUMÁRIO

LISTA DE SÍMBOLOS .....	i
RESUMO .....	iii
<i>ABSTRACT</i> .....	iv
CAPÍTULO 1	
INTRODUÇÃO .....	1
1.1 – Estruturas inteligentes.....	3
1.2 – Estruturas inteligentes em aeroelasticidade .....	4
1.3 – Atuadores e sensores piezelétricos para estruturas inteligentes.....	5
1.4 – Controle de estruturas inteligentes .....	7
1.4.1 – Lógica difusa.....	9
1.5 – Otimização do controlador difuso via algoritmos genéticos.....	10
1.6 – Objetivos do trabalho.....	12
1.7 – Organização do texto.....	13
CAPÍTULO 2	
MODELO MATEMÁTICO DA ESTRUTURA ATIVA .....	14
2.1 – Introdução .....	14
2.2 – Modelagem do comportamento eletromecânico .....	15
2.3 – Modelo de viga ativa pelo método dos elementos finitos.....	17
2.4 – Modelo reduzido.....	21
2.5 – Sumário .....	23



## CAPÍTULO 3

CONTROLE VIA LÓGICA DIFUSA	24
3.1 – Introdução .....	24
3.2 – Controle convencional e não convencional .....	24
3.3 – Fundamentos da lógica difusa .....	25
3.4 – Modelo lingüístico de Mamdani.....	29
3.5 – Modelo de Takagi-Sugeno-Kang .....	36
3.6 – Projeto de controlador difuso .....	37
3.7 – Sumário .....	42

## CAPÍTULO 4

OTIMIZAÇÃO DE CONTROLADORES DIFUSOS VIA ALGORITMO GENÉTICO	43
4.1 – Introdução .....	43
4.2 – Fundamentos de algoritmos genéticos.....	44
4.2.1 – Representação e codificação de indivíduos .....	45
4.2.2 – Definição da população inicial .....	47
4.2.3 – Função de aptidão .....	47
4.2.4 – Seleção de indivíduos.....	49
4.2.5 – Operadores genéticos .....	50
4.2.5.1 – Recombinação .....	50
4.2.5.2 – Mutação.....	51
4.2.6 – Elitismo.....	52
4.2.7 – Considerações diversas.....	52
4.2.7.1 – Critérios de substituição.....	52
4.2.7.2 – Desempenho de um algoritmo genético.....	52
4.3 – Processo de otimização de um controlador difuso por algoritmo genético.....	53
4.3.1 – Obtenção dos ganhos do controlador .....	53
4.3.2 – Obtenção das funções de pertinência .....	54
4.3.3 – Processo de otimização .....	55
4.4 – Sumário .....	57

## CAPÍTULO 5

### PROJETO DE CONTROLADOR DIFUSO PARA ESTRUTURA

INTELIGENTE	58
5.1 – Introdução .....	58
5.2 – Modelo da viga .....	59
5.3 – Estrutura do controlador difuso .....	60
5.4 – Estrutura e parâmetros do algoritmo genético .....	62
5.5 – Resultados e discussões .....	65
5.5.1 – Controlador difuso com ganhos ajustados manualmente e ganhos ajustados pelo AG .....	66
5.5.2 – Controlador difuso com ganhos ajustados manualmente e funções de pertinência ajustadas pelo AG .....	76
5.5.3 – Controlador difuso com ganhos e funções de pertinência ajustados separadamente pelo AG .....	79
5.5.4 – Controlador difuso com ganhos e funções de pertinência ajustados simultaneamente pelo AG .....	82
5.5.5 – Superfícies de decisão dos controladores difusos .....	88
5.6 – Verificação do desempenho do algoritmo genético .....	90
5.7 – Sumário .....	92

## CAPÍTULO 6

CONCLUSÕES	93
------------	----

6.1 – Sugestões para trabalhos futuros .....	95
--	----

REFERÊNCIAS BIBLIOGRÁFICAS .....	96
----------------------------------	----

## LISTA DE SÍMBOLOS

<b>A</b>	Matriz de estados
<b>B</b>	Matriz de entrada ou de controle
<b><math>B_\phi</math></b>	Operador gradiente
<b>C</b>	Matriz de saída
<b><math>C^E</math></b>	Módulo de Young
<b><math>C_{qq}</math></b>	Matriz global de amortecimento
<b>d</b>	Matriz das constantes de deformações piezelétricas
<b>D</b>	Matriz de transmissão direta
<b><math>d_{ij}</math></b>	Vetor das constantes de deformação piezelétricas
<b>e</b>	Matriz de coeficientes piezelétricos
<b>E</b>	Vetor campo elétrico
<b>F</b>	Força mecânica externa
<b>G</b>	Força elétrica externa
<b>I</b>	Matriz identidade
<b><math>K_{\phi\phi}</math></b>	Matriz global de rigidez dielétrica
<b><math>K_{\phi\phi s}</math></b>	Matriz global de rigidez dielétrica do sensor
<b><math>K^*</math></b>	Matriz global de rigidez
<b><math>K_{q\phi}</math></b>	Matriz global de rigidez eletroelástica ou de acoplamento
<b><math>K_{q\phi s}</math></b>	Matriz global de rigidez eletroelástica ou de acoplamento do sensor
<b><math>K_{qq}</math></b>	Matriz global de rigidez elástica
<b><math>M_{qq}</math></b>	Matriz global de massa
<b><math>N_u</math></b>	Função de forma para deslocamento axial
<b><math>N_w</math></b>	Função de forma para deslocamento transversal
<b><math>P_b</math></b>	Matriz de forças de corpo
<b><math>P_C</math></b>	Vetor de força concentrada
<b><math>P_S</math></b>	Vetor de força de superfície

---

$Q$	Carga elétrica superficial
$\mathbf{q}$	Vetor das coordenadas generalizadas
$\mathbf{q}_k$	Vetor dos deslocamentos axial, transversal e giro no elemento $k$
$s$	Variável de Laplace
$\mathbf{S}$	Vetor de deformação específica do material
$S_1$	Superfície de atuação de $\mathbf{P}_S$
$S_2$	Superfície de atuação de $Q$
$T$	Energia cinética total
$U$	Energia potencial total
$\mathbf{u}$	Vetor das entradas do sistema
$u_i$	Deslocamento axial no nó $i$
$u_k$	Deslocamento axial no elemento $k$
$V$	Volume
$\mathbf{v}_d$	Autovetor direito da matriz $\mathbf{A}$
$\mathbf{v}_e$	Autovetor esquerdo da matriz $\mathbf{A}$
$W$	Trabalho total das forças externas
$\mathbf{w}$	Vetor deslocamento transversal
$w_i$	Deslocamento transversal no nó $i$
$w_k$	Deslocamento transversal no elemento $k$
$x$	Varição do comprimento ao longo do elemento
$\mathbf{x}$	Vetor das variáveis de estado
$\mathbf{y}$	Vetor de saída
$z$	Distância da linha neutra
$\lambda$	Autovalores da matriz $\mathbf{A}$
$\rho$	Densidade do material
$\sigma$	Matriz de tensão
$\phi$	Vetor potencial elétrico
$\alpha, \beta$	Coefficientes para cálculo da matriz de amortecimento de Rayleigh
$\phi_a$	Matriz de potencial elétrico no atuador
$\theta_i$	Giro no nó $i$
$\theta_k$	Deslocamento angular no elemento $k$



## RESUMO

GRUPPIONI, E.M. (2003). *Otimização de parâmetros de controladores difusos para estruturas inteligentes*. São Carlos, 2003. 101 p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

As estruturas aeronáuticas estão sujeitas a diversas solicitações, devido principalmente às interações com o escoamento aerodinâmico, que podem causar distúrbios e vibrações, comprometendo seu desempenho. Diversas pesquisas vêm sendo realizadas para solucionar estes problemas. Dentre elas está o uso de atuadores e sensores piezelétricos integrados na estrutura, que juntamente com um sistema de controle passa a ser denominada estrutura inteligente, a qual promove o controle ativo de vibrações garantindo um aumento no desempenho.

O objetivo deste trabalho é obter parâmetros ótimos de um controlador não convencional baseado na lógica difusa para controle de vibrações em uma viga com atuadores e sensores piezelétricos. A viga e elementos piezelétricos são modelados pelo método de elementos finitos utilizando o princípio variacional eletromecânico. O sistema de controle difuso, o qual está se tornando amplamente utilizado principalmente devido à sua capacidade de representar sistemas não lineares e complexos, é baseado nos modelos difusos de Mamdani e Takagi-Sugeno-Kang. A otimização é feita através de algoritmo genético que é um processo de procura probabilística baseado nas leis de seleção natural influenciadas pelas teorias de Charles Darwin. São otimizados os valores dos ganhos de controle, bem como os suportes dos conjuntos difusos da base de conhecimento. São feitas comparações com o controlador difuso obtido por processo de ajuste manual.

Palavras-chave: aeroelasticidade; estruturas inteligentes; controle difuso; algoritmo genético; otimização.

## ABSTRACT

GRUPPIONI, E.M. (2003). *Parameter optimization of fuzzy controllers for smart structures*. São Carlos, 2003. 101 p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

Aeronautical structures are subject to a variety of loads, due mainly to the interaction with the aerodynamic flow that can present disturbances, compromising their performance. Various researches have been carried out to solve these problems. Among them, the use of piezoelectric actuators and sensors integrated to the structure, jointly with a control system, the so-called smart structure technology, has been seen with good potential. A smart structure promotes active vibration control, guaranteeing a performance increase.

The objective of this work is to obtain optimal control parameters of a non-conventional vibration controller based on the fuzzy logic. A smart beam with piezoelectric actuators and sensors, that has been modeled by the finite element method, has been used to control. The fuzzy control, which is becoming broadly utilized, mainly due to its capacity to represent complex and non-linear systems, is based in Mamdani and Takagi-Sugeno-Kang fuzzy models. The optimization scheme is based on genetic algorithms, a methodology inspired on the natural selection laws influenced by the Darwin's theories. Gains values and membership functions are optimized. Comparisons with the fuzzy controller achieved by trial and error parameters tuning are presented.

Keywords: aeroelasticity; smart structures; fuzzy control; genetic algorithm; optimization.



# CAPÍTULO 1

## INTRODUÇÃO

As estruturas aeronáuticas estão sujeitas a diversas solicitações, devido principalmente à interação com o escoamento de ar. A interação fluido-estrutura pode levar a fenômenos aeroelásticos de característica instável, comprometendo a estrutura e seu funcionamento. As exigências atuais por aeronaves mais leves (SHEN & HOMAIFAR, 2001), mais rápidas e que transportem mais peso proporcionam desafios maiores para a solução de problemas aeroelásticos.

Diversas pesquisas vêm sendo realizadas para procurar soluções para problemas aeroelásticos em estruturas aeronáuticas. Historicamente as soluções passivas tais como incremento da rigidez, balanço de massa e mudança da geometria têm sido utilizadas para prevenir o aparecimento de fenômenos aeroelásticos, porém, resultando em aumento de peso, custo e queda de desempenho. Durante os últimos 20 anos, têm sido feitos estudos com atuadores (servo-hidráulicos) e sensores convencionais, que atuam basicamente nas superfícies de controle, para diminuir as vibrações e conseguir a estabilidade do sistema em malha fechada (NAGAMINE, 2001). DE MARQUI et al. (2000) apresentam uma revisão de vários trabalhos realizados para o controle de fenômenos aeroelásticos, no qual destaca o fenômeno de *flutter*. Podemos destacar também BELO et al. (2001) que desenvolvem o controle baseado em lógica difusa para controle de *flutter*.

Durante os anos 90 houve o desenvolvimento expressivo de componentes ativos nas estruturas, sendo os dispositivos sensores e atuadores que utilizam materiais piezelétricos os mais utilizados, além das fibras ópticas, ligas de memórias de forma, materiais estricativos e fluidos eletro- e magneto-reológicos. Os materiais piezelétricos possuem a característica de atuarem mediante a aplicação de uma

tensão elétrica, provocando força ou deslocamento, podendo também ocorrer a ação inversa, ou seja, mediante a aplicação de uma força ou deslocamento há geração de tensão elétrica. Esta é uma das razões da utilização destes materiais em determinadas estruturas, a fim de modificarem sua forma ou posição. Integrado a um sistema de controle, este sistema como um todo passa a ser ativo, sendo denominado *Estrutura Inteligente*, a qual garante o aumento de desempenho, principalmente devido à sua menor intrusão na estrutura (CRAWLEY, 1994).

O sistema de controle que deve integrar a estrutura inteligente deve ser bem elaborado para proporcionar uma adaptação conveniente entre a técnica e o problema. A grande complexidade dos sistemas aeroelásticos e os requisitos de desempenho exigem técnicas avançadas de controle, tais como as redes neurais artificiais (HAYKIN, 1999) e a lógica difusa (YAGER & FILEV, 1994), que são tratadas na literatura como técnicas de controle não convencionais. Os controladores baseados em lógica difusa (ou lógica *fuzzy*) vêm sendo amplamente utilizados, principalmente por serem adequados na descrição de sistemas de processamento de informação complexos, não-lineares ou não claramente definidos.

A maior dificuldade no projeto de controladores difusos encontra-se na determinação dos seus parâmetros, que geralmente é feita baseada em um processo heurístico por tentativa e erro. Um dos métodos para ajustar os parâmetros o melhor possível é através de técnicas de afinação ou sintonia (SHAW & SIMÕES, 1999), que é baseada em experiências do projetista e faz analogia com controle convencional tipo proporcional-integral-derivativo (PID) (YAGER & FILEV, 1994).

Os algoritmos genéticos (AG) baseados nas leis de seleção natural influenciadas por Charles Darwin (GOLDBERG, 1989) são amplamente utilizados em problemas de otimização, em especial naqueles em que técnicas tradicionais de otimização não são aplicáveis ou que apresentem desempenho insatisfatório. Atualmente os AG são bastante usados na obtenção e otimização de sistemas de controladores difusos, devido a sua fácil aplicação. Podem ser utilizados para ajustar diversos parâmetros dos controladores difusos, tais como a base de conhecimento, base de regras, ganhos de ponderação e outros.

Este capítulo apresenta uma introdução e revisão de alguns trabalhos sobre estruturas inteligentes, com sua principal aplicação em controle de fenômenos

aeroelásticos. Faz algumas considerações sobre elementos ativos piezelétricos e sua utilização em estruturas inteligentes. Enfatiza o controle difuso como umas das técnicas de controle não convencionais e apresenta os AG, o qual será tratado neste trabalho, como um importante método de otimização destes controladores.

## 1.1 – Estruturas inteligentes

Segundo CRAWLEY (1994), *Estruturas Inteligentes* são aquelas que possuem atuadores e sensores integrados na própria estrutura, contendo também um controle lógico altamente integrado, condicionamento de sinal e amplificador de potência eletrônico. CRAWLEY (1994) classifica estruturas inteligentes segundo o diagrama da Figura 1.1. O conjunto adaptativas compõe-se das estruturas que estão sujeitas a algum tipo de atuação e o conjunto sensoreadas compõe-se das estruturas que apresentam sensores. A intersecção destes dois grandes grupos compõe as estruturas controladas, onde se supõe que atuadores e sensores estão unidos por um controle do tipo malha fechada. Dentro desta intersecção o subconjunto ativas contém estruturas onde os atuadores e sensores estão distribuídos ao longo da estrutura, possuindo também uma função estrutural. As estruturas inteligentes são um subconjunto das estruturas ativas, onde apresentam também sistemas de aquisição, processamento de sinal, controle e atuação inteiramente incorporados.




FIGURA 1.1 – Modelo esquemático para estruturas inteligentes (CRAWLEY, 1994).



As estruturas inicialmente eram feitas a partir de grandes peças de materiais isotrópicos, restringindo o uso de elementos ativos (CRAWLEY, 1994). Os avanços nas áreas de materiais e computação permitiram o surgimento e crescimento do uso de materiais piezelétricos como elementos ativos de estruturas inteligentes, tendo o termo piezeletricidade fortalecido em trabalhos envolvendo estruturas ativas e controle estrutural.

Diversos tipos de materiais permitiram o desenvolvimento de elementos ativos, tais como elementos com liga com memória de forma, cerâmica e polímeros piezelétricos, fibras ópticas, materiais eletro- e magneto-strictivos e fluidos magneto- e electro-reológicos, sendo os materiais piezelétricos os mais utilizados.

## 1.2 – Estruturas inteligentes em aeroelasticidade

Os trabalhos envolvendo o uso de materiais inteligentes para controle de respostas aeroelásticas indesejadas em estruturas aeronáuticas começaram a ser desenvolvidos a partir da metade da década de 90.

NAGAMINE (2001) apresenta várias referências de trabalhos onde os autores realizaram pesquisas incorporando elementos piezelétricos nas estruturas aeroespaciais para o controle aeroelástico e de vibração, realizados em importantes centros de pesquisas, tais como o Centro de Pesquisa de NASA Langley nos EUA, os laboratórios de pesquisa da força aérea dos EUA e da Northrop Grumman. Destacam-se ainda pesquisas com o uso de elementos piezelétricos como amortecedores de vibrações.

FORSTER & YANG (1998) utilizam atuadores piezelétricos para controle de *flutter* supersônico em uma asa retangular. DENOYER et al. (2000) apresentam alguns projetos do Diretório de Veículos Espaciais do Laboratório de Pesquisas da Força Aérea dos EUA em Albuquerque, Novo México, mostrando o uso prático em experimentos da tecnologia de estruturas inteligentes. Sensores e atuadores piezelétricos para o controle e supressão de vibrações em estruturas espaciais são utilizados. SULEMAN (2000) apresenta uma investigação da praticidade de empregar atuadores piezelétricos para suprimir o *flutter* de painel e

ruído de estruturas. CASELLA et al. (2002) apresentam o projeto de uma larga estrutura de laboratório equipada com motor a jato e atuadores piezelétricos para redução de vibração. GREWAL et al. (2001) utilizam elementos piezocerâmicos para atenuar vibração na cabina de passageiros de uma aeronave.

Outros trabalhos vêm sendo realizados, para posterior aplicação em controle aeroelástico, como em MATHEW et al. (2001) que apresentam a modelagem de estruturas ativas com atuadores piezelétricos, as quais agem como flapes para controle de fluxo; REAVES & HORTA (2001) discutem as aplicações e limitações de pacotes comerciais de elementos finitos na modelagem de estruturas ativas com atuadores piezelétricos.

### **1.3 – Atuadores e sensores piezelétricos para estruturas inteligentes**

O efeito piezelétrico direto é definido como o “potencial elétrico produzido por deformações mecânicas em cristais pertencendo a certas classes, o potencial elétrico sendo proporcional à deformação e mudando de sinal com isso” (CADY, 1946). Pode ocorrer também o efeito reverso (chamado também de recíproco ou inverso). Dentre os materiais piezelétricos utilizados estão os cristais piezelétricos, os cristais piezo-ressonantes, materiais amorfos policristalinos e os mais utilizados, que são o titanato zirconato de chumbo (PZT) e o fluorido de polivilideno (PVDF) que é um filme plástico.

O fenômeno da piezeletricidade sob o ponto de vista microscópico é entendido como a polarização do meio cristalino devido aos deslocamentos de íons da sua posição de equilíbrio, pela ação de um campo de tensões mecânicas (BOTTOM, 1968), produzindo um dipolo elétrico. Os átomos de um cristal estão arranjados em grupos denominados células unitárias, idênticas em dimensões e estrutura atômica, com formato de pequenos paralelepípedos. Os elementos piezelétricos, como por exemplo, nas cerâmicas policristalinas, apresentam cristais aleatoriamente orientados com domínios ou regiões com arranjos de dipolo similares. Quando é aplicado um campo elétrico, estes domínios apresentam uma polarização em uma dada direção (veja Figura 1.2), tornando o material permanentemente

alongado na direção do campo de polarização e contraído na direção transversal numa razão definido pelo coeficiente de Poisson. Quando o campo é removido a peça retorna às dimensões originais, conforme mostra a Figura 1.3.

