



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Renato Borba Teixeira

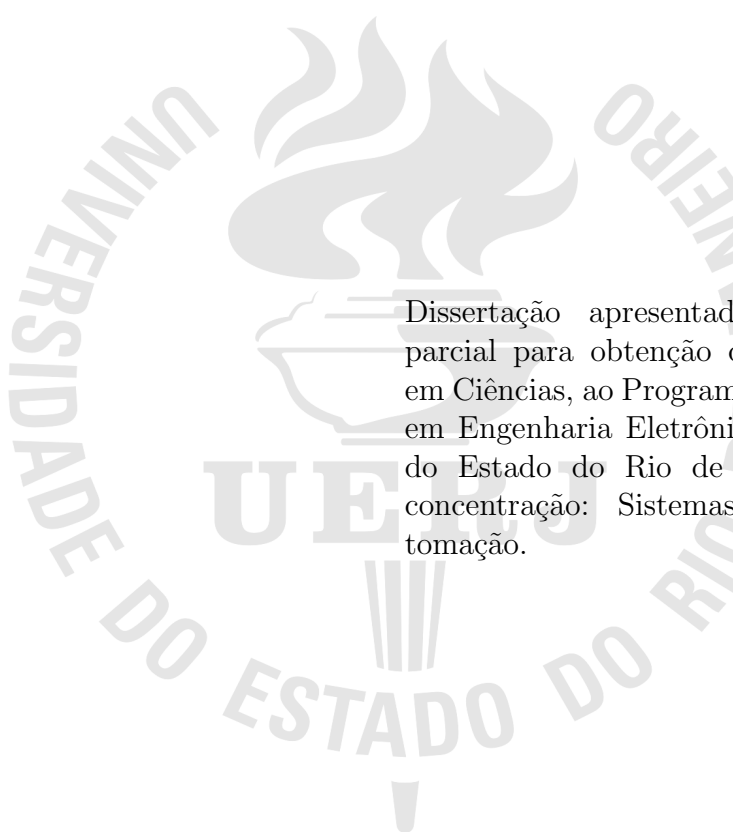
**Contribuições à Teoria de Controle Adaptativo Utilizando
Técnicas de Inteligência Computacional e Funções de
Monitoração**

Rio de Janeiro

2017

Renato Borba Teixeira

**Contribuições à Teoria de Controle Adaptativo Utilizando Técnicas de
Inteligência Computacional e Funções de Monitoração**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre em Ciências, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientadores: Prof. Dr. José Franco Machado do Amaral

Prof. Dr. Tiago Roux de Oliveira

Rio de Janeiro

2017

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

T266 Teixeira, Renato Borba.
Contribuição à teoria de controle adaptativo utilizando técnicas de inteligência computacional e funções de monitoração / Renato Borba Teixeira. – 2017.
86f.

Orientadores: José Franco Machado do Amaral e Tiago Roux de Oliveira.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia Eletrônica - Teses. 2. Redes neurais (Computação) - Teses. 3. Algoritmos genéticos - Teses. 4. Controladores programáveis - Teses. I. Amaral, José Franco Machado do. II. Oliveira, Tiago Roux de. III. Universidade do Estado do Rio de Janeiro. IV. Título.

CDU 004.032.26

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Data

Renato Borba Teixeira

**Contribuições à Teoria de Controle Adaptativo Utilizando Técnicas de
Inteligência Computacional e Funções de Monitoração**

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre em Ciências, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em: 21 de Dezembro de 2017

Banca Examinadora:

Prof. Dr. José Franco Machado do Amaral (Orientador)
Faculdade de Engenharia - UERJ

Prof. Dr. Tiago Roux de Oliveira (Orientador)
Faculdade de Engenharia - UERJ

Prof. Dr. Pedro Henrique Gouvêa Coelho
Faculdade de Engenharia - UERJ

Prof. Dr. Ramon Romankevicius Costa
Universidade Federal do Rio de Janeiro - UFRJ - COPPE

Rio de Janeiro

2017

AGRADECIMENTO

Agradeço primeiramente a Deus, por ter guiado meus caminhos até esse momento. Dando-me força, coragem e sabedoria, me cercando de pessoas de bom coração, sempre dispostas a ajudar. Que eu possa retornar ao mundo tudo de bom que recebo e aprendo.

Aos meus pais Plínio Lima Teixeira e Maria de Fatima Borba Teixeira, que sempre me incentivaram a estudar e sempre foram e ainda são exemplos de como levar uma vida ética, com honra e trabalho duro, mostrando que não existem atalhos para construir algo grandioso, todo o caminho deve ser percorrido integralmente.

À minha mãe por tudo já mencionado acima e por me mostrar como amor de mãe é algo tão grandioso.

À minha irmã Karla Borba Teixeira por todo apoio e preocupação, que possamos sempre apoiar um ao outro.

À minha namorada Rayza Telo Loureiro, por ser uma grande amiga e companheira de vida. Mostrando que nossas conversas filosóficas, científicas ou mesmo cotidianas ainda durarão por muitos anos. Por me apoiar em meus planos de vida, me compreender e me incentivar sempre. Que ainda trilhemos juntos muitos caminhos na vida.

Aos meus orientadores Tiago Roux de Oliveira e José Franco Machado do Amaral por toda a orientação, apoio, paciência e ensinamentos ao longo desses anos, sem vocês esse trabalho não teria acontecido.

Agradeço especialmente ao meu orientador Tiago Roux de Oliveira por ter se tornado um orientador na vida acadêmica, profissional e particular, sempre pronto para uma boa conversa com bons conselhos à respeito da vida. Obrigado por toda a ajuda nos momentos difíceis.

À todos os professores da UERJ que se dedicam a ensinar e manter viva essa instituição tão importante para o país.

Na vida, não existe nada a temer, mas a entender.

Marie Curie

RESUMO

TEIXEIRA, Renato Borba. Contribuições à Teoria de Controle Adaptativo Utilizando Técnicas de Inteligência Computacional e Funções de Monitoração. 2017. 86 f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2017.

Este trabalho tem como principal objetivo investigar a aplicação de técnicas inteligentes em controladores adaptativos do tipo extremal e por modelo de referência, de forma a melhorar o desempenho de tais controladores. Essas técnicas foram aplicadas em três estudos de caso. No primeiro estudo de caso foi desenvolvida uma rede neural artificial (RNA) capaz de suprimir as oscilações de alta frequência existentes na saída de um controlador extremal. A supressão dessas oscilações é importante pois elas prejudicam o desempenho de controle em aplicações práticas. A rede neural artificial utilizada foi uma perceptron multicamadas com uma entrada e uma saída, com uma camada escondida. Para o seu treinamento foi utilizada uma pequena amostragem obtida da saída oscilatória do controle extremal. No segundo estudo de caso foram aplicados algoritmos genéticos (AG) na inicialização de controladores adaptativos por modelo de referência (MRAC) como forma de reduzir os conhecimentos prévios necessários para a implementação desse tipo de controlador no problema de rastreamento de trajetórias. Na primeira abordagem foram utilizados sistemas com uma entrada e uma saída onde o AG encontra os parâmetros para a inicialização do MRAC de forma que os transitórios são reduzidos de maneira significativa sem a necessidade de aumentar o sinal de controle. Na segunda abordagem, considera-se sistemas de múltiplas entradas e saídas onde o AG encontra os sinais de direção de controle da matriz de ganho de alta frequência, de forma que a estabilidade global do controlador MRAC e a convergência do erro de rastreamento para zero possam ser garantidas. Esse conhecimento prévio é fundamental para o funcionamento desse tipo de controlador em sistemas reais, onde dependendo da aplicação torna-se impossível de saber previamente. Os resultados do segundo estudo de caso foram comparados com um método de funções de monitoração também desenvolvido nesse trabalho, onde o AG se mostra ainda mais útil conforme o número de entradas e saídas do sistema aumenta. O terceiro estudo de caso aplica funções de monitoração em conjunto com con-

troladores adaptativos binários do tipo BMRAC como forma de resolver o problema do desconhecimento dos sinais dos menores principais da matriz de ganho de alta frequência (HFG), responsável por definir a direção de controle. A grande vantagem desse método é ser aplicável em tempo real. O método proposto foi desenvolvido para sistemas de grau relativo um com múltiplas entradas e saídas (MIMO), pois esses tipos de sistemas apresentam desafios para controladores BMRAC até mesmo quando os sinais da matriz HFG são conhecidos, devido ao grande número de restrições necessárias e conhecimentos prévios. Todos os métodos aplicados apresentaram bons resultados, mostrando sua eficiência e servindo de base para novos estudos.

Palavras-chave: controle extremal; controle adaptativo; redes neurais artificiais; algoritmos genéticos; funções de monitoração.

ABSTRACT

TEIXEIRA, Renato Borba. Contributions to the Adaptive Control Theory using Computational Intelligence Techniques and Monitoring Functions. 2017. 86 f. Dissertation (Master Degree in Electronic Engineering) - Faculty of Engineering, State University of Rio de Janeiro (UERJ), Rio de Janeiro, 2017.

The main goal of this dissertation is to apply intelligent techniques to adaptive controllers, in order to improve their performance. These techniques are applied to three cases. In the first case, it was developed an artificial neural network that is able to suppress high-frequency oscillations in the output of an extremum seeking control system. High-frequency oscillation degrades the control performance in practical applications. The artificial neural network used is a multilayer perceptron with one input, one hidden layer and one output. For the training, only a small sample of the extremum seeking output signal is utilized. In the second case, a genetic algorithm (GA) is applied to initialize the parameters of a model reference adaptive control (MRAC), by reducing the previous knowledge required for the implementation of this kind of controller in the trajectory tracking problem. First, the GA is used to find the best control parameters for single-input-single-output (SISO) systems, so that the transient of the output responses are significantly reduced without needing to increase the control signal amplitudes. Second, multi-input-multi-output (MIMO) plants were taken into account, where the GA is able to find the control direction signs of the high-frequency gain (HFG) matrix, so that the global stability/convergence of the multivariable MRAC controller is guaranteed. This prior knowledge is fundamental to the operation of the multivariable adaptive controller in real-world scenarios, which depending on the application is impossible to be known a priori. The results of the latter case are compared with a method of monitoring functions, also developed in this work, where the benefits of using the GA for the closed-loop system are evident as the number of inputs and outputs increases. The last contribution applies monitoring functions with adaptive binary control, of the BMRAC type, to solve the problem of high frequency gain matrix with leading principal minors of unknown signs, responsible to define the control direction. The proposed method is developed to multi-input-multi-output (MIMO) systems of relative degree one, since the design of BMRAC

controllers even when the signs of the HFG matrix are known are very challenging, due to the large number of restrictions required and prior knowledge. All methods exhibited good performance results, showing their efficiency and, therefore, opening new possibilities to new studies.

Keywords: extremum seeking; adaptive control; artificial neural network; genetic algorithm; monitoring functions.

LISTA DE FIGURAS

Figura 1 - Diagrama de Blocos ESC	25
Figura 2 - Rede Perceptron Multicamadas	26
Figura 3 - Diagrama de Blocos ESC com RNA	27
Figura 4 - Sinal de saída da planta com ESC	29
Figura 5 - Dados amostrados para treinamento	29
Figura 6 - Número de dados <i>vs.</i> MSE, Épocas e H	30
Figura 7 - Sinal de saída da planta com ESC antes e após o acionamento da RNA em $t = 20s$	31
Figura 8 - Busca pelo z^* antes e após o acionamento da RNA em $t = 20s$	32
Figura 9 - Controle Adaptativo por Modelo de Referência	34
Figura 10- Diagrama de blocos AG	44
Figura 11- Diagrama de blocos	45
Figura 12- Simulação realizada no Matlab	46
Figura 13- Sinal de saída $y(t)$	47
Figura 14- Sinal de controle $u(t)$	47
Figura 15- Sinais de saída $y(t)$ e $y_m(t)$	48
Figura 16- Sinal de controle $u(t)$	48
Figura 17- Sinal de erro $e(t)$	49
Figura 18- Simulação do segundo estudo de caso	50
Figura 19- Subsistema 1	51
Figura 20- Subsistema 2	51
Figura 21- Sinais de saída da planta $y(t)$ e do modelo $y_m(t)$	52
Figura 22- Sinais de erro $e_1(t)$ e $e_2(t)$	52
Figura 23- Sinais de controle $u_1(t)$ e $u_2(t)$	53
Figura 24- Sinais de saída da planta $y(t)$ e do modelo $y_m(t)$	53
Figura 25- Sinais de erro $e_1(t)$ e $e_2(t)$	54
Figura 26- Sinais de controle $u_1(t)$ e $u_2(t)$	54
Figura 27- Sinal de monitoração com norma do erro $ e(t) $	55
Figura 28- Diagrama de blocos	68

Figura 29- Saída $y_{1m}(t)$ e $y_1(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	71
Figura 30- Saída $y_{2m}(t)$ e $y_2(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	71
Figura 31- Saída $y_{1m}(t)$ e $y_1(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$	72
Figura 32- Saída $y_{2m}(t)$ e $y_2(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$	72
Figura 33- Sinal de erro $e(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	73
Figura 34- Sinal de erro $e(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$	73
Figura 35- Sinal de controle $u(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	74
Figura 36- Sinal de controle $u(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$	74
Figura 37- Parâmetros Θ_1 sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	75
Figura 38- Parâmetros Θ_2 sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	75
Figura 39- Parâmetros Θ_1 com fator de projeção e $\gamma_1 = \gamma_2 = 1$	76
Figura 40- Parâmetros Θ_2 com fator de projeção e $\gamma_1 = \gamma_2 = 1$	76
Figura 41- Função de monitoração 1 com $ e_1(t) $ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$	77
Figura 42- Direção de controle referente à função de monitoração 1	77
Figura 43- Função de monitoração 1 com $ e_1(t) $ com fator de projeção e $\gamma_1 = \gamma_2 = 1$	78
Figura 44- Direção de controle referente à função de monitoração 1	78
Figura 45- Sinal de erro $e(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 100$	79
Figura 46- Sinal de controle $u(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 100$	79
Figura 47- Parâmetros Θ_1 com fator de projeção e $\gamma_1 = \gamma_2 = 100$	80
Figura 48- Parâmetros Θ_2 com fator de projeção e $\gamma_1 = \gamma_2 = 100$	80

SUMÁRIO

	INTRODUÇÃO	14
1	SUPRESSÃO DE OSCILAÇÕES EM CONTROLE EXTREMAL VIA REDES NEURAIAS	19
1.1	Formulação do Problema	19
1.1.1	Objetivo de Controle e Principal Hipótese	19
1.1.2	Equação Básica do Erro	20
1.1.3	Limitante Superior de Erro.....	22
1.2	Lei de Controle.....	22
1.2.1	Função de Monitoração	23
1.2.2	Convergência Global	24
1.3	Redes Neurais Artificiais	24
1.3.1	Topologia da RNA	25
1.3.2	Algoritmo de Treinamento	26
1.4	Desenvolvimento	27
1.4.1	Obtenção e Tratamento dos Dados	28
1.4.2	Treinamento e validação	30
1.4.3	Resultados obtidos	31
2	ALGORITMOS GENÉTICOS PARA INICIALIZAÇÃO DE CONTROLADORES ADAPTATIVOS E REDUÇÃO DE CONHECIMENTOS PRÉVIOS	33
2.1	Controle Adaptativo por Modelo de Referência	33
2.1.1	Conhecimentos Preliminares	34
2.2	Formulação do Problema	35
2.2.1	Revisão de Abordagens Anteriores para o Controle Adaptativo.....	36
2.2.2	Fatoração da matriz de ganho de alta frequência.....	38
2.2.3	Parametrização do sinal de controle e lei de adaptação	40
2.2.4	Análise de Estabilidade	41

2.3	Algoritmos Genéticos aplicados à Controle Adaptativo por Modelo de Referência	43
2.3.1	Desenvolvimento e Resultados Obtidos.....	44
2.3.2	Primeiro estudo de caso: encontrar $\theta_i(0)$	45
2.3.3	Segundo estudo de caso: sinais desconhecidos dos menores principais de K_p	49
3	BMRAC APLICADO EM SISTEMAS MIMO UTILIZANDO FUNÇÕES DE MONITORAÇÃO	56
3.1	Conhecimento Prévio	56
3.2	Formulação do problema	58
3.2.1	MRAC com fator de projeção.....	59
3.2.2	Análise de estabilidade	60
3.3	Função de monitoração	66
3.4	Nova lei de adaptação com função de monitoração	68
3.5	Simulações e resultados	70
	Produção Científica	81
	CONCLUSÃO	82
	REFERÊNCIAS	84

INTRODUÇÃO

A aplicação de Sistemas Inteligentes no aperfeiçoamento de tecnologias amplamente difundidas ou até mesmo na resolução de questões, até então sem respostas, tem tornado esse tema um objeto de grande interesse de estudo para engenheiros e pesquisadores em todo o mundo.

Nessa dissertação utiliza-se sistemas inteligentes como ferramentas fundamentais para melhorar o desempenho de alguns métodos de controle conhecidos e outros até mesmo inovadores. O objetivo é tornar as estratégias de controle empregadas ainda mais robustas e confiáveis, mostrando que as ferramentas de inteligência computacional podem ser empregadas em diversos cenários, sistemas e métodos, se adaptando bem de acordo com cada finalidade.

Essa dissertação apresenta três principais aplicações, onde em cada uma delas foi abordado um ou mais estudos de caso.

Foram utilizadas redes neurais artificiais (RNA) e algoritmos genéticos (AG) como técnicas inteligentes e, além disso, foram utilizadas funções de monitoração chaveadas. Os problemas abordados consideram controladores: do tipo extremal (*Extremum Seeking Control* - ESC) com supressão de oscilação; do tipo adaptativo por modelo de referência (*Model Reference Adaptive Control* - MRAC) com inicialização *offline* da adaptação e direção de controle; e do tipo adaptativo binário (*Binary Model Reference Adaptive Control* - BMRAC) multivariável para adaptação em tempo real da direção de controle desconhecida.

Controle extremal utilizando redes neurais

O Controle Extremal (ESC) é um método de otimização em tempo real criado em 1922, que apresenta grande destaque atualmente, principalmente pelo desenvolvimento de sua teoria e aplicações em campos da indústria, e até mesmo fora da área de engenharia de controle (Ariyur; Krstic, 2003). O ESC vem sendo aplicado recentemente em sistemas de combustão, biomédicos e controle de vazão, todos eles caracterizados pela complexidade e dificuldades para concepção de um modelo matemático para a planta (Ariyur; Krstic, 2003).

Existem muitas versões de ESC com várias abordagens em relação ao estudo de estabilidade. A versão mais comum consiste em aplicar um sinal de perturbação ou excitação

periódica com o propósito de estimar o gradiente do mapeamento não-linear desconhecido com extremo que deve ser otimizado (Ariyur; Krstic, 2003), outra versão também existente utiliza os sinais disponíveis do sistema (entrada e saída) para desenvolver o controle dinâmico que busca a otimização das suas entradas (Oliveira et al., 2012).

Em (Aminde, 2013) podemos ver uma maneira nova de utilizar o ESC em conjunto com funções de monitoração, aplicado para sistemas dinâmicos não-lineares com escape em tempo finito (em malha aberta) e que consegue obter convergência global, encontrando o ponto extremo mesmo na presença de outros pontos de extremo locais (máximos ou mínimos). Porém, o problema de oscilação de alta frequência em torno do ponto de extremo encontrado ainda persiste, e esse efeito é indesejável por causar problemas como a deterioração do atuador, excitar modos de alta frequência da planta e prejudicar o desempenho de controle em aplicações práticas.

