

UNIVERSIDADE FEDERAL DO PARANÁ

IDENTIFICAÇÃO USANDO PROGRAMAÇÃO DE EXPRESSÃO GÊNICA E
APLICAÇÃO DE CONTROLADORES EM VÁLVULAS DE RECIRCULAÇÃO DE
GASES DE ESCAPE

CURITIBA
2016

GABRIEL MAIDL

IDENTIFICAÇÃO USANDO PROGRAMAÇÃO DE EXPRESSÃO GÊNICA E
APLICAÇÃO DE CONTROLADORES EM VÁLVULAS DE RECIRCULAÇÃO DE
GASES DE ESCAPE

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica, no curso de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Paraná.

Orientador: Prof. Leandro dos Santos Coelho

CURITIBA
2016

M217i

Maidl, Gabriel

Identificação usando programação de expressão gênica e aplicação de controladores em válvulas de recirculação de gases de escape / Gabriel Maidl. – Curitiba, 2016.

84 f ; il. color : 30 cm.

Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, 2016.

Orientador: Leandro dos Santos Coelho

Bibliografia: p. 82-84.

1. Óxidos de Nitrogênio. 2. Queima de gases. 3. Automóveis – Motores – Combustão. 4. Algoritmos genéticos. 5. Expressão gênica. 6. Ar – Poluição .
I. Universidade Federal do Paraná. II.Coelho, Leandro dos Santos. III. Título.

CDD: 629.253

TERMO DE APROVAÇÃO

GABRIEL MAIDL

IDENTIFICAÇÃO USANDO PROGRAMAÇÃO DE EXPRESSÃO GÊNICA E APLICAÇÃO DE CONTROLADORES EM VÁLVULAS DE RECIRCULAÇÃO DE GASES DE ESCAPE

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica, no curso de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Paraná, pela seguinte banca examinadora:



Prof. Dr. Leandro dos Santos Coelho
Orientador – Departamento de Engenharia Elétrica UFPR



Prof. Dr. Gideon Villar Leandro
Departamento de Engenharia Elétrica UFPR



Prof. Dr. Roberto Zanetti Freire
Departamento de Engenharia de Produção e Sistemas, PUCPR

Curitiba, 25 de agosto de 2016.

RESUMO

A Recirculação de Gases de Escape é um método que visa à diminuição da emissão de uma importante classe de poluente, os Óxidos de Nitrogênio. Esta redução é alcançada por meio da diminuição da temperatura em que a queima do combustível ocorre, ocasionada pela reinserção de parte dos gases de escape, inertes na combustão, na admissão do motor através de uma válvula. Essa válvula, chamada de Válvula de Recirculação de Gases de Escape, é um sistema eletromecânico composto por um motor de corrente contínua, um trem de engrenagens e a própria válvula. O posicionamento da abertura desta válvula é diretamente ligado à quantidade de gases recirculados e, por consequência, à quantidade de poluentes emitidos. Portanto, o estudo e controle de sua dinâmica são realizados neste trabalho. São investigadas as estruturas de modelos Autorregressivos lineares e não-lineares, as quais, utilizando dados obtidos dessa válvula, servirão para modelar a dinâmica do sistema. A seleção de estrutura desses modelos é realizada por intermédio da Programação de Expressão Gênica, um algoritmo bioinspirado otimizador de estruturas. Um controlador Proporcional-Integral a ser aplicado é obtido por meio da otimização de seus parâmetros pelo Algoritmo Genético. Também foi investigado e aplicado o Controlador Preditivo Generalizado, que calcula o sinal de controle ideal por meio da estimativa das respostas futuras utilizando um modelo do sistema. Posteriormente, foram comparados os modelos encontrados e o desempenho dos controladores aplicados.

Palavras-chave: Recirculação de Gases de Escape. Identificação de Sistemas.

Algoritmos Genéticos. Programação de Expressão Gênica.

Controle de Sistemas.

ABSTRACT

The Recirculation of Exhaust Gases is a method with aim to reduce the emission of a Oxides of Nitrogen, a relevant pollutant class. This reduction is achieved by decreasing the temperature the fuel burns, achieved through the reinsertion of exhaust gases into the engine inlet through a poppet valve, these gases are inert in the combustion process. Such valve, so-called Recirculation Exhaust Gas Valve, is an electromechanical system composed by a DC motor, a gear train and the valve itself. The positioning of the valve's opening is directly attached to the amount of recirculated gas and therefore the amount of pollutants emitted. Therefore the study and control of its dynamics are carried out in this work. We'll investigate the structures of linear and nonlinear autoregressive models, which will be used to model the system dynamics taking in account the data collected from the valve. The selection of these models structure is accomplished by Gene Expression Programming, a bioinspired structure optimization. A Genetic Algorithm is used to optimize the parameters of a Proportional-Integral Controller which will be applied in the system. We will also investigate and apply the Generalized Predictive Controller, which calculates the optimal control signal by estimating the future responses using a system model. Later, we compare the models results and the performances of the applied controllers.

Keywords: Exhaust Gases Recirculation. System Identification. Genetic algorithms.
Gene Expression Programming. Control systems.

LISTA DE FIGURAS

FIGURA 1 - DIAGRAMA DE BLOCOS DE UM CONTROLADOR PID	29
FIGURA 2 - SINAIS DE REFERÊNCIA, CONTROLE E SAÍDA NO GPC	34
FIGURA 3 - FLUXOGRAMA DO ALGORITMO GENÉTICO	41
FIGURA 4 - CRUZAMENTO NO ALGORITMO GENÉTICO	42
FIGURA 5 - MUTAÇÃO NO ALGORITMO GENÉTICO	43
FIGURA 6 - FLUXOGRAMA DA GEP	44
FIGURA 7 - ÁRVORE DE EXPRESSÃO DE UM GENE	46
FIGURA 8 - ÁRVORE DE EXPRESSÃO DE UM CROMOSSOMO COM DOIS GENES.....	47
FIGURA 9 - TIPOS DE MUTAÇÃO DA GEP	48
FIGURA 10 - EXEMPLO DE TRANSPOSIÇÃO IS.....	49
FIGURA 11 - TRANSPOSIÇÃO RIS	49
FIGURA 12 - RECOMBINAÇÃO DE GENES EM UM PONTO	50
FIGURA 13 - RECOMBINAÇÃO DE GENES EM DOIS PONTOS.....	51
FIGURA 14 - ESQUEMÁTICO DA READMISSÃO DE GASES ESCAPE	55
FIGURA 15 - ELEMENTOS DA VÁLVULA.....	56
FIGURA 16 - FOTOGRAFIA DE UMA VÁLVULA DE RGE.....	56
FIGURA 17 - ESQUEMÁTICO DA TROCA DE SINAIS	57
FIGURA 18 - SINAL DE ESTÍMULO PARA AS AQUISIÇÕES	59
FIGURA 19 - AQUISIÇÃO DA VÁLVULA DE TESTES EM BANCADA	60
FIGURA 20 - AQUISIÇÃO DA VÁLVULA UTILIZADA EM VEÍCULOS PESADOS...61	
FIGURA 21 - EVOLUÇÃO DAS GEP PARA OS MODELOS DA VÁLVULA DE TESTES	63
FIGURA 22 - RESPOSTAS DO MODELO DA GEP1 PARA A VÁLVULA DE TESTES	64
FIGURA 23 - RESPOSTAS DO MODELO DA GEP2 PAR A VÁLVULA DE TESTES	65
FIGURA 24 - RESULTADOS PARA O MODELO DA GEP3 DA VÁLVULA DE TESTES	66
FIGURA 25 - EVOLUÇÃO DA GEP3 NA IDENTIFICAÇÃO DA VÁLVULA USADA .68	
FIGURA 26 - RESULTADOS PARA O MODELO DA GEP3 DA VÁLVULA USADA.68	

FIGURA 27 - EVOLUÇÃO DO MELHOR TESTE DO ALGORITMO GENÉTICO	71
FIGURA 28 - SIMULAÇÃO DE CONTROLADOR PI COM MELHOR IAE	72
FIGURA 29 - RESPOSTA DO CONTROLADOR PI NA VÁLVULA DE TESTES	73
FIGURA 30 - RESPOSTA DO CONTROLADOR PI NA VÁLVULA USADA	73
FIGURA 31 – GPC SIMULADO NO MODELO DA GEP3 DA VÁLVULA DE TESTES	74
FIGURA 32 - EVOLUÇÃO DOS PARÂMETROS NO MODELO DA GEP3 DA VÁLVULA DE TESTES	75
FIGURA 33 - RESPOSTA DO CONTROLADOR GPC NA VÁLVULA NOVA	76
FIGURA 34 - EVOLUÇÃO DOS PARÂMETROS NA VÁLVULA NOVA	76
FIGURA 35 - ERRO ENTRE O GPC NA SIMULAÇÃO E NA VÁLVULA REAL	77
FIGURA 36 - RESPOSTA DO CONTROLADOR GPC NA VÁLVULA USADA	78
FIGURA 37 - EVOLUÇÃO DOS PARÂMETROS NA VÁLVULA USADA	78

LISTA DE TABELAS

TABELA 1 - TIPOS DE APROXIMAÇÃO PARA SISTEMAS AMOSTRADOS	30
TABELA 2 - PARÂMETROS PARA AS CONFIGURAÇÕES DA GEP	62
TABELA 3 - COMPARATIVO DO R^2 DAS GEPS PARA A VÁLVULA DE TESTES .	63
TABELA 4 - DESEMPENHO DOS MELHORES MODELOS PARA A VÁLVULA DE TESTES	64
TABELA 5 - ANÁLISE DO MSE N PASSOS A FRENTE PARA A VÁLVULA DE TESTES	67
TABELA 6 - ANÁLISE DO MSE N PASSOS A FRENTE PARA A VÁLVULA USADA	69
TABELA 7 - COMPARATIVO DE TESTES DOS CONTROLADORES	70
TABELA 8 - DESEMPENHO DO GA NA OTIMIZAÇÃO DO CONTROLE PI.....	71

LISTA DE SIGLAS

AR	- <i>Autoregressive</i>
ARMA	- <i>Autorregressive Moving Average</i>
ARMAX	- <i>Autoregressive Moving Average with eXogenous Input</i>
ARX	- <i>Autoregressive with eXogenous Input</i>
DC	- <i>Direct Current</i>
DMC	- <i>Dynamic Matrix Control</i>
ET	- <i>Expression Tree</i>
FIR	- <i>Finite Impuse Response</i>
GA	- <i>Genetic Algorithm</i>
GEP	- <i>Gene Expression Programming</i>
GMV	- <i>Generalized Minimum Variance</i>
GP	- <i>Genetic Programming</i>
GPC	- <i>Generalized Predictive Control</i>
IDCOM	- <i>Identification-Command</i>
LSE	- <i>Least-Squares Estimation</i>
MA	- <i>Moving Average</i>
MPC	- <i>Model Predictive Control</i>
MSE	- <i>Mean Squared Error</i>
NARMAX	- <i>Nonlinear Autoregressive Moving Average with eXogenous Inputs</i>
NARX	- <i>Nonlinear Autoregressive with eXogenous Inputs</i>
NO _x	- <i>Óxidos de Nitrogênio</i>
ORF	- <i>Open Reading Frame</i>
PI	- <i>Proporcional-Integral</i>
PID	- <i>Proporcional-Integral-Derivativo</i>
PSO	- <i>Particle Swarm Optimization</i>
PWM	- <i>Pulse Width Modulation</i>
RGE	- <i>Recirculação de Gases de Escape</i>
RLS	- <i>Recursive Least-Squares</i>

SUMÁRIO

1 INTRODUÇÃO	12
1.1 POSICIONAMENTO E MOTIVAÇÃO DA PESQUISA	12
1.2 OBJETIVO DA PESQUISA	13
1.3 ORGANIZAÇÃO DO TEXTO	14
2 IDENTIFICAÇÃO E REPRESENTAÇÃO DE SISTEMAS POR MEIO DE MODELOS AUTORREGRESSIVOS	15
2.1 INTRODUÇÃO.....	15
2.2 O MODELO ARMAX E SEUS DERIVADOS.....	17
2.3 OS MODELOS NARMAX E NARX	19
2.4 ALGORITMO DOS MÍNIMOS QUADRADOS.....	21
2.5 ALGORITMO DOS MÍNIMOS QUADRADOS RECURSIVO.....	24
3 TÉCNICAS DE CONTROLE	28
3.1 CONTROLE PID DISCRETO.....	28
3.1.1 Controle PID Contínuo.....	29
3.1.2 Discretização	30
3.2 CONTROLE PREDITIVO BASEADO EM MODELO.....	32
3.2.1 Fundamentos de Controle Preditivo.....	32
3.2.2 Controle Preditivo Generalizado	33
4 APLICAÇÃO DE METAHEURÍSTICAS DE OTIMIZAÇÃO NA IDENTIFICAÇÃO E CONTROLE DE SISTEMAS	39
4.1 INTRODUÇÃO.....	39
4.2 ALGORITMO GENÉTICO.....	41
4.3 PROGRAMAÇÃO DE EXPRESSÃO GÊNICA.....	43
4.3.1 Interpretação dos Cromossomos na GEP	45
4.3.2 Seleção e Replicação	47

4.3.3 Mutaç�o	47
4.3.4 Transposiç�o e Inserç�o de Sequ�ncia	48
4.3.5 Recombinaç�o	50
4.3.6 M�todo de Poda e Funç�o Objetivo	52
5 DESCRIÇ�O DO ESTUDO DE CASO	54
5.1 V�LVULA DE RECIRULAÇ�O DE GASES DE ESCAPE	54
5.2 INTERFACE COM A V�LVULA	57
6 RESULTADOS	59
6.1 DADOS DA AQUISIÇ�O DO SISTEMA	59
6.2 MODELOS OBTIDOS PARA AS V�LVULAS DE RGE	61
6.2.1 Modelos para a V�lvula de Testes	62
6.2.2 Modelo para a V�lvula Usada em Ve�culos Pesados	67
6.3 RESULTADOS DAS T�CNICAS DE CONTROLE	69
6.3.1 Resultados para a Aplicaç�o do Controlador PI	70
6.3.2 Resultados para a Aplicaç�o do GPC	74
7 AN�LISE DE RESULTADOS E DISCUSS�O	79
8 CONCLUS�O E PERSPECTIVAS FUTURAS	81
REFER�NCIAS	83

1 INTRODUÇÃO

Neste capítulo são apresentados os conceitos introdutórios, bem como as peculiaridades do sistema de Recirculação de Gases de Escape que demonstram a necessidade do presente estudo. Também são elucidados os objetivos do trabalho e a organização do texto.

1.1 POSICIONAMENTO E MOTIVAÇÃO DA PESQUISA

A maioria dos sistemas encontrados em aplicações práticas possuem características não-lineares ou variantes no tempo, das quais métodos convencionais, como o controle por Alocação de Polos e o Proporcional Integral Derivativo, não são capazes de lidar. Tentativas para solucionar tais problemas, em geral para aplicações militares, começaram a surgir na década de 1950. Nesta época começara a surgir classes de controle adaptativo, que monitoram as saídas dos sistemas a fim de ajustar os parâmetros dos controladores (BOBÁL, 2005; WELLSTEAD; ZARROP, 1991).

Uma das principais metodologias desenvolvidas para a solução de problemas que não são facilmente tratados pelas técnicas clássicas é o Controlador Preditivo Generalizado. Esta técnica utiliza a previsão, por meio de modelo, das saídas do sistema e do sinal de controle, e a lei de controle é estipulada pela minimização de um critério de desempenho destes sinais futuros. Isto permite que o sistema de controle lide com variações no tempo morto, processos de fase não-mínima, plantas instáveis em malha aberta e com polos mal amortecidos (CLARKE; MOHTADI; TUFFS, 1987).

A modelagem de um sistema pode ser descrita em uma grande variedade de modelos matemáticos, sendo um dos mais difundidos os modelos Autorregressivos de entrada exógena, que podem também, dependendo de sua formulação matemática expressar unidades não-lineares. Com o intuito determinar modelos destas classes, este trabalho fará uso de um algoritmo otimizador de estruturas, chamado de Programação de Expressão Gênica, desenvolvido por Ferreira (2001).

Já no que tange o estudo de caso, este será constituído por duas Válvulas de Recirculação de Gases de Escape, que, cada uma, constitui um sistema com uma entrada e uma saída. Estas válvulas são inseridas em motores a Diesel a fim de reduzir o nível de emissão de um grupo importante de poluentes, os Óxidos de Nitrogênio, nos gases de escape em até 50% (MUNCRIEF *et al.*, 2008). Devido a tal importância, um bom conhecimento das dinâmicas deste sistema e, também, a aplicação de técnicas eficientes de controle são desejadas.

1.2 OBJETIVO DA PESQUISA

A pesquisa visa analisar e controlar um sistema não-linear conhecido como Válvula de Recirculação de Gases, importante colaborador na redução da emissão de poluentes em veículos pesados movidos a Diesel, utilizando técnicas avançadas de identificação e controle de sistemas. De forma mais específica, tem-se como objetivos:

- Realizar um levantamento de informações acerca da Válvula de Recirculação de Gases de Escape;
- Elucidar as metodologias de identificação de sistemas lineares e não-lineares;
- Fazer um levantamento da literatura abordando a otimização de parâmetros por meio do Algoritmo Genético;
- Explicar a otimização de modelos para a identificação de sistemas por meio da Programação de Expressão Gênica,
- Apresentar a formulação das técnicas de Controle Proporcional-Integral e de Controle Preditivo.
- Coletar dados dos sistemas e realizar as modelagens por meio da Programação de Expressão Gênica;
- Projetar os controladores Preditivo e Proporcional-Integral para a válvula de Recirculação de Gases;

- Aplicar as técnicas de controle em duas válvulas, uma utilizada apenas em bancada de testes e outra já utilizada em um veículo pesado;
- Analisar a exatidão dos modelos obtidos e o desempenho dos controladores testados.