A aplicação dos materiais piezelétricos em controle estrutural é relativamente nova, sendo bastante apropriada com controle de vibrações de sistemas distribuídos. Estes materiais conseguem resistir a altas tensões mecânicas e são capazes de deslocar cargas de várias toneladas, não cedendo, desde que não exceda a capacidade máxima de carga. A força máxima (força de bloqueio) que um piezelétrico pode gerar é o produto da rigidez pelo deslocamento máximo que ele consegue realizar. Um piezelétrico é capaz de resistir a tensões mecânicas de aproximadamente  $250\text{ MPa}$  antes de se partir, porém, deve ser operado com valores máximo entre 10 a 20% desse valor sob o risco de despolarização (NAGAMINE, 2001).




FIGURA 1.2 – Polarização macroscópica de um piezelétrico (NAGAMINE, 2001).




FIGURA 1.3 – Deformação física de um piezelétrico (NAGAMINE, 2001).



Podem-se conseguir diversas configurações das disposições dos elementos piezelétricos nas estruturas. Vários trabalhos como SHEN & HOMAIFAR (2001), MARQUES & NAGAMINE (2001), NAGAMINE (2001), ABREU e RIBEIRO (2002), além de outros, utilizam pares de atuadores piezelétricos colados em faces opostas de uma viga. BALAMURUGAN & NARAYANAN (2001) utilizam uma placa laminada com uma face contendo o sensor e outra contendo o atuador. TRINDADE (2001) faz o estudo de atuadores piezelétricos com efeito de cisalhamento em uma viga.

#### 1.4 – Controle de estruturas inteligentes

Um importante aspecto no desenvolvimento de estruturas inteligentes está no sistema de controle adotado (LEIPHOLTZ & ABDEL-ROHMAN, 1986 *apud* MARQUES & NAGAMINE, 2001).

O controle convencional é tratado aqui como compreendendo as técnicas de controle clássicas e modernas. Vários trabalhos utilizam diferentes técnicas clássicas no controle ativo de vibrações de estruturas inteligentes, porém, uma limitação do controle clássico está na representação de sistemas com apenas uma entrada e uma saída (sistemas SISO ou *single-input, single-output*). As estruturas inteligentes, assim como a grande parte dos sistemas apresentados na literatura, possuem múltiplas entradas e/ou múltiplas saídas (sistemas MIMO ou *multiple-input, multiple-output*). Estes sistemas podem ser descritos por um conjunto de funções de transferência SISO dificultando, por exemplo, a inclusão de efeitos de acoplamentos. As técnicas de controle moderno são mais apropriadas para sistemas MIMO, pois podem ser empregadas em sistemas invariáveis no tempo e/ou não lineares. Algumas referências básicas sobre controle clássico são OGATA (1982) e D'AZZO & HOUPIS (1988). Dentre as técnicas empregadas para o controle de estruturas ativas pode-se citar LIU & ONODA (1999) que propõe a utilização de uma lei de controle com índice quadrático sendo tratada como uma lei em malha aberta para mudança dos estados; o emprego do controle ótimo LQR (BALAMURUGAN &

---

NARAYANAN, 2001; TRINDADE, 2001; LIU & BEGG, 2000; BEGG & LIU, 2000; ABREU & RIBEIRO, 2001) e LQG (WON & SULLA, 1994).

Devido à complexidade dos sistemas ter aumentado nos últimos tempos, considerando-se modelos mais complicados e mais graus de liberdades, principalmente com o avanço da tecnologia aeroespacial, técnicas avançadas de controle (tratadas aqui como técnicas não convencionais) passaram a ser exploradas ativamente no projeto de controladores não lineares e/ou operando em ambientes complexos com ambigüidades e incertezas. As técnicas não convencionais (que compreendem basicamente métodos de controle inteligente, como as redes neurais e a lógica difusa) são aquelas que não seguem as abordagens das técnicas relacionadas ao controle clássico e moderno.

As redes neurais artificiais (RNA), juntamente com a lógica difusa e a computação evolutiva compreendem os principais paradigmas que compõem a área de inteligência computacional (MASATO, 2000). RNA são sistemas de processamento maciçamente paralelos (HARVEY, 1994) e distribuídos, inspirados no funcionamento do cérebro humano (BRAGA et al., 2000). A capacidade de aprender e generalizar modelos com não linearidades e altamente complexos, a capacidade de auto-organização de processamento temporal, a grande velocidade de processamento para geração de dados em tempo real (SOUZA et al., 2002), e fácil implementação faz das RNA uma ferramenta extremamente poderosa para a solução de problemas, tendo sido muito utilizadas como alternativa para controle de sistemas dinâmicos.

A estrutura das redes neurais permite adquirir conhecimento por experiências, através de um processo de aprendizagem. Uma RNA é composta por unidades de processamento (neurônios) dispostas em uma ou mais camadas e interligados por um grande número de conexões (associadas aos pesos sinápticos, os quais armazenam o conhecimento adquirido). A literatura básica sobre RNA pode ser encontrada em HAYKIN (1999) e HAGAN et al. (1996). FALLER & SCHRECK (1996), LEE (1996) e JHA & ROWER (2001) apresentam mais detalhes sobre redes neurais aplicadas em controle de estruturas.



### 1.4.1 – Lógica difusa

A lógica difusa é um algoritmo de processamento de informações que lida com dados vagos e ambíguos dentro de um domínio de incertezas, procurando aproximar o raciocínio lógico humano (SHAW & SIMÕES, 1999). Sua teoria fornece uma rigorosa aproximação matemática baseada na definição de conjuntos difusos para representar as incertezas dos sistemas. Com sua aproximação, pode-se supor variáveis como elementos pertencendo parcialmente a um conjunto particular e também assumir operadores booleanos aplicados para processar o sistema de informação. O resultado é uma transição suave de uma operação para outra durante o processamento dos conjuntos difusos. Esta propriedade é muito útil na modelagem e controle de sistemas dinâmicos complexos (YAGER & FILEV, 1994).

A representação de sistemas realizada pela aproximação por lógica difusa provê um modelo básico de entradas-saídas, mapeadas por um conjunto de regras, que consideram a relação lógica entre as quantidades vagas e ambíguas.

A lógica difusa é uma técnica que incorpora a forma humana de pensar em um sistema de controle. Um controlador difuso típico pode ser considerado, em determinadas condições, um sistema esperto (KLIR & YUAN, 1995), que se comporta conforme o raciocínio natural e intuitivo do homem, baseado nos seus conhecimentos, para controle de processos e plantas não lineares e até com pouco conhecimento de seu comportamento dinâmico (SHAW & SIMÕES, 1999). Sua implementação é fácil e de baixo custo, além de apresentar características de robustez às incertezas ou variações paramétricas.

Os controladores difusos podem ser relacionados convenientemente às estratégias de controle clássicas como PI, PD e PID (YAGER & FILEV, 1994), as quais auxiliam no projeto dos controladores, que variam substancialmente de acordo com a natureza dos problemas que devem ser resolvidos (KLIR & YUAN, 1995). Mais detalhes sobre controle difuso pode ser encontrado em YAGER & FILEV (1994), PATYRA & MLYNEK (1996) e JAMSHIDI et al. (1993).

Pode-se destacar ainda vários trabalhos que utilizam controladores baseados em lógica difusa para controle de vibrações em estruturas inteligentes, tais como em TEIXEIRA & RIBEIRO (2001), que realizam o controle ativo de vibrações

de uma viga engastada-livre com atuadores e sensores piezelétricos, através de um controlador difuso otimizado por algoritmo genético. ABREU & RIBEIRO (2001) desenvolvem um controlador difuso adaptativo para controle de uma viga engastada-livre com atuador piezelétrico. NAGAMINE (2001) e MARQUES & NAGAMINE (2001) apresentam o controle ativo de uma estrutura inteligente com atuadores piezelétricos. SHEN & HOMAIFAR (2001) apresentam vários tipos de controladores de vibração de uma placa linear e elástica com sensores e atuadores piezelétricos. Dentre estes, apresenta o controle híbrido PID-difuso, onde um controlador PID convencional tem seus ganhos ajustados automaticamente pelo controlador difuso.

### **1.5 – Otimização do controlador difuso via algoritmos genéticos**

Controladores de sistemas dinâmicos são escolhidos de acordo com as necessidades de controle. Porém, um dos grandes problemas no projeto de controladores está na determinação correta de seus parâmetros. Os processos de obtenção e ajuste dos controladores são normalmente feitos de forma manual por tentativa e erro, que na maioria dos casos torna-se tedioso, podendo consumir uma considerável quantidade de tempo ocasionando grandes dispêndios, aumentando assim o custo do projeto (WONG & HAMOUDA, 2000).

Diferentes técnicas convencionais de otimização podem ser empregadas na determinação de parâmetros de sistemas. A técnica de controle ótimo é aplicada em estruturas inteligentes e tem sido bastante estudado em diversos trabalhos usando diferentes metodologias. SHEN & HOMAIFAR (2001) apresentam diversos sistemas de controle usado para o controle ativo de vibração de uma placa usando atuadores piezelétricos. Dentre eles é aplicado o controle LQG (*linear quadratic gaussian*). ABREU & RIBEIRO (2002) desenvolvem um controlador LQR para controle ativo de vibração de uma viga com atuadores piezelétricos usando posições ideais dos atuadores e sensores. ABREU & RIBEIRO (2001) propõem um controle difuso adaptativo para estrutura inteligente, cujos parâmetros são ajustados em tempo real segundo uma lei de adaptação derivada da teoria de estabilidade de Lyapunov.



O projeto de controladores difusos implica no ajuste de vários parâmetros, que em geral se valida pela interpretação do projetista dos fenômenos físicos envolvidos. O ajuste destes parâmetros geralmente é feito por um processo de tentativa e erro, envolvendo a experiência e conhecimento do projetista, bem como entrevistas com operadores. Isto tem motivado investigações sobre métodos para automatizar a escolha dos parâmetros dos controladores difusos. Um dos métodos que tem ganho grande atenção é o algoritmo genético, que é muito aplicado em problemas de otimização, em especial naqueles em que técnicas tradicionais de otimização não são aplicáveis ou apresentam desempenho insatisfatório (MASATO, 2000).

Os algoritmos genéticos (AG) surgiram das teorias dos algoritmos evolucionários e se baseiam na teoria da evolução natural formulada por Charles Darwin e da genética. Os AG envolvem princípios genéticos da reprodução, recombinação de cromossomos (*crossover*) e mutação dos indivíduos, os quais participam de uma competição, onde sobrevivem os mais aptos (GOLDBERG, 1989). Assim sendo, um AG é basicamente um processo de procura probabilística onde uma característica importante é que o processo de obtenção de uma solução ótima é paralelo e estruturado. Um AG trabalha com indivíduos representando um conjunto possível de soluções do problema, enquanto que técnicas convencionais de otimização e busca trabalham geralmente de forma seqüencial. A literatura básica sobre AG pode ser encontrada em GOLDBERG (1989), BARBOSA (1997) e MICHALEVICZ (1994).

AG têm sido aplicados com sucesso no contexto de otimização de controladores difusos com aplicações em diversos tipos de sistemas. Pode-se citar trabalhos que empregam o AG para ajuste da base de conhecimento e da base de regras, tais como em TARNG et al. (1996, 1997), WONG & HER (1999), HERRERA et al. (1995), HOFFMANN & PFISTER (1997), ARSLAN & KAYA (2001), CHEN & CHANG (1998), CHO & LEE (2000), KIM & KIM (1997), MAZZUCCO et al. (2000), MING et al. (1996), NG & LI (1994), TÚPAC et al. (1999) e MAGDALENA (1994).

SHEN & HOMAIFAR (2001) apresentam um sistema de controle usado para o controle ativo de vibração de uma placa usando atuadores piezelétricos,

aplicando o controle PID convencional ajustado por algoritmo genético. TEIXEIRA & RIBEIRO (2001) propõem um algoritmo genético para otimizar a base de regras, o peso das regras e as funções de pertinência de entrada de um controlador difuso para alívio de vibração de uma estrutura inteligente.

## 1.6 – Objetivos do trabalho

O objetivo deste trabalho é obter os parâmetros ótimos de um controlador difuso para controle de vibração de uma estrutura inteligente. A estrutura inteligente compreende uma viga com atuadores e sensores piezelétricos colados. A viga foi modelada e validada por NAGAMINE (2001) usando o método de elementos finitos, com base nas hipóteses de viga Euler-Bernoulli e o princípio variacional eletromecânico. Os parâmetros a serem determinados são os ganhos dos sinais de entrada ( $k_e$  e  $k_{\Delta e}$ ) e saída ( $k_u$ ) do controlador difuso e os suportes dos conjuntos difusos das funções de pertinência. Controladores difusos baseados nos modelos Mamdani e Takagi-Sugeno-Kang são implementados, visando reduzir a resposta vibratória da viga quando sujeita a distúrbios mecânicos externos. Os parâmetros dos controladores são obtidos e otimizados através de algoritmos genéticos. Dentre os parâmetros a serem otimizados tem-se os ganhos do controlador difuso e os suportes dos conjuntos da base de conhecimento. São consideradas quatro formas de ajuste do controlador, onde são obtidos os ganhos através de AG, depois são obtidas as funções de pertinência, considerando-se os ganhos obtidos manualmente por NAGAMINE (2001), depois são obtidas as funções de pertinência com os ganhos obtidos anteriormente pelo AG e por último são obtidos os ganhos e funções de pertinência simultaneamente pelo AG. Os resultados são comparados entre si.

As principais contribuições deste trabalho estão no desenvolvimento e aplicação do algoritmo genético na otimização do controlador difuso, projeto, aplicação e análise de controladores difusos, no campo de estruturas inteligentes.



## 1.7 – Organização do texto

Uma introdução sobre estruturas inteligentes, sua aplicação em controle de fenômenos aeroelásticos, considerações sobre elementos ativos piezelétricos e sua utilização em estruturas inteligentes, controle convencional e não convencional de estruturas inteligentes, enfatizando o controle difuso e otimização de controladores através de algoritmos genéticos foram tratados neste primeiro Capítulo. Os objetivos e contribuições deste trabalho também são apresentados.

O Capítulo 2 mostra uma síntese da modelagem matemática de uma viga com elementos sensores e atuadores piezelétricos incorporados, pelo método de elementos finitos, com base nas hipóteses de viga Euler-Bernoulli e o princípio variacional eletromecânico. A modelagem é feita por NAGAMINE (2001), onde são construídas as matrizes de massa e rigidez, amortecimento e carregamento, considerando-se a discretização com três graus de liberdade por nó e efeitos elétricos considerados por elemento. O modelo é representado em espaço de estados para se obter a redução de ordem pelo método de expansão em frações parciais, a fim de reduzir o custo computacional durante as simulações.

O Capítulo 3 mostra os fundamentos da lógica difusa e aplicação em controle não convencional. São descritos os modelos difusos de Mamdani e Takagi-Sugeno-Kang e é mostrado o procedimento do projeto de um controlador difuso.

No Capítulo 4 são abordados os conceitos de algoritmos genéticos e apresentados seus principais componentes: codificação dos indivíduos, seleção dos indivíduos e os principais operadores genéticos (recombinação e mutação). É mostrado também o processo de obtenção e otimização do controlador difuso, através do ajuste dos ganhos e dos conjuntos difusos.

O Capítulo 5 apresenta os resultados da aplicação do controle difuso na estrutura inteligente. São apresentadas as condições de simulação e resultados e discussões da otimização são mostrados. São apresentadas quatro formas de ajuste do controlador através do AG, apresentando ao final discussão sobre o desempenho do método.

O Capítulo 6 apresenta as conclusões sobre o trabalho desenvolvido e propostas para futuros trabalhos.

## CAPÍTULO 2

### MODELO MATEMÁTICO DA ESTRUTURA ATIVA

#### 2.1 – Introdução

A discretização de uma estrutura pelo método de elementos finitos permite estabelecer e resolver as equações do movimento de maneira eficiente (BATHE & WILSON, 1976) e com custo computacional relativamente reduzido.

Partindo-se do princípio de Hamilton e usando as expressões de energia cinética, potencial de deformação da viga e trabalho virtual efetuado juntamente com as equações constitutivas da piezeletricidade, chega-se ao Princípio Variacional Eletromecânico.

Através da discretização da viga em elementos simples de viga Euler-Bernoulli com três graus de liberdade por nó e do uso das funções de forma de Hermite e do Princípio Variacional são montadas as matrizes de massa, rigidez e amortecimento do elemento. Neste modelo os componentes piezelétricos também são modelados pelo método dos elementos finitos. Estes podem ser colados em qualquer posição da viga, inclusive, sobrepostos a outros piezelétricos, podendo-se obter os chamados motores piezelétricos (bimórficos), além de permitir ligações em paralelo ou em série dos mesmos (NAGAMINE, 2001).

Para redução do esforço computacional e implementação do projeto do controlador é feita a redução de ordem do modelo através do método de expansão em frações parciais, sendo conveniente o modelo estar representado no espaço de estados. Este modelo permite simulações da viga na condição livre no espaço, engastada ou bi-engastada.

## 2.2 – Modelagem do comportamento eletromecânico

Com o princípio variacional eletromecânico é possível obter uma expressão geral para o comportamento de meios piezelétricos, através da aplicação de métodos como o de elementos finitos (NAGAMINE, 2001).

Partindo-se do princípio de Hamilton, o qual provê uma completa formulação dos problemas mecânicos e independe do sistema de coordenadas utilizado, pois utiliza coordenadas generalizadas (MEIROVITCH, 1967), tem-se a seguinte equação:

$$\delta \int_{t_1}^{t_2} (T - U) dt + \int_{t_1}^{t_2} \delta W_{nc} dt = 0 \quad (2.1)$$

sendo  $T$  a energia cinética total do sistema,  $U$  a energia potencial de deformação do sistema e  $\delta W_{nc}$  o trabalho virtual das forças não conservativas atuando no sistema.

A energia cinética  $T$  de uma viga qualquer é dada por (MEIROVITCH, 1970):

$$T = \frac{1}{2} \int \rho \dot{\mathbf{q}}^T \cdot \dot{\mathbf{q}} dV \quad (2.2)$$

sendo  $V$  o volume do corpo,  $\rho$  a densidade do material e  $\dot{\mathbf{q}}$  o vetor das velocidades generalizadas.

Segundo PREUMONT (1997), para um material piezelétrico as equações constitutivas elétricas e mecânicas estão acopladas, ou seja:

$$\begin{aligned} \boldsymbol{\sigma} &= \mathbf{C}^E \mathbf{S} - \mathbf{e} \mathbf{E} \\ \mathbf{D} &= \mathbf{E}^T \mathbf{S} - \boldsymbol{\varepsilon} \mathbf{E} \\ \mathbf{e} &= d \mathbf{C}^E \end{aligned} \quad (2.3)$$

sendo  $\boldsymbol{\sigma}$  o vetor de tensão da viga,  $\mathbf{C}^E$  a matriz do módulo de Young para campo elétrico constante,  $\mathbf{S}$  o vetor de deformação específica do material,  $\mathbf{e}$  a matriz de



coeficientes piezelétricos,  $\mathbf{E}$  o vetor campo elétrico,  $\mathbf{D}$  o vetor deslocamento elétrico,  $\boldsymbol{\varepsilon}$  a matriz das constantes dielétricas para uma deformação específica constante e  $\mathbf{d}$  a matriz das constantes de deformações piezelétricas.