O objetivo desse estudo de caso é apresentar uma forma de reduzir a oscilação de alta frequência em torno do ponto de extremo encontrado pelo ESC. Nesse trabalho será utilizado um ESC baseado em funções de monitoração, semelhante ao encontrado em (Aminde, 2013), porém para cancelar a oscilação de alta frequência será utilizada uma rede neural artificial (RNA), que aprenderá o comportamento do sinal indesejado e contribuirá para anulá-lo.

MRAC utilizando algoritmos genéticos

Apesar de todo o progresso alcançado nas áreas de controle adaptativo, as aplicações desse tipo de controlador para sistemas de múltiplas entradas e saídas (*multi-input-multi-output* - MIMO) não obtiveram grande sucesso nem mesmo para casos de grau relativo um, principalmente devido ao fato dos controladores adaptativos por modelo de referência (*Model Reference Adaptive Control* - MRAC) para caso MIMO necessitarem de premissas muito mais rigorosas em relação à planta do que os casos de uma entrada e uma saída (*single-input-single-output* - SISO). A maioria das dificuldades estão relacionadas à matriz de ganho de alta frequência K_p (Costa et al., 2003).

Por exemplo, para o MRAC utilizando a estratégia direta são realizadas premissas restritas em relação ao conhecimento prévio de K_p . Por exemplo, em (Ioannou, 2012) assumiu-se que a matriz S_p é conhecida tal que $K_p S_p = (K_p S_p)^T > 0$. Por outro lado, utilizando a adaptação indireta é necessário que a estimativa de K_p seja não-singular para todo instante de tempo.

Os algoritmos genéticos (AG) são algoritmos de busca inspirados no processo de evolução natural, podendo ser aplicado em problemas de otimização onde é necessário encontrar parâmetros desconhecidos (Coppin, 2015).

Nesse trabalho utilizaremos um AG para inicialização *offline* da lei de adaptação dos parâmetros desconhecidos de um controlador MRAC aplicado à um sistema SISO para melhorar o transitório do erro de rastreamento. Em seguida um AG será aplicado em um sistema MIMO, porém nessa aplicação ele será responsável por descobrir a combinação correta de sinais da matriz de ganho de alta frequência K_p capaz de estabilizar o sistema e fazê-lo convergir, o que seria impossível para o caso da matriz K_p ser desconhecida e, ainda pior, quando sua dimensão for grande gerando um número de combinações altíssimo, conforme apresentado em (Martensson, 1991). Será utilizado o mesmo sistema que em (Costa et al., 2003), porém com a diferença que em nosso trabalho os menores principais são assumidos desconhecidos. Os resultados obtidos para o caso MIMO serão ainda comparados com os resultado de um método aplicando funções de monitoração, desenvolvido também nesse trabalho baseado nos resultados de (Oliveira et al., 2010), onde tal função é responsável por mudar o conjunto de combinações possíveis sempre que o módulo do sinal de erro atingir determinado limiar.

Nesse estudo de caso foi utilizado a fatoração de $K_p = SDU$, da mesma forma que foi utilizada em (Costa et al., 2003), onde S é uma matriz simétrica positiva definida, D é uma matriz diagonal e U é uma matriz triangular superior unitária. Essa fatoração de K_p é conveniente devido à grande importância de cada um de seus fatores S , D e U .

BMRAC com funções de monitoração

Em alguns casos a mudança repentina de parâmetros pode ocasionar sérios problemas e comprometer o funcionamento de alguns sistemas, por exemplo nas condições de voo de aeronaves, causadas devido a falhas que gerem mudanças de parâmetros e direção de controle. Segurança de voo para aeronaves que tenham sofrido danos estruturais tem sido uma área de grande interesse de pesquisa, pois tais danos estruturais podem causar mudanças na aerodinâmica e centro de massa da aeronave, fazendo com que a modelagem utilizada para o projeto de controle em pleno voo não seja mais válida (Liu; Tao, 2008).

Muitos estudos baseados em falhas de aeronaves foram realizados, como pode ser visto em (Nguyen et al., 2006) (Liu; Tao, 2006) (Lombaerts et al., 2007) (Nguyen et al., 2007) (Liu; Tao, 2008). Em (Liu; Tao, 2008) foi realizado o estudo de caso onde as

falhas podem causar a mudança dos sinais dos menores principais da matriz de ganho de alta frequência (K_p), onde foi utilizada uma decomposição LDS em conjunto com um controle MRAC e ganhos de Nussbaum para dar maior grau de liberdade em relação ao conhecimento dos sinais da matriz de ganho de alta frequência.

Nesse estudo de caso será utilizado um controlador adaptativo binário do tipo BMRAC com fatoração SDU (a mesma fatoração que foi utilizada no capítulo 2) aplicado em sistemas MIMO, como foi feito em (Costa et al., 2003), porém em nossa aplicação os sinais de matriz de ganho de alta frequência são totalmente desconhecidos. Para descobrir os sinais corretos que fazem o controle convergir foi utilizado funções de monitoração para cada menor principal da matriz.

A grande contribuição desse estudo de caso está em apresentar um controlador BMRAC para sistemas MIMO onde não existe nenhum conhecimento prévio dos sinais dos menores principais da matriz de ganho de alta frequência e a busca é realizada em tempo real, diferentemente da aplicação anterior com AG.

Objetivo e Proposta do Trabalho

O foco principal desse trabalho é a pesquisa sobre métodos inteligentes aplicados a estratégias de controle adaptativo. A pesquisa inclui os seguintes tópicos:

- Supressão de oscilação em regime permanente de um controle Extremum Seeking (ES) utilizando redes neurais artificiais (RNA);
- Ajuste paramétrico para inicialização de Controle Adaptativo por Modelo de Referência (MRAC) utilizando algoritmos genéticos (AG);
- Aplicação de funções de monitoração como forma de reduzir o conhecimento prévio dos parâmetros de direção de controle dos controladores BMRAC.

O objetivo final é investigar se os métodos inteligentes são capazes de contribuir de forma significativa nas estratégias de controle adaptativo apresentadas, com a finalidade de resolver problemas como oscilações em regime permanente, transitórios indesejáveis e esforço de controle exagerado.

Organização Geral da Dissertação

No Capítulo 1, é apresentado o estudo de caso utilizando redes neurais artificiais para melhorar o desempenho de um controlador extremal, onde a rede neural é utilizada para reduzir as oscilações na saída do controlador.

No Capítulo 2 foram utilizados algoritmos genéticos (AG) para melhorar a inicialização de um controlador por modelo de referência (MRAC) e para redução de conhecimentos prévios sobre a planta, pois ao se utilizar esse tipo de controlador existe uma quantidade significativa de restrições e conhecimentos prévios necessários e, com a ajuda do AG, foi possível reduzir o número de restrições.

No final dos estudos de caso apresentados no Capítulo 2 foi vislumbrada a possibilidade de utilizar funções de monitoração como forma de reduzir os conhecimentos prévios para aplicação de controladores BMRAC para casos MIMO, em tempo real, o que resulta em uma grande vantagem. Esses resultados deram origem ao Capítulo 3, onde são apresentados os desenvolvimentos e resultados ao aplicarmos funções de monitoração para decidir a direção de controle. A função de monitoração atua em cada entrada/saída gerando a combinação correta e consequentemente a direção de controle correta.

Ao final encontra-se um capítulo apresentando as produções científicas geradas pelos estudos de caso e finalmente a conclusão, com as considerações finais e sugestões de trabalhos futuros. Para facilitar a leitura, todos os capítulos desta dissertação foram escritos de modo a serem seguidos de maneira independente sem grandes alterações de compreensão final. Em particular, as hipóteses feitas em um determinado capítulo se restringem a ele de forma a deixá-los auto-contidos na medida do possível.

1 SUPRESSÃO DE OSCILAÇÕES EM CONTROLE EXTREMAL VIA REDES NEURAIIS

O objetivo desse capítulo é apresentar uma forma de eliminar a oscilação de alta frequência em torno do ponto de extremo encontrado pelo ESC. Nesse estudo será utilizado um ESC em conjunto com funções de monitoração, semelhante ao encontrado em (Aminde et al., 2013), porém para cancelar a oscilação de alta frequência será utilizada uma rede neural artificial (RNA), que aprenderá o comportamento do sinal indesejado e contribuirá para anulá-lo.

1.1 Formulação do Problema

Para otimização em tempo real em sistemas de uma dimensão e grau relativo um, foi considerado o simples caso de um integrador com uma não linearidade na saída:

$$\dot{z} = u \tag{1.1}$$

$$y = \Phi(z) \tag{1.2}$$

onde $u \in R$ é a entrada de controle, $z \in R$ é o vetor de estado e $y \in R$ é o sinal de saída medido. A função $\Phi : R \rightarrow R$ é a não linearidade desconhecida que deve ser maximizada (ou minimizada), sendo localmente Lipschitz. Assume-se por conveniência que o instante inicial é $t_0 = 0$ s. Em (1.1)-(1.2) os sinais de perturbações originalmente considerados em (Aminde et al., 2013) foram omitidos para simplificar a representação.

1.1.1 Objetivo de Controle e Principal Hipótese

O principal objetivo do ESC é a otimização em tempo real, entretanto o ESC pode ser reformulado como um problema de rastreamento de trajetória onde a direção de controle é desconhecida (Oliveira et al., 2012). O objetivo do ESC aplicado é encontrar uma lei de controle u via realimentação de saída, tal que, partindo de qualquer condição inicial, o sistema seja conduzido para o ponto de extremo $y^* = \Phi(z^*)$ de (1.2) e permaneça o mais próximo possível desse ponto. Sem perda de generalidade, podemos considerar o problema de maximização e utilizar as notações $\Phi'(z) := \frac{d\Phi(z)}{dz}$ e $\Phi''(z) := \frac{d^2\Phi(z)}{dz^2}$, assumindo

a seguinte hipótese.

(H1) (Função Objetivo): Existe um único máximo $z^* \in R$ em que $y^* = \Phi(z^*)$ é um extremo da função objetivo $\Phi : R \rightarrow R$, satisfazendo:

$$\Phi'(z^*) = 0, \quad \Phi''(z^*) < 0$$

$$\Phi(z^*) > \Phi(z), \quad \forall z \in R, \quad z \neq z^*$$

e para qualquer $\Delta > 0$, existe uma constante $L_\Phi(\Delta) > 0$ tal que

$$L_\Phi(\Delta) \leq |\Phi'(z)|, \forall z \notin \Upsilon_\Delta := \{z : |z - z^*| < \Delta/2\}$$

onde Υ_Δ é chamado vizinhança- Δ de z^* e Δ pode ser escolhido arbitrariamente pequeno permitindo um L_Φ pequeno.

1.1.2 Equação Básica do Erro

A partir de (1.1) e (1.2) é possível obter a derivada primeira do sinal de saída y , dada por

$$\dot{y} = k_p(z)u \tag{1.3}$$

onde k_p é o ganho de alta frequência (*High Frequency Gain*- HFG) e pode ser dado como

$$k_p(z) = \Phi'(z). \tag{1.4}$$

Da mesma forma que em (Oliveira et al., 2012), o $\text{sgn}(k_p)$ também é chamado de *direção de controle*. A hipótese (H1) nos leva a considerar o sistema de controle com um HFG dependente do estado que muda de sinal próximo do ponto de extremo de forma contínua.

A partir de (1.4) e (H1), k_p satisfaz

$$|k_p(z)| \geq \underline{k}_p > 0, \quad \forall z \notin \Upsilon_\Delta, \tag{1.5}$$

onde $\underline{k}_p \leq L_\Phi$ é uma constante de limite inferior conhecida para o HFG, considerando todas as incertezas em $\Phi(\cdot)$.

O sinal de erro é dado por

$$e(t) = y(t) - y_m(t), \quad (1.6)$$

onde $y_m \in R$ é uma rampa gerada pelo modelo de referência

$$\dot{y}_m = r_m, \quad (1.7)$$

onde $r_m > 0$ é uma constante. Para evitar que o sinal de referência y_m se torne ilimitado, pode-se saturar a saída do modelo em um limitante superior conhecido para y^* , sem afetar o desempenho do sistema.

A principal ideia em (Aminde et al., 2013) é projetar uma lei de controle onde $y(t)$ se aproxime o mais perto possível de y_m , dessa maneira, y é conduzido para a vizinhança do máximo $y^* = \Phi(z^*)$ e permanece próximo do valor ótimo y^* . Para isso, foi proposta uma lei de controle u tal que o erro de rastreamento $e(t)$ decaia até que a vizinhança- Δ seja atingida, ou seja, a vizinhança do máximo z^* .

Entretanto, uma vez que y alcança a vizinhança de y^* , o HFG irá se aproximar de zero e a controlabilidade será perdida. Consequentemente, o rastreamento de y_m também irá parar. Porém a vizinhança do máximo já foi atingida, como desejado, e a estratégia de controle foi projetada para garantir que y irá permanecer próximo de y^* .

A partir de (1.3), (1.6) e (1.7), adicionando e subtraindo $\lambda_m e$ à equação da derivada do erro no tempo temos

$$\dot{e} = k_p u - r_m + \lambda_m e - \lambda_m e, \quad (1.8)$$

$$\dot{e} = -\lambda e + k_p(u + d_e), \quad (1.9)$$

onde $\lambda_m > 0$ é uma constante arbitrária e

$$d_e := \frac{1}{k_p}[-r_m + \lambda_m e]. \quad (1.10)$$

1.1.3 Limitante Superior de Erro

Em (Aminde et al., 2013) foi demonstrado que se a lei de controle

$$u = -\text{sgn}(k_p)\rho(t)\text{sgn}(e) \quad (1.11)$$

for usada com uma função de modulação não negativa ρ satisfazendo

$$\rho \geq |d_e| + \delta, \quad (1.12)$$

e $\delta > 0$ sendo uma constante arbitrária e pequena, então usando o Lema da Comparação (Filippov, 1960), tem-se $\forall t \in [t_i, t_M)$:

$$|e(t)| \leq \zeta(t), \zeta(t) := |e(t_i)|e^{-\lambda_m(t-t_i)}, \quad (1.13)$$

onde $t_i \in [0, t_M)$.

O principal problema é que o $\text{sgn}(k_p)$ é desconhecido e, portanto, não pode ser implementado. Em (Aminde et al., 2013) é apresentado um esquema de chaveamento, baseado em função de monitoração, desenvolvido para resolver o problema do desconhecimento da direção de controle fora da vizinhança- Δ . Tal lei de controle é apresentada a seguir.

1.2 Lei de Controle

No caso apresentado, a lei de controle para plantas com HFG desconhecido foi definida como:

$$u = (-1)^{k+m}\rho(t)\text{sgn}(e), \quad (1.14)$$

onde $k \in \{1, 2, \dots\}$ é o índice de chaveamento gerado pela função de monitoração, apresentada na próxima subseção, utilizada para decidir quando u chaveia e $m \in \{0, 1\}$. Assim, dependendo da escolha de m (0 ou 1) escolhemos o valor inicial de $(-1)^{k+m}$.

Em (1.11), $\rho(t) > 0$ é uma função de modulação contínua designada para satisfazer (1.12). Considerando (1.1)-(1.2), o modelo de referência (1.7), a lei de controle (1.11) pode

ser escolhida através da *Proposição 1* em (Aminde et al., 2013):

$$\rho = \frac{1}{\underline{k}_p} [r_m + \lambda_m |e|] + \delta, \quad (1.15)$$

onde (1.15) satisfaz (1.12) somente fora da região Υ_Δ .

1.2.1 Função de Monitoração

Nessa subseção é apresentada uma breve explicação sobre o funcionamento da função de monitoração (Oliveira et al., 2010). Lembrando que a inequação (1.13) é garantida quando a direção de controle é conhecida, é natural usar ζ em (1.13) como referência para se decidir quando o chaveamento de u em (1.11) é necessário. Isto é, o chaveamento ocorre somente quando (1.13) é violada. Portanto, considerando a seguinte função:

$$\varphi_k(t) = |e(t_k)|e^{-\lambda_m(t-t_k)} + r, \quad (1.16)$$

onde t_k é o instante de chaveamento e $r \geq 0$ é qualquer constante arbitrariamente pequena. É importante ressaltar que caso fosse utilizado um r com um valor suficientemente pequeno (da ordem de L_ϕ ou Δ em (H1)), o problema de oscilação no extremo seria reduzido porém para isso seria necessário um sinal de controle demasiadamente grande (conservador), o que não é desejado e em alguns casos inviável.

A função de monitoração φ_m é definida como

$$\varphi_m(t) := \varphi_k(t), \quad \forall t \in [t_k, t_{k+1}). \quad (1.17)$$

Note que de (1.16) e (1.17), tem-se $|e(t)| < |\varphi_k(t)|$ em $t = t_k$. Dessa forma, t_k é definido como o instante em que a função de monitoração $\varphi_m(t)$ encontra $|e(t)|$, isto é,

$$t_{k+1} := \begin{cases} \min\{t > t_k : |e(t)| = \varphi_k(t)\}, & \text{se existir,} \\ +\infty, & \text{caso contrário,} \end{cases} \quad (1.18)$$

onde $k \in \{1, 2, \dots\}$ e $t_0 := 0$ s.

Para construção, a seguinte desigualdade é obtida diretamente de (1.17).

$$|e(t)| \leq \varphi_m(t), \quad \forall t \in [0, +\infty). \quad (1.19)$$

1.2.2 Convergência Global

O teorema a seguir mostra que o controlador por realimentação de saída baseado em função de monitoração conduz z para a região Υ_Δ definida em (H1) onde encontra-se o valor desconhecido z^* que maximiza y . Isto não implica que $z(t)$ permaneça em torno de $\Upsilon_\Delta, \forall t$. Entretanto, a amplitude das oscilações em torno de y^* pode ser feita da ordem de r .

Teorema 1.2.1. *Considere o sistema (1.1), com saída ou função objetivo (1.2), lei de controle (1.11), modelo de referência (1.7), função de monitoração (1.16)-(1.17) e função de modulação (1.15). Assumindo que (H1) seja satisfeita, então: (i) a região Υ_Δ em (H1) é globalmente atrativa, sendo alcançada em tempo finito e (ii) para L_Φ suficientemente pequeno, as oscilações de $y(t)$ em torno do valor máximo y^* podem ser feitas da ordem de r , com r definido em (1.16). Desde que o sinal y_m possa ser saturado em (1.7), todos os sinais em malha fechada permanecem uniformemente limitados.*

A prova para este teorema encontra-se em (Aminde et al., 2013), Teorema 1.

Na Figura 1 é apresentado um diagrama de blocos básico do funcionamento do ESC, onde o sinal de erro $e(t)$ é utilizado pela função de monitoração para decidir a direção de controle.

1.3 Redes Neurais Artificiais

Redes Neurais Artificiais podem ser definidas como um conjunto de unidades de processamento, composta por neurônios artificiais, que foram desenvolvidos utilizando como inspiração o neurônio biológico. Possuem a capacidade de aquisição e manutenção do conhecimento adquirido baseado em dados apresentados (Silva et al., 2010).

As pesquisas com Redes Neurais Artificiais (RNAs) foram iniciadas na década de 1940, tendo sido inspiradas em células nervosas vivas e no processo de interligação entre elas. O trabalho desenvolvido na época consistia em um modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio biológico (Tafner, 1998).