1.3 ORGANIZAÇÃO DO TEXTO

O texto é dividido em oito capítulos, que contemplam a introdução, posicionamento da pesquisa, embasamento teórico, descrição do estudo de caso, análise de resultados, conclusão e perspectiva futura.

A sequência necessária para a identificação e controle da Válvula de Recirculação de Gases de Escape inicia com a seleção de um modelo para representá-la, os quais são introduzidos no capítulo 2. Posteriormente, é preciso que se escolha as técnicas de controle que serão utilizadas na válvula, assunto elencado no capítulo 3.

Com estas duas informações, os modelos escolhidos e as técnicas de controle, pode-se passar para a fase de escolha dos parâmetros que estes exigem. Para tal, no capítulo 4 são abordadas duas Metaheurísticas de Otimização, uma para a otimização dos parâmetros do controlador, e outra para a otimização da estrutura do modelo.

No capítulo 5 são descritas as características da Válvula de Recirculação de Gases de Escape, que é o estudo de caso utilizado neste trabalho. Neste capítulo também são encontradas informações sobre a interface utilizada para os experimentos.

Os resultados das otimizações, bem como dos testes das técnicas de controle, são expostos no capítulo 6, junto com informações relacionadas ao desempenho obtido por estes.

Uma discussão sobre os resultados é abordada no capítulo 7, enquanto a conclusão e as perspectivas futuras são apresentadas no capítulo 8.

2 IDENTIFICAÇÃO E REPRESENTAÇÃO DE SISTEMAS POR MEIO DE MODELOS AUTORREGRESSIVOS

Neste capítulo são abordadas técnicas utilizadas para a representação de sistemas por modelos matemáticos, bem como os algoritmos utilizados para a sua parametrização. Estas ferramentas são utilizadas neste trabalho para obter representações computacionais da Válvula de Recirculação de Gases de Escape, que posteriormente se tornam úteis ao projeto de controladores.

2.1 INTRODUÇÃO

Os modelos matemáticos constituem uma abordagem relevante quando se deseja estudar ou interferir na dinâmica de um sistema. Neste contexto, um sistema pode ser interpretado como qualquer processo ou fenômeno cujo comportamento é de interesse, como a Válvula de Recirculação de Gases de Escape, estudo de caso abordado neste trabalho, que será apresentado na seção 4.3.1. Com o auxílio de um modelo é possível projetar diversas operações com o sistema, como o controle ou filtragem da saída, ou, até mesmo, prever seu comportamento futuro (LJUNG; SÖDERSTRÖM, 1986).

Tais modelos podem ser qualificados conforme as características matemáticas que carregam, como sendo: em tempo contínuo ou discreto, lineares ou não-lineares, estocásticos ou determinísticos, entre outros. Em geral, quando se trata de um processo observado por intermédio de um sistema computacional, a modelagem matemática tem por característica o tempo discreto. Isto significa que a representação é concebida para expressar o comportamento de amostras das entradas e saídas do processo, tomadas com uma determinada frequência (LJUNG, 1999; ÅSTRÖM; WITTENMARK, 1997).

Segundo Billings (2013), os modelos Autorregressivos com Média Móvel e Entrada Exógena, do inglês *Autoregressive Moving Average with eXogenous Input* (ARMAX), e seus derivados são os mais utilizados na representação de sistemas lineares. São derivados deste modelo: o Autorregressivo, do inglês *Autoregressive*

(AR); o Autorregressivo com Entrada Exógena, do inglês *Autoregressive with eXogenous Input* (ARX); o de Média Móvel, em inglês *Moving Average*, (MA); o Autorregressivo com Média Móvel, do inglês *Autoregressive Moving Average* (ARMA); além do modelo de Resposta Finita ao Impulso, do inglês *Finite Impulse Response* (FIR). Estes modelos utilizam os valores passados das entradas e/ou saídas do sistema e, eventualmente, do ruído que incide sobre este, para estimar o valor da saída atual. A formulação do modelo ARMAX e seus derivados são mais bem exemplificados na seção 2.2.

Quanto aos sistemas não-lineares, estes são caracterizados pela saída como função não-linear de suas entradas. Existem diversos modelos capazes de representar sistemas com esta característica, tais como: Redes Neurais Artificiais, sistemas baseados em Lógica Nebulosa, Séries de Volterra, modelos baseados em blocos, a exemplo dos de Hammerstein e Wiener, entre outros (OGUNFUNMI, 2007; BILLINGS, 2013).

Porém, o modelo Autorregressivo com Média Móvel e Entrada Exógena Não-linear, do inglês *Nonlinear Autoregressive Moving Average with eXogenous Inputs* (NARMAX), polinomial na forma de potências pode apresentar vantagens em relação aos modelos citados anteriormente. Pois este consegue representar uma ampla variedade de funções não-lineares utilizando poucos parâmetros, enquanto modelos como os baseados em Séries de Volterra, por exemplo, possuem aumento exponencial do número de termos em relação ao grau de não-linearidade (BILLINGS, 2013). Este modelo e sua variante, o modelo Autorregressivo com Entrada Exógena Não-linear, do inglês *Nonlinear Autoregressive with eXogenous Input* (NARX), são descritos na seção 2.3 deste trabalho.

Segundo Ljung (1999), a construção de um modelo depende de três fatores básicos: dados do sistema, um conjunto de candidatos a modelos, e uma regra que avalia o modelo em relação aos dados. No caso deste projeto, os dados são um conjunto de estímulos e respostas obtidos de Válvulas de Recirculação de Gases de escape. Enquanto os modelos candidatos são variantes dos modelos ARMAX e NARMAX, no caso os modelos ARX e NARX, posteriormente apresentados ainda neste capítulo. E a regra utilizada para relacionar o modelo com os dados é a média do erro de predição ao quadrado, sendo o erro de predição a diferença entre os valores obtidos por meio do modelo e os dados do sistema. Após isto, é necessária a validação do modelo, a qual é possível por meio da avaliação de desempenho

utilizando dados que não compunham o conjunto utilizado na seleção de parâmetros do modelo.

Dois métodos principais podem ser tomados para estimar parâmetros de modelos utilizando a regra da minimização do Erro Quadrático Médio, o algoritmo Estimador de Mínimos Quadrados, do inglês *Least-Squares Estimation* (LSE), e o algoritmo Recursivo de Mínimos Quadrados, do inglês, *Recursive Least-Squares* (RLS). O primeiro é utilizado para a identificação *Off-Line*, ou seja, quando se tem um conjunto de dados previamente medidos e deseja-se, por meio destes, estimar os parâmetros de um modelo. Enquanto o segundo é utilizado para a identificação *On-Line*, em que o modelo é estimado toda vez que uma nova medição é realizada no sistema. O RLS é particularmente útil em sistemas com propriedades dinâmicas, os quais o comportamento varia conforme o ponto de operação ou carga, por exemplo (LJUNG; SÖDERSTRÖM, 1986; LJUNG, 1999).

2.2 O MODELO ARMAX E SEUS DERIVADOS

Com base em Ljung (1999) e Billings (2013), nesta seção são descritos o modelo ARMAX e seus derivados, utilizados para a representação de sistemas lineares.

Para a definição do modelo matemático, assume-se que $y(k)$ e $u(k)$, são os sinais de saída e entrada do sistema em dado instante k , e $\xi(k)$ é um ruído branco que incide sobre a saída do sistema, sendo assim:

$$A(q^{-1})y(k) = B(q^{-1})u(k) + C(q^{-1})\xi(k), \quad (1)$$

onde

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na}, \quad (2)$$

$$B(q^{-1}) = b_1q^{-1} + \dots + b_{nb}q^{-nb}, \text{ e} \quad (3)$$

$$C(q^{-1}) = 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc}. \quad (4)$$

Os termos $A(q^{-1})$, $B(q^{-1})$, e $C(q^{-1})$ são polinômios do operador atraso q^{-1} , que indica a relação $q^{-n}y(k) = y(k - n)$, por exemplo. Já os valores na , nb e nc representam a ordem, que também pode ser visto como a quantidade de termos, dos polinômios $A(q^{-1})$, $B(q^{-1})$, e $C(q^{-1})$, respectivamente. Logo, a representação apropriada de um sistema linear real por este modelo matemático depende da escolha correta da ordem dos polinômios e de suas constantes multiplicadoras a_i , b_i e c_i . Levando em consideração que a equação (1) representa um sistema discreto, o polinômio $A(q^{-1})$ contém os polos e o polinômio $B(q^{-1})$ contém os zeros da função de transferência do sistema.

Estendendo o modelo da equação (1) por meio dos polinômios apresentados, obtém-se:

$$\begin{aligned} y(k) + a_1y(k-1) + \dots + a_{na}y(k-na) = \\ b_1u(k-1) + b_2u(k-2) + \dots + b_{nb}u(k-nb) + \\ \xi(k) + c_1\xi(k-1) + \dots + c_{nc}\xi(k-nc). \end{aligned} \quad (5)$$

A derivação do modelo ARMAX é realizada conforme a escolha dos três polinômios supracitados. O modelo FIR infere que a saída do processo depende apenas dos valores passados de sua entrada, logo $A(q^{-1}) = 1$ e $C(q^{-1}) = 0$, então se tem:

$$y(k) = B(q^{-1})u(k), \quad (6)$$

que denota,

$$y(k) = b_1u(k-1) + b_2u(k-2) + \dots + b_{nb}u(k-nb). \quad (7)$$

Já o modelo ARX descreve o processo sem admitir valores passados da parcela referente ao ruído, tendo apenas $C(q^{-1}) = 1$, portanto:

$$y(k) + a_1y(k-1) + \dots + a_{na}y(k-na) = b_1u(k-1) + \dots + b_{nb}u(k-nb) + \xi(k). \quad (8)$$

Na variante de Média Móvel, $A(q^{-1}) = 1$ e $B(q^{-1}) = 0$, logo pode-se descrevê-lo como:

$$y(k) = \xi(k) + c_1\xi(k-1) + \dots + c_{nc}\xi(k-nc). \quad (9)$$

No modelo exclusivamente Autorregressivo, particularmente útil em séries temporais, $B(q^{-1}) = 0$ e $C(q^{-1}) = 1$, então:

$$y(k) + a_1y(k-1) + \dots + a_{na}y(k-na) = \xi(k). \quad (10)$$

O modelo ARMA, que pode ser visto como uma soma dos dois anteriores, tem apenas $B(q^{-1}) = 0$, por consequência sua formação é igual a:

$$y(k) + a_1y(k-1) + \dots + a_{na}y(k-na) = \xi(k) + c_1\xi(k-1) + \dots + c_{nc}\xi(k-nc). \quad (11)$$

2.3 OS MODELOS NARMAX E NARX

Segundo Billings (2013), modelos NARMAX, conforme comentado na parte introdutória deste capítulo, estabelecem a relação entre saída e entrada como função não-linear dos valores passados das próprias entrada e saída, e do ruído que incide sobre o processo, assim pode-se estabelecer que:

$$\begin{aligned}
y(k) = & F[y(k-1) + y(k-2) \dots + y(k-n_y) + \\
& u(k-d) + u(k-d-1) + u(k-n_u) + \\
& \xi(k-1) + \xi(k-2) + \xi(k-n_e)],
\end{aligned} \tag{12}$$

onde $F[\cdot]$ representa uma função não linear, d o atraso, e os demais símbolos correspondem aos mesmos expressados na seção 2.2.

De maneira mais explícita, para o modelo polinomial na forma de potências, a relação matemática pode ser expressa como a soma das multiplicações dos regressores:

$$\begin{aligned}
y(k) = & \theta_0 + \sum_{i_1=1}^n \theta_{i_1} x_{i_1}(k) + \sum_{i_1=1}^n \sum_{i_2=1}^n \theta_{i_1 i_2} x_{i_1}(k) x_{i_2}(k) + \\
& \sum_{i_1=1}^n \dots \sum_{i_l=i_{l-1}}^n \theta_{i_1 i_2 \dots i_l} x_{i_1}(k) \dots x_{i_l}(k) + \xi(k)
\end{aligned} \tag{13}$$

onde l é o grau de não-linearidade, $n = n_y + n_u + n_e$, $\theta_{i_1 i_2 \dots i_l}$ são os parâmetros do modelo, θ_0 é o termo independente, e $x_m(k)$ pode ser definido como:

$$x_m(k) = \begin{cases} y(k-m) & 1 \leq m \leq n_y \\ u(k-(m-n_y)) & n_y + 1 \leq m \leq n_y + n_u \\ \xi(k-(m-n_y-n_u)) & n_y + n_u + 1 \leq m \leq n_y + n_u + n_e \end{cases} \tag{14}$$

Em geral, na identificação destes sistemas, o ruído é estabelecido como o erro de estimação do modelo, portanto $\xi(k) = y(k) - \hat{y}(k|k-1)$, onde $\hat{y}(k|k-1)$ é o valor estimado de $y(k)$ pelo modelo no instante $k-1$. Dessa maneira as saídas do modelo têm de ser calculadas iterativamente, não podendo realizar a estimativa da saída em determinado instante k sem ter realizado as estimativas dos instantes anteriores. Devido a essa característica, para obter-se os parâmetros $\theta_{i_1 i_2 \dots i_l}$ do modelo NARMAX é necessário o uso de um algoritmo recursivo, como o que será

apresentado na seção 2.5. Essa necessidade é existente também no modelo linear ARMAX, e nos demais que dependem da parcela relativa ao ruído, a Média Móvel (BILLINGS, 2013; LJUNG; SÖDERSTRÖM, 1986).

No caso do modelo NARX um algoritmo em batelada pode ser usado, visto que este não utiliza a parte da modelagem matemática referente ao ruído que incide no processo. O que significa que todos os parâmetros do modelo podem ser estimados simultaneamente por meio de uma notação matricial, como a utilizada pela técnica apresentada na seção 2.3. Assim, a representação geral do modelo NARX é estabelecida como:

$$y(k) = F[y(k-1) + y(k-2) \dots + y(k-n_y) + u(k-d) + u(k-d-1) + u(k-n_u)] \quad (15)$$

Logo, $n = n_y + n_u + n_e$, e

$$x_m(k) = \begin{cases} y(k-m) & 1 \leq m \leq n_y \\ u(k-(m-n_y)) & n_y + 1 \leq m \leq n_y + n_u \end{cases} \quad (16)$$

2.4 ALGORITMO DOS MÍNIMOS QUADRADOS

Como abordado na introdução deste capítulo, o algoritmo Estimador dos Mínimos Quadrados é utilizado nas situações em que se possui um conjunto de medidas realizadas sobre os sinais de um sistema, e se deseja estabelecer uma relação matemática, ou modelo, que descreva a dinâmica entrada-saída deste.

O algoritmo LSE aproxima os parâmetros do modelo pela minimização do Erro Quadrático entre as medidas tomadas da saída do sistema real e as estimadas, aqui chamados de J . Ou seja, o algoritmo busca reduzir o erro produzido pela informação que não foi absorvida pelo modelo (LJUNG; SÖDERSTRÖM, 1986; WELLSTEAD; ZARROP, 1991).

Assumindo a relação entrada saída estipulada como:

$$y(k) = \sum_{i=1}^{n_\theta} \psi_i(k-1)\theta_i + e(k) \quad (17)$$

onde $y(k)$ é a saída do sistema no instante k , $\psi(k-1)$ são as medidas das regressões do modelo para o instante $k-1$, θ são os parâmetros, n_θ a quantidade de parâmetros, e $e(k)$ é o ruído que incide sobre o sistema.

Como o procedimento é realizado para uma predeterminada quantidade N de amostras no tempo, ou seja $k = 1, 2, \dots, N$, a equação, excluindo o ruído, que não é mensurável, pode ser reescrita para a forma matricial como sendo:

$$\mathbf{Y} = \mathbf{\Psi}\mathbf{\Theta}, \quad (18)$$

na qual

$$\mathbf{Y} = \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix}, \quad (19)$$

$$\mathbf{\Psi} = \begin{bmatrix} \psi^T(1) \\ \psi^T(2) \\ \vdots \\ \psi^T(N) \end{bmatrix} \mathbf{e} \quad (20)$$

$$\mathbf{\Theta} = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_{n_\theta} \end{bmatrix}. \quad (21)$$

Os valores contidos em $\psi^T(k)$ podem variar conforme o tipo do modelo, no caso de um modelo ARX, este deve conter apenas os valores passados da entrada e saída:

$$\begin{aligned} \psi^T(k) = [y(k-1), y(k-2) \dots y(k-n_y), \\ u(k-1), u(k-2) \dots u(k-n_u)]. \end{aligned} \quad (22)$$

Já no caso de modelos NARX, como os especificados anteriormente neste capítulo, é possível ter quaisquer valores que constituam relações lineares ou não-lineares entre as entradas e saídas, por exemplo:

$$\begin{aligned} \psi^T(k) = [y(k-1), y(k-2), y^2(k-1), y(k-2) * y(k-3) \\ u(k-1), u(k-1) * u^3(k-4), u(k-1) * y(k-3)]. \end{aligned} \quad (23)$$

Permitindo, assim, o uso do LSE na identificação de sistemas não-lineares, mas que, contudo, são lineares nos parâmetros.