A energia potencial total do sistema deriva das equações constitutivas (Equação (2.3)) e inclui as energias potenciais elétrica e mecânica (MARQUES & NAGAMINE, 2001), ou seja:

$$U = \frac{1}{2} \int [\mathbf{S}^T \boldsymbol{\sigma} - \mathbf{E}^T \mathbf{D}] dV \quad (2.4)$$

O trabalho total das forças externas aplicadas é dado por:

$$W = W_m + W_e \quad (2.5)$$

sendo,  $W_m$  a componente mecânica expressa na Equação (2.6) como a soma de trabalhos produzidos pelas forças concentradas, de corpo e de superfície e  $W_e$  a componente elétrica expressa na Equação (2.7), que é gerada pela movimentação de cargas elétricas na superfície.

$$W_m = \mathbf{q} \cdot \mathbf{P}_C + \int \mathbf{q} \cdot \mathbf{P}_b dV + \int_{S_1} \mathbf{q} \cdot \mathbf{P}_S dS_1 \quad (2.6)$$

$$W_e = - \int_{S_1} \phi \cdot Q dS_2 \quad (2.7)$$

Portanto, o trabalho total das forças externas aplicadas é:

$$W = \mathbf{q} \cdot \mathbf{P}_C + \int \mathbf{q} \cdot \mathbf{P}_b dV + \int_{S_1} \mathbf{q} \cdot \mathbf{P}_S dS_1 - \int_{S_1} \phi \cdot Q dS_2 \quad (2.8)$$

sendo,  $\mathbf{P}_C$  o vetor de força concentrada,  $\mathbf{P}_b$  um tensor de forças de corpo atuando sobre um volume  $V$ ,  $\mathbf{P}_S$  um vetor de força de superfície atuando sobre uma superfície  $S_1$ ,  $\mathbf{q}$  o vetor dos deslocamentos generalizados,  $\phi$  o potencial elétrico e  $Q$  a carga elétrica superficial atuando na superfície  $S_2$ .

Substituindo-se as equações das energias cinéticas e potenciais e a equação do trabalho virtual na Equação (2.1), temos o princípio variacional eletromecânico resultante (Equação (2.9)), que é empregado para obter as equações de elementos finitos (ABREU & RIBEIRO, 2002).

$$\int_V [\rho \delta \dot{\mathbf{q}}^T \dot{\mathbf{q}} - \delta \mathbf{S}^T \mathbf{C}^E \mathbf{S} + \delta \mathbf{S}^T \mathbf{e} \mathbf{E} - \delta \mathbf{E}^T \boldsymbol{\varepsilon} \mathbf{E} + \delta \mathbf{q}^T \mathbf{P}_b] dV + \int_{S_1} \delta \mathbf{q}^T \cdot \mathbf{P}_s dS_1 + \delta \mathbf{q}^T \cdot \mathbf{P}_c - \int_{S_2} \delta \phi \cdot Q dS_2 = 0 \quad (2.9)$$

### 2.3 – Modelo de viga ativa pelo método dos elementos finitos

Para o modelo em elementos finitos adotou-se a viga discretizada com elementos simples de viga Euler-Bernoulli com três graus de liberdade mecânicos (deslocamento axial  $u$ , deslocamento vertical  $w$  e rotacional  $\theta$ ), como mostra a Figura 2.1, e graus de liberdade elétricos que dependem da quantidade de potenciais aplicados no elemento. A Figura 2.2 ilustra algumas das disposições possíveis usando-se componentes piezelétricos colados e as hipóteses empregadas na modelagem do efeito piezelétrico.




FIGURA 2.1 – Viga discretizada com elementos finitos de viga e os graus de liberdade mecânicos.



FIGURA 2.2 – Representação esquemática de alguns graus de liberdade elétricos.

O vetor que representa os deslocamentos nos nós  $i$  e  $j$  do  $k$ -ésimo elemento é dado por:

$$\mathbf{q}_k = [u_i \quad w_i \quad \theta_i \quad u_j \quad w_j \quad \theta_j]^T \quad (2.10)$$

sendo que os deslocamentos generalizados são expressos em termos da coordenada generalizada elementar  $\mathbf{q}_k$  e do uso das matrizes de função de forma  $\mathbf{N}_u$  e  $\mathbf{N}_w$  (baseadas nos polinômios de Hermite, pois permitem que a deflexão da viga seja expressa diretamente em termos das variáveis nodais), da seguinte maneira:

$$\begin{aligned} u_k &= \mathbf{N}_u \mathbf{q}_k \\ w_k &= \mathbf{N}_w \mathbf{q}_k \\ \theta_k &= \frac{dw_k}{dx} = \frac{d\mathbf{N}_w}{dx} \mathbf{q}_k = \mathbf{B}_w \mathbf{q}_k \end{aligned} \quad (2.11)$$

onde  $x$  é a variação do comprimento ao longo do elemento.

No equacionamento da viga de Euler-Bernoulli o deslocamento é considerado sobre seu plano neutro (como mostra a Figura 2.3), sendo sua deformação específica longitudinal dada por:

$$\mathbf{S} = \frac{du}{dx} - z \frac{d^2w}{dx^2} \quad (2.12)$$






FIGURA 2.3 – Deslocamento da viga sobre o plano neutro.

Da teoria da eletricidade, o campo elétrico é expresso como um gradiente do potencial elétrico  $\phi$  (HALLIDAY & RESNICK, 1984), que associa o grau de liberdade elétrico ao elemento finito piezelétrico da seguinte forma:

$$\mathbf{E} = -\mathbf{B}_\phi \phi \quad (2.13)$$

sendo  $\mathbf{B}_\phi$  um operador matemático que representa gradiente (NAGAMINE, 2001).

Seja a  $p$ -ésima camada piezelétrica representada na Figura 2.4, sendo o eixo de polarização (eixo 3) paralelo à direção de polarização do material e  $\vec{P}$  o vetor de polarização, estabelecido durante o processo de fabricação. Assumindo-se que o potencial elétrico varia linearmente na espessura da  $p$ -ésima camada piezelétrica (ao longo do eixo 3) e que a direção principal de expansão do elemento piezelétrico é axial (eixo 1), tem-se o vetor contendo as constantes piezelétricas  $\mathbf{d}_{31}$ , que relacionam o potencial elétrico aplicado na direção transversal com o deslocamento na direção axial.




FIGURA 2.4 – Sistema de eixos de orientação para materiais piezelétricos (NAGAMINE, 2001).

Substituindo as Equações (2.12) e (2.13) na equação do princípio variacional eletromecânico (ver Equação (2.9)) e considerando-se o equilíbrio dos elementos finitos obtêm-se as equações do sistema global de movimento expressa por:

$$\begin{aligned} \mathbf{M}_{qq}\ddot{\mathbf{q}} + \mathbf{K}_{qq}\mathbf{q} + \mathbf{K}_{q\phi}\phi &= \mathbf{F} \\ \mathbf{K}_{\phi q}\mathbf{q} + \mathbf{K}_{\phi\phi}\phi &= \mathbf{G} \end{aligned} \quad (2.14)$$

sendo  $\mathbf{M}_{qq}$ ,  $\mathbf{K}_{qq}$ ,  $\mathbf{K}_{\phi q} = \mathbf{K}_{q\phi}^T$ ,  $\mathbf{K}_{\phi\phi}$ ,  $\mathbf{F}$  e  $\mathbf{G}$  as matrizes de massa, rigidez elástica, eletromecânica, rigidez dielétrica e cargas externas mecânicas e elétricas.

Aplicando-se o método de Rayleigh (CLOUGH & PENZIEN, 1975) para prever o amortecimento da estrutura tem-se a matriz de amortecimento:

$$\mathbf{C}_{qq} = \alpha\mathbf{M}_{qq} + \beta\mathbf{K}_{qq} \quad (2.15)$$

onde os coeficientes  $\alpha$  e  $\beta$  dependem de frequências naturais consecutivas e fatores de amortecimento desejados (MARQUES, 1993).

Considerando-se a matriz de amortecimento e sendo na equação global (Equação (2.14)) as parcelas dependentes do potencial elétrico decompostas por tipo de piezelétrico (sensor ou atuador), temos a equação global do movimento escrita da seguinte maneira:

$$\mathbf{M}_{qq}\ddot{\mathbf{q}} + \mathbf{C}_{qq}\dot{\mathbf{q}} + \mathbf{K}^*\mathbf{q} = \mathbf{F} - \mathbf{K}_{q\phi\alpha}\phi_\alpha \quad (2.16)$$

sendo  $\mathbf{K}^* = \mathbf{K}_{qq} - \mathbf{K}_{q\phi s}\mathbf{K}_{\phi s}^{-1}\mathbf{K}_{\phi s}$ , onde os índices  $\alpha$  e  $s$  se referem a atuador e sensor, respectivamente.

A validação do modelo em elementos finitos da viga, com elementos piezelétricos incorporados, foi realizada por NAGAMINE (2001), através de comparações com resultados aceitos e publicados, como em LIMA (1999) e CHEN et al. (1997), e com resultados experimentais realizados pelo mesmo. Esta validação

visava verificar a eficácia do modelo matemático para prever o comportamento dinâmico.

## 2.4 – Modelo reduzido

Para redução do esforço computacional e implementação do projeto do controlador, NAGAMINE (2001) propôs a redução de ordem do modelo matemático pelo método de expansão em frações parciais (STEVENS & LEWIS, 1992; MARQUES, 1993). O método baseia-se na omissão dos modos de alta frequência ou pela omissão de termos que contenham pequenos resíduos. É conveniente que o sistema dinâmico seja, então, representado no espaço de estados.

O sistema dinâmico de ordem  $n$  pode ser representado em termos de suas variáveis de estado na forma matricial geral abaixo (OGATA, 1982; D'AZZO & HOUPIS, 1988):

$$\begin{aligned}\dot{\mathbf{x}} &= \mathbf{Ax} + \mathbf{Bu} \\ \mathbf{y} &= \mathbf{Cx} + \mathbf{Du}\end{aligned}\tag{2.17}$$

sendo  $\mathbf{x}$  o vetor de estados,  $\mathbf{u}$  o vetor de entradas,  $\mathbf{y}$  o vetor de saídas,  $\mathbf{A}$  a matriz dinâmica,  $\mathbf{B}$  a matriz de controle,  $\mathbf{C}$  a matriz de saída e  $\mathbf{D}$  a matriz de transmissão direta.

Com base na Equação (2.17) o sistema dinâmico da viga com piezelétricos é representado no espaço de estados. A partir da equação global de movimento, selecionam-se as variáveis de estado como sendo os deslocamentos e velocidades generalizados e o vetor de entradas do sistema como sendo a força externa atuante e a força elétrica dos atuadores, como mostra as equações abaixo:

$$\mathbf{x} = [\mathbf{q} \quad \dot{\mathbf{q}}]^T\tag{2.18}$$

$$\mathbf{u} = [\mathbf{F} \quad \phi_a]^T\tag{2.19}$$

Para realizar o método de redução de ordem por expansão em frações parciais, transforma-se o modelo do sistema dinâmico na forma de função de transferência:

$$\mathbf{H}(s) = \mathbf{C}(s\mathbf{I} - \mathbf{A})^{-1}\mathbf{B} \quad (2.20)$$

que pode ser escrita na forma de expansão em frações parciais:

$$\mathbf{H}(s) = \sum_{i=1}^n \frac{\mathbf{C}\mathbf{v}_{d_i}\mathbf{v}_{e_i}^T\mathbf{B}}{s - \lambda_i} \quad (2.21)$$

sendo  $\lambda_i$  os autovalores da matriz  $\mathbf{A}$  e  $\mathbf{v}_{d_i}$  e  $\mathbf{v}_{e_i}$  os respectivos autovetores direitos e esquerdos da matriz  $\mathbf{A}$ .

Como a redução de ordem do modelo se dá com a omissão dos modos de alta frequência ou de termos que contenham pequenos resíduos, seleciona-se, através de critérios que envolvem a análise do modelo,  $r$  autovalores de  $\mathbf{H}(s)$  que serão mantidos no modelo reduzido, que é representado por:

$$\begin{aligned} \dot{\mathbf{x}}_r &= \mathbf{A}_r\mathbf{x}_r + \mathbf{B}_r\mathbf{u} \\ \mathbf{y} &= \mathbf{C}_r\mathbf{x}_r + \mathbf{D}_r\mathbf{u} \end{aligned} \quad (2.22)$$

sendo

$$\begin{aligned} \mathbf{x}_r &= \mathbf{V}_E\mathbf{x} \\ \mathbf{A}_r &= \mathbf{V}_E\mathbf{A}\mathbf{V}_D \\ \mathbf{B}_r &= \mathbf{V}_E\mathbf{B} \\ \mathbf{C}_r &= \mathbf{C}\mathbf{V}_D \end{aligned} \quad (2.23)$$

As matrizes auxiliares  $\mathbf{V}_E$  e  $\mathbf{V}_D$  são calculadas da seguinte maneira:

$$\mathbf{V}_E = \mathbf{T}^{-1} \begin{bmatrix} \mathbf{v}_{e_1}^T \\ \vdots \\ \mathbf{v}_{e_r}^T \end{bmatrix} \quad \mathbf{V}_D = [\mathbf{v}_{d_1} \quad \cdots \quad \mathbf{v}_{d_r}] \mathbf{T} \quad (2.24)$$

sendo  $\mathbf{T}$  a matriz de transformação ( $r \times r$ ) definida como:

$$\mathbf{T} = \text{diag}(\mathbf{T}_{ij}) \quad (2.25)$$

$$\text{onde } \mathbf{T}_{ij} = \begin{cases} 1 & \text{para cada autovalor real mantido} \\ \begin{bmatrix} 0,5 & -0,5i \\ 0,5 & 0,5i \end{bmatrix} & \text{para cada par complexo conjugado mantido} \end{cases} \quad (2.26)$$

e  $i = \sqrt{-1}$ .

Para  $\mathbf{V}_E$  e  $\mathbf{V}_D$  ortonormais, a matriz  $\mathbf{D}_r$  é dada em termos dos resíduos dos autovalores desprezados, contendo os efeitos de todos os modos desprezados no sistema original, ou seja:

$$\mathbf{D}_r = \sum_{i=r+1}^n \frac{\mathbf{C} \mathbf{v}_{d_i} \mathbf{v}_{e_i}^T \mathbf{B}}{\lambda_i} \quad (2.27)$$

## 2.5 – Sumário

Este capítulo apresenta a metodologia de modelagem de uma viga Euler-Bernoulli com elementos piezelétricos colados, discretizada pelo método dos elementos finitos. Partindo-se do princípio de Hamilton, deduzindo o princípio variacional eletromecânico e discretizando-se a estrutura pelo método dos elementos finitos, obtêm-se as equações de movimento da estrutura. O método de redução do modelo por meio de expansão em frações parciais é usado para reduzir o custo computacional durante as simulações.



## CAPÍTULO 3

### CONTROLE VIA LÓGICA DIFUSA

#### 3.1 – Introdução

As estruturas inteligentes, por definição possuem um sistema de controle integrado. Sendo assim, é de grande importância o estudo das leis e estratégias de controle que melhor se ajustam às necessidades de projeto das estruturas inteligentes.

Este Capítulo aborda uma estratégia de controle não convencional baseada em lógica difusa para o controle de estruturas inteligentes. As diferenças básicas entre o controle convencional e não convencional são apresentadas inicialmente. Em seguida são apresentados os conceitos básicos e fundamentos da lógica difusa para aplicação em controle de sistemas dinâmicos. São abordados os modelos difusos de Mamdani e Takagi-Sugeno-Kang. O projeto de controladores difusos é apresentado, mostrando as relações destes controladores com as estratégias de controle convencionais, a normalização dos conjuntos de entradas e saídas e as bases de conhecimento e de regras.

#### 3.2 – Controle convencional e não convencional

As técnicas de controle convencionais compreendem o controle clássico e moderno. O controle clássico é aplicado em sistemas lineares SISO (uma entrada uma saída) e são tratados no domínio da frequência, enquanto que o controle moderno pode ser aplicado em sistemas lineares e não lineares, SISO e MIMO

(múltiplas entradas múltiplas saídas) e são tratados no domínio do tempo, os quais podem ser representados no espaço de fase e variáveis de estado (OGATA, 1982; D'AZZO & HOUPIS, 1988). Esta diferenciação de controle clássico e moderno tem-se diminuído nos últimos tempos, pois ambas as estratégias se completam (NAGAMINE, 2001).

No controle convencional o algoritmo de controle é descrito analiticamente por equações (algébricas, diferenciais etc.) e requerem a descrição e conhecimento do sistema (YAGER & FILEV, 1994). Para contornar estes problemas, as técnicas de controle não convencionais vêm sendo amplamente exploradas. Estas técnicas, que incluem basicamente as redes neurais artificiais e a lógica difusa, possibilitam o projeto de controladores de sistemas não convencionais e complexos ou não claramente definidos (MASATO, 2000). A principal característica do uso de técnicas não convencionais de controle em estruturas inteligentes é a grande robustez de trabalhar com sistemas de baixa ou nenhuma confiabilidade (NAGAMINE, 2001). Neste texto, são abordados os conceitos e fundamentos da lógica difusa para controle não convencional.

### 3.3 – Fundamentos da lógica difusa

A **lógica difusa** surgiu com o trabalho “*Fuzzy Sets*” de Lotfi Zadeh em 1965 (ZADEH, 1965). A lógica difusa fornece um meio para prover um algoritmo de processamento de informação que lida com dados vagos e ambíguos dentro de um domínio de incertezas. Isto permite a representação de controle de sistemas pela emulação do conhecimento humano e raciocínio da física dos sistemas, em que o processo de inferência do homem para incertezas e ambigüidades do mundo real é dirigido subconscientemente. A teoria difusa fornece uma rigorosa aproximação matemática baseada na definição de conjuntos difusos para representar as incertezas dos sistemas. Com esta aproximação, pode-se assumir variáveis como elementos pertencendo parcialmente a um conjunto particular e também assumir operadores booleanos aplicados para processar o sistema de informação. O resultado é uma transição suave de uma operação para outra durante o processamento dos conjuntos

difusos. Tal propriedade é bastante apropriada para modelagem e controle de sistemas dinâmicos complexos (YAGER & FILEV, 1994).

Os conjuntos clássicos (aqui também denominados por conjuntos *crisp*) usam um processo de modelagem que faz uso de operadores aritméticos, cujas transições entre um membro e um não membro são abruptas e bem definidas.

A **função de associação ou de pertinência** (ROSS, 1995) é uma função característica de mapeamento dos elementos de um universo de discurso  $X$  de um conjunto *crisp*  $A \subset X$ , ou seja:

$$\mu_A(x) = \{0; 1\} \quad (3.1)$$

onde cada elemento do universo de discurso apresenta exclusão completa  $\mu_A(x) = 0$  ou pertinência completa  $\mu_A(x) = 1$  ao conjunto *crisp*  $A$ .

O mapeamento é um importante conceito no relacionamento da teoria de conjuntos às representações por funções de informação, o qual, para conjuntos clássicos, pode ser representado como na Figura 3.1.




FIGURA 3.1 – Função de associação para um conjunto clássico.

Os conjuntos difusos utilizam conectivos do tipo lógico *booleano*, tais como E, OU e SE-ENTÃO, e apresentam uma transição gradual, no qual aos elementos do universo de discurso são atribuídos graus contínuos de pertinência entre 0 (exclusão completa) e 1 (pertinência completa) a cada conjunto definido. Estes valores de pertinência expressam os graus com os quais cada elemento é

compatível com as propriedades dos conjuntos do universo (MASATO, 2000) e no qual pode ser representado pela função de pertinência da Equação (3.2).

$$\mu_A(x) = [0; 1] \quad (3.2)$$

A Figura 3.2 é uma representação típica de função de associação da Equação (3.2), com forma triangular.




FIGURA 3.2 – Função de associação para um conjunto difuso.

A Figura 3.3 ilustra a diferença básica entre os conjuntos clássicos e difusos. Nos conjuntos clássicos a transição entre um membro (elemento  $b$ ) e um não membro (elemento  $a$ ) é abrupta e bem definida (o elemento pertence ou não pertence ao conjunto  $A$ ), enquanto que nos conjuntos difusos a transição é gradual (o elemento  $c$  pertence parcialmente ao conjunto  $A$ ) (YAGER & FILEV, 1994).

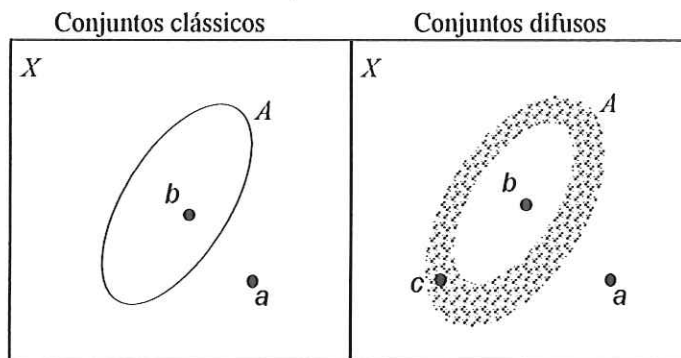


FIGURA 3.3 – Representação de conjuntos clássicos e difusos.