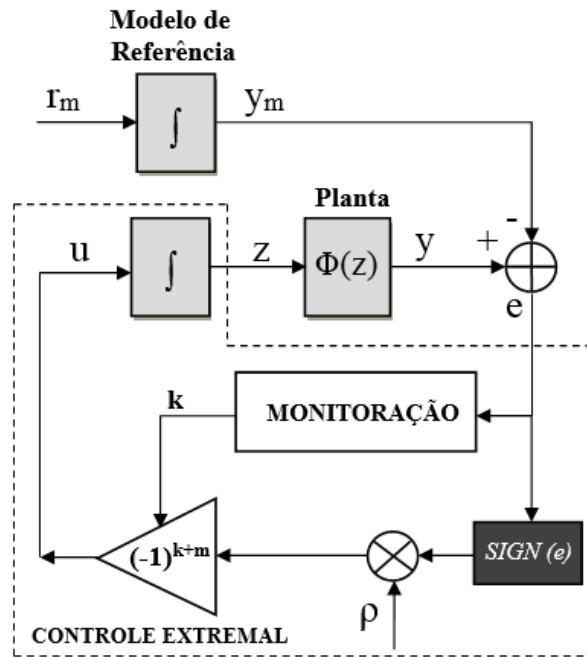


Figura 1 - Diagrama de Blocos ESC

1.3.1 Topologia da RNA

Uma rede neural artificial pode ser dividida basicamente em três partes: camada de entrada, camada escondida e camada de saída.

A camada de entrada é responsável pelo recebimento das informações de entrada, a camada escondida tem a função de realizar o processamento dos dados e a camada de saída de produzir e apresentar o resultado final (Silva et al., 2010).

Em relação à arquitetura da rede podemos classificar basicamente em *feedforward* de camada simples, *feedforward* de camadas múltiplas, redes recorrentes e arquitetura em estrutura reticulada.

Rede *feedforward* de camada simples: Nessa arquitetura tem-se apenas uma camada de entrada e uma camada de neurônios que é a própria camada de saída. Essas redes são utilizadas basicamente em problemas de classificação e filtragem linear. As redes *perceptron* e *adaline* pertencem a esta topologia.

Rede *feedforward* de camadas múltiplas: Essa arquitetura se diferencia da anterior por apresentar uma ou mais camadas escondidas de neurônios entre as camadas de entrada e saída. São empregadas na aproximação de funções, classificação, identificação de sistemas, otimização, robótica, automação, etc.

Redes recorrentes: São redes onde as saídas de neurônios são realimentadas como

sinais de entradas de outros neurônios de camadas anteriores ou da própria camada de entrada. A realimentação qualifica esse tipo de rede para processamento dinâmico de informações, permitindo que elas sejam utilizadas para previsão de séries temporais, otimização e identificação de sistemas, controle de processos, etc.

Redes com estrutura reticulada: A principal característica dessa rede está na disposição espacial dos neurônios visando propósitos de extração de características. Suas aplicações são bem diversificadas, podendo ser utilizadas em problemas de agrupamento, reconhecimento de padrões, otimização, etc.

Nesse trabalho será utilizada uma rede *feedforward* de camadas múltiplas, por funcionar como uma aproximadora universal de funções, aprendendo a função da oscilação de alta frequência indesejada (presente na saída da planta) e gerando o inverso da mesma, para cancelá-la.

A Figura 2 mostra como é a arquitetura da rede neural que foi utilizada, sendo constituída de uma entrada, uma camada escondida de neurônios e uma saída. Em (Silva et al., 2010) é possível ver de forma mais detalhada o princípio de funcionamento envolvendo o algoritmo *backpropagation*.

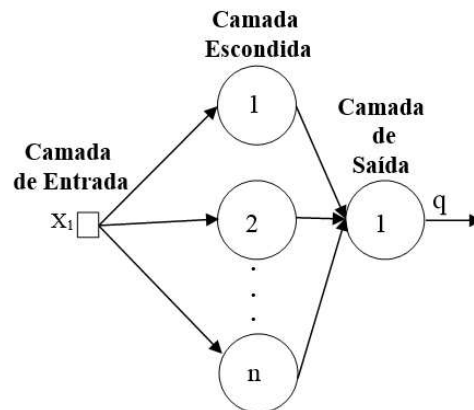


Figura 2 - Rede Perceptron Multicamadas

1.3.2 Algoritmo de Treinamento

O algoritmo *backpropagation* utiliza o método supervisionado e consiste basicamente em apresentar os dados de entrada, comparar a saída obtida com o resultado desejado e essa diferença ser utilizada para ajustar os pesos das camadas da rede da última camada até a primeira. Essas etapas são realizadas até que o desempenho seja

satisfatório.

Nesse trabalho foi utilizado o algoritmo *backpropagation Levenberg-Marquardt*, que é uma variação do algoritmo *backpropagation* tradicional, porém mais rápido, utilizando matriz Jacobiana.

1.4 Desenvolvimento

Este trabalho tem como objetivo desenvolver uma rede neural artificial que seja capaz de aprender as oscilações de alta frequência do ESC de forma que consiga diminuir tais oscilações (Teixeira et al., 2016). Na Figura 3 é apresentado o diagrama de blocos que mostra o funcionamento do sistema. O ESC é inicializado e quando atinge a região de máximo é realizada uma amostragem da saída y para treinamento em paralelo da RNA. Após o treinamento da RNA ser concluído, a mesma é utilizada para cancelar as oscilações de alta frequência do ESC, de forma que a saída se mantenha no ponto de extremo porém sem as oscilações indesejadas. Em conjunto com a RNA é utilizado um filtro passa-alta (*High Pass Filter- HPF*) com a finalidade de eliminar a componente contínua (CC) da saída da RNA.

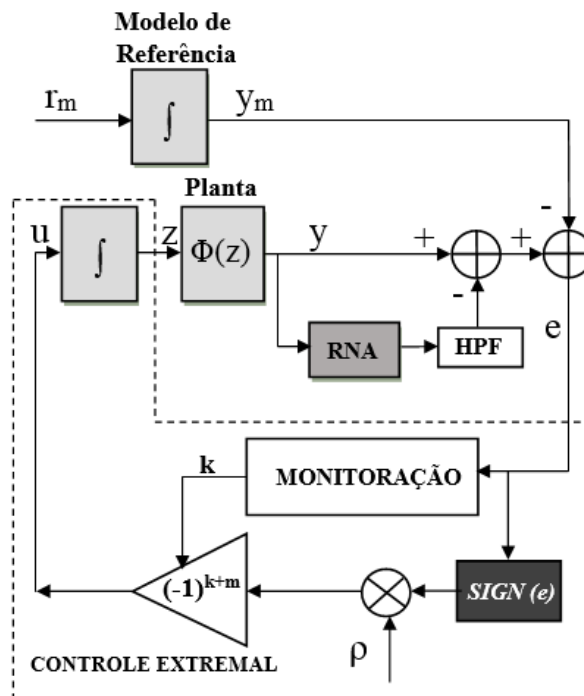


Figura 3 - Diagrama de Blocos ESC com RNA

No sistema simulado a equação da planta utilizada foi:

$$\Phi(z) = 10 - (z - 5)^2 \quad (1.20)$$

onde o sistema composto pelo ESC e a RNA irá procurar o $z^* = 5$ e $y^* = 10$ que satisfazem (H1). Os parâmetros da monitoração e do ESC foram $\lambda_m = 0,5$; $r = 0,1$; $t_k = 0$; $k_p = 1$; $r_m = 1,5$; $\delta = 0,01$. Para a realização do projeto foi utilizado o ambiente *Matlab/Simulink* com o *toolbox* de redes neurais artificiais.

Foi projetada uma RNA com uma entrada e uma saída, onde a entrada da RNA será o valor do sinal atual de saída da planta (y). A definição dos parâmetros da rede neural desenvolvida, como o número de neurônios na camada escondida e a quantidade de dados necessários para treinamento, foi realizada de forma empírica.

Em uma primeira etapa os dados para treinamento foram obtidos do sinal de saída da planta que está em operação. Na segunda etapa os dados foram separados entre 70% para treinamento, 15% para validação e 15% para teste. O conjunto de treinamento serve para ajustar os pesos dos neurônios, o conjunto de validação para escolha e ajuste de parâmetros e o conjunto de teste serve para medir a capacidade de generalização da rede treinada. Nesse trabalho os parâmetros ajustados pelo conjunto de validação foram o número de neurônios na camada escondida e a quantidade de dados amostrados para treinamento da rede. A terceira etapa está relacionada a aplicação da rede e verificação do desempenho.

1.4.1 Obtenção e Tratamento dos Dados

Os dados de treinamento da RNA são obtidos diretamente da saída da planta controlada pelo ESC (Figura 4), porém o intervalo de tempo inicial da fase transitória, onde o máximo ainda está sendo procurado, não é utilizado. Portanto foram amostrados 1000 pontos de treinamento estando a saída da planta em torno do máximo (Figura 5).

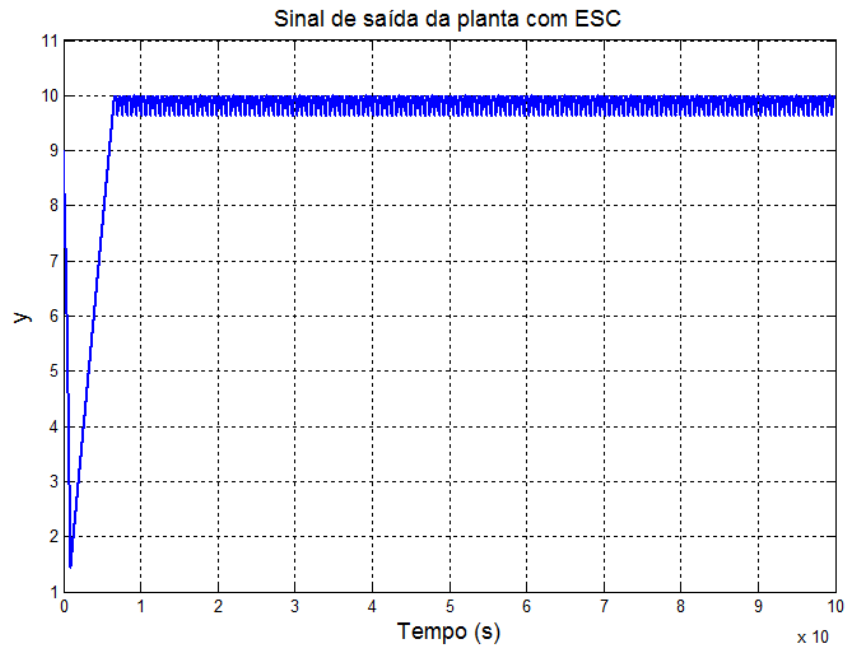


Figura 4 - Sinal de saída da planta com ESC

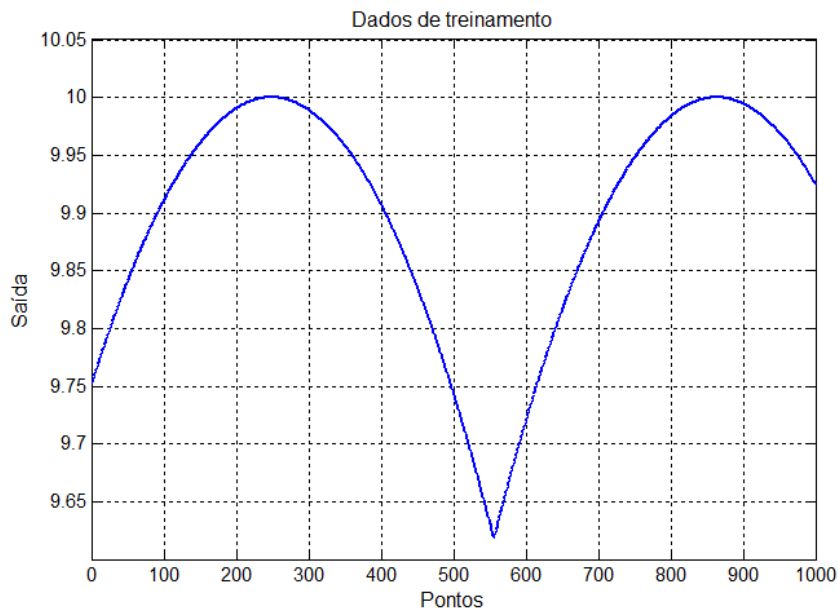


Figura 5 - Dados amostrados para treinamento

Nesse trabalho o número de dados de treinamento também é um parâmetro procurado, pois quanto menor o número de dados necessários para treinamento da RNA menor será o tempo de amostragem o que implica em uma implementação e aplicação mais rápida da RNA no sistema. Nas próximas subseções é mostrado como esses dados foram divididos e avaliados.

Não foi necessário utilizar nenhuma normalização no conjunto de dados de treinamento (Figura 5) pois a média e o desvio padrão foram respectivamente 9,90 e 0,03095, mostrando que não existem grandes variações nos valores dos dados utilizados.

1.4.2 Treinamento e validação

O número máximo de épocas não foi limitado pois o algoritmo utiliza os dados da validação para a parada antecipada (ocorre quando há estagnação do desempenho na validação). Os neurônios da camada escondida utilizam a função sigmoide e o da camada de saída função linear.

Os dados da validação foram utilizados para definir o número mínimo de dados para treinamento (D) e o número de neurônios na camada escondida (H). Onde D variou de 100 a 1000 (com incrementos de 100) e H de 1 a 10 (com incrementos de 1), sendo que para cada variação de H foram realizados 10 ensaios, resultando em um total de 1000 redes criadas.

Como medida de desempenho foram utilizadas a média e o desvio padrão do erro médio quadrático (*Mean Square Error* - MSE) e do número de épocas referentes aos resultados obtidos através dos dados de validação nos 10 ensaios.

Utilizando a melhor RNA desenvolvida para cada quantidade de dados foi gerado o gráfico mostrado na Figura 6, onde o eixo das abscissas representa o número de dados de treinamento.

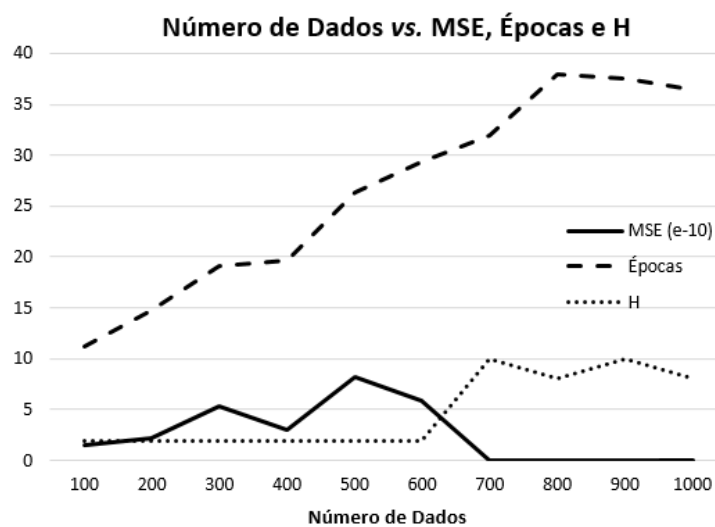


Figura 6 - Número de dados *vs.* MSE, Épocas e H

Pelo gráfico da Figura 6 é possível constatar que mesmo uma quantidade menor de dados, com poucos neurônios na camada escondida (H), apresentam um MSE baixo e um número de épocas muito pequeno. Também é interessante observar que embora um número maior de dados ocasione um MSE ainda menor, também implica em um número maior de épocas de treinamento. Como esse trabalho busca encontrar uma RNA que utilize um menor número de dados e épocas com um MSE aceitável, foi utilizada uma RNA com 2 neurônios na camada escondida (H) e 100 dados de treinamento (D).

1.4.3 Resultados obtidos

Após a RNA estar pronta e ser acoplada à saída da planta, as oscilações em torno do máximo são, basicamente, eliminadas, conforme é mostrado na Figura 7, onde inicialmente existe uma oscilação em torno do ponto de máximo e a partir do instante $t = 20s$, onde a RNA é acionada, a oscilação é suprimida.

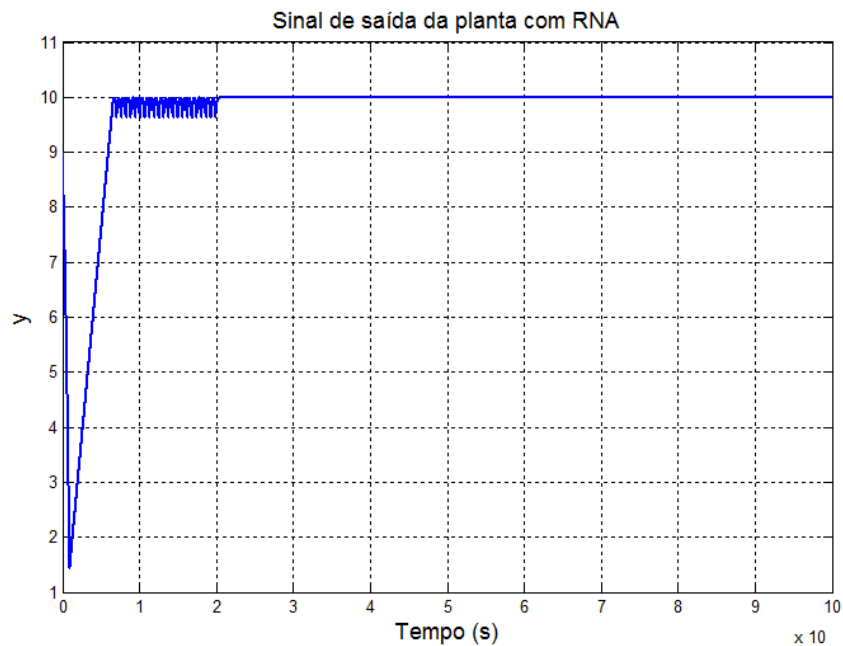


Figura 7 - Sinal de saída da planta com ESC antes e após o acionamento da RNA em $t = 20s$

A busca pelo z^* que maximiza y também se torna mais precisa, conforme visto na Figura 8.

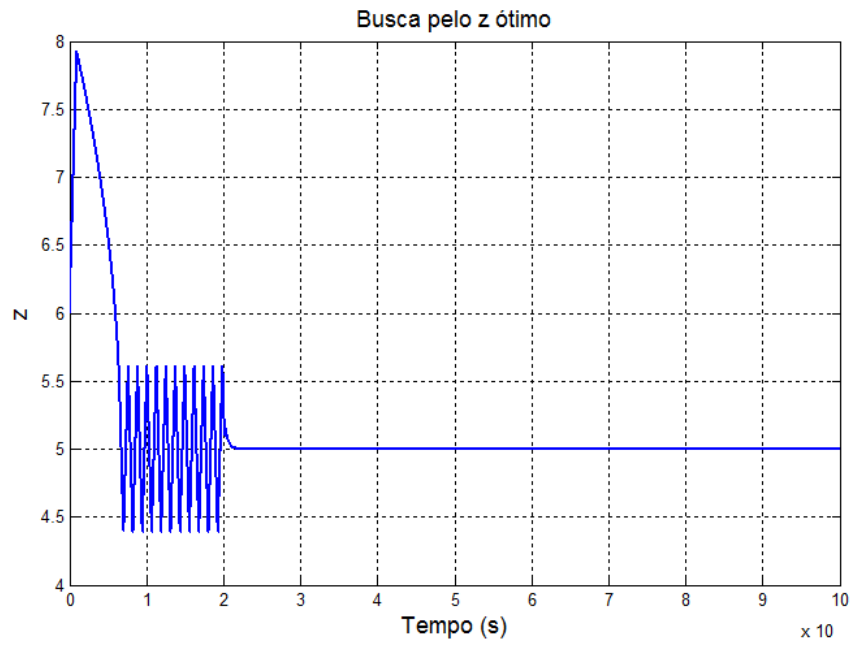


Figura 8 - Busca pelo z^* antes e após o acionamento da RNA em $t = 20s$

2 ALGORITMOS GENÉTICOS PARA INICIALIZAÇÃO DE CONTROLADORES ADAPTATIVOS E REDUÇÃO DE CONHECIMENTOS PRÉVIOS

Nesse capítulo foi utilizado a fatoração de $K_p = SDU$, da mesma forma que foi utilizada em (Costa et al., 2003), onde S é uma matriz simétrica positiva definida, D é uma matriz diagonal e U é uma matriz triangular superior unitária. Essa fatoração de K_p é conveniente devido à grande importância de cada um de seus fatores S , D e U . A característica fundamental dessa fatoração é que a matriz diagonal D aparece no lugar de K_p . Conseqüentemente, apenas o conhecimento dos sinais das entradas de D , d_1, \dots, d_m , já é suficiente para se obter leis adaptativas estáveis. Por outro lado, $W_M(s)S$ deverá satisfazer a condição de SPR, ao invés de só $W_M(s)$. É fato que $W_M(s)$ sendo SPR e juntamente com $S = S^T > 0$ não implica que $W_M(s)S$ seja SPR. Felizmente é possível provar que para qualquer $W_M(s)$, sempre existe uma matriz $S = S^T$ positiva definida tal que $W_M(s)S$ é SPR. Para provar isso emprega-se a propriedade de que S em $K_p = SDU$ não é única (Imai, 2003).