Tendo em vista que não se conhece o vetor de parâmetros Θ , é estabelecida a seguinte relação:

$$\hat{Y} = \Psi \hat{\Theta}, \quad (24)$$

onde \hat{Y} é a saída do modelo com os parâmetros estimados $\hat{\Theta}$.

Com esta informação, pode-se inferir que o erro de estimação $\xi(k)$ é a diferença entre o valor da saída medida, $y(k)$, e a estimada, $\hat{y}(k)$, portanto:

$$\xi(k) = y(k) - \hat{y}(k) = y(k) - \psi^T(k) \hat{\Theta}. \quad (25)$$

Desta forma, o erro quadrático da predição, J , a ser minimizado pode ser escrito como,

$$J = \sum_{k=1}^N \xi^2(k) = \xi^T \xi, \quad (26)$$

expandindo para a notação matricial, tem-se:

$$J = (Y - \Psi \hat{\Theta})^T (Y - \Psi \hat{\Theta}). \quad (27)$$

A minimização do critério é alcançada quando sua derivada é igualada a zero, ou seja, $dJ / d\hat{\Theta} = 0$. Realizando este procedimento na notação matricial, obtém-se:

$$\hat{\Theta} = (\Psi^T \Psi)^{-1} \Psi^T Y. \quad (28)$$

Com este procedimento, $\hat{\Theta}$ será um vetor contendo os valores dos parâmetros que acarretam no menor Erro Quadrático do modelo em relação ao sistema real para as amostras utilizadas. O que possibilita seu uso para fins como a sintonia de controladores.

2.5 ALGORITMO DOS MÍNIMOS QUADRADOS RECURSIVO

Nos casos de avaliação *on-line* de parâmetros de modelo, o que constitui a base de uma das linhas de Controle Adaptativo, e também no caso de modelos que possuam a Média Móvel, como ARMAX e NARMAX, o uso do algoritmo de Mínimos Quadrados Recursivo é frequente. Isto se dá pela característica de poder realizar uma estimativa a cada novo dado sem a necessidade de guardar todo o conjunto de medições realizadas sobre o sistema. O que torna o RLS a versão apropriada do algoritmo de Mínimos Quadrados para tais situações (BILLINGS, 2013; LJUNG; SÖDERSTRÖM, 1986; WELLSTEAD; ZARROP, 1991).

Inicialmente, a definição do algoritmo RLS requer a atualização das componentes y e Ψ , adicionando um novo termo a cada uma destas, $y(k+1)$ e $\psi^T(k+1)$, resultando no seguinte:

$$y(k+1) = \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(k) \\ y(k+1) \end{bmatrix} = \begin{bmatrix} y(k) \\ y(k+1) \end{bmatrix} e \quad (29)$$

$$\Psi(k+1) = \begin{bmatrix} \psi^T(1) \\ \psi^T(2) \\ \vdots \\ \psi^T(k) \\ \psi^T(k+1) \end{bmatrix} = \begin{bmatrix} \Psi(k) \\ \psi^T(k+1) \end{bmatrix}. \quad (30)$$

Reescrevendo, então, a equação (28) da estimação de parâmetros do LSE, para se adequar a este novo paradigma, tem-se:

$$\hat{\Theta}(k+1) = (\Psi^T(k+1) \Psi(k+1))^{-1} \Psi^T(k+1) Y(k+1). \quad (31)$$

Neste ponto, a equação (31) é separada, por conveniência, em duas componentes, P(k+1) e R(k+1), como segue:

$$P(k+1) = (\Psi^T(k+1) \Psi(k+1))^{-1}, \quad (32)$$

$$R(k+1) = \Psi^T(k+1) Y(k+1). \quad (33)$$

Sendo agora:

$$\hat{\Theta}(k+1) = P(k+1) R(k+1). \quad (34)$$

E sua equivalente no instante k:

$$\hat{\Theta}(k) = P(k) R(k). \quad (35)$$

Estende-se então o conteúdo da inversão de P(k+1), como procedido nas equações (36) e (37).

$$\Psi^T(k+1) \Psi(k+1) = [\Psi^T(k) \quad \psi(k+1)] \begin{bmatrix} \Psi(k) \\ \psi^T(k+1) \end{bmatrix} \quad (36)$$

$$\Psi^T(k+1) \Psi(k+1) = \Psi^T(k) \Psi(k) + \psi(k+1) \psi^T(k+1) \quad (37)$$

É possível verificar que a equação (37) já denota de forma implícita a atualização da matriz P , como é exposto quando se faz a substituição por intermédio da equação (32):

$$P(k+1)^{-1} = P(k)^{-1} + \psi(k+1)\psi^T(k+1). \quad (38)$$

A resolução da equação (38) é possível sem a necessidade da inversão de matrizes, o que reduz o custo computacional na operação. Para tal, recorre-se ao lema da inversão:

$$(A + BCD)^{-1} = A^{-1} - A^{-1}B(C^{-1} + DA^{-1}B)^{-1}DA^{-1}. \quad (39)$$

Definindo $A = P(k)^{-1}$, $B = \psi(k+1)$, $C = 1$ e $D = \psi^T(k+1)$, e, posteriormente, realizando a substituição na equação (38), obtém-se:

$$P(k+1) = P(k) - \frac{P(k)\psi(k+1)\Psi^T(k+1)P(k)}{1 + \psi^T(k+1)P(k)\psi(k+1)} \quad (40)$$

É importante observar que a resultante da expressão no divisor da equação (40) é um valor escalar, o que evita o procedimento de divisão de matrizes.

No que tange a componente $R(k+1)$, esta pode ser extendida substituindo as equações (29) e (30) na equação (33), como demonstrado a seguir:

$$\Psi^T(k+1)Y(k+1) = [\Psi^T(k) \quad \psi(k+1)] \begin{bmatrix} Y(k) \\ y(k+1) \end{bmatrix}, \quad (41)$$

$$\Psi^T(k+1)Y(k+1) = \Psi^T(k)Y(k) + \psi(k+1)y(k+1), \quad (42)$$

$$R(k+1) = R(k) + \psi(k+1)y(k+1). \quad (43)$$

Rearranjando a definição de Erro de Estimção ξ do LSE, presente na equação (25), para o instante $k+1$, obtém-se:

$$\xi(k+1) = y(k+1) - \psi^T(k+1)\hat{\Theta}(k). \quad (44)$$

Isolando o termo $y(k+1)$ desta equação, e substituindo na equação (43), resulta-se na seguinte igualdade:

$$R(k+1) = R(k) + \psi(k+1)(\xi(k+1) + \psi^T(k+1)\hat{\Theta}(k)), \quad (45)$$

estendendo a equação temos,

$$R(k+1) = R(k) + \psi(k+1)\xi(k+1) + \psi(k+1)\psi^T(k+1)\hat{\Theta}(k). \quad (46)$$

Substituindo as equações (35) e (41) na equação (43), chega-se a:

$$\begin{aligned} P(k+1)^{-1}\hat{\Theta}(k+1) = \\ P(k)^{-1}\hat{\Theta}(k) + \psi(k+1)\xi(k+1) + (P(k+1)^{-1} - P(k)^{-1})\hat{\Theta}(k), \end{aligned} \quad (47)$$

rearranjando,

$$\hat{\Theta}(k+1) = P(k+1)\psi(k+1)\xi(k+1) + \hat{\Theta}(k) \quad (48)$$

Assim, para estimar os parâmetros do modelo deve-se a cada iteração: primeiramente montar a matriz $\Psi(k+1)$, em seguida calcular $\xi(k+1)$ utilizando a equação (44), posteriormente calcular $P(k+1)$ por intermédio da equação (40), e, por fim, estimar os parâmetros $\hat{\Theta}(k+1)$ utilizando a equação (48).

3 TÉCNICAS DE CONTROLE

Para os testes de técnicas de controle nas válvulas de Recirculação de Gases de Escape que são o foco deste trabalho, foram escolhidas as técnicas de controle Proporcional-Integral, bem como o Controle Preditivo Generalizado. Neste capítulo o embasamento matemático destas técnicas é abordado.

3.1 CONTROLE PID DISCRETO

Segundo Ogata (2010), mais da metade dos processos industriais são controlados por uma estratégia Proporcional-Integral-Derivativa (PID) ou uma de suas variantes. Sua popularidade é tão grande que é utilizado em sistemas que estão presente no dia-a-dia das pessoas, como nos sistema de controle automático de velocidade de veículos, o *cruise control*, e até mesmo em reprodutores de CD (ÅSTRÖM; HÄGGLUND, 2006).

A larga aplicação desta técnica ocorre pelo fato deste tipo de controlador ter se provado satisfatório em processos contínuos, mesmo sem atingir resultados ótimos. Na indústria estes controladores são geralmente ajustados em campo, ou seja, junto ao processo, por meio de regras como a de Ziegler-Nichols (OGATA, 2010).

Como controladores PID frequentemente já estão disponíveis em sistemas e processos, devido a sua vasta implementação analógica, muitas vezes se utiliza de uma implementação digital destes controladores para sua realização em microprocessadores eletrônicos. Esta forma digital é obtida pela discretização da forma contínua, tornando possível seu uso em sistemas amostrados (OGATA, 2010; ÅSTRÖM; WITTENMARK, 1997).

3.1.1 Controle PID Contínuo

Um controlador PID em tempo contínuo convencional, representado na FIGURA 1, funciona realizando operações matemáticas sobre as informações do erro da resposta de um sistema, de forma a torná-lo nulo.

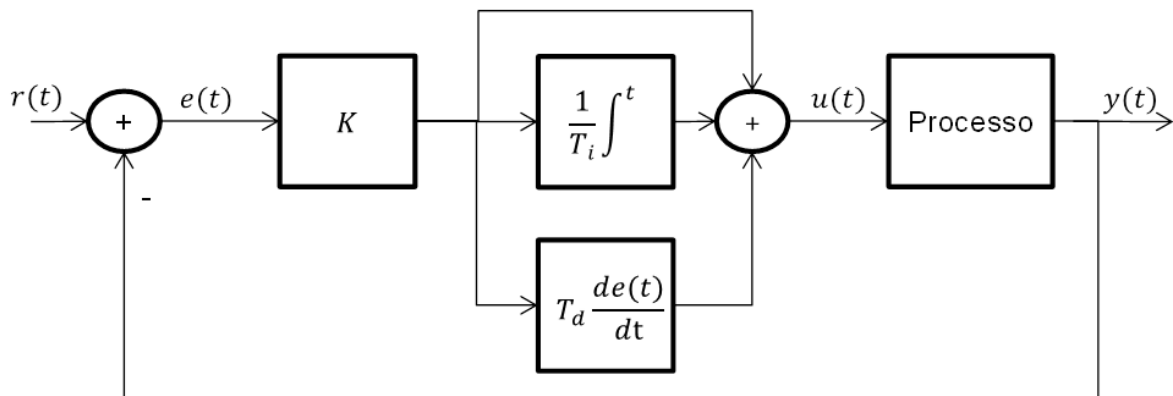


FIGURA 1 - DIAGRAMA DE BLOCOS DE UM CONTROLADOR PID
FONTE: BASEADO EM OGATA (1998)

Para tal, toma-se a medida da diferença entre a referência a que o sistema está sujeito, sinal representado por $r(t)$, e a saída do sistema, $y(t)$, gerando o sinal de erro $e(t)$. As resultantes da integração e derivação de $e(t)$, juntamente com o sinal puro, são em seguida ponderadas por valores conhecidos como ganhos do controlador, e então somadas para formarem o sinal de entrada do sistema, $u(t)$, também chamado de sinal de controle, como na equação a seguir:

$$u(t) = k \left(e(t) + \frac{1}{T_i} \int_0^t e(t) dt + T_d \frac{de(t)}{dt} \right) \quad (49)$$

Esta estrutura de controle é capaz de agregar informações acerca do presente, passado e futuro do erro de sistema, o que o torna eficiente em diversas aplicações. Sendo que estas partes são reguladas por três parâmetros ajustáveis, sendo o ganho k , o tempo integral T_i e o tempo derivativo T_d (ÅSTRÖM; HÄGGLUND, 2006).

O valor de ganho k refere-se, principalmente, à parte proporcional, que isoladamente é uma das formas mais básicas de controle por retroalimentação. Esta

atua no sistema simplesmente inserindo um estímulo proporcional ao valor do erro, fazendo com que este decresça. Todavia, é pouco comum que esta abordagem consiga estabilizar a saída do sistema no valor de referência, geralmente ocasionando uma diferença conhecida como *offset*.

A principal função da atuação de uma parte integral é eliminar a presença dessa diferença, utilizando o acúmulo da informação do erro ao longo do tempo, o que traz uma informação sobre o passado da saída do sistema. O parâmetro T_i está relacionado ao tempo necessário para um determinado valor de erro seja absorvido pelo integrador.

O termo derivativo introduz, por meio de uma extrapolação linear, uma previsão do erro do sistema T_d instantes de tempo à frente. A extrapolação ocorre pela soma da unidade do erro com a derivada, que é a taxa de variação do sinal, dentro do cálculo da lei de controle.

3.1.2 Discretização

As implementações digitais do controlador PID geralmente seguem transformações sobre sua função de transferência no tempo contínuo, mais especificamente no domínio da transformada de Laplace. Estas transformações são aproximações da derivação, em Laplace representada por s , para tempo discreto, com um determinado espaçamento amostral h . Estas aproximações são diferenciações das saídas no tempo, podendo ser realizadas em avanço, atraso, ou na forma trapezoidal, também conhecida como bilinear, como traz a TABELA 1.

TABELA 1 - TIPOS DE APROXIMAÇÃO PARA SISTEMAS AMOSTRADOS

APROXIMAÇÃO EM AVANÇO	APROXIMAÇÃO EM ATRASO	APROXIMAÇÃO BILINEAR
$s = \frac{z-1}{h}$	$s = \frac{z-1}{zh}$	$s = \frac{2z-1}{hz+1}$

FONTE: BASEADO EM ÅSTRÖM E WITTENMARK (1997)

Com essa informação, seria possível substituir s na equação em Laplace da lei de controle e se teria a versão discreta do controlador, desde que observada a necessidade de manter o sistema causal.

Portanto neste trabalho é apresentada uma forma abordada em Åström e Wittenmark (1997), onde o controlador é mantido causal. Além disto, segundo os autores, se provou que não é desejável que toda a referência tenha ação sobre a parte proporcional, sendo ponderada por um coeficiente b , como esta ação é linear, ela não requer uma aproximação discreta:

$$P(kh) = K(br(kh) - y(kh)), \quad (50)$$

onde k é a amostra atual e h o tempo de amostragem.

Enquanto isso, a parte integral pode ser obtida por uma aproximação em avanço:

$$I(kh + h) = I(kh) + \frac{Kh}{T_i} e(kh), \quad (51)$$

Já a parte derivativa é discretizada por meio de uma aproximação em atraso e geralmente contempla um limitador, a fim de evitar a amplificação de altas frequências:

$$D(kh) = \frac{T_d}{T_d + Nh} D(kh - h) - \frac{KT_d N}{T_d + Nh} (y(kh) - y(kh - h)), \quad (52)$$

com esta configuração, o limitador, que é a substituição da parte derivativa por um aproximador, possui apenas o parâmetro N , que, segundo os Åström e Wittenmark (1997), tipicamente deve ser ajustado em um valor entre 3 e 20.

Somando as partes do controlador, a ação de controle em determinado instante k de um controlador PI seria:

$$u(kh) = P(kh) + I(kh). \quad (53)$$

Enquanto a ação de um controlador PID seria dada pela seguinte equação:

$$u(kh) = P(kh) + I(kh) + D(kh). \quad (54)$$

3.2 CONTROLE PREDITIVO BASEADO EM MODELO

Nesta seção são apresentados os fundamentos de Controle Preditivo e, também, sua estrutura matemática. Esses conceitos dão suporte a sua aplicação no controle da válvula de Recirculação de Gases de Escape.

3.2.1 Fundamentos de Controle Preditivo

Controladores Preditivos começaram a ter seu uso consolidado em processos industriais no final da década de 1970, com a introdução de dois algoritmos de controle que utilizavam modelos para prever o comportamento futuro de processos e, com isto, obter o sinal de controle ideal para se aplicar ao sistema (QIN; BADGWELL, 2003).

O primeiro, de Richalet *et al.* (1978), ficou conhecido com IDCOM, uma abreviação de *Identification-Command*, ou Identificação e Comando, em português. Este algoritmo utiliza como modelo, para prever as saídas futuras, uma resposta do sistema a uma entrada do tipo impulso. Para, então, utilizar uma norma quadrática para calcular o valor do sinal de controle a ser aplicado. Além disto, este algoritmo já incluía a possibilidade de incluir restrições em sua formulação.

Já a segunda técnica, o Controle por Matriz Dinâmica, ou *Dynamic Matrix Control* (DMC), foi apresentada por Cutler e Ramaker (1979). O DMC tinha por característica principal a determinação das saídas futuras do sistema por meio de um modelo baseado na resposta do sistema a uma entrada do tipo degrau. Esta característica, que o diferencia do IDCOM, também o torna mais aplicado na prática, vez que uma entrada do tipo degrau é mais facilmente reproduzível do que uma do tipo impulso.