A função de associação provê uma relação entre o valor exato (físico) para uma representação num conjunto difuso. Os conjuntos difusos podem ser adjetivados por termos ou vocábulos que representam uma abstração do valor da variável, como por exemplo, negativo grande (NG), negativo médio (NM), negativo pequeno (NP), zero (Z), positivo pequeno (PP), positivo médio (PM) e positivo grande (PG), conforme ilustrada na Figura 3.4. Esta abstração facilita o processo de decisão e representa o ponto crucial em muitos sistemas de inteligência artificial (ROSS, 1995).




FIGURA 3.4 – Funções de associação adjetivadas.

O processo de conversão de valores exatos para valores difusos é chamado de **difusificação**, como mostrado na Figura 3.5.



FIGURA 3.5 – Difusificação.

Uma **base de conhecimento** difuso é composta por uma coleção de conjuntos difusos e contém informação significativa sobre o sistema que está sendo representado. Além disso, o comportamento do sistema também é representado por

uma **base de regras**, que combina os resultados do processamento das funções de associação para representar o grau de confiança dos passos anteriores do algoritmo difuso. Para estabelecer um grau de confiança em que esta base de regra é verdadeira, cada uma das saídas difusas é multiplicada por um fator de escala adequado (YAGER & FILEV, 1994)?.

Os modelos difusos basicamente se dividem em duas categorias, que diferem fundamentalmente em sua representação da base de regras. Os **modelos lingüísticos (modelos de Mamdani)** são baseados em uma coleção de regras SE-ENTÃO. Os **modelos de Takagi-Sugeno-Kang (TSK)** são formados por regras lógicas que têm uma combinação dos modelos difusos e não difusos.

### 3.4 – Modelo lingüístico de Mamdani

O modelo lingüístico é baseado em uma forma relevante de pensar dos seres humanos que é a implicação lógica, consistindo numa coleção de regras do tipo SE-ENTÃO. Tais formas compreendem a expressão natural mais comum para representar o conhecimento humano, pois expressa o conhecimento empírico e heurístico da linguagem de comunicação e de tomada de decisões, seja consciente ou inconsciente.

A forma geral da expressão é:

**SE premissa ENTÃO conclusão** (3.3)

que expressa uma regra de inferência, tal que se é conhecida uma premissa (fato, hipótese), então é possível inferir ou deduzir uma conclusão. Esta regra de inferência, geralmente é do tipo *modus ponens*, ou seja, modo afirmativo (SHAW & SIMÕES, 1999).

Em geral, pode-se utilizar três formas de expressões com as variáveis lingüísticas (formas de regras canônicas), como mostra a Figura 3.6, as quais podem compor regras compostas em cadeias.



FIGURA 3.6 – Expressões com variáveis lingüísticas.

Para estabelecer uma relação difusa  $R$  entre duas variáveis (ou conjuntos) existem técnicas que fazem uso dos operadores de implicação, ou seja,  $R = A \rightarrow B$  ( $A$  implica  $B$ ) que é conhecida como implicação clássica. Outras técnicas de implicação podem ser usadas para obter as funções de associação das relações difusas  $R$ , definidas no espaço de produto cartesiano  $X \times Y$  (ROSS, 1995):

- clássico

$$\mu_R(x, y) = \max\{\min[\mu_A(x), \mu_B(y)], 1 - \mu_A(x)\} \quad (3.4)$$

- mínima correlação ou implicação de Mamdani

$$\mu_R(x, y) = \min[\mu_A(x), \mu_B(y)] \quad (3.5)$$

- Lukasiewicz

$$\mu_R(x, y) = \min\{1, [1 - \mu_A(x) + \mu_B(y)]\} \quad (3.6)$$

- soma limitada

$$\mu_R(x, y) = \min\{1, [\mu_A(x) + \mu_B(y)]\} \quad (3.7)$$

- de Goguen

$$\mu_R(x, y) = \min\left\{1, \left[\frac{\mu_B(y)}{\mu_A(x)}\right]\right\}, \mu_A(x) > 0 \quad (3.8)$$

- correlação produto

$$\begin{aligned}\mu_R(x, y) &= \max\{\mu_A(x) \cdot \mu_B(y), [1 - \mu_A(x)]\} \\ \mu_R(x, y) &= \mu_A(x) \cdot \mu_B(y)\end{aligned}\quad (3.9)$$

- Brouwerian

$$\mu_R(x, y) = \begin{cases} 1 & \text{para } \mu_B(y) \leq \mu_A(x) \\ \mu_B(y) & \text{outros} \end{cases} \quad (3.10)$$

- R-Seq (seqüência lógica padrão)

$$\mu_R(x, y) = \begin{cases} 1 & \text{para } \mu_B(y) \leq \mu_A(x) \\ 0 & \text{outros} \end{cases} \quad (3.11)$$

Muitos sistemas de base de regras envolvem mais que uma regra. O processo de obtenção do conseqüente global a partir dos conseqüentes individuais de cada regra é conhecido como agregação das regras, onde todas estas inferências são ativadas em paralelo (SHAW & SIMÕES, 1999). Existem duas estratégias de agregação:

(i) **sistema de regras conjuntivas**, em que as regras devem ser satisfeitas conjuntamente (regras conectadas pelo conectivo E). A saída agregada (conseqüente) é encontrada pela intersecção de todas regras conseqüentes individuais  $y^i$ :

$$y = y^1 \text{ E } y^2 \text{ E } \dots \text{ E } y^r \quad \text{ou} \quad y = y^1 \cup y^2 \cup \dots \cup y^r \quad (3.12)$$

que é definido pela função de associação

$$\mu_y(x) = \min[\mu_{y^1}(x), \mu_{y^2}(x), \dots, \mu_{y^r}(x)] \quad \text{para } y \in Y \quad (3.13)$$



(ii) **sistema de regras disjuntivas**, em que pelo menos uma regra seja satisfeita (regras conectadas pelo conectivo OU). A saída agregada é encontrada pela união de todas regras consequentes individuais  $y^i$ :

$$y = y^1 \text{ OU } y^2 \text{ OU } \dots \text{ OU } y^r \quad \text{ou} \quad y = y^1 \cap y^2 \cap \dots \cap y^r \quad (3.14)$$

que é definida pela função de associação

$$\mu_y(x) = \max[\mu_{y^1}(x), \mu_{y^2}(x), \dots, \mu_{y^r}(x)] \quad \text{para } y \in Y \quad (3.15)$$

As técnicas de inferência podem ser representadas graficamente, onde é possível calcular as inferências manualmente, a fim de realizar um processo de verificação de erros nos modos computacionais (ROSS, 1995).

Baseada no método de implicação de Mamdani para inferência e para conjunto de regras disjuntivas a saída agregada para  $r$  regras é dada por:

$$\mu_{B^k}((\alpha(i), \alpha(j))) = \max\{\min[\mu_{A_1^k}(\alpha(i)), \mu_{A_2^k}(\alpha(j))]\} \quad k = 1, 2, \dots, r \quad (3.16)$$

onde  $A_1^k$  e  $A_2^k$  representam os  $k$ -ésimos conjuntos difusos antecedentes e  $B^k$  o  $k$ -ésimo conjunto difuso consequente para  $k$ -ésima regra com entradas *crisp*  $\alpha(i)$  e  $\alpha(j)$ . A representação gráfica desta interpretação está mostrada na Figura 3.7 e é conhecida como método de inferência **max-min**.

Outro método é pela técnica de implicação **max-produto**, dado por (ver Figura 3.8):

$$\mu_{B^k}((\alpha(i), \alpha(j))) = \max[\mu_{A_1^k}(\alpha(i)) \cdot \mu_{A_2^k}(\alpha(j))] \quad k = 1, 2, \dots, r \quad (3.17)$$




FIGURA 3.7 – Método de inferência max-min.




FIGURA 3.8 – Método de inferência max-produto.

Tendo-se o conjunto difuso resultante é preciso obter um valor exato (físico) da saída para aplicação real. Este processo é chamado **dedifusificação** e os principais métodos são:

- princípio da máxima associação (ver Figura 3.9);

$$\mu_A(x^*) \geq \mu_A(x) \quad (3.18)$$




FIGURA 3.9 – Princípio da máxima associação.

- método do centróide, ou centro de área ou gravidade (veja Figura 3.10);

$$x^* = \frac{\int \mu_A(x) x dx}{\int \mu_A(x) dx} \quad (3.19)$$




FIGURA 3.10 – Método do centróide.

- método da média ponderada (válido somente para saídas com funções de associação simétricas);

$$x^* = \frac{\sum \mu_A(\bar{x}) \bar{x}}{\sum \mu_A(\bar{x})} \quad (3.20)$$






FIGURA 3.11 – Método da média ponderada.

- média da associação máxima, diferindo do primeiro método onde os pontos de máximo podem não ser únicos;

$$x^* = \frac{a+b}{2} \quad (3.21)$$




FIGURA 3.12 – Método da média da associação máxima.

- centro das somas

$$x^* = \frac{\int_x \sum_{k=1}^n \mu_{A_k}(x) dx}{\int_x \sum_{k=1}^n \mu_{A_k}(x) dx} \quad (3.22)$$




FIGURA 3.13 – Método do centro das somas.

### 3.5 – Modelo de Takagi-Sugeno-Kang

Uma desvantagem dos modelos lingüísticos é que eles não contêm uma forma explícita de conhecimento objetivo sobre o sistema se tal conhecimento não é expresso ou incorporado na estrutura do conjunto difuso. O modelo Takagi-Sugeno-Kang (TSK) é uma alternativa para este problema, o qual é caracterizado por regras lógicas que têm uma parte antecedente difusa e conseqüente funcional. Com este modelo o conjunto de saídas conseqüentes será em um conjunto difuso discreto com um número finito de pontos, simplificando e elevando a eficiência do processo computacional (YAGER & FILEV, 1994). A forma geral de inferência do modelo TSK é

$$\text{Regra } i: \text{ SE } x_1 \text{ é } A_1 \text{ e... e } x_n \text{ é } A_n \text{ ENTÃO } y_i = f_i(x_1, \dots, x_n) \quad (3.23)$$

onde  $A_1 \dots A_n$  são conjuntos difusos,  $x_1 \dots x_n$  são as entrada de valores *crisp*,  $y_i$  é a  $i$ -ésima saída da regra e  $f_i$  normalmente representa uma combinação linear aplicada aos valores exatos, como exemplificada na Equação (3.24).

$$\text{Regra } i: \text{ SE } x_1 \text{ é } A_1 \text{ e } x_2 \text{ é } A_2 \text{ ENTÃO } y_i = a_1 \cdot x_1 + a_2 \cdot x_2 \quad (3.24)$$

A saída do modelo TSK devido a  $r$  regras difusas é dada pela média ponderada das saídas individuais de cada regra, ou seja:

$$y = \frac{\sum_{i=1}^r w_i y_i}{w_i} \quad (3.25)$$

onde  $w_i = \prod_{i=1}^r \mu_{A_i}(x_i)$  representa o grau de liberdade da regra  $i$ .

### 3.6 – Projeto de controlador difuso

Um controlador em malha fechada pode ser representado pela Figura 3.14, onde a saída da planta é comparada com um sinal de referência gerando um sinal de erro. O controlador recebe este sinal e fornece um sinal de ação de controle para a planta, com a finalidade de gerar o sinal de saída igual à referência.




FIGURA 3.14 – Esquema de um sistema de controle em malha fechada.

Por controle difuso entende-se como uma lei de controle que é obtida por um sistema de base de conhecimento consistindo de um conjunto de regras e uma metodologia de inferência difusa. A base de regras é a principal parte de um controlador difuso, que pode ser representada em uma forma similar à lei de controle convencional, de acordo com a Equação (3.26).

$$u(n) = F[e(n), e(n-1), \dots, u(n-1), u(n-2)] \quad (3.26)$$

onde  $F$  é a função que representa a lei de controle, ou seja, a lei de controle difuso,  $e(n)$  é o erro e  $u(n)$  a ação de controle no tempo  $n$ .

Um controlador difuso típico descreve a relação entre a variação da ação de controle  $\Delta u(n) = u(n) - u(n-1)$  para o erro  $e(n)$  e sua variação  $\Delta e(n) = e(n) - e(n-1)$ , podendo ser usado os modelos Mamdani ou TSK.

Os controladores difusos podem ser associados às estratégias de controle convencional do tipo PID. Essa relação pode ajudar durante o projeto do controlador difuso, desde que se saiba o comportamento teórico de tais controladores (NAGAMINE, 2001).

O controlador tipo PI combina a ação de controle proporcional mais integral, relacionando a variação de ação de controle, o erro e a variação do erro, ou seja:

$$\Delta u(k) = F[e(n), \Delta e(n)] \quad (3.27)$$

que é similar à lei de controle PI convencional, ou seja:

$$\Delta u(n) = K_P \Delta e(n) + K_I e(n) \quad (3.28)$$

onde  $K_P$  e  $K_I$  são os parâmetros do controlador tipo PI (ganho proporcional e integral). Enquanto que o controlador convencional tipo PI possui uma relação linear, o controlador difuso geralmente possui uma relação não linear (YAGER & FILEV, 1994).

O controlador tipo PD combina as ações do erro e da variação do erro para se obter a ação de controle, ou seja:

$$u(n) = F[e(n), \Delta e(n)] \quad (3.29)$$

Sua lei de controle é similar à lei de controle PD convencional, ou seja:

$$u(n) = K_P e(n) + K_D \Delta e(n) \quad (3.30)$$

onde  $K_P$  e  $K_D$  são os parâmetros do controlador tipo PD (ganho proporcional e derivativo). A Figura 3.15 caracteriza um controlador difuso do tipo PD.




FIGURA 3.15 – Controlador difuso tipo PD.



O controlador tipo PID combina as ações do erro, da variação do erro e da soma dos erros para se obter a ação de controle, ou seja:

$$u(n) = F[e(n), \sum e(n), \Delta e(n)] \quad (3.31)$$

que é similar à lei de controle PID convencional, ou seja:

$$u(n) = K_P e(n) + K_I \sum e(n) + K_D \Delta e(n) \quad (3.32)$$

onde  $K_P$ ,  $K_I$  e  $K_D$  são os parâmetros do controlador tipo PID.

A Figura 3.16 ilustra o sistema de controle difuso em malha fechada, com ganhos de controle aplicados nas variáveis de entrada e de saída. As entradas do controlador difuso dos modelos lingüísticos são difusificadas e medidos seus graus de pertinência em relação às variáveis lingüísticas, através das funções de associação da base de conhecimento. Através de um processo de inferência utilizando-se a base de regras, obtêm-se as saídas difusas de cada regra. Agrégando-se estas saídas, obtém-se a saída difusa global, que pelo processo de defusificação é obtido a saída *crisp* desejada, correspondendo à ação de controle. Para facilitar o processo computacional, os universos de discurso dos conjuntos de entrada e saída do controlador são normalizados, constituindo um controlador difuso generalizado. Os ganhos de controle são aplicados ao controlador difuso, de maneira que eles alterem a intensidade de cada variável com respeito ao controle, ou seja, uma mudança dos ganhos provoca uma mudança da resposta do controlador.

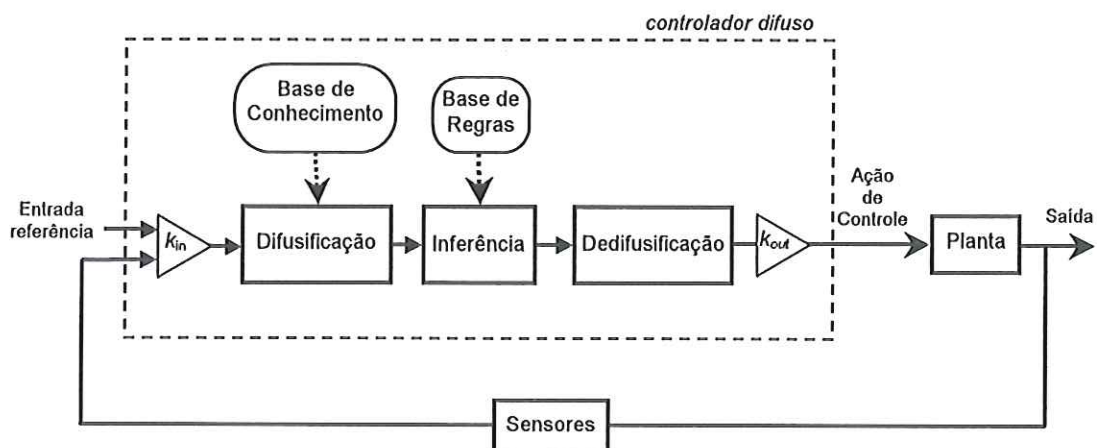


FIGURA 3.16 – Sistema com controle difuso.

Considerando-se um controlador difuso do tipo PD, com os universos dos conjuntos difusos normalizados, pode-se aplicar os ganhos de controle nas variáveis de entrada (erro e variação do erro) e na variável de saída (ação de controle), de acordo com a Figura 3.17.




FIGURA 3.17 – Ganhos aplicados ao controlador difuso.

A base de conhecimento pode ser representada por conjuntos difusos com diversos formatos das funções de pertinência. O formato mais usado é o triangular, onde na Figura 3.4 temos como exemplo os conjuntos difusos adjetivados pelas variáveis lingüísticas NG, NM, NP, Z, PP, PM e PG.

Pode-se estabelecer para o modelo de Mamdani as entradas (erro e variação do erro) e saída (ação de controle) de acordo com o formato da base de conhecimento definido no parágrafo acima, considerando-se as bases normalizadas.

No modelo TSK as entradas podem ser as mesmas que no modelo Mamdani, porém a saída é baseada em informação difusa, mas emprega uma combinação linear ponderada por coeficientes, de acordo com a Equação (3.33).

$$y_i = a_2 e + a_1 \Delta e + a_0 \quad (3.33)$$

sendo  $a_0$ ,  $a_1$  e  $a_2$  os coeficientes do modelo TSK para a  $i$ -ésima saída da  $i$ -ésima regra.

Para as diferentes variáveis lingüísticas de saída, os coeficientes de ponderação são diferentes. Tendo-se as variáveis lingüísticas e a base de conhecimento do controlador, a próxima etapa é elaborar a base de regras, as quais definem uma lei de controle e funcionam de acordo com um mecanismo de

inferência baseado nas informações da base de conhecimento, permitindo controlar a planta.

A base de regras é formada por um conjunto de regras SE-ENTÃO, de acordo com a Equação (3.3). A Tabela 3.1 mostra uma base de regras empregada em controladores difusos tipo PD, sugerida por MacVicar-Whelan (YAGER & FILEV, 1994), sendo a premissa representada pelos sinais de erro e variação do erro, ligados pelo conectivo lógico E. A parte conseqüente corresponde à ação de controle (área escura da tabela). Esta base é mais utilizada nos modelos lingüísticos de Mamdani, mas é válida para o modelo TSK, onde para cada conjunto difuso atingido tem-se um conjunto de coeficientes da combinação linear diferente. Outros conjuntos de regras podem ser obtidos seguindo-se o modelo de MacVicar-Whelan, pois esta base segue um modelo padrão do raciocínio lógico empregado no controle de processos, estabelecido pelas três regras básicas a seguir:

- Regra 1: Se o erro  $e(n)$  e sua variação  $\Delta e(n)$  são zeros, então mantenha a ação de controle presente;
- Regra 2: Se o erro  $e(n)$  tende a zero numa variação satisfatória, então mantenha a ação de controle presente;
- Regra 3: Se o erro  $e(n)$  não está se corrigindo, então a ação de controle é não zero e depende do sinal e magnitude do erro  $e(n)$  e de sua variação  $\Delta e(n)$ .

TABELA 3.1 – Base de regras do controlador difuso.