2.1 Controle Adaptativo por Modelo de Referência

O controle adaptativo por modelo de referência, basicamente, busca estimar parâmetros incertos da planta, ou diretamente os parâmetros do controlador adequados - em tempo real - com bases nos sinais medidos do sistema e utiliza tais parâmetros para calcular o sinal de controle adequado. De forma que um sistema de controle adaptativo pode ser considerado como um sistema de controle com estimação paramétrica em tempo real (Ioannou; Sun, 1996).

A Figura 9 apresenta um esquema básico de um controle adaptativo por modelo de referência (*Model Reference Adaptive Control* - MRAC), onde utilizando uma lei de adaptação e um modelo de referência é possível estimar os parâmetros do controlador, de maneira que o controle da planta tenha um bom desempenho.

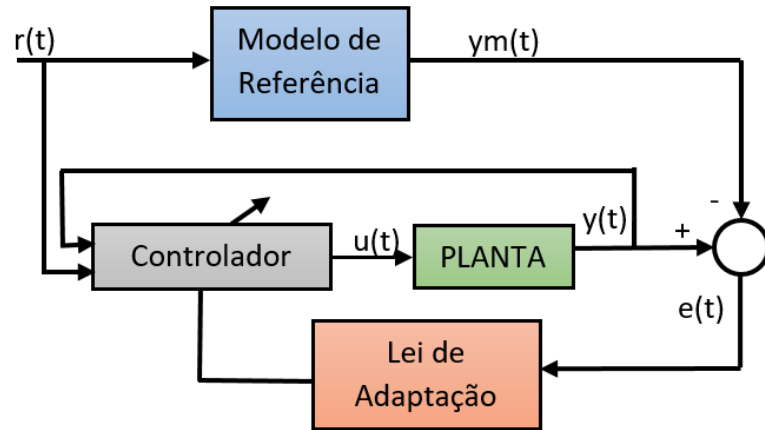


Figura 9 - Controle Adaptativo por Modelo de Referência

onde:

- $r(t)$ - sinal de referência;
- $u(t)$ - sinal de controle;
- $y(t)$ - sinal de saída da planta que se deseja controlar;
- $ym(t)$ - saída do modelo de referência;
- $e(t)$ - sinal de erro, sendo a diferença entre $y(t)$ e $ym(t)$.

2.1.1 Conhecimentos Preliminares

Seja $\{A, B, C\}$ uma realização estritamente própria e não singular $m \times m$ com matriz de função de transferência racional $G(s) = C(sI - A)^{-1}B$.

- O índice de observabilidade do par $\{C, A\}$ ($A \in R^{n \times n}$, $C \in R^{m \times n}$) é a menor integral ν , ($1 \leq \nu \leq n$), tal que

$$O_\nu = [C^T (AC)^T \dots (A^{\nu-1}C)^T]^T \quad (2.1)$$

é posto completo. O índice de observabilidade possui um bom sistema de interpretação: $(\nu - 1)$ é o maior número de derivadas de y necessário para determinar as condições iniciais (Kailath, 1980). Em outras palavras, ele fornece informações sobre a ordem dos filtros das variáveis de estado necessários na estrutura do MRAC MIMO.

- Se o $\det(CB) \neq 0$ podemos dizer que $G(t)$ possui grau relativo 1 e a matriz não singular $K_p = CB$ é referente à matriz HFG. Essa é uma generalização natural do grau relativo um para sistemas SISO (Bodson; Groszkiewicz, 1997).

2.2 Formulação do Problema

Para um sistema MIMO controlável, observável, linear e invariante no tempo do tipo $m \times m$ com matriz de transferência dada por $G(s)$,

$$y = G(s)u, \quad (2.2)$$

podemos assumir as seguintes hipóteses:

- (H1) Os zeros de $G(s)$ possuem parte real negativa.
- (H2) $G(s)$ possui grau relativo 1.
- (H3) Um limite superior do índice de observabilidade ν de $G(s)$ é conhecido.
- (H4) A matriz de HFG K_p é totalmente desconhecida.

Embora existam outros controladores adaptativos que abordam o problema de fase não-mínima (Barkana, 2014), a hipótese (H1) que diz respeito à fase mínima é comum na estrutura clássica do MRAC (Ioannou, 2012). Com a hipótese (H2) é possível focarmos no caso do modelo mais simples baseado em funções de Lyapunov. A hipótese (H3) pode ser enfraquecida para utilizarmos somente o conhecimento sobre o limite superior de ν , como em (Ioannou, 2012), onde, entretanto, podemos aumentar a ordem dos filtros e do número de parâmetros.

Em (Costa et al., 2003) foi considerado que os sinais dos menores principais de K_p são conhecidos. Nesse trabalho a hipótese (H4) considera que a matriz K_p e os seus sinais são desconhecidos e o AG será capaz de descobrir a combinação certa de sinais capaz de fazer o sistema convergir, em conjunto com a fatoração SDU, explicada mais adiante.

O controle adaptativo proposto visa obter transitórios bons, reduzir o conhecimento prévio, como indicado na (H4), e obter o rastreamento do sinal de referência de forma assintótica

$$e(t) = y(t) - y_M(t) \rightarrow 0, \quad \text{conforme } t \rightarrow \infty, \quad (2.3)$$

onde $y_m \in R^m$ é a saída do modelo de referência

$$y_M = W_M(s)r, \quad (2.4)$$

e $r \in R^m$ é um intervalo uniformemente contínuo e limitado. Para selecionarmos nosso modelo de referência, lembramos o fato de que o $\det(CB) \neq 0$ implica que $G(s)$ pode ser reescrita como diagonal através de realimentação dinâmica (Rugh, 1996). Sem perda de generalidade, podemos selecionar um modelo de referência diagonal SPR

$$W_M(s) = \text{diag} \left\{ \frac{1}{s + a_i} \right\}, \quad (2.5)$$

onde $a_i > 0$, ($i = 1, \dots, m$).

2.2.1 Revisão de Abordagens Anteriores para o Controle Adaptativo

Se $G(s)$ é conhecido, então a lei de controle que atinge o casamento entre a matriz de transferência em malha fechada e $W_M(s)$,

$$y = G(s)u^* = W_M(s)r = y_M \quad (2.6)$$

dado por (Sastry; Bodson, 2011).

$$u^* = \theta_1^{*T} w_1 + \theta_2^{*T} w_2 + \theta_3^* y + \theta_4^* r = \theta^{*T} w, \quad (2.7)$$

onde $\theta^{*T} = [\theta_1^{*T} \ \theta_2^{*T} \ \theta_3^* \ \theta_4^*]$ e o vetor regressor $w = [w_1^T \ w_2^T \ y^T \ r^T]^T$ podem ser definidos como

$$\theta_1^*, \theta_2^* \in \mathfrak{R}^{m(\nu-1) \times m}, \quad \theta_3^* \in \mathfrak{R}^{m \times m}, \quad \theta_4^* = K_p^{-1},$$

$$w_1 = \frac{A(s)}{\Lambda(s)} u, \quad w_2 = \frac{A(s)}{\Lambda(s)} y, \quad w_1, w_2 \in \mathfrak{R}^{m(\nu-1)},$$

$$A(s) = [I \ I s \ \dots \ I s^{\nu-2}]^T, \quad I \in \mathfrak{R}^{m \times m},$$

$$\Lambda(s) = \lambda_0 + \lambda_1 s + \dots + s^{\nu-1} \quad \text{é Hurwitz.}$$

O encontro do sistema em malha fechada é obtido fazendo $u = u^*$. Quando w_1, w_2, y e r em (2.7) são expressos em termos de u^* ,

$$u^* = \theta_1^{*T} \frac{A(s)}{\Lambda(s)} u^* + \theta_2^{*T} \frac{A(s)}{\Lambda(s)} G(s) u^* + \theta_3^* G(s) u^* + \theta_4^* W_M^{-1}(s) G(s) u^*, \quad (2.8)$$

a equação se torna

$$I - \theta_1^{*T} \frac{A(s)}{\Lambda(s)} - \theta_2^{*T} \frac{A(s)}{\Lambda(s)} G(s) - \theta_3^* G(s) = \theta_4^* W_M^{-1}(s) G(s). \quad (2.9)$$

Multiplicando os dois lados da equação (2.9) por u obtemos:

$$u = \theta^{*T} w - K_p^{-1} r + K_p^{-1} W_M^{-1}(s) G(s) u. \quad (2.10)$$

Finalmente, multiplicando (2.10) por $W_M(s) K_p$, rearranjando e utilizando $e = y - y_M$, $y = G(s)u$, $y_M = W_M(s)r$, obtemos a equação de erro da saída

$$e = W_M(s) K_p [u - \theta^{*T} w]. \quad (2.11)$$

Exceto pelo fato de $W_M(s)$ e K_p serem matrizes e e e u serem vetores, essa equação de erro MIMO possui a mesma forma que a já conhecida equação de erro SISO. Relembrando os principais passos em um sistema SISO:

1. $W_M(s)$ é uma função de transferência escalar escolhida para ser SPR.
2. A lei de controle adaptativa é

$$u = \theta^T w, \quad (2.12)$$

onde $\theta(t)$ é uma estimativa de θ^* . Com (2.12) a saída de erro é uma função linear do parâmetro de erro $\tilde{\theta} = \theta - \theta^*$,

$$e = W_M(s) K_p [\tilde{\theta}^T w]. \quad (2.13)$$

3. Assumindo que $\text{sgn}(K_p)$ é conhecido, a estabilidade e convergência de $e(t)$ são garantidas pela lei de adaptação (caso SISO)

$$\dot{\theta} = -\gamma \text{sgn}(K_p) w e. \quad (2.14)$$

A generalização desses passos para sistema MIMO pode ser encontrada em (Ioannou, 2012) e pode ser resumida da seguinte forma: Para o passo 1 o modelo de referência diagonal $W_M(s)$ é escolhido como em (2.5). Para o passo 2 foi escolhida a versão de matriz de lei de controle (2.12), onde θ é uma matriz, enquanto w é um vetor estendido. A equação de erro MIMO permanece com a mesma forma que a equação de erro do modelo SISO (2.13), exceto que $W_M(s)$ e K_p são matrizes. Para o passo 3 diferentes premissas sobre K_p foram feitas. Em (Sastry; Bodson, 2011), o problema é resolvido admitindo que K_p é conhecido. Em (Ioannou, 2012) o K_p é considerado desconhecido sob a premissa que a matriz S_p é conhecida tal que $K_p S_p = (K_p S_p)^T > 0$, entretanto, essa premissa é muito restritiva, pois a propriedade de simetria acima envolve uma restrição de igualdade, o que é difícil de verificar em sistemas do mundo real (Hsu; Costa, 1999). Em (Costa et al., 2003) o K_p é considerado desconhecido, porém existe a necessidade de conhecer os sinais dos elementos da diagonal principal, o que em alguns casos não é possível.

2.2.2 Fatoração da matriz de ganho de alta frequência

Em (Costa et al., 2003) foi desenvolvido uma nova forma de fatorar o ganho K_p , onde foi introduzida a matriz diagonal positiva D_+ como um parâmetro livre, baseando-se no seguinte lema.

Lema 2.2.1. *Toda matriz real K_p $m \times m$ com menores principais diferentes de zero, $\Delta_1, \Delta_2, \dots, \Delta_m$ pode ser fatorada como*

$$K_p = SDU, \quad (2.15)$$

onde S é uma matriz simétrica positiva definida, D é uma matriz diagonal e U é uma matriz triangular superior unitária.

Como está provado em (Costa et al., 2003), podemos afirmar que se os menores

principais de K_p são diferentes de zero, existe uma fatoração única

$$K_p = L_1 D_p L_2^T, \quad (2.16)$$

onde L_1 e L_2 são matrizes unitárias triangulares inferiores e

$$D_p = \text{diag} \left\{ \Delta_1, \frac{\Delta_2}{\Delta_1}, \dots, \frac{\Delta_m}{\Delta_{m-1}} \right\}. \quad (2.17)$$

Fatorando D_p como

$$D_p = D_+ D, \quad (2.18)$$

onde D_+ é uma matriz diagonal com elementos positivos, podemos reescrever (2.16) como $K_p = L_1 D_+ L_1^T L_1^{-T} D L_2^T$, de forma que (2.15) é satisfeita por

$$S = L_1 D_+ L_1^T, \quad U = D^{-1} L_1^{-T} D L_2^T. \quad (2.19)$$

Para deixar mais claro a fatoração SDU será realizado o exemplo a seguir, considerando

$$K_p = \begin{bmatrix} k_{11} & k_{12} \\ k_{21} & k_{22} \end{bmatrix}$$

Através da fatoração LDU (2.16) obtemos

$$L_1 = \begin{bmatrix} 1 & 0 \\ l_1 & 1 \end{bmatrix}, \quad D_p = \begin{bmatrix} \Delta_1 & 0 \\ 0 & \frac{\Delta_2}{\Delta_1} \end{bmatrix}, \quad L_2 = \begin{bmatrix} 1 & 0 \\ l_2 & 1 \end{bmatrix},$$

onde $l_1 = k_{21}/\Delta_1$ e $l_2 = k_{12}/\Delta_1$, e para

$$D_+ = \begin{bmatrix} d_1^+ & 0 \\ 0 & d_2^+ \end{bmatrix},$$

utilizando a fatoração SDU (2.15) junto com $D = D_+^{-1} D_p$, obtemos

$$S = \begin{bmatrix} d_1^+ & d_1^+ l_1 \\ d_1^+ l_1 & d_2^+ + d_1^+ l_1^2 \end{bmatrix}, \quad U = \begin{bmatrix} 1 & l_2 - \frac{d_1^+ l_1 \Delta_2}{d_2^+ \Delta_1^2} \\ 0 & 1 \end{bmatrix}$$

2.2.3 Parametrização do sinal de controle e lei de adaptação

Podemos agora, aplicar a fatoração SDU de K_p para encontrarmos uma nova equação de erro. Substituindo $K_p = SDU$ em (2.11) e utilizando (2.7) obtemos

$$e = W_M(s)SD \times [Uu - U\theta_1^{*T}w_1 - U\theta_2^{*T}w_2 - U\theta_3^*y - U\theta_4^*r]. \quad (2.20)$$

Analisando melhor essa expressão é possível perceber que a lei de controle é bem definida, com a decomposição

$$Uu = u - (I - U)u, \quad (2.21)$$

onde $(I - U)$ é uma matriz triangular superior, sendo possível definir o sinal de controle u em função de $(I - U)u$. Não é possível que a adaptação fique estagnada porque u_1 depende de u_2, \dots, u_m , enquanto que u_2 depende de u_3, \dots, u_m , e assim sucessivamente. As entradas desconhecidas de U são incorporadas na nova parametrização definindo $K_1 = U\theta_1^{*T}$, $K_2 = U\theta_2^{*T}$, $K_3 = U\theta_3^*$, e $K_4 = U\theta_4^*$, e reescrevendo (2.20) como

$$e = W_M(s)SD[u - K_1w_1 - K_2w_2 - K_3y - K_4r - (I - U)u]. \quad (2.22)$$

Em seguida, introduzimos o novo vetor de parâmetros Θ_i^* através da identidade

$$[\Theta_1^{*T}\Omega_1 \ \Theta_2^{*T}\Omega_2 \ \dots \ \Theta_m^{*T}\Omega_m]^T \equiv K_1w_1 + K_2w_2 + K_3y + K_4r + (I - U)u. \quad (2.23)$$

Além disso, para concatenar as i -ésimas linhas da matriz K_1 , K_2 , K_3 , K_4 , cada linha do vetor Θ_i^{*T} inclui as entradas desconhecidas das i -ésimas linhas de $(I - U)$. Formando então, o seguinte vetor regressor correspondente

$$\begin{aligned} \Omega_1^T &= [w^T \ u_2 \ u_3 \ \dots \ u_m], \\ \Omega_2^T &= [w^T \ u_3 \ \dots \ u_m], \\ &\vdots \\ \Omega_m^T &= [w^T]. \end{aligned} \quad (2.24)$$

porém, pode ser escrita também da seguinte forma

$$\Omega := [\Omega_1 \ \Omega_2 \ \dots \ \Omega_m]^T. \quad (2.25)$$

A equação de erro (2.22) passa a ser dada da seguinte forma

$$e = (W_M(s)S)D(u - [\Theta_1^{*T}\Omega_1 \ \Theta_2^{*T}\Omega_2 \ \dots \ \Theta_m^{*T}\Omega_m]^T). \quad (2.26)$$

A característica chave da equação do erro (2.26) é que a matriz diagonal D aparece no lugar de K_p , onde em (Costa et al., 2003) são feitas premissas em relação aos sinais de d_1, \dots, d_m . Essa vantagem vem com o preço da condição SPR ser satisfeita por $W_M(s)S$, ao invés de $W_M(s)$ sozinho. De fato, $W_M(s)$ ser SPR combinado com $S = S^T$ ser positiva definida não implica que $W_M(s)S$ é SPR. Felizmente, pode-se provar que para qualquer $W_M(s)$ em (2.5), existe $S = S^T$ definida positiva tal que $W_M(s)S$ é SPR.

Nessa nova parametrização, a lei de controle adaptativa é

$$u = [\Theta_1^T\Omega_1 \ \Theta_2^T\Omega_2 \ \dots \ \Theta_m^T\Omega_m]^T, \quad (2.27)$$

onde Θ_i são as estimativas de Θ_i^* obtidas a partir da lei de adaptação proposta em (Costa et al., 2003) dada por:

$$\dot{\Theta}_i = \dot{\check{\Theta}}_i = -\gamma_i \text{sgn}(d_i) e_i \Omega_i \quad (i = 1, \dots, m). \quad (2.28)$$

De (2.26) e (2.27) é possível presumir que:

$$u^* = [\Theta_1^{*T}\Omega_1 \ \Theta_2^{*T}\Omega_2 \ \dots \ \Theta_m^{*T}\Omega_m]^T \quad (2.29)$$

onde u^* é a lei de controle ideal.

2.2.4 Análise de Estabilidade

Em Costa et al. (2003) foi desenvolvida a análise de estabilidade apresentada a seguir. Combinando o estado $x \in R^n$ da planta (2.2) com os filtros de estado w_1 e w_2 , podemos definir $X = [x^T \ w_1^T \ w_2^T]^T \in R^{n+2m(\nu-1)}$. Com X_M denotamos que o estado da realização não mínima correspondente $C_M(sI - A_M)^{-1}B_M$ de $W_M(s)$ onde $C_M B_M = S$.

