

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

FERNANDA MARIA MACIEL DE LIMA

**PROPOSTA DE CONTROLE NEBULOSO BASEADO EM CRITÉRIO DE ESTABILIDADE
ROBUSTA NO DOMÍNIO DO TEMPO CONTÍNUO VIA ALGORITMO GENÉTICO
MULTIOBJETIVO**

São Luís, MA
2015

FERNANDA MARIA MACIEL DE LIMA

**PROPOSTA DE CONTROLE NEBULOSO BASEADO EM CRITÉRIO DE ESTABILIDADE
ROBUSTA NO DOMÍNIO DO TEMPO CONTÍNUO VIA ALGORITMO GENÉTICO
MULTIOBJETIVO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão, para a obtenção do título de mestre em Engenharia de Eletricidade - Área de Concentração: Automação e Controle.

Orientador: Prof. Dr. Ginalber Luiz de Oliveira Serra

São Luís, MA
2015

Lima, Fernanda Maria Maciel de.

Proposta de controle nebuloso baseado em critério de estabilidade robusta no domínio do tempo contínuo via algoritmo genético multiobjetivo/
Fernanda Maria Maciel de Lima. – São Luís, 2015.

105 f.

Impresso por computador (fotocópia).

Orientador: Ginalber Luiz de Oliveira Serra.

Dissertação (Mestrado) – Universidade Federal do Maranhão, Programa de Pós-Graduação em Engenharia Elétrica, 2015.

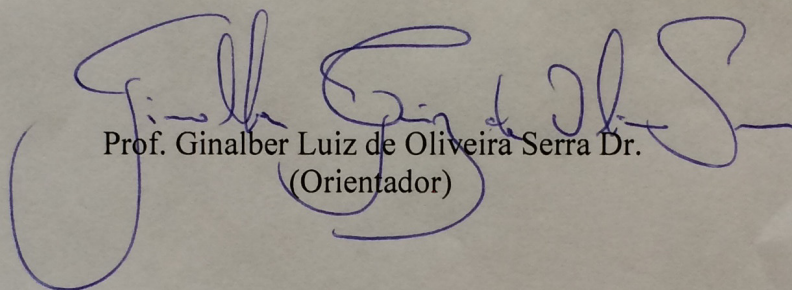
1. Controle robusto. 2. Modelagem nebulosa. 3. Agrupamento nebuloso.
4. Algoritmo genético multiobjetivo. I. Título.

CDU 62-52

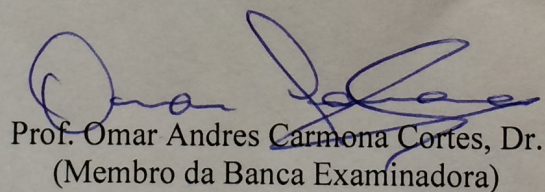
**PROPOSTA DE CONTROLE NEBULOSO BASEADO EM
CRITÉRIO DE ESTABILIDADE ROBUSTA NO DOMÍNIO DO
TEMPO CONTÍNUO VIA ALGORITMO GENÉTICO
MULTIOBJETIVO**

Fernanda Maria Maciel de Lima

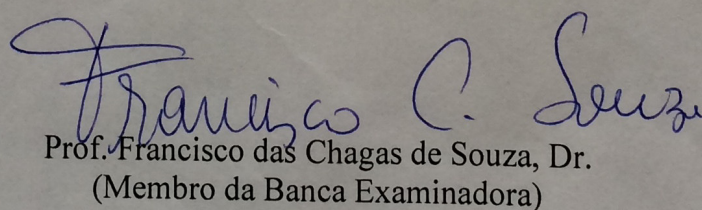
Dissertação aprovada em 31 de agosto de 2015.



Prof. Ginalber Luiz de Oliveira Serra Dr.
(Orientador)



Prof. Omar Andres Carmona Cortes, Dr.
(Membro da Banca Examinadora)



Prof. Francisco das Chagas de Souza, Dr.
(Membro da Banca Examinadora)

A DEUS por tudo e a minha família, minha base.

Agradecimentos

Agradeço, primeiramente, a Deus que em todos os momentos não me deixou faltar coragem de continuar e por está presente em minha vida e tornar tudo possível.

À Nossa Senhora que em todos os momentos de minha caminhada esteve ao meu lado.

Aos meus pais, Fernando e Ana Claudia, que são meus alicerces e que, em toda minha vida acreditaram em mim, muitas vezes quando nem eu acreditava, e me tornaram o que sou, que nunca deixaram faltar nada, principalmente com relação aos meus estudos, e que realizaram todos os tipos de esforços para que eu pudesse seguir em minha incessante busca pelo saber. Agradeço pelas horas de dedicação, pelo amor, carinho e apoio incondicionais. Mãe, seu cuidado, dedicação e horas de oração, foi que deram em muitos momentos a coragem e força de seguir. Pai, sua presença significou segurança, a certeza de que estava comigo nessa caminhada, e a me fez acreditar em momentos difíceis que tudo dará certo.

À minha irmã, Amanda, que com suas orações e do seu jeito torto me incentivou em toda caminhada.

Ao meu noivo, Mario, que, com sua postura incansável, amorosa, compreensiva me deu forças e teve paciência o tempo todo. Agradeço por cada palavra de carinho, de força e apoio incondicional, principalmente naqueles momentos mais difíceis, por acreditar em mim e tornar tudo mais simples e fácil.

A Dada, que me ajudou em muitos momentos da minha caminhada até essa conquista.

Aos meus familiares, pelo incentivo e colaboração.

Ao meu orientador, Prof. Dr. Ginalber Luiz de Oliveira Serra.

A todos os meus professores, do ensino fundamental até o superior, que me ensinaram muito do que sei hoje.

A PPGEE - UFMA por proporcionar a realização desse trabalho.

Aos colegas do ICAT (Laboratório de Inteligência Computacional Aplicada a Tecnologia) do IFMA.

Resumo

Um projeto de controle nebuloso Takagi-Sugeno(TS) com estabilidade robusta baseado nas especificações das margens de ganho e fase via algoritmo genético multiobjetivo no domínio do tempo contínuo é proposto nesta dissertação. Um algoritmo de agrupamento *Fuzzy C-Means* (FCM) é usado para estimar os parâmetros do antecedente e o número da regras de um modelo nebuloso TS, por meio dos dados experimentais de entrada e de saída da planta a ser controlada, enquanto que o algoritmo de mínimos quadrados estima os parâmetros do consequente. Uma estratégia genética multiobjetiva é definida para ajustar os parâmetros de um controlador PID nebuloso, de modo que, as margens de ganho e fase do sistema de controle nebuloso estejam próximos dos valores especificados. São propostos dois teoremas que analisam as condições necessárias e suficientes para o projeto do controlador PID nebuloso de modo a garantir a estabilidade robusta na malha de controle. O controlador PID nebuloso foi simulado no ambiente *Simulink* e comparado com compensadores de avanço e de atraso e os resultados analisados. Resultados experimentais obtidos em uma plataforma de controle, em tempo real, para validação da metodologia proposta são apresentados e comparado com controlador PID nebuloso obtido pelo método de Ziegler Nichols. Os resultados obtidos demonstram a eficácia e viabilidade prática da metodologia proposta.

Palavras-chave: Controle Robusto, Controle Nebuloso, Controle PID Nebuloso TS Robusto, Modelagem Nebulosa, Agrupamento Nebuloso, Algoritmo Genético Multiobjetivo.

Abstract

A fuzzy project Takagi-Sugeno (TS) with robust stability based on the specifications of the gain and phase margins via multi-objective genetic algorithm in continuous time domain is proposed in this master thesis. A Fuzzy C-means (FCM) clustering algorithm is used to estimate the antecedent parameters and rules number of a fuzzy TS model by means of the input and output experimental data of the plant to be controlled, while minimum squares algorithm estimate the consequent parameters. A multi-objective genetic strategy is defined to adjust the parameters of a fuzzy PID controller, so that, the gain and phase margins of the fuzzy control system are close to the specified values. Two theorems are proposed to analyse the necessary and sufficient conditions for the fuzzy PID controller design to ensure the robust stability in the close-loop control. The fuzzy PID controller was simulated in the Simulink environment and compared with lead and delay compensator. Experimental results obtained in a control platform in real time to validation the methodology proposed are presented and compared with fuzzy PID controller obtained by the Ziegler Nichols method. The results demonstrate the effectiveness and practical feasibility of the proposed methodology.

Keywords: Robust Control, Fuzzy Control, Robust Fuzzy PID TS Controller, Modelling Fuzzy, Fuzzy Clustering, Multi-objective Genetic Algorithm.

Trabalhos Publicados Pelo Autor

Artigos Publicados em Congressos

1. LIMA, F. M. M.; SERRA, G. L. O.; *Fuzzy PID Controller Multiobjective Genetic Design based on Gain and Phase Margins Specifications in Continuous Time Domain*. IEEE 16th International Conference on Industrial Technology (ICIT 2015), Spain, 2015.
2. LIMA, F. M. M.; SERRA, G. L. O.; *Fuzzy PID Controller Multiobjective Genetic Design*. IEEE 10th International Conference on Industrial Electronics and Applications (ICIEA 2015), New Zealand, 2015.
3. LIMA, F. M. M.; SERRA, G. L. O.; *Robust Fuzzy PID Controller Design for Dynamic Systems with Time Delay*. IEEE 24th International Symposium on Industrial Electronics (ISIE 2015), Rio de Janeiro, 2015.

Lista de Figuras

2.1	Representação em um diagrama de blocos de um sistema dinâmico com incerteza aditiva	10
2.2	Representação em um diagrama de blocos de um sistema dinâmico com incerteza multiplicativa	10
2.3	Diagrama de Bode com margens de ganho e fase de sistema estáveis e instáveis . . .	18
2.4	Estratégia de Compensação Paralela e Distribuída aplicada a estrutura controlador nebuloso Takagi-Sugeno	20
3.1	Diagrama sistema de controle proposto.	23
3.2	Grau de ativação para a condição de uma regra ativada	33
3.3	Grau de ativação para a condição de mais de uma regra (região intermediária)	36
3.4	Comportamento da função trigonométrica tangente	38
3.5	Esquema do método de otimização multobjetiva - soma ponderada	42
4.1	Diagrama da plataforma utilizada para supervisão e controle do processo térmico. . .	49
4.2	Dados utilizados na etapa de identificação da planta térmica. A tensão alternada, representada pelo seu valor eficaz (tensão)(a), é aplicada à planta cuja resposta temporal é a temperatura, em graus Celsius (b).	50
4.3	Funções de pertinência obtidas pelo algoritmo de agrupamento nebuloso FCM a partir dos dados experimentais de entrada e saída da planta térmica. F^1 representa o grau de ativação do submodelo para primeira regra e F^2 representa o grau de ativação do submodelo para segunda regra	51
4.4	Dados de entrada e saída para estimação do atraso puro de tempo referencia ao submodelo na primeira regra.	54
4.5	Estimação do atraso puro de tempo a partir da correlação cruzada entre os sinais de entrada e saída do processo térmico para o submodelo na primeira regra.	54
4.6	Dados de entrada e saída para estimação do atraso puro de tempo referencia ao submodelo na segunda regra.	55

4.7	Estimação do atraso puro de tempo a partir da correlação cruzada entre os sinais de entrada e saída do processo térmico para o submodelo na segunda regra.	55
4.8	Dados utilizados na etapa de validação da planta térmica. A tensão alternada, representada pelo seu valor eficaz (tensão), (a) é aplicada à planta cuja resposta temporal é a temperatura, em graus Celsius (b).	56
4.9	(a) Dados de entrada da planta térmica . (b) Comparativo entre a resposta do modelo fuzzy identificado (linha vermelha) e a saída real da planta térmica(linha azul). . . .	57
4.10	Desempenho do algoritmo genético usado para otimizar o modelo nebuloso TS da planta térmica: o melhor custo (a) e a diversidade (b).	58
4.11	Funções de pertinência obtidas pelo algoritmo de agrupamento (linha azul) e funções de pertinência obtidas pelo algoritmo genético (linha preta). F^1 representa o grau de ativação do submodelo para primeira regra e F^2 representa o grau de ativação do submodelo para segunda regra.	58
4.12	Etapa de validação: em (a) o sinal de entrada e em (b) a comparação das respostas temporal da planta térmica(linha preta), modelo nebuloso TS identificado(linha vermelha) e modelo nebuloso TS otimizado(linha azul).	59
4.13	Desempenho do algoritmo genético relacionando o melhor custo de cada indivíduo (a) e média dos custos (b) para controlador PID na primeira regra	61
4.14	Desempenho do algoritmo genético relacionando o melhor custo de cada indivíduo (a) e média dos custos (b) para controlador PID na segunda regra	62
4.15	Valores, a cada geração, dos parâmetros do controlador PID na primeira regra (K_p em (a), K_i em (b) e K_d em (c)) do melhor indivíduo obtidos pelo AG para o submodelo ($G_p^1(s)$). Na última geração os valores dos parâmetros para a melhor solução (menor custo) foram: $K_p = 199.0713$, $K_i = 0.2642$ e $K_d = 0.0311$	63
4.16	Valores, a cada geração, dos parâmetros do controlador PID na segunda regra (K_p em (a), K_i em (b) e K_d em (c)) do melhor indivíduo obtidos pelo AG para o submodelo ($G_p^2(s)$). Na última geração os valores dos parâmetros para a melhor solução (menor custo) foram: $K_p = 122.0369$, $K_i = 0.1795$ e $K_d = 0.0680$	64
4.17	Diagrama de Bode de $G_p^1(s)G_c^1(s)e^{-3.4}$. A margem de ganho é 9.1411(em módulo) e 19.2 (em dB) na frequência de cruzamento de fase, $w_p = 0.54rad/s$ e a margem de fase é 79° na frequência de cruzamento do ganho, $w_p = 0.0591rad/s$	65
4.18	Diagrama de Bode de $G_p^2(s)G_c^2(s)e^{-1.87}$. A margem de ganho é 9.0894(em módulo) e 19.2 (em dB) na frequência de cruzamento de fase, $w_p = 0.537rad/s$ e a margem de fase é 79° na frequência de cruzamento do ganho, $w_p = 0.0592rad/s$	65

4.19	Comparação entre a resposta temporal do controlador PID nebuloso TS (linha azul), compensador de avanço (linha vermelha) e compensador de atraso (linha verde). . .	68
4.20	Comportamento do controlador PID TS especificado na Tabela 4.1(linha azul)	68
4.21	Comparação entre a resposta temporal do controlador PID nebuloso TS com $MG=5$ e $MF = 30^\circ$ (linha vermelha), com $MG=5$ e $MF = 45^\circ$ (linha verde), com $MG=9$ e $MF = 79^\circ$ (linha azul) e o controlador TS Ziegler-Nichols (linha preta)	70
4.22	Comparação entre as ações de controle do PID nebuloso robusto $MG = 5$ e $MF = 30^\circ$ (linha vermelha), com $MG = 5$ e $MF = 45^\circ$ (linha verde), com $MG = 9$ e $MF = 79^\circ$ (linha azul) e o controlador TS Ziegler-Nichols (linha preta).	70
4.23	Comportamento da planta térmica em malha aberta, aplicando a perturbação no tempo de 5.7 minutos.	71
4.24	Comportamento da planta térmica em malha fechada (controlador-planta), aplicando a perturbação no tempo de 3.4 minutos e no tempo 6.8 minutos.	71
4.25	Margem de ganho (MG) e margem de fase (MF) instantâneas definidas pela ação do controlador: (a) e (b) PID nebuloso robusto proposto com com $MG = 5$ e $MF = 30^\circ$	72
4.26	Margem de ganho (MG) e margem de fase (MF) instantâneas definidas pela ação do controlador: (a) e (b) PID nebuloso robusto proposto com com $MG = 5$ e $MF = 45^\circ$	72
4.27	Margem de ganho (MG) e margem de fase (MF) instantâneas definidas pela ação do controlador: (a) e (b) PID nebuloso robusto proposto com com $MG = 9$ e $MF = 79^\circ$	73
A.1	Exemplo de um conjunto <i>crisp</i>	84
A.2	Exemplo de um conjunto nebuloso	84

Lista de Tabelas

2.1	Passos para implementação do Algoritmo FCM	16
4.1	Margem de ganho (em módulo), margem de fase (em graus) e parâmetros do controlador PID obtidos para cada submodelo.	62
4.2	Parâmetros, margem de ganho e margem de fase do controlador PID proposto, do compensador de avanço e do compensador de atraso obtido para cada submodelo.	67
4.3	Parâmetros do controlador PID e do Ziegler-Nichols e a margem de ganho e fase obtidas para cada submodelo	69

Sumário

Trabalhos Publicados Pelo Autor	vi
Lista de Figuras	vii
Lista de Tabelas	x
1 Introdução	1
1.1 Motivação	3
1.2 Objetivos	5
1.2.1 Objetivo Geral	5
1.2.2 Objetivos Específicos	5
1.3 Organização da Dissertação	5
2 Fundamentos para Controle Baseado em Modelo Nebuloso TS com Estabilidade Robusta	7
2.1 Definição e Caracterização de Sistemas Complexos	8
2.1.1 Incertezas Dinâmicas	8
2.1.2 Atraso Puro de Tempo	11
2.2 Sistema de Inferência Nebuloso Takagi-Sugeno	12
2.3 Algoritmo de Agrupamento Nebuloso	13
2.4 Margem de Ganho e Fase	16
2.5 Estratégia de Compensação Paralela e Distribuída	18
3 Metodologia de Controle Baseado em Modelo Nebuloso Takagi-Sugeno	21
3.1 Modelagem Nebulosa Takagi-Sugeno Baseada em Dados Experimentais	24
3.1.1 Estrutura do Modelo Nebuloso Takagi-Sugeno	24
3.1.2 Estimação Paramétrica do Antecedente	24
3.1.3 Estimação Paramétrica do Consequente	26

3.2	Projeto do Controlador Baseado em Modelo Nebuloso via Especificações das Margens de Ganho e Fase	28
3.2.1	Estrutura do Controlador PID Nebuloso Takagi-Sugeno	28
3.2.2	Estrutura Margens de Ganho e Fase	28
3.2.3	Análise da Estabilidade Robusta do Sistema de Controle Nebuloso	29
3.3	Estratégia Genética Multiobjetiva para Projeto de Controlador PID Nebuloso TS	41
4	Resultados Experimentais	48
4.1	Descrição da Plataforma de Controle em Tempo Real	48
4.2	Modelagem Nebulosa TS da Planta Térmica	49
4.2.1	Estimação Paramétrica e Obtenção do Modelo Nebuloso TS	50
4.2.2	Estimação do Atraso Puro de Tempo	52
4.2.3	Validação e Ajuste Fino do Modelo Nebuloso TS	56
4.3	Projeto do Controlador PID Nebuloso para Estabilidade Robusta	60
4.4	Resultados Computacionais	67
4.5	Resultados Experimentais	67
5	Conclusões	74
5.1	Propostas Futuras	75
	Referências	76
A	Considerações sobre os Sistemas Nebulosos	83
A.1	Conjuntos Nebulosos	83
A.2	Definições Básicas	85
A.2.1	Centro	85
A.2.2	Ponto de <i>Crossover</i>	85
A.2.3	Altura	85
A.2.4	Núcleo	85
A.2.5	Conjunto Suporte	85
A.2.6	Conjunto <i>Singleton</i>	86
A.2.7	Conjunto Corte α	86
A.2.8	Conjunto Nebuloso Convexo	86
A.2.9	Contigência	86
A.2.10	Igualdade	86
A.2.11	Cardinalidade	87
A.2.12	Complemento Nebuloso (Norma-C)	87

A.2.13 União Nebulosa (Norma-S)	87
A.2.14 Interseção Nebulosa (Norma-T)	88
A.3 Relações Nebulosas	89
A.4 Projeções e Extensões Cilíndricas em Conjuntos Nebulosos	90

Capítulo 1

Introdução

Através de um projeto de sistema de controle pode-se atuar em uma planta para que esta responda de acordo com o comportamento desejado. Um sistema de controle bem projetado e confiável deve ser baseado no modelo da planta a ser controlada e possuir características fundamentais, tais como, a redução do efeito de ruídos e distúrbios bem como um melhor rastreamento da trajetória de referência, mesmo diante de incertezas que afetam o comportamento da planta a ser controlada (robustez à incerteza)(BARTOSZEWICZ, 2011).

A modelagem de plantas complexas, ao contrário das simples, exige mais do que apenas a observação das leis físicas, sendo necessária a utilização de outros métodos que incorporem os problemas relacionados aos aspectos dinâmicos (complexidade) tais como: não-linearidade, atraso puro de tempo, incertezas, entre outras, inerentes a este tipo de planta (GAHINET; APKARIAN; CHILALI, 1996). Por isso, outras metodologias de modelagem matemática tem sido desenvolvidas levando em consideração as restrições de modo a garantir robustez e estabilidade no projeto do controlador(SERRA, 2005). Cabe ressaltar que o desenvolvimento dessas metodologias e a incorporação de complexidades no projeto de sistemas de controle é possível devido ao avanço das tecnologias dos *softwares* e dos *hardwares* para esse tipo de aplicação (SERRA, 2012).

A análise e o projeto de sistemas de controle (GOODWIN; GRAEBE; SALGADO, 2001) para situações com plantas de características complexas podem ser fundamentadas pela teoria de controle robusto, que é muito estudada na academia e tem sido utilizada com sucesso no campo industrial (ZADEH, 2006), (BOTTURA, 2013), (IOANNOU; PITSILLIDES, 2010). Um trabalho sobre aplicações da teoria de controle robusto é o de Hosoe (HOSOE, 2013), que propôs um método de projeto de um controlador Proporcional Integral e Derivativo (PID) com realimentação e parâmetros iterativamente calculados por programação linear, que satisfaz o critério de desempenho robusto. Outro trabalho que se pode citar é o de Maeda e Iwasaki (MAEDA; IWASAKI, 2013), onde é apresentado um projeto de controlador PID robusto para o posicionamento de sistemas mecatrônicos, proporcionando uma

margem de estabilidade pela condição em círculo do diagrama de Nyquist, equilibrando efetivamente o *trade-off* entre a supressão de distúrbios e a estabilidade do sistema. Uma pesquisa semelhante foi feita por Salloum, Arvan e Moaveni (SALLOUM; ARVAN; MOAVENI, 2013), no qual é apresentado o projeto de um controlador PID robusto para controle de posição de atuador eletromecânico aplicando o teorema de Kharitonov.

A utilização de inteligência computacional, aliada as técnicas de controle convencional, vem sendo demonstrada em diversas pesquisas como uma maneira de projetar sistemas de controle capazes de reagir de maneira mais eficiente à dinâmica da planta a ser controlada (MACEDO; DIMURO; AGUIAR, 2011), (KIM; CHO, 2013), (CHEN; WU, 2011). É grande a quantidade de técnicas de Inteligência Computacional (IC)(RUTKOWSKI, 2004) (KONAR, 2008) que podem ser aplicadas no projeto de sistemas de controle, dentre as quais destacam-se os algoritmos evolutivos, os sistemas nebulosos, os agentes inteligentes, os sistemas especialistas e as redes neurais artificiais (COPPIN, 2010) (ZADEH, 1994). Dentre estas, será ressaltada as que utilizam os algoritmo evolutivos (algoritmo genético) e os sistemas nebulosos, pois estas técnicas são utilizadas na metodologia proposta nessa dissertação.

Os algoritmos evolutivos são técnicas de otimização baseadas no processo de evolução natural encontrada na genética de seres vivos. Especificamente, essas técnicas promovem reprodução (passagem de características), mutação (inclusão de características) e seleção (identificação e escolha de melhores indivíduos), em situações computacionalmete compatíveis no intuito de selecionar melhores parâmetros para um determinado contexto. Os algoritmo genético são uma classe particular de algoritmos evolutivos que usam técnicas inspiradas pela biologia evolutiva como hereditariedade, mutação, seleção natural e cruzamento (ENGELBRECHT, 2007). Alguns trabalhos utilizam algoritmo evolutivo para projeto de sistemas de controle, dentre eles podemos citar o trabalho de Korkmaz, Aydogdu e Dogan (KORKMAZ; AYDOGDU; DOGAN, 2012), que realizam uma comparação entre dois controladores PID, um utiliza a variação não linear de parâmetros e o outro algoritmo genético, este último demonstrou ter melhores resultados.

De forma geral, para a teoria de controle clássica uma determinada proposição ou é verdadeira ou é falsa, não existindo nada entre o verdadeiro e o falso. Os seres humanos são capazes de trabalhar com o que existe entre o verdadeiro e o falso e desenvolvem seu raciocínio lógico, seguindo regras estabelecidas em sua consciência através de suas experiências(TERANO; ASAI; SUGENO, 1989) (CHEN; PHAM, 2005). Um sistema capaz de simular ou modelar o conhecimento humano, utilizando-se da lógica nebulosa, é chamado de sistema nebuloso. Essa técnica é eficaz em fazer uso de termos linguísticos e uma base de proposições (regras) para modelar, representar e formalizar as relações entre os elementos de um sistema (ZADEH, 1965) (WANG, 1997) (PEDRYCZ; GOMIDE, 2007).

São muitos os trabalhos que visam o projeto de sistemas de controle, utilizando sistemas nebulosos, dentre eles o trabalho de Torre (TORRE, 2013), que implementam um modelo nebuloso Takagi-Sugeno a duas regras para modelar um sistema não linear de um pêndulo. Outro trabalho é o de Chaouech e Chaari (CHAOUÉCH; CHAARI, 2013), que implementam um controle por modos deslizantes baseado em um modelo nebuloso Takagi-Sugeno. Ainda neste trabalho, os autores desenvolvem uma regra de controle não linear para deslize em uma superfície em uma quantidade finita de tempo.

Além das técnicas de inteligência computacional já mencionadas neste trabalho, pode-se ainda comentar sobre os sistemas híbridos inteligentes. No contexto deste trabalho, estes sistemas funcionam a partir da união de duas ou mais técnicas de inteligência computacional no desenvolvimento do projeto de sistemas de controle (ENGELBRECHT, 2007). Especificamente, a utilização dos algoritmos evolucionários e sistemas nebulosos é uma área onde várias pesquisas vem sendo desenvolvidas. Um exemplo disto, é o trabalho de Xiu e Ren (XIU; REN, 2004), que descrevem o método de desenvolvimento de um controlador PID nebuloso Takagi-Sugeno baseado em algoritmo genético. Os autores verificaram um bom desempenho deste controlador ao aplicá-lo em um simulador de controle marinho. Outro exemplo foi o estudo feito por Koshiyama que mostra um novo sistema para resolução do problema de controle, baseado em Programação Multi-Genética e *Fuzzy*. O autor aplica e testa este método em dois problemas bem conhecidos, o Problema da Parada Ótima e o Problema do Pêndulo Invertido, obtendo bons resultados (KOSHIYAMA et al., 2014). Outra contribuição é a de Lei (LEI, 2014) que conciliou as vantagens e desvantagens das técnicas de "Busca Tabu" e Otimização por Enxame de Partículas para o desenvolvimento de um algoritmo de otimização híbrido. Este algoritmo mostrou ter resultados eficientes quando testado e comparado a outros.