$e \backslash \Delta e$	NG	NM	NP	Z	PP	PM	PG
NG	NG	NG	NG	NG	NM	NP	Z
NM	NG	NG	NM	NM	NP	Z	PP
NP	NG	NM	NP	NP	Z	PP	PM
Z	NG	NM	NP	Z	PP	PM	PG
PP	NM	NP	Z	PP	PP	PM	PG
PM	NP	Z	PP	PM	PM	PG	PG
PG	Z	PP	PM	PG	PG	PG	PG

### **3.7 – Sumário**

Este Capítulo apresenta inicialmente as diferenças básicas de controle convencional e não convencional. Depois são tratados os conceitos básicos e os fundamentos teóricos da lógica difusa para aplicação em controle de sistemas dinâmicos. São apresentados os modelos lingüísticos de Mamdani e Takagi-Sugeno-Kang para construção do controlador. O projeto típico do controlador difuso é mostrado, relacionando suas ações com as ações convencionais de controle (PI, PD e PID).



## CAPÍTULO 4

### OTIMIZAÇÃO DE CONTROLADORES DIFUSOS VIA ALGORITMO GENÉTICO

#### 4.1 – Introdução

Um dos grandes problemas na elaboração de controladores difusos está na determinação correta de seus parâmetros. Geralmente a determinação de parâmetros para controladores difusos é feita baseada em um processo por tentativa e erro, tornando-se tedioso, consumindo uma considerável quantidade de tempo, ocasionando grandes dispêndios e aumentando assim o custo do projeto. Os controladores difusos possuem diversos parâmetros a serem ajustados, que variam de acordo com o sistema dinâmico empregado. Dentre estes parâmetros, estão os ganhos das variáveis de entrada e saída, que se associam aos ganhos do controle convencional PID. Também se pode ajustar a base de conhecimento, alterando-se os tipos e parâmetros (forma) das funções de pertinência.

Diferentes métodos de otimização podem ser empregados na determinação de parâmetros de sistemas. Técnicas convencionais de otimização e busca trabalham geralmente de forma seqüencial explorando um ponto por vez no espaço de busca. O algoritmo genético é um processo de procura probabilística onde uma característica importante é que o processo de obtenção de uma solução ótima é paralelo e estruturado, ou seja, trabalha com indivíduos representando um conjunto possível de soluções do problema (BARBOSA, 1997).

Este Capítulo apresenta os conceitos básicos e fundamentos de algoritmos genéticos. Apresenta também o emprego na obtenção dos ganhos e das funções de pertinência dos controladores difusos para controle de vibração de estruturas inteligentes.

## 4.2 – Fundamentos de algoritmos genéticos

Um algoritmo genético (AG) compreende uma abordagem da computação evolutiva introduzida por J. Holland no final da década de 60, visando principalmente o estudo de sistemas adaptativos complexos e aplicação em problemas de otimização (BARBOSA, 1997). Basicamente é um processo de procura estocástica, combinando regras probabilísticas e determinísticas (GOLDBERG, 1989). Um algoritmo genético é baseado nas leis de seleção natural influenciadas pelas teorias de Charles Darwin e nos princípios da genética. O método é composto de um processo de reprodução, recombinação de cromossomos (*crossover*) e mutação dos indivíduos, os quais participam de uma competição, onde sobrevivem os mais aptos. Os AG podem ser aplicados em problemas de otimização contínuos e discretos.

Uma característica importante de um AG é que o processo de obtenção de uma solução ótima é paralelo e estruturado, ou seja, um AG trabalha com indivíduos representando um conjunto possível de soluções do problema, enquanto que técnicas convencionais de otimização e busca trabalham geralmente de forma sequencial processando um único ponto no espaço de busca a cada instante. Segundo MICHALEWICZ (1994) esta busca em soluções potenciais para o problema requer um equilíbrio entre o aproveitamento das melhores soluções e a exploração do espaço de busca.

A população inicial é geralmente obtida por um meio aleatório, sendo seus parâmetros previamente conhecidos em um intervalo de soluções possíveis (fenótipos). O passo seguinte consiste em avaliar os **indivíduos** através de uma **função de avaliação (função de aptidão ou *fitness*)**. A fase de **reprodução** consiste em selecionar os indivíduos aptos a passarem à próxima geração, em que os

indivíduos representando as soluções “boas” se reproduzem e os indivíduos representando as soluções “ruins” são eliminados. Os novos indivíduos passam por um processo onde ocorre a **recombinação**, ou seja, seus materiais genéticos são trocados e depois passam pelo processo de **mutação**, onde os indivíduos sofrem mudanças em seu material genético. A nova população é então criada e avaliada novamente pela função de aptidão dos novos indivíduos. A fase de evolução ocorre até que um critério de parada seja estabelecido, que geralmente ocorre quando uma solução desejada é encontrada ou o número máximo de **gerações** é alcançado. A Figura 4.1 representa um algoritmo genético típico.

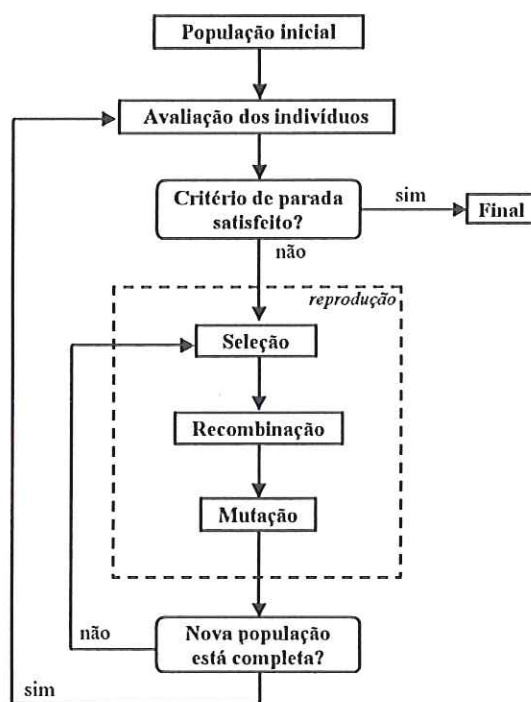


FIGURA 4.1 – Algoritmo genético típico.

#### 4.2.1 – Representação e codificação dos indivíduos

Os AG trabalham com codificação do conjunto de parâmetros (que podem representar vários entes matemáticos, tais como vetores, matrizes, pesos, expressões matemáticas etc.) e não com os parâmetros diretamente. Por isto, a fase de codificação é a primeira e mais importante para o processo, pois uma codificação inadequada pode levar a problemas de convergência prematura do AG (MASATO,



2000). A codificação representa o **genótipo** (conjunto de **genes**) do indivíduo e define uma estrutura chamada **cromossomo**, que são geralmente uma seqüência de variáveis do problema (parâmetros a serem determinados ou otimizados) em uma forma agrupada e organizada.

A codificação binária proposta por J. Holland é a mais utilizada, pois maximiza o paralelismo implícito inerente ao algoritmo genético (MICHALEWICZ, 1994). Ela é simples, fácil de manipular os cromossomos através dos operadores genéticos, fácil de ser transformada em outras bases numéricas e facilita a prova de alguns teoremas (PACHECO, 1999).

Na codificação binária, o tamanho do cromossomo depende da precisão numérica adotada e do número de parâmetros a serem determinados. Um cromossomo pode ser representado por várias cadeias binárias representando diversos parâmetros. A Figura 4.2 mostra o genótipo de um indivíduo com um cromossomo e diversos códigos de variáveis ( $v_1, v_2, \dots, v_n$ ) concatenados, sendo de diferentes tamanhos para cada variável.

$$\underbrace{10010110}_{v_1} \underbrace{0100101}_{v_2} \dots \underbrace{01101}_{v_n}$$

FIGURA 4.2 – Representação de um cromossomo binário.

Em problemas dinâmicos, geralmente trabalha-se com números reais. Portanto, para uma codificação binária, é preciso transformar as variáveis para a potência de dez, para representar os parâmetros reais do sistema, como os ganhos do controlador.

Uma variável real  $x_R \in \{x_{\min}; x_{\max}\}$  com espaçamento  $p$  pode ser representada por uma cadeia de  $k$  bits, como na Equação (4.1), onde se associa a cadeia  $\underbrace{00\dots0}_{k \text{ bits}}$  ao limite inferior e  $\underbrace{11\dots1}_{k \text{ bits}}$  ao limite superior (BARBOSA, 1997).

$$p = \frac{x_{\max} - x_{\min}}{2^k - 1} \quad (4.1)$$



### 4.2.2 – Definição da população inicial

O processo de inicialização da população de indivíduos geralmente é feito por um meio aleatório, que permite uma maior variabilidade dos indivíduos dentro do **universo de busca**. Indivíduos com soluções próximas das requeridas ou com algum tipo de informação prévia podem ser inseridos na população inicial para convergência mais rápida do algoritmo. Deve-se tomar cuidado, no entanto, na geração de indivíduos inválidos, os quais podem ficar além dos limites do universo de busca.

A inicialização aleatória possui a desvantagem de poder gerar regiões com concentração de indivíduos e outras sem indivíduos. Uma forma de contornar este problema é através da inicialização determinística, que distribui a população uniformemente no espaço de solução. Outros métodos de inicialização podem ser empregados, como a inicialização aleatória com nicho e a inicialização implementada (GUIMARÃES & RAMALHO, 2001).

### 4.2.3 – Função de aptidão

A função de aptidão é a responsável pelo processo de **seleção** e é a principal forma de determinar a condição de cada indivíduo no espaço de busca, fornecendo indicações sobre a localização do ótimo (BARBOSA, 1997). É também uma importante ligação entre o AG e o sistema. A função de aptidão recebe o valor do cromossomo decodificado, obtido por uma função de custo do sistema, e produz um valor que é a medida do desempenho do indivíduo. Assim sendo, os melhores indivíduos são aqueles cujos valores de aptidão estão em uma margem de precisão estabelecida. O processo de avaliação pode ser realizado pela maximização ou minimização da função de aptidão, dependendo dos objetivos do problema e pode compreender a etapa mais custosa do AG, pois é necessária a simulação de sistemas dinâmicos (em casos de implementação matemática destes sistemas).

Em sistemas dinâmicos pode-se utilizar, de forma geral, a minimização da função de custo que emprega o índice de desempenho do erro estabelecido pela integral do erro quadrático em um determinado intervalo de tempo, ou seja:

$$J = \int_0^{\infty} e^2(t) dt \quad (4.2)$$

Utilizando-se o tempo discreto  $n$ , para cada indivíduo  $i$  será gerada a saída  $y_i(n)$  do sistema, cuja comparação com um valor de referência  $y_{ref}(n)$  fornece o erro  $e_i(n)$ , ou seja:

$$e_i(n) = y_{ref}(n) - y_i(n) \quad (4.3)$$

Pode-se então calcular a função de custo empregando-se a somatória dos erros quadráticos, ou seja:

$$J_i = \sum_{n=1}^N (e_i(n))^2 \quad (4.4)$$

onde  $N$  é o índice do tempo final decorrido na simulação.

A função de aptidão denotada  $f_i^g$  representando a aptidão do indivíduo  $i$  em uma geração  $g$  é então calculada por uma lei  $F$  sobre o valor de custo obtido pela Equação 4.4, ou seja:

$$f_i^g = F(J_i) \quad (4.5)$$

Essa lei tipicamente pode ser o inverso de seu argumento, a qual deverá ser maximizada, ou seja:

$$f_i^g = 1/J_i \quad (4.6)$$

Outros índices de desempenho do erro podem ser empregados, tais como a integral do erro quadrático multiplicado pelo tempo, a integral do erro absoluto, a integral da soma do erro quadrático e do quadrado da variação do erro, entre outros, onde se pode variar o grau de seletividade no processo de otimização (OGATA, 1982; DAZZO & HOUPIS, 1988) e permitindo também a minimização da energia usada no sistema.

Nestes índices estão implícitos o erro de regime, o valor de sobre-sinal, o tempo de estabilização e outras características da resposta do sistema, podendo-se ter respostas distintas com o mesmo índice de desempenho.

#### 4.2.4 – Seleção de indivíduos

O processo de seleção consiste em selecionar os melhores indivíduos (com maior aptidão) da população para o processo de reprodução (onde serão criadas cópias dos indivíduos selecionados) permitindo que estes indivíduos passem as suas características à próxima geração. Este processo representa a sobrevivência dos melhores na natureza (GOLDBERG, 1989).

Existem diferentes métodos para aplicar o processo de seleção. O método da **roda de roleta** (*roulette wheel*) é o método mais utilizado, onde é gerado um número aleatório  $\alpha$  entre zero e a aptidão total (soma de toda as aptidões da população) e o indivíduo escolhido é aquele cuja somatória das aptidões dos indivíduos anteriores (os indivíduos podem ser ordenados de acordo com sua aptidão) é maior ou igual a  $\alpha$  (GOLDBERG, 1989). No método de seleção por **torneio** um grupo de  $t$  indivíduos é aleatoriamente escolhido e o indivíduo de melhor aptidão é selecionado (BARBOSA, 1997). Nestes dois métodos os indivíduos são selecionados aos pares para serem reproduzidos. Além disso, pode ocorrer a perda do melhor ou melhores indivíduos da população (não serem selecionados). Uma solução é utilizar a seleção **elitista**, que consiste em manter sempre um certo número dos melhores indivíduos da geração atual na geração seguinte (MICHALEWICZ, 1994).



Outro método bastante empregado é a seleção baseada em grau (*rank*), onde os indivíduos são ordenados de acordo com suas aptidões para determinar a probabilidade de seleção.

Diversos outros métodos de seleção podem ser encontrados na literatura, tais como os métodos por amostragem aleatória simples ou equiprovável (GUIMARÃES & RAMALHO, 2001), por truncamento, por normalização linear e por normalização exponencial (PACHECO, 1999).

## 4.2.5 – Operadores genéticos

### 4.2.5.1 – Recombinação

A recombinação é um operador genético que representa o acasalamento entre os indivíduos. É a operação básica em um AG para a propagação das características dos indivíduos mais aptos, na qual ocorre a troca de informações dos indivíduos para produzir um novo cromossomo. Esta operação depende de um fator de probabilidade (taxa de *crossover*) para ocorrer e consiste em selecionar dois indivíduos aleatoriamente e determinar um ponto de corte (localização no cromossomo onde haverá a ruptura) para permutar as partes correspondentes de cada cromossomo. A Figura 4.3 ilustra o processo de recombinação para indivíduos com codificação binária, representando o *crossover* de um ponto (BARBOSA, 1997).




FIGURA 4.3 – *Crossover* típico entre dois cromossomos.



Outra forma de realizar a recombinação é através do *crossover* multiponto, onde mais de um ponto de ruptura pode ser selecionado, e o *crossover* uniforme, em que ocorre uma troca dos genes com certa probabilidade, para cada posição (BARBOSA, 1997).

#### 4.2.5.2 – Mutação

A mutação é um outro operador genético que consiste na mudança de informação do cromossomo sem razão prévia, ou seja, é uma operação que define a variação local ou global no cromossomo. A mutação é responsável pela introdução e manutenção da diversidade genética na população, alterando arbitrariamente um ou mais genes de um cromossomo, quando determinada condição é satisfeita (de acordo com a taxa de mutação) (GOLDBERG, 1989).

Geralmente utiliza-se uma taxa de mutação pequena, pois se trata de um operador genético secundário. Uma baixa taxa de mutação previne que uma dada posição fique estagnada em um valor, além de possibilitar que se chegue em qualquer ponto do espaço de busca. Na maioria das vezes a mutação é aplicada após a recombinação (MASATO, 2000).

Na representação binária de indivíduos, a mutação pode ocorrer simplesmente modificando um gene, ou seja, trocando-se os valores dos genes com uma probabilidade que depende da taxa de mutação. A Figura 4.4 mostra a mutação de um indivíduo, onde há a troca pelos valores binários opostos para os genes nas posições 3 e 7.

antes:	1	0	1	1	0	1	0	0	0	0
depois:	1	0	0	1	0	1	1	0	1	0

FIGURA 4.4 – Mutação de um indivíduo.

## **4.2.6 – Elitismo**

O método elitista é o mais utilizado para melhorar a convergência do AG. Este método garante que uma elite de indivíduos seja mantida nas gerações futuras, pois com os operadores de recombinação e mutação, estes indivíduos estão sujeitos a serem destruídos, originando indivíduos com menor aptidão (MASATO, 2000; GOLDBERG, 1989).

O elitismo consiste basicamente em selecionar uma elite dos  $n$  melhores indivíduos da população da geração atual e inseri-los na população da geração seguinte (após a reprodução e operações genéticas) (MASATO, 2000). Geralmente considera-se um tamanho pequeno para a elite, sendo 1 ou 2 para uma população de 50 indivíduos (GUIMARÃES & RAMALHO, 2001).

## **4.2.7 – Considerações diversas**

### **4.2.7.1 – Critérios de substituição**

Diversos tipos de substituição da população anterior pela nova podem ser empregados (GUIMARÃES & RAMALHO, 2001). Pode-se citar: (i) substituição imediata, em que os indivíduos gerados após a reprodução (descendentes) substituem toda a população que os antecederam (progenitores); (ii) substituição por fator cheio, onde os descendentes substituem os indivíduos da população anterior mais parecidos com eles; (iii) substituição por inserção, onde  $m$  descendentes substituem os  $m$  piores indivíduos da população anterior e (iv) substituição por inclusão, onde os  $n$  melhores indivíduos de uma população formada pelos descendentes e progenitores juntos são selecionados.

### **4.2.7.2 – Desempenho de um algoritmo genético**

Diversos fatores contribuem para o desempenho do AG, dos quais a codificação é o mais crítico. A codificação binária geralmente apresenta pouco

desempenho quando aplicada a problemas numéricos de alta dimensionalidade, pois os cromossomos podem ser representados por cadeias de grande comprimento. Isto aumenta o custo computacional, sendo mais apropriada a codificação em ponto flutuante ou codificação real (MICHALEWICZ, 1994).

O tamanho da população está ligado diretamente com o desempenho do AG. O custo computacional é maior se a população aumenta, pois mais simulações deverão ser feitas, porém previne convergências prematuras para soluções locais. Se a população é pequena a acurácia diminui devido à redução da variação de cromossomos (pequena cobertura do espaço de busca) (GUIMARÃES & RAMALHO, 2001).

Altas taxas de cruzamento podem deixar o algoritmo genético mais rápido, porém a possibilidade de se perder indivíduos de melhor aptidão também é maior. Baixas taxas de mutação previnem que as soluções fiquem estagnadas em uma dada posição, fazendo que estas alcancem outros pontos do espaço de busca (GUIMARÃES & RAMALHO, 2001).

A avaliação dos cromossomos e os cálculos de aptidão são os que consomem maior tempo em um AG. Se a operação de avaliação é reduzida, o AG processará mais rápido e isto pode ser conseguido reduzindo-se o tamanho da população e o número de gerações para alcançar a solução.

Diversos outros fatores encontrados na literatura podem ser considerados no desempenho de algoritmos genéticos, tais como, os métodos de seleção dos indivíduos, tipos de operadores genéticos envolvidos, critérios de substituição etc.

### **4.3 – Processo de otimização de um controlador difuso por algoritmo genético**

#### **4.3.1 – Obtenção dos ganhos do controlador**

Tendo-se o sistema dinâmico (planta) e o controlador difuso definidos, o passo inicial no emprego do algoritmo genético é a identificação e codificação dos parâmetros do controlador a serem ajustados. Considerando-se o controlador difuso



com estratégia PD, a otimização do controlador será feita através da obtenção dos ganhos de controle, ou seja, os ganhos dos sinais de entrada (erro  $k_e$  e variação do erro  $k_{\Delta e}$ ) e do sinal de saída (ação de controle  $k_u$ ), conforme mostrado na Figura 3.17. Os indivíduos da população são formados pelas cadeias de cromossomos de acordo com o vetor de valores  $[k_e k_{\Delta e} k_u]$ , que correspondem às variáveis a serem ajustadas (ganhos do controlador).