A partir de então, os Controladores Preditivos Baseados em Modelo, em inglês chamado de *Model Predictive Control* (MPC), foram popularizados na

indústria, tendo aplicações registradas no processamento de papel e celulose, refinarias, indústria química, entre outros. Também foram publicados milhares de artigos e pelo menos cinco livros abordando as técnicas de MPC (QIN; BADGWELL, 2003; MAYNE, 2014).

Um acentuado progresso foi dado com a formulação do Controlador Preditivo Generalizado, do inglês *Generalized Predictive Control* (GPC), por Clarke, Mohtadi e Tuffs (1987a, 1987b). Um MPC adaptativo que otimiza o sinal de controle minimizando o erro futuro utilizando uma norma quadrática. Este controlador foi desenvolvido como sendo uma extensão ao controlador de Variância Mínima Generalizada, ou *Generalized Minimum Variance* (GMV), de Clarke e Gawthrop (1975), que fazia a previsão para apenas uma amostra futura, baseando-se no tempo morto do sistema. Algumas características do GPC são:

- Pode ser utilizado em sistemas instáveis em malha aberta;
- É capaz de atuar em sistemas de fase não-mínima;
- Pode ser utilizado em sistemas com tempo morto desconhecido ou variável;
- Permite o uso de restrições quando combinado a uma técnica de programação quadrática;
- É capaz de controlar sistemas com múltiplas entradas e múltiplas saídas.

3.2.2 Controle Preditivo Generalizado

A definição matemática apresentada para o Controlador Preditivo Generalizado se baseia no trabalho original de Clarke, Mohtadi e Tuffs (1987a), e no livro de Åström e Wittenmark (2008).

O GPC é projetado com a finalidade de reduzir a esperança matemática da soma do erro quadrático médio da saída do sistema com uma ponderação do esforço de controle, por meio de um fator λ , como a seguir:

$$J(N_1, N_y, N_u) = E \left\{ \sum_{k=N_1}^{N_y} (y(t+k) - r(t+k))^2 + \sum_{k=1}^{N_u} \lambda \Delta u(t+k-1)^2 \right\}, \quad (55)$$

onde

$$\Delta = 1 - q^{-1}. \quad (56)$$

A definição do GPC possui ainda três valores para definir o intervalo de predição que será usado para o cálculo da lei de controle. O primeiro instante da previsão que será usado no cálculo, N_1 , é utilizado para evitar que cálculos desnecessários sejam feitos para respostas anteriores ao tempo morto do sistema, de símbolo d , uma vez que estes valores seriam nulos. O horizonte final de previsão N_y , e o horizonte de controle N_u , que limita a quantidade de mudanças no sinal de controle, sendo que após este o sinal assume valor constante, como mostrado na FIGURA 2.




FIGURA 2 - SINAIS DE REFERÊNCIA, CONTROLE E SAÍDA NO GPC
 FONTE: ADAPTADO DE CLARKE, MOHTADI E TUFFS (1987a)

Define-se, também, a estrutura do modelo que representa o sistema:

$$A(q^{-1})y(t) = B(q^{-1})u(t-d) + \frac{\xi(t)}{\Delta}, \quad (57)$$

esta estrutura propicia ao controlador uma característica incremental, que faz com que este possua automaticamente um integrador.

Para a definição das equações que realizam as predições j instantes a frente, é necessária a separação entre os valores anteriores e posteriores ao instante t , para isto estipula-se a seguinte identidade:

$$1 = A(q^{-1})F_j(q^{-1})\Delta + q^{-j}G_j(q^{-1}), \quad (58)$$

onde o grau do polinômio F_j é $j - 1$, e o grau de G_j é $na - 1$.

Multiplicando a equação (57) pela expressão $F_j\Delta q^j$, obtém-se:

$$F_jA(q^{-1})\Delta y(t + j) = F_jB\Delta u(t + j - d) + F_j\xi(t + j), \quad (59)$$

substituindo $F_j\Delta q^j$ por intermédio da identidade em (58),

$$y(t + j) = F_jB\Delta u(t + j - d) + G_jy(t) + F_j\xi(t + j). \quad (60)$$

Como o polinômio F_j é de grau $j - 1$, todos os termos de do ruído ξ estarão no futuro, e portanto não são conhecidos. Logo, a saída estimada no instante t para o instante j é definida como:

$$\hat{y}(t + j|t) = F_jB\Delta u(t + j - d) + G_jy(t). \quad (61)$$

Introduzindo outra identidade:

$$F_j(q^{-1})B(q^{-1}) = R_j(q^{-1}) + q^{-(j-d+1)}\bar{R}_j(q^{-1}) \quad (62)$$

onde o grau de R_j é igual a $j - d$, e o grau de \bar{R}_j é $na - 2$.

Realizando a substituição da identidade em (62) na equação (61), tem-se que:

$$\begin{aligned}\hat{y}(t+j|t) &= R_j(q^{-1})\Delta u(t+j-d) + R_j(q^{-1})\Delta u(t-1) + G_j y(t) \\ &= R_j(q^{-1})\Delta u(t+j-d) + \bar{y}_j(t),\end{aligned}\quad (63)$$

onde a resultante de $R_j(q^{-1})\Delta u(t-1)$, $\bar{y}_j(t)$, é um valor referente a saída que só depende de medições passadas. Estendendo ao longo do horizonte de previsão N_y as saídas serão:

$$\begin{aligned}y(t+1) &= R_1(q^{-1})\Delta u(t+1-d) + \bar{y}_1(t) + F_1 e(t+1) \\ y(t+2) &= R_2(q^{-1})\Delta u(t+2-d) + \bar{y}_2(t) + F_2 e(t+2) \\ &\vdots \\ y(t+N_y) &= R_{N_y}(q^{-1})\Delta u(t+1-d) + \bar{y}_{N_y}(t) + F_{N_y} e(t+N_y).\end{aligned}\quad (64)$$

O conjunto de equações em (64) pode ser transformado para uma notação matricial, resultando na seguinte igualdade:

$$\mathbf{y} = \mathbf{R}\Delta\mathbf{u} + \bar{\mathbf{y}} + \mathbf{e},\quad (65)$$

onde

$$\begin{aligned}\mathbf{y} &= \left(y(t+1) \dots y(t+N_y) \right)^T, \\ \Delta\mathbf{u} &= \left(\Delta u(t+1-d) \dots \Delta u(t+N_y) \right)^T, \\ \bar{\mathbf{y}} &= \left(\bar{y}_1(t) \dots \bar{y}_{N_y}(t) \right)^T, \\ \mathbf{e} &= \left(F_{N_y} e(t+1) \dots F_{N_y} e(t+N_y) \right)^T.\end{aligned}\quad (66)$$

Os elementos de R_j são os primeiros $j-d+1$ elementos da resposta ao impulso de $q^{-d}B/(A\Delta)$, o que é equivalente aos mesmos primeiros elementos da resposta ao degrau da função em malha aberta do sistema, $q^{-d}B/A$. Estes elementos são dispostos na matriz \mathbf{R} da seguinte forma:

$$\mathbf{R} = \begin{pmatrix} r_0 & 0 & \dots & 0 \\ r_1 & r_0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ r_{N_y-1} & r_{N_y-2} & \dots & r_0 \end{pmatrix}. \quad (67)$$

Agora organizando as referências futuras, $r(t)$, do sistema também na forma matricial, chega-se a:

$$\mathbf{r} = (r(t+1) \dots r(t+N_y))^T, \quad (68)$$

usualmente, como em diversas aplicações não se conhece os valores futuros da referência, utiliza-se a repetição de $r(t+1)$ para todo o horizonte N_y .

Com as formulações de (65), (66), (67) e (68), pode-se reescrever a função custo descrita na equação (55), sendo então:

$$\begin{aligned} J(1, N_y, N_u) &= E\{(\mathbf{y} - \mathbf{r})^T(\mathbf{y} - \mathbf{r}) + \lambda \Delta \mathbf{u}^T \Delta \mathbf{u}\} \\ &= (\mathbf{R} \Delta \mathbf{u} + \bar{\mathbf{y}} - \mathbf{r})^T (\mathbf{R} \Delta \mathbf{u} + \bar{\mathbf{y}} - \mathbf{r}) + \lambda \Delta \mathbf{u}^T \Delta \mathbf{u}. \end{aligned} \quad (69)$$

O menor valor para a função custo nesta expressão é dado por:

$$\Delta \mathbf{u} = (\mathbf{R}^T \mathbf{R} + \lambda \mathbf{I})^{-1} \mathbf{R}^T (\mathbf{r} - \bar{\mathbf{y}}), \quad (70)$$

onde \mathbf{I} é a matriz identidade.

Para o controlador GPC tornar-se adaptativo, os polinômios $A(q^{-1})$ e $B(q^{-1})$ são calculados utilizando o Algoritmo de Mínimos Quadrados Recursivos, apresentado na seção 2.5 deste trabalho, a cada nova medição realizada no processo. Sendo, então, realizados todos os procedimentos matemáticos necessários para gerar a equação que determina a lei de controle apresentada na equação (70).

Dos valores de variação do sinal de controle contidos em $\Delta \mathbf{u}$, utiliza-se apenas o primeiro valor, referente ao instante t , para formar o novo valor de controle, como mostrado a seguir:

$$u(t) = u(t - 1) + \Delta u(t). \quad (71)$$

A parametrização dos horizontes de controle do GPC é realizada observando as características do processo a ser controlado. O valor de N_1 pode ser escolhido como o tempo morto do sistema, caso este seja desconhecido, é possível utilizar o valor 1 sem prejuízos à ação de controle. O valor de N_y deve ser escolhido como sendo maior que o grau do polinômio $B(q^{-1})$, porém, na prática, costuma se escolher um valor próximo ao tempo de subida da resposta ao degrau da planta. Enquanto o parâmetro N_u pode ter valores pequenos em sistemas simples, no entanto, em sistemas mais complexos, este deve ser igual ao número de polos instáveis ou mal amortecidos do processo.

4 APLICAÇÃO DE METAHEURÍSTICAS DE OTIMIZAÇÃO NA IDENTIFICAÇÃO E CONTROLE DE SISTEMAS

Para a otimização dos parâmetros dos controladores, bem como para a seleção da melhor estrutura para o modelo NARX, são utilizadas neste trabalho metaheurísticas de otimização. Neste capítulo estas técnicas são abordadas, sendo apresentado o Algoritmo Genético para a otimização de parâmetros, e a Programação de Expressão Gênica para a escolha de modelos.

4.1 INTRODUÇÃO

Metaheurísticas de otimização são técnicas guiadas de busca estocásticas que visam reduzir uma função custo. Estas técnicas são particularmente úteis quando a função que se deseja otimizar é não-linear, o que dificulta ou impede a aplicação de metodologias convencionais, como as baseadas na derivada das funções.

Estas técnicas de otimização buscam inspiração em fenômenos naturais para realizar sua tarefa. Como é o caso do algoritmo de Enxame de Partículas, em inglês *Particle Swarm Optimization* (PSO), que tem sua inspiração no comportamento de cardumes de peixes e na revoada de aves. E também do algoritmo de Colônia de Formigas, que tem por base a forma como as formigas deixam rastros de feromônios, o que as ajuda a encontrar alimento (KENNEDY; EBERHART, 1995; DORIGO; MANIEZZO; COLORNI, 1996).

Os Algoritmos Genéticos, ou GA, do inglês *Genetic Algorithm*, que emulam o princípio Darwiniano da evolução de sistemas biológicos, também possuem a finalidade de resolver problemas de otimização. Nestes algoritmos parâmetros são codificadas em *strings* que representam um indivíduo em uma população. A cada geração são selecionados indivíduos, conforme sua aptidão, para realizar cruzamento e dar origem à próxima geração, sendo que estes podem estar sujeito a mutações (RIBEIRO FILHO; TRELEAVEN; ALIPPI, 1994).

Em particular, a inspiração dos Algoritmos Genéticos não se limitou a dar origem a um algoritmo otimizador de parâmetros em problemas mono-objetivos, tendo sido estendido também a problemas de otimização de programas, ou estruturas, e de problemas multiobjetivos. A exemplo da Programação Genética, ou, do inglês, *Genetic Programming* (GP), e da Programação de Expressão Gênica, em inglês *Gene Expression Programming* (GEP), que tem por finalidade a otimização de programas. Ou o algoritmo genético multiobjetivo NSGA-II, em inglês *Non-dominated Sorting Genetic Algorithm – II*, que utiliza os conceitos de Pareto para realizar a otimização de problemas com mais de um objetivo (KOZA, 1992; FERREIRA, 2001; DEB *et al*, 2002).

O GA pode ser usado como ferramenta alternativa na escolha de parâmetros de controladores PID, razão pela qual este é parte integrante deste trabalho, servindo como opção ao lugar das raízes e aos métodos baseados em regras, como Ziegler-Nichols. Isto pode ser feito programando o algoritmo para buscar parâmetros do controlador que reduzam algum critério de erro da resposta em relação a uma dada referência. Este critério pode ser, por exemplo, a Integral do Erro Absoluto, do inglês *Integral of Absolut Value Error* (IAE), o qual tem sua formulação apresentada na seção 6.3 (MENG; SONG, 2007).

A Programação de Expressão Gênica foi introduzida por Ferreira (2001) com a finalidade de criar programas automaticamente. Esta se distingue do Algoritmo Genético pela forma como a população é representada, sendo composta por cromossomos que podem possuir vários genes. Cada um desses sequenciamentos genéticos é interpretado como uma fase de leitura aberta, do inglês *Open Reading Frame* (ORF), que pode representar uma expressão não-linear, por exemplo.

Em Ferreira (2006) são mostrados diversos exemplos de aplicação Programação de Expressão Gênica na solução de problemas práticos, como: regressão linear simbólica, problemas de classificação e síntese de expressões lógicas.

Bai, Zhu e Jiang (2007) apresentaram uma forma de utilizar a GEP na otimização da seleção de modelos não-lineares da classe NARX, que serão utilizados neste trabalho para representar a Válvula de Recirculação de Gases. Para tal, foram propostas mudanças nos operadores genéticos a fim de adequá-las ao trabalho com esses modelos matemáticos.

4.2 ALGORITMO GENÉTICO

Nesta seção é apresentada a formulação do Algoritmo Genético básico, com base no trabalho de Ribeiro Filho, Treleaven e Alippi (1994).

Como o Algoritmo Genético é baseado na evolução de sistemas biológicos, seu funcionamento ocorre por meio de operações genéticas que acontecem em cromossomos ao longo de gerações, que são as iterações do algoritmo. Um fluxograma deste sequenciamento é exibido na FIGURA 3.

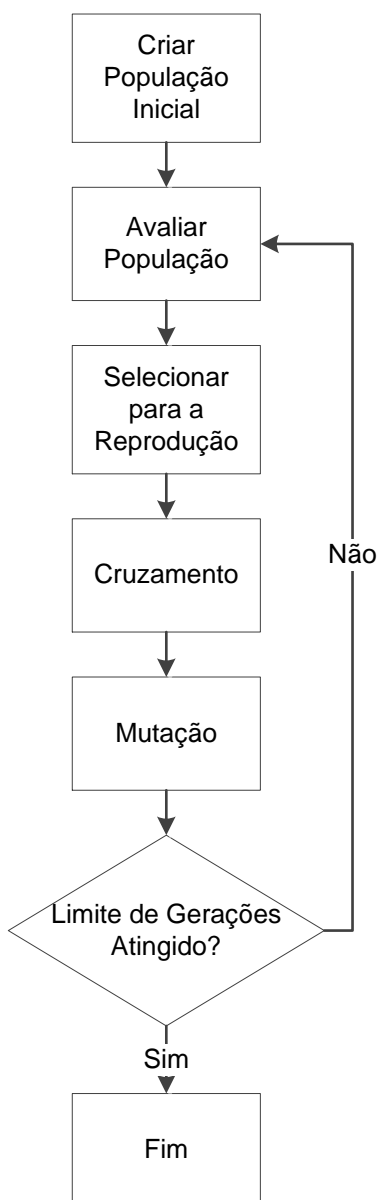


FIGURA 3 - FLUXOGRAMA DO ALGORITMO GENÉTICO




FIGURA 5 - MUTAÇÃO NO ALGORITMO GENÉTICO
 FONTE: BASEADO EM RIBEIRO FILHO, TRELEAVEN E ALIPPI (1994)

Para garantir a evolução do algoritmo sem que haja nenhum retrocesso, uma estratégia elitista pode ser adotada. Esta estratégia consiste em substituir o indivíduo que obteve a pior avaliação na geração atual pelo que obteve o melhor desempenho na geração anterior.

4.3 PROGRAMAÇÃO DE EXPRESSÃO GÊNICA

O Algoritmo de Expressão Gênica apresentado neste trabalho é embasado no algoritmo original, abrangido em Ferreira (2001). Além deste, também se utilizou do trabalho de Bai, Zhu e Jiang (2007), que criou ferramentas específicas para que a GEP fosse capaz de realizar a otimização de modelos NARX.

A GEP consiste na modificação de uma população de cromossomos por operadores genéticos ao longo de gerações. Sendo que estes operadores podem ser divididos em três classes principais: de mutação, transposição e recombinação. Um fluxograma que representa esta sequência é posto na FIGURA 6.

A subseção 4.3.1 traz as explicações acerca da representação e interpretação dos cromossomos na GEP, que é a principal diferença deste algoritmo em relação à programação genética. Em outro viés, as subseções que vão de 4.3.2 até 4.3.5 explicam e exemplificam o funcionamento dos operadores genéticos que constituem a GEP. Operadores estes que são os responsáveis pela evolução do algoritmo e consequente otimização dos parâmetros.