1.1 Motivação

Os desafios, no que diz respeito a projeto de controle e modelagem de plantas com características cada vez mais complexas, vem aumentando sua complexidade em virtude, principalmente dos critérios de desempenho multiobjetivos a serem satisfeitos de forma eficiente e prática. A teoria de controle com estabilidade robusta é extensamente utilizada como embasamento para construção de controladores que sejam aplicados em plantas complexas. Isto implica em um sistema de controle capaz de resistir a variações tais como: desgate natural de componentes, paramétricas associadas a condições ambientais, perturbações no sistema, entre outras.

Além de garantir a estabilidade robusta o sistema de controle tem que saber lidar corretamente com o atraso puro de tempo, pois desconsiderar este pode comprometer a eficiência do sistema de controle e leva-lo a instabilidade.

A dinâmica de uma planta a ser controlada por muita vezes é algo que não pode ser facilmente prevista. Por esta razão, as técnicas de inteligência computacional tem sido utilizadas por apresentarem maior flexibilidade e adaptação na etapa de modelagem. Dentre essas técnicas, os sistemas nebulosos são ferramentas poderosas e consagradas no que tange a identificação, modelagem e controle. Este fato pode ser percebido ao serem analisados os diversos trabalhos publicados, com aplicação deste tipo de sistema em diversas áreas, entre os quais pode-se citar os publicados no **IEEE Control Systems, IEEE Transactions on Robotics, IEEE Intelligent Systems, IEEE Transactions on Automatic Control, IEEE Transactions on Control Systems Technology, IEEE Transactions on Systems, Man, and Cybernetics, IEEE Transactions on Industrial Electronics, Fuzzy Sets and Systems, Engineering Applications of Artificial Intelligence, Control Engineering Practice, Journal of Process Control, IEEE Transactions on Fuzzy Systems.**

Dentre as principais áreas de aplicação, podemos citar as seguintes:

- **Tecnologia Médica:** Diagnóstico médico de diabetes (LEE; WANG, 2011); Estimação de elasticidade de pulmão (KANAE; NAKAMICHI, 2013);
- **Agricultura:** Identificação de ervas daninhas (MAJID; HERDIYENI; RAUF, 2013); classificação de nutrientes de solos (liying); Identificação de necessidade de fertilizante para plantas baseada no nível de coloração de folhas (PRILIANI, 2014);
- **Motores:** Diagnóstico de falha de motor (FAN; HUANG, 2009); Controle de velocidade de motor a diesel (MOHAMMED N.AND MA; HAYAT, 2014);
- **Robótica:** Auxílio a decisões lógicas para robotes autômatos (MITCHELL; COHEN, 2014); Controle robótico para iteração humana (YOO B.-S.; KIM, 2014);
- **Energia:** Sistema de gerenciamento de energia para aceleração e desaceleração de motores de elevadores (MESEMANOLIS; MADEMLIS; KIOSKERIDIS, 2014); Sistema de gerenciamento de veículos elétricos híbridos (MOGHBELI; NIASAR; FALLAHI, 2014).

Os algoritmos evolutivos são também um tipo de técnica de inteligência computacional e dedica-se a realizar busca global dentro de uma base de opções que são gradativamente modificadas a fim de obter um resultado satisfatório (YU; GEN, 2010). Essa técnica merece destaque, pois vem sendo mostrada como uma ótima possibilidade de determinação de parâmetros, sendo aplicada a problemas de otimização como pode ser observado nos trabalhos de Yun (YUN-SHAN; XIAO-DONG, 2014) e Aarabi (AARABI et al., 2015).

O interesse desta dissertação em propor uma metodologia de controle nebuloso se baseia, ainda, nas numerosas aplicações de controle nebuloso a partir de técnicas clássicas e modernas de controle,

seja no domínio da frequência ou no domínio do tempo. Como exemplo cita-se o trabalho de Jianling, Zhenjie e Yezi (JIANLING; ZHENJIE; YEZI, 2014) onde é apresentada uma nova estrutura de controlados PID nebuloso e é aplicado ao controle de temperatura para tratamento de vidro.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo desta dissertação é propor uma metodologia de controle PID nebuloso utilizando algoritmo genético multiobjetivo, baseado nas especificações das margens de ganho e fase no domínio do tempo contínuo.

1.2.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Projetar um controlador PID nebuloso baseado em modelo nebuloso via algoritmo genético multiobjetivo que garanta estabilidade robusta na malha de controle;
- Analisar as condições de estabilidade robusta para o projeto do controlador PID nebuloso no domínio do tempo contínuo a partir das especificações de margem de ganho e fase;
- Analisar a viabilidade prática da metodologia proposta no controle de temperatura de uma planta térmica em tempo real.

1.3 Organização da Dissertação

Em sequência a este capítulo, serão exibidos no **capítulo 2** alguns conceitos para controle baseado em modelo nebuloso TS, com a definição e caracterização de sistema complexos, incluindo os fundamentos das incertezas dinâmicas (estruturadas e não estruturadas) e atraso puro de tempo. Ainda neste capítulo, serão abordados o sistema de inferência nebuloso Takagi-Sugeno, o algoritmo de agrupamento nebuloso *Fuzzy C-Means (FCM)*, a estratégia de compensação paralela e distribuída, e as definições de margem de ganho e fase.

No **capítulo 3** será apresentada o método para projeto de controlador PID nebuloso com estabilidade robusta baseado em modelo nebuloso a partir das especificações de margem de ganho e fase. Serão descritas ainda a estrutura do modelo nebuloso Takagi-Sugeno da planta a ser controlada, a

estimação paramétrica do antecedente, a estimação paramétrica do consequente e a estrutura do controlador PID nebuloso robusto. A partir da análise da estabilidade robusta são propostos dois teoremas contendo as condições necessárias e suficientes para o projeto do controlador PID nebuloso robusto. Por fim, é apresentada uma estratégia genética multiobjetiva utilizada para garantir as especificações das margens de ganho e fase do sistema de controle nebuloso a partir da determinação dos parâmetros do controlador nebuloso.

No **capítulo 4** serão mostrados resultados obtidos através da utilização da metodologia proposta em um ambiente de simulação (*Simulink*) e em uma planta térmica via plataforma de aquisição de dados da *National Instruments* com interface baseada no *software* LabVIEW.

O **capítulo 5** mostra quais as conclusões relevantes a partir da análise dos resultados obtidos, tal como as contribuições científicas obtidas. Por fim, serão exibidas as vertentes que podem ser exploradas a partir deste estudo, com sugestões de trabalhos futuros.

Capítulo 2

Fundamentos para Controle Baseado em Modelo Nebuloso TS com Estabilidade Robusta

Um bom sistema de controle deve responder de forma eficiente as mudanças inerentes de uma planta, as quais podem estar relacionadas a questões operacionais, como mudança de carga e perturbações ou a mudanças temporais nas componentes físicas (TRIPATHI, 2008) (BROGAN, 2009). Portanto, é necessário que o projeto de um sistema de controle seja desenvolvido baseado em um modelo que descreva a complexidade da planta de forma satisfatória. Existem diferentes abordagens para o desenvolvimento desses modelos dos quais podemos mencionar os métodos clássicos, que são baseados apenas em leis físicas e são mais adequados em situações de natureza simples, e os baseados em Inteligência Computacional (IC) (IBRAHIM, 2003).

Quando a planta está sujeita a complexidades dinâmicas e estruturais, como por exemplo o atraso puro de tempo, variações paramétricas, incertezas, não-linearidades, os métodos clássicos podem ter seu desempenho limitado no controle baseado em modelo, sendo necessário o uso de métodos mais rebuscados como os baseados em IC, dentre os quais pode-se citar as redes neurais artificiais, a computação evolutiva, sistemas nebulosos e os sistemas híbridos (combinação de mais de um método de IC)(SERRA; BOTTURA, 2006). Sendo assim, aplicar métodos de IC para modelar e projetar um sistema de controle eficiente para plantas complexas, garantindo a estabilidade robusta, tem sido um grande desafio para pesquisadores na área de controle (PIRES; SERRA, 2013)(LAM; NARIMANI, 2010).

2.1 Definição e Caracterização de Sistemas Complexos

Normalmente, os projetos de controle são baseados em um modelo matemático do sistema que se deseja controlar. Representar comportamentos de sistemas com características complexas através de modelos matemáticos com maior grau de similaridade possível, não é uma tarefa simples (SKOGSTAD; POSTLETHWAITE, 2005) (GAHINET; APKARIAN; CHILALI, 1996). Como foi citado, existem muitas ferramentas que podem ser utilizadas para auxiliar nessa tarefa (AGUIRRE, 1992b) (WU; HE; SHE, 2010). Para projetar um bom sistema de controle, eficiente e que garanta a estabilidade (WU; HE; SHE, 2010) (MATSUDA; MORI, 2009) (MING-LIANG; YA-LI; JIN-YING, 2009) para plantas complexas é importante aplicarmos a teoria de controle com estabilidade robusta (SKOGSTAD; POSTLETHWAITE, 2005), por esta considerar as características complexas tais como incertezas, atraso puro de tempo, não linearidade, variações paramétricas, entre outras. Neste contexto, o objetivo dessa seção é apresentar conceitos e definições de algumas dessas características complexas.

2.1.1 Incertezas Dinâmicas

O termo incertezas refere-se às diferenças ou erros entre o modelo utilizado e o sistema real, sendo que qualquer mecanismo usado para expressar esses erros é chamado de representação de incertezas (IANNOU; SUN, 1996). As incertezas podem ter várias origens, dentre elas destacam-se: possibilidade de haver parâmetros do modelo linear que são conhecidos apenas aproximadamente ou com erro, variação dos parâmetros devido à não-linearidade ou mudança do ponto de operação, imperfeições nos sensores, a estrutura e a ordem do modelo serem desconhecidos em altas frequências, etc, que podem levar o sistema de controle a instabilidade. Estas incertezas podem ser agrupadas em duas categorias: as incertezas não-estruturadas e as incertezas estruturadas (IANNOU; SUN, 1996).

Incetezas Não Estruturadas

As incertezas não-estruturadas são aquelas que descrevem dinâmicas não modeladas. Como por exemplo, atrasos puro de tempo não modelados, histerese, não linearidade, acoplamento parasita, etc. Ela pode ser caracterizada como aditiva ou multiplicativa.

Seja $H(s, v)$ a função de transferência de um sistema dinâmico real e $H(s)$ a função de transferência nominal. A relação entre $H(s, v)$ e $H(s)$, considerando a incerteza aditiva, é dada pela Equação (2.1) (FERREIRA; SERRA, 2010):

$$H(s, v) = H(s) + \Delta_a(s, v) \quad (2.1)$$

ou

$$H(s, v) = \frac{Y(s, v)}{X(s)} = \frac{b_\alpha s^{\alpha-1} + b_{\alpha-1} s^{\alpha-1} + \dots + b_1 s + b_0}{s^\beta + a_{\beta-1} + \dots + a_1 s + a_0} + \Delta_A(s, v) \quad (2.2)$$

na qual:

- $\Delta_A(s, v)$ é a incerteza aditiva do sistema dinâmico e é estável;
- $X(s)$ e $Y(s, v)$ representam a entrada determinística e a saída do sistema dinâmico incerto, respectivamente;
- a e b são os coeficientes do sistema dinâmico nominal;
- $v(t)$ é a variável de escalonamento da incerteza $\Delta_A(s, v)$
- s é o operador de Laplace
- α e β são as ordens do numerador e denominador de $H(s)$, respectivamente.
- v é uma variável escalar $v = [0, 1]$

A estrutura de $\Delta_A(s, v)$ é usualmente desconhecida, no entanto $\Delta_A(s, v)$ é dita satisfazer um limite superior no domínio da frequência, isto é:

$$|\Delta_A(s, v)| \leq \delta_A(\omega) \quad \forall \omega \quad (2.3)$$

para alguma função conhecida $\delta_A(\omega)$. Com as Equações (2.1) e (2.3), define-se uma família de plantas descritas pela Equação (2.4):

$$\Pi_A = \{H \mid |H(j\omega, v) - H(j\omega)| \leq \delta_A(j\omega)\} \quad (2.4)$$

O limite superior $\delta_A(\omega)$ da incerteza aditiva $\Delta_A(s, v)$ pode ser obtido através de experimentos de resposta em frequência. Em controle robusto, $H(s)$ é exatamente conhecido e as incertezas dos pólos e zeros de $H(s, v)$ estão incluídas em $\delta_A(s, v)$. A Figura 2.1 mostra o diagrama de blocos que representa o modelo da planta com incerteza aditiva (FERREIRA, 2013).

Na incerteza multiplicativa, a relação entre $H(s, v)$ e $H(s)$ é dada pela Equação (2.5):

$$H(s, v) = H(s)(1 + \Delta_M(s, v)) \quad (2.5)$$

na qual $\Delta_M(s, v)$ é estável e conhecido como perturbação ou incerteza multiplicativa da planta.

No caso de uma perturbação multiplicativa na planta, $\Delta_M(s, v)$ deve satisfazer um limite superior no domínio da frequência conforme a Equação (2.6):




Figura 2.1: Representação em um diagrama de blocos de um sistema dinâmico com incerteza aditiva

$$|\Delta_M(\omega, v)| \leq \delta_M(\omega) \quad (2.6)$$

A incerteza multiplicativa, $\Delta_M(\omega, v)$, pode ser obtida através de experimentos de resposta em frequência. Das Equações (2.5) e (2.6), uma família de plantas pode ser descrita pela Equação (2.7):

$$\Pi_M = \left\{ H \mid \frac{|H(\omega, v) - H_\omega|}{H_\omega} \leq \delta_M \right\} \quad (2.7)$$

A Figura 2.2 mostra o diagrama de blocos que representa o modelo da planta com incerteza multiplicativa.




Figura 2.2: Representação em um diagrama de blocos de um sistema dinâmico com incerteza multiplicativa

Incertezas Estruturadas

As incertezas estruturadas, também chamadas de incertezas paramétricas, são aquelas que podem ser causadas devido a uma descrição imprecisa de características de seus componentes, efeitos de

uso-desuso sobre componentes da planta, mudanças nos pontos de operação, etc. Estas incertezas (perturbações) podem ser representadas por variações dos parâmetros do sistema sobre alguns possíveis intervalos de valores (complexos ou reais) e afetam o desempenho em baixas frequências. Incertezas paramétricas podem ser quantificadas assumindo-se que o parâmetro incerto é limitado dentro de uma região $[\alpha_{min}, \alpha_{max}]$. Assim, um dado parâmetro α_p pode ser representado como mostra a Equação (2.8):

$$\alpha_p = \bar{\alpha}(a + r_\alpha \delta) \quad (2.8)$$

na qual $\bar{\alpha}$ é o valor paramétrico médio e δ é um escalar real que satisfaz $\delta \leq 1$. A incerteza relativa no parâmetro é dada por:

$$r_\alpha = \frac{\alpha_{max} - \alpha_{min}}{\alpha_{max} + \alpha_{min}} \quad (2.9)$$

2.1.2 Atraso Puro de Tempo

A utilização de sistemas com atraso puro de tempo em aplicações reais é cada vez maior (PIMENTEL; GAD; ROY, 2013) (MING et al., 2010) e a não modelagem do atraso puro de tempo é um dos fatores que pode comprometer o bom desempenho do sistema, acarretando em instabilidade do sistema de controle em malha fechada (W.; GUAN, 2003), tornando o processo de análise e projeto de controle uma atividade mais complexa (ZADEH, 2006).

O atraso puro de tempo é uma das propriedades de um sistema real com características complexas na qual a resposta a uma entrada aplicada (ação) é atrasada em relação ao seu efeito normal. É difícil representar o atraso puro de tempo na forma de função de transferência devido a impossibilidade de expressá-lo em termos de razão de polinômios em s com *rank* finito. Um método amplamente utilizado no projeto e análise de controle de sistemas dinâmicos com atraso puro de tempo é a **Aproximação de Padè** (BREZINSKI, 1985) (AGUIRRE, 1992a) (ANTWERP, 1979), representada pela Equação (2.10):

$$e^{-sL} \approx R_n(s) = \frac{Q_n(-Ls)}{Q_n(Ls)} \quad (2.10)$$

com,

$$Q_n(s) = \sum_{j=0}^n \frac{(1+j)!}{j!(1-j)!} (Ls)^{1-j} \quad (2.11)$$

na qual L é o tempo de atraso, n é a ordem da aproximação de Padè e s é o operador de Laplace.

2.2 Sistema de Inferência Nebuloso Takagi-Sugeno

O sistema de inferência nebuloso (TAKAGI; SUGENO, 1985), originamente proposto por Takagi-Sugeno(1985), é caracterizado por uma base de regras nebulosas *SE-ENTÃO* na qual a i ésima regra, sem perda de generalidade, possui a seguinte estrutura(SERRA, 2005):

$$R^{(i)} : SE \tilde{x}_1 \text{ é } F_{j|\tilde{x}_1}^i E \dots E \tilde{x}_n \text{ é } F_{j|\tilde{x}_n}^i \text{ ENTÃO } \tilde{y}_i = f_i(\tilde{x}) \quad (2.12)$$

na qual l é o número máximo de regras. O vetor $\tilde{x}^T = [\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n] \in R^n$ contém as variáveis linguísticas do antecedente. $\tilde{y}^T = [\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_n] \in R^n$ é a variável do consequente, a qual contém uma expressão funcional na i -ésima regra. Cada variável linguística tem o seu próprio universo de discurso $U_{\tilde{x}_1}, \dots, U_{\tilde{x}_n}$ particionado pelos conjuntos nebulosos representando os termos linguísticos correspondentes. A variável \tilde{x}_t pertence ao conjunto nebuloso $F_{j|\tilde{x}_t}^i$ com um valor $\mu_{F_{j|\tilde{x}_t}^i}^i$ definido por uma função de pertinência $\mu_{F_{j|\tilde{x}_t}^i}^i : \mathfrak{R} \rightarrow [0, 1]$, com $\mu_{F_{j|\tilde{x}_t}^i}^i \in \mu_{F_{1|\tilde{x}_t}^i}, \mu_{F_{2|\tilde{x}_t}^i}, \mu_{F_{3|\tilde{x}_t}^i}, \dots, \mu_{F_{p_{\tilde{x}_t}|\tilde{x}_t}^i}$ na qual $p_{\tilde{x}_t}$ é o número de partições do universo de discurso associado a variável linguística \tilde{x} . O grau de ativação h_i para a regra i , é dado pela Equação (2.13):

$$h_i(\tilde{x}) = \mu_{F_{j|\tilde{x}_1}^i} \otimes \mu_i(\tilde{x}) \mu_{F_{j|\tilde{x}_2}^i} \otimes \dots \mu_{F_{j|\tilde{x}_n}^i} \quad (2.13)$$

na qual \tilde{x}_t^* tem algum ponto em $U_{\tilde{x}_t}$. O grau de ativação normalizado para a regra i , é dado conforme apresentado na Equação (2.14):

$$\gamma_i(\tilde{x}) = \frac{h_i(\tilde{x})}{\sum_{\lambda=1}^l h_\lambda(\tilde{x})} \quad (2.14)$$

na qual assume-se que,

$$\sum_{\lambda=1}^l h_\lambda(\tilde{x}) > 0, \quad (2.15)$$

$$h_\lambda(\tilde{x}) \geq 0, \quad i = 1, 2, \dots, l$$

Esta normalização implica em,

$$\sum_{i=1}^l \gamma_i(\tilde{x}) = 1 \quad (2.16)$$

A resposta do sistema de inferência nebuloso TS é uma soma ponderada dos parâmetros do con-

sequente, *i.e.*, uma combinação convexa das funções lineares locais (modelos) f_i , como segue:

$$f_i(\tilde{\mathbf{x}}) = \sum_{i=1}^l \gamma_i(\tilde{\mathbf{x}}) f_i(\tilde{\mathbf{x}}) \quad (2.17)$$

Este sistema de inferência pode ser interpretado como um sistema Linear Variante nos Parâmetros (LVP) (BALAS, 1997) (SHAMMA; ATHANS, 1991). Com esta propriedade, a análise de sistemas de inferência nebulosos TS em um contexto robusto é simplificada, seja na etapa de identificação ou no projeto de controladores que atendem as características de desempenho e estabilidade requeridos para sistemas de controle em malha fechada.

2.3 Algoritmo de Agrupamento Nebuloso

Um conjunto de regras nebulosas pode ser obtida com informações fornecidas por um especialista sobre o sistema em questão ou particionando os dados experimentais (de entrada e saída) referentes ao sistema em subconjuntos e aproximar cada um destes por um modelo simples (BABUSKA, 1998).

Como exemplo de métodos utilizados na obtenção de modelos nebulosos são: linearização em torno de pontos de operação e agrupamento nebuloso, conforme definidos a seguir:

- **Linearização:** o sistema dinâmico é aproximado por um modelo linear válido em torno de um dado ponto de operação. Diferentes pontos de operação podem levar a diferentes modelos lineares. A Linearização é realizada através de expansões e aproximações via série de Taylor, por exemplo (KOMATSU; TAKATA, 2008);
- **Algoritmo de Agrupamento Nebuloso:** são utilizados algoritmos nebulosos para constuir modelos nebulosos a partir de dados experimentais de entrada e saída. Os dados são agrupados em grupos (*clusters*) de acordo com características semelhantes e levam o grupo a ter um determinado tipo de comportamento. Entre os algoritmos de agrupamento nebulosos mais populares estão: *Fuzzy C - Means (FCM)*, *Gustafson-Kessel (GK)* e *Algoritmo de Estimção através da Máxima Verossimilhança Nebulosa (FMLE)* (HOPPNER et al., 1999) (BABUSKA, 1998) (OLIVEIRA; PEDRYCZ, 2007). Este será o método utilizado nesta dissertação.

Uma das definições para agrupamento nebuloso é um grupo de objetos que são mais similares entre si e que tem características divergentes com os demais grupos. Tal similaridade pode ser entendida, em termos matemáticos, como a norma da distância ou norma métrica, podendo ser medida a partir de um vetor de dados até um dado *cluster* (centro) (ALMEIDA, 2005) (OLIVEIRA; PEDRYCZ, 2007). As métricas quantificam o quanto os pontos são próximos ou semelhantes.

Os dados a serem utilizados são tipicamente observações de processos físicos. Cada observação consiste em n variáveis medidas, agrupadas em um vetor coluna $z_k = [z_{1k}, z_{2k}, \dots, z_{nk}]^T$, $z_k \in \mathbb{R}^n$. Um conjunto de n observações é expresso por $Z = \{z_k | k = 1, 2, \dots, N\}$, onde Z é a matriz de dados $n \times N$, representada como apresentado na Equação (2.18):

$$\mathbf{Z} = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1N} \\ z_{21} & z_{22} & \dots & z_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ z_{n1} & z_{n2} & \dots & z_{nN} \end{bmatrix} \quad (2.18)$$

na qual as colunas são chamadas de *padrões* ou *objetos* e as linhas são chamadas de *características* ou *atributos*.

A distância pode ser medida entre os vetores de dados ou entre um vetor de dados e um objeto prototipado de um agrupamento. Os protótipos geralmente não são conhecidos e são obtidos através dos algoritmos de agrupamento à medida que a divisão de dados ocorre; além disso, podem ser vetores de mesma dimensão dos objetos de dados, como também podem ser definidos como objetos geométricos, tais como subespaços, funções lineares ou não-lineares.

O objetivo do agrupamento é particionar um conjunto de dados Z em c agrupamentos. Considerando que c é conhecido *a priori*. A **partição nebulosa** de Z pode ser definida como uma família de subconjuntos $\{A_i | 1 \leq i \leq c\} \subset P(Z)$, com as seguintes propriedades:

$$\bigcup_{i=1}^c A_i = \mathbf{Z} \quad (2.19)$$

$$A_i \cap A_j = \emptyset \quad (2.20)$$

$$\emptyset \subset A_i \subset \mathbf{Z}_i \quad (2.21)$$

A Equação (2.19) expressa que os subconjuntos A_i coletivamente contém todos os dados em Z . Os subconjuntos devem ser disjuntos, conforme a Equação (2.20) e nenhum deles pode ser vazio ou conter todos os dados em Z , de acordo com a Equação (2.21). Em termos da função de pertinência, μ_{A_i} é a função de pertinência de A_i . Para fins de simplificação, nesta dissertação é utilizado o termo μ_{ik} , em lugar do termo $\mu_{ik}(z_k)$. A matriz $c \times N$, $\mathbf{U} = [\mu_{ik}]$ representa um espaço de particionamento nebuloso se, e somente se:

$$M_{f_c} = \{ \mathbf{U} \in \mathfrak{R}^{c \times N} \mid \mu_{ik} \in [0, 1], \forall i, k; \sum_{i=1}^c \mu_{ik} = 1, \forall k; 0 < \sum_{k=1}^N \mu_{ik} < N, \forall i \} \quad (2.22)$$

A i -ésima linha da matriz de partição nebulosa \mathbf{U} contém valores da i -ésima função de pertinência do subconjunto nebuloso A_i de Z . Um conjunto inicial de centróides é otimizado através do algoritmo de agrupamento por meio da minimização da função de custo J em um processo iterativo. Esta função é dada pela Equação (2.23).

$$\mathbf{J}(\mathbf{Z}; \mathbf{U}, \mathbf{V}, \mathbf{A}) = \sum_{i=1}^c \sum_{k=1}^N \mu_{ik}^m D_{ikA_i}^2 \quad (2.23)$$

na qual:

- $\mathbf{Z} = \{z_1, z_2, \dots, z_n\}$ é o conjunto de dados finito;
- $\mathbf{U} = [\mu_{ik}] \in M_{f_c}$ é a partição nebulosa de \mathbf{Z} ;
- $\mathbf{V} = \{v_1, v_2, \dots, v_c\}$, $v_i \in \mathfrak{R}^n$ é o vetor de protótipos de agrupamentos (centros);
- \mathbf{A} corresponde a c -tupla de norma induzida ($\mathbf{A} = (\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_c)$);
- $D_{ikA_i}^2$ corresponde ao quadrado da norma do produto interno da distância;
- $m \in [1, \infty)$ é o grau de ponderação, o qual determina o grau de fuzzificação dos agrupamentos.