Então, o estado de erro $z = X - X_M$ e a saída de erro e em (2.26) satisfaz

$$\begin{aligned}\dot{z} &= A_M z + B_M D(u - [\Theta_1^{*T} \Omega_1 \dots \Theta_m^{*T} \Omega_m]^T), \\ e &= C_M z.\end{aligned}\tag{2.30}$$

Porque $W_M(s)S$ é SPR, então existem matrizes $P_M = P_M^T > 0$ e $Q_M = Q_M^T > 0$ satisfazendo

$$\begin{aligned}A_M^T P_M + P_M A_M &= -2Q_M, \\ P_M B_M &= C_M^T.\end{aligned}\tag{2.31}$$

Em (Costa et al., 2003) foi desenvolvida a lei de adaptação dos parâmetros de controle do vetor Θ_i no controle adaptativo (2.27) em analogia direta com o caso adaptativo SISO. Utilizando a função de Lyapunov

$$V = \frac{1}{2} \left(z^T P_M z + \sum_{i=1}^m \gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \tilde{\Theta}_i \right),\tag{2.32}$$

onde $\tilde{\Theta}_i = \Theta_i - \Theta_i^*$ são parâmetros de erros, d_i são entradas de D e $\gamma_i > 0$ são ganhos de adaptação. Derivando (2.32) ao longo da trajetória do sistema de erro (2.30) obtemos

$$\begin{aligned}\dot{V} &= -z^T Q_M z + z^T P_M B_M D [\tilde{\Theta}_1^T \Omega_1 \dots \tilde{\Theta}_m^T \Omega_m]^T + \sum_{i=1}^m \gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\tilde{\Theta}}_i \\ &= -z^T Q_M z + \sum_{i=1}^m \gamma_i^{-1} |d_i| \tilde{\Theta}_i^T [\gamma_i \text{sgn}(d_i) e_i \Omega_i + \dot{\tilde{\Theta}}_i].\end{aligned}\tag{2.33}$$

A lei de adaptação (2.28) quando aplicada na última linha de (2.33) resulta em \dot{V} negativa, i.e., $\dot{V} = -z^T Q_M z$.

Portanto, o controle adaptativo (2.27) e a lei de adaptação (2.28) garantem $\tilde{\Theta}_i, \Theta_i \in L_\infty$ e $z \in L_\infty \cap L_2$.

Porque $z = X - X_M$ e X_M são limitados, X também é limitado e, conseqüentemente, y, w_1 e w_2 são limitados. Desde que seja assumido um $r(t)$ uniformemente limitado, w é limitado. Para provar que $\Omega_1, \dots, \Omega_m$ são limitados e, portanto, u é também limitado, voltamos para (2.24). A vantagem da estrutura de (2.24), originado pela parametrização de controle, é que $\Omega_m = w$ sendo limitado, implica que $u_m = \Theta_m^T \Omega_m$ é limitado. Desta

forma $\Omega_{m-1}^T = [w^T \ u_m]$ é limitado. Repetindo essa argumentação podemos mostrar que u_{m-1}, \dots, u_2, u_1 são todos limitados. Desta maneira, todos os sinais no sistema em malha fechada são limitados. Isso também implica que $\dot{z}, \dot{e}, \dot{\Omega}_i$ e conseqüentemente \ddot{V} são todos uniformemente limitados. Finalmente, aplicando-se o lema de Barbalat, conclui-se que $z(t), e(t) \rightarrow 0$ com $t \rightarrow \infty$.

2.3 Algoritmos Genéticos aplicados à Controle Adaptativo por Modelo de Referência

Nesse trabalho foram utilizados os AG para a resolução de dois tipos de problemas. No primeiro, o AG é responsável por encontrar os melhores valores de $\Theta_i(0)$ (ou $\theta_i(0)$ no caso SISO) de forma que os transitórios iniciais sejam reduzidos. Desta forma, para esse tipo de aplicação, a equação de controle (2.27) pode ser utilizada, porém a inicialização dos parâmetros ocorre da seguinte forma

$$\Theta_1(0) = \Theta_{AG_1}, \Theta_2(0) = \Theta_{AG_2}, \dots, \Theta_m(0) = \Theta_{AG_m}$$

onde os Θ_{AG_i} são os valores iniciais dos parâmetros adaptados.

Para o segundo problema abordado, os AG são responsáveis por descobrir a combinação correta dos sinais da matriz de HFG, reescrevendo a equação (2.28) obtemos

$$\dot{\Theta}_i = \dot{\Theta}_i = -\gamma_i \text{sgn}(AG_i) e_i \Omega_i \quad (i = 1, \dots, m). \quad (2.34)$$

onde γ_i é a taxa da adaptação e AG_i são os valores entre $-\delta_i$ e δ_i , onde $\delta_i > 0$ é qualquer valor arbitrariamente pequeno, de forma que ao utilizarmos a função sgn nos interessamos somente pelo sinal.

Os AG são um método de busca e otimização global inspirado na teoria da evolução desenvolvida por Darwin. O AG busca em diversas direções a solução ótima localizada em um determinado espaço de busca, enquanto que os algoritmos clássicos utilizam técnicas de derivadas locais e dirigem a busca em somente uma direção. Os algoritmos clássicos, que utilizam métodos de gradiente, apresentam maiores probabilidades de estagnarem em pontos de máximo ou mínimo locais, enquanto que os AG escapam desses pontos devido à mutação aplicada de forma aleatória em um percentual pequeno das populações geradas à cada nova geração (Coppin, 2015).

Em qualquer instante de tempo os AG trabalham com uma população de possíveis soluções. A população é inicializada, cada membro da população é avaliado através de uma determinada função de aptidão desenvolvida e os membros mais aptos possuem maiores chances de passarem para a próxima geração, realizarem cruzamento, gerarem descendentes e sofrerem mutação. Os indivíduos desta população são avaliados novamente e o ciclo continua de forma que ao final de determinado número de gerações ou através do critério de parada em relação à função de aptidão, será obtido o indivíduo mais apto com base na função de aptidão desenvolvida, conforme a Figura 10 apresenta.

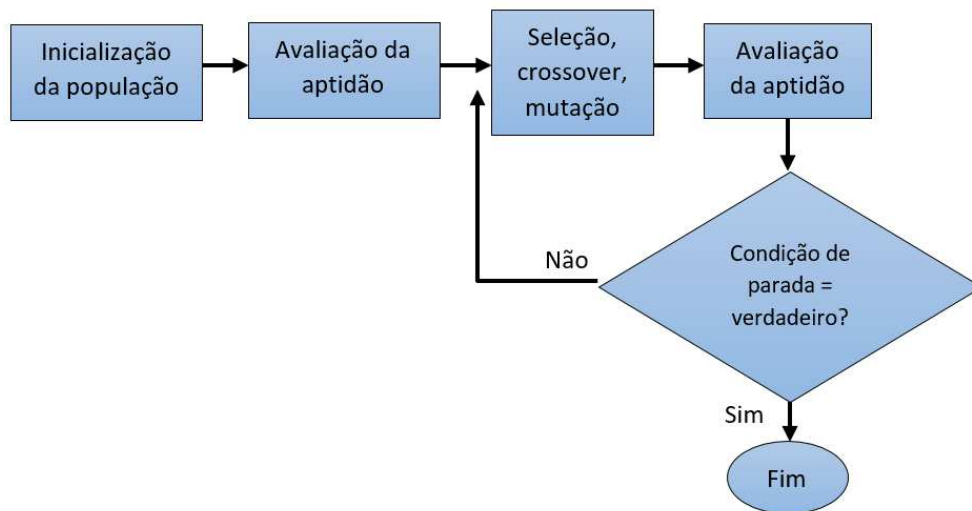


Figura 10 - Diagrama de blocos AG

Foi desenvolvida a função do erro médio quadrático (EMQ) como função de aptidão, da seguinte forma

$$EMQ = \frac{\int_{t=0}^{t_f} \sum_{i=1}^n (y_i(t) - y_{mi}(t))^2 dt}{t_f} \quad (2.35)$$

onde, t_f é o tempo final de simulação e $i = \{1, \dots, n\}$ é o número de saídas do sistema.

Nesse trabalho foi utilizado o algoritmo desenvolvido e apresentado em (Houck et al., 1995).

2.3.1 Desenvolvimento e Resultados Obtidos

Os dois estudos de caso abordados nesse trabalho estão representados de forma simplificada na Figura 11, onde uma planta modelo é responsável por gerar a saída de-

sejada y_m e o controlador MRAC recebe os sinais de erro e , referência e saída da planta y para gerar o sinal de controle u . No primeiro estudo de caso foi utilizada uma planta SISO e o AG teve a função de encontrar os melhores parâmetros capazes de inicializar o sistema de forma que os transitórios se tornassem menores sem a necessidade de aumentar o sinal de controle (Teixeira et al., 2017). No segundo estudo de caso, foi considerada uma planta MIMO, devido à significância e grau de complexidade desse tipo de planta, com duas entradas e saídas, onde o AG foi responsável por encontrar a combinação dos sinais da diagonal principal da matriz K_p de HFG, possibilitando a controlabilidade do sistema (Teixeira et al., 2017).

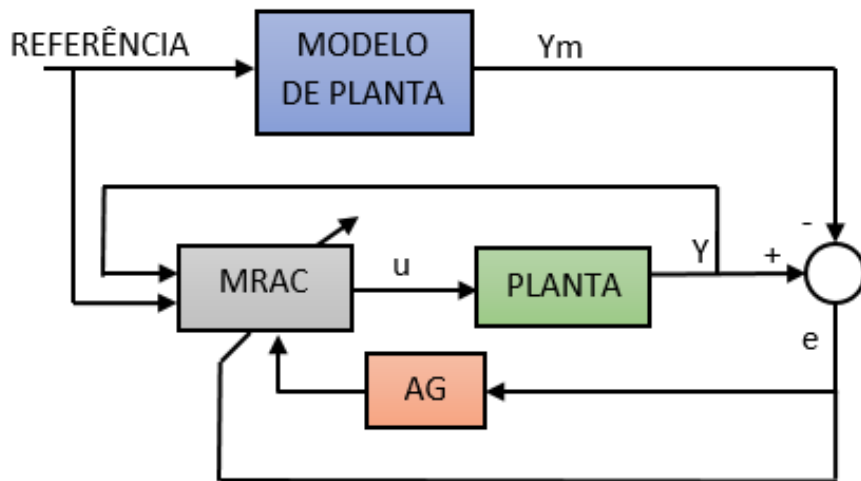


Figura 11 - Diagrama de blocos

2.3.2 Primeiro estudo de caso: encontrar $\theta_i(0)$

Considerando a seguinte planta SISO com

$$G(s) = \frac{1}{(s+1)} K_p,$$

sendo $K_p = 0.5$. Considerando o modelo de referência com $W_M = 1/(s+1)$, $u = \theta^T w$, $w = [r \ y]$ e a lei de adaptação é $\dot{\theta} = -\gamma \text{sgn}(0.5) w e$, sendo $\gamma = 0.5$.

Nessa aplicação o sinal de K_p é conhecido e o AG terá o papel de encontrar $\theta(0) = [\theta_{AG1} \ \theta_{AG2}]^T$, de forma que θ_{AGi} seja o mais próximo possível do valor ideal θ_i^* , para que o funcionamento do MRAC seja melhorado. Onde o sinal de referência é dado por $r(t) = 2\mathcal{U}(t-1)$, onde $\mathcal{U}(t)$ é o degrau unitário.

As simulações foram realizadas utilizando o *software* Matlab, o AG utilizado foi o mesmo que em (Houck et al., 1995). O AG inicia a busca pelos parâmetros desejados e a função de avaliação obtém os dados para aplicar na função de aptidão (2.35) através da simulação apresentada na Figura 12.

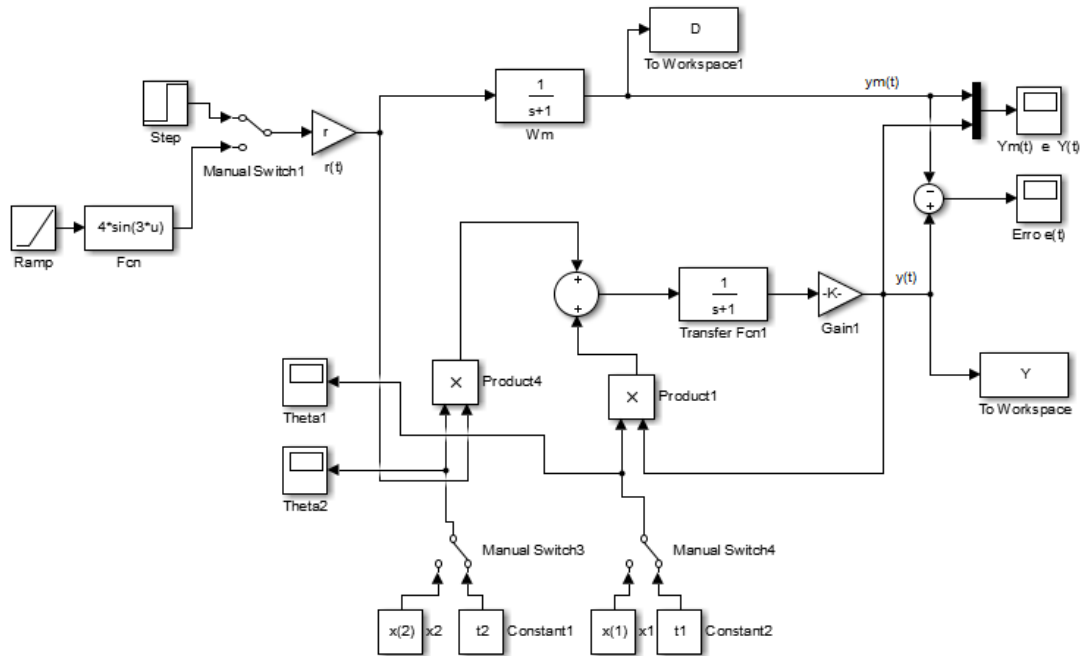


Figura 12 - Simulação realizada no Matlab

Na Figura 12 é possível ver que foi realizado um esquema básico da planta, onde $t1$ e $t2$ são os indivíduos da população que serão avaliados, a parte adaptativa do MRAC não foi implementada nessa simulação que é utilizada em conjunto com o AG, porque a intenção era avaliar o quão promissores seriam os resultados encontrados pelos AG sem a utilização do MRAC. Porém, é interessante ressaltar que alguns testes foram realizados utilizando o MRAC dentro do algoritmo de busca, ou seja, cada indivíduo da população de todas as gerações eram aplicados em um sistema MRAC (diferente do sistema simplificado da Figura 12) e isso fez com que o tempo de simulação fosse cinco vezes maior, sem que os resultados fossem significativamente melhores, sendo um indicativo de que ao utilizar um sistemas mais simples para simular e avaliar os indivíduos da população ganha-se eficiência na busca sem afetar o desempenho.

Os blocos $x(1)$ e $x(2)$ na Figura 12 são utilizados para simular os resultados com o melhor indivíduo encontrado pelo AG ao final da busca.

Para o AG foi utilizado a representação binária, utilizando 12 genes, com 40%

da população realizando crossover simples, 5% de mutação, população inicial de 20 indivíduos, universo de busca entre $-\delta_i$ e δ_i , onde $\delta_1 = \delta_2 = 5$ e função de seleção através da normalização geométrica com probabilidade de seleção do melhor indivíduo de 20%. Como critério de parada foi utilizado o número de gerações em 20, obtendo o melhor resultado na décima geração. O resultados obtidos estão apresentados nas Figura 13 e Figura 14, onde é possível perceber que com o AG atuando na inicialização do MRAC o transiente na saída se tornou menor, além do sinal de controle u .




Figura 13 - Sinal de saída $y(t)$




Figura 14 - Sinal de controle $u(t)$

O sistema representado na Figura 12 também foi utilizado para verificar o que ocorreria caso o sinal de referência não fosse um degrau unitário. Utilizando $r(t) = r\text{sen}(3t)$, sendo $r = 2$. Para o AG foram utilizados exatamente os mesmo parâmetros apresentados acima. O resultados estão apresentados nas Figura 15, Figura 16 e Figura 17.




Figura 15 - Sinais de saída $y(t)$ e $y_m(t)$




Figura 16 - Sinal de controle $u(t)$




Figura 17 - Sinal de erro $e(t)$

É possível perceber que o transitório e o sinal de controle do sistema utilizando AG são ligeiramente menores, e o sinal de erro foi apresentado como forma de enfatizar a ligeira melhoria obtida através da utilização do AG. Os parâmetros calculados de θ_1 e θ_2 foram, respectivamente, 2 e 0, os AG encontraram θ_{AG1} e θ_{AG2} iguais à 2,0079 e $-0,039$, respectivamente. Na simulação com adaptação MRAC, utilizando os valores de θ_{AG1} e θ_{AG2} para inicialização, os parâmetros convergiram para 2,0094 e $-0,034$ respectivamente. Comprovando que os AG conseguiram convergir para bons valores de inicialização, muito próximo dos valores calculados.

2.3.3 Segundo estudo de caso: sinais desconhecidos dos menores principais de K_p

Considerando a seguinte planta MIMO com

$$G(s) = \frac{1}{(s+1)} K_p,$$

sendo

$$K_p = \begin{bmatrix} \cos(\phi) & \text{sen}(\phi) \\ -\text{sen}(\phi) & \cos(\phi) \end{bmatrix},$$

com $\phi = 60^\circ$, admitindo que K_p e seus sinais são desconhecidos, $W_M = \text{diag}\{1/(s+1), 1/(s+1)\}$, $u_1 = \Theta_1^T \Omega_1$, $\Omega_1^T = [r_1 \ r_2 \ u_2]$, $u_2 = \Theta_2^T \Omega_2$, $\Omega_2^T = [r_1 \ r_2]$, e as leis de adaptação

são $\dot{\Theta}_i = -\gamma_i \text{sgn}(AG_i)\Omega_i e_i$, sendo $i = 1, 2$, $\gamma_1 = \gamma_2 = 1$. Nessa aplicação os sinais da diagonal principal de K_p , ou seja, AG_1 e AG_2 são desconhecidos e o AG terá o papel de encontrá-los, para que o sistema utilizando MRAC convirja. Onde $r^T = 10[\text{sen}(t) \text{cos}(t)]$.

De forma análoga ao primeiro estudo de caso desse capítulo, as simulações foram realizadas utilizando o *software* Matlab, o AG utilizado foi o mesmo que em (Houck et al., 1995). O AG inicia a busca pelos parâmetros desejados e a função de avaliação obtém os dados para aplicar na função de aptidão (2.35) através da simulação apresentada na Figura 18.