O método de poda e a função objetivo, que são mais ligadas ao problema de otimização do modelo NARX que a própria GEP, são mostrados na subseção 4.3.6.

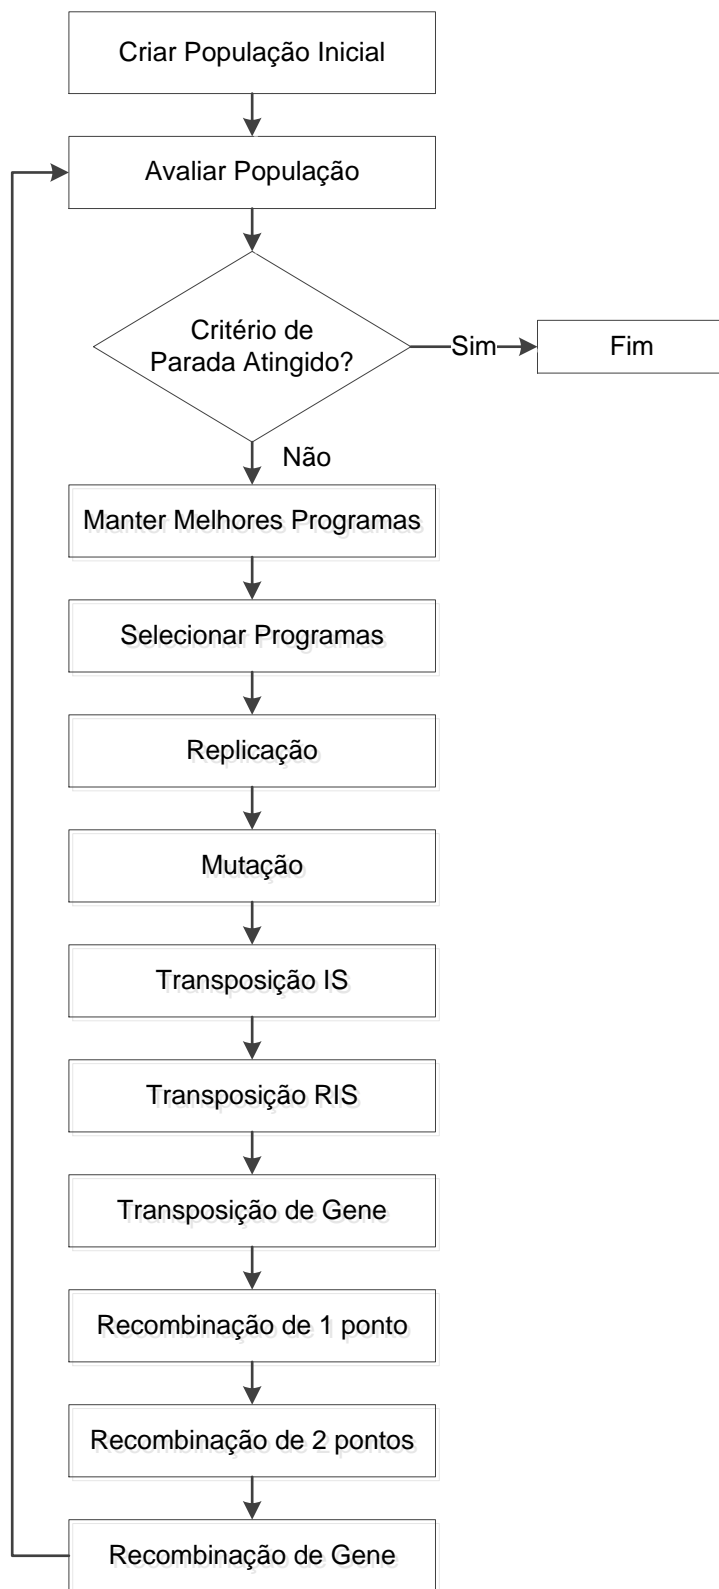


FIGURA 6 - FLUXOGRAMA DA GEP
FONTE: BASEADO EM FERREIRA (2001)

4.3.1 Interpretação dos Cromossomos na GEP

A organização das informações contidas em um cromossomo na Programação de Expressão Gênica se baseia no sequenciamento do código de um gene, chamado de ORF. Onde cada gene é composto uma cabeça e uma calda, onde a cabeça pode conter funções e valores terminais, enquanto os elementos da calda podem conter apenas valores terminais.

Para a GEP, o tamanho da cabeça do sequenciamento genético é um parâmetro a ser escolhido, h , e o tamanho da calda, t , é proporcional ao número máximo de ramificações, n , permitidos pelos elementos da calda:

$$t = h(n - 1) + 1. \quad (72)$$

A interpretação dos cromossomos é realizada por intermédio das expressões na linguagem Karva, desenvolvida por Ferreira (2001). Porém, estas ORFs também podem ser representadas na forma de um diagrama, ou uma árvore de expressão, em inglês *Expression Tree* (ET).

Tomando como base um modelo NARX, as funções presentes na cabeça dos genes seriam os operadores não-lineares, mais especificamente a multiplicação, enquanto os terminais seriam os regressores da entrada e saída do sistema. Como o número máximo de ramificações da multiplicação é $n = 2$, e adotando um comprimento de cabeça do sequenciamento genético $h = 3$, ter-se-ia um cromossomo de tamanho 7.

Na FIGURA 7 é mostrado um exemplo de um gene que poderia representar um modelo NARX, bem como sua árvore de expressão e a expressão algébrica resultante. A tradução da expressão é feita realizando-se a leitura sequencial das informações contidas no gene, ou seja, caso a primeira posição do gene contenha uma função com duas ramificações, os próximos dois valores neste gene representarão os novos nós.




FIGURA 7 - ÁRVORE DE EXPRESSÃO DE UM GENE
 FONTE: BASEADO EM FERREIRA (2001)

É importante notar que como a presença de valores terminais na cabeça do gene é possível, o tamanho das expressões resultantes é variável, e nem toda a informação contida no gene é repassada. Portanto é possível haver dois genes distintos que resultem na mesma ET.

Esta formação a primeira vista não aparenta possuir nenhuma vantagem. Porém, como os nós finais das ETs sempre vão conter um valor terminal, e jamais uma função, as expressões geradas nos cromossomos da GEP são sempre válidas. O que evita a necessidade de uma função supervisória que corrija possíveis valores mal colocados.

Os cromossomos da GEP podem ser ainda compostos de mais de um gene, que são relacionados por meio de uma função de ligamento. A FIGURA 8 trás um exemplo de cromossomo com dois genes que poderia ser utilizado para formar um modelo NARX.

A leitura de cromossomos com múltiplos genes é feita de maneira similar a de apenas um, e a ligação pode ser interpretada como um nó acima das ETs dos genes que as relaciona. A principal vantagem no uso de diversos genes esta na possibilidade dos operadores genéticos transportarem informações completas de um cromossomo para outro, e não apenas fragmentos.

No caso da GEP para a otimização de modelos NARX de Bai, Zhu e Jiang (2007), a função de ligamento adotada é a adição, enquanto os genes, individualmente, representam as unidades não-lineares do modelo. Os autores incluíram nesta aplicação a possibilidade de um número variável de genes para o

cromossomo, variando de apenas um cromossomo para até um determinado valor limite.

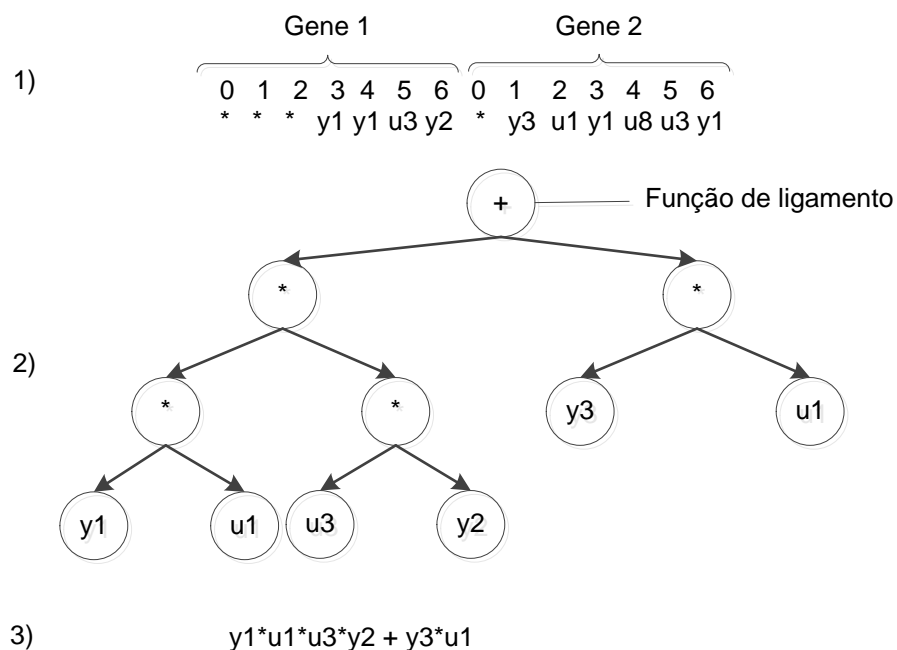


FIGURA 8 - ÁRVORE DE EXPRESSÃO DE UM CROMOSSOMO COM DOIS GENES
 FONTE: BASEADO EM FERREIRA (2001)

4.3.2 Seleção e Replicação

As fases de seleção e replicação na GEP, apesar de vitais para seu funcionamento, consistem apenas na escolha dos melhores cromossomos e sua clonagem. Para garantir a seleção dos melhores indivíduos da população para a próxima geração, o método da roleta é aplicado (FERREIRA, 2001).

4.3.3 Mutação

A mutação pode ocorrer de duas formas distintas na GEP de Bai, Zhu e Jiang (2007). Dentro do gene, ela pode alterar o valor de um elemento da cabeça

para qualquer valor possível do conjunto de funções e valores terminais. Quando a mutação ocorre na calda, esta pode assumir apenas valores terminais.

Outra mutação possível ao cromossomo é a probabilidade da adição de um novo gene, gerado aleatoriamente. Desde que o cromossomo não tenha atingido o seu tamanho máximo.

A FIGURA 9 trás um exemplo destes dois tipos de mutação. Onde a posição 1 do gene 1 sofreu a mutação para um valor terminal, a posição 4 do gene 2 foi modificada, e o cromossomo recebeu a adição de um terceiro gene totalmente novo.




FIGURA 9 - TIPOS DE MUTAÇÃO DA GEP
 FONTE: BASEADO EM BAI, ZHU E JIANG (2007)

4.3.4 Transposição e Inserção de Sequência

Existem três operadores de transposição na Programação de Expressão Gênica: a da sequência de elementos, do inglês *Inserestion Sequence (IS)*; a de inserção de elementos na raiz do cromossomo, *Root IS (RIS)*; e a transposição de gene.

A transposição IS seleciona um trecho de informação de qualquer posição do cromossomo e o reinsere em outra posição, exceto a raiz dos cromossomos. Para que este operador gere um novo cromossomo válido, basta que a posição no gene destino seja anterior à posição do gene de origem. Como no exemplo da FIGURA 10, no qual os valores contidos entre as posições 4 e 6 do gene 2 foram recolocadas nas posições 2 e 3 do gene 3. Nota-se que esta função tem grande impacto na informação contida no gene, uma vez que exclui os valores anteriores da

posição para qual o trecho foi transplantado. Também é importante notar que quanto mais próximo da raiz do gene, maior a modificação realizada.




FIGURA 10 - EXEMPLO DE TRANSPOSIÇÃO IS
 FONTE: BASEADO EM FERREIRA (2001)

O operador RIS transplanta uma informação adquirida de um trecho da cabeça de um gene para o seu nó raiz. Para a escolha do trecho, que tem tamanho predeterminado, um ponto aleatório da cabeça é escolhido, e esta é então varrida até que se encontre uma função. O ponto onde a função é encontrada torna-se o ponto inicial do trecho, caso não se ache função, o operador não faz nada.

A FIGURA 11 trás um exemplo de uma transposição RIS de tamanho três para um cromossomo de um único gene, o qual possuía tamanho da cabeça $h = 5$. Sendo sorteada a posição um, a varredura foi realizada até encontrar a função na posição 2, logo o trecho de 2 a 4 é reinserido entre as posições 0 e 2.




FIGURA 11 - TRANSPOSIÇÃO RIS
 FONTE: BASEADO EM FERREIRA (2001)

O operador RIS provoca uma mudança estrutural profunda na informação contida no gene. Pois toda a informação anterior é excluída, e a nova estrutura do

gene será baseada na função que estava na posição de início do trecho transplantado.

A transposição de genes consiste em trocar a posição de um gene selecionado aleatoriamente para o início do cromossomo. Esta forma provoca mudanças na informação que este representa em diversas aplicações, porém isto não acontece no uso da GEP para a seleção de modelos NARX. Visto que a função que faz a ligação entre os genes nesta aplicação é a adição, a ordem dos genes no cromossomo não tem influência alguma. Portanto, nesta versão da GEP a transposição de genes não é realizada.

4.3.5 Recombinação

Operadores de recombinação simulam a reprodução em sistemas biológicos, assim, ela é realizada por meio da troca de informação entre dois cromossomos pais, que geram dois cromossomos filhos. Na GEP existem dois tipos principais de recombinação: a recombinação de trechos dos cromossomos e a recombinação de genes inteiros entre cromossomos.

Como a quantidade de genes nos cromossomos da aplicação em identificação de modelos NARX é variável, apenas a recombinação de genes inteiros é utilizada. E esta é realizada de duas formas: a recombinação em um ponto e a recombinação em dois pontos.

A recombinação de genes em um ponto é feita selecionando uma posição aleatória para cada um dos dois genes, e, depois, trocando as informações posteriores a esta referência entre os genes, como mostrado na FIGURA 12.

P1)	Gene11 Gene12 Gene13 Gene14
P2)	Gene21 Gene22 Gene23
F1)	Gene11 Gene23
F2)	Gene21 Gene22 Gene12 Gene13 Gene14

FIGURA 12 - RECOMBINAÇÃO DE GENES EM UM PONTO
 FONTE: BAI, ZHU E JIANG (2007)

A operação de recombinação em um ponto tem que obedecer às seguintes restrições:

$$\begin{aligned}
 i_1 + N_{g2} - i_2 &\leq N_{g \max} \\
 i_2 + N_{g1} - i_1 &\leq N_{g \max} , \\
 1 \leq i_1 < N_{g1}, \quad 1 \leq i_2 < N_{g2}
 \end{aligned}
 \tag{73}$$

onde N_{g1} e N_{g2} são a quantidade de genes nos cromossomos pais, $N_{g \max}$ é o número máximo de genes em um cromossomo, enquanto i_1 e i_2 são as posições sorteadas nos cromossomos pais.

A recombinação em dois pontos seleciona um trecho de um cromossomo que será trocado com outro trecho de outro cromossomo, para isso é necessária a seleção de dois intervalos. Um exemplo do uso deste operador é exibido na FIGURA 13.

P1)	Gene11 Gene12 Gene13 Gene14
P2)	Gene21 Gene22 Gene23 Gene 24 Gene 25
F1)	Gene11 Gene23 Gene24 Gene13 Gene14
F2)	Gene21 Gene22 Gene12 Gene25

FIGURA 13 - RECOMBINAÇÃO DE GENES EM DOIS PONTOS
 FONTE: BAI, ZHU E JIANG (2007)

Esta recombinação também está sujeita a restrições, sendo elas:

$$\begin{aligned}
 i_{12} - i_{11} + N_{g2} - (i_{22} - i_{21}) &\leq N_{g \max} \\
 i_{22} - i_{21} + N_{g1} - (i_{12} - i_{11}) &\leq N_{g \max} , \\
 1 \leq i_{11} < i_{12} < N_{g1}, \quad 1 \leq i_{21} < i_{22} < N_{g2}
 \end{aligned}
 \tag{74}$$

onde i_{11} e i_{12} delimitam o trecho que será recombinado do primeiro cromossomo pai, enquanto i_{21} e i_{22} delimitam o do segundo.

4.3.6 Método de Poda e Função Objetivo

Na identificação de modelos NARX, a Programação de Expressão Gênica fica a cargo de selecionar a estrutura mais adequada. Porém, esta técnica não é capaz de realizar ajustes finos nas constantes do modelo. Nesta função, o algoritmo dos Mínimos Quadrados, apresentado na seção 2.4, é utilizado para complementar a técnica.

Para o uso do RLS como método de estimação de parâmetros, Bai, Zhu e Jiang (2007) recomendam que primeiro se elimine os genes que geram expressões repetidas no cromossomo. E, posteriormente, aplique-se um método de poda.

O método em questão consiste em avaliar o modelo com todos os regressores M , além de modelos M_i auxiliares que excluem o i ésimo regressor, utilizando-se a média do erro quadrático, o *Mean Squared Error* (MSE).

$$MSE(M) = \sum_{t=1}^N \frac{(y(k) - \hat{y}(k))^2}{N}, \quad (75)$$

onde $y(k)$ é a saída real do sistema, $\hat{y}(k)$ é a saída estimada e N o número de amostras.

Então calcula-se a razão de redução de erro, ERR_i , de cada regressor, como a seguir:

$$ERR_i = \frac{MSE(M_i) - MSE(M)}{\sum_{k=1}^N y^2(k)}. \quad (76)$$

Caso o valor de ERR_i de um regressor seja inferior a certo limiar, este é cortado do modelo.