Os algoritmos de agrupamento nebulosos diferem na escolha da norma de distância. A norma métrica influencia no critério de agrupamento pela escolha da medida de dissimilaridade. O algoritmo de agrupamento nebuloso *Fuzzy C-Means* (FCM) será utilizado nesta dissertação. O FCM utiliza a norma *Euclidiana* como norma métrica. A norma Euclidiana, enquanto norma métrica, induz a agrupamentos hiperesféricos, o que caracteriza o algoritmo FCM. Além disso, neste algoritmo, a matriz de norma induzida A_{iFCM} é igual a matriz identidade ($A_{iFCM} = I$), a qual impõe, estritamente, uma forma circular a todos os agrupamentos e é dada por:

$$D_{ikFCM}^2 = (z_k - v_i)^T \mathbf{A}_{iFCM} (z_k - v_i) \quad (2.24)$$

A Tabela 2.1 mostra os passos para implementação do algoritmo FCM.

Tabela 2.1: Passos para implementação do Algoritmo FCM

Algoritmo FCM
Dado um conjunto de dados \mathbf{Z} e a matriz de partição inicial $U^{(0)} \in M_{fc}$, escolha o número de agrupamentos $1 < c < N$, a tolerância de encerramento $\epsilon > 0$ e o expoente de ponderação $m > 1$.
Repita para $l = 1, 2, \dots$
Passo 1 - Calcule os centros dos agrupamentos (protótipos):
$v_i^{(l)} = \frac{\sum_{k=1}^N \mu_{ik}^{(l-1)} z_k}{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^m}, \quad 1 \leq i \leq c$
Passo 2 - Calcular as distâncias:
$D_{ikFCM}^2 = (z_k - v_i)^T \mathbf{A}_{iFCM} (z_k - v_i), \quad 1 \leq i \leq c, \quad 1 \leq k \leq N$
Passo 3 - Atualize a matriz de partição:
Se $D_{ikA} > 0$ para $1 \leq i \leq c, \quad 1 \leq k \leq N$,
$\mu_{ik}^{(l)} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ikA}}{D_{jkA}} \right)^{\frac{2}{m-1}}}$
Senão
$\mu_{ik}^{(l)} = 0 \text{ se } D_{ikA} > 0, \text{ e } \mu_{ik}^{(l)} \in [0, 1] \text{ com } \sum_{i=1}^c \mu_{ik}^{(l)} = 1$
até que $\ U^{(l)} - U^{(l-1)}\ < \epsilon$

2.4 Margem de Ganho e Fase

Em um projeto de controle, é necessário que o sistema seja estável. A análise da estabilidade pode ser feita no domínio do tempo ou no domínio da frequência. Uma vantagem da abordagem no domínio da frequência surge do fato da simplicidade com que se pode, experimentalmente, realizar testes de resposta em frequência de forma precisa usando-se geradores de sinais senoidais disponíveis e instrumentos precisos para medição. Outra vantagem é que fornece informações suficiente para se analisar a estabilidade do sistema mesmo na presença de incertezas (OGATA, 2010). Dentre os métodos utilizados para apresentar as características da resposta em frequência em um projeto de controle de sistemas no domínio do tempo contínuo, cita-se: *Bode*, *Nichols*, *Nyquist*, entre outros (DORF; BISHOP, 2009) (OGATA, 2010).

Para se verificar a estabilidade de um sistema de controle, duas importantes medidas, em termos

de resposta em frequência, tem sido amplamente utilizadas: *margens de ganho e fase* (FRANKLIN; POWELL; BAEINI, 2002) (JAY et al., 2011). A importância dessas medidas se deve ao fato que elas informam, não apenas se o sistema é instável ou estável, mas também quanto deve se acrescentar a fase (para margem de fase) ou ao ganho (para margem de ganho) do sistema de controle para tornar o sistema estável. Nesta dissertação, serão utilizadas especificações de margens de ganho e fase no projeto de controle nebuloso.

A **Margem de Ganho** é o recíproco do módulo $|G_p(j\omega_p)|$ na frequência onde o ângulo de fase é -180° . Define-se a frequência de cruzamento de fase, ω_p como a frequência na qual o ângulo de fase da função de transferência é igual a -180° . Logo, a margem de ganho resulta em:

$$A_m = \frac{1}{|G(j\omega_p)|} \quad (2.25)$$

na qual A_m é a margem de ganho e $G(j\omega_p)$ é a função de transferência do sistema.

A margem de ganho, em dB, é positiva para $A_m > 1$ e negativa para $A_m < 1$. Para sistemas estáveis, a margem de ganho deve ser positiva (em Decibéis). A margem de ganho indica o quanto o ganho pode ser incrementado para tornar o sistema instável.

A **Margem de Fase** é o atraso adicional a frequência de cruzamento do ganho, necessário para levar o sistema a instabilidade. A frequência de cruzamento de ganho é a frequência na qual o módulo da função de transferência em malha-aberta, $|G(j\omega_g)|$, é unitário. Então, a margem de fase resulta em:

$$\phi_m = \arg[G(j\omega_g)] + \pi \quad (2.26)$$

na qual ω_g é a frequência de cruzamento do ganho e $G(j\omega_g)$ é a função de transferência do sistema. A margem de fase é positiva para $\phi_m > 0$ e negativa para $\phi_m < 0$. Para sistemas estáveis, a margem de fase deve ser positiva. Quando as margens de ganho e fase estão especificadas adequadamente, garante robustez contra variações paramétricas da planta e são especificados para valores definidos de frequência.

A Figura 2.3 ilustra a margem de ganho e a margem de fase tanto de um sistema estável quanto de um instável. Nos gráficos logarítmicos, Figura 2.3, o ponto crítico no plano complexo corresponde as retas $0dB$ e -180° .

Considerando as funções de transferência para um sistema dinâmico e um controlador dadas por $G_p(s)$ e $G_c(s)$, respectivamente; e as margens de ganho e fase especificadas por A_m e ϕ_m , respectivamente, as expressões para as margens de ganho e fase do sistema resultam em:




Figura 2.3: Diagrama de Bode com margens de ganho e fase de sistema estáveis e instáveis

$$\arg[G_c(j\omega_p)G_p(j\omega_p)] = -\pi \quad (2.27)$$

$$A_m = \frac{1}{|G_c(j\omega_p)G_p(j\omega_p)|} \quad (2.28)$$

$$|G_c(j\omega_g)G_p(j\omega_g)| = 1 \quad (2.29)$$

$$\phi_m = \arg[G_c(j\omega_g)G_p(j\omega_g)] + \pi \quad (2.30)$$

em que A_m é a margem de ganho desejada, ϕ_m é a margem de fase desejada, $G_c(j\omega_p)$ é a função de transferência do controlador e $G_p(j\omega_p)$ é a função de transferência da planta.

As Equações (2.27) e (2.28) representam a margem de ganho e as Equações (2.29) e (2.30) representam a margem de fase.

2.5 Estratégia de Compensação Paralela e Distribuída

Outro conceito importante para o desenvolvimento desta dissertação é o da Compensação Paralela e Distribuída, que foi primeiramente exposta por Wang(WANG; TANAKA; GRIFFIN, 1995), teve

desenvolvimento prático iniciado por Kang e Sugeno, que utilizaram a estratégia de projeto baseado em modelo (SUGENO; KANG, 1986). Esta estratégia corresponde ao projeto do controlador a partir de um modelo nebuloso da planta a ser controlada. Fazer um projeto de controle através da estratégia de Compensação Paralela e Distribuída requerer que todas as regras de controle sejam projetadas de acordo com a respectiva regra no modelo do sistema dinâmico.

Uma vez projetado, o controlador faz uso de um conjunto nebuloso idêntico ao existente no antecedente da regra linguística do modelo do sistema dinâmico. Isto faz com que as regras do controlador nebuloso compensem as regras do modelo nebuloso. O resultado deste processo é a junção dos controladores lineares, resultando em um controlador não linear. Esta técnica é utilizada no projeto de sistemas de controladores baseados em modelo, sendo de grande eficiência.

A estratégia CPD aplicada ao controlador nebuloso Takagi-Sugeno é ilustrada na Figura 2.4

Neste capítulo foram apresentados alguns conceitos importantes em relação ao problema de controle baseado em estabilidade robusta no domínio do tempo contínuo, tais como, definições e características das incertezas e o efeito do atraso puro de tempo. Também foram apresentados a formulação matemática que utiliza a modelagem nebulosa Takagi-Sugeno, baseada em dados experimentais, o método de agrupamento nebuloso, conceitos relacionados às margens de ganho e fase, e a estratégia de compensação paralela e distribuída. Estes conceitos são os que serão utilizados no desenvolvimento da proposta desta dissertação.

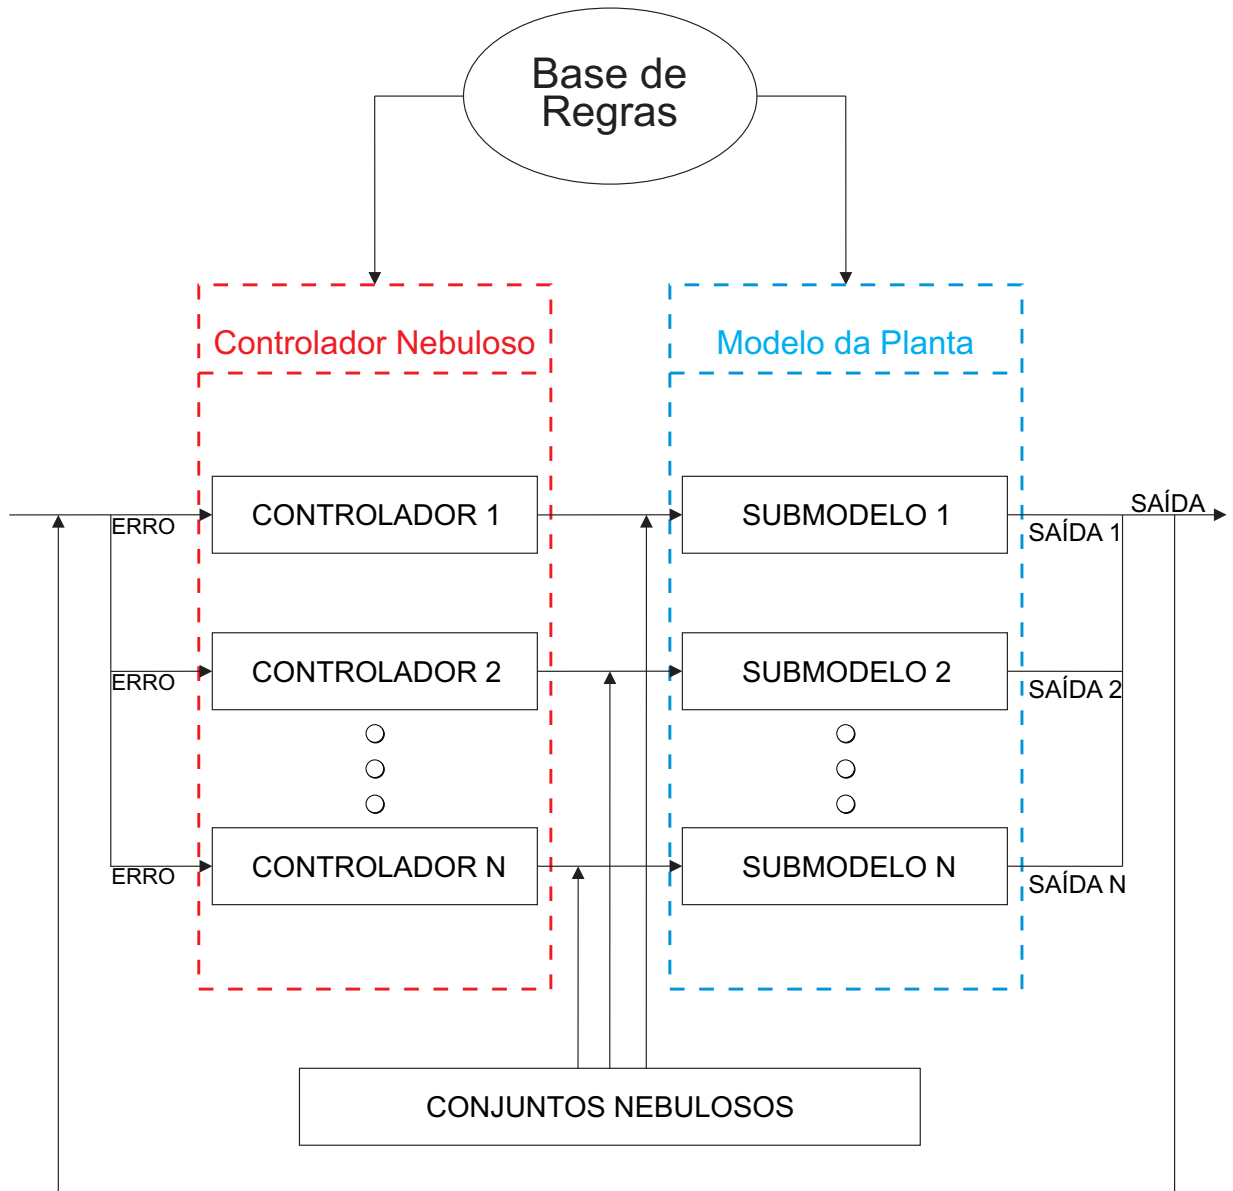


Figura 2.4: Estratégia de Compensação Paralela e Distribuída aplicada a estrutura controlador nebuloso Takagi-Sugeno

Capítulo 3

Metodologia de Controle Baseado em Modelo Nebuloso Takagi-Sugeno

Como apresentado, é crescente a demanda por controle de plantas cada vez mais complexas. Logo, modelagem e controle de sistemas para plantas com características dinâmicas tem sido baseados em vários tipos de sistemas nebulosos (AYDI; DJEMEL; CHTOUROU, 2014) (MEHRAN, 2008), uma vez que os sistemas de controle clássicos não se adequam. Um destes tipos é chamado Takagi-Sugeno (TS), que são sistemas nebulosos cujas entradas e saídas são valores reais das variáveis numéricas de entrada e saída, mas que não possuem blocos de defuzificação, pois nesse sistema os termos do consequente são funções matemáticas das variáveis de entrada. Este tipo de sistema é extensamente utilizado por ser composto por um conjunto de regras para a aproximação de funções (lineares e não-lineares) e incertezas (AZEEM, 2012) (HO; TSAI; CHOU, 2007).

Uma vez definida a modelagem, é necessário projetar o controlador que irá atuar na planta, o qual pode ser também de vários tipos. O controlador PID, apesar de ter uma estrutura simples, é um dos tipos de controlador mais utilizado academicamente e na indústria, pois garante estabilidade com pequenos ajustes (TAJJUDIN et al., 2012). Contudo, diante da necessidade de controle de plantas complexas, a formulação original do PID precisa ser agregada a outros tipos de sistema que permitam que este controlador possa lidar com as variações da planta, mesmo diante de situações adversas. Nesse contexto, uma das possibilidades é realizar a união de sistemas nebulosos com este controlador, dando origem a um controlador PID nebuloso para plantas com características dinâmicas complexas (SERRA; SILVA, 2014) (YUAN-JAY et al., 2010) (GHOSH; MARTIN; ZHOU, 2009).

Portanto, é proposta nesta dissertação o desenvolvimento de uma metodologia de controle PID nebuloso robusto baseado em modelo com estrutura nebulosa do tipo TS, a partir das especificações das margens de ganho e fase no domínio do tempo contínuo. Será utilizado para isso o modelo nebuloso TS e a estratégia CPD como base para a formulação matemática. Os parâmetros do modelo nebuloso

da planta em questão serão obtidos por agrupamento nebuloso e método dos mínimos quadrados, e o ganho DC será ajustado via algoritmo genético. Ainda nesta metodologia, os parâmetros dos subcontroladores PID lineares no consequente do controlador PID nebuloso são obtidos por um algoritmo genético multiobjetivo, de acordo com as margens de ganho e fase especificadas. (ZITZLER; THIELE, 1999) (WRIGHT, 1991).

Serão apresentados os resultados sobre as condições necessárias e suficientes para o projeto do controlador PID nebuloso com a proposta de dois teoremas, bem como experimentos com a aplicação desta metodologia em um sistema para controle de temperatura.

A Figura 3.1 ilustra a estrutura utilizada para o projeto do controlador PID TS proposto nesta dissertação. Observa-se que inicialmente tem-se a planta complexa, desta faz-se a aquisição de dois conjuntos de dados de entrada e saída, em seguida obtém-se uma estrutura nebulosa Takagi-Sugeno que melhor represente a planta que se deseja modelar através do agrupamento nebuloso *FCMeans* e a estimação paramétrica dos mínimos quadrados. Com o modelo obtido, utiliza-se o conjunto de dados de entrada e saída, diferente do utilizado para obtenção do modelo, para validar-lo. Caso o erro entre o modelo obtido e a planta (sistema real) não esteja na faixa desejada, faz-se a aquisição de outro conjunto de dados de entrada e saída, obtém-se outro modelo até que o erro esteja na faixa desejada. Em seguida, valida-se o modelo, aplica-se a estratégia de compensação paralela e distribuída. Em seguida, utiliza-se o algoritmo genético multiobjetivo para obter os ganhos dos controladores através das especificações das margens de ganho e fase. Então o projeto do controlador nebuloso TS está pronto e será testado para ver se alcança o desempenho esperado.

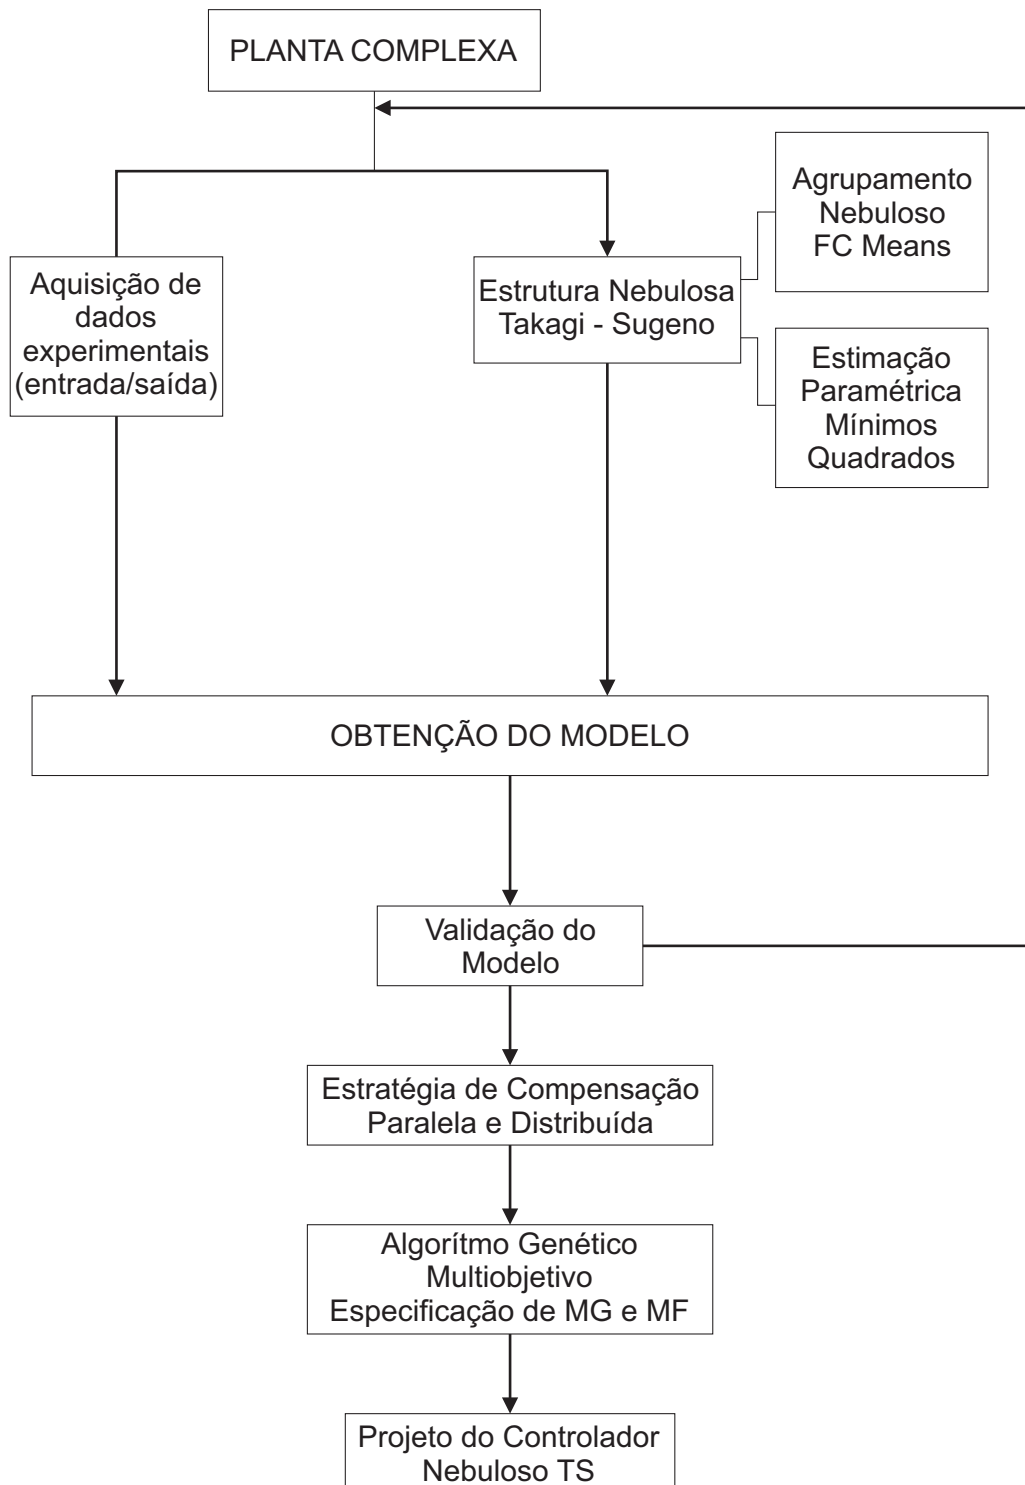


Figura 3.1: Diagrama sistema de controle proposto.

3.1 Modelagem Nebulosa Takagi-Sugeno Baseada em Dados Experimentais

3.1.1 Estrutura do Modelo Nebuloso Takagi-Sugeno

O modelo nebuloso Takagi-Sugeno (TS) é usado como aproximador universal de muitos tipos de sistemas não lineares (BAI; ZHUANG; WANG, 2007). Neste modelo, o antecedente da regra é uma proposição nebulosa e o conseqüente é uma função matemática das variáveis do antecedente (BARROS; BASSANEZI, 2006). A estrutura apresentada para a i -ésima regra no sistema de inferência nebuloso TS usado como modelo da planta a ser controlada é dada por:

$$R^{(i)} : \text{SE } \tilde{y}(t) \text{ É } F_{t|\tilde{y}(t)}^i \text{ ENTÃO } G_p^i(s) = \frac{K_c^i}{a^i s^2 + b^i s + 1} e^{-Ls} U(s) \quad (3.1)$$

na qual a^i , b^i e K_p^i são os parâmetros a serem estimados pelo algoritmo dos mínimos quadrados e L representa o atraso puro de tempo. Cada variável $\tilde{y}(t)$ possui o seu próprio universo de discurso o qual é particionado em regiões nebulosas pelos conjuntos nebulosos descritos pelas variáveis linguísticas $F_{t|\tilde{y}(t)}^i$ com um valor $\mu_{F_{t|\tilde{y}(t)}^i}$ definido por uma função de pertinência $\mu_{\tilde{y}(t)}^i : \mathfrak{R} \rightarrow [0, 1]$, com $\mu_{F_{t|\tilde{y}(t)}^i} \in \mu_{F_{1|\tilde{y}(t)}^i}, \mu_{F_{2|\tilde{y}(t)}^i}, \mu_{F_{3|\tilde{y}(t)}^i}, \dots, \mu_{F_{p_{\tilde{y}(t)}|\tilde{y}(t)}^i}$, onde $p_{\tilde{y}(t)}$ corresponde ao número de partições do universo de discurso relacionado à variável linguística $\tilde{y}(t)$.

O modelo nebuloso TS, $G_p(\tilde{y}(t), s)$ é dado pela soma ponderada de submodelos locais:

$$G_p(\tilde{y}(t), s) = \sum_{i=1}^l \gamma^i(\tilde{y}(t)) \frac{K_c^i}{a^i s^2 + b^i s + 1} e^{-Ls} U(s) \quad (3.2)$$

3.1.2 Estimativa Paramétrica do Antecedente

Nessa dissertação, o modelo da planta é obtido pelo processamento dos dados experimentais de entrada e saída. O algoritmo de agrupamento nebuloso *Fuzzy C-Means* (FCM) é utilizado e através dele os parâmetros do antecedente são obtidos.

O objetivo do algoritmo de agrupamento é particionar o conjunto Z dos dados em c clusters. Assumindo que c já é conhecido, a partição de Z pode ser definida como uma família de subconjuntos $A_i | 1 \leq i \leq c \subset P(Z)$, com as seguintes propriedades:

$$\bigcup_{i=1}^c A_i = \mathbf{Z} \quad (3.3)$$

$$A_i \cap A_j = \emptyset \quad (3.4)$$

$$0 \subset A_i \subset \mathbf{Z}_i \quad (3.5)$$

A Equação (3.3) expressa que os subconjuntos A_i coletivamente contém todos os dados em Z . Os subconjuntos devem ser disjuntos, conforme a Equação (3.4) e nenhum deles pode ser vazio ou conter todos os dados em Z , de acordo com a Equação (3.5). Em termos da função de pertinência, μ_{A_i} é a função de pertinência de A_i . Como já mencionado, para fins de simplificação, nesta dissertação é utilizado o termo μ_{ik} , em lugar do termo $\mu_{ik}(z_k)$. A matriz $c \times N$, $\mathbf{U} = [\mu_{ik}]$ representa um espaço de particionamento nebuloso se, e somente se:

$$M_{f_c} = \{\mathbf{U} \in \mathfrak{R}^{c \times N} \mid \mu_{ik} \in [0, 1], \forall i, k; \sum_{i=1}^c \mu_{ik} = 1, \forall k; 0 < \sum_{k=1}^N \mu_{ik} < N, \forall i\} \quad (3.6)$$

A i -ésima linha da matriz de partição nebulosa \mathbf{U} contém valores da i -ésima função de pertinência do subconjunto nebuloso A_i de Z . Um conjunto inicial de centróides é otimizado através do algoritmo de agrupamento por meio da minimização da função de custo J em um processo iterativo. Esta função é dada como segue:

$$\mathbf{J}(\mathbf{Z}; \mathbf{U}, \mathbf{V}, \mathbf{A}) = \sum_{i=1}^c \sum_{k=1}^N \mu_{ik}^m D_{ikA_i}^2 \quad (3.7)$$

em que $\mathbf{Z} = \{z_1, z_2, \dots, z_n\}$ é o conjunto de dados finito, $\mathbf{U} = [\mu_{ik}] \in M_{f_c}$ é a partição nebulosa de \mathbf{Z} , $\mathbf{V} = \{v_1, v_2, \dots, v_c\}$, $v_i \in \mathfrak{R}^n$ é o vetor de protótipos de agrupamentos (centros), \mathbf{A} corresponde a c -tupla de norma induzida ($\mathbf{A} = (\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_c)$), $D_{ikA_i}^2$ corresponde ao quadrado da norma do produto interno da distância, $m \in [1, \infty)$ é o grau de ponderação, o qual determina o grau de fuzzificação dos agrupamentos.