### 4.3.2 – Obtenção das funções de pertinência

Da mesma forma que o item 4.3.1 pode-se empregar o algoritmo genético para obtenção das funções de pertinência do controlador difuso. Considerando-se as funções de pertinência com formas triangulares, pode-se empregar o algoritmo genético para modificar o suporte de cada função, ou seja, modificar as posições no universo de discurso de cada vértice dos triângulos, como mostra a Figuras 4.5.




FIGURA 4.5 – Funções de pertinência do controlador difuso.

Na Figura 4.5, a função triangular da variável lingüística NM, por exemplo, pode ser ajustada de acordo com o suporte (posições  $P_1$ ,  $P_3$  e  $P_5$ ) ao longo do **universo de discurso**. Os indivíduos da população são formados então pelas cadeias de cromossomos contendo todas as posições a serem ajustadas, ou seja, de acordo com o vetor de valores  $[P_1 P_2 \dots P_{10}]$ .



É importante observar, que para determinados controladores, os fenótipos obtidos após os ajustes das formas das funções de pertinência podem não ser adequados (ARSLAN & KAYA, 2001), pois podem resultar em ações de controle indesejáveis, tais como altas acelerações. A Figura 4.6 mostra uma situação não adequada onde não há decisão entre as variáveis NM e NG, bem como entre Z e PM. Isso poderia provocar um efeito de “zona morta” na ação de controle. Para contornar esta situação, pode-se definir os intervalos de trabalho (ou universo de discurso) de cada parâmetro de ajuste, por exemplo:  $P_1 \leq P_2 \leq P_3$  e  $0 \leq P_6 \leq P_7$ .

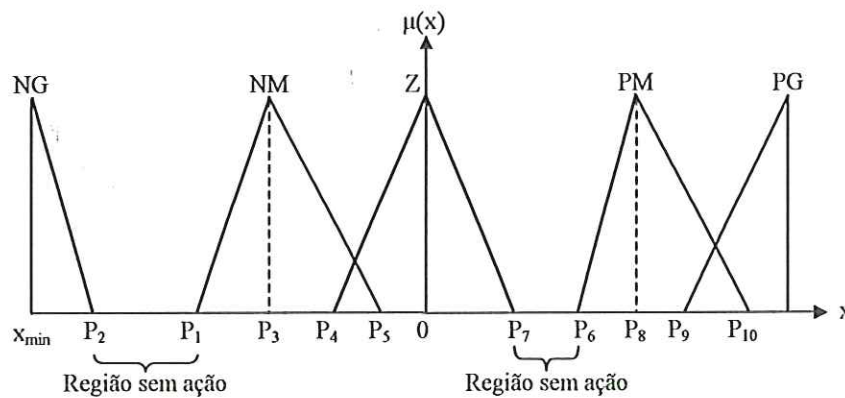


FIGURA 4.6 – Funções de pertinência não adequadas para um controlador difuso.

### 4.3.3 – Processo de otimização

No processo de otimização por AG de sistemas de controle em malha fechada é necessária a execução de simulações. Cada indivíduo da população fornecerá parâmetros de ajuste do controlador, representando o controlador a ser utilizado, ou seja, para  $q$  indivíduos são necessárias  $q$  simulações em cada geração. Tendo-se a planta e o controlador definidos, deve-se então definir os parâmetros de simulação do sistema, tais como tempo de amostragem e discretização no tempo.

Define-se a codificação dos indivíduos e o critério de avaliação dos indivíduos (função de aptidão) a ser empregada no processo de avaliação pelo AG. Define-se também os parâmetros do AG, tais como o tamanho da população (número

de indivíduos na população), número máximo de gerações, taxa de *crossover* e taxa de mutação dos indivíduos, número de indivíduos da elite e o critério de parada do processo de otimização (pode ser o número máximo de gerações ou quando uma aptidão é alcançada).

A Figura 4.7 ilustra o processo de ajuste dos parâmetros de um controlador difuso por meio de um AG. Para cada indivíduo da população é realizada a simulação do sistema de controle em malha fechada, tendo-se a resposta gerada pela planta, de acordo com as condições iniciais e sinais de distúrbios. O controlador difuso recebe o sinal de erro entre a resposta da planta e um valor de referência e gera uma ação de controle para a planta, a qual proverá uma outra resposta. O AG recebe os sinais de erro das simulações referentes a cada indivíduo, calcula as aptidões deste e procede com a otimização de acordo com o algoritmo da Figura 4.1.

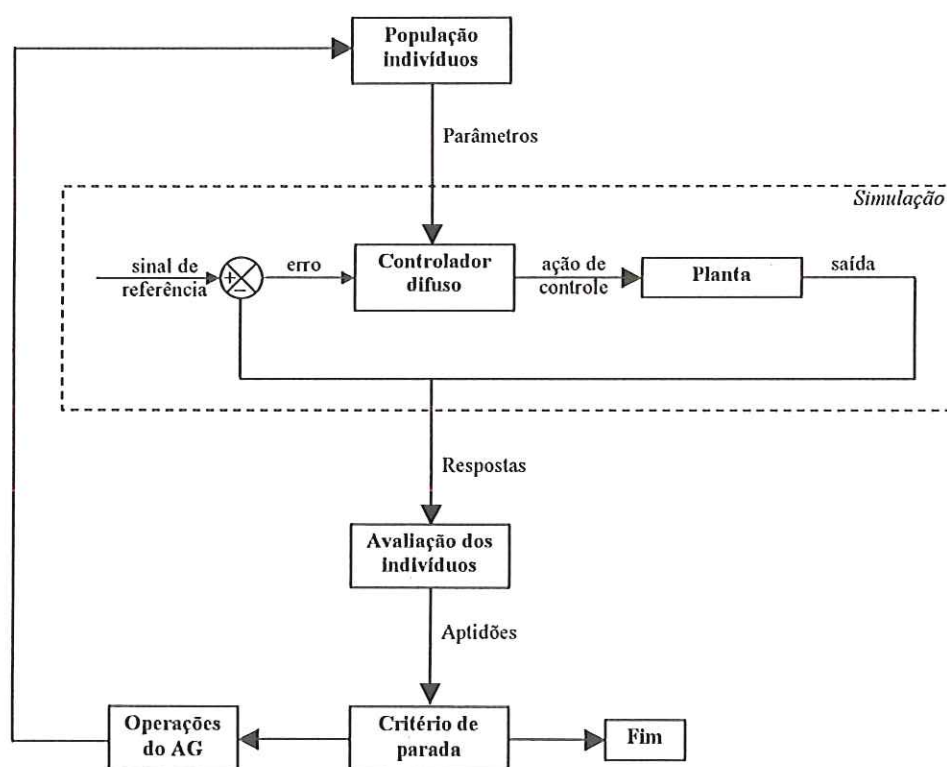


FIGURA 4.7 – Processo de otimização do controlador difuso de um sistema dinâmico.

#### **4.4 – Sumário**

Este Capítulo apresenta os fundamentos teóricos de algoritmos genéticos para emprego em otimização de sistemas dinâmicos. São mostradas as partes que o compõem, compreendendo a codificação dos indivíduos, inicialização da população inicial, avaliação dos indivíduos, diferentes métodos de seleção para reprodução e operadores genéticos (recombinação e mutação). São considerados também o método elitista de seleção e algumas considerações sobre critérios de seleção e desempenho. É descrito o processo de uso do AG para otimização dos controladores difusos, para ajuste do ganhos de controle e das funções de pertinência.

## CAPÍTULO 5

### PROJETO DE CONTROLADOR DIFUSO PARA ESTRUTURA INTELIGENTE

#### 5.1 – Introdução

Este Capítulo apresenta as características empregadas no projeto de um controlador difuso para redução de vibrações do modelo da viga ativa e as condições de otimização do controlador por algoritmos genéticos (AG).

São apresentadas as características e propriedades empregadas na modelagem obtida por NAGAMINE (2001) em uma viga de alumínio com atuadores piezelétricos colados. São apresentados os projetos dos controladores difusos baseados na estratégia de controle PD, sendo tratados os modelos difusos de Mamdani e Takagi-Sugeno-Kang (TSK), mostrando suas bases de conhecimento e de regras.

Diferentes formas de ajuste do controlador difuso são consideradas. Primeiramente ajustam-se os ganhos do controlador obtido por NAGAMINE (2001) (sendo tratado aqui como controlador manual). Depois ajustam-se as funções de pertinência do controlador manual. Em seguida ajustam-se as funções de pertinência, considerando-se os ganhos obtidos pelo AG no primeiro caso. Por último, ajusta-se os ganhos e as funções de pertinência simultaneamente. Definem-se os parâmetros de otimização empregados pelo AG com elitismo e as condições de simulação do modelo.

Resultados da otimização, respostas do sistema de controle para diferentes entradas e discussões dos resultados são apresentados. São apresentadas



também as superfícies de decisão dos controladores difusos obtidos e realizados alguns testes para verificação do desempenho e da robustez do AG.

## 5.2 – Modelo de viga ativa

A Figura 5.1 ilustra o esquema do sistema de controle em malha fechada para redução de vibrações da viga inteligente utilizada por NAGAMINE (2001). A viga é considerada engastada e composta por uma estrutura principal de alumínio, cujas características estão na Tabela 5.1.

TABELA 5.1 – Dimensões e características da viga de alumínio.

Dimensões da viga [mm]	500 × 50,8 × 3,18
Rigidez elástica [GPa]	68
Densidade [kg/m <sup>3</sup> ]	2741

Os coeficientes para o cálculo do amortecimento de Rayleigh são escolhidos como sendo  $\alpha = 0,59$  e  $\beta = 0,0006$ .




FIGURA 5.1 – Esquema do controle em malha fechada da viga inteligente (NAGAMINE, 2001).

A viga contém dois pares de atuadores piezelétricos colados em faces opostas da estrutura principal, posicionados a 20 mm e 100 mm a partir do engaste. As características e dimensões dos atuadores piezelétricos são dadas na Tabela 5.2.

TABELA 5.2 – Dimensões e características dos atuadores piezelétricos.

dimensões dos atuadores [mm]	63 × 31,8 × 0,51
rigidez elástica [GPa]	63
densidade [kg/m <sup>3</sup> ]	7750
constante de deformação piezelétrica [pm/V]	-190
permissividade dielétrica [nF/m]	15,93

O modelo da viga é obtido pelo método dos elementos finitos com discretização de 25 elementos, de acordo com o descrito no Capítulo 2. É utilizado o modelo reduzido com 10 modos mantidos.

Para uma aplicação experimental, pode-se utilizar um acelerômetro com o sensor de deslocamento em determinadas partes da viga. Neste trabalho tal condição é conseguida através da simulação do modelo tomando-se o deslocamento na ponta livre da viga.

### 5.3 – Estrutura do controlador difuso

Adota-se o controlador difuso do tipo PD para redução da vibração da viga devido a sua capacidade de melhorar a resposta transiente. A Figura 5.2 mostra o esquema utilizado, onde o controlador difuso recebe como entradas o erro  $e$  e a variação do erro  $\Delta e$ , fornecendo a ação de controle  $u$ .

O erro é definido como a diferença entre a posição de referência  $y_{ref}$  (que neste caso é zero) e o deslocamento na ponta da viga  $y(n)$  no tempo corrente  $n$ , ou seja:

$$e(n) = y_{ref} - y(n) \quad (5.1)$$

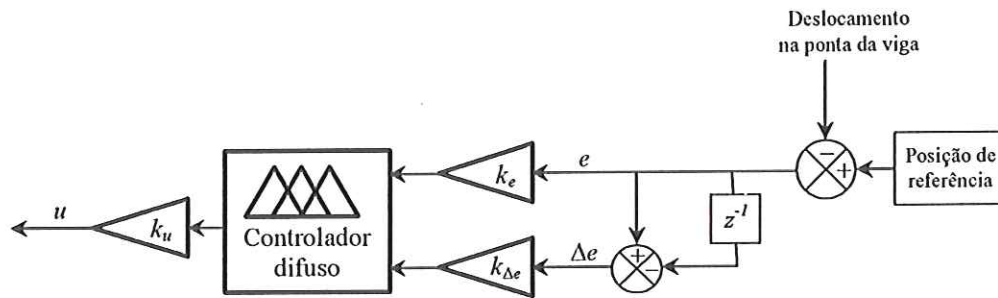


FIGURA 5.2 – Esquema do controle difuso tipo PD.

A **base de conhecimento** é representada por conjuntos difusos, adjetivados pelas variáveis lingüísticas negativo grande (NG), negativo pequeno (NP), quase zero (Z), positivo pequeno (PP) e positivo grande (PG). Os formatos das funções de pertinência são trapezoidais para as variáveis NG e PG e triangulares para as demais. Para o modelo de Mamdani os conjuntos difusos referentes às variáveis de entrada (erro e variação do erro) e saída (ação de controle) são normalizadas no intervalo  $[-1, 1]$ .

No modelo TSK as entradas são as mesmas que no modelo Mamdani, porém a saída é baseada na Equação (3.32), sendo os coeficientes de ponderação definidos de acordo com a Tabela 5.3.

TABELA 5.3 – Coeficientes do modelo TSK.

coef. \ $u$	NG	NP	Z	PP	PG
$a_0$	0	0	0	0	0
$a_1$	1	1	1	1	1
$a_2$	1	1	1	1	1

A Tabela 5.4 mostra a **base de regras** empregada no controlador difuso tipo PD, sendo empregada de acordo com a Equação (3.3), onde a premissa é representada pelos sinais de erro e variação do erro, ligados pelo conectivo lógico E a conclusão corresponde à ação de controle. Esta base de regras é obtida da base sugerida por MacVicar-Whelan (YAGER & FILEV, 1994). Neste projeto foi

considerada a mesma base de regras para os modelos Mamdani e TSK. O método de dedifusão empregado é o do centróide (ver Equação (3.19)).

TABELA 5.4 – Base de regras do controlador difuso.

$e \backslash \Delta e$	NG	NP	Z	PP	PG
NG	NG	NG	NP	NP	Z
NP	NG	NG	NP	Z	PP
Z	NP	Z	Z	Z	PP
PP	NP	Z	PP	PG	PG
PG	Z	PP	PP	PG	PG

#### 5.4 – Estrutura e parâmetros do algoritmo genético

Tendo-se a estrutura inteligente definida como a viga ativa e o controlador difuso com estratégia PD considerados, o passo inicial no emprego do algoritmo genético é a identificação e codificação dos parâmetros do controlador a serem ajustados. Considera-se a otimização feita através da obtenção dos ganhos das variáveis de entrada e saída do controlador difuso, ou seja, os ganhos dos sinais de entrada (erro  $k_e$  e variação do erro  $k_{\Delta e}$ ) e do sinal de saída (ação de controle  $k_u$ ), conforme mostrado na Figura 5.2. Os indivíduos da população apresentam cromossomos contendo as variáveis a serem ajustadas, ou seja,  $[k_e \ k_{\Delta e} \ k_u]$ . Os intervalos de ajuste dos ganhos foram definidos observando-se as simulações do sistema de acordo com conhecimento prévio dos limites de operação da viga. Os valores dos intervalos encontrados foram  $k_e = [0, 10^5]$ ,  $k_{\Delta e} = [0, 10^4]$  e  $k_u = [0, 100]$  para o controlador TSK e  $k_e = [0, 10^3]$ ,  $k_{\Delta e} = [0, 5 \times 10^5]$  e  $k_u = [0, 100]$  para o controlador Mamdani.

Considerando-se a obtenção e otimização dos suportes dos conjuntos difusos do controlador difuso pelo AG (como na seção 4.3.2), os indivíduos da população apresentam cromossomos contendo as posições dos suportes das funções de pertinência a serem ajustadas, ou seja,  $[P_1 \ P_2 \ \dots \ P_5]$ , como mostra a Figura 5.3,



sendo que as funções são simétricas. Foram adotadas algumas restrições para os pontos de ajustes, para que não fossem gerados conjuntos difusos inadequados para o controle, conforme descrito na seção 4.3.2.




FIGURA 5.3 – Funções de pertinência com suportes ajustáveis.

Adotou-se a codificação binária para a formação dos cromossomos dos indivíduos da população, pois segundo Goldberg (1989) esta codificação aumenta o espaço de busca da solução do problema e facilita nas operações de reprodução. O tamanho dos cromossomos depende da precisão adotada para cada variável do controlador, de acordo com a Equação (4.1). Para os ganhos do controlador TSK, considerando-se os limites de operação dos ganhos definidos anteriormente e com um espaçamento máximo (discretização) de 1 unidade, o total de genes é de 20 para o erro, 20 para a variação do erro e 7 para a ação de controle, totalizando 47 genes, conforme ilustrado na Figura 5.4. Para os ganhos do controlador Mamdani, o total de genes é 10 para o erro, 19 para a variação do erro e 7 para a ação de controle, o que resulta em um cromossomo com 36 genes.

$$\underbrace{100\dots100}_{k_e} \quad \underbrace{010\dots001}_{k_{\Delta e}} \quad \underbrace{01\dots11}_{k_u}$$

FIGURA 5.4 – Cromossomo representando os ganhos de controle (controlador TSK).

Para os indivíduos representando os suportes das funções de pertinência a serem ajustados, considera-se um espaçamento máximo de 5 dígitos binários. Para funções de pertinência simétricas (de acordo com a Figura 5.3), e como são 5 pontos a serem ajustados, totalizam 25 genes para cada variável. Portanto, para o controlador Mamdani, os cromossomos possuem 75 genes, como exemplificado na Figura 5.5 e para o controlador TSK os cromossomos possuem 50 genes.




FIGURA 5.5 – Cromossomo representando os parâmetros das funções de pertinência (controlador Mamdani).

No processo de obtenção simultânea dos ganhos e das funções de pertinência, os indivíduos possuem cromossomos com partes representando os ganhos e partes representando os parâmetros de ajustes dos suportes das funções de pertinência, como exemplificado na Figura 5.6.




FIGURA 5.6 – Cromossomo representando os ganhos de controle e os parâmetros das funções de pertinência (controlador Mamdani).

Adotou-se o método da roda de roleta para a seleção de indivíduos. Foi considerado para todos os casos de otimização um indivíduo pertencente à elite. Outros parâmetros do algoritmo genético, tais como número máximo de gerações, número de indivíduos da população, probabilidade para ocorrência de *crossover*,

número de pontos de *crossover* e probabilidade para mutação foram considerados individualmente para cada caso.

O desempenho do ajuste é calculado através da minimização do tempo de acomodação, do sobre-sinal e do erro de regime da resposta da saída do sistema. Este cálculo é feito implicitamente através da soma dos erros quadráticos (baseada na Equação (4.3)), onde sua inversa corresponde à função aptidão (Equação (5.2)). Os melhores indivíduos são aqueles que tiverem melhor desempenho, pois se trata da maximização da função aptidão. Sendo o erro dado em metros ( $m$ ), a unidade da função de aptidão corresponde ao inverso do quadrado do erro, ou seja,  $[1/m^2]$ .

$$f_i^g = \frac{1}{\sum_{n=1}^N (e_i(n))^2} \quad (5.2)$$

Para as simulações durante o processo de otimização dos controladores do tipo Mamdani e TSK foram considerados uma discretização do tempo de 0,001 s e um tempo de simulação de 0,5 s, pois nas respostas ao degrau obtidas por NAGAMINE (2001) o tempo de estabilização foi de aproximadamente 0,4 s. O sinal de distúrbio aplicado foi uma força degrau de 0,01 N aplicada na ponta livre da viga durante a simulação. O sinal de referência para o controlador difuso é zero, tratando-se de um regulador, onde se deve reduzir a vibração da viga ativa proveniente de distúrbios externos.