Bai, Zhu e Jiang (2007) propõem uma função custo, f , que penaliza o modelo de acordo com o número de termos p , o grau de não-linearidade l , e os maiores valores de atraso na entrada e na saída do sistema, n_u e n_y . Sendo a definição da função igual:

$$f = Fr^n, \quad (77)$$

onde r é um coeficiente entre zero e um, e $n = (p + l + n_u + n_y)/4$. Enquanto F é uma função do erro residual, como mostrado a seguir:

$$F = \frac{1}{1 + J},$$
$$J = \sqrt{\frac{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}{N}}. \quad (78)$$

5 DESCRIÇÃO DO ESTUDO DE CASO

Este capítulo traz a apresentação do estudo de caso que será alvo das técnicas de identificação e controle de sistema anteriormente apresentadas, a Válvula de Recirculação de Escapes, que é introduzida na seção 5.1. Enquanto na seção 5.2 é apresentada as características que realizaram a interface entre o sistema físico e a parte computacional.

5.1 VÁLVULA DE RECIRULAÇÃO DE GASES DE ESCAPE

Motores a Diesel oferecem maior potência, menor consumo de combustível e menor emissão de Dióxido de Carbono quando comparados a motores a gasolina, por isto costumam ser usado em veículos para tarefas pesadas. Porém, o ciclo Diesel traz como desvantagens uma grande produção de Óxidos de Nitrogênio (NO_x) e vasta emissão de partículas. Diversas mudanças foram realizadas nos motores e nos sistemas de injeção e de escape para reduzir a quantidade emitida desses poluentes (TSOLAKIS; MEGARITIS; WYSZYNSKI, 2003).

Um dos métodos para atingir a redução dos NO_x é a Recirculação dos Gases de Escape, seu uso teve início nos anos 1970, e é capaz de reduzir as taxas de emissão entre 25 e 50%. A recirculação é realizada com a inserção de uma válvula, a Válvula de Recirculação de Gases de Escape (RGE), ligando o sistema de escape à admissão dos motores a Diesel (MUNCRIEF *et al.*, 2008; TSOLAKIS; MEGARITIS; WYSZYNSKI, 2003).

A ligação permite passagem de parte dos gases de escape para a admissão do motor, tomando proveito da maior pressão que este possui em relação à tomada de ar, como ilustrado na FIGURA 14. Esses gases, inertes na combustão, substituem parte do Oxigênio no momento da combustão, o que provoca a diminuição da temperatura em que a explosão ocorre, o que acarreta na redução dos NO_x . O volume de gases de escape recirculados está diretamente ligado ao fluxo de gases sendo expelido, portanto um aumento na pressão do gás de escape acarretaria em um volume recirculado maior, e, logo, numa queda abrupta da

proporção de Óxigênio. Para garantir níveis adequados de readmissão, a abertura da válvula de RGE é controlável (MUNCRIEF *et al.*, 2008; BUCKLAND; COOK, 2005; GARCÍA-NIETO *et al.*, 2008).




FIGURA 14 - ESQUEMÁTICO DA READMISSÃO DE GASES ESCAPE
 FONTE: BASEADO EM MUNCRIEF *ET AL.* (2008)

Como a válvula é um sistema eletromecânico que trabalha com gases em alta temperatura e sofre com a contrapressão variável do sistema de escape, desgastes com sua operação são esperados. Assim, vide sua importância, técnicas de controle eficientes devem ser aplicadas a fim de manter sua boa funcionalidade.

A FIGURA 15 traz uma ilustração dos elementos que compõem a válvula de RGE: um motor de corrente contínua, responsável pela movimentação das engrenagens; as engrenagens, que transformam o movimento rotacional do motor na abertura, ou fechamento, linear da válvula; um sensor de efeito Hall, responsável por informar a posição; e a válvula em si, que libera, de acordo com sua abertura, níveis diferentes de fluxo de gás vindos do escape (COELHO; KLEIN, 2009).

O motor de corrente contínua, responsável pela movimentação do trem de engrenagens que regula a abertura de válvulas, é acionado por Modulação de Largura de Pulso, do inglês *Pulse Width Modulation (PWM)*, a uma tensão de 12 Volts. As informações providas pelo sensor de posição possuem uma faixa de 5 Volts e as medições são realizadas a cada 100 milissegundos. O sistema que realiza estas operações nos testes realizados neste trabalho é melhor descrito na seção 5.2.




FIGURA 15 - ELEMENTOS DA VÁLVULA
 FONTE: ADAPTADO DE COELHO E KLEIN (2009)

A fotografia de uma válvula de Recirculação de Gases de Escape é exibida na FIGURA 16. A válvula mostrada foi apenas utilizada em testes de laboratório, nunca tendo sido utilizada em um veículo pesado.



FIGURA 16 - FOTOGRAFIA DE UMA VÁLVULA DE RGE
 FONTE: O AUTOR (2016)

5.2 INTERFACE COM A VÁLVULA

Atentando ao fato de que a válvula de RGE é componente integrante de motores Diesel, e, por isto, depende da operação de todos os sistemas que o integram para funcionar, torna-se inviável avaliar sua dinâmica e testar técnicas de controle *in loco*. Pela necessidade de estudá-la isoladamente, criou-se uma interface de acionamento e monitoramento específica para a válvula.

A interface necessária para a realização da leitura do sensor de posição da válvula e acionamento do motor de corrente contínua é composta, principalmente, por dois elementos. O primeiro é um software, implementado na plataforma LabVIEW, responsável pelos cálculos das rotinas de controle, armazenagem dos dados coletados e troca de informação, via comunicação serial, com o segundo elemento, o circuito microcontrolado. Esse circuito, por sua vez, recebe do software ordens de leitura da posição da válvula, na qual devolve esta informação ao computador, ou de acionamento da válvula via sinal PWM. Um esquemático dessa troca de sinais é exibido na FIGURA 17.

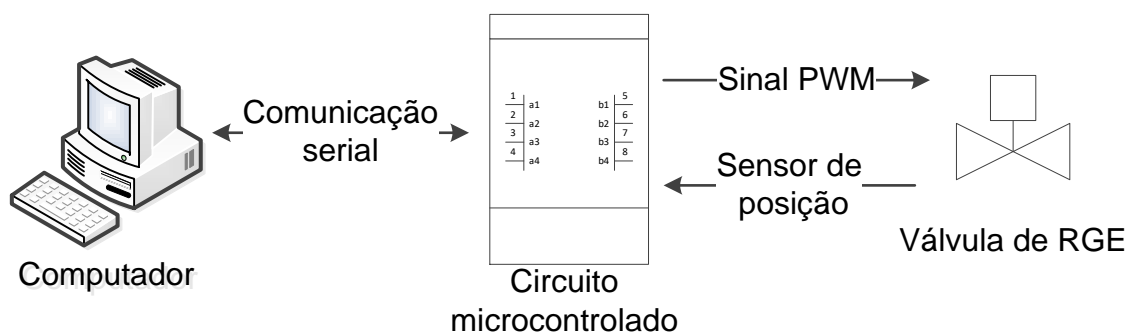


FIGURA 17 - ESQUEMÁTICO DA TROCA DE SINAIS
 FONTE: O AUTOR (2016)

O circuito microcontrolado se trata de uma plataforma compatível com a do sistema ARDUINO®, porém dotado de um microcontrolador PIC32MX320F128H. Este dispositivo é capaz de operar em 80 MHz, possui 16 canais de conversão analógica-digital com resolução de 10 bits, além de 5 saídas PWM (MICROCHIP, 2011).

A saída PWM do dispositivo utilizada para o acionamento da válvula de RGE foi configurada para operar a 4,88 KHz com uma resolução de 10 bits. Este sinal é

enviado para um circuito de ponte-H, o VNH2SP30-E, alimentado por uma fonte 12 V. O referido circuito de acionamento tem capacidade para operar com até 41 V, 30 ampères e sinais de entrada com frequência de até 20 KHz (ST, 2013).

6 RESULTADOS

Neste capítulo são expostos os resultados obtidos neste trabalho. Sendo que primeiramente são exibidos os dados de aquisição do sistema. Posteriormente dos modelos obtidos, e, por último, os resultados obtidos nos sistemas de controle.

6.1 DADOS DA AQUISIÇÃO DO SISTEMA

Para estudar o a dinâmica das válvulas de Recirculação de Gases de Escape, é preciso realizar um levantamento de seu comportamento quando exposta a diferentes estímulos. Para tal, escolheu-se um sinal, mostrado na FIGURA 18, que contém uma sequência degraus de amplitudes que variam de 0 a 1, onde 0 representa a válvula completamente fechada e 1 totalmente aberta, e durações que variam de uma amostra até 50 amostras.




FIGURA 18 - SINAL DE ESTÍMULO PARA AS AQUISIÇÕES
FONTE: O AUTOR (2016)

Os valores de amplitude e duração destes degraus foram selecionados através de um gerador de números pseudo-aleatórios, que é um algoritmo que busca gerar sequências numéricas aproximadamente independentes.

Este sinal engloba diversos pontos de operação ao longo do curso da abertura da válvula, além de possuir durações diferentes, o que permite que a resposta a este estímulo contenha informação relevante sobre a dinâmica do sistema.

Duas válvulas de RGE são submetidas a esta sequência de degraus, uma utilizada apenas em testes de bancada, que nunca foi instalada em um veículo pesado, e outra que teve largo uso em veículo. Tendo o conhecimento de que estas válvulas são instáveis em malha aberta, as aquisições são realizadas em malha fechada, com um controlador proporcional de ganho unitário.

A FIGURA 19 ilustra a resposta do sistema a entrada escolhida, onde nota-se diversos picos nas mudanças de referência, porém pouco comportamento oscilatório.




FIGURA 19 - AQUISIÇÃO DA VÁLVULA DE TESTES EM BANCADA
FONTE: O AUTOR (2016)

Já na FIGURA 20 é exibida a resposta da válvula de RGE usada ao mesmo sinal de entrada. É possível verificar grande mudança no comportamento nos valores transitórios, onde a válvula usada possui um comportamento extremamente oscilatório, que não era presente na válvula nova. Isto ocorre pela presença de folgas no trem de engrenagens que move o cursor da válvula.

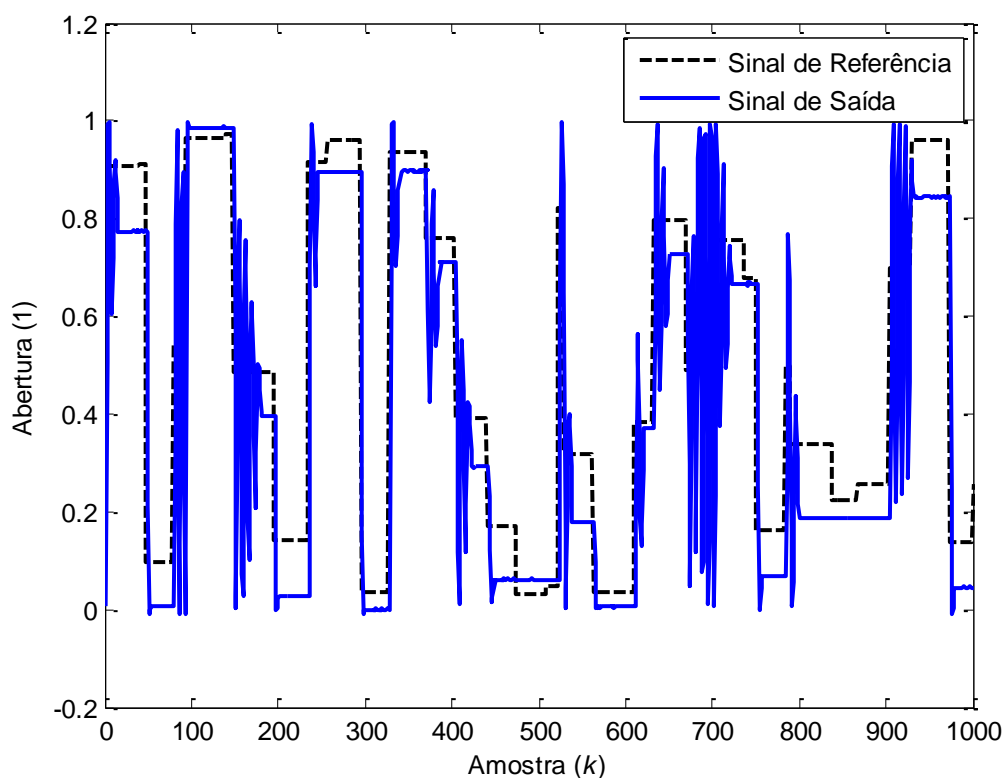


FIGURA 20 - AQUISIÇÃO DA VÁLVULA UTILIZADA EM VEÍCULOS PESADOS
 FONTE: O AUTOR (2016)

6.2 MODELOS OBTIDOS PARA AS VÁLVULAS DE RGE

A obtenção dos modelos foi realizada por meio da Programação de Expressão Gênica, detalhada na seção 4.3, utilizando 70% dos dados coletados, enquanto os outros 30% dos dados são utilizados para a validação. Foram obtidos quatro modelos diferentes, sendo três para a válvula com desgaste apenas em testes de bancada, e um para a válvula usada em veículo pesado.

Na válvula de testes foram utilizadas três programações da GEP, a fim de verificar qual obteria o melhor desempenho. Sendo a primeira configurada para

encontrar um modelo ARX reduzindo-se o erro quadrático, a partir daqui chamado de GEP1. O segundo, o GEP2, utilizando o MSE como critério para a otimização de um modelo NARX. Enquanto o GEP3, o único que também foi aplicado a válvula usada, busca o melhor modelo NARX utilizando o critério proposto pelo artigo de Bai, Zhu e Jiang (2007).

O critério de parada do algoritmo é de duas mil gerações, no entanto ele também é terminado caso não haja evolução nas últimas cem iterações. Os demais parâmetros utilizados nas três configurações da GEP estão dispostos na TABELA 2, e tem origem nos testes do trabalho de Bai, Zhu e Jiang (2007).

TABELA 2 - PARÂMETROS PARA AS CONFIGURAÇÕES DA GEP

Descrição	GEP1	GEP2	GEP3
Conjunto de Funções	{+}	{*}	{*}
Conjunto de Terminais	$\{y(k-1) \dots y(k-10), u(k-1) \dots u(k-10)\}$		
Tamanho da População	50		
Probabilidade de mutação	0,1		
Recombinação em Um Ponto	0,2		
Recombinação em Dois Pontos	0,5		
Transposição IS	0,1 e tamanho de 1 a 3		
Transposição RIS	0,1 e tamanho de 1 a 3		
Tamanho da Cabeça	20	8	
Número Máximo de Genes	1	20	
Número Máximo de Gerações	2000		
Número de Rodadas	30		
Coefficiente r	-	0,995	
Limiar da Poda	0,0001		

FONTE: O AUTOR (2016)

6.2.1 Modelos para a Válvula de Testes

Como para cada uma das três especificações do algoritmo são gerados 30 testes, um comparativo do desempenho final de cada um para o critério R^2 é relatado na TABELA 3. Na qual é possível observar que a GEP2 obteve os melhores valores para o fator R^2 . Isto é uma consequência da representação do modelo NARX sem penalização, que parametriza excessivamente o modelo, criando bons

resultados analíticos, porém contando com oito regressores, o dobro da GEP3 que possui penalização neste critério.

TABELA 3 - COMPARATIVO DO R^2 DAS GEPs PARA A VÁLVULA DE TESTES

	Mínimo	Médio	Máximo
GEP1	0,97760	0,99327	0,99419
GEP2	0,99339	0,99397	0,99559
GEP3	0,98779	0,99324	0,99389

FONTE: O AUTOR (2016)

A evolução das melhores rodadas de cada um dos três algoritmos na seleção de parâmetros para a válvula de testes é exibida na FIGURA 21. Aqui também é possível observar a maior evolução da GEP2, que é mais livre e consegue evoluir por mais gerações.

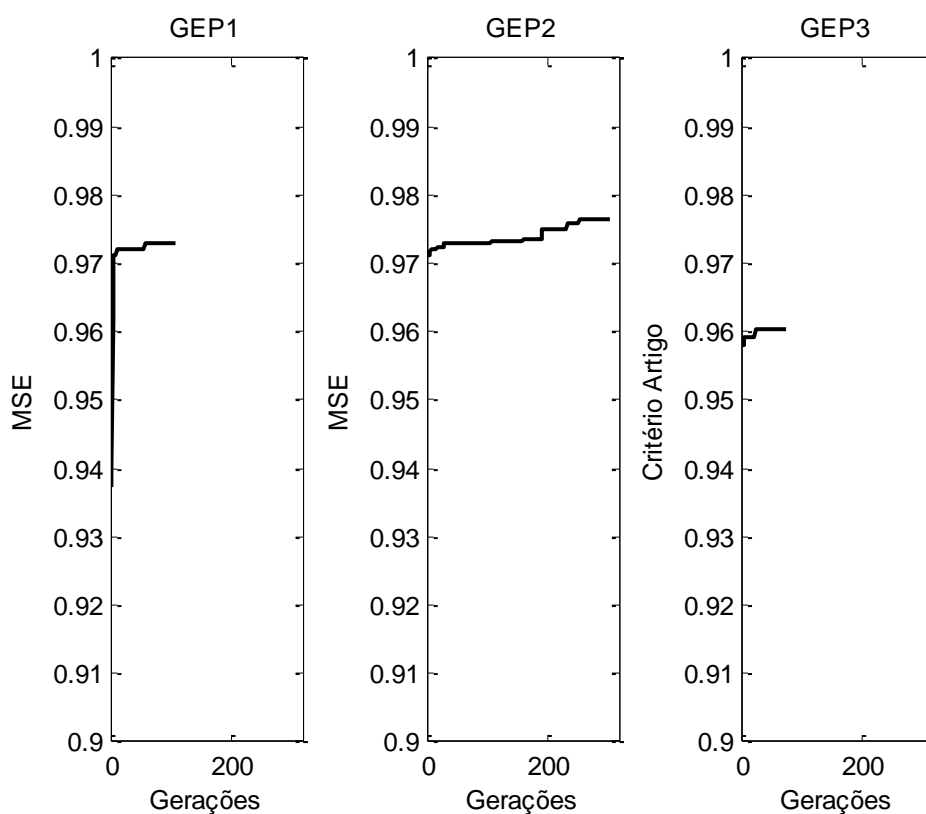


FIGURA 21 - EVOLUÇÃO DAS GEP PARA OS MODELOS DA VÁLVULA DE TESTES
FONTE: O AUTOR (2016)

Um comparativo entre os valores de R^2 para o treinamento e para a validação dos três algoritmos é mostrado na TABELA 4. Onde fica possível avaliar que a GEP2 também se destacou na validação dos modelos.