O algoritmo de agrupamento nebuloso *Fuzzy C-Means* (FCM) utiliza a norma *Euclidiana* como norma métrica. A norma Euclidiana, enquanto norma métrica, induz a agrupamentos hiperesféricos, o que caracteriza o algoritmo FCM. Além disso, neste algoritmo, a matriz de norma induzida A_{iFCM} é igual a matriz identidade ($A_{iFCM} = I$), a qual impõe estritamente uma forma circular a todos os agrupamentos sendo dada por:

$$D_{ikFCM}^2 = (z_k - v_i)^T \mathbf{A}_{iFCM} (z_k - v_i) \quad (3.8)$$

O termo F_i é a matriz de covariância do i -ésimo *cluster* e é definido por:

$$F_i = \frac{\sum_{k=1}^N (\mu_{ik})^m (z_k - v_i)(z_k - v_i)^T}{\sum_{k=1}^N (\mu_{ik})^m} \quad (3.9)$$

O termo P_i é a probabilidade de seleção do *cluster* i , dado por:

$$P_i = \frac{1}{N} \sum_{k=1}^N (\mu_{ik})^m \quad (3.10)$$

3.1.3 Estimação Paramétrica do Consequente

Seja a função de transferência $G_P^i(s)$ como consequente da i -ésima regra do sistema nebuloso TS, dado por:

$$G_P^i(s) = \frac{b_0^i + b_1^i s^{-1} + \dots + b_\beta^i s^{-\beta}}{1 + a_1^i s^{-1} + a_2^i s^{-2} + \dots + a_\alpha^i s^{-\alpha}} \quad (3.11)$$

em que:

- s é a transformada de Laplace;
- $a_{1,2,\dots,\alpha}^i$ e $b_{1,2,\dots,\beta}^i$ são os parâmetros do i -ésimo submodelo;
- α e β são as ordem do numerador e denominador de $G_P^i(s)$ respectivamente;
- i é o número da regra ($i=1,2,\dots, l$)

O modelo dinâmico do sistema nebuloso TS apresenta a seguinte estrutura:

$$\tilde{y}(t) = \sum_{i=1}^l \gamma^i [b_0^i u - a_1^i \dot{y} - a_2^i \ddot{y} - \dots - a_\alpha^i y^\alpha] \quad (3.12)$$

E na forma matricial resulta:

$$\tilde{\mathbf{Y}}(t) = \Gamma^1 X(t)\Theta^1 + \Gamma^2 \mathbf{X}(t)\Theta^2 + \dots + \Gamma^l \mathbf{X}(t)\Theta^l \quad (3.13)$$

onde:

$$\tilde{\mathbf{X}}(t) = [u \quad -\dot{y} \quad -\ddot{y} \quad \dots \quad -y^\alpha] \quad (3.14)$$

é a matriz de regressores,

$$\Theta^i = \begin{bmatrix} b_0^i \\ a_0^i \\ a_1^i \\ \vdots \\ a_\beta^i \end{bmatrix} \quad (3.15)$$

é o vetor dos parâmetros do submodelo na i -ésima regra,

$$\Gamma = \begin{bmatrix} \gamma_1^i & 0 & \dots & 0 \\ 0 & \gamma_2^i & \dots & 0 \\ \dots & \dots & \ddots & \dots \\ 0 & 0 & \dots & \gamma_N^i \end{bmatrix} \quad (3.16)$$

é a matriz diagonal de ponderação da i -ésima regra,

$$\tilde{\mathbf{Y}}(\mathbf{k}) = \begin{bmatrix} \tilde{y}_1 \\ \tilde{y}_2 \\ \vdots \\ \tilde{y}_N \end{bmatrix} \quad (3.17)$$

é o vetor de saída do modelo nebuloso.

Considerando a saída do modelo do sistema dinâmico dada por:

$$\mathbf{Y}(\mathbf{k}) = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \quad (3.18)$$

e aplicando o algoritmo de mínimos quadrados a fim de reduzir o erro de aproximação entre as saídas do modelo nebuloso e do sistema dinâmico considerado, os parâmetros dos submodelos do consequente podem ser estimados como a seguir:

$$\begin{aligned} \Theta^1 &= (\mathbf{X}'\Gamma^1\mathbf{X})^{-1}\mathbf{X}'\Gamma^1\mathbf{Y}(\mathbf{k}) \\ \Theta^2 &= (\mathbf{X}'\Gamma^2\mathbf{X})^{-1}\mathbf{X}'\Gamma^2\mathbf{Y}(\mathbf{k}) \\ &\vdots \\ \Theta^l &= (\mathbf{X}'\Gamma^l\mathbf{X})^{-1}\mathbf{X}'\Gamma^l\mathbf{Y}(\mathbf{k}) \end{aligned} \quad (3.19)$$

3.2 Projeto do Controlador Baseado em Modelo Nebuloso via Especificações das Margens de Ganho e Fase

3.2.1 Estrutura do Controlador PID Nebuloso Takagi-Sugeno

O controlador PID nebuloso TS apresenta $i|^{i=1,2,\dots,l}$ -ésima regra dada por:

$$R^{(i)} : \text{SE } \tilde{y}(t) \text{ É } F_{k|\tilde{y}(t)}^i \text{ ENTÃO } G_c^i(s) = \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} E(s) \quad (3.20)$$

na qual K_d , K_c e K_i são os ganhos derivativo, proporcional e integral do controlador nebuloso, respectivamente (DORF; BISHOP, 2009) e $G_c^j(s)$ é a função de transferência do controlador. Logo, o controlador nebuloso TS $G_c(\tilde{y}(t), s)$ é uma soma ponderada de subcontroladores PID lineares locais:

$$G_c(\tilde{y}(t), s) = \sum_{i=1}^l \gamma^i(\tilde{y}(t)) \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} \quad (3.21)$$

Considerando o modelo e o controlador PID Nebuloso, tem-se no ramo direto do sistema de controle em malha fechada:

$$G_c(\tilde{y}(t), s) G_p(\tilde{y}(t), s) = \sum_{i=1}^l \gamma_i(\tilde{y}(t)) \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} \frac{K_c^i}{a^i s^2 + b^i s + 1} e^{(-Ls)} \quad (3.22)$$

onde $G_p(\tilde{y}(t), s)$ é a função de transferência da planta.

Na Seção 3.1 foi obtida a estrutura nebulosa TS da planta, Equações (3.1) e (3.2) e nesta Seção, a do controlador, Equações (3.20) e (3.21). Com essas Equações, o projeto do controlador PID nebuloso TS no domínio do tempo contínuo pode ser desenvolvido via estratégia CPD, conforme Seção 2.5, no Capítulo 2.

3.2.2 Estrutura Margens de Ganho e Fase

Considerando as funções de transferência da planta, Equação (3.2), e do controlador nebuloso, Equação (3.21) e a margem de ganho dada por A_m e de fase dada por ϕ_m , as expressões para as margens de ganho e fase do sistema de controle nebuloso resultam em:

$$\arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p) e^{-Lj\omega}] = -\pi \quad (3.23)$$

$$A_m = \frac{1}{|G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega}|} \quad (3.24)$$

$$|G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega}| = 1 \quad (3.25)$$

$$\phi_m = \text{arg}[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega}] + \pi \quad (3.26)$$

na qual L é o atraso puro de tempo, ω_g é a frequência de cruzamento do ganho e ω_p é a frequência de cruzamento de fase.

As Equações (3.23) e (3.24) define a margem de ganho do sistema de controle em malha fechada e as Equações (3.25) e (3.26) define a margem de fase do sistema de controle em malha fechada.

3.2.3 Análise da Estabilidade Robusta do Sistema de Controle Nebuloso

A fim de garantir a estabilidade robusta do sistema, serão propostos nesta seção os seguintes teoremas para análise das condições necessárias e suficientes ao projeto do controlador PID nebuloso baseado nas especificações das margens de ganho e fase no domínio do tempo contínuo:

Teorema 1: Cada subcontrolador PID robusto $G_c^j(s) \mid^{[j=1,2,\dots,l]}$, no espaço do consequente da base de regras do controlador PID nebuloso TS, garante estabilidade para o respectivo submodelo linear $G_p^i(s) \mid^{[i=1,2,\dots,l]}$, no espaço do consequente da base de regras do modelo nebuloso TS do sistema dinâmico não-linear a ser controlado, ou seja, quando $i = j$.

Prova: A função de transferência a malha fechada é dada por:

$$G_{MF}^i(s) = \frac{\sum_i^l \gamma_i G_c^i(s) G_p^i(s)}{1 + \sum_i^l \gamma_i G_c^i(s) G_p^i(s)} \quad (3.27)$$

$$G_{MF}^i(s) = \frac{\sum_i^l \gamma_i \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} \frac{K_c^i}{a^i s^2 + b^i s + 1} e^{-Ls}}{1 + \sum_i^l \gamma_i \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} \frac{K_c^i}{a^i s^2 + b^i s + 1} e^{-Ls}} \quad (3.28)$$

em que:

$$\sum_{i=1}^l \gamma_i (G_{MF}^i(s), s) = 1 \quad (3.29)$$

De acordo com a Seção 2.1.2 e supondo a aproximação de Padè de segunda ordem para o atraso puro de tempo da planta a ser controlada, a função de transferência do sistema de controle nebuloso em malha-fechada, é dada por:

$$G_{MF}^i(s) = \frac{\sum_i^l \gamma_i \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} \frac{K_c^i}{a^i s^2 + b^i s + 1} e^{-Ls}}{1 + \sum_i^l \gamma_i \frac{K_d^i s^2 + K_p^i s + K_i^i}{s} \frac{K_c^i}{a^i s^2 + b^i s + 1} \frac{L^2 s^2 - 6Ls + 12}{L^2 s^2 + 6Ls + 12}}$$

$$= \frac{\sum_i^l \gamma_i (K_d^i s^2 + K_p^i s + K_i^i) K_c^i (L^2 s^2 - 6Ls + 12)}{(s(a^i s^2 + b^i s + 1)(L^2 s^2 + 6Ls + 12)) + (\sum_i^l \gamma_i (K_d^i s^2 + K_p^i s + K_i^i) K_c^i (L^2 s^2 - 6Ls + 12))} \quad (3.30)$$

O critério de Routh (FRANKLIN; POWELL; BAEINI, 2002) (OGATA, 2010) (SHINNERS, 1998) (FRIEDLAND, 2005) é um dos métodos para testar estabilidade do sistema. Para a condição de estabilidade, a equação característica da função de transferência, dada pela equação 3.30, deve possuir todas as raízes (pólos) no lado esquerdo do semiplano complexo (parte real negativa). Portanto, a equação característica resulta em:

$$(L^2 a^i) s^5 + (6L a^i + L^2 b^i + L^2 \gamma^i k_d^i k_c^i) s^4 + (12a^i + 6Lb^i + L^2 + L^2 \gamma^i k_c^i k_p^i - 6L \gamma^i k_d^i k_c^i) s^3 + (6L + 12b^i + 12\gamma^i k_d^i k_c^i + L^2 \gamma^i k_i^i k_c^i - 6L \gamma^i k_c^i k_p^i) s^2 + (12\gamma^i k_c^i k_p^i - 6L \gamma^i k_i^i k_c^i + 12) s + 12\gamma^i k_i^i k_c^i = 0 \quad (3.31)$$

Para garantir a estabilidade, todos os elementos da primeira coluna da matriz de coeficientes devem ser positivos. Pode-se observar a matriz de coeficientes, como segue:

$$\begin{array}{l} s^5 : \quad L^2 a^i \quad 12a^i + 6Lb^i + L^2 + L^2 \gamma^i k_c k_p - 6L \gamma^i k_d k_c \quad 12\gamma^i k_c^i k_p^i - 6L \gamma^i k_i^i k_c^i + 12 \\ s^4 : \quad 6La^i + L^2 b^i + L^2 \gamma^i k_d^i k_p^i \quad 6L + 12b^i + 12\gamma^i k_d^i k_c^i - 6L \gamma^i k_c^i k_p^i + L^2 \gamma^i k_i^i k_c^i \quad 12\gamma^i k_i^i k_c^i \\ s^3 : \quad B_1 \quad B_2 \\ s^2 : \quad C_1 \quad C_2 \\ s^1 : \quad D_1 \quad 0 \\ s^0 : \quad E_1 \end{array}$$

na qual:

$$B_1 = \frac{(6La^i + L^2 b^i + L^2 \gamma^i k_d^i k_p^i)(12a^i + 6Lb^i + L^2 + L^2 \gamma^i k_c k_p - 6L \gamma^i k_d k_c)}{6La^i + L^2 b^i + L^2 \gamma^i k_d^i k_p^i} - \frac{(L^2 a^i)(6L + 12b^i + 12\gamma^i k_d^i k_c^i - 6L \gamma^i k_c^i k_p^i + L^2 \gamma^i k_i^i k_c^i)}{6La^i + L^2 b^i + L^2 \gamma^i k_d^i k_p^i} \quad (3.32)$$

$$B_2 = \frac{((6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i)(12\gamma^i k_c^i k_p^i - 6L\gamma^i k_i^i k_c^i + 12)) - ((L^2a^i)(12\gamma^i k_i^i k_c^i))}{6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i} \quad (3.33)$$

$$C_1 = \frac{(B_1(6L + 12b^i + 12\gamma^i k_d^i k_c^i - 6L\gamma^i k_c^i k_p^i + L^2\gamma^i k_i^i k_c^i)) - ((6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i)B_2)}{B_1} \quad (3.34)$$

$$C_2 = 12\gamma^i k_c^i k_i^i \quad (3.35)$$

$$D_1 = \frac{C_1 B_2 - B_1 C_2}{C_1} \quad (3.36)$$

$$E_1 = C_2 = 12\gamma^i k_c^i k_i^i \quad (3.37)$$

Uma vez que todos os termos da primeira coluna devem ser positivos, tem-se as seguintes restrições:

$$L^2 a^i > 0 \quad (3.38)$$

$$6La^i + L^2b^i + L^2k_d^i k_p^i > 0 \quad (3.39)$$

$$B_1 > 0$$

$$\frac{(6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i)(12a^i + 6Lb^i + L^2 + L^2\gamma^i k_c k_p - 6L\gamma^i k_d^i k_c^i)}{6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i} - \frac{(L^2 a^i)(6L + 12b^i + 12\gamma^i k_d^i k_c^i - 6L\gamma^i k_c^i k_p^i + L^2\gamma^i k_i^i k_c^i)}{6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i} > 0 \quad (3.40)$$

$$C_1 > 0$$

$$\frac{(B_1(6L + 12b^i + 12\gamma^i k_d^i k_c^i - 6L\gamma^i k_c^i k_p^i + L^2\gamma^i k_i^i k_c^i)) - ((6La^i + L^2b^i + L^2\gamma^i k_d^i k_p^i)B_2)}{B_1} > 0 \quad (3.41)$$

$$\begin{aligned} D_1 &> 0 \\ \frac{C_1 B_2 - B_1 C_2}{C_1} &> 0 \end{aligned} \quad (3.42)$$

$$\begin{aligned} E_1 &> 0 \\ 12\gamma^i k_i^i k_c^i &> 0 \end{aligned} \quad (3.43)$$

Segundo o critério de Routh, para que o sistema seja estável é necessário que as Equações (3.38) a (3.43) sejam satisfeitas. Sabendo que L (atraso puro de tempo) e os ganhos K_p^i , K_i^i , K_d^i e K_c^i são positivos, então para que a Equação (3.38) seja maior que zero, a^i tem que ser positivo e para que a Equação (3.39) seja maior que zero, b^i tem que ser positivo. Se todos os parâmetros (L , K_p^i , K_i^i , K_d^i , K_c^i , a^i , b^i) forem positivos, K_p for muito maior que os demais ganhos e b^i muito maior que a^i as desigualdades em (3.41) a (3.42), que se referem as condições de estabilidade, são satisfeitas, e cada sub-controlador PID robusto garante a estabilidade para todos os sub-modelos da planta a ser controlada, para o caso $i = j$.

Teorema 2: O controlador PID nebuloso robusto, $G_c(\tilde{y}(t), j\omega)$, garante as especificações das margens de ganho e fase ao sistema de controle nebuloso.

Prova: Na prova deste teorema serão considerados dois casos particulares: **Ativação de uma única regra** e **Ativação de mais de uma regra (região intermediária)**

Ativação de uma única regra

A partir das Equações (3.23) e (3.24), a margem de ganho do sistema de controle nebuloso, é dada por:

$$\begin{aligned} \arg[\lambda_{F^1} G_c^{F^1}(\tilde{y}(t), j\omega_p) G_p^{F^1}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \dots \\ \dots + \lambda_{F^l} G_c^{F^l}(\tilde{y}(t), j\omega_p) G_p^{F^l}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}] = -\pi \end{aligned} \quad (3.44)$$

$$A_m = \frac{1}{A_{mD}} \quad (3.45)$$

onde A_{mD} , corresponde ao denominador da Equação 3.28 dada por:

$$A_{mD} = |\lambda_{F^1} G_c^{F^1}(\tilde{y}(t), j\omega_p) G_p^{F^1}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \dots + \lambda_{F^l} G_c^{F^l}(\tilde{y}(t), j\omega_p) G_p^{F^l}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}| \quad (3.46)$$

e l corresponde ao número de regras do modelo e consequentemente do controlador nebuloso TS.

Sabendo que a estrutura do sistema de inferência nebuloso TS implica na soma ponderada dos submodelos do consequente, ou seja, $\sum_{i=1}^l \lambda_i = 1$, ativando uma única regra p , conforme mostra a Figura 3.2, o grau de ativação desta regra é igual a um, enquanto que o grau de ativação das outras regras são iguais a zero. Dessa forma, para a ativação somente da regra p ($\lambda_{F^p} = 1$) as Equações




Figura 3.2: Grau de ativação para a condição de uma regra ativada

(3.44) e (3.45) podem ser reescritas da seguinte forma:

$$\begin{aligned} & \arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}] = \\ & \arg[0 \cdot G_c^{F^1}(\tilde{y}(t), j\omega_p) G_p^{F^1}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \dots \\ & + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \dots \\ & + 0 \cdot G_c^{F^l}(\tilde{y}(t), j\omega_p) G_p^{F^l}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}] \end{aligned} \quad (3.47)$$

e

$$\begin{aligned}
 & |G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}| = \\
 & |0 \cdot G_c^{F^1}(\tilde{y}(t), j\omega_p) G_p^{F^1}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \dots \\
 & + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \dots \\
 & + 0 \cdot G_c^{F^l}(\tilde{y}(t), j\omega_p) G_p^{F^l}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}| \quad (3.48)
 \end{aligned}$$

Considerando o respectivo submodelo linear, na regra p , e sabendo que cada subcontrolador PID garante a especificação de margem de ganho, em ω_p , tem-se:

$$\begin{aligned}
 \arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}] &= \arg[G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}] \\
 -\pi &= -\pi \quad (3.49)
 \end{aligned}$$

e

$$\begin{aligned}
 |G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}| &= |G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p}| \\
 \frac{1}{A_m} &= -\frac{1}{A_m} \quad c.q.d. \quad (3.50)
 \end{aligned}$$

A partir das Equações (3.25) e (3.26), a margem de fase do sistema resulta em:

$$\begin{aligned}
 & |\lambda_{F^1} G_c^{F^1}(\tilde{y}(t), j\omega_g) G_p^{F^1}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g} + \dots \\
 & + \lambda_{F^l} G_c^{F^l}(\tilde{y}(t), j\omega_g) G_p^{F^l}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}| = 1 \quad (3.51)
 \end{aligned}$$

e

$$\begin{aligned}
 \phi_m &= \arg[\lambda_{F^1} G_c^{F^1}(\tilde{y}(t), j\omega_g) G_p^{F^1}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}] + \dots \\
 & + \lambda_{F^l} G_c^{F^l}(\tilde{y}(t), j\omega_g) G_p^{F^l}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g} + \pi \quad (3.52)
 \end{aligned}$$

na qual l corresponde ao número de regras do modelo e consequentemente do controlador nebuloso TS.

Para a ativação somente da regra p ($\lambda_{F^p} = 1$), as Equações 3.34 e 3.35 podem ser reescritas da seguinte forma:

$$\begin{aligned}
& |G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}| = \\
& |0 \cdot G_c^{F^1}(\tilde{y}(t), j\omega_g) G_p^{F^1}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g} + \dots \\
& + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g} + \dots \\
& + 0 \cdot G_c^{F^l}(\tilde{y}(t), j\omega_g) G_p^{F^l}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}| \quad (3.53)
\end{aligned}$$

e

$$\begin{aligned}
& \arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}] = \\
& \arg[0 \cdot G_c^{F^1}(\tilde{y}(t), j\omega_g) G_p^{F^1}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g} + \dots \\
& + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g} + \dots \\
& + 0 \cdot G_c^{F^l}(\tilde{y}(t), j\omega_g) G_p^{F^l}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}] \quad (3.54)
\end{aligned}$$

Considerando o respectivo submodelo linear, na regra p , e sabendo que cada subcontrolador PID garante a especificação de margem de ganho, em ω_g , tem-se:

$$\begin{aligned}
|G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}| &= |G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}| \\
&= 1 \quad (3.55)
\end{aligned}$$

e

$$\begin{aligned}
\arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}] &= \arg[G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}] \\
\phi_m - \pi &= \phi_m - \pi \\
\phi_m &= \phi_m \quad (c.q.d.) \quad (3.56)
\end{aligned}$$

Ativação de mais de uma regra (região intermediária)

Na Figura 3.3, observa-se que quando mais de uma regra é ativada tem-se duas funções de pertinência contribuindo com seus respectivos graus de pertinência (F^{λ_p} e $F^{\lambda_{p+1}}$).

Visto que a estrutura do sistema de inferência nebuloso TS implica na soma poderada dos sub-




Figura 3.3: Grau de ativação para a condição de mais de uma regra (região intermediária)

modelos do consequente, ou seja, $\sum_{i=1}^n \lambda_i = 1$, então o somatório dos graus de ativação destas regras é igual a 1 (um), enquanto que o grau de ativação das outras regras serão iguais a 0 (zero).