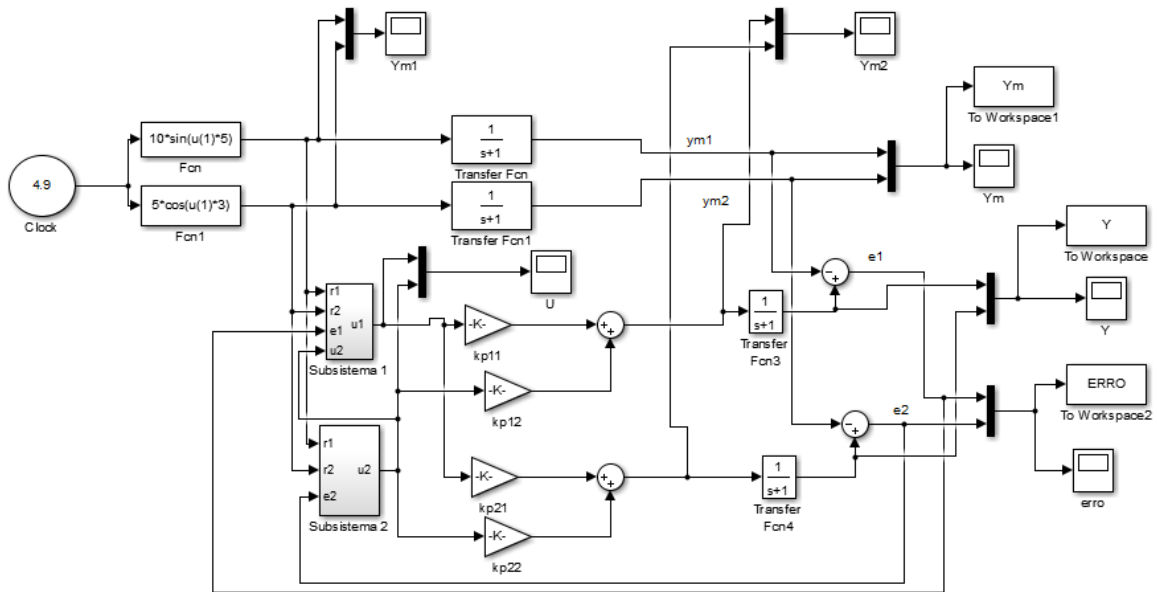


Figura 18 - Simulação do segundo estudo de caso

Os indivíduos gerados pelo AG são representados por t_1 e t_2 e estão localizados dentro dos blocos 'Subsistema 1' e 'Subsistema 2', conforme ilustrado nas Figura 19 e Figura 20.

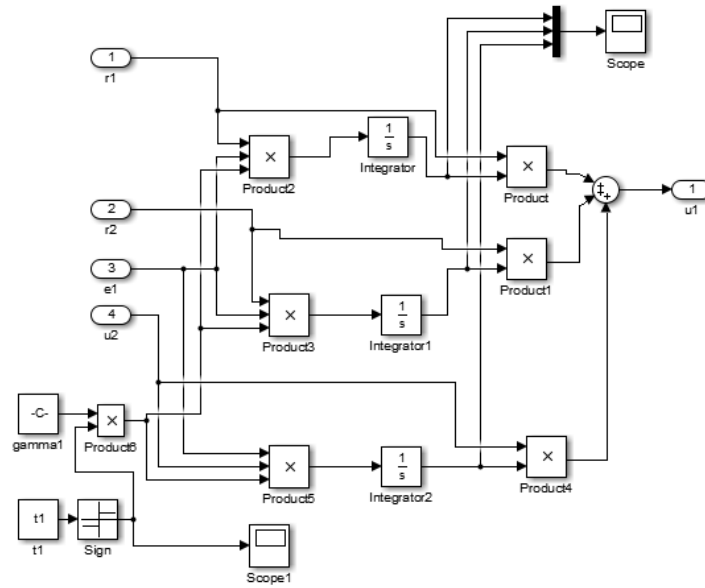


Figura 19 - Subsistema 1

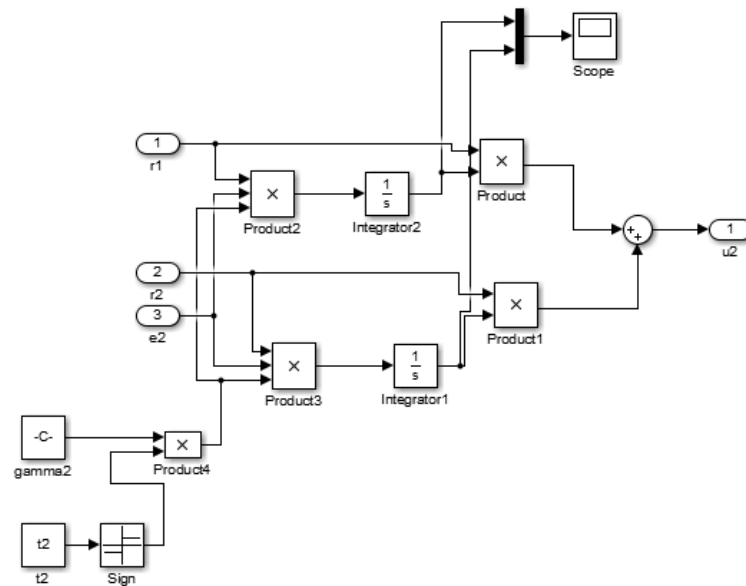


Figura 20 - Subsistema 2

Para o AG foi utilizado a representação binária, utilizando 12 genes, com 40% da população realizando crossover simples, 5% de mutação, população inicial de 20 indivíduos, com universo de busca entre $-\delta_i$ e δ_i , onde $\delta_1 = \delta_2 = 0,001$, lembrando que nos interessa somente a mudança de sinal, e função de seleção através da normalização geométrica com probabilidade de seleção do melhor indivíduo de 6%. Como critério de parada foi utilizado o número de gerações em 20. O resultados obtidos estão apresentados

nas Figura 21, Figura 22 e Figura 23. É importante ressaltar que a função de aptidão foi aplicada nos dados dos últimos 10s da simulação, para garantir que os transitórios não atrapalhariam a avaliação de cada indivíduo e também para saber se a simulação tendia a convergir ou não.




Figura 21 - Sinais de saída da planta $y(t)$ e do modelo $y_m(t)$




Figura 22 - Sinais de erro $e_1(t)$ e $e_2(t)$

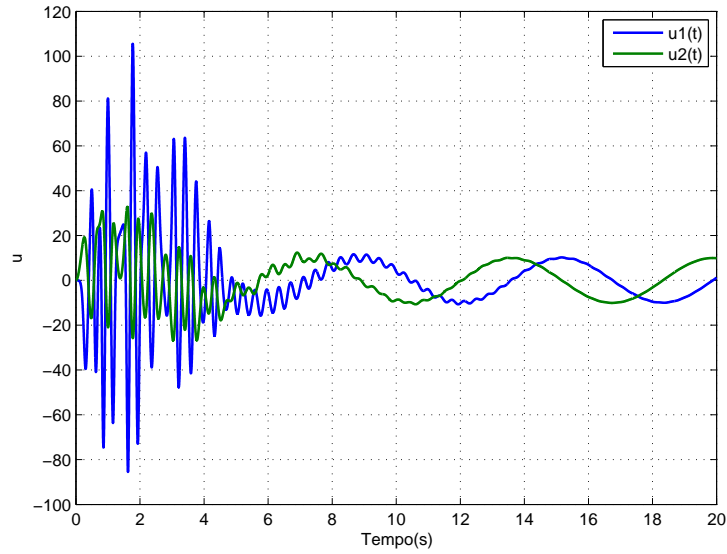


Figura 23 - Sinais de controle $u_1(t)$ e $u_2(t)$

Os resultados obtidos com o AG foram comparados com um método de monitoração inspirado em (Oliveira et al., 2010), onde, para este caso, o sistema possui 2 entradas e portanto 2^2 combinações (+1 +1; +1 -1; -1 +1; -1 -1), de forma que toda vez que a norma do erro encontra o sinal de monitoração (sinal de saturação) o conjunto de sinais é trocado e o sinal de saturação é multiplicado por 2. O sinal de monitoração foi iniciado em 8. O resultados obtidos estão apresentados nas Figura 24, Figura 25, Figura 26 e Figura 27.






Figura 24 - Sinais de saída da planta $y(t)$ e do modelo $y_m(t)$

Figura 25 - Sinais de erro $e_1(t)$ e $e_2(t)$ Figura 26 - Sinais de controle $u_1(t)$ e $u_2(t)$

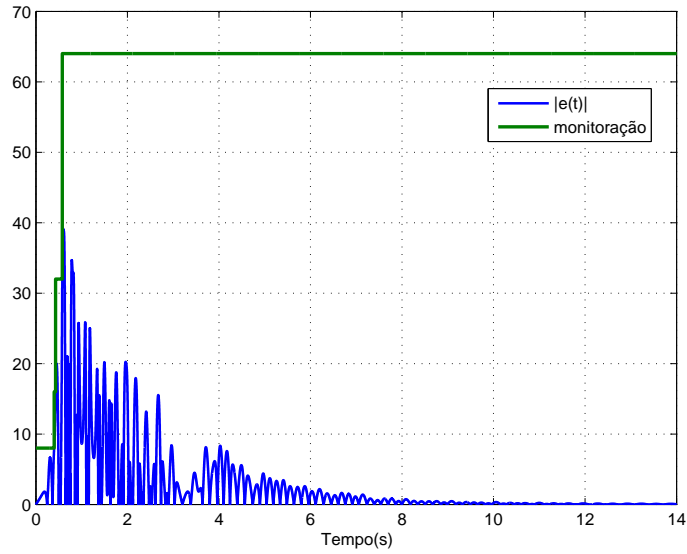


Figura 27 - Sinal de monitoração com norma do erro $|e(t)|$

Comparando os resultados obtidos pelo AG e pela função de monitoração é possível perceber que o AG apresenta melhores resultados, com transitórios, sinal de controle e erros menores, sendo importante ainda ressaltar que para casos de dimensões maiores o número de combinações seria 2^m (Ryan, 1993) para a função de monitoração, o que causaria transitórios ainda piores pois o método poderia levar mais tempo para acertar a combinação de sinais. Isso ocorre também devido ao fato desse método de monitoração ser em tempo real e o método utilizando AG não.

3 BMRAC APLICADO EM SISTEMAS MIMO UTILIZANDO FUNÇÕES DE MONITORAÇÃO

No capítulo anterior foi apresentada uma revisão do MRAC MIMO com aplicação de AG para solucionar os problemas de inicialização de parâmetros e desconhecimento da direção de controle. Porém, os controladores do tipo MRAC ainda apresentam transitório lento pois a convergência do erro é assintótica. Além disso, a estratégia baseada em AG lida com o problema da direção de controle de forma *offline*.

Por outro lado, existe o controlador BMRAC (*Binary Model Reference Adaptive Control*) que possui adaptação baseada em projeção com transitórios rápidos (exponenciais). Entretanto o BMRAC está restrito ao caso SISO. Na literatura encontramos (Oliveira et al., 2016) generalizando o BMRAC SISO para direção de controle escalar desconhecida.

Neste capítulo foi utilizado um controlador BMRAC com fatoração SDU aplicado em sistemas MIMO, onde os sinais da matriz HFG são totalmente desconhecidos. Para encontrar a direção de controle correta foram utilizadas funções de monitoração em cada menor líder principal da matriz HFG, ao invés dos AG utilizados no capítulo anterior. Dessa forma a adaptação é realizada em tempo real.

A motivação desse trabalho está relacionada à mudanças rápidas de parâmetros em condições de voo de aeronaves ocorridas devido à falhas. Segurança de voo para aeronaves que tenham sofrido danos estruturais vem sendo uma área de grande interesse e pesquisa, porque essas estruturas danificadas podem mudar a aerodinâmica e o centro de massa das aeronaves, causando alterações nos parâmetros de projeto (Liu; Tao, 2008).

A principal contribuição desse capítulo é apresentar um controlador BMRAC para sistemas MIMO onde não existem conhecimentos prévios em relação aos sinais dos menores principais da matriz HFG e a busca ser em tempo real.

3.1 Conhecimento Prévio

- Seja $\{A, B, C\}$ uma realização estritamente própria e não-singular $m \times m$ com matriz de função de transferência racional $G(s) = C(sI - A)^{-1}B$.
 - O índice de observabilidade do par $\{C, A\}$ ($A \in R^{n \times n}, C \in R^{m \times n}$) é a menor integral ν , ($1 \leq \nu \leq n$), tal que

$$O_\nu = [C^T(AC)^T \dots (A^{\nu-1}C)^T]^T \quad (3.1)$$

é posto completo. O índice de observabilidade possui um bom sistema de interpretação: $(\nu - 1)$ é o maior número de derivadas de y .

Em outras palavras, ele fornece informações sobre a ordem dos filtros das variáveis de estado necessários na estrutura do MRAC MIMO.

- Se o $\det(CB) \neq 0$ é possível demonstrar que $G(t)$ possui grau relativo 1 e a matriz não-singular $K_p = CB$ a qual é referente à matriz HFG. Essa é uma generalização natural do grau relativo um para sistemas SISO (Bodson; Groszkiewicz, 1997).

- A norma Euclidiana de um vetor x e a correspondente norma de uma matriz A são representados por $\|x\|$ e $\|A\|$, respectivamente.

- Normas \mathcal{L}_2 , \mathcal{L}_∞ e funções classe \mathcal{K} , \mathcal{K}_∞ são definidas como em (Khalil, 2002):

- As normas \mathcal{L}_2 e \mathcal{L}_∞ do sinal $x(t) \in R^n$ são definidas, respectivamente, como

$$\|x\|_{\mathcal{L}_2} = \sqrt{\int_0^\infty u^T(t)u(t)dt} < \infty$$

$$\|x\|_{\mathcal{L}_\infty} = \sup_{t \geq 0} \|u(t)\| < \infty$$

- Funções de classe \mathcal{K} e \mathcal{K}_∞ são definidas como:

Definição 3.1.1. *Uma função $\alpha_{\mathcal{K}}:R_+ \rightarrow R_+$ pertencem à classe \mathcal{K} se*

- * $\alpha_{\mathcal{K}}(\cdot)$ é zero na origem, ou seja, $\alpha_{\mathcal{K}}(0) = 0$;
- * $\alpha_{\mathcal{K}}(\cdot)$ é contínua;
- * $\alpha_{\mathcal{K}}(\cdot)$ é estritamente crescente.

Definição 3.1.2. *Uma função $\alpha_{\mathcal{K}_\infty}:R_+ \rightarrow R_+$ pertence à classe $\alpha_{\mathcal{K}_\infty}$ se*

- * $\alpha_{\mathcal{K}_\infty}(\cdot)$ pertence à classe \mathcal{K} ;
- * $\alpha_{\mathcal{K}_\infty}(\cdot)$ é ilimitada, i.e., $\alpha_{\mathcal{K}_\infty}(t) \rightarrow \infty$ quando $t \rightarrow \infty, \forall t \in R_+$.

3.2 Formulação do problema

Para uma planta MIMO controlável, observável, linear e invariante no tempo, do tipo $m \times m$ com matriz de transferência dada por $G(s)$,

$$y = G(s)u, \quad (3.2)$$

podemos assumir as seguintes hipóteses:

- (H1) Os zeros de $G(s)$ possuem parte real negativa;
- (H2) $G(s)$ possui grau relativo 1;
- (H3) Um limite superior do índice de observabilidade ν de $G(s)$ é conhecido.
- (H4) A matriz de HFG K_p é totalmente desconhecida.

A hipótese (H1) relacionada à fase não mínima é comum na estrutura clássica MRAC (Ioannou, 2012). Com a hipótese (H2) é possível focarmos no caso do modelo mais simples baseado em funções de Lyapunov. A hipótese (H3) pode ser enfraquecida para utilizarmos somente o conhecimento sobre o limite superior de ν , como em (Ioannou, 2012), onde, entretanto, podemos aumentar a ordem dos filtros e do número de parâmetros.

Mesmo com K_p não-singular, alguns dos menores principais podem ser zero. Utilizando a hipótese (H4), (Weller; Goodwin, 1994) resolveu esse problema utilizando uma espécie de sistema composto com chaveamento lógico, porque de uma maneira adaptativa cada menor líder principal de K_p pode ser selecionado e ordenado, considerando serem diferentes de zero. Em (Costa et al., 2003) foi considerado que os sinais de K_p eram conhecidos, como uma forma de resolver esse problema.

Nesse trabalho a hipótese (H4) considera que a matriz K_p e os seus sinais são desconhecidos, e a função de monitoração em conjunto com a fatoração SDU, que foi explicada no capítulo anterior, é capaz de encontrar a combinação correta de sinais para fazer o sistema convergir.

O controle adaptativo proposto visa obter bons transitórios, reduzir os conhecimentos prévios, como indicado pela hipótese (H4), e atingir o rastreamento do sinal de referência de forma assintótica

$$e(t) = y(t) - y_M(t) \rightarrow 0, \quad \text{quando } t \rightarrow \infty, \quad (3.3)$$

onde $y_m \in R^m$ é a saída do modelo de referência

$$y_M = W_M(s)r, \quad (3.4)$$

e $r \in R^m$ é um intervalo uniformemente contínuo e limitado. Para selecionarmos o modelo de referência, é importante lembrar o fato de que $\det(CB) \neq 0$ implica que $G(s)$ pode ser reescrita como diagonal através da realimentação dinâmica (Rugh, 1996). Sem perda de generalidade, é possível selecionar um modelo de referência diagonal SPR

$$W_M(s) = \text{diag} \left\{ \frac{1}{s + a_i} \right\}, \quad (3.5)$$

onde $a_i > 0$, ($i = 1, \dots, m$).

Toda a revisão de abordagens anteriores, fatoração da matriz HFG e parametrização do sinal de controle e lei de adaptação apresentados no capítulo 2, nas subseções 2.2.1, 2.2.2 e 2.2.3 são válidas para esse capítulo.

3.2.1 MRAC com fator de projeção

Nessa seção será apresentado o MRAC com fator de projeção, também conhecido como BMRAC (*Binary Model Reference Adaptive Control*), proposto em (Hsu; Costa, 1990) (Hsu; Costa, 1994) para plantas de grau relativo um.

O fator de projeção faz com que o vetor de parâmetros adaptativos θ convirja rapidamente para dentro de uma região finita de raio apropriado.

Podemos reescrever (2.28) como

$$\dot{\Theta}_i = -\text{sgn}(d_i)[\sigma_i \Theta_i + \gamma_i e_i \Omega_i], \quad \sigma_i \text{sgn}(d_i) \geq 0 \quad (i = 1, \dots, m). \quad (3.6)$$

O fator σ_i é o fator de projeção, definido como

$$\sigma_i = \begin{cases} 0, & \text{se } \|\Theta_i\| < M_\theta \quad \text{ou} \quad \sigma_{eq} \text{sgn}(d_i) < 0 \\ \sigma_{eq}, & \text{se } \|\Theta_i\| \geq M_\theta \quad \text{e} \quad \sigma_{eq} \text{sgn}(d_i) \geq 0 \end{cases} \quad (3.7)$$

onde

$$\sigma_{eq} = \frac{-\gamma_i e_i \Theta_i^T \Omega_i}{\|\Theta_i\|^2} \quad (3.8)$$

e $M_\theta (> \|\Theta_i^*\|)$ é uma constante.

A adaptação é aplicada dentro de um conjunto invariante compacto, por exemplo, uma região definida por M_θ para Θ_i . Considerando que $\|\Theta_i(0)\| \leq M_\theta$, a projeção do vetor de adaptação pode ser interpretado geometricamente da seguinte forma: se o termo $-\gamma_i e_i \Omega_i$ aparece fora da região $\|\Theta_i\| \leq M_\theta$, o vetor de adaptação é projetado para o plano tangente da região, se aparece dentro, o fator σ_i é igual a zero e $\Theta_i(t)$ se move para o interior da região definida, de acordo com a lei de adaptação do MRAC clássico. Podemos definir essa região como uma bola de raio M_θ , então se torna fácil provar que essa região é invariante, ou seja, $\|\Theta_i(t)\| \leq M_\theta, \forall t \geq 0$.

3.2.2 Análise de estabilidade

Os resultados de estabilidade estão resumidos no seguinte teorema.