TABELA 4 - DESEMPENHO DOS MELHORES MODELOS PARA A VÁLVULA DE TESTES

		GEP1	GEP2	GEP3
R2	Treinamento	0,99419	0,99559	0,99339
	Validação	0,99495	0,99568	0,99423

FONTE: O AUTOR (2016)

A FIGURA 22 exibe a resposta do modelo obtido pela configuração GEP1 para esta válvula, representado na equação (79). Em uma inspeção visual, o modelo aparenta ser adequado a aplicação, porém quando se observa a equação, é possível enxergar um elevado número de parâmetros, junto com regressores com atraso muito grande.

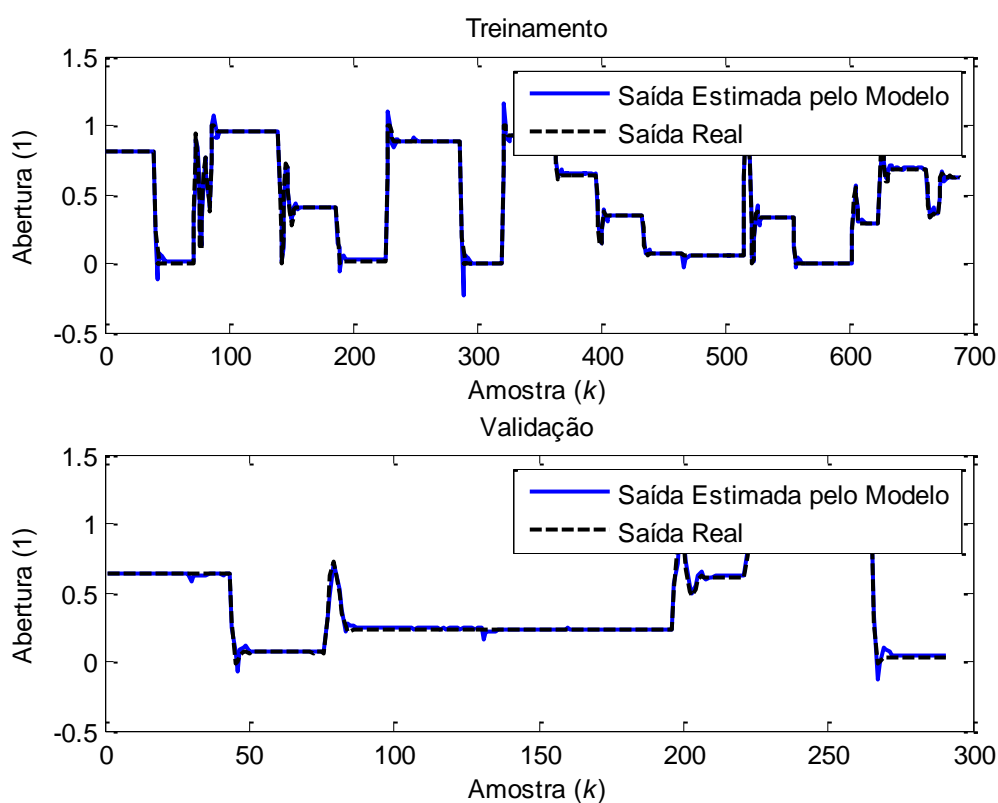


FIGURA 22 - RESPOSTAS DO MODELO DA GEP1 PARA A VÁLVULA DE TESTES
FONTE: O AUTOR (2016)

$$\begin{aligned}
 y(k) = & 0,741386u(k - 2) + 0,542440u(k - 3) - 0,112543u(k - 7) \\
 & + 1,347824 * y(k - 1) - 0,378398 * y(k - 3) \\
 & + 0,121079 * y(k - 5) + -0,097551 * y(k - 7)
 \end{aligned}
 \tag{79}$$

O modelo resultante para a GEP2, que apresentou os melhores valores para o critério R^2 , é apresentado na FIGURA 23. Observando a equação (80), que representa o modelo, é encontrada além de uma quantidade elevada de parâmetros, uma não-linearidade de grau 3, o que o torna um modelo complexo.

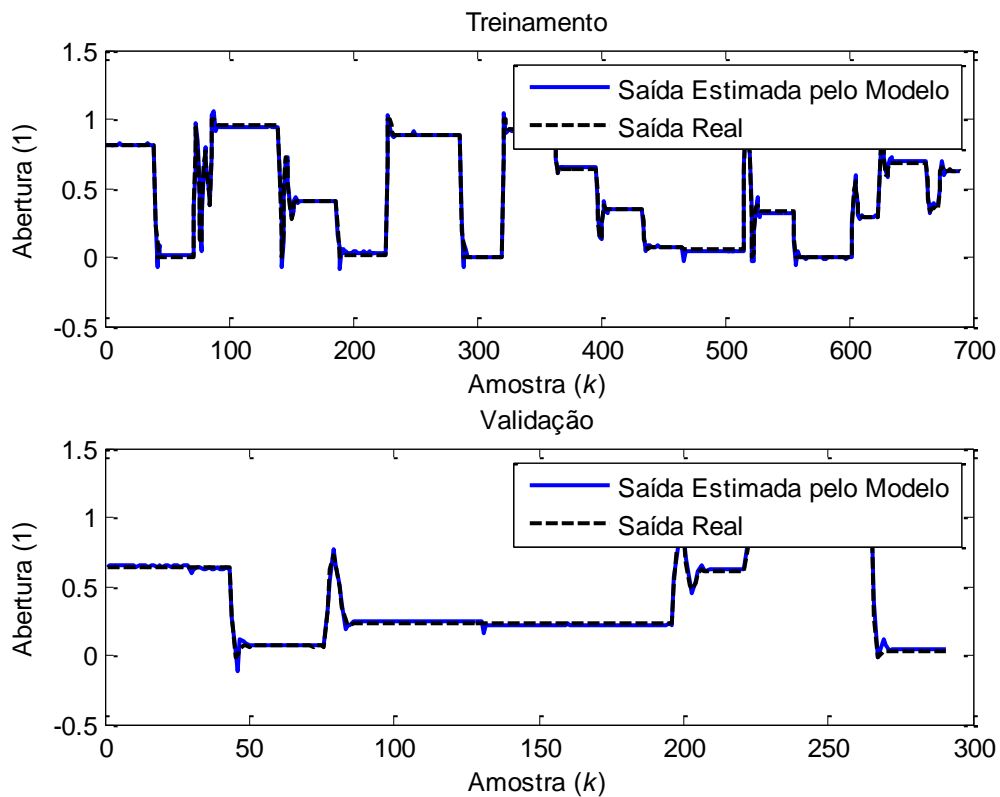


FIGURA 23 - RESPOSTAS DO MODELO DA GEP2 PAR A VÁLVULA DE TESTES
 FONTE: O AUTOR (2016)

$$\begin{aligned}
 y(k) = & 0,734194u(k - 2) - 0,523267u(k - 3) + 1,647291y(k - 1) \\
 & - 0,437355y(k - 2) - 0,210915y(k - 3) \\
 & + 0,082633u^2(k - 2) - 0,502064u^2(k - 3)u(k - 2) \\
 & - 0,011146
 \end{aligned}
 \tag{80}$$

Já o modelo encontrado pela GEP3, que também apresentou um valor aceitável no critério comparativo, mais de 99%, é representado pela equação (81). A

qual constitui um modelo ARX com apenas quatro parâmetros e um valor de atraso dos regressores baixo. As curvas obtidas para treinamento e validação deste modelo podem ser vistas na FIGURA 24.

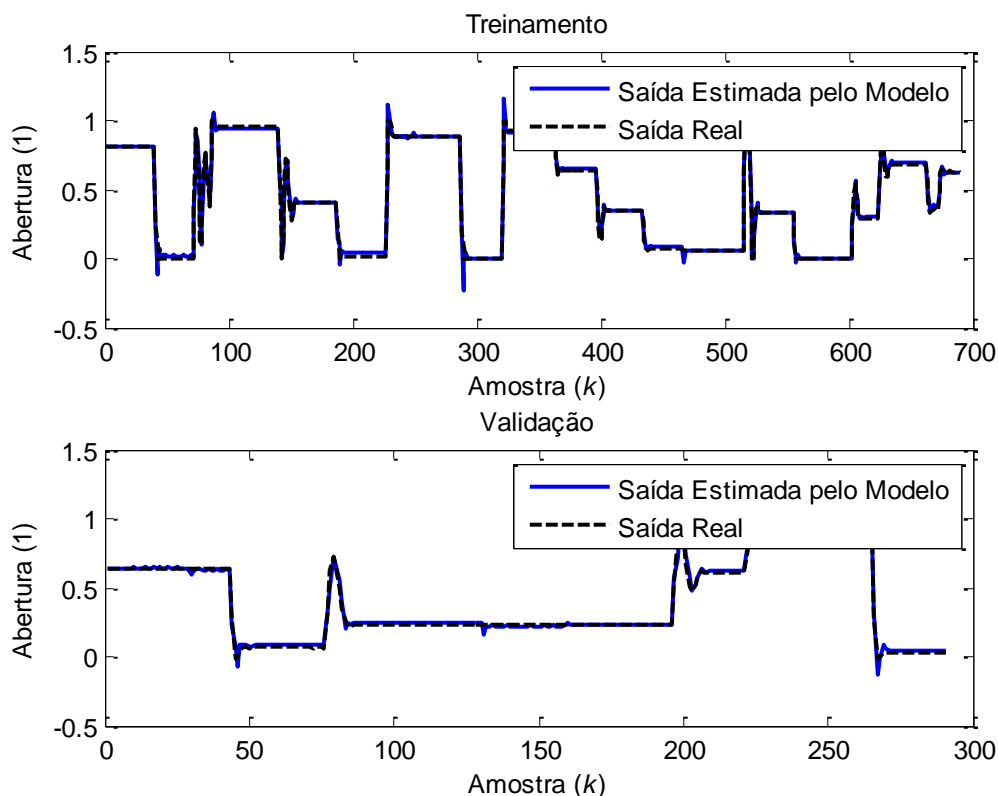


FIGURA 24 - RESULTADOS PARA O MODELO DA GEP3 DA VÁLVULA DE TESTES
 FONTE: O AUTOR (2016)

O modelo obtido para a GEP3 é linear, apesar de esta possibilitar a criação de modelos não-lineares, em razão das penalidades aplicadas ao grau de não-linearidade. Logo, o incremento na relação de proximidade entre o modelo e válvula real dado pelos regressores não-lineares testados pela GEP3 foi menor que o critério de penalização estabelecido.

$$y(k) = 0,759390u(k - 2) - 0,577068u(k - 3) + 1,362820y(k - 1) - 0,378153y(k - 3) \quad (81)$$

Buscando analisar a robustez do modelo, a TABELA 5 mostra a avaliação do Erro Quadrático Médio, do inglês *Mean Squared Error* (MSE), do período de validação para previsões até 10 passos à frente. Na referida tabela é possível

observar que o MSE aumenta mais de dez vezes apenas na troca da previsão de um para dois passos à frente, o que retira sua confiabilidade para previsões longas.

TABELA 5 - ANÁLISE DO MSE N PASSOS A FRENTE PARA A VÁLVULA DE TESTES

Passos à Frente	VÁLVULA DE TESTES		
	GEP1	GEP2	GEP3
1	0,001	0,001	0,002
2	0,010	0,012	0,010
3	0,051	0,071	0,056
4	0,137	0,216	0,162
5	0,283	0,491	0,351
6	0,510	0,944	0,641
7	0,842	1,618	1,042
8	1,300	2,558	1,562
9	1,900	3,803	2,200
10	2,656	5,391	2,952

FONTE: O AUTOR (2016)

6.2.2 Modelo para a Válvula Usada em Veículos Pesados

Para a válvula já utilizada em veículos buscou-se obter apenas um modelo, utilizando a configuração da GEP3. Os valores mínimo, médio e máximo de R^2 para as trinta rodadas deste teste foram, respectivamente 0,9752, 0,97916 e 0,9853. A curva de evolução do melhor teste pode ser vista na FIGURA 25.

O valor de R^2 da validação do melhor modelo obtido foi 0,98835, sendo representado pela equação (82). O gráfico que traz as previsões de treinamento e validação para este modelo é exibido na FIGURA 26.




FIGURA 25 - EVOLUÇÃO DA GEP3 NA IDENTIFICAÇÃO DA VÁLVULA USADA
 FONTE: O AUTOR (2016)

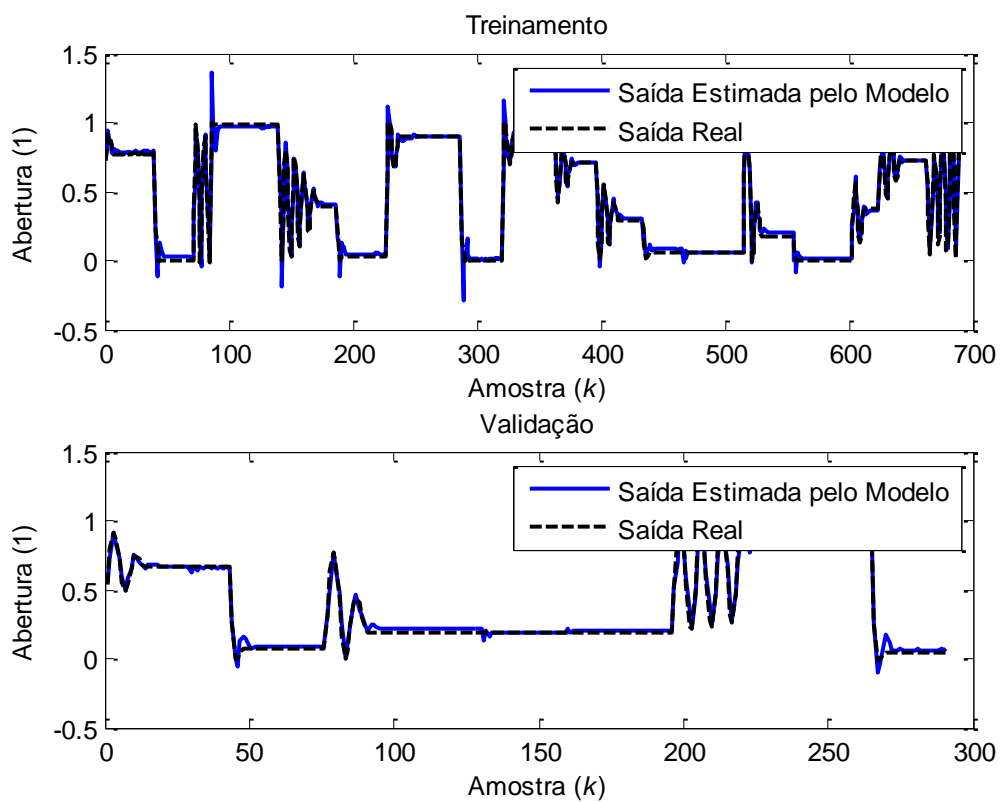


FIGURA 26 - RESULTADOS PARA O MODELO DA GEP3 DA VÁLVULA USADA
 FONTE: O AUTOR (2016)

$$\begin{aligned}
 y(k) = & 0,727116u(k-2) - 0,640618u(k-3) + 0,353726u(k-4) \\
 & - 0,235366u(k-5) + 1,486235y(k-1) \\
 & - 0,504270y(k-2)
 \end{aligned} \tag{82}$$

Na TABELA 6 são exibidos os valores de MSE para previsões até dez passos à frente para o modelo da válvula usada. Assim como no caso da válvula de testes, o modelo também não confere confiabilidade para previsões com longos horizontes.

TABELA 6 - ANÁLISE DO MSE N PASSOS A FRENTE PARA A VÁLVULA USADA

Passos à Frente	VÁLVULA USADA
	GEP3
1	0,001
2	0,014
3	0,058
4	0,139
5	0,256
6	0,405
7	0,584
8	0,787
9	1,013
10	1,258

FONTE: O AUTOR (2016)

6.3 RESULTADOS DAS TÉCNICAS DE CONTROLE

Duas técnicas de controle foram aplicadas a cada uma das duas válvulas estudadas neste trabalho. A primeira trata-se de um controlador Proporcional-Integral otimizado por um algoritmo genético. Enquanto a segunda é um controlador Preditivo Adaptativo, o GPC.