No contexto nebuloso, a partir das Equações (3.23) e (3.24), a margem de ganho do sistema de controle para ativação de duas regras, F^p e F^{p+1} , é dada por:

$$\begin{aligned} & \arg[0 + \dots + 0 + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \\ & + \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + 0 \dots + 0] = -\pi \end{aligned} \quad (3.57)$$

$$A_m = \frac{1}{A_{m_{D1}}} \quad (3.58)$$

na qual $A_{m_{D1}}$ na Equação (3.58) é dado por:

$$\begin{aligned} A_{m_{C1}} = & |0 + \dots + 0 + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + \\ & + \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p) e^{-Lj\omega_p} + 0 \dots + 0| \end{aligned} \quad (3.59)$$

As Equações (3.57) e (3.58) pode ser reescritas da seguinte forma:

$$\begin{aligned} & \arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}] = \\ & \arg[\lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p} + \\ & + \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}] \end{aligned} \quad (3.60)$$

e

$$\begin{aligned} & |G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| = \\ & |\lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p} + \\ & + \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| \end{aligned} \quad (3.61)$$

A equação do submodelo e controlador correspondente, pode ser representada em termos de módulo e fase (FRANKLIN; POWELL; WORKMAN, 1997), como segue:

$$G_c G_p e^{-Ls} = |G_c G_p e^{-Ls}| e^{j\omega_p \phi} \quad (3.62)$$

e, de acordo com a propriedade do somatório dos módulos, tem-se (CARMO; MORGADO; WAGNER, 2001) (AMORIM, 2006):

$$|c| \leq |a| + |b| \quad (3.63)$$

Substituindo as equações (3.62) e (3.63) em (3.60) e (3.61), respectivamente, tem-se:

$$\begin{aligned} & \arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}] = \\ & \arg[|\lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| e^{j\omega_p \phi_p} + \\ & + |\lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| e^{j\omega_p \phi_{p+1}}] e \end{aligned} \quad (3.64)$$

$$\begin{aligned} & |G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| \leq \\ & |\lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| + \\ & + |\lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| \end{aligned} \quad (3.65)$$

Uma vez que λ_{F^p} e $\lambda_{F^{p+1}}$ assumem valores positivos, tem-se:

$$\begin{aligned}
 & \arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}] = \\
 & \arg[\lambda_{F^p}|G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}|e^{j\omega_p\phi_p} + \\
 & + \lambda_{F^{p+1}}|G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}|e^{j\omega_p\phi_{F^{p+1}}}] \quad (3.66)
 \end{aligned}$$

e

$$\begin{aligned}
 & |G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| \leq \\
 & \lambda_{F^p}|G_c^{F^p}(\tilde{y}(t), j\omega_p) G_p^{F^p}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| + \\
 & + \lambda_{F^{p+1}}|G_c^{F^{p+1}}(\tilde{y}(t), j\omega_p) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| \quad (3.67)
 \end{aligned}$$

Uma vez que cada subcontrolador PID garante a especificação da margem de ganho em ω_p , considerando o respectivo modelo linear das regras p e $p + 1$, tem-se:

$$\arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}] = \arg[\lambda_{F^p} \frac{1}{A_m} e^{j\omega_p\phi_{F^p}} + \lambda_{F^{p+1}} \frac{1}{A_m} e^{j\omega_p(\phi_{F^{p+1}})}] \quad (3.68)$$

$$|G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| \leq \lambda_{F^p} \frac{1}{A_m} + \lambda_{F^{p+1}} \frac{1}{A_m} \quad (3.69)$$

desde que $\lambda_{F^p} + \lambda_{F^{p+1}} = 1$ e, conforme observado na Figura 3.4, -180° , 0° e 180° são ângulos congruentes, resulta que:




Figura 3.4: Comportamento da função trigonométrica tangente

$$\begin{aligned}
arg[G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}] &= arg[\lambda_{F^p} \frac{1}{A_m} \cdot 0 + \lambda_{F^{p+1}} \frac{1}{A_m} \cdot 0] \\
-\pi &= arg[0] \\
-\pi &= -\pi \quad (c.q.d.)
\end{aligned} \tag{3.70}$$

e

$$\begin{aligned}
|G_c(\tilde{y}(t), j\omega_p) G_p(\tilde{y}(t), j\omega_p)e^{-Lj\omega_p}| &\leq (\lambda_{F^p} + \lambda_{F^{p+1}}) \frac{1}{A_m} \\
\frac{1}{A_m} &\leq 1 \cdot \frac{1}{A_m} \\
\frac{1}{A_m} &= \frac{1}{A_m} \quad (c.q.d.)
\end{aligned} \tag{3.71}$$

A partir das Equações (3.25) e (3.26), a margem de fase do sistema de controle nebuloso, para a ativação de duas regras, F^p e F^{p+1} , é dada por:

$$\begin{aligned}
|0 + \dots + 0 \cdot \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + \\
+ \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_g) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + 0 + \dots + 0| &= 1
\end{aligned} \tag{3.72}$$

$$\begin{aligned}
\phi_m &= arg[0 + \dots + 0 + \lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + \\
&\lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_g) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + 0 + \dots + 0] + \pi
\end{aligned} \tag{3.73}$$

As Equações (3.72) e (3.73) podem ser reescritas da seguinte forma:

$$\begin{aligned}
|G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| &= \\
|\lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + \\
+ \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_g) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| &
\end{aligned} \tag{3.74}$$

e

$$\begin{aligned}
arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}] &= \\
arg[\lambda_{F^p} G_c^{F^p}(\tilde{y}(t), j\omega_g) G_p^{F^p}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + \\
+ \lambda_{F^{p+1}} G_c^{F^{p+1}}(\tilde{y}(t), j\omega_g) G_p^{F^{p+1}}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}] &
\end{aligned} \tag{3.75}$$

Utilizando a propriedade para somatório de módulos da Equações (3.63) na Equação (3.74) e a representação por módulo e fase da Equação (3.62) na Equação (3.75), tem-se:

$$\begin{aligned}
 & |G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| \leq \\
 & |\lambda_{Fp}G_c^{Fp}(\tilde{y}(t), j\omega_g) G_p^{Fp}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g} + \\
 & + \lambda_{Fp+1}G_c^{Fp+1}(\tilde{y}(t), j\omega_g) G_p^{Fp+1}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| \quad (3.76)
 \end{aligned}$$

e

$$\begin{aligned}
 & arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}] \leq \\
 & arg[|\lambda_{Fp}G_c^{Fp}(\tilde{y}(t), j\omega_g) G_p^{Fp}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}|e^{j\omega_p\phi_{Fp}} + \\
 & + |\lambda_{Fp+1}G_c^{Fp+1}(\tilde{y}(t), j\omega_g) G_p^{Fp+1}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}|e^{j\omega_p\phi_{Fp+1}}] \quad (3.77)
 \end{aligned}$$

Uma vez que λ_{Fp} e λ_{Fp+1} assumem valores positivos, tem-se:

$$\begin{aligned}
 & |G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| \leq \\
 & \lambda_{Fp}|G_c^{Fp}(\tilde{y}(t), j\omega_g) G_p^{Fp}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| + \\
 & + \lambda_{Fp+1}|G_c^{Fp+1}(\tilde{y}(t), j\omega_g) G_p^{Fp+1}(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| \quad (3.78)
 \end{aligned}$$

e

$$\begin{aligned}
 & arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}] = \\
 & arg[\lambda_{Fp}|G_c^{Fp}(\tilde{y}(t), j\omega_g) G_p^{Fp}e^{-Lj\omega_g}|e^{j\omega_g\phi_{Fp}} + \\
 & + \lambda_{Fp+1}|G_c^{Fp+1}(\tilde{y}(t), j\omega_g) G_p^{Fp+1}e^{-Lj\omega_g}|e^{j\omega_g\phi_{Fp+1}}] \quad (3.79)
 \end{aligned}$$

Uma vez que cada subcontrolador PID garante a especificação da margem de fase, em ω_g , considerando o respectivo submodelo das regras ϕ_{Fp} e ϕ_{Fp+1} , tem-se:

$$|G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}| \leq \lambda_{Fp}.1 + \lambda_{Fp+1}.1 \quad (3.80)$$

e

$$arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g)e^{-Lj\omega_g}] = arg[\lambda_{Fp}.e^{j\omega_g\phi_{Fp}} + \lambda_{Fp+1}.e^{j\omega_g\phi_{Fp+1}}] \quad (3.81)$$

desde que $\lambda_{F^p} + \lambda_{F^{p+1}} = 1$ e $\phi_{F^p} = \phi_{F^{p+1}}$, tem-se:

$$\begin{aligned} |G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}| &\leq (\lambda_{F^p} + \lambda_{F^{p+1}}) \cdot 1 \\ 1 &= 1 \end{aligned} \quad (3.82)$$

e

$$\begin{aligned} \arg[G_c(\tilde{y}(t), j\omega_g) G_p(\tilde{y}(t), j\omega_g) e^{-Lj\omega_g}] &= \arg[(\lambda_{F^p} + \lambda_{F^{p+1}})j\omega_g] \\ \phi_m - \pi &= \phi_m - \pi \\ \phi_m &= \phi_m \quad (\text{c.q.d.}) \end{aligned} \quad (3.83)$$

3.3 Estratégia Genética Multiobjetiva para Projeto de Controlador PID Nebuloso TS

A otimização busca a minimização de uma função custo para que o problema seja resolvido. Entretanto, existem situações em que mais de um objetivo precisa ser atingido, ou seja, existe mais de uma função objetivo. Para esses tipos de situação, é necessária a utilização da chamada otimização multiobjetiva. A otimização multiobjetivo exige que as funções a serem otimizadas sejam conflitantes, ou seja, a melhora de uma implica na deteriorização da outra.

Existem muitos métodos para o tratamento de problemas de otimização multiobjetiva, e a grande maioria é desenvolvida com embasamento em duas estratégias principais: a construção de uma única função objetivo, por meio de uma relação matemática entre todas as funções objetivo envolvidas no problema (soma ponderada) e a busca pelo conjunto de soluções ótimas de Pareto.

Na soma ponderada das funções objetivo (relação matemática), estratégia usada nessa dissertação, a ideia é transformar a multiobjetividade em um único objetivo, para isso, as n funções objetivos são combinadas em uma única função. Uma das formas de fazer isto é atribuir pesos a cada uma das funções e somá-las, ficando da seguinte forma:

$$F = \sum_{n=1}^N \delta_n f_n \quad (3.84)$$

onde δ_n é o peso atribuído a função objetivo (f_n) e tem um valor no intervalo $[0, 1]$ sendo que $= \sum_{n=1}^N \delta_n = 1$. A Figura 3.5 mostra um esquema desse método.

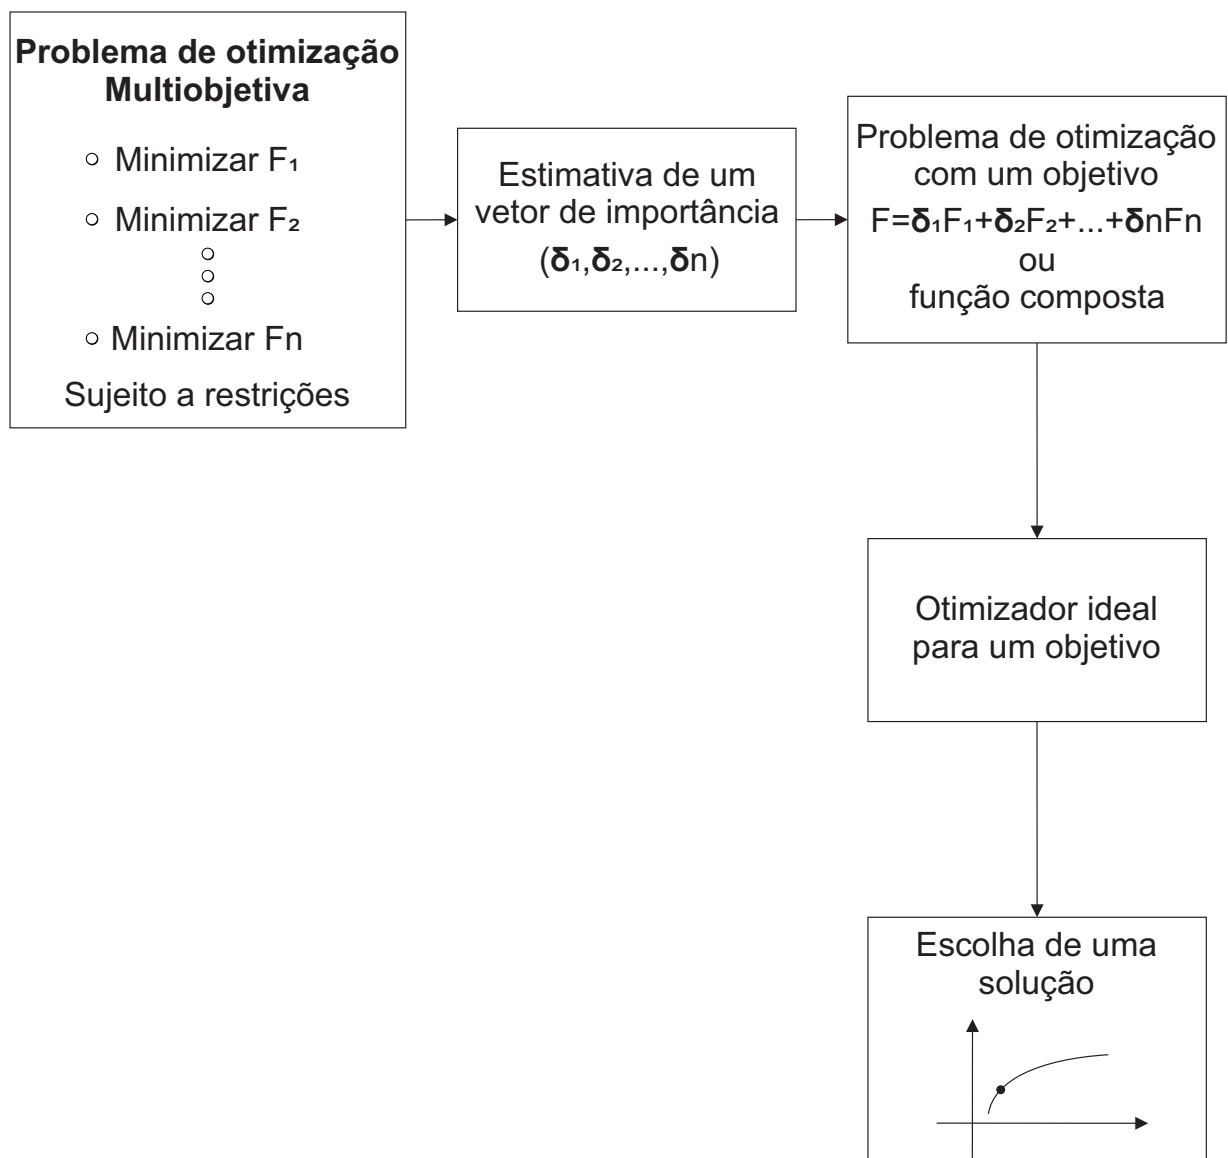


Figura 3.5: Esquema do método de otimização multiobjetiva - soma ponderada

Algoritmo genético (AG) é um método de busca e otimização baseado nos princípios da genética e seleção natural (HAUPT; HAUPT, 2004). O método de otimização multiobjetiva, é capaz de avaliar simultaneamente vários pontos no espaço de pesquisa e retomar a melhor solução ou um grupo das melhores soluções para o problema em questão. Como vantagens do AG pode-se citar: permite buscas simultâneas a partir de uma ampla superfície de custo, pode abranger um grande número de variáveis, otimiza problemas com variáveis contínuas ou discretas, tem como resultado uma lista das melhores variáveis e não uma solução única, trabalha com dados gerados experimentalmente, numericamente ou através de funções, entre outras.

Dentre as operações básicas de um AG temos a seleção que é o mecanismo que seleciona os

indivíduos mais aptos para reprodução, combinando seus alelos e proporcionando o surgimento de indivíduos mais aptos, o cruzamento (*crossover*), que é responsável pelo cruzamento entre cada parte de cromossomos e a geração dos descendentes e a operação de mutação, que é a alteração aleatória sobre as características de um gene.

Os algoritmos genéticos para resolução de problemas de otimização multiobjetiva, empenham-se em executar buscas no espaço objetivo e determinar as melhores soluções para problemas que tenham mais que um objetivo. São genericamente nomeados como Algoritmos Genéticos Multiobjetivos.

Nesta dissertação o AG multiobjetivo é utilizado para otimizar os ganhos do controlador PID nebuloso TS no domínio do tempo contínuo de acordo com as especificações das margens de ganho e fase e sua estrutura apresenta uma população inicial (primeira geração) composta por um conjunto de cromossomos N (resultando na matriz $N \times N_{var}$). Cada indivíduo (cromossomo) dessa população é um vetor de decisão em que todos os N_{var} elementos (genes) representam possíveis soluções para o problema. O número de gerações para um AG é idêntico ao número de iterações, que geralmente é definido pelo projetista do algoritmo antes do início da execução do algoritmo. Para cada geração, um determinado número de indivíduos é selecionado, baseado em um *ranking*, realizado a partir dos custos de cada indivíduo obtido de uma função custo multobjetivo, os quais, geram a descendência a partir da operação de combinação genética. A probabilidade de ocorrer o cruzamento entre indivíduos é determinada pela probabilidade de *crossover* (cruzamento). Em um dado instante, alguns dos indivíduos de uma geração sofre mutação para alteração de genes de maneira aleatória, permitindo buscas por soluções melhores e evitando a queda em mínimos locais. A probabilidade de ocorrer a mutação entre indivíduos é determinada pela probabilidade de mutação. A seguir, a estrutura do AG utilizada neste trabalho será apresentada.

Estratégia Genética Multiobjetiva para Projeto do Controlador Baseado em Modelo Nebuloso

Etapa 1 - Definir os parâmetros da planta a ser controlada (K_c^i, a^i, b^i).

Etapa 2 - Especificar os valores das margem de ganho e fase desejados ($A_{m(e)}, P_{m(e)}$).

Etapa 3 - Definir os parâmetros do AG: número de gerações, número de genes, número de indivíduos da população (N), função de custo (f), Probabilidade de *crossover* (T_c) e Probabilidade de Mutação (T_M).

Etapa 4 - Gerar população inicial:

$$cromossomo_1 = [K_{p1}^1 K_{i1}^1 K_{d1}^1 K_{p2}^1 K_{i2}^1 K_{d2}^1]$$

$$cromossomo_2 = [K_{p1}^2 K_{i1}^2 K_{d1}^2 K_{p2}^2 K_{i2}^2 K_{d2}^2]$$

⋮

$$cromossomo_N = [K_{p1}^N K_{i1}^N K_{d1}^N K_{p2}^N K_{i2}^N K_{d2}^N]$$

onde K_p é o ganho proporcional, K_i é o ganho integral e K_d é o ganho derivativo.

Etapa 5 - Obter as margens de ganho e fase de cada indivíduo:

A margem de ganho é obtida por:

$$\arg[G_c(j\omega_p)G_p(j\omega_p)] = -\pi$$

$$A_m = \frac{1}{G_c(j\omega_p)G_p(j\omega_p)}$$

onde G_c é a função de transferência do controlador, G_p é a função de transferência da planta.

A margem de fase é obtida por:

$$|G_c(j\omega_g)G_p(j\omega_g)| = 1$$

$$\phi_m = \arg[G_c(j\omega_g)G_p(j\omega_g)] + \pi$$

onde G_c é a função de transferência do controlador, G_p é a função de transferência da planta.

Etapa 6 - Calcular os custos(aptidão) de cada cromossomo:

$$f_1 = (\gamma_1|A_{o1}^1 - A_e^1| + \gamma_2|P_{o1}^1 - P_e^1|) + (\gamma_1|A_{o2}^1 - A_e^1| + \gamma_2|P_{o2}^1 - P_e^1|)$$

$$f_2 = (\gamma_1|A_{o1}^2 - A_e^2| + \gamma_2|P_{o1}^2 - P_e^2|) + (\gamma_1|A_{o2}^2 - A_e^2| + \gamma_2|P_{o2}^2 - P_e^2|)$$

⋮

$$f_N = (\gamma_1|A_{o1}^N - A_e^N| + \gamma_2|P_{o1}^N - P_e^N|) + (\gamma_1|A_{o2}^N - A_e^N| + \gamma_2|P_{o2}^N - P_e^N|)$$

onde $\gamma_1 + \gamma_2 = 1$, A_o é a margem de ganho obtida, A_e é a margem de ganho especificada, P_o é a margem de fase obtida e P_e é a margem de fase especificada.

Etapa 7 - Classificar os cromossomos de acordo com os seus custos(aptidão):

$$\begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_N \end{bmatrix}$$

Etapa 8 - Selecionar os melhores cromossomos da população gerada (N_c) pela seleção em roleta por posição e por torneios

$$[N_c] = [T_c * N]$$

Etapa 9 - Aplicar o operador de *crossover* aritmético:

$$descendente_1 = \eta \times ([K_{p_1}^1 K_{i_1}^1 K_{d_1}^1 K_{p_2}^1 K_{i_2}^1 K_{d_2}^1]) + (1 - \eta) \times ([K_{p_1}^2 K_{i_1}^2 K_{d_1}^2 K_{p_2}^2 K_{i_2}^2 K_{d_2}^2])$$

$$descendente_2 = \eta \times ([K_{p_1}^2 K_{i_1}^2 K_{d_1}^2 K_{p_2}^2 K_{i_2}^2 K_{d_2}^2]) + (1 - \eta) \times ([K_{p_1}^1 K_{i_1}^1 K_{d_1}^1 K_{p_2}^1 K_{i_2}^1 K_{d_2}^1])$$

⋮

$$descendente_{N_{c-1}} = \eta \times ([K_{p_1}^{N_{c-1}} K_{i_1}^{N_{c-1}} K_{d_1}^{N_{c-1}} K_{p_2}^{N_{c-1}} K_{i_2}^{N_{c-1}} K_{d_2}^{N_{c-1}}]) + (1 - \eta) \times ([K_{p_1}^N K_{i_1}^N K_{d_1}^N K_{p_2}^N K_{i_2}^N K_{d_2}^N])$$

$$descendente_{N_c} = \eta \times ([K_{p_1}^N K_{i_1}^N K_{d_1}^N K_{p_2}^N K_{i_2}^N K_{d_2}^N]) + (1 - \eta) \times ([K_{p_1}^{N_{c-1}} K_{i_1}^{N_{c-1}} K_{d_1}^{N_{c-1}} K_{p_2}^{N_{c-1}} K_{i_2}^{N_{c-1}} K_{d_2}^{N_{c-1}}])$$

Etapa 10 - Selecionar os genes para mutação:

$$T_M \times \text{descendentes} = I_M$$

Etapa 11 - Aplicar o operador de mutação sobre os descendentes:

$$\text{descendente}_1 = [K_{p_1}^{1mut} K_{i_1}^1 K_{d_1}^{1mut} K_{p_2}^1 K_{i_2}^1 K_{d_2}^{1mut}]$$

$$\text{descendente}_2 = [K_{p_1}^2 K_{i_1}^{2mut} K_{d_1}^2 K_{p_2}^2 K_{i_2}^{2mut} K_{d_2}^2]$$

⋮

$$\text{descendente}_{I_N} = [K_{p_1}^{Nmut} K_{i_1}^N K_{d_1}^N K_{p_2}^{Nmut} K_{i_2}^N K_{d_2}^N]$$

Etapa 12 - Formar a nova população com elitismo:

$$N_P = N_s + I_M$$

Etapa 13 - Calcular os custos(aptidão) de cada indivíduo na nova população:

$$f_{Nova1} = \gamma_1 |A_{ONova}^{Nova1} - A_{eNova}^{Nova1}| + \gamma_2 |P_{ONova}^{Nova1} - P_{eNova}^{Nova1}|$$

$$f_{Nova2} = \gamma_1 |A_{ONova}^{Nova2} - A_{eNova}^{Nova2}| + \gamma_2 |P_{ONova}^{Nova2} - P_{eNova}^{Nova2}|$$

⋮

$$f_{NovaN} = \gamma_1 |A_{ONova}^{NovaN} - A_{eNova}^{NovaN}| + \gamma_2 |P_{ONova}^{NovaN} - P_{eNova}^{NovaN}|$$

Etapa 14 - Checar Convergência:

Caso o critério de parada tenha sido satisfeito, encerrar.

Caso Contrário, voltar ao **Passo4**.

Neste capítulo foi apresentada a estrutura do modelo nebuloso Takagi- Sugeno, a estimação dos parâmetros do antecedente e do consequente. Posteriormente, apresentou-se a estrutura do controlador PID nebuloso TS e foi feita a análise das condições necessárias e suficientes para desenvolvimento

do projeto do controlador nebuloso com estabilidade robusta propondo dois teoremas. Por fim, a estratégia genética foi utilizada para descobrir os valores dos parâmetros do controlador PID nebuloso, a fim de atingir, de forma otimizada, os valores especificados de margem de ganho e fase do sistema de controle nebuloso em malha fechada.

Capítulo 4

Resultados Experimentais

Neste capítulo é descrita a plataforma de controle em tempo real. Em seguida são apresentadas as etapas para obtenção e validação do modelo nebuloso Takagi-Sugeno para a planta térmica, o projeto de controle nebuloso simulado e aplicado em uma planta térmica, bem como a validação experimental dos teoremas propostos no Capítulo 3. Neste capítulo, também é feita uma comparação do controlador proposto com outros compensadores.

4.1 Descrição da Plataforma de Controle em Tempo Real

A plataforma usada para aquisição de dados experimentais para identificação do modelo nebuloso da planta térmica e implementação do controlador PID nebuloso é baseada no *Software LabVIEW (Laboratory Virtual Engineering Workbench)* e na controladora *CompactRIO 9073*. A *CompactRIO 9073* consiste na integração de um controlador industrial de tempo real e um FPGA (*Field Programmable Gate Arrays*). O *hardware* deste controlador é composto de: chassi com oito slots, portas de entrada e saída (para a configuração de tempo, controle e processamento), porta *Ethernet* de 10/100 BASE-T, porta serial (para conexão de periféricos), processador de tempo real (266MHz) e FPGA reconfigurável embutido. O *LabVIEW* (LARSEN, 2011) é um sistema supervisor baseado em linguagem de programação gráfica que foi utilizado para a coleta dos dados de entrada (tensão de entrada, em rms) e saída (temperatura, em graus Celsius) em tempo real. A planta térmica utilizada para implementação da plataforma de controle consiste em uma torradeira comercial monofásica que funciona em corrente alternada. A entrada desta planta é a tensão elétrica de 220V e a saída é a temperatura que varia no intervalo de $25^{\circ}C$ a $265^{\circ}C$. Como sensor de temperatura foi utilizado o LM35 que é um circuito integrado fabricado pela *National Semiconductors*, e tem como saída uma tensão linearmente proporcional à temperatura em graus Celsius, com sensibilidade de $10mV/^{\circ}C$. Esse sensor precisa ser acoplado a um módulo de entrada analógica, o *NI 9219*, que recebe o valor de tensão do sensor

de temperatura para ser processado pela plataforma e comparado com a temperatura de referência. A partir da temperatura aferida, um sinal de erro é calculado (resultado do valor desejado subtraído do valor obtido). Este sinal é utilizado para definir a atuação do controlador nebuloso implementado no *LabVIEW*, que utiliza um módulo de saída analógica, neste caso o NI 9263, para enviar o sinal de controle para a planta, podendo variar de 0V a 8V. Especificamente, este sinal de controle é enviado para um atuador, o circuito integrado *TCA 785*, que controla o ângulo de disparo dos tiristores, TRIACS e transistores. Os pulsos de disparo podem ser deslocados dentro de um ângulo de fase de 0° e 180° , garantindo ampla faixa de controle em circuitos de Corrente Alternada. No sistema de controle de temperatura apresentado nesta dissertação, o *TCA 785* deve modificar o ângulo de disparo do TRIAC TIC 226D e, conseqüentemente, obter o controle da temperatura a partir da variação da potência aplicada ao processo térmico (ALMEIDA, 2007). Na Figura 4.1, pode ser observado o diagrama da plataforma do sistema de controle do processo térmico em tempo real.




Figura 4.1: Diagrama da plataforma utilizada para supervisão e controle do processo térmico.

4.2 Modelagem Nebulosa TS da Planta Térmica

O modelo obtido é uma representação aproximada da planta (AGUIRRE, 2007). Para obtenção de um modelo existem algumas etapas necessárias, entre elas destacam-se: realização do experimento na planta, definição da estrutura do modelo, definição da ordem do modelo, estimação paramétrica,

validação do modelo obtido e ajuste fino do modelo (AGUIRRE, 2007).

Nesta dissertação, a modelagem nebulosa TS está baseada em dados experimentais (coletados para etapa de identificação) de entrada (correspondente a tensão RMS - *Root Mean Square*) e saída (correspondente a temperatura em $^{\circ}C$) da planta térmica obtidos através de experimentos em malha aberta realizados com a plataforma de controle. Na Figura 4.2 são observados os sinais de entrada (a) e saída (b) utilizado na etapa de identificação.




Figura 4.2: Dados utilizados na etapa de identificação da planta térmica. A tensão alternada, representada pelo seu valor eficaz (tensão)(a), é aplicada à planta cuja resposta temporal é a temperatura, em graus Celsius (b).