Teorema 3.2.1. *Considerando o sistema em malha fechada (3.9), (2.26), (2.27), (3.6) e (3.7) e supondo $\|\theta(0)\| \leq M_\theta$ com uma constante $M_\theta > \|\theta^*\|$. Assumindo que (H1)-(H4) são mantidas. Então,*

1. $\|\theta(t)\|_\theta, \forall t \geq 0$;
2. z e e tendem assintoticamente para zero;
3. $|z(t)| \leq C|z(0)|e^{-\lambda t} + O(\sqrt{\gamma^{-1}}), \forall t \geq 0$ e alguma constante positiva C e λ_1 .

Demonstração. Combinando o estado $x \in R^n$ da planta (3.2) com filtros de estado w_1 e w_2 , podemos definir $X = [x^T w_1^T w_2^T]^T \in R^{n+2m(\nu-1)}$. Com X_M denotamos que o estado corresponde à uma realização não mínima $C_M(sI - A_M)^{-1}B_M$ de $W_M(s)$ onde $C_M B_M = S$. Então, o estado de erro $z = X - X_M$ e a saída de erro e em (2.26) satisfazem

$$\dot{z} = A_M z + B_M D(u - [\Theta_1^{*T} \Omega_1 \dots \Theta_m^{*T} \Omega_m]^T), \quad (3.9)$$

$$e = C_M z, \quad e^T = z^T C_M^T. \quad (3.10)$$

Porque $W_M(s)S$ é SPR, existem matrizes $P_M = P_M^T > 0$ e $Q_M = Q_M^T > 0$ satisfa-

zendo

$$A_M^T P_M + P_M A_M = -2Q_M, \quad (3.11)$$

$$P_M B_M = C_M^T, \quad C_M = B_M^T P_M^T. \quad (3.12)$$

Usando a seguinte função de Lyapunov

$$V = \frac{1}{2} \left(z^T P_M z + \sum_{i=1}^m \gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \tilde{\Theta}_i \right), \quad (3.13)$$

onde $\tilde{\Theta}_i = \Theta_i - \Theta_i^*$ são parâmetros de erro, d_i são entradas de D e $\gamma_i > 0$ são ganhos de adaptação. Derivando (3.13) ao longo da trajetória de erro do sistema (3.10) obtemos

$$\dot{V} = \frac{1}{2} \left[\dot{z}^T P_M z + z^T P_M \dot{z} + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\tilde{\Theta}}_i \right], \quad (3.14)$$

substituindo (3.9) em (3.14) e considerando (2.29):

$$\dot{V} = \frac{1}{2} \left[\dot{z}^T P_M z + z^T P_M (A_M z + B_M D(u - u^*)) + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\tilde{\Theta}}_i \right] \quad (3.15)$$

e reorganizando os termos:

$$\dot{V} = \frac{1}{2} \left[\dot{z}^T P_M z + z^T P_M A_M z + z^T P_M B_M D(u - u^*) + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\tilde{\Theta}}_i \right]. \quad (3.16)$$

Considerando (3.9) e (2.29) é possível afirmar que:

$$\dot{z}^T = z^T A_M^T + (u - u^*)^T D^T B_M^T, \quad (3.17)$$

portanto, substituindo (3.17) em (3.16) temos

$$\dot{V} = \frac{1}{2} \left[(z^T A_M^T + (u - u^*)^T D^T B_M^T) P_M z + z^T P_M A_M z + z^T P_M B_M D(u - u^*) + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\tilde{\Theta}}_i \right], \quad (3.18)$$

realizando a distributiva e reorganizando os termos, temos

$$\dot{V} = \frac{1}{2} \left[z^T A_M^T P_M z + (u - u^*)^T D^T B_M^T P_M z + z^T P_M A_M z + z^T P_M B_M D (u - u^*) + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\Theta}_i \right], \quad (3.19)$$

substituindo (3.11)-(3.12) em (3.19)

$$\dot{V} = \frac{1}{2} \left[z^T (A_M^T P_M + P_M A_M) z + z^T C_M^T D (u - u^*) + (u - u^*)^T D^T C_M z + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\Theta}_i \right] \quad (3.20)$$

e reescrevendo (3.20):

$$\dot{V} = \frac{1}{2} \left(-2z^T Q_M z + z^T C_M^T D (u - u^*) + (u - u^*)^T D^T C_M z + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \dot{\Theta}_i \right), \quad (3.21)$$

substituindo (3.6) em (3.21) obtemos

$$\dot{V} = \frac{1}{2} \left(-2z^T Q_M z + z^T C_M^T D (u - u^*) + (u - u^*)^T D^T C_M z + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \operatorname{sgn}(d_i) [-\sigma \Theta_i - \gamma_i e_i \Omega_i] \right), \quad (3.22)$$

e substituindo (2.27), (2.29) e (3.10) em (3.22), como uma forma de reescrever u em função de $\tilde{\Theta}$ e Ω (2.25):

$$\dot{V} = \frac{1}{2} \left[-2z^T Q_M z + e^T D [\tilde{\Theta}^T \Omega]^T + [\tilde{\Theta}^T \Omega] D^T e + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \operatorname{sgn}(d_i) [-\sigma \Theta_i - \gamma_i e_i \Omega_i] \right], \quad (3.23)$$

onde $\tilde{\Theta} = \Theta - \Theta^*$. Como D é uma matriz diagonal e cada elemento da diagonal principal é representado por d_i , podemos reescrever (3.23) como:

$$\dot{V} = \frac{1}{2} \left[-2z^T Q_M z + \sum_{i=1}^m e_i d_i [\tilde{\Theta}_i \Omega_i] + [\tilde{\Theta}_i \Omega_i] d_i e_i + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \operatorname{sgn}(d_i) [-\sigma \Theta_i - \gamma_i e_i \Omega_i] \right], \quad (3.24)$$

reescrevendo (3.24):

$$\dot{V} = \frac{1}{2} \left[-2z^T Q_M z + \sum_{i=1}^m 2e_i d_i \tilde{\Theta}_i \Omega_i + \sum_{i=1}^m 2\gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \operatorname{sgn}(d_i) [-\sigma \Theta_i - \gamma_i e_i \Omega_i] \right], \quad (3.25)$$

simplificando (3.25):

$$\dot{V} = -z^T Q_M z + \sum_{i=1}^m e_i d_i \tilde{\Theta}_i \Omega_i + \sum_{i=1}^m \gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \operatorname{sgn}(d_i) [-\sigma \Theta_i - \gamma_i e_i \Omega_i], \quad (3.26)$$

e realizando a distributiva dentro do segundo somatório:

$$\begin{aligned} \dot{V} = -z^T Q_M z + \sum_{i=1}^m e_i d_i \tilde{\Theta}_i \Omega_i + \sum_{i=1}^m -\gamma_i^{-1} |d_i| \operatorname{sgn}(d_i) \sigma \tilde{\Theta}_i^T \Theta_i - \\ - \gamma_i^{-1} |d_i| \operatorname{sgn}(d_i) \tilde{\Theta}_i \gamma_i e_i \Omega_i, \end{aligned} \quad (3.27)$$

considerando a projeção com $\sigma \neq 0$ para $\|\Theta\| = M_\theta$, podemos dizer que:

$$\tilde{\Theta}^T \Theta = \Theta^T \Theta - \Theta^{*T} \Theta \geq \underbrace{M_\theta^2 - \|\Theta^*\| M_\theta}_{=M_\theta(M_\theta - \|\Theta^*\|)} \geq 0 \quad (3.28)$$

então, podemos afirmar que:

$$\begin{aligned} \tilde{\Theta}^T \Theta &\geq 0 \\ -\tilde{\Theta}^T \Theta &\leq 0 \end{aligned} \quad (3.29)$$

considerando $\sigma \operatorname{sgn}(d_i) \geq 0$, podemos afirmar que o primeiro termo do segundo somatório é não positivo e reescrever (3.27) como:

$$\dot{V} \leq -z^T Q_M z + \sum_{i=1}^m e_i d_i \tilde{\Theta}_i \Omega_i - \sum_{i=1}^m \gamma_i^{-1} |d_i| \operatorname{sgn}(d_i) \tilde{\Theta}_i \gamma_i e_i \Omega_i, \quad (3.30)$$

onde reescrevendo (3.30) obtemos:

$$\dot{V} \leq -z^T Q_M z + \sum_{i=1}^m e_i d_i \tilde{\Theta}_i \Omega_i - \sum_{i=1}^m e_i d_i \tilde{\Theta}_i \Omega_i, \quad (3.31)$$

chegando finalmente ao seguinte resultado:

$$\dot{V} \leq -z^T Q_M z \quad (3.32)$$

Portanto, o controle adaptativo (2.27) e a lei de adaptação (3.6) garantem $\tilde{\Theta}_i, \Theta_i \in \mathcal{L}_\infty$ e $z \in \mathcal{L}_\infty \cap \mathcal{L}_2$.

Uma vez que $z = X - X_M$ e X_M são limitados, X é também limitado e, conseqüentemente, y , w_1 e w_2 são limitados. Desde que $r(t)$ é uniformemente limitado, w é limitado. Para provar que $\Omega_1, \dots, \Omega_m$ são limitados e, portanto, u é também limitado, retornamos em (2.24). A vantagem da estrutura de (2.24), resultando da parametrização do controle, é que $\Omega_m = w$ é limitado, implicando que $u_m = \Theta_m^T \Omega_m$ é limitado. Desta forma $\Omega_{m-1}^T = [w^T \ u_m]$ é limitado. Repetindo esse argumento podemos mostrar que u_{m-1}, \dots, u_2, u_1 são também limitados. Ou seja, todos os sinais do sistema em malha fechada são limitados. Isso também implica que $\dot{z}, \dot{e}, \dot{\Omega}_i$ e conseqüentemente \dot{V} são também uniformemente limitados. Finalmente, o usual argumento invocando o lema de Barbalat prova que $z(t), e(t) \rightarrow 0$ com $t \rightarrow \infty$.

Também é possível provar a estabilidade exponencial para um termo residual utilizando a inequação de Rayleigh (Khalil, 2002), sendo $V = \frac{1}{2} \left(z^T P_M z + \sum_{i=1}^m \gamma_i^{-1} |d_i| \tilde{\Theta}_i^T \tilde{\Theta}_i \right)$ e $\dot{V} \leq -z^T Q_M z$ tal que $Q_M > 0$, temos:

$$\lambda_{\min}(P_M) |z|^2 \leq z^T P_M z \leq \lambda_{\max}(P_M) |z|^2 \quad (3.33)$$

$$\lambda_{\min}(Q_M) |z|^2 \leq z^T Q_M z \leq \lambda_{\max}(Q_M) |z|^2 \quad (3.34)$$

De (3.32) e do lado esquerdo de (3.34) obtemos:

$$\dot{V} \leq -z^T Q_M z \leq -\lambda_{\min}(Q_M) |z|^2. \quad (3.35)$$

Considerando $\tilde{\Theta}_i \in \mathcal{L}_\infty$ podemos reescrever (3.13) como:

$$V \leq \frac{1}{2} \left(z^T P_M z + \sum_{i=1}^m O(\gamma_i^{-1}) \right), \quad (3.36)$$

relembrando que $\sum_{i=1}^m O(\gamma_i^{-1}) \leq \sum_{i=1}^m O(\gamma^{-1}) \leq O(\gamma^{-1})$. Portanto, (3.36) se torna:

$$V \leq \frac{1}{2} (z^T P_M z + O(\gamma^{-1})), \quad (3.37)$$

sendo $\gamma = \min \gamma_i$, a partir de (3.33) e (3.36) obtemos:

$$V \leq \lambda_{\max}(P_M) |z|^2 + O(\gamma^{-1}). \quad (3.38)$$

Reescrevendo (3.38):

$$|z|^2 \geq \frac{1}{\lambda_{\max}(P_M)} [V(z) - O(\gamma^{-1})] \quad (3.39)$$

e substituindo (3.39) em (3.35) obtemos:

$$\dot{V}(z) \leq -\frac{\lambda_{\min}(Q_M)}{\lambda_{\max}(P_M)} [V(z) - O(\gamma^{-1})], \quad (3.40)$$

podemos reescrever (3.40) como:

$$\dot{V}(z) \leq -2\lambda_1 [V(z) - O(\gamma^{-1})] \quad (3.41)$$

onde $2\lambda_1 = \frac{\lambda_{\min}(Q_M)}{\lambda_{\max}(P_M)}$.

Resolvendo (3.41) obtemos:

$$V(t) \leq e^{-2\lambda_1 t} V(0) + O(\gamma^{-1}) \quad (3.42)$$

sendo:

$$V(0) = \frac{1}{2} [z(0)^T P_M z(0) + O(\gamma^{-1})] \quad (3.43)$$

e reescrevendo (3.43):

$$V(0) \leq \frac{1}{2} [\lambda_{\max}(P_M) |z(0)|^2 + O(\gamma^{-1})] \quad (3.44)$$

A partir de (3.33), (3.42) e (3.44) obtemos:

$$\lambda_{\min}(P_M) |z|^2 \leq \frac{\lambda_{\max}(P_M) |z(0)|^2}{2} e^{-2\lambda_1 t} + O(\gamma^{-1}) \quad (3.45)$$

reescrevendo (3.45):

$$|z(t)| \leq \sqrt{\frac{\lambda_{\max}(P_M)}{2\lambda_{\min}(P_M)}} |z(0)| e^{-\lambda_1 t} + O(\sqrt{\gamma^{-1}}) \quad (3.46)$$

podemos também reescrever (3.46) como:

$$|z(t)| \leq C |z(0)| e^{-\lambda_1 t} + O(\sqrt{\gamma^{-1}}) \quad (3.47)$$

onde $C = \sqrt{\frac{\lambda_{\max}(P_M)}{2\lambda_{\min}(P_M)}}$.

A partir de (3.10) e utilizando (3.47) é possível reescrever e como

$$|e| = |C_M| |z| \leq C_e |z(0)| e^{-\lambda_1 t} + O(\sqrt{\gamma^{-1}}), \quad (3.48)$$

onde $C_e = \|C_M\| \|C\|$. □

Desta forma, podemos verificar a convergência exponencial em (3.47) e (3.48), existindo um termo residual pequeno, da ordem de γ^{-1} .

3.3 Função de monitoração

Nessa seção será explicada como a função de monitoração será capaz de mudar a direção de controle baseada na saída do erro do sistema para atingir a convergência mesmo sem nenhum conhecimento sobre os sinais da matriz HFG K_p .

Podemos redefinir a lei de adaptação (3.6)-(3.8) como

$$\dot{\Theta}_i = \begin{cases} -\sigma_i^+ \Theta_i - \gamma_i e_i \Omega_i, & t \in T^+ \\ \sigma_i^- \Theta_i + \gamma_i e_i \Omega_i, & t \in T^-, \end{cases} \quad (3.49)$$

$$\sigma_i^+ = \begin{cases} 0, & \text{se } \|\Theta_i\| < M_\theta \text{ ou } \sigma_{eq} < 0 \\ \sigma_{eq}, & \text{se } \|\Theta_i\| \geq M_\theta \text{ e } \sigma_{eq} \geq 0 \end{cases} \quad (3.50)$$

$$\sigma_i^- = \begin{cases} 0, & \text{se } \|\Theta_i\| < M_\theta \text{ ou } \sigma_{eq} > 0 \\ \sigma_{eq}, & \text{se } \|\Theta_i\| \geq M_\theta \text{ e } \sigma_{eq} \leq 0 \end{cases} \quad (3.51)$$

onde uma função de monitoração apropriada decidirá, baseada no erro de trajetória e , quando $\dot{\Theta}_i$ irá chavear, permitindo a detecção de qualquer estimativa errada de $\text{sgn}(K_p)$.

Os conjuntos T^+ e T^- satisfazem $T^+ \cup T^- = [0, \infty)$ e $T^+ \cap T^- = \emptyset$, e como será mostrado na análise a seguir, ambos T^+ e T^- possuem a forma $[t_k, t_{k+1}) \cup \dots \cup [t_j, t_{j+1})$. Onde, t_k ou t_j denotam o tempo de chaveamento para $\dot{\Theta}_i$ e serão definidos futuramente.

De (3.48) é possível escrever

$$|e_i(t)| \leq C_e |z(0)| e^{-\lambda_1 t} + O(\sqrt{\gamma^{-1}}) := \xi(t), \forall t \geq 0. \quad (3.52)$$

Construímos a função de monitoração φ_m baseada no limite superior de (3.52). Considerando a função auxiliar φ_k definida como demonstrado a seguir:

$$\begin{aligned} \varphi_{ik}(t) &= e_i^{-\lambda_m(t-t_k)} |\varphi_{k-1}(t_k)| + a_i(k) e_i^{-t/a_i(k)} + a_i(k), \\ t &\in [t_k, \infty), \varphi_{i0}(0) = e_i(0), \quad (i=1, \dots, m), \end{aligned} \quad (3.53)$$

onde $0 < \lambda_m \leq \lambda_1$ e $a(k)$ é qualquer sequência crescente ilimitada e monotonicamente positiva e t_k sendo o tempo de chaveamento usado para decidir quando o parâmetro de adaptação $\dot{\Theta}_i$ deverá chavear de $\sigma_i^- \Theta_i + \gamma_i e_i \Omega_i$ para $-\sigma_i^+ \Theta_i - \gamma_i e_i \Omega_i$ e vice versa como definido a seguir. A taxa de decaimento λ_m atua como um fator de esquecimento, o qual provém uma propriedade de reinicialização para φ_k .

A função de monitoração φ_m é definida como

$$\varphi_{im}(t) := \varphi_{ik}(t), \forall t \in [t_k, t_{k+1}) \subset [0, \infty), \quad (i=1, \dots, n). \quad (3.54)$$

A motivação por trás da introdução de φ_m é que $C_e |z(0)| e^{-\lambda_1 t}$ não está disponível para medição. Relembrando que a inequação (3.52) é válida se o $\text{sgn}(K_p)$ é corretamente estimado, é natural utilizar ξ como uma referência para decidir quando será necessário chavear o parâmetro de adaptação $\dot{\Theta}_i$ em (3.49), ou seja, o chaveamento irá ocorrer somente quando (3.52) é violada.

Entretanto, como $C_e |z(0)| e^{-\lambda_1 t}$ não está disponível, utilizamos φ_m para substituir ξ e invocamos o chaveamento de φ_m . Note que de (3.54), sempre temos $\|e_i(t_k)\| < \varphi_{ik}(t_k)$ em $t = t_k$. Portanto, o tempo de chaveamento t_k é

$$t_{k+1} = \begin{cases} \min t > t_k : |e_i(t)| = \varphi_{ik}(t), & \text{se existe,} \\ \infty, & \text{caso contrário,} \end{cases} \quad (3.55)$$

onde $k \in 0, 1, 2, \dots$ e $t_0 := 0$. A seguinte inequação é obtida diretamente de (3.54):

$$|e_i(t)| \leq \varphi_{im}(t), \forall t > 0. \quad (3.56)$$

3.4 Nova lei de adaptação com função de monitoração

Nesse trabalho as funções de monitoração foram utilizadas para descobrir a combinação correta que leva à direção de controle correta, por exemplo, a combinação dos sinais da matriz HFG K_p .

A Figura 28 mostra de uma maneira simplificada o funcionamento do sistema, no qual o controlador MRAC recebe a informação da combinação correta dos sinais da matriz HFG descobertos pela função de monitoração.