## 5.5 – Resultados e discussões

Os resultados dos diferentes tipos de ajuste dos controladores difusos com o algoritmo genético, comparados com os resultados obtidos manualmente por NAGAMINE (2001) são mostrados aqui. Na seção 5.5.1 consideram-se os controladores Mamdani e TSK obtidos manualmente, com as mesmas bases de conhecimento e de regras, e otimizam-se os ganhos pelo AG. É feita a comparação deste com o controlador manual e a resposta do sistema em malha aberta. A seção



5.5.2 considera o controlador Mamdani com os ganhos obtidos manualmente e otimiza as funções de pertinência. A comparação deste com o controlador manual e o controlador com ganho obtido pelo AG também é realizada. A seção 5.5.3 considera o controlador Mamdani com os ganhos obtidos pelo AG e otimizam-se as funções de pertinência. É feita a comparação deste com o controlador manual, o controlador com ganho obtido pelo AG e o controlador com ganho manual e funções de pertinência obtidas pelo AG. A seção 5.5.4 mostra os controladores difusos Mamdani e TSK com ajuste automático dos ganhos e dos suportes das funções de pertinência simultaneamente, comparando estes com os controladores obtidos manualmente e pelo AG.

### 5.5.1 – Controlador difuso com ganhos ajustados manualmente e ganhos ajustados pelo AG

Para verificação do método de otimização por algoritmos genéticos utilizou-se o mesmo controlador difuso desenvolvido por NAGAMINE (2001), onde os suportes das funções de pertinência das variáveis de entradas e saída do controlador são ajustados manualmente, de acordo com conhecimento prévio e intuitivo da dinâmica da planta. Para o modelo de Mamdani as entradas (erro e variação do erro) e saída (ação de controle) são mostradas nas Figuras 5.7 a 5.9, respectivamente, considerando-se as bases normalizadas.

Os ganhos do controlador são ajustados pelo AG considerando-se valores usuais encontrados na literatura para os seguintes parâmetros listados na Tabela 5.5.

TABELA 5.5 – Parâmetros do algoritmo genético.

Número máximo de gerações	30
Número de indivíduos na população	30
probabilidade para ocorrência de <i>crossover</i>	67%
Número de pontos de <i>crossover</i>	1
probabilidade para mutação	2%

A evolução dos indivíduos ao longo das gerações para o modelo difuso de TSK está ilustrada na Figura 5.10, onde é mostrada a evolução da aptidão



máxima, mínima e média da população em cada geração. As aptidões máxima e mínima correspondem às aptidões do melhor e pior indivíduos, respectivamente. A aptidão média corresponde à media da soma das aptidões de todos os indivíduos da população.




FIGURA 5.7 – Funções de pertinência do erro (NAGAMINE, 2001).




FIGURA 5.8 – Funções de pertinência da variação do erro (NAGAMINE, 2001).




FIGURA 5.9 – Funções de pertinência da ação de controle (NAGAMINE, 2001).




FIGURA 5.10 – Evolução da aptidão no modelo TSK.

Pode-se observar na Figura 5.10 o crescimento da aptidão máxima, sendo esta representada e mantida pelo grupo de elite. Verifica-se também o crescimento da

aptidão média, mostrando que os indivíduos estão distribuídos de maneira satisfatória a não gerar muitos indivíduos com baixa aptidão. A aptidão mínima se manteve em uma mesma margem, provavelmente, devido às ocorrências de mutações e *crossover*, que foram 562 e 298, respectivamente, gerando indivíduos com baixa aptidão. O número de mutações ocorridas excedeu o número de *crossover* devido ao tamanho dos cromossomos, pois com cromossomos menores, o número de mutações seria menor. A Tabela 5.6 mostra os ganhos obtidos na otimização para o controlador TSK, e compara-os com os ganhos obtidos manualmente por NAGAMINE (2001).

TABELA 5.6 – Ganhos do controlador TSK.

ajuste ganho	manual	AG
$k_e$	$95 \times 10^3$	$135 \times 10^3$
$k_{\Delta e}$	$4 \times 10^5$	$5,67 \times 10^5$
$k_u$	8	5,5

A resposta da viga ativa com controlador difuso ajustado por AG, para uma força degrau de 0,01 *N* está mostrada na Figura 5.11. Compara-se com a resposta da viga ativa com controlador manual e com a resposta sem sinal de controle (malha aberta). Observa-se uma melhora no tempo de estabilização em torno de 50%, porém, o erro de regime e sobre-sinal mantiveram-se próximos do ajustado manualmente. A Figura 5.12 mostra o erro, a variação do erro e o sinal de controle na entrada dos atuadores, para o sistema com o controlador ajustado automaticamente para o caso da resposta mostrada na Figura 5.11.

Para uma força degrau duplo, sendo 0,01 *N* até 0,5 *s* e depois um degrau de 0,005 *N* até 1 *s* (como mostra a Figura 5.13), a resposta do sistema é mostrada na Figura 5.14. A Figura 5.15 mostra o erro, a variação do erro e o sinal de controle dos atuadores, para a entrada degrau duplo.




FIGURA 5.11 – Deslocamento da ponta livre da viga para uma entrada degrau.




FIGURA 5.12 – Erro, variação do erro e sinal de controle nos atuadores para entrada degrau.






FIGURA 5.13 – Entrada degrau duplo.




FIGURA 5.14 – Deslocamento da ponta livre da viga para uma entrada degrau duplo.




FIGURA 5.15 – Erro, variação do erro e sinal de controle nos atuadores para entrada degrau duplo.

A evolução dos indivíduos ao longo das gerações para o modelo difuso Mamdani está ilustrada na Figura 5.16, onde é mostrada a evolução da aptidão máxima, mínima e média da população em cada geração. Como para o caso anterior do modelo difuso TSK, observa-se o crescimento da aptidão máxima, sendo esta representada e mantida pelo grupo de elite. Verifica-se também o crescimento da aptidão média e variações abruptas da aptidão mínima. O número de mutações e *crossover* ocorridos foi 493 e 310, respectivamente. Novamente o número de mutações ocorridas excedeu o número de *crossover* devido ao tamanho dos cromossomos. A Tabela 5.7 mostra os ganhos obtidos na otimização para o controlador Mamdani e compara-os com os ganhos obtidos manualmente.

TABELA 5.7 – Ganhos do controlador Mamdani.

ajuste ganho	manual	AG
$k_e$	600	984
$k_{\Delta e}$	$2 \times 10^5$	$0,22 \times 10^5$
$k_u$	80	86,6

A resposta da viga ativa com controlador Mamdani ajustado por AG, para uma força degrau de  $0,01 N$  está representada na Figura 5.17, comparada com a resposta obtida da viga com controlador manual e com o sistema em malha aberta.

Observa-se na Figura 5.17 uma diminuição do sobre-sinal, porém o sinal continua com uma oscilação devido à vibração residual induzida pelo controlador Mamdani (NAGAMINE, 2001). O erro de regime manteve-se aproximadamente o mesmo. A Figura 5.18 ilustra o erro, a variação do erro e o sinal de controle nos atuadores para a entrada degrau. A Figura 5.19 mostra a resposta para a entrada degrau duplo da Figura 5.13 e a Figura 5.20 mostra o erro, variação do erro e a ação de controle obtida nos atuadores.




FIGURA 5.16 – Evolução da aptidão no modelo Mamdani.




FIGURA 5.17 – Deslocamento da ponta livre da viga para uma entrada degrau.




FIGURA 5.18 – Erro, variação do erro e sinal de controle nos atuadores para entrada degrau.






FIGURA 5.19 – Deslocamento da ponta livre da viga para uma entrada degrau duplo.




FIGURA 5.20 – Erro, variação do erro e sinal de controle nos atuadores para entrada degrau duplo.

### 5.5.2 – Controlador difuso com ganhos ajustados manualmente e funções de pertinência ajustadas pelo AG

Para comparação com os controladores com ganhos obtidos manualmente e pelo AG, obteve-se através do AG as funções de pertinência do controlador difuso tipo Mamdani com ganho manual. Os parâmetros do AG estão mostrados na Tabela 5.8.

TABELA 5.8 – Parâmetros do algoritmo genético.

número máximo de gerações	30
número de indivíduos na população	50
Probabilidade para ocorrência de <i>crossover</i>	65%
número de pontos de <i>crossover</i>	2
Probabilidade para mutação	3%

Os pontos de ajuste dos conjuntos difusos estão mostrados na Figura 5.21, sendo as funções não simétricas e representados pelo cromossomo da Figura 5.22.




FIGURA 5.21 – Exemplo de modificação das funções de pertinência não simétricas.




FIGURA 5.22 – Cromossomo representando os parâmetros das funções de pertinência (controlador Mamdani).

Os ganhos utilizados foram os ganhos obtidos pelo AG para o controlador Mamdani da seção 5.5.1, ou seja,  $k_e = 600$ ,  $k_{\Delta e} = 2 \times 10^5$  e  $k_u = 80$ .

A Figura 5.23 mostra a evolução da aptidão ao longo das gerações. A Figura 5.24 mostra as funções de pertinência obtidas para o melhor indivíduo e a Figura 5.25 mostra a resposta no tempo para uma força de entrada degrau de  $0,01 N$ , comparada com a resposta do controlador obtido na seção 5.5.1. A Figura 5.26 mostra o erro, variação do erro e a ação de controle obtida nos atuadores.




FIGURA 5.23 – Evolução da aptidão no modelo Mamdani.

Observa-se na Figura 5.25 que em relação às respostas dos controladores com ganhos ajustados manualmente e ajustados pelo AG, o ajuste das funções de pertinência permite eliminação da oscilação presente no sinal em regime permanente, apesar de manter o mesmo sobre-sinal e o mesmo tempo de estabilização.

Para o controlador TSK obtido na seção 5.5.1, o ajuste das funções de pertinência não surtiram efeitos nos sinais de resposta, não fazendo sentido apresentar tais resultados.




FIGURA 5.24 – Funções de pertinência ajustadas pelo AG (controlador com ganhos manuais).




FIGURA 5.25 – Resposta para o controlador com ajuste das funções de pertinência (ganhos manuais), comparada com o controlador obtido manualmente.






FIGURA 5.26 – Erro, variação do erro e sinal de controle nos atuadores para o controlador Mamdani.

### 5.5.3 – Controlador difuso com ganhos e funções de pertinência ajustados separadamente pelo AG

Seguindo-se o mesmo procedimento da seção anterior, fez-se o ajuste das funções de pertinência do controlador difuso obtido pela otimização automática dos ganhos, ou seja, os controladores obtidos pelo AG na seção 5.5.1. Para o controlador difuso tipo Mamdani, utilizou-se os parâmetros do AG mostrados na Tabela 5.9.

TABELA 5.9 – Parâmetros do algoritmo genético.

número máximo de gerações	30
número de indivíduos na população	50
probabilidade para ocorrência de <i>crossover</i>	65%
número de pontos de <i>crossover</i>	2
probabilidade para mutação	3%

Os ganhos utilizados foram os ganhos obtidos pelo AG para o controlador Mamdani da seção 5.5.1, ou seja,  $k_e = 984$ ,  $k_{\Delta e} = 0,22 \times 10^5$  e  $k_u = 86,6$ .

A Figura 5.27 mostra a evolução da aptidão ao longo das gerações. A Figura 5.28 mostra as funções de pertinência obtidas pelo melhor indivíduo e a Figura 5.29 mostra a resposta no tempo para uma entrada degrau de  $0,01 N$ , comparada com a resposta do controlador obtido na seção 5.5.1. A Figura 5.30 mostra o erro, variação do erro e a ação de controle obtida nos atuadores.




FIGURA 5.27 – Evolução da aptidão no modelo Mamdani.

Observa-se na Figura 5.29 uma sensível melhora do controlador com ganhos e funções de pertinência ajustados pelo AG, em relação aos controladores com ganhos ajustados manualmente e pelo AG, pois há a eliminação da oscilação presente no sinal em regime permanente. Porém, em relação ao controlador com ganhos manuais e funções de pertinência otimizadas, há um aumento do erro de regime e do tempo de estabilização, mas mantém o mesmo sobre-sinal.

Para o controlador TSK obtido na seção 5.5.1, o ajuste das funções de pertinência também não surtiram efeitos nos sinais de resposta.




FIGURA 5.28 – Funções de pertinência ajustadas pelo AG (ganhos otimizados).




FIGURA 5.29 – Resposta para o controlador com ganhos obtidos pelo AG e ajuste das funções de pertinência (ganhos manuais e otimizados), comparada com o controlador obtido manualmente.




FIGURA 5.30 – Erro, variação do erro e sinal de controle nos atuadores para o controlador Mamdani.

#### 5.5.4 – Controlador difuso com ganhos e funções de pertinência ajustados simultaneamente pelo AG

Utilizou-se o AG para obter simultaneamente os ganhos e os suportes das funções de pertinência. Para otimização do controlador TSK, a codificação dos indivíduos passa a ser a união das codificações apresentadas na seção 5.4, ou seja, o indivíduo é representado pelo vetor de valores  $[k_e \ k_{\Delta e} \ k_u \ P]$ , sendo  $P = [P_1 \dots P_5 \ P_1 \dots P_5]$ , os pontos de ajustes das funções de pertinência das variáveis do erro e variação do erro, respectivamente. O cromossomo possui, portanto, 122 genes. Os parâmetros utilizados no AG estão mostrados na Tabela 5.10.

TABELA 5.10 – Parâmetros do algoritmo genético.

número máximo de gerações	30
número de indivíduos na população	30
probabilidade para ocorrência de <i>crossover</i>	65%
número de pontos de <i>crossover</i>	2
probabilidade para mutação	3%



A Figura 5.31 mostra a evolução da aptidão ao longo das gerações. A Figura 5.32 mostra as funções de pertinência obtidas pelo melhor indivíduo e a Figura 5.33 mostra a resposta no tempo para uma força de entrada degrau de  $0,01 N$ , comparada com a resposta do controlador obtido na seção 5.5.1. A Figura 5.34 mostra o erro, variação do erro e a ação de controle obtida nos atuadores.

Os ganhos obtidos na otimização, comparados com os casos da seção 5.5.1, estão mostrados na Tabela 5.11.

TABELA 5.11 – Ganhos do controlador TSK.

ajuste ganho	manual	AG (só ganhos)	AG (ganhos e suportes)
$k_e$	$95 \times 10^3$	$135 \times 10^3$	$2,95 \times 10^4$
$k_{\Delta e}$	$4 \times 10^5$	$5,67 \times 10^5$	$7,57 \times 10^4$
$k_u$	8	5,5	31,4




FIGURA 5.31 – Evolução da aptidão no modelo TSK.




FIGURA 5.32 – Funções de pertinência ajustadas pelo AG (ajuste simultâneo dos ganhos).




FIGURA 5.33 – Resposta para o controlador TSK com ganhos e funções de pertinência obtidos simultaneamente pelo AG, comparada com o controlador obtido manualmente.




FIGURA 5.34 – Erro, variação do erro e sinal de controle nos atuadores para o controlador TSK.

Observa-se que há uma melhora na resposta do controlador quando os ganhos e as funções de pertinência são ajustados automaticamente, sendo reduzido o erro de regime, o tempo de estabilização e o sobre-sinal.

Para o controlador do tipo Mamdani, os parâmetros do AG foram os mesmos que o anterior, porém, os indivíduos são representados pelo vetor de valores  $[k_e k_{\Delta e} k_u P]$ , sendo  $P = [P_1 \dots P_5 P_1 \dots P_5 P_1 \dots P_5]$ , os pontos de ajustes das funções de pertinência das variáveis do erro, da variação do erro e ação de controle.

A Figura 5.35 mostra a evolução da aptidão ao longo das gerações. A Figura 5.36 mostra as funções de pertinência obtidas pelo melhor indivíduo e a Figura 5.37 mostra a resposta no tempo para uma entrada degrau de  $0,01 N$ , comparada com a resposta do controlador obtido na seção 5.5.1. A Figura 5.38 mostra o erro, variação do erro e a ação de controle obtida nos atuadores. Os parâmetros utilizados no AG estão mostrados na Tabela 5.12. Os ganhos obtidos na otimização, comparados com os casos da seção 5.51, estão mostrados na Tabela 5.13.

TABELA 5.12 – Parâmetros do algoritmo genético.

número máximo de gerações	30
número de indivíduos na população	30
probabilidade para ocorrência de <i>crossover</i>	65%
número de pontos de <i>crossover</i>	2
probabilidade para mutação	3%

TABELA 5.13 – Ganhos do controlador Mamdani.

ajuste ganho	manual	AG (só ganhos)	AG (ganhos e suportess)
$k_e$	600	984	$1,67 \times 10^5$
$k_{\Delta e}$	$2 \times 10^5$	$0,22 \times 10^5$	$8,16 \times 10^4$
$k_u$	80	86,6	19,9

Neste caso também se observa uma melhora na resposta do controlador quando os ganhos e as funções de pertinência são ajustados automaticamente, sendo reduzidos o erro de regime, o tempo de estabilização e o sobre-sinal. Observa-se também a eliminação da oscilação do sinal de regime.




FIGURA 5.35 – Evolução da aptidão no modelo Mamdani.






FIGURA 5.36 – Funções de pertinência ajustadas pelo AG (ajuste simultâneo dos ganhos).




FIGURA 5.37 – Resposta para o controlador Mamdani com ganhos e funções de pertinência obtidos simultaneamente pelo AG, comparada com o controlador obtido manualmente.






FIGURA 5.38 – Erro, variação do erro e sinal de controle nos atuadores para o controlador Mamdani.

### 5.5.5 – Superfícies de decisão dos controladores difusos


As Figuras 5.39 (a) a (e) ilustram as superfícies de decisão dos controladores difusos obtidos. A Figura 5.39(a) mostra a superfície de decisão do controlador TSK para todos os casos obtidos. Esta superfície é igual para todos os casos, pois possui a saída como função linear das entradas. Na seqüência (Figura 5.39(b)) temos as superfícies de decisão do controlador Mamdani obtido manualmente, controlador Mamdani com ganhos manuais e suportes dos conjuntos difusos ajustados pelo AG (Figura 5.39(c)), controlador Mamdani com ganhos e suportes dos conjuntos difusos ajustados separadamente pelo AG (Figura 5.39(d)), e controlador Mamdani com ganhos e suportes dos conjuntos difusos ajustados simultaneamente pelo AG (Figura 5.39(e)).




(a) Controladores TSK



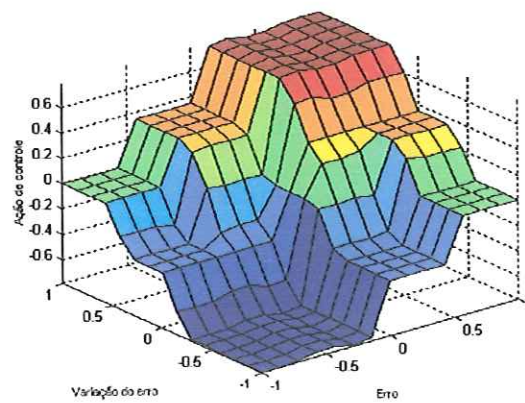
(b) Controlador Mamdani com ganhos manuais



(c) Controlador Mamdani com ganhos manuais e funções de pertinência ajustadas pelo AG



(d) Controlador Mamdani com ganhos e funções de pertinência ajustados separadamente pelo AG



(e) Controlador Mamdani com ganhos e funções de pertinência ajustados simultaneamente pelo AG

FIGURA 5.39 – Superfícies de decisão dos controladores difusos obtidos.



Como se pode observar pelas superfícies de decisão dos controladores Mamdani, nota-se que os controladores com as funções de pertinência ajustadas pelo AG possuem uma pequena suavização em relação à superfície do controlador obtido manualmente. Para o controlador com ganhos e funções de pertinência ajustados pelo AG, nota-se também uma tendência para deixar a superfície mais próxima da superfície plana, pois apresentou alguns patamares a mais que as superfícies dos controladores anteriores.

## 5.6 – Verificação do desempenho do algoritmo genético

Para verificação do desempenho do AG executou-se 12 testes de otimização para o caso da seção 5.5.1. Todos os testes foram executados com os mesmos parâmetros de simulação e do algoritmo genético, variando-se apenas as populações iniciais.

A Figura 5.40 ilustra os erros de regime e os tempos de estabilização das respostas dos melhores indivíduos obtidos para cada teste. A Figura 5.41 ilustra os ganhos dos melhores indivíduos obtidos para cada teste.




FIGURA 5.40 – Características de resposta, onde  $e_{ss}$  é o erro em estado de regime permanente e  $t_{ss}$  é o tempo de estabilização.