4.2.1 Estimação Paramétrica e Obtenção do Modelo Nebuloso TS

O algoritmo de agrupamento *Fuzzy C-Means* (FCM) e o método dos mínimos quadrados ponderados foram usados para estimação dos parâmetros do antecedente e do consequente do modelo nebuloso TS da planta térmica, respectivamente. O FCM utilizado possui expoente de ponderação $m = 1.5$, tolerância de $\epsilon = 0.01$ e dois agrupamentos (*clusters*). As funções de pertinência forne-

cidas pelo algoritmo FCM são mostradas na Figura 4.3. Elas correspondem ao grau de ativação dos dois submodelos lineares a serem obtidos para representação da planta térmica, isto significa que, um submodelo deve representar as regiões de baixa temperatura e outro a região de altas temperaturas, enquanto que as temperaturas intermediárias são representadas pelos dois submodelos com a ponderação dos seus graus de pertinência. Assim, a base de regras do modelo nebuloso TS da planta




Figura 4.3: Funções de pertinência obtidas pelo algoritmo de agrupamento nebuloso FCM a partir dos dados experimentais de entrada e saída da planta térmica. F^1 representa o grau de ativação do submodelo para primeira regra e F^2 representa o grau de ativação do submodelo para segunda regra

térmica é dada por:

R^1 : Se Temperatura é F^1 , ENTÃO :

$$G_p^1(s) = \frac{1.3311}{15.51s^2 + 4043s + 1} \quad (4.1)$$

R^2 : Se Temperatura é F^2 , ENTÃO :

$$G_p^2(s) = \frac{1.077}{45.91s^2 + 2730s + 1} \quad (4.2)$$

onde as regiões F^1 e F^2 podem ser representadas por funções de pertinência dadas por:

$$F^1(Temperatura, a, b)|_{a=105.3; b=121.1} =$$

$$\begin{cases} 1 & Temperatura \leq a \\ 1 - 2\left(\frac{Temperatura - a}{b - a}\right)^2, & a \leq Temperatura \leq \frac{a+b}{2} \\ 2\left(\frac{Temperatura - a}{b - a}\right)^2, & \frac{a+b}{2} \leq Temperatura \leq b \\ 0, & Temperatura \geq b \end{cases} \quad (4.3)$$

$$e F^2 = 1 - F^1.$$

4.2.2 Estimação do Atraso Puro de Tempo

O submodelo para representar de forma completa a planta térmica tem que incorporar o atraso puro de tempo que pode ser estimado de várias formas, entre elas citam-se: partir da simples observação da resposta ao degrau da planta térmica, isso quando pressupõe que o ruído presente é suficientemente baixo e outra forma seria um método estocástico FCC (Função de Correlação Cruzada) (HONGKAI; LIQING; CHAO, 2011) (TAMIM; GHANI, 2009) entre os sinais de entrada $u(t)$ e saída $y(t)$ da planta térmica, para casos em que o ruído é significativo ou requerem maior rigor. Nessa dissertação, o atraso puro de tempo será incorporado através da correlação cruzada entre os dados de entrada e saída da planta térmica.

A FCC entre dois sinais $u(t)$ e $y(t)$ é definida como (AGUIRRE, 2007):

$$r_{uy}(\tau, t) = E[u(t)y^*(t + \tau)] \quad (4.4)$$

Considerando o processo real, nesse caso $y^*(t) = y(t)$, ergótico, a fim de substituir a esperança matemática ($E[.]$) pela média temporal e supondo a estacionariedade, para eliminar a dependência da função de covariância cruzada com o tempo a FCC entre dois sinais resulta em:

$$r_{uy}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T u(t)y(t + \tau) dt \quad (4.5)$$

Uma maneira de estimar a função de correlação cruzada a partir de séries discretas no tempo é:

$$r_{uy}(k) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N u(n)y(n+k) \quad (4.6)$$

Desde que a resposta $y(k)$ de um sistema a uma entrada $u(k)$ é dada pelo somatório da convolução:

$$r_{uy}(k+n) = \sum_{r=0}^{\infty} h(r)u(r+n-r) \quad (4.7)$$

em que $h(r)$ é a resposta ao impulso do sistema no instante r . Substituindo a Equação (4.4) em (4.3), considerando o somatório pra $N = 0$ a $N = -\infty$ tem-se:

$$r_{uy}(k) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=0}^N u(n) \sum_{r=0}^{\infty} h(r)u(k+n-r) \quad (4.8)$$

uma vez que, assim como r , n váia de 0 a ∞ :

$$r_{uy}(k) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=0}^N u(n) \sum_{n=0}^{\infty} h(n)u(k) \quad (4.9)$$

reorganizando os termos , tem-se:

$$r_{uy}(k) = \sum_{n=0}^{\infty} h(n) \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=0}^N u(n)u(k) \quad (4.10)$$

ou:

$$r_{uy}(k) = \sum_{n=0}^{\infty} h(n)r_{uu}(k-n) \quad (4.11)$$

Na Figura 4.4 podem ser visto os dados de entrada e saída utilizados na correlação cruzada para obtenção do atraso puro de tempo para o submodelo 1, já na Figura 4.6 podem ser vistos os dados para o submodelo 2. São apresentados na Figura 4.5 e 4.7 o gráfico da correlação cruzada para cada submodelo.

Considerando o tempo de amostragem de 17 ms, o valor do atraso puro de tempo referente ao submodelo na primeira regra é determinado a partir do ponto máximo do gráfico, conforme indicado na Figura 4.5, resultando em um atraso de $L1 = 3.4s$ e referente ao submodelo na segunda regra é determinado a partir do ponto máximo do gráfico 4.7 resultando em um atraso de $L2 = 1.87s$.




Figura 4.4: Dados de entrada e saída para estimação do atraso puro de tempo referencia ao submodelo na primeira regra.




Figura 4.5: Estimação do atraso puro de tempo a partir da correlação cruzada entre os sinais de entrada e saída do processo térmico para o submodelo na primeira regra.




Figura 4.6: Dados de entrada e saída para estimação do atraso puro de tempo referencia ao submodelo na segunda regra.

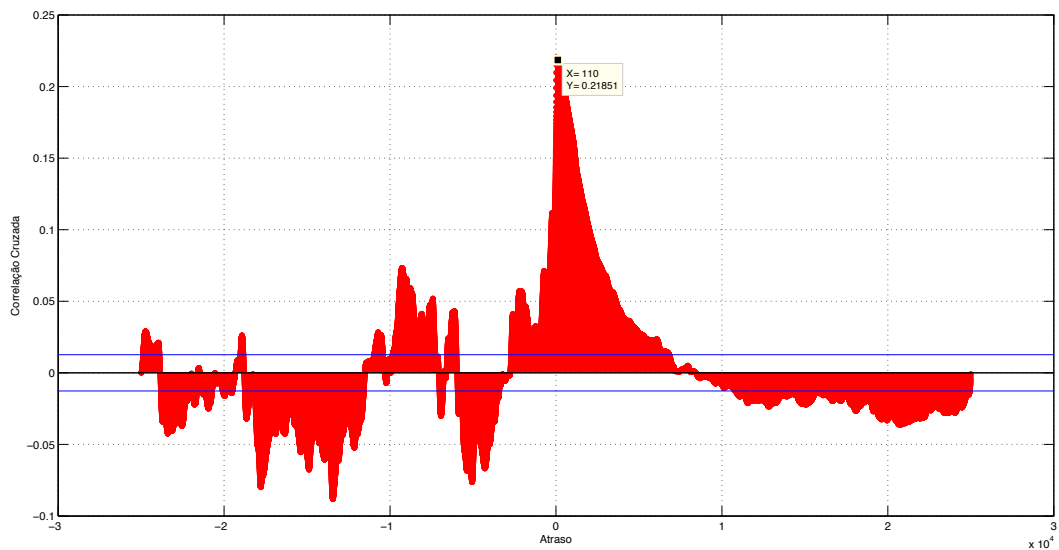


Figura 4.7: Estimação do atraso puro de tempo a partir da correlação cruzada entre os sinais de entrada e saída do processo térmico para o submodelo na segunda regra.

4.2.3 Validação e Ajuste Fino do Modelo Nebuloso TS

Para a validação do modelo são necessários novos dados de entrada e saída da planta térmica. São apresentados na Figura 4.8 os dados para validação:




Figura 4.8: Dados utilizados na etapa de validação da planta térmica. A tensão alternada, representada pelo seu valor eficaz (tensão), (a) é aplicada à planta cuja resposta temporal é a temperatura, em graus Celsius (b).

Na Figura 4.9, pode ser observado que o modelo nebuloso obtido acompanhou o comportamento da planta térmica, mas não foi satisfatório, pois o erro existente entre o modelo obtido e a planta (sistema real) é relativamente alto para elaboração do controle. Portanto, faz-se necessário a realização de um ajuste fino, nos submodelos e na função de pertinência, o qual foi realizado através de um AG, com as seguintes características: 100 gerações, população inicial de 100 cromossomos com valores aleatórios, onde cada cromossomo compreende seis genes: os ganhos DC (g_1 e g_2) aplicados a cada submodelo, coeficientes (a e b) de cada função de pertinência e os intensificadores (m_1 e m_2) de cada função de pertinência. A probabilidade de seleção é de 50% e a probabilidade de mutação é de 12%.

A função de custo utilizada é dada a partir do erro relativo médio quadrático (MRQE - *Mean Relative Quadratic Error*), como segue:

$$MRQE = \frac{1}{N} \sum_{k=1}^N \frac{(y_{real}(k) - y_{modelo}(k))^2}{y_{real}(k)} \quad (4.12)$$




Figura 4.9: (a) Dados de entrada da planta térmica . (b) Comparativo entre a resposta do modelo fuzzy identificado (linha vermelha) e a saída real da planta térmica(linha azul).

na qual y_{real} corresponde aos dados da planta térmica e y_{modelo} correspondente aos dados do modelo a ser otimizado.

Analisando a Figura 4.10 (melhor solução) pode ser observado o comportamento do algoritmo genético na busca pela melhor solução. O operador de mutação contribui para manter a diversidade com MRQE em torno de 0.07 e o operador de *crossover* contribui para obter a melhor solução com MRQE em torno de 8.4, como pode ser visto na Figura 4.10.

A nova função de pertinência obtida pode ser vista na Figura 4.11. Com a otimização, os ganhos do submodelo da primeira regra passou a ser $g_1 = 0.9148$ e do submodelo da segunda regra passou a ser $g_2 = 1.2282$. Os intensificadores m_1 e m_2 das funções de pertinência, que realizam as operações $(F_1)^{m_1}$ e $(F_2)^{m_2}$, ficaram com os valores $m_1 = 1.2882$ e $m_2 = 0.3011$, cujo efeito é mostrado na Figura 4.11. A estrutura otimizada do modelo TS da planta térmica resultou em:

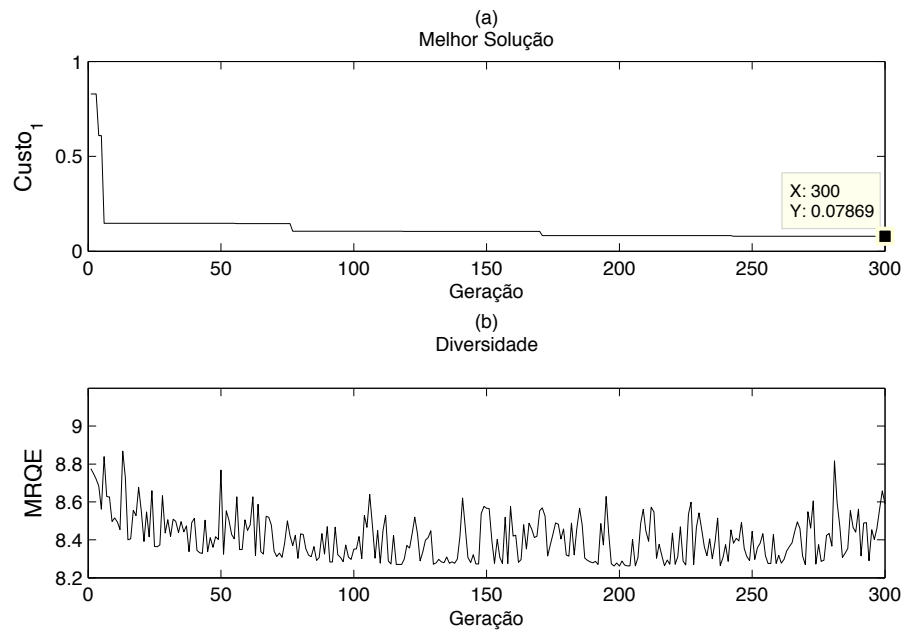


Figura 4.10: Desempenho do algoritmo genético usado para otimizar o modelo nebuloso TS da planta térmica: o melhor custo (a) e a diversidade (b).




Figura 4.11: Funções de pertinência obtidas pelo algoritmo de agrupamento (linha azul) e funções de pertinência obtidas pelo algoritmo genético (linha preta). F^1 representa o grau de ativação do submodelo para primeira regra e F^2 representa o grau de ativação do submodelo para segunda regra.

R^1 : Se Temperatura é $(F^1)^{1.2882}$, ENTÃO :

$$G_p^1(s) = \frac{g_1 \times 1.3311}{15.51s^2 + 4043s + 1} e^{-3.4s} \quad (4.13)$$

R^2 : Se Temperatura é $(F^2)^{0.3011}$, ENTÃO :

$$G_p^2(s) = \frac{g_2 \times 1.077}{45.91s^2 + 2730s + 1} e^{-1.87s} \quad (4.14)$$

na qual as regiões F^1 e F^2 podem ser representadas por funções de pertinência dadas por:

$$F^1(\text{Temperatura}, a, b) |_{a=43.8976; b=95.02} = \begin{cases} 1 & \text{Temperatura} \leq a \\ 1 - 2\left(\frac{\text{Temperatura} - a}{b - a}\right)^2, & a \leq \text{Temperatura} \leq \frac{a+b}{2} \\ 2\left(\frac{\text{Temperatura} - a}{b - a}\right)^2, & \frac{a+b}{2} \leq \text{Temperatura} \leq b \\ 0, & \text{Temperatura} \geq b \end{cases} \quad (4.15)$$

e $F^2 = 1 - F^1$

São apresentados na Figura 4.12 o sinal de entrada e as saídas para o modelo nebuloso identificado (linha vermelha), o processo térmico real (linha preta) e o modelo nebuloso validado através do AG (linha azul).




Figura 4.12: Etapa de validação: em (a) o sinal de entrada e em (b) a comparação das respostas temporal da planta térmica (linha preta), modelo nebuloso TS identificado (linha vermelha) e modelo nebuloso TS otimizado (linha azul).

Observa-se que o AG implementado conseguiu encontrar ganhos DC adequados a cada submo-

delo e valores para ajuste na função de pertinência de forma que o modelo nebuloso TS representa satisfatoriamente o comportamento dinâmico da planta térmica.

4.3 Projeto do Controlador PID Nebuloso para Estabilidade Robusta

No Capítulo 3, Seção 3.3, foi apresentada a estrutura do AG e a formulação da estratégia de otimização multiobjetiva para sintonia dos parâmetros do controlador PID nebuloso a partir das especificações das margens de ganho e fase desejada.

Nesta Seção, serão apresentados os resultados da otimização dos parâmetros do controlador PID nebuloso TS, com base nas especificações das margens de ganho e fase, de acordo com os dois teoremas propostos no Capítulo 3, na seção 3.2.3. Inicialmente, foi implementado um algoritmo genético multiobjetivo para projeto dos subcontroladores PID nebuloso juntos, em seguida foi feito um teste com um AG multiobjetivo para projeto dos subcontroladores PID nebuloso e os resultados obtidos neste último foram melhores. Nesta dissertação foi implementada a estratégia do AG multiobjetivo para projeto dos subcontroladores PID nebuloso separados.

O algoritmo genético multiobjetivo implementado, possui seguintes características: 300 gerações, população inicial aleatória de 100 cromossomos, onde cada cromossomo compreende três genes (K_p , K_i , K_d), a probabilidade de seleção de 50% e a probabilidade de mutação de 15%. O operador de cruzamento utilizado é o descrito em:

$$\begin{aligned}
 cromossomo_{pai} &= [K_p^i, K_i^i, K_d^i] \\
 cromossomo_{mãe} &= [K_p^i, K_i^i, K_d^i] \\
 cromossomo_{descendente_1} &= \eta * cromossomo_{pai} + (1 - \eta) * cromossomo_{mãe} \\
 cromossomo_{descendente_2} &= \eta * cromossomo_{mãe} + (1 - \eta) * cromossomo_{pai} \quad (4.16)
 \end{aligned}$$

onde $i = 1, 2$ e corresponde ao número de regras. Para exemplificar o AG multiobjetivo desenvolvido, foi escolhida uma margem de ganho de $MG = 9$ e $MF = 79^\circ$ de forma que a função de custo resultou em:

Controlador PID para cada regra:

$$\begin{aligned}
 Custo^i &= \delta_1 * |A_{m(e)}^i - A_{m(o)}^i| + \delta_2 * |P_{m(e)}^i - P_{m(o)}^i| \\
 Custo^i &= 0.5 * |9 - A_{m(o)}^i| + 0.5 * |79 - P_{m(o)}^i| \quad (4.17)
 \end{aligned}$$

onde $A_{m(e)}^i$ é a margem de ganho especificada para i -ésima regra, $A_{m(o)}^i$ é a margem de ganho obtida i -

ésima, $p_{m(e)}^i$ é a margem de fase especificada i -ésima e $A_{m(o)}^i$ é a margem de fase obtida i -ésima. Pode ser observada, na Figura 4.13 e na Figura 4.14 o desempenho da estratégia genética multiobjetiva para cada submodelo.

Na Figura 4.13, observa-se que o operador de *crossover* contribuiu para obter a melhor solução, custo em torno de 0.064 e o operador de mutação contribuiu para manter a diversidade em torno de 8.8 e na Figura 4.14, observa-se que o operador de *crossover* contribuiu para obter a melhor solução, custo em torno de 0.04 e o operador de mutação contribuiu para manter a diversidade com MRQE em torno de 11.6. No AG, a cada geração, a população fica mais diversificada e com maior campo de busca, tendo por consequencia a maior probabilidade de encontrar valores de custos mínimos.

São apresentados nas Figuras 4.15 e 4.16, os valores dos ganhos proporcional (K_p), integral (K_i) e derivativo (K_d) associados ao melhor indivíduo obtido em cada geração para os submodelos ($G_p^1(s)$) e ($G_p^2(s)$), respectivamente.

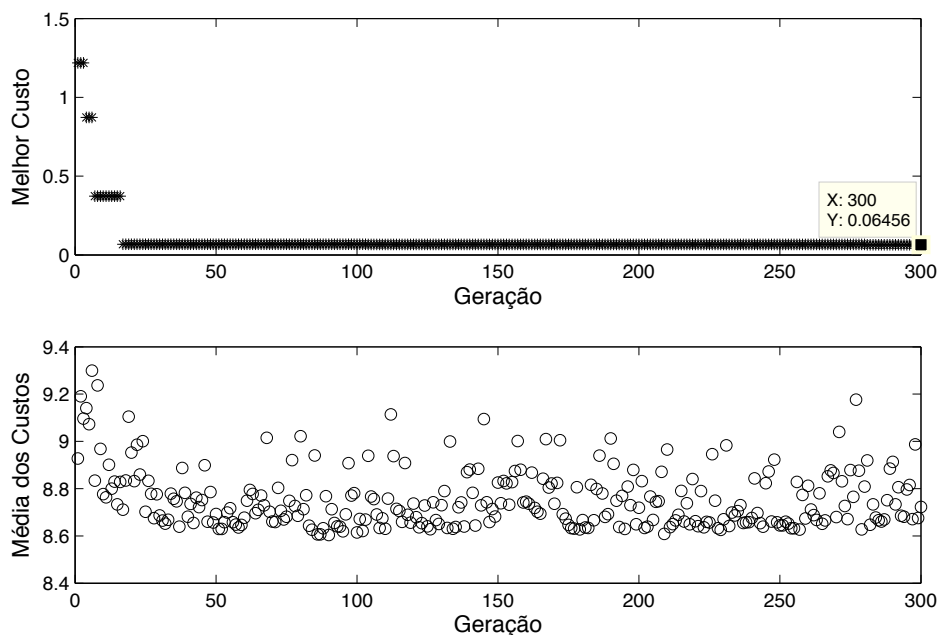


Figura 4.13: Desempenho do algoritmo genético relacionando o melhor custo de cada indivíduo (a) e média dos custos (b) para controlador PID na primeira regra

São apresentados na Tabela 4.1 os valores especificados, coluna (A_e, P_e), e os valores obtidos, coluna ($A_o P_o$), para as margens de ganho e fase. Observa-se que as margens de ganho e fase obtidas para o controlador PID nebuloso TS no domínio do tempo contínuo ficaram bem próximo dos valores especificados.

A base de regras do controlador PID nebuloso para estabilidade robusta resultou em:

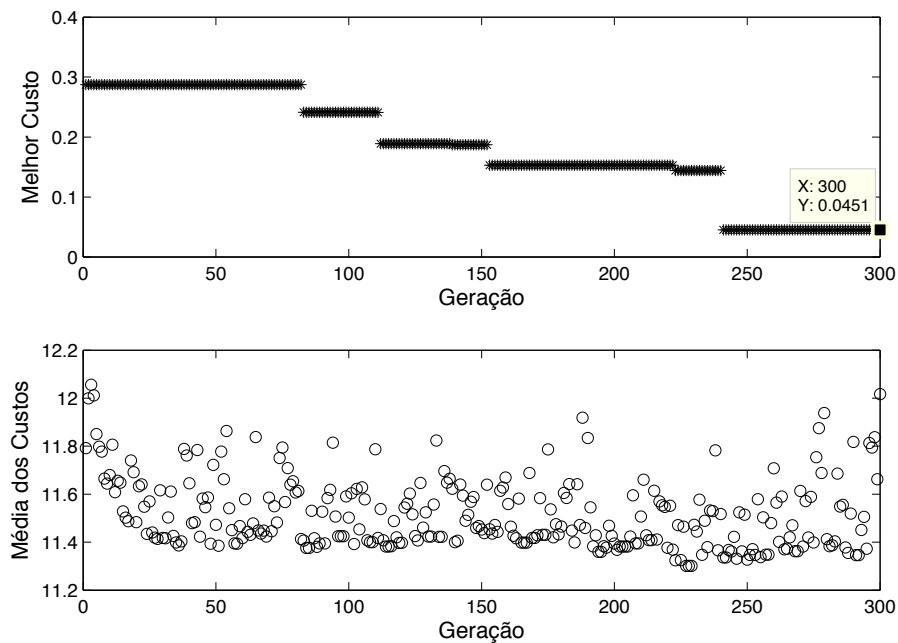


Figura 4.14: Desempenho do algoritmo genético relacionando o melhor custo de cada indivíduo (a) e média dos custos (b) para controlador PID na segunda regra

Tabela 4.1: Margem de ganho (em módulo), margem de fase (em graus) e parâmetros do controlador PID obtidos para cada submodelo.

Submodelo	(A_e, P_e)	(A_o, P_o)	(K_P, K_I, K_D)
$G_c^1(s)$	(9, 79°)	(9.1411, 79.0436°)	(199.0713, 0.2642, 0.0311)
$G_c^2(s)$	(9, 79°)	(9.0894, 79.0443°)	(122.0369, 0.1795, 0.0680)

SE Temperatura é F^1 , ENTÃO:

$$G_c^1(s) = \frac{0.0311s^2 + 199.0713s + 0.2642}{s}$$

SE Temperatura é F^2 , ENTÃO:

$$G_c^2(s) = \frac{0.0680s^2 + 122.0369s + 0.1795}{s} \quad (4.18)$$

Na Figura 4.17 observa-se o diagrama de Bode da função de transferência $G_c^1(s)G_p^1(s)$ e na Figura 4.18 observa-se o diagrama de Bode da função de transferência $G_c^2(s)G_p^2(s)$.

Pelo critério de estabilidade de Routh, foi feita uma análise de estabilidade do sistema de controle em malha fechada, que pode ser vista na equação 4.11. A partir da Equação (3.31) (que foi apre-

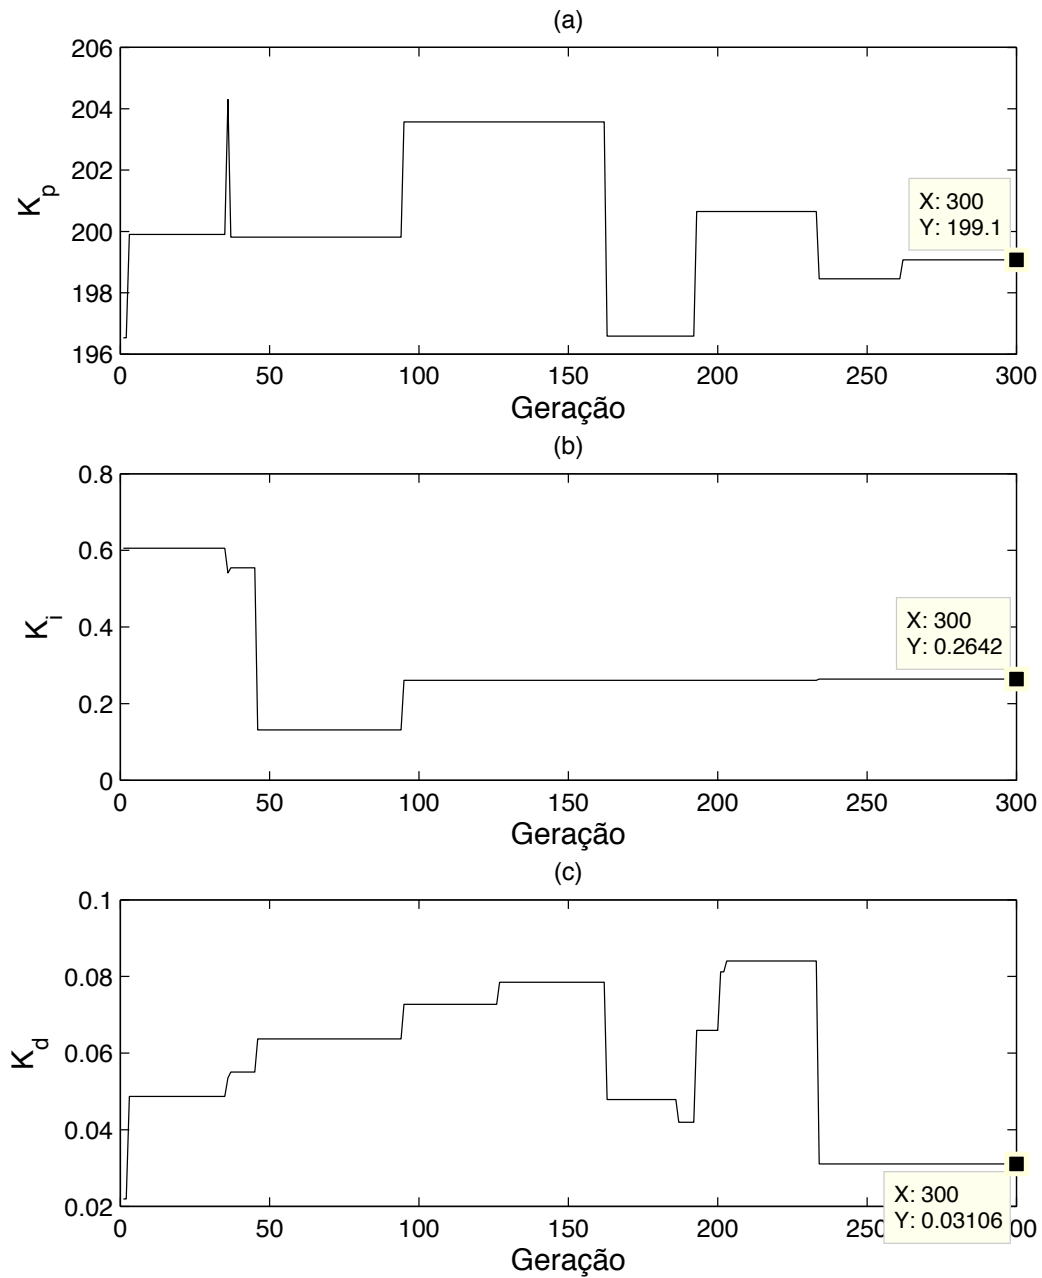


Figura 4.15: Valores, a cada geração, dos parâmetros do controlador PID na primeira regra (K_p em (a), K_i em (b) e K_d em (c)) do melhor indivíduo obtidos pelo AG para o submodelo ($G_p^1(s)$). Na última geração os valores dos parâmetros para a melhor solução (menor custo) foram: $K_p = 199.0713$, $K_i = 0.2642$ e $K_d = 0.0311$.