Para avaliar as técnicas aplicadas, foram utilizadas duas métricas de desempenho, o IAE e a energia do sinal de controle E_C . A Integral do Erro Absoluto, exibida em (83), demonstra o erro total gerado durante uma ação de controle.

Enquanto a Energia do sinal de controle, apresentada em (84), é uma forma de medir a quantidade de energia utilizada para realizar uma ação de controle, este valor é obtido calculando-se a energia dissipada pelo sinal em uma resistência de 1Ω .

$$IAE = \int |e(t)| dt \quad (83)$$

$$E_c = \int |u(t)|^2 dt \quad (84)$$

Um quadro comparativo das métricas dos resultados obtidos é exibido na TABELA 7. Observando os desempenhos obtidos nestas medidas, o controlador GPC superou o controlador PI projetado especificamente para a válvula, e ainda foi capaz de superar a mudança de dinâmica entre a válvula de teste e a já usada, desgastada com o tempo. Além disto, o GPC utilizou consideravelmente menos energia do sinal de Controle para esta tarefa.

TABELA 7 - COMPARATIVO DE TESTES DOS CONTROLADORES

	Válvula de Testes		Válvula Usada	
	PI	GPC	PI	GPC
IAE	32,538	24,655	83,877	25,293
Energia Sinal de Controle	17,686	14,965	43,482	11,294

FONTE: O AUTOR (2016)

O detalhamento dos resultados dos controladores é exibido nas subseções 6.3.1, para o controlador PI, e 6.3.2, para o controlador GPC.

6.3.1 Resultados para a Aplicação do Controlador PI

O controlador PI utilizado neste trabalho foi obtido por meio da otimização de seus parâmetros, tomando como base o modelo para a válvula de testes encontrado pela GEP3, da equação (80). Para tal foram realizados trinta experimentos com o

algoritmo genético, nos quais contava com uma população de tamanho igual a 30, realização de 100 gerações, probabilidade de cruzamento de 80%, e probabilidade de mutação de 5%. Algumas métricas de desempenho para estes testes são mostradas na TABELA 8, e a evolução do melhor caso é mostrada na FIGURA 27

TABELA 8 - DESEMPENHO DO GA NA OTIMIZAÇÃO DO CONTROLE PI

IAE		
Mínimo	Médio	Máximo
3,9393	9,7405	19,7620

FONTE: O AUTOR (2016)




FIGURA 27 - EVOLUÇÃO DO MELHOR TESTE DO ALGORITMO GENÉTICO
FONTE: O AUTOR (2016)

Os ganhos encontrados pelo melhor teste para o controlador PI detalhado na seção 3.1, foram $k = 1,1947$, $b = 0,97672$ e $t_i = 1,4123$. E o resultado para esta simulação é encontrado na FIGURA 28.




FIGURA 28 - SIMULAÇÃO DE CONTROLADOR PI COM MELHOR IAE
 FONTE: O AUTOR (2016)

Este controlador PI encontrado por meio da simulação do sistema da válvula real foi empregado na válvula de teste e na usada, resultados que são mostrados na FIGURA 29 e na FIGURA 30. Observa-se que mesmo na aplicação à válvula de testes, para qual o controlador foi projetado, seu desempenho já não atinge as proximidades com o da simulação. Isto pode ter ocorrido pela não representação de alguma não-linearidade do sistema por parte do modelo.

Quando o controlador é aplicado à válvula usada, este torna-se apenas oscilatório, não tendo nenhuma ação de controle efetiva sobre o sistema. O que demonstra sua ineficiência para esta aplicação, vez que uma válvula, mesmo desgastada, pode obter um funcionamento minimamente razoável.

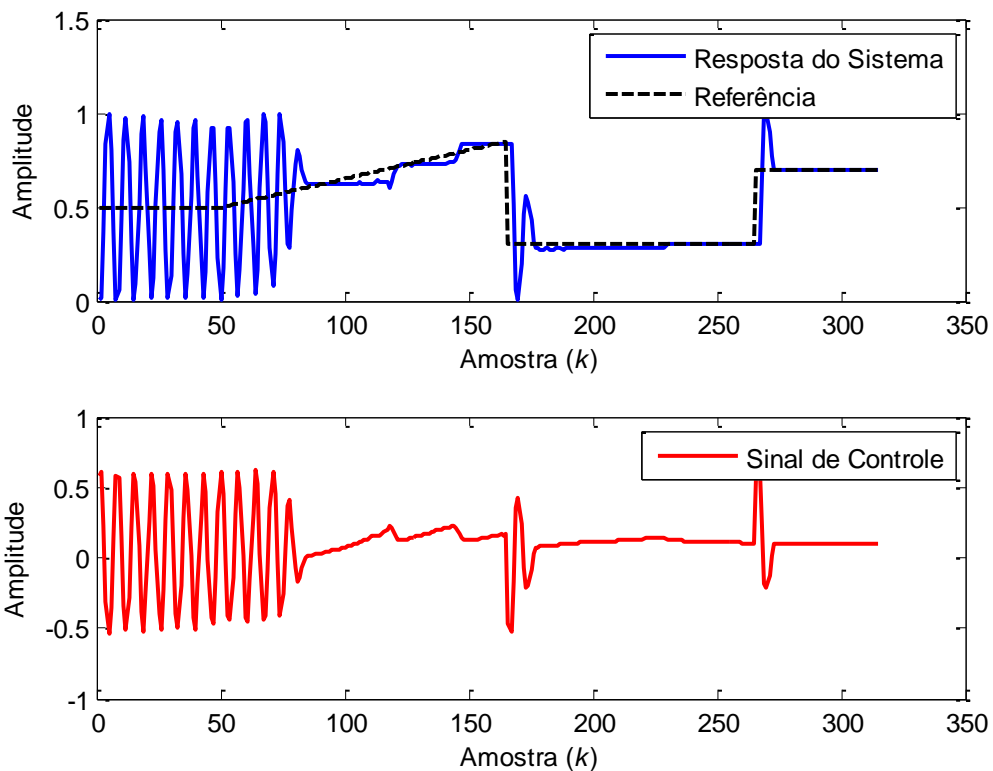


FIGURA 29 - RESPOSTA DO CONTROLADOR PI NA VÁLVULA DE TESTES
 FONTE: O AUTOR (2016)

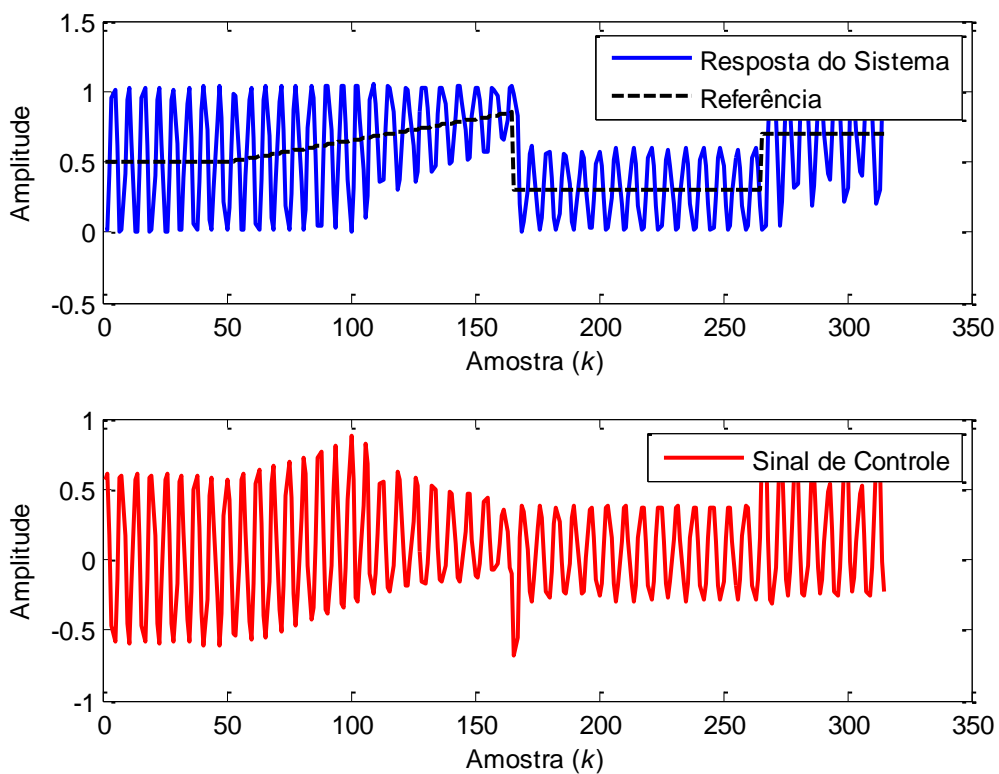


FIGURA 30 - RESPOSTA DO CONTROLADOR PI NA VÁLVULA USADA
 FONTE: O AUTOR (2016)

6.3.2 Resultados para a Aplicação do GPC

O controlador GPC utilizado possuía ponderação do sinal de controle nula, e três regressões para entrada e três para a saída do sistema. O modelo inicial é criado como sendo o último valor da saída e o último da entrada, o que justifica a grande oscilação inicial nas saídas. Para o horizonte de controle N_u utilizou-se o valor 3, o início do horizonte de previsão N_1 foi estabelecido como 1, e o horizonte final de previsão N_y igual a 10.

Inicialmente apresenta-se na FIGURA 31 o resultado de uma simulação do controlador GPC utilizando estes parâmetros para o modelo obtido para a válvula de testes em bancada através da configuração GEP3 da Programação de Expressão Gênica. E a FIGURA 32 exibe a evolução dos parâmetros do controlador ao longo da referência aplicada.

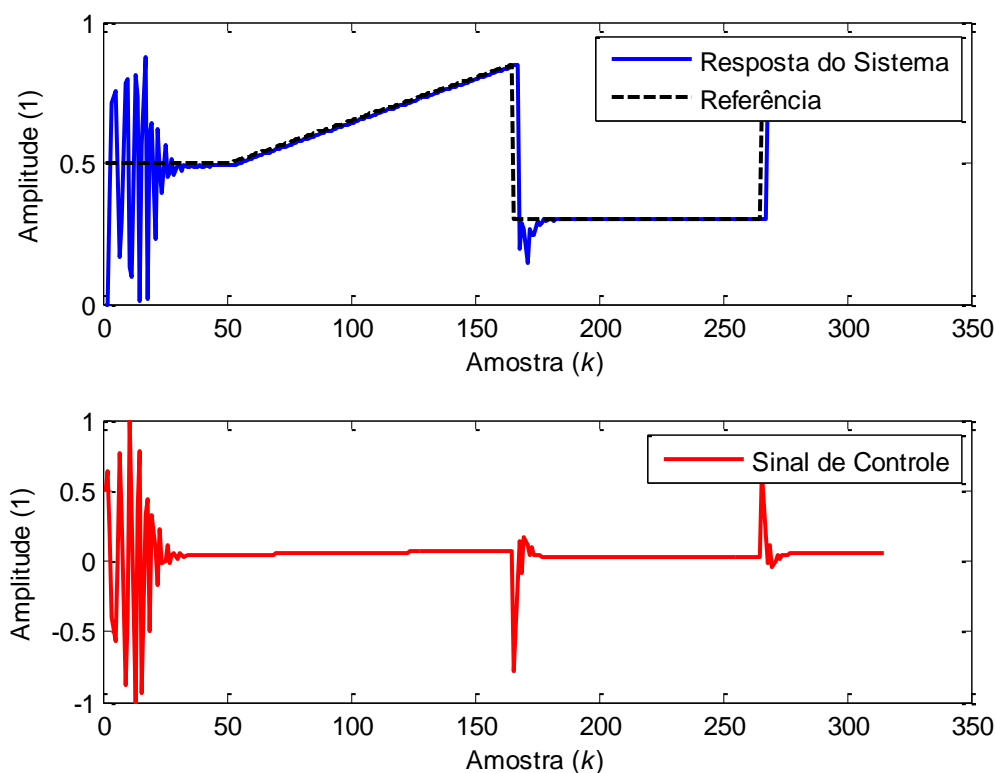


FIGURA 31 – GPC SIMULADO NO MODELO DA GEP3 DA VÁLVULA DE TESTES
FONTE: O AUTOR (2016)




FIGURA 32 - EVOLUÇÃO DOS PARÂMETROS NO MODELO DA GEP3 DA VÁLVULA DE TESTES
 FONTE: O AUTOR (2016)

A resposta da válvula de RGE de testes de bancada ao GPC é mostrada na FIGURA 33. É possível verificar que o controlador consegue acompanhar as mudanças de referência, porém apresenta certa dificuldade em acompanhar a rampa da entrada, o que é causado pelo atrito estático presente nas partes mecânicas da válvula.

A evolução dos parâmetros do modelo que é utilizado internamente no GPC para este caso é exibida na FIGURA 34. A qual convalida a hipótese da oscilação inicial ser causada pela diferença do modelo inicial para o real. Também é possível observar que existe adaptação dos parâmetros ao longo do curso da válvula.




FIGURA 33 - RESPOSTA DO CONTROLADOR GPC NA VÁLVULA NOVA
 FONTE: O AUTOR (2016)




FIGURA 34 - EVOLUÇÃO DOS PARÂMETROS NA VÁLVULA NOVA
 FONTE: O AUTOR (2016)

A comparação entre as respostas da simulação do GPC e a sua aplicação real na válvula de testes de bancada evidenciou um erro médio absoluto de 0,0598, para o sinal de referência testado. Uma ilustração deste erro pode ser observada na FIGURA 35.




FIGURA 35 - ERRO ENTRE O GPC NA SIMULAÇÃO E NA VÁLVULA REAL
FONTE: O AUTOR (2016)

Já a FIGURA 36 exibe a resposta do GPC para a válvula que teve largo uso em veículo pesado. Observa-se que o controlador não teve obstáculos para superar os desgastes mecânicos presente nesta válvula, o que não ocorreu com o controlador PI. A evolução dos parâmetros para este teste de controle é exibida na FIGURA 37, onde também é observada a rápida adaptação de modelo.




FIGURA 36 - RESPOSTA DO CONTROLADOR GPC NA VÁLVULA USADA
 FONTE: O AUTOR (2016)




FIGURA 37 - EVOLUÇÃO DOS PARÂMETROS NA VÁLVULA USADA
 FONTE: O AUTOR (2016)

7 ANÁLISE DE RESULTADOS E DISCUSSÃO

Na primeira etapa dos resultados foram coletados dados de duas Válvulas de Recirculação de Gases de Escape, uma de uso em testes e outra com largo uso em veículo pesado. Por meio de uma análise gráfica, nota-se claramente que a operação no veículo modifica a dinâmica da válvula, isto ocorre devido à deterioração de seus componentes mecânicos, que lidam com altas temperaturas e contrapressão vindas do escape.

Posteriormente os dados coletados foram utilizados para a realização da identificação de modelos ARX e NARX, resultando em três diferentes configurações para a válvula de testes, e uma para a usada. Esta operação foi realizada por meio da Programação de Expressão Gênica, que otimiza a estrutura dos modelos, cujo os parâmetros são então obtidos utilizando o algoritmo de mínimos quadrados.

Todos modelos obtidos através da GEP possuem resultados aparentemente satisfatórios, sendo que um modelo ARX encontrado teve um desempenho similar ao do NARX quando os critérios foram avaliados. Porém quando avaliadas sua previsão sobre um horizonte mais longo, observa-se uma perda rápida na precisão dos modelos. O modelo ARX, que possui menos parâmetros e menor complexidade, foi escolhido para a avaliação de um controlador PI.

Em seguida, um Algoritmo Genético foi utilizado para encontrar a melhor configuração de um controlador PI para o modelo matemático não-linear obtido. Em análise gráfica, o controlador foi capaz de anular o erro em regime permanente, porém apresentava sobre-elevação nas mudanças de referência. Além disso, possui um valor da Integral do Erro Absoluto relativamente baixo, quando confrontado ao número de amostras, por exemplo.

Porém, quando este controlador foi aplicado as válvulas reais, o desempenho não foi o mesmo do simulado. Sendo que este não conseguiu reproduzir a sua eficiência na válvula nova e se tornou oscilatório quando testado na válvula usada. O que impossibilitaria sua implantação prática em um veículo pesado dotado de uma destas válvulas.

De maneira diversa, o Controlador Preditivo Generalizado foi capaz de controlar ambas as válvulas, inclusive superando as dificuldades impostas pelas

folgas mecânicas presentes na válvula usada. Isto feito, sobretudo, com uma atuação do sinal de controle mais econômica, quando comparado ao controlador PI.

Ademais, o GPC pode ainda comportar uma ponderação no sinal de controle, que, se bem escolhida, pode reduzir o efeito oscilatório presente nas mudanças de referência. Além disto, este ainda pode ser utilizado caso haja alguma restrição de projeto quanto a limitações no sinal de controle, como uma taxa de variação máxima, por exemplo.

8 CONCLUSÃO E PERSPECTIVAS FUTURAS

O documento traz um apanhado teórico em relação à Identificação de modelos ARMAX e NARMAX, Algoritmo Genético, Programação de Expressão Gênica, o Controlador PID, o Controlador Preditivo Generalizado, e a descrição da Válvula de Recirculação de Gases de Escape.

A Programação de Expressão Gênica foi aplicada na Identificação de modelos matemáticos lineares e não-lineares de duas válvulas reais, uma utilizada apenas em testes de bancada e outra com uso em veículos. Os resultados obtidos demonstraram