Observando-se a Figura 5.40 vemos que os melhores indivíduos obtidos em cada teste possuem parâmetros que geram respostas no tempo aproximadamente iguais, ou seja, o AG tende a obter indivíduos com o mesmo valor de aptidão, apresentando sinais de resposta com o mesmo erro de regime e tempos de estabilização e valor de sobre-sinais aproximadamente iguais. Isto mostra que o AG possui boa robustez, partindo-se de situações diferentes (população inicial diferente) e chegando-se a situações próximas.

Na Figura 5.41 observa-se que os ganhos são diferentes para os indivíduos obtidos nos diferentes testes, mostrando que os ganhos possuem uma certa relação entre si. Assim sendo, diferentes combinações dos valores dos ganhos podem gerar respostas idênticas, mantendo assim uma certa analogia com controladores PID convencionais.




FIGURA 5.41 – Ganhos obtidos para casos com populações iniciais diferentes.

## 5.7 – Sumário

Neste Capítulo são apresentadas as características e propriedades do modelo de uma viga de alumínio com atuadores piezelétricos colados, utilizada por NAGAMINE (2001). São apresentados os projetos dos controladores difusos tipo PD, abordados nos modelos Mamdani e Takagi-Sugeno-Kang, também utilizados por NAGAMINE (2001). São apresentadas as condições de simulação do modelo e as características e parâmetros de otimização empregados pelo algoritmo genético com elitismo. Realiza-se o ajuste dos ganhos e das funções de pertinência, em diferentes situações para o controlador difuso tipo PD, obtendo-se os resultados para comparação com o controlador ajustado manualmente. São mostradas as superfícies de decisão dos controladores difusos obtidos e é realizado também alguns testes para verificar o desempenho e a robustez do AG empregado.

## CAPÍTULO 6

### CONCLUSÕES

Este trabalho apresenta o projeto de um controlador difuso para controle de vibrações de uma estrutura inteligente através do ajuste de seus parâmetros por um algoritmo genético. O modelo matemático da estrutura foi desenvolvido por NAGAMINE (2001) o qual utiliza pares de atuadores piezelétricos colados em uma viga. Para uma comparação da otimização do controlador utilizam-se as mesmas características de simulação e o controlador difuso desenvolvido por NAGAMINE (2001), o qual é ajustado manualmente por uma processo de tentativa e erro e aborda a estratégia de controle PD, utilizando os modelos difusos de Mamdani e Takagi-Sugeno-Kang.

Para ajuste dos ganhos e/ou das funções de pertinência do controlador utiliza-se o algoritmo genético (AG) com codificação binária dos indivíduos e operador de elitismo. Os indivíduos são testados para uma simulação com entrada degrau de distúrbio e avaliados por uma função de aptidão baseada no erro quadrático, a fim de reduzir implicitamente o erro de regime, o sobre-sinal e o tempo de estabilização. A evolução dos indivíduos ocorreu de forma que os parâmetros de ajuste do controlador difuso sejam obtidos automaticamente e ajustados de acordo com a função de aptidão.

Para comparação com o controlador ajustado manualmente, obtêm-se os controladores difusos com os ganhos ajustados automaticamente. Diferentes sinais de distúrbios foram aplicados e as respostas foram comparadas com as respostas obtidas do sistema com controlador ajustado manualmente. Para o controlador TSK observa-se apenas uma melhora no tempo de estabilização, enquanto que para o controlador Mamdani observa-se uma pequena melhora não significativa do sobre-sinal e do erro

de regime, porém com um nível de oscilação semelhante ao controlador ajustado manualmente.

Os controladores obtidos manualmente são então otimizados pelo AG, modificando-se as funções de pertinência. Observa-se uma melhora da resposta do sistema com o controlador Mamdani, tendo reduzido o nível de oscilação do sinal de regime. Porém, para o controlador TSK, nenhum efeito é observado nas respostas, supostamente devido aos valores de ganhos obtidos.

Os controladores com ganhos obtidos pelo AG também são otimizados novamente, modificando-se as funções de pertinência. Como no caso anterior, observa-se uma melhora da resposta do sistema com o controlador Mamdani, tendo reduzido o nível de oscilação do sinal de regime. Porém, para o controlador TSK, novamente nenhum efeito é observado nas respostas.

O processo de ajuste simultâneo dos ganhos e das funções de pertinência dos controladores difusos fornece resultados melhores que os anteriores. Há uma melhora no sinal de resposta para o sistema com controlador TSK, comparado ao controlador com ganhos obtidos manualmente. Para o controlador Mamdani, há uma significativa diminuição do erro de regime e do sobre-sinal, porém, o tempo de estabilização mantém-se no mesmo valor.

Analisando-se as superfícies de controle dos controladores difusos obtidos nota-se uma tendência de suavização pelo processo de otimização, pois o mesmo procura obter uma relação de controle próxima do linear, a fim de minimizar a função de custo.

Realizou-se uma verificação do desempenho do AG através da otimização do sistema, variando-se apenas as populações iniciais de cada teste. Observa-se que o AG apresenta uma certa robustez, pois tende a apresentar sempre os melhores indivíduos.

Para eliminação do erro de regime, utilizando-se controladores difusos, seria necessário utilizar estratégia de controle do tipo PID. Porém, segundo YAGER & FILEV (1994), é grande a dificuldade em formular uma base de regras que envolva as três ações do controle PID, o que se constata pelo não aparecimento de literaturas relacionadas a este controlador. Este problema pode ser contornado



associando-se controladores difusos PD ou PI com ações PID convencionais, como encontrado em diversas literaturas.

CAPORALI et al. (2002) utilizam um controlador difuso tipo PID para o controle de posição de servomecanismo eletro-hidráulico. A lei de controle utiliza os sinais de erro, variação do erro e a integral de ponto do erro (pois utiliza a soma do erro atual com o erro anterior), sendo que a lei de controle proposta em YAGER & FILEV (1994) relaciona o erro, variação do erro e a somatória do erro até o tempo presente.

## 6.1 – Sugestões para trabalhos futuros

A aplicação das estratégias de controle difuso tipo PI e/ou PID são necessárias para uma melhora no desempenho do controlador, para se obter uma resposta transiente e em regime permanente satisfatórias, porém deve-se considerar as dificuldades em se empregar estes tipos de controladores difusos.

O ajuste de outros parâmetros do controlador difuso também pode ser investigado, tais como o ajuste da base de regras e dos coeficientes de ponderação da saída do modelo TSK.

Variações nos operadores do algoritmo genético também podem ser tratadas, tais como outros métodos de reprodução, operadores de recombinação e mutação e substituição da população.

Uma investigação importante a ser tratada é o uso do sensor piezelétrico, ao invés de sensores comuns, tais como acelerômetros; e o estudo do posicionamento dos elementos piezelétricos na viga, e estudo de sua influência no sistema de controle.

Podem ser investigadas também a estabilidade e robustez dos controladores difusos obtidos, a fim de obter um controlador ótimo, que promova respostas do sistema com os parâmetros desejados.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABREU, G.L.C.M.; RIBEIRO, J.F. (2001). Controle fuzzy adaptativo em estruturas inteligentes. /Apresentado à Primeira Escola Brasileira de Aplicações em Dinâmica e Controle (Aplicon), São Carlos, 2001/
- ABREU, G.L.C.M.; RIBEIRO, J.F. (2002). Optimal control design of a flexible beam containing piezoelectric elements. /Apresentado ao Congresso Brasileiro de Automática, 14., Natal, 2002/
- ARSLAN, A.; KAYA, M. (2001). Determination of fuzzy logic membership functions using genetic algorithms. *Fuzzy Sets and Systems*, v.118, p.297-306.
- BALAMURUGAN, V.; ARAYANAN, S. (2001). Shell finite elements for smart piezoelectric composite plate/shell structures and its application to the study of active vibration control. *Finite Elements in Analysis and Design*, v.37, p.713-38.
- BATHE, K.; WILSON, E.L. (1976). *Numerical methods in finite element analysis*. New Jersey, Prentice Hall.
- BARBOSA, H.J.C. (1997). Introdução aos algoritmos genéticos. In: XX Congresso Nacional de Matemática Aplicada e Computacional (CNMAC), Gramado, RS.
- BEGG, D.W.; LIU, X. (2000). On simultaneous optimization of smart structures: algorithms and examples. *Computer Methods in Applied Mechanics and Engineering*, v.184, p.25-37.
- BELO, E.M.; ROCHA, J.C.; DE MARQUI Jr., C. (2001). *A fuzzy controller for active flutter suppression*. In: IX DINAME, Florianópolis-SC, 2001. Anais. Rio de Janeiro, ABCM, p.9-14.
- BOTTOM, V.E. (1968). *The theory and design of quartz crystal units: an introduction to the basic principles of piezoelectricity and their application to the design of quartz crystal units*. Abilene, McMurry Press.

- BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDEMIR, T.B. (2000). *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro, Livros Técnicos e Científicos.
- CADY, W.G. (1946). *Piezoelectricity: an introduction to the theory and applications of electromechanical phenomena in crystals*. New York, McGraw Hill.
- CAPORALI, A.S.; NAGAMINE, R.K.; BELO, E.M; MARQUES, F.D. (2002). Controle de posição de servomecanismo eletro-hidráulico usando controle difuso. In: Congresso Nacional de Engenharia Mecânica, 2., João Pessoa, 2002.
- CASELLA, F.; LOCATELLI, A.; SCHIAVONI, N. (2002). Modeling and control for vibration suppression in a large flexible structure with jet thrusters and piezoactuators. *IEEE Transactions on Control Systems Technology*, v.10, n.4, p.589-99.
- CHEN, H.W.; CHANG, N. (1998). Water pollution control in the river basin by fuzzy genetic algorithm-based multi-objective programming modeling. *Water Science and Technology*, v.3, p.55-63.
- CHEN, S.H.; WANG, Z.D.; LIU, X.H. (1997). Active vibration control and suppression for intelligent structures. *Journal of Sound and Vibration*, v.200, n.2, p.167-177.
- CHO, S.I.; LEE, J.H. (2000). Autonomous speedsprayer using differential global positioning system, genetic algorithm and fuzzy control. *Journal of Agricultural Engineering Research*, v.76, p.111-9.
- CLOUGH, R.W.; PENZIEN, J. (1975). *Dynamics of structures*. New York, McGraw-Hill.
- CRAWLEY, E.F. (1994). Intelligent structures for aerospace: a technology overview and assessment. *AIAA Journal*, v.32, n.8, p.1689-99.
- D'AZZO, J.J.; HOUPIS, C.H. (1988). *Linear control system analysis and design: conventional and modern*. 3.ed. New York, McGraw-Hill.
- DE MARQUI Jr., C.; BENINI, G.R.; BELO, E.M. (2001). *Uma revisão histórica do fenômeno flutter*. In: Congresso Brasileiro de Engenharia Mecânica, 16., Uberlândia, 2001.
- DENOYER, K.K.; ERWIN, R.S.; NINNEMAN, R.R. (2000). Advanced smart structures flight experiments for precision spacecraft. *Acta Astronautica*, v.47, n.2-9, p.389-97.



- FALLER, W.E.; SCHRECK, S.J. (1996). Neural networks: applications and opportunities in aeronautics. *Prog. Aerospace Sci.*, v.32, p.433-56.
- FORSTER, E.E.; YANG, H.T.Y. (1998). Flutter control of wing boxes using piezoelectric actuators. *Journal of Aircraft*, v.35, n.6, p.949-57.
- GOLDBERG, D.F. (1989). *Genetic algorithms in search, optimization, and machine learning*. Reading, Mass., Addison-Wesley.
- GREWAL, A.; ZIMCIK, D.G.; LEIGH, B. (2001). Feedforward piezoelectric structural control: an application to aircraft cabin noise reduction. *Journal of Aircraft*, v.38, n.1, p.164-73.
- GUIMARÃES, F.G.; RAMALHO, M.C. (2001) *Implementação de um algoritmo genético*. Rio de Janeiro. /Relatório interno PUC-Rio/
- HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. (1996) *Neural network design*. Boston, PWS Pub. Co.
- HALLIDAY, D.; RESNICK, R. (1984). *Física 3*. 4.ed. Rio de Janeiro, Livros Técnicos e Científicos.
- HARVEY, R. (1994). *Neural network principles*. Englewood Cliffs, N.J., Prentice-Hall.
- HAYKIN, S. (1999). *Neural networks: a comprehensive foundation*. 2.ed. Upper Saddle River, N.J., Prentice Hall.
- HERRERA, F.; LOZANO, M.; VERDEGAY, J.L. (1995). *Generation fuzzy rules from examples using genetic algorithms*. /Internal Report of Universidad de Granada/
- HOFFMANN, F.; PFISTER, G. (1997). Evolutionary design of a fuzzy knowledge base for a mobile robot. *International Journal of Approximate Reasoning*, v.17, p.447-69.
- JAMSHIDI, M.; VADIEE, N.; ROSS, T. J. (1993). *Fuzzy logic and control: software and hardware applications*. Englewood Cliffs, N.J., PTR Prentice Hall.
- JHA, R.; ROWER, J. (2001). Experimental investigation of active vibration control using neural networks. *AIAA 2001-1436*.
- KIM, J.; KIM, K. (1997). Multicriteria fuzzy control using evolutionary programming. *Information Sciences*, v.103, p.71-86.



- 
- KLIR, G.J.; YUAN, B. (1995). *Fuzzy sets and fuzzy logic: theory and applications*. Upper Saddle River, N.J., Prentice Hall.
- LEE, G. (1996). System identification and control of smart structures using neural networks. *Acta Astronautica*, v.38, n.4-8, p.269-76.
- LEIPHOLZ, H.H.; ABDEL-ROHMAN, M. (1986). *Control of structures*. The Netherlands, Martinus Nijhoff Publishers.
- LIMA Jr., J.J. (1999). *Modelagem de sensores e atuadores piezelétricos com aplicações em controle ativo de estruturas*. Campinas. Tese (Doutorado) - Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas.
- LIU, X.; BEGG, D.W. (2000). On simultaneous optimization of smart structures: theory. *Computer Methods in Applied Mechanics and Engineering*, v.184, p.15-24.
- LIU, X.; ONODA, J. (1999). Controller design for vibration suppression of slewing flexible structures. *Computers & Structures*, v.70, p.119-28.
- MAGDALENA, L. (1994). Adapting the gain of an FLC with genetic algorithms. *International Journal of Approximate Reasoning*, v.11, p.1-158.
- MARQUES, F.D. (1993). *Controle de vibração em uma pá de helicóptero*. São Carlos. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.
- MARQUES, F.D.; NAGAMINE, R.K. (2001). Non-conventional control approach for intelligent structures. In: *AIAA/ ASME/ ASCE/ AHS/ ASC Structures, Struc. Dynamics, and Materials Conf. and Exhibit*, 42, Seattle, 2001. AIAA 2001-1683.
- MASATO, I.E. (2000). *Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas*. Campinas. Dissertação (Mestrado) – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas.
- MATHEW, J.; SANKAR, B.; CATTAFESTA, L. (2001). Finite element modeling of piezoelectric actuators for active flow control applications. *AIAA 2001-0300*.
- MAZZUCCO, M.; BOLZAN, A.; BARCIA, R.M.; MACHADO, R.A.F. (2000). Application of genetic algorithms to the adjustment of the supports of fuzzy sets

- in a Mamdani controller. *Brazilian Journal of Chemical Engineering*, v.17, n.4-7, 15p.
- MEIROVITCH, L. (1967). *Analytical methods in vibrations*. London, McMillan.
- MEIROVITCH, L. (1970). *Methods of analytical dynamics*. New York, McGraw-Hill.
- MICHALEWICZ, Z. (1994). *Genetic algorithms + data structures = evolution programs*. 2.ed. Berlin, Springer-Verlag.
- MING, L.; ZAILIN, G.; SHUZI, Y. (1996). Mobile robot fuzzy control optimization using genetic algorithm. *Artificial Intelligence in Engineering*, v.10, p.293-8.
- NAGAMINE, R.K. (2001). *Lógica difusa para controle não convencional de uma viga inteligente*. São Carlos. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.
- NG, K.C.; LI, Y. (1994). *Design of sophisticated fuzzy logic controllers using genetic algorithms*. /Internal Report of Department of Electronics and Electrical Engineering, University of Glasgow/
- OGATA, K. (1982). *Engenharia de controle moderno*. Rio de Janeiro, Prentice Hall.
- PACHECO, M.A.C. (1999) Algoritmos genéticos: princípios e aplicações. In: VI Congresso Internacional de Ingeniería Electrónica, Eléctrica y Sistemas, Lima, Peru, 1999.
- PATYRA, M. J.; MLYNEK, D. M. (1996). *Fuzzy logic: implementation and applications*. Chichester, John Wiley & Sons e B.G. Teubner.
- PREUMONT, A. (1997). *Vibration control of active structures*. Dordrecht, The Netherlands, Klüwer Academic Publishers.
- REAVES, M.C.; HORTA, L.G. (2001). Test cases for modeling and validation of structures with piezoelectric actuators. *AIAA 2001-1466*.
- ROSS, T.J. (1995). *Fuzzy logic with engineering applications*. New York, McGraw-Hill.
- SHAW, I.S.; SIMÕES, M.G. (1999). *Controle e modelagem fuzzy*. São Paulo, Edgard Blücher; FAPESP.
- SHEN, Y.; HOMAIFAR, A. (2001) Vibration control of flexible structures with PZT sensors and actuators. *Journal of Vibration and Control*, n.7, p.417-51.





- SOUZA, L.F.R.; GRUPPIONI, E.M.; BELO, E.M.; MARQUES, F.D. (2002). Identificação da dinâmica não linear de uma pá de helicóptero via redes neurais. In: Congresso Nacional de Engenharia Mecânica. 2., João Pessoa, 2002.
- SULEMAN, A. (2000). Adaptive composites modeling and application in panel flutter and noise suppression. *Computers & Structures*, v.76, p.365-78.
- STEVENS, B.L.; LEWIS, F.L. (1992). *Aircraft control and simulation*. New York, John Wiley & Sons.
- TARNG, Y.S.; YEH, Z.M.; NIAN, C.Y. (1996). Genetic synthesis of fuzzy logic controllers in turning. *Fuzzy Sets and Systems*, v.83, p.301-10.
- TARNG, Y.S.; NIAN, C.Y.; KAO, J.Y. (1997). Automatic synthesis of membership functions for the force control of turning operations. *Journal of Materials Processing Technology*, v.65, p.80-7.
- TEIXEIRA, R.L.; RIBEIRO, J.F. (2001). Uma metodologia de projeto de controladores híbridos inteligentes aplicada no controle ativo de vibrações mecânicas. /Apresentado à Primeira Escola Brasileira de Aplicações em Dinâmica e Controle (Aplicon), São Carlos, 2001/
- TRINDADE, M.A. (2001). Piezoatuadores em cisalhamento para controle de estruturas. /Apresentado à Primeira Escola Brasileira de Aplicações em Dinâmica e Controle (Aplicon), São Carlos, 2001/
- TÚPAC, Y.J.; PACHECO, M.A.; VELLASCO, M.; TANSCHKEIT. (1999). Geração do conjunto de regras de inferência para um controlador nebuloso usando algoritmos genéticos. In: Simpósio Brasileiro de Automação Inteligente, 4., São Paulo.
- WON, C.C.; SULLA, J.L. (1994) Application of piezoelectric devices to vibration suppression. *Journal of Guidance, Control, and Dynamics*, v.17, n.6, p.1333-8.
- WONG, C.; HER, S. (1999). A self-generating method for fuzzy system design. *Fuzzy Sets and Systems*, v.103, p.13-25.
- WONG, S.V.; HAMOUDA, A.M.S. (2000). Optimization of fuzzy rules design using genetic algorithm. *Advances in Engineering Software*, v.31, p.251-62.
- YAGER, R.R.; FILEV, D.P. (1994). *Essentials of fuzzy modeling and control*. New York, John Wiley & Sons.
- ZADEH, L.A. (1965). Fuzzy sets. *Information and Control*, v.8, p.338-53.