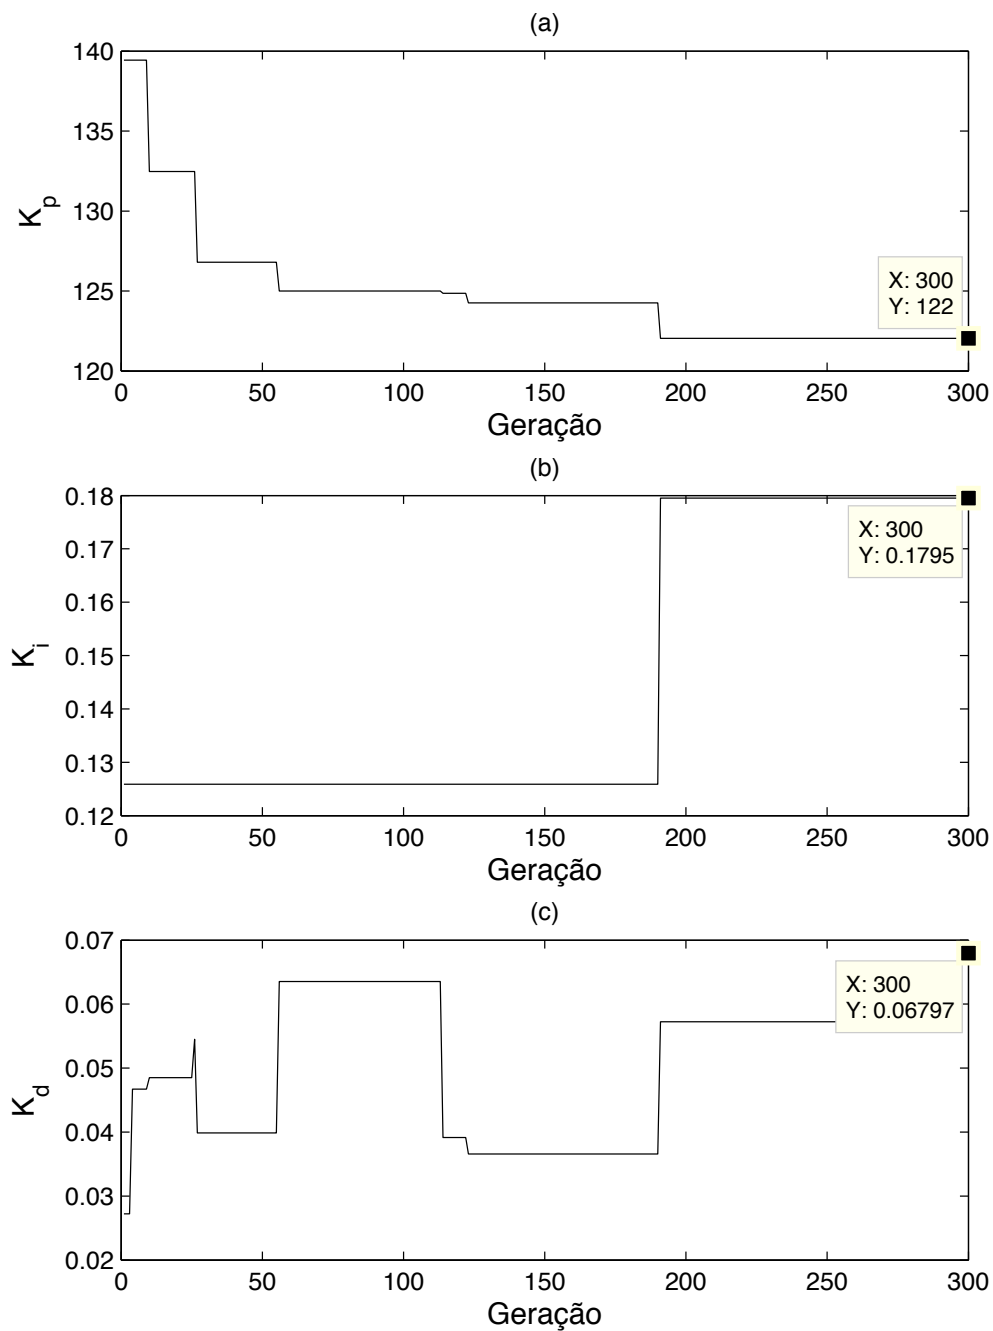


Figura 4.16: Valores, a cada geração, dos parâmetros do controlador PID na segunda regra (K_p em (a), K_i em (b) e K_d em (c)) do melhor indivíduo obtidos pelo AG para o submodelo ($G_p^2(s)$). Na última geração os valores dos parâmetros para a melhor solução (menor custo) foram: $K_p = 122.0369$, $K_i = 0.1795$ e $K_d = 0.0680$.




Figura 4.17: Diagrama de Bode de $G_p^1(s)G_c^1(s)e^{-3.4}$. A margem de ganho é 9.1411(em módulo) e 19.2 (em dB) na frequência de cruzamento de fase, $w_p = 0.54rad/s$ e a margem de fase é 79° na frequência de cruzamento do ganho, $w_p = 0.0591rad/s$

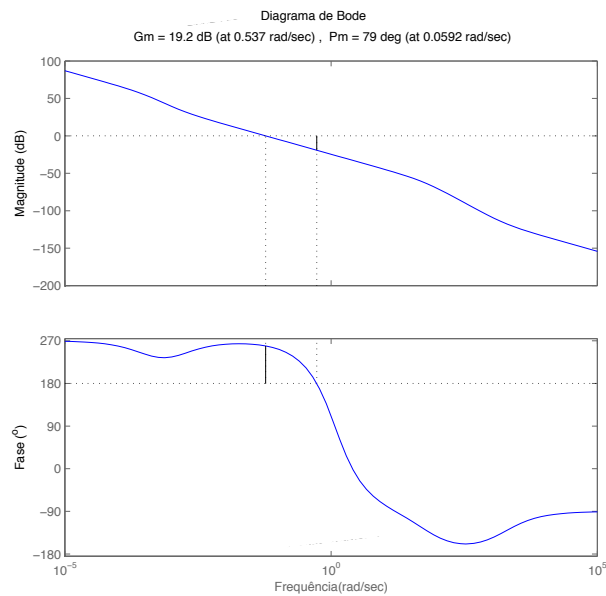


Figura 4.18: Diagrama de Bode de $G_p^2(s)G_c^2(s)e^{-1.87}$. A margem de ganho é 9.0894(em módulo) e 19.2 (em dB) na frequência de cruzamento de fase, $w_p = 0.537rad/s$ e a margem de fase é 79° na frequência de cruzamento do ganho, $w_p = 0.0592rad/s$

sentada no Catípulo3, Seção 3.2.3), obtém-se as Equações 4.19 e 4.20, representando as equações características dos submodelos do sistema nebuloso.

Equação característica de $G_p^1(s)G_c^1(s)e^{-3.4s}$:

$$179.6424s^5 + 47126s^4 + 85477s^3 + 43595s^2 + 2914.3s + 3.8606 \quad (4.19)$$

Equação característica de $G_p^2(s)G_c^2(s)e^{-1.87s}$:

$$160.5427s^5 + 10091s^4 + 31749s^3 + 30962s^2 + 1946.5s + 2.8492 \quad (4.20)$$

Análise da estabilidade pelo critério de Routh para primeira regra:

<i>coluna1</i>	<i>coluna2</i>	<i>coluna3</i>	<i>coluna4</i>	
s^5 :	179.6424	85477	2914.3	
s^4 :	47126	43595	3.8606	
s^3 :	85311	2914.3	0	(4.21)
s^2 :	41986	3.8606		
s^1 :	2906.5	0		
s^0 :	3.8606			

Análise da estabilidade pelo critério de Routh para segunda regra:

<i>coluna1</i>	<i>coluna2</i>	<i>coluna3</i>	<i>coluna4</i>	
s^5 :	160.5427	31749	1946.5	
s^4 :	10091	30962	2.8492	
s^3 :	31256	1946.4	0	(4.22)
s^2 :	30334	2.8492		
s^1 :	1943.5	0		
s^0 :	2.8492			

Para que a estabilidade do sistema de controle seja garantida é necessário que os termos da segunda coluna das equações 4.21 e 4.22 sejam positivos. Pode-se observar que no exemplo utilizado os termos são positivos e assim pode-se concluir que o sistema é estável.

4.4 Resultados Computacionais

Para ilustrar a metodologia proposta nesta dissertação, uma simulação foi feita no *simulink* com os dados da planta térmica. Foi projetado um compensador Takagi-Sugeno de avanço e um de atraso a fim de ser realizada uma comparação com o controlador proposto. Na Tabela 4.2 é possível observar os dados obtidos da comparação simulada.

Com a estratégia genética multiobjetiva utilizada, especificando as margens de ganho de 5 e margem de fase de 45° para o sistema de controle, observa-se na Tabela 4.2 que as margem de ganho e fase do controlador PID TS proposto na dissertação são bem próximos dos especificados, com erro na ordem de 10^{-2} , enquanto que no projeto dos compensadores a margem de fase obtida é próxima do especificado, mas não obtém-se a mesma eficiência para a margem de ganho. Para alcançar margens de fase maiores seria necessária uma estrutura mais complexa.

O comportamento do controlador PID proposto e dos compensadores podem ser observados na Figura 4.19. Observa-se que para as mesmas especificações o controlador proposto é mais eficiente, tendo menor tempo de acomodação e menor overshoot.

Tabela 4.2: Parâmetros, margem de ganho e margem de fase do controlador PID proposto, do compensador de avanço e do compensador de atraso obtido para cada submodelo.

Submodelo	(A_c, P_c)	(A_c^*, P_c^*)	Controlador
$G_{PID}^1(s)$	$(5, 45^\circ)$	$(5.0067, 45.0063^\circ)$	$\frac{11.6116s^2 + 336.7987s + 18.801}{s}$
$G_{PID}^2(s)$	$(5, 45^\circ)$	$(5.0559, 45.0041^\circ)$	$\frac{6.6s^2 + 205.2043s + 11.4094}{s}$
$G_{avano}^1(s)$	$(5, 45^\circ)$	$(6.02, 45.4^\circ)$	$\frac{49.15s + 0.96}{s(s + 0.4428)}$
$G_{avano}^2(s)$	$(5, 45^\circ)$	$(6.5904, 45.1^\circ)$	$\frac{46.86s + 1.01}{s(s + 0.668)}$
$G_{atraso}^1(s)$	$(5, 45^\circ)$	$(6.76, 45.3^\circ)$	$\frac{3.335s + 0.01394}{s(s + 0.0418)}$
$G_{atraso}^2(s)$	$(5, 45^\circ)$	$(5.95, 45.3^\circ)$	$\frac{3.024s + 0.01633}{s(s + 0.054)}$

4.5 Resultados Experimentais

Nessa seção será realizada uma aplicação prática para a metodologia proposta e esta será comparada com um controlador PID projetado através do Método de Ziegler-Nichols.

Inicialmente, a metodologia proposta foi submetida a uma aplicação prática. Na Figura 4.20, pode-se observar comportamento do controlador descrito pela Equação 4.18, com margem de fase e margem de ganho especificadas na Tabela 4.1. Para testar o comportamento do controlador PID nebuloso TS robusto foram feitas mudanças no *set point* da temperatura. A condição inicial para temperatura é de $100^\circ C$ e no tempo de, aproximadamente, 5.6 minutos o *set point* é modificado para




Figura 4.19: Comparação entre a resposta temporal do controlador PID nebuloso TS (linha azul), compensador de avanço (linha vermelha) e compensador de atraso (linha verde).

$60^{\circ}C$. Observa-se que o controlador proposto é capaz de alcançar a temperatura de *set point*, o tempo de acomodação é de, aproximadamente, 5,6 minutos, e o overshoot é de 3%.




Figura 4.20: Comportamento do controlador PID TS especificado na Tabela 4.1 (linha azul)

A eficiência da metodologia desenvolvida para o projeto de um controlador PID TS baseado em modelo, pode ser comprovada uma vez que as margens de ganho e de fase obtidas através da estratégia

genética multiobjetiva desenvolvida foram bem próximas das especificadas e a resposta temporal do sistema (controlador-planta) alcançou valores satisfatórios.

Em seguida, foi comparada com um controlador PID projetado através do Método TS Ziegler-Nichols, com os seguintes parâmetros para a primeira regra $K_p^1 = 120.92$ $K_i^1 = 50.27$ e $K_d^1 = 14.60$ e os seguintes para a segunda regra $K_p^2 = 170.92$ $K_i^2 = 40.27$ e $K_d^2 = 13.60$. Na Tabela 4.3, pode-se observar os dados utilizados na aplicação.

A resposta temporal do controlador PID TS nebuloso robusto com $MG = 5$ e $MF = 30^\circ$ (linha vermelha), com $MG = 5$ e $MF = 45^\circ$ (linha verde) e com $MG = 9$ e $MF = 79^\circ$ (linha azul) e do controlador TS Ziegler-Nichols (linha preta) pode ser observado na Figura 4.21. Observa-se que o controlador proposto, nos três casos (linha vermelha, azul e verde), possui desempenho melhor e mais eficiente que o TS Ziegler-Nichols pois possui menor tempo de acomodação e menor *overshoot*.

Pode-se observar na Figura 4.22 as ações de controle obtida pelo controladores PID nebuloso robusto com $MG = 5$ e $MF = 30^\circ$ (linha vermelha), com $MG = 5$ e $MF = 45^\circ$ (linha verde) e com $MG = 9$ e $MF = 79^\circ$ (linha azul) e TS Ziegler-Nichols (linha preta). A partir da ação de controle observa-se que o controlador proposto apresenta amplitudes menores em relação ao TS Ziegler-Nichols. Este desempenho deve-se à natureza da metodologia proposta, baseada em especificações de margem de ganho e fase, a qual garante estabilidade do sistema.

Na Figura 4.24, é possível observar uma perturbação, acondicionamento de temperatura que causa uma variação no ganho do sistema em torno de 4, aplicada no sistema térmico em malha aberta no tempo de 5.7 minutos. Essa perturbação foi aplicada ao sistema térmico em malha fechada no tempo de 3.4 minutos e no tempo de 6.8 minutos, como pode ser visto na Figura 4.24. Observa-se que o controlador nebuloso proposto apresentou uma variação de 5% e acomodou em 0.9 minutos. Quando foi novamente perturbado, variou de 4% e acomodou em 0.96 minutos.

Tabela 4.3: Parâmetros do controlador PID e do Ziegler-Nichols e a margem de ganho e fase obtidas para cada submodelo

Submodelo	(A_c, P_c)	(A_c^*, P_c^*)	(K_P, K_I, K_D)
$G_c^1(s)G_p^1(s)$	(5, 30°)	(5.0101, 30.0045°)	(315.3583, 32.1499, 19.4710)
$G_c^2(s)G_p^e(s)$	(5, 30°)	(5.002, 30.001°)	(190.5171, 19.2991, 9.2187)
$G_c^1(s)G_p^1(s)$	(5, 45°)	(5.006, 45.006°)	(336.7987, 18.801, 11.6116)
$G_c^2(s)G_p^2(s)$	(5, 45°)	(5.0598, 45.003°)	(205.2043, 11.4094, 6.600)
$G_c^1(s)G_p^1(s)$	(9, 79°)	(9.1411, 79.0436°)	(199.0713, 0.2642, 0.0311)
$G_c^2(s)G_p^2(s)$	(9, 79°)	(9.0894, 79.0443°)	(122.0369, 0.1795, 0.0680)
$G_{ZN}^1(s)G_p^1(s)$	(-, -)	(47.88, 14.40°)	(120.92, 50.27, 14.60)
$G_{ZN}^2(s)G_p^2(s)$	(-, -)	(30.7651, 31.28°)	(170.92, 40.27, 13.60)

É importante notar que, nas Figuras 4.25, 4.26 e 4.27, as margens de ganho e fase instantâneas




Figura 4.21: Comparação entre a resposta temporal do controlador PID nebuloso TS com $MG=5$ e $MF = 30^\circ$ (linha vermelha), com $MG=5$ e $MF = 45^\circ$ (linha verde), com $MG=9$ e $MF = 79^\circ$ (linha azul) e o controlador TS Ziegler-Nichols (linha preta)

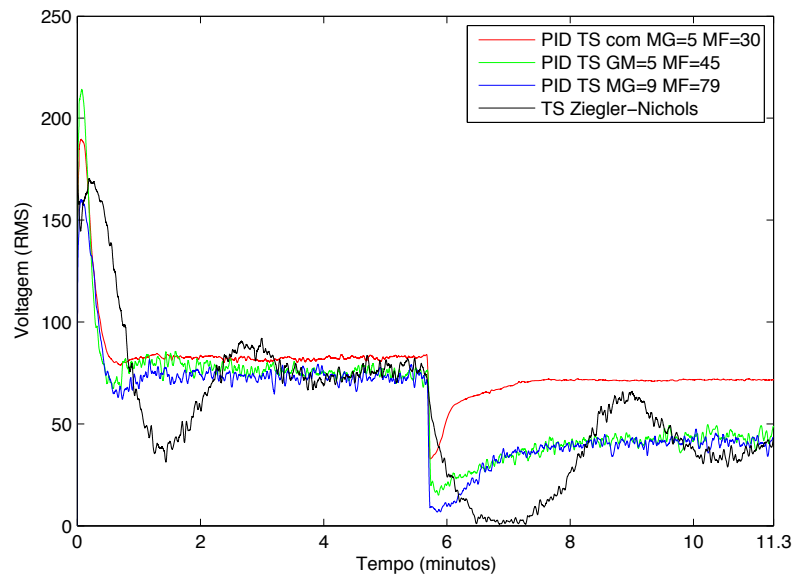


Figura 4.22: Comparação entre as ações de controle do PID nebuloso robusto $MG = 5$ e $MF = 30^\circ$ (linha vermelha), com $MG = 5$ e $MF = 45^\circ$ (linha verde), com $MG = 9$ e $MF = 79^\circ$ (linha azul) e o controlador TS Ziegler-Nichols (linha preta).

obtidas pelo controlador PID nebuloso permanecem próximas das margem de ganho e fase especificadas.




Figura 4.23: Comportamento da planta térmica em malha aberta, aplicando a perturbação no tempo de 5.7 minutos.




Figura 4.24: Comportamento da planta térmica em malha fechada (controlador-planta), aplicando a perturbação no tempo de 3.4 minutos e no tempo 6.8 minutos.




Figura 4.25: Margem de ganho (MG) e margem de fase (MF) instantâneas definidas pela ação do controlador: (a) e (b) PID nebuloso robusto proposto com com $MG = 5$ e $MF = 30^\circ$.

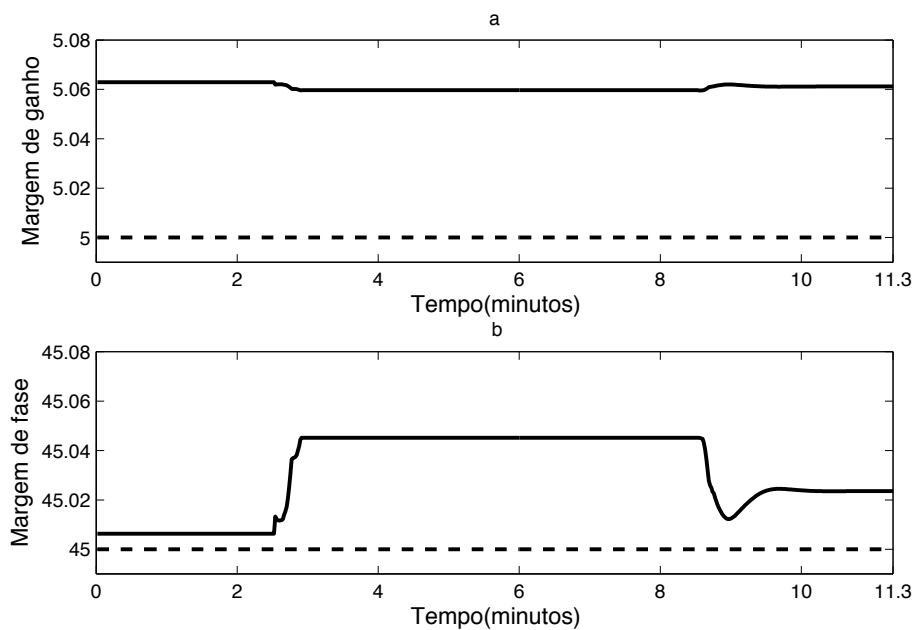


Figura 4.26: Margem de ganho (MG) e margem de fase (MF) instantâneas definidas pela ação do controlador: (a) e (b) PID nebuloso robusto proposto com com $MG = 5$ e $MF = 45^\circ$.




Figura 4.27: Margem de ganho (MG) e margem de fase (MF) instantâneas definidas pela ação do controlador: (a) e (b) PID nebuloso robusto proposto com $MG = 9$ e $MF = 79^\circ$.

Capítulo 5

Conclusões

Nesta dissertação uma metodologia de controle PID nebuloso robusto utilizando algoritmo genético multiobjetivo, baseado nas especificações das margens de ganho e fase, no domínio do tempo contínuo foi desenvolvida. Foram apresentados conceitos importantes para elaboração desta dissertação, tais como definições das incertezas dinâmicas e do atraso puro de tempo, sistema de inferência nebuloso Takagi-Sugeno, algoritmo de agrupamento nebuloso, margem de ganho e fase, e estratégia de compensação paralela e distribuída.

A partir de dados experimentais, foi utilizado um algoritmo de agrupamento nebuloso (Fuzzy C-means) para estimar as regras e as funções de pertinência relacionadas ao antecedente do modelo da planta. Em seguida, foi utilizado o algoritmo dos mínimos quadrados para estimar os parâmetros de cada submodelo linear do consequente do modelo da planta. Em seguida, os parâmetros de cada subcontrolador para cada submodelo identificado foram obtidos a partir de um algoritmo genético multiobjetivo, desenvolvido baseado nas especificações de margem de ganho e fase.

Para comprovar a estabilidade robusta da metodologia de controle desenvolvida foram propostos dois teoremas. O primeiro é baseado na análise da equação por Critério de Routh, que dispõe as condições necessárias e suficientes para que cada subcontrolador garanta a estabilidade do seu respectivo modelo. O segundo é baseado nas equações de margem de ganho e fase quando uma ou mais regras são ativadas, que prova que o controlador garante as especificações das margens de ganho e fase ao sistema de controle em malha-fechada.

Resultados computacionais foram apresentados e comparados com os compensadores de avanço e de atraso. Pode-se observar que a metodologia proposta apresentou resultados satisfatórios. A proposta apresentada, foi aplicada a uma planta térmica. Nessa aplicação, a proposta desenvolvida nessa dissertação demonstrou ser estável e robusta, pois o controlador PID nebuloso TS proposto garantiu, durante todo o processo, os valores de margens de ganho e fase obtidos no projeto do controlador bem próximos aos especificados, através da estratégia genética multiobjetiva utilizada. O controlador pro-

posto foi comparado com o controlador projetado pelo método Ziegler-Nichols e mostrou-se eficiente no que se refere ao rastreamento da trajetória de referência, mesmo diante de incertezas, não linearidade e atraso puro de tempo, que influenciam no comportamento da planta térmica. Os teoremas propostos foram comprovados experimentalmente.

A partir dos resultados experimentais, a metodologia de controle proposta apresenta como contribuição: uma formulação matemática em termos de função de transferência, fundamentada na estrutura do modelo nebuloso Takagi-Sugeno, utilizando a estratégia de compensação paralela e distribuída, para projeto de controle PID nebuloso TS com estabilidade robusta, no domínio do tempo contínuo, permite a análise das condições de estabilidade robusta no projeto do controlador nebuloso TS, baseado nas especificações de margem de ganho e fase, uma abordagem genética multiobjetiva, a partir das especificações de margem de ganho e fase, para obtenção dos parâmetros dos subcontroladores PID nebuloso.

5.1 Propostas Futuras

Uma vez que a metodologia proposta apresentou resultados relevantes quanto a estabilidade, robustez e eficiência, pode-se considerar a seguinte lista de possíveis trabalhos futuros:

- A metodologia de controle proposta, pode ser estendida para sistemas dinâmicos multivariáveis com atraso puro de tempo;
- O estudo e análise da metodologia proposta considerando o aspecto de desempenho robusto;
- Uso de outros algoritmos multiobjetivos, tais como: *Strength Pareto Algorithm* e *Multiobjective Evolutionary Algorithm*;
- Obtenção de regras do consequente do sistema nebuloso usando programação genética.

Referências Bibliográficas

AARABI, A. et al. Improved closed loop performance and control signal using evolutionary algorithms based pid controller. Carpathian Control Conference (ICCC), 2015 16th International, p. 8889–8894, 2015.

AGUIRRE, L. A. The least square padé method for model reduction. In: . [S.l.]: Int. J. Systems Sci, 1992. p. 1559–1570.

AGUIRRE, L. A. Open-loop model matching in frequency domain. Electronics Letters, p. 484–485, 1992.

AGUIRRE, L. A. *Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. 3. ed. [S.l.]: Editora UFMG, 2007.

ALMEIDA, F. *Identificação multivariável de um processo de incineração de resíduos líquidos Utilizando Modelos Nebulosos Takagi-Sugeno*. Dissertação (Mestrado) — Universidade Estadual de Campinas, São Paulo, 2005.

ALMEIDA, J. L. A. d. *Dispositivos Semicondutores: Tiristores Controle de Potência em CC E CA*. 11. ed. [S.l.]: ERICA, 2007.