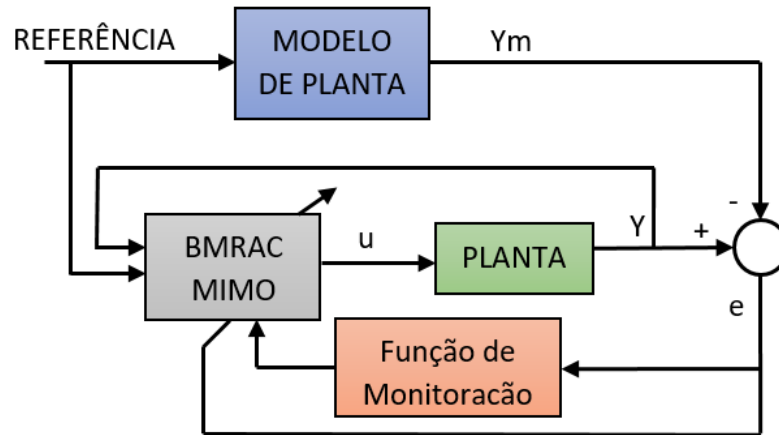


Figura 28 - Diagrama de blocos

E os seguintes resultados podem ser concluídos:

Teorema 3.4.1. *Considere o sistema em malha fechada (3.9), com sinal de controle (2.27), lei de adaptação (3.49)-(3.51) e função de monitoração (3.53)-(3.55). Sob as mesmas hipóteses do Teorema 3.2.1, supondo $\|\theta(0)\| \leq M_\theta$ com uma constante $M_\theta > \|\theta^*\|$, então o sinal de controle irá parar de chavear com a combinação correta de sinais, o equilíbrio $z \equiv 0$ é atingido assintoticamente. E ainda, o erro de rastreamento de saída e convergirá para um resíduo pequeno de ordem $O(\gamma^{-1})$ ao menos exponencialmente e todos os sinais do sistema em malha fechada permanecerão uniformemente limitados.*

Demonstração. Na prova a seguir, $k_i > 0$ são constantes que não dependem das condições iniciais e $\Psi_i(\cdot) \in \mathcal{K}$. A prova é demonstrada em três partes.

1) *A função de monitoração para chavear com o sinal correto:* Suponha que a lei de controle (2.27) chaveie de acordo com a lei de adaptação definida em (3.49) e fator de projeção definido em (3.50) e (3.51), sem parar $\forall t \in [0, t_M)$, onde t_M pode ser finito ou infinito. Então, $a_i(k)$ em (3.53) e (3.54) crescerá de forma ilimitada com $k \rightarrow +\infty$. Portanto, existe um valor finito κ tal que para $k \geq \kappa$ o termo $a_i(k)e_i^{-t/a_i(k)} \geq C_e|z(0)|e^{-\lambda_1 t}$, $a_i(k) > O(\gamma^{-1/2})$ e $\text{sgn}(K_p)$ é estimado corretamente. Nesse caso, $\varphi_{im}(t) > \xi(t), \forall t \in [t_k, t_{k+1})$ com ξ em (3.52). Além disso, ξ é um limite superior válido para $\|e_i\|$. Portanto, nenhum chaveamento ocorrerá depois de $t = t_k$, por exemplo, $t_{k+1} = t_M$ [ver (3.55)], o que leva a uma contradição. Desta forma, φ_{im} (3.54) tem que parar de chavear depois de algum tempo finito $k = N$ e $t_N \in [0, t_M)$.

2) *Estabilidade em relação a um conjunto restrito:* Porque N é o número de chaveamentos necessários para garantir que as inequações $a(N)e^{-t/a(N)}|z(0)|e^{-\lambda_1 t}$ e $a(N) > O(\gamma^{-1/2})$ sejam mantidas, não é difícil concluir que N pode ser relacionado a $\|z(0)\|$. De fato, podemos escrever $N \leq \Psi_1(\|z(0)\|) + k_1$, que significa que N pode ser feito menor (não abaixo de k_1) através da redução de $\|z(0)\|$. Portanto, temos $a(N) \leq \Psi_2(\|z(0)\|) + k_2$ e, de (3.52),

$$\|e(t)\| \leq \Psi_2(\|z(0)\|) + c, \forall t \geq 0, \quad (3.57)$$

$\forall t \in [0, t_M)$, onde c é uma constante positiva. Utilizando a forma regular (Utkin, 1978),(Utkin et al., 2009) para a realização do espaço de estados de (2.26), todos os estados z do sistema são dirigidos pela saída y da planta, a qual é uniformemente limitada porque $y = e + y_m$ e o modelo de referência de saída y_m é também uniformemente limitado. Portanto, dado $R > c$, para $\|z(0)\| < R_0$, com $R_0 \leq \Psi_3^{-1}(R - c)$, então $\|z(t)\|$ é limitado a uma distância de R com $t \rightarrow t_M$. Isso implica que $z(t)$ é uniformemente limitado ($t_M = +\infty$). Portanto, a estabilidade com relação à bola de raio c é garantida para $z(0)$ na bola R_0 .

3) *Limitação do sinal em malha fechada e convergência exponencial:* Primeiro, porque z e e são uniformemente limitados, então $X = z + X_M$ também é uniformemente limitado porque X_M é o modelo de referência do vetor de estados. Dessa forma, lembrando que $X = [x^T \ w_1^T \ w_2^T]$, podemos também concluir, de forma subsequente, que x, w_1, w_2, w são uniformemente limitados. Seguindo os mesmos argumentos apresentados na prova do Teorema 3.2.1, podemos verificar que $\|\theta(t)\| \leq M_\theta, \forall t \geq 0$. Desda forma, $u = [\Theta_1^T \Omega_1 \ \Theta_2^T \Omega_2 \ \dots \ \Theta_m^T \Omega_m]^T$ é também uniformemente limitado.

Porque o controle de direção foi corretamente estimado, o rastreamento global e assintótico é alcançado, de acordo com o teorema 3.2.1. A convergência assintótica de todo o vetor de erro de estado z para zero pode ser demonstrada utilizando a forma regular (Utkin, 1978), (Utkin et al., 2009) para a realização do espaço de estados de (2.26), onde todos os estados do sistema são conduzidos pela saída da planta y_m que é uniformemente limitada. Finalmente, a partir do Teorema 3.2.1, sabemos adicionalmente que todas as trajetórias do sistema convergem para uma vizinhança pequena da ordem de $O(\gamma^{-1/2})$ perto da origem do espaço do estado de erro, ao menos exponencialmente. \square

3.5 Simulações e resultados

Considerando a seguinte planta MIMO com

$$G(s) = \frac{1}{(s+1)} K_p,$$

sendo

$$K_p = \begin{bmatrix} \cos(\phi) & \text{sen}(\phi) \\ -\text{sen}(\phi) & \cos(\phi) \end{bmatrix},$$

com $\phi = 60^\circ$, assumindo que K_p e seus sinais são desconhecidos, $W_M = \text{diag}\{1/(s+1), 1/(s+1)\}$, $u_1 = \Theta_1^T \Omega_1$, $\Omega_1^T = [r_1 \ r_2 \ u_2]$, $u_2 = \Theta_2^T \Omega_2$, $\Omega_2^T = [r_1 \ r_2]$, e as leis de adaptação são (3.49)-(3.51), sendo $i = 1, 2$ e $r^T = 10[\text{sen}(t) \ \cos(t)]$. Foram realizadas simulações com valores de $\gamma_1 = \gamma_2 = 1$ e $M_\theta = 5$.

A função de monitoração irá mudar a direção de controle toda vez que a inequação (3.56) for violada.

Os resultados obtidos estão apresentados da Figura 29 à Figura 44.

É possível ver pelos resultados que as funções de monitoração são capazes de encontrar a direção de controle correta e que os sinais de erro convergem para zero. Sem sacrificar demasiadamente as amplitudes dos sinais de controle como ocorrido no capítulo 2. Também é possível perceber que os sinais de controle se tornam ainda menores quando utilizamos o fator de projeção.




Figura 29 - Saída $y_{1m}(t)$ e $y_1(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 30 - Saída $y_{2m}(t)$ e $y_2(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 31 - Saída $y_{1m}(t)$ e $y_1(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 32 - Saída $y_{2m}(t)$ e $y_2(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 33 - Sinal de erro $e(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 34 - Sinal de erro $e(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 35 - Sinal de controle $u(t)$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 36 - Sinal de controle $u(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 37 - Parâmetros Θ_1 sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 38 - Parâmetros Θ_2 sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 39 - Parâmetros Θ_1 com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 40 - Parâmetros Θ_2 com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 41 - Função de monitoração 1 com $|e_1(t)|$ sem fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 42 - Direção de controle referente à função de monitoração 1




Figura 43 - Função de monitoração 1 com $|e_1(t)|$ com fator de projeção e $\gamma_1 = \gamma_2 = 1$




Figura 44 - Direção de controle referente à função de monitoração 1

Da Figura 45 à Figura 48 são mostrados os resultados quando utilizamos $\gamma_1 = \gamma_2 = 100$. Os parâmetros são adaptados de forma mais agressiva o que faz com que o fator de projeção tenha um papel ainda mais importante para que a adaptação ocorra dentro de determinada região, com isso, é possível obter melhores transitórios sem sacrificar o sinal de controle.




Figura 45 - Sinal de erro $e(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 100$




Figura 46 - Sinal de controle $u(t)$ com fator de projeção e $\gamma_1 = \gamma_2 = 100$




Figura 47 - Parâmetros Θ_1 com fator de projeção e $\gamma_1 = \gamma_2 = 100$




Figura 48 - Parâmetros Θ_2 com fator de projeção e $\gamma_1 = \gamma_2 = 100$

Produção Científica

Nesse capítulo encontram-se apresentados os dois artigos publicados durante o mestrado.

- TEIXEIRA, R. B.; OLIVEIRA, T. R.; AMARAL, J. F. M.. Aplicação de Algoritmos Genéticos para Inicialização de Controladores Adaptativos e Redução de Conhecimentos Prévios. In: Simpósio Brasileiro de Automação Inteligente (SBAI), 2017, Porto Alegre. Proc. of the XIII Simpósio Brasileiro de Automação Inteligente:1145-1152. 2017.
- TEIXEIRA, R. B.; OLIVEIRA, T. R.; AMARAL, J. F. M.. Supressão de Oscilações em Controle Extremal via Redes Neurais. In: Congresso Brasileiro de Automática (CBA), 2016, Vitória. XXI Congresso Brasileiro de Automática (CBA):1494-1499. 2016.

CONCLUSÃO e TRABALHOS FUTUROS

Nessa dissertação foram realizados três estudos de caso envolvendo a aplicação de técnicas de inteligência computacional a controladores adaptativos. Em particular, foram usadas redes neurais, algoritmos genéticos e funções de monitoração chaveadas. Todos eles obtiveram resultados satisfatórios apresentados pelas simulações realizadas e, portanto, servem de base para novos estudos e futuras aplicações.

No Capítulo 1 foi apresentada uma introdução teórica sobre controle extremal (ESC) e redes neurais artificiais (RNA). Em seguida, foi desenvolvido um método de controle utilizando ESC com função de monitoração e RNA, onde o ESC garante que a saída da planta convirja para uma vizinhança do extremo e a RNA contribui para que a oscilação em torno do extremo seja suprimida. Mesmo utilizando uma rede neural artificial com poucos neurônios na camada escondida e poucos dados de treinamento foi possível obter resultados satisfatórios. Como continuidade desse trabalho pode-se aplicar tal método em sistemas estabilizadores, como por exemplo uma colher que neutraliza o tremor da mão de pessoas com Parkinson, comprovando também a aplicação prática do método proposto.

No Capítulo 2 a técnica de AG foi utilizada em duas aplicações em conjunto com controladores MRAC. Na primeira a função do AG foi descobrir os melhores parâmetros para inicialização do MRAC como forma de diminuir o efeito da resposta transitória. O método foi formulado para sistemas SISO, mas pode ser generalizado para sistemas MIMO. Na segunda aplicação o AG foi proposto para relaxar a hipótese do conhecimento prévio dos sinais de direção de controle de um controlador MRAC multivariável. Desta forma, o AG é responsável por descobrir a combinação correta dos sinais dos elementos da diagonal principal da matriz de HFG. O mesmo sistema ainda foi comparado com um método que utiliza funções de monitoração, como forma de mostrar que o papel do AG na obtenção desse conhecimento prévio é fundamental para a redução de transitórios e redução do sinal de controle. Nota-se que na abordagem com funções de monitoração implementados em tempo real mas utilizando majorantes mais conservadores, onde os transitórios não são garantidamente bons e tendem a piorar conforme o número de entradas e saídas do sistema aumenta. As simulações realizadas apresentaram resultados convincentes, onde os objetivos propostos foram atingidos, provando assim a eficiência

do método. Como continuidade desse estudo de caso pode-se aplicar a técnica desenvolvida para plantas com grau relativo maior que um, verificando a efetividade do método proposto para tais casos.

No Capítulo 3 foram utilizadas funções de monitoração individualizadas para cada variável do vetor de erros de saída em conjunto com controladores BMRAC. A função de monitoração foi responsável por encontrar o sinal de cada menor principal da matriz HFG (responsável pela direção de controle), de forma que o erro de trajetória convergisse para zero através de uma prova rigorosa para a estabilidade exponencial do sistema em malha fechada.

As simulações realizadas apresentaram resultados esperados, onde os objetivos propostos foram alcançados, ilustrando assim a eficiência dos métodos empregados e mostrando que os métodos inteligentes podem ser de fato combinados a diversos outros sistemas de controle contribuindo de forma significativa para a obtenção de melhores resultados.

REFERÊNCIAS

- Aminde, N. O. *Controle Extremal via Funções de Monitoração e Realimentação de Saída*. Dissertação, Universidade Federal do Rio de Janeiro, 2013.
- Aminde, N. O.; Oliveira, T. R.; Hsu, L. Global output-feedback extremum seeking control via monitoring functions. In *Decision and Control (CDC), 2013 IEEE 52nd Annual Conference on*, pages 1031–1036. IEEE, 2013.
- Ariyur, K. B; Krstic, M. *Real-time optimization by extremum-seeking control*. John Wiley & Sons, 2003.
- Barkana, I. Simple adaptive control- a stable direct model reference adaptive control methodology-brief survey. *International Journal of Adaptive Control and Signal Processing*, 28(7-8):567–603, 2014.
- Bodson, M.; Groszkiewicz, J. E. Multivariable adaptive algorithms for reconfigurable flight control. *IEEE transactions on control systems technology*, 5(2):217–229, 1997.
- Coppin, B. *Inteligência artificial*. Grupo Gen-LTC, 2015.
- Costa, R. R.; Hsu, L.; Imai, A. K.; Kokotović, P. Lyapunov-based adaptive control of mimo systems. *Automatica*, 39(7):1251–1257, 2003.
- Filippov, A. F. Differential equations with discontinuous right-hand side. *Matematicheskii sbornik*, 93(1):99–128, 1960.
- Houck, C. R.; Joines, J.; Kay, M. G. A genetic algorithm for function optimization: a matlab implementation. *NCSU-IE TR*, 95(09), 1995.
- Hsu, L.; Costa, R. R. A binary control approach to design globally exponentially stable systems. In *Proceedings of the 7th International Conference on Systems Engineering*, 1–9, 1990.
- Hsu, L.; Costa, R. R. B-MRAC: Global exponential stability with a new model reference adaptive controller based on binary control theory. *Control-Theory and Advanced Technology*, 10(4):p.649–668, 1994.

- Hsu, L.; Costa, R. R. MIMO direct adaptive control with reduced prior knowledge of the high frequency gain. In *Decision and Control, 1999. Proceedings of the 38th IEEE Conference on*, volume 4, p.3303–3308. IEEE, 1999.
- Imai, A. K. *Controlador Adaptativo Multivariável usando Fatoração da Matriz de Ganho de Alta Frequência*. Tese, Universidade Federal do Rio de Janeiro, COPPE, 2003.
- Ioannou, Petros A.; Sun, J. *Robust adaptive control*. Courier Corporation, 2012.
- Ioannou, P. A.; Sun, J. *Robust adaptive control*, volume 1. PTR Prentice-Hall Upper Saddle River, NJ, 1996.
- Kailath, T. *Linear systems*, volume 156. Prentice-Hall Englewood Cliffs, NJ, 1980.
- Khalil, H. K. *Nonlinear systems*, 3rd. *New Jersey, Prentice Hall*, 9, 2002.
- Liu, Y.; Tao, G. Model-based direct adaptive actuator failure compensation techniques with applications to aircraft flight control systems. In *AIAA Guidance, Navigation, and Control Conference and Exhibit*, p. 6554, 2006.
- Liu, Y.; Tao, G. Multivariable MRAC using nussbaum gains for aircraft with abrupt damages. In *Decision and Control, 2008. CDC 2008. 47th IEEE Conference on*, p. 2600–2605. IEEE, 2008.
- Lombaerts, T.; Chu, Q.; Mulder, J.; Joosten, D. Real time damaged aircraft model identification for reconfiguring flight control. In *AIAA atmospheric flight mechanics conference and exhibit*, p. 6717, 2007.
- Martensson, B. The unmixing problem. *IMA–Journal of Mathematical Control and Information*, 8(4):p. 367–377, 1991.
- Nguyen, N.; Bakhtiari-Nejad, M.; Huang, Y. Hybrid adaptive flight control with bounded linear stability analysis. In *AIAA Guidance, Navigation and Control Conference and Exhibit*, p. 6422, 2007.
- Nguyen, N.; Krishnakumar, K.; Kaneshige, J.; Nespeca, P. Dynamics and adaptive control for stability recovery of damaged asymmetric aircraft. In *AIAA Guidance, Navigation, and Control Conference and Exhibit*, p. 6049, 2006.

- Oliveira, T. R.; Peixoto, A. J.; Hsu, L. Global real-time optimization by output-feedback extremum-seeking control with sliding modes. *Journal of the Franklin Institute*, 349(4): p.1397–1415, 2012.
- Oliveira, T. R.; Peixoto, A. J.; Hsu, L. Sliding mode control of uncertain multivariable nonlinear systems with unknown control direction via switching and monitoring function. *IEEE Transactions on Automatic Control*, 55(4):p. 1028, 2010.
- Oliveira, T. R.; Peixoto, A. J.; Nunes, E. V. Binary robust adaptive control with monitoring functions for systems under unknown high-frequency-gain sign, parametric uncertainties and unmodeled dynamics. *International Journal of Adaptive Control and Signal Processing*, 30(8-10):p. 1184–1202, 2016.
- Rugh, W. J. *Linear system theory*, volume 2. Prentice-Hall Upper Saddle River, NJ, 1996.
- Ryan, E. Adaptive stabilization of multi-input nonlinear systems. *International Journal of Robust and Nonlinear Control*, 3(2):p. 169–181, 1993.
- Sastry, S.; Bodson, M. *Adaptive control: Stability, convergence and robustness*. Courier Corporation, 2011.
- Silva, I. d.; Spatti, D. H.; Flauzino, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. *São Paulo: Artliber*, p. 33–111, 2010.
- Tafner, M. A. Redes neurais artificiais: aprendizado e plasticidade. *Revista Cérebro e Mente, Universidade Estadual de Campinas*, 1998.
- Teixeira, R. B.; Oliveira, T. R.; Amaral, J. F. M. Supressão de oscilações em controle extremal via redes neurais. *XXI Congresso Brasileiro de Automática (CBA)*, p. 1494–1499, 2016.
- Teixeira, R. B.; Oliveira, T. R.; Amaral, J. F. M. Aplicação de algoritmos genéticos para inicialização de controladores adaptativos e redução de conhecimentos prévios. *XXIII Simpósio Brasileiro de Automação Inteligente (SBAI)*, p. 1145–1499, 2017.
- Utkin, V.; Guldner, J.; Shi, J. *Sliding mode control in electro-mechanical systems*, volume 34. CRC press, 2009.

Utkin, V. I. Sliding modes and their applications in variable structure systems. *Mir, Moscow*, 1978.

Weller, S.; Goodwin, G. C. Hysteresis switching adaptive control of linear multivariable systems. *IEEE Transactions on Automatic Control*, 39(7):p. 1360–1375, 1994.