AMORIM, J. G. *Trigonometria e Números Complexos*. [S.l.]: UNB, 2006.

ANTWERP, B. *Padé Approximation and its Applications*. [S.l.]: Springer, 1979.

AYDI, A.; DJEMEL, M.; CHTOUROU, M. On the fuzzy modeling of uncertain nonlinear systems. Sciences and Techniques of Automatic Control and Computer Engineering (STA), p. 1055–1060, 2014.

AZEEM, M. F. *Fuzzy Inference System - Theory and Applications*. [S.l.]: Croácia: InTech, 2012.

BABUSKA, R. *Fuzzy Modeling for Control*. [S.l.]: Boston: Kluwer Academic Publishers, 1998.

BAI, Y.; ZHUANG, H.; WANG, D. *Advanced Fuzzy Logic Technologies in Industrial Applications*. [S.l.]: Springer, 2007. (Advances in Industrial Control), 2007.

BALAS, G. Theory and application of linear parameter varying control techniques. ACC Workshop notes, 1997.

- BARROS, L. C. d.; BASSANEZI, R. C. *Tópicos de Lógica Fuzzy e Biomatemática*. [S.l.]: Unicamp-Imecc (Colecao IMECC. Textos Didáticos), 2006.
- BARTOSZEWICZ, A. Challenge and paradigms in applied robust control. InTech, Croácia, 2011.
- BOTTURA, C. P. Memórias e reflexões de um professor brasileiro de controle de sistemas dinâmicos. TEMA: Tendências em Matemática Aplicada e Computacional, v. 14, n. 1, p. 23–42, 2013.
- BREZINSKI, C. The birth and early developments of padé approximation: Differential geometry, calculus of variations, and their applications. Lecture notes in pure and appl. math., p. 105–121, 1985.
- BROGAN, W. L. *Modern Control Theory*. [S.l.]: Prentice Hall, 2009.
- CARMO, M.; MORGADO, A.; WAGNER, E. *Trigonometria e Números Complexos*. [S.l.]: Sociedade Brasileira de Matemática, 2001.
- CHAOUECH, L.; CHAARI, A. Design of sliding mode control of nonlinear system based on takagi sugeno fuzzy model. IEEE, p. 1–6, 2013.
- CHEN, G.; PHAM, T. T. *Introduction to Fuzzy Systems*. [S.l.]: Chapman and Hall (CRC), 2005.
- CHEN, G.; WU, T. A cloud model based computacional intelligence algorithm for parameter identification of chaotic systems. In: Seventh Intenational Conference on Computational Intelligence and Security (CIS), p. 1–5, 2011.
- COPPIN, B. *Inteligência Computacional*. [S.l.]: Jones e Barlett, Inc., 2010.
- DORF, R. C.; BISHOP, R. H. *Sistemas de controle modernos*. [S.l.]: LTC, 2009.
- ENGELBRECHT, A. P. *Computational Intelligence: An Introduction*. [S.l.]: Wiley, 2007.
- ENGELBRECHT, A. P. Computational intelligence: An introduction. Wiley, v. 41, n. 3, p. 436–442, 2007.
- FAN, Z.; HUANG, M. Fuzzy rule set based engine fault diagnosis. Power and Energy Engineering Conference, p. 1–5, 2009.
- FERREIRA, C.; SERRA, G. Fuzzy frequency response for complex dynamic systems. Intelligent Control (ISIC), 2010 IEEE International Symposium on, p. 464–469, 2010.
- FERREIRA, C. C. T. *Metodologia Nebulosa Robusta para Estimção da Resposta em Frequência de Sistemas Dinâmicos Incertos*. 127 p. Tese (Tese de Doutorado) — Universidade Federal de Campina Grande, 2013.
- FRANKLIN, G. F.; POWELL, J. D.; BAEINI, A. *Feedback Control of Dynamic Systems*. [S.l.]: Addison-Wesley Longman, Incorporated, 2002.
- FRANKLIN, G. F.; POWELL, J. D.; WORKMAN, M. L. *Digital Control of Dynamic Systems*. [S.l.]: Addison-Wesley, 1997.

FRIEDLAND, B. *Control System Design: An Introduction to State-Space Methods*. [S.l.]: McGraw-Hill, New York, 2005.

GAHINET, P.; APKARIAN, P.; CHILALI, M. Affine parameter-dependent lyapunov functions and real parametric uncertainty. *IEEE Transactions on Automatic Control*, v. 41, n. 3, p. 436–442, 1996.

GHOSH, B.; MARTIN, C. F.; ZHOU, Y. *Emergent Problems in Nonlinear Systems and Control*. [S.l.]: Springer, 2009. (Lecture Notes in Control and Information Sciences).

GOODWIN, G. C.; GRAEBE, S. F.; SALGADO, M. E. *Control system design*. [S.l.]: Prentice Hall, 2001.

HAUPT, R. L.; HAUPT, S. E. *Practical Genetic Algorithms*. 2. ed. [S.l.]: A JOHN WILEY e SONS, INC., PUBLICATION, 2004. (New Jersey: Wiley-Interscience).

HO, W.-H.; TSAI, J.-T.; CHOU, J.-H. Robust-stable and quadratic-optimal control for ts-fuzzy-model-based control systems with elemental parametric uncertainties. In: . [S.l.]: Control Theory e Applications, IET, 2007. v. 1, p. 731–742.

HONGKAI, W.; LIQING, F.; CHAO, X. Research of generalized cross correlation to time delay estimation based on wavelet analysis. *Instrumentation, Measurement, Computer, Communication and Control, 2011 First International Conference on*, IEEE Conference Publications, p. 74–77, 2011.

HOPPNER, F. et al. *Fuzzy Cluster Analysis*. [S.l.]: Wiley, 1999.

HOSOE, S. Pid controlle design for robust performance. *SICE Annual Conference, Nagoya, Japan*, p. 468–473, 2013.

IANNOU, P. A.; SUN, J. *Robust adaptive control*. Prentice Hall (Automation and Control Engineering), p. 468–473, 1996.

IBRAHIM, A. *Fuzzy energy control strategy of through-to-road hybrid electric vehicle*. USA, Elsevier Science, 2003.

IOANNOU, P. A.; PITSILLIDES, A. *Modeling and Control of Complex Systems*. [S.l.]: Taylor & Francis, 2010. (Automation and Control Engineering).

JAY, W. Y. et al. Determination of all feasible robust pid controllers for open-loop unstable plus time delay systems with gain margin and phase margin specifications. *Control Conference (CCC)*, p. 2394–2399, 2011.

JIANLING, Q.; ZHENJIE, D.; YEZI, L. Genetic algorithm optimised fuzzy control of dstatcom for improving power quality. *Electronic Measurement and Instruments, 2007. ICEMI07. 8th International Conference on*, p. 1–6, 2014.

KANAE, S.; NAKAMICHI, M. An ant colony optimization method for fuzzy membership functions and its application to estimate the pulmonary elastance. *Control Conference (CCC), 32nd Chinese*, p. 8056–8060, 2013.

- KIM, K.; CHO, S. B. Game ai competitions: An open platform for computational intelligence education. *IEEE*, v. 8, n. 3, p. 64–68, 2013.
- KOMATSU, K.; TAKATA, S. Nonlinear feedback control of stabilization problem via formal linearization using taylor expansion. *International Symposium on Information Theory and Its Applications*, p. 1–5, 2008.
- KONAR, A. *Computational Intelligence: Principles, Techniques and Applications*. [S.l.]: Springer, 2008.
- KORKMAZ, M.; AYDOGDU, O.; DOGAN, H. Design and performance comparison of variable parameter nonlinear pid controller and genetic algorithm based pid controller. *International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*, IEEE, p. 1–5, 2012.
- KOSHIYAMA, A. et al. Gpfs-control: A fuzzy genetic model for control tasks. *Fuzzy Systems (FUZZ-IEEE)*, 2014 IEEE International Conference on, p. 1953–1959, 2014.
- LAM, H. K.; NARIMANI, M. Stability analysis of sampled-data output-feedback polynomial fuzzy-model based control systems. *IEEE International Conference on Fuzzy Systems (FUZZ)*, p. 1–7, 2010.
- LARSEN, R. W. *LabVIEW for Engineers*. [S.l.]: Pearson Education, 2011.
- LEE, C. S.; WANG, M. H. A fuzzy expert system for diabetes decision support application. *IEEE*, v. 41, p. 139–153, 2011.
- LEI, K. A fast hybrid optimization algorithm based on ts and pso for circles packing problem with the equilibrium constraints. *Software Engineering and Service Science (ICSESS)*, 2014 5th IEEE International Conference on, p. 314–317, 2014.
- MACEDO, L. d.; DIMURO, G.; AGUIAR, M. d. Hybrid intelligent systems: A study on genetic algorithms and fuzzy approaches. *IEEE*, p. 138–144, 2011.
- MAEDA, Y.; IWASAKI, M. Circle condition based pid controller design considering robust stability against plant perturbations. *IEEE*, p. 6442–6447, 2013.
- MAJID, K.; HERDIYENI, Y.; RAUF, A. I-pedia: Mobile application for paddy disease identification using fuzzy entropy and probabilistic neural network. *Advanced Computer Science and Information Systems (ICACSIS)*, International Conference on, IEEE, p. 403–406, 2013.
- MATSUDA, T.; MORI, T. Stability feeler: a tool for parametric robust stability analysis and its applications. In: . [S.l.]: Control Theory e Applications, IET, 2009. v. 1, p. 1625–1633.
- MEHRAN, K. Takagi-sugeno fuzzy modeling for process control. *Material of School of Electrical, Electronic and Computer Engineering*, Newcastle University., 2008.
- MESEMANOLIS, A.; MADEMLIS, C.; KIOSKERIDIS, I. Neuro-fuzzy energy management system in elevator drive applications for maximum braking energy regenerative capability. *Power Electronics, Machines and Drives*, IEEE, p. 1–6, 2014.

- MING, L. et al. Time delay signal process assisted by virtual instrument. 2nd International Workshop on Database Technology and Applications (DBTA), p. 1–4, 2010.
- MING-LIANG, L.; YA-LI, D.; JIN-YING, L. Robust stability criteria for uncertain singular systems with multiple-state delays. *Intelligent Networks and Intelligent Systems*, IEEE Conference Publications, v. 1, p. 19–22, 2009.
- MITCHELL, S.; COHEN, K. Fuzzy logic decision making for autonomous robotic applications. IEEE 6th International Conference on Awareness Science and Technology (iCAST), p. 1–5, 2014.
- MOGHBELI, H.; NIASAR, A. H.; FALLAHI, N. Fuzzy energy control strategy of through-to-road hybrid electric vehicle. IEEE 23rd International Symposium on Industrial Electronics (ISIE), p. 1660–1665, 2014.
- MOHAMMED N.AND MA, E. S. X.; HAYAT, Q. D6114 diesel engine speed control: A case between pid controller and fuzzy logic controller. IEEE, p. 275–279, 2014.
- OGATA, K. *Modern Control Engineering*. [S.l.]: Pearson Prentice Hall, 2010.
- OLIVEIRA, J. V. d.; PEDRYCZ, W. *Advances in Fuzzy Clustering and its Applications*. [S.l.]: John Wiley e Sons, Ltd, 2007. 454 p.
- PEDRYCZ, W.; GOMIDE, F. *Fuzzy Systems Engineering: toward human-centric computing*. [S.l.]: John Wiley, 2007.
- PIMENTEL, J.; GAD, E.; ROY, S. Stability analysis of bldc motor speed controllers under the presence of time delays in the control loop. International Conference on Connected Vehicles and Expo (ICCVE), IEEE, p. 171–176, 2013.
- PIRES, D. S.; SERRA, G. L. O. Robust fuzzy digital pid control for uncertain dynamic systems with time delay. Anais do Congresso Brasileiro de Inteligência Computacional, 2013.
- PRILIANI, K. Automatic leaf color level determination for need based fertilize leaves. 6th International Conference on, Information Technology and Electrical Engineering (ICITEE), p. 1–6, 2014.
- RUTKOWSKI, L. *Computational Intelligence: Methods and Techniques*. [S.l.]: Springer, 2004.
- SALLOUM, R.; ARVAN, M.; MOAVENI, B. Identification, uncertainty modelling, and robust controller design for an electromechanical actuator. IEEE, p. 1–6, 2013.
- SCHAFFER, J. D. *Some Experiments in Machine Learning Using Vector Evaluated Genetic Algorithms*. Tese (Tese de Doutorado) — Vanderbilt University, Nashville, TN, Campinas, SP, 1984.
- SERRA, G. L. O. *Propostas de Metodologias para Identificação e Controle Inteligentes*. 127 p. Tese (Tese de Doutorado) — Unicamp / FEEC / DMSCI, Campinas, SP, 2005.
- SERRA, G. L. O. (Ed.). *Frontiers in Advanced Control Systems*. [S.l.]: Intech, 2012.

- SERRA, G. L. O.; BOTTURA, C. P. Multiobjective evolution based fuzzy pi controller design for nonlinear systems. *Engineering Applications of Artificial Intelligence*, v. 19, p. 157–167, 2006.
- SERRA, G. L. O.; SILVA, J. A. Robust pid ts fuzzy control methodology based on gain and phase margins specifications. *Journal of Intelligent e Fuzzy Systems*, p. 869–888, 2014.
- SHAMMA, J.; ATHANS, M. Guaranteed properties of gain scheduled control for linear parameter varying plants. *ACC Workshop notes*, p. 559–564, 1991.
- SHINNERS, S. M. *Modern Control System Theory and Design*. [S.l.]: John Wiley e Sons, INC, 1998.
- SKOGESTAD, S.; POSTLETHWAITE, I. *Multivariable feedback control: Analysis and design*. John Wiley e Sons, 2005.
- SUGENO, M.; KANG, G. T. Fuzzy modeling and control of multilayer incinerator. *Fuzzy Sets and Systems*, p. 329–346, 1986.
- TAJJUDIN, M. et al. Simple pid tuning using relay perturbation with error switching. *System Engineering and Technology (ICSET)*, p. 1–6, 2012.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modelling and control. *IEEE Transactions on Systems, Man and Cybernetics*, p. 116–132, 1985.
- TAMIM, N.; GHANI, F. Hilbert transform of fft pruned cross correlation function for optimization in time delay estimation. *Communications (MICC), 2009 IEEE 9th Malaysia International Conference on, IEEE Conference Publications*, p. 809–814, 2009.
- TERANO, T.; ASAI, K.; SUGENO, M. *Applied Fuzzy Systems*. [S.l.]: Academic Press, 1989.
- TORRE, W. D. L. Takagi sugeno fuzzy dynamic regulator for a pendulum on a cart system. p. 52–57, 2013.
- TRIPATHI, S. M. *Modern Control Systems: An Introduction*. [S.l.]: Infinity Science Press LLC, 2008.
- W., C.; GUAN, Z. L. X. Delay-dependent guaranteed cost control for uncertain discrete-time systems with delay. *Control Theory Appl.*, v. 150, n. 4, p. 412–416, 2003.
- WANG, H. O.; TANAKA, K.; GRIFFIN, M. F. Parallel distributed compensation of non- linear systems by takagi-sugeno fuzzy model. *IEEE*, p. 531–538, 1995.
- WANG, L. X. *A Course in Fuzzy Systems and Control*. [S.l.]: Prentice Hall PTR, 1997.
- WRIGHT, A. H. Genetic algorithms for real parameter optimization. In: *Foundations of Genetic Algorithms.*, p. 205–218, 1991.
- WU, M.; HE, Y.; SHE, J. *Stability analysis and robust control of time-delay systems*. Springer, 2010.

XIU, Z.; REN, G. Optimization design of ts-pid fuzzy controllers based on genetic algorithms. IEEE, v. 3, p. 2476–2480, 2004.

YOO B.-S.; KIM, J.-H. Fuzzy integral-based gaze control of a robotic head for human robot interaction. IEEE, 2014.

YU, X.; GEN, M. *Introduction to Evolutionary Algorithms*. [S.l.]: Springer, 2010.

YUAN-JAY, W. et al. Graphical computation of gain and phase margin specifications-oriented robust pid controllers for uncertain systems with time-varying delay. Control Conference (CCC), p. 2034–2040, 2010.

YUN-SHAN, W.; XIAO-DONG, L. Pid and epid types of iterative learning control based on evolutionary algorithm. Control Conference (CCC), 2014 33rd Chinese, p. 8889–8894, 2014.

ZADEH, L. Fuzzy sets. Information and Control, v. 8, p. 338–353, 1965.

ZADEH, L. Soft computing and fuzzy logic. IEEE Software, p. 48–56, 1994.

ZADEH, L. Robust control of time-delay systems. USA: British Library, 2006.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach. IEEE Transactions on Evolutionary Computation, v. 3, n. 4, p. 257–271, 1999.

Apêndice A

Considerações sobre os Sistemas Nebulosos

Este apêndice, mostra-nos alguns conceitos e princípios em relação a teoria dos conjuntos nebulosos, os quais foram utilizados no desenvolvimento desta dissertação.

A.1 Conjuntos Nebulosos

Sendo definido em um universo de discurso ou conjunto universal U o conjunto nebuloso A que pode ser representado por um conjunto de par ordenado de um elemento genérico x e seus valores de pertinência, que tem valores no intervalo de $[0, 1]$, como segue:

$$A = \{(x, \mu_A(x)) | x \in U\} \quad (\text{A.1})$$

onde:

$$\mu_A = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (\text{A.2})$$

A representação matemática do conjunto nebuloso A quando U é contínuo (por exemplo, $U = \mathfrak{R}$) é dada por:

$$A = \int_U \mu_A(x)/x \quad (\text{A.3})$$

onde a integral não significa integração e sim a coleta de todos os pontos $x \in U$ com a função de pertinência associada $\mu_A(x)$.

Um número genérico x , em lógica nebulosa, pode pertencer parcialmente a um conjunto com um determinado grau de pertinência $\mu_A(x)$ que varia entre 0 e 1. Na literatura dos conjuntos nebulosos, o

termo *crisp* é utilizado para denotar quantidades não-nebulosas, por exemplo, um número *crisp*, um conjunto *crisp*, etc. Na figura A.1 pode-se observar um conjunto *crisp* e na Figura A.2 um exemplo de um conjunto nebuloso.




Figura A.1: Exemplo de um conjunto *crisp*




Figura A.2: Exemplo de um conjunto nebuloso

A.2 Definições Básicas

A.2.1 Centro

O centro de um conjunto nebuloso é definido como o valor médio de todos os pontos, nos quais a função de pertinência possui valor máximo.

A.2.2 Ponto de *Crossover*

O ponto de *crossover* de um conjunto nebuloso é o ponto no universo de discurso U que os valores da função de pertinência do conjunto nebuloso A são iguais a 0.5.

A.2.3 Altura

A altura de um conjunto nebuloso A é o máximo valor atingindo pelo função de pertinência em qualquer ponto. Se o valor máximo do conjunto nebuloso for igual a 1(um) este conjunto é chamado de conjunto nebuloso normal.

A.2.4 Núcleo

O núcleo de um conjunto nebuloso A é o conjunto de todos os ponto $x \in X$, para os quais a função de pertinência é igual a 1(um) ($\mu_A(x) = 1$). A notação do núcleo é:

$$N_A = \{x \in U / \mu_A(x) = 1\} \quad (\text{A.4})$$

A.2.5 Conjunto Suporte

O conjunto suporte de um conjunto nebuloso A no universo de discurso U é um conjunto *crisp* que contém todos os elementos de U que tem o valor da função de pertinência de A diferente de zero. Na equação (A.5) pode-se observa a notação de suporte ($supp(A)$).

$$supp(A) = \{x \in U / \mu_A > 0\} \quad (\text{A.5})$$

A.2.6 Conjunto *Singleton*

O conjunto *Singleton* é um conjunto nebuloso cujo o suporte é um único ponto no universo de discurso U , com grau de pertinência igual a 1.

A.2.7 Conjunto Corte α

Um conjunto de corte α (ou corte no nível α) é definido como um conjunto *crisp* A_α que contém todos os elementos do universo de discurso U que tem todos os valores das funções de pertinência de A maior ou igual a α .

$$A_\alpha = \{x \in U / \mu_A(x) \geq \alpha\} \quad (\text{A.6})$$

A.2.8 Conjunto Nebuloso Convexo

Um conjunto nebuloso definido em \mathfrak{R}^n é dito convexo, se e somente se cada um dos seus α -corte, A_α é um conjunto convexo para qualquer α no intervalo $(0, 1]$. Um conjunto nebuloso A é convexo, se para qualquer valor de λ compreendido entre $[0, 1]$, tem-se:

$$\mu_A[\lambda x_1 + (1 - \lambda)x_2] \geq \min[\mu_A(x_1), \mu_A(x_2)] \quad (\text{A.7})$$

A.2.9 Contigência

Para afirmar que A está contido em B , representado por $A \subset B$, a seguinte condição tem que ser satisfeita:

$$\mu_A(x) \leq \mu_B(x), \forall x \in U \quad (\text{A.8})$$

A.2.10 Igualdade

Dois conjunto nebulosos A e B são iguais, se e somente se,

$$\mu_A(x) = \mu_B(x), \forall x \in U \quad (\text{A.9})$$

A.2.11 Cardinalidade

Cardinalidade de um conjunto nebuloso $A = \{\mu_A(x_i)/x_i | i = 1, 2, \dots, n\}$ é definida como a soma dos graus de pertinência.

$$|A| = \sum_{i=1}^n \mu_A(x_i) \quad (\text{A.10})$$

A.2.12 Complemento Nebuloso (Norma-C)

Considerando $c : [0, 1] \rightarrow [0, 1]$ como sendo um mapeamento que transforma a função de pertinência em um conjunto nebuloso A em uma função de pertinência do complemento de A , isto é:

$$c[\mu_A(x)] = 1 - \mu_{\bar{A}}(x), \quad \forall x \in U \quad (\text{A.11})$$

Para que a função c seja qualificada como um complemento, em qualquer operação, ela deve satisfazer no mínimo, os seguintes requisitos:

Axioma c1: Condição de Contorno

$$c(0) = 1 \quad e \quad c(1) = 0 \quad (\text{A.12})$$

Axioma c2: Condição Decrescente

Para todo $a, b \in [0, 1]$, se $a < b$ então $c(a) \geq c(b)$ onde a e b denota a função de pertinência dos conjuntos nebulosos,

$$a = \mu_A(x) \text{ e } b = \mu_B(x). \quad (\text{A.13})$$

A.2.13 União Nebulosa (Norma-S)

Considerando $s : [0, 1] \times [0, 1] \rightarrow [0, 1]$ como sendo um mapeamento que transforma a função de pertinência de conjuntos nebulosos A e B em uma função de pertinência da união de A e B , descrito por:

$$s[\mu_A(x), \mu_B(x)] = \mu_{A \cup B}(x) \quad (\text{A.14})$$

Para que a função s seja qualificada como um complemento, em qualquer operação, ela deve satisfazer no mínimo, os seguintes requisitos:

Axioma s1: Condição de Contorno

$$s(1, 1) = 1, \quad e \quad s(0, a) = s(a, 0) = a \quad (\text{A.15})$$

Axioma s2: Condição Comutativa

$$s(a, b) = s(b, a) \quad (\text{A.16})$$

Axioma s3: Condição Associativa

$$s(s(a, b), c) = s(a, s(b, c)) \quad (\text{A.17})$$

Axioma s4: Condição Crescente

$$\text{Se } a \leq a^* \quad e \quad b \leq b^*, \text{ então } s(a, b) \leq s(a^*, b^*) \quad (\text{A.18})$$

A.2.14 Interseção Nebulosa (Norma-T)

Considerando $t : [0, 1] \times [0, 1] \rightarrow [0, 1]$ como sendo um mapeamento que transforma a função de pertinência de conjuntos nebulosos A e B em uma função de pertinência da interseção de A e B , descrito por:

$$t[\mu_A(x), \mu_B(x)] = \mu_{A \cap B}(x) \quad (\text{A.19})$$

Para que a função s seja qualificada como um complemento, em qualquer operação, ela deve satisfazer no mínimo, os seguintes requisitos:

Axioma t1: Condição de Contorno

$$t(0, 0) = 0, \quad e \quad t(a, 1) = t(1, 1) = a \quad (\text{A.20})$$

Axioma t2: Condição Comutativa

$$t(a, b) = t(b, a) \quad (\text{A.21})$$

Axioma t3: Condição Associativa

$$t(t(a, b), c) = t(a, t(b, c)) \quad (\text{A.22})$$

Axioma t4: Condição Crescente

$$\text{Se } a \leq a^* \quad e \quad b \leq b^*, \text{ então } t(a, b) \leq t(a^*, b^*) \quad (\text{A.23})$$

A.3 Relações Nebulosas

A relação nebulosa Q corresponde a um conjunto nebuloso definido a partir do produto cartesiano de um conjunto *crisp* U_1, U_2, \dots, U_n dada por:

$$Q = \{((u_1, u_2, \dots, u_n), \mu_Q((u_1, u_2, \dots, u_n))) | (u_1, u_2, \dots, u_n) \in U_1 \times U_2 \times \dots \times U_n\} \quad (\text{A.24})$$

onde $\mu_Q : U_1 \times U_2 \times \dots \times U_n \rightarrow [0, 1]$.

A.4 Projeções e Extensões Cilíndricas em Conjuntos Nebulosos

Seja Q uma relação nebulosa definida em $U_1 \times U_2 \times \cdots \times U_n$ e $\{i_1, \dots, i_k\}$, uma subsequência de $\{1, 2, \dots, n\}$. A **projeção** de Q em $U_{i_1} \times U_{i_2} \times \cdots \times U_{i_k}$ é uma relação Q_P em $U_{i_1} \times U_{i_2} \times \cdots \times U_{i_k}$ definida pela seguinte função de pertinência:

$$\mu_{Q_P} = \{((u_{i_1}, u_{i_2}, \dots, u_{i_k})) = \max_{\mu_{j_1} \in U_{j_1}, \dots, \mu_{j_{n-k}} \in U_{n-k}} \mu_Q(u_1, \dots, u_n) \quad (\text{A.25})$$

Considerando Q_P uma relação nebulosa definida em $U_{i_1} \times U_{i_2} \times \cdots \times U_{i_k}$ e $\{i_1, \dots, i_k\}$, uma subsequência de $\{1, 2, \dots, n\}$, então a **extensão cilíndrica** de Q_P em $\{U_1 \times U_2 \times \cdots \times U_n\}$ é uma relação Q_{PE} em $\{U_1 \times U_2 \times \cdots \times U_n\}$ definida por:

$$\mu_{Q_{PE}}\{((u_1, u_2, \dots, u_n))\} = \mu_{Q_P}((u_{i_1}, u_{i_2}, \dots, u_{i_k})) \quad (\text{A.26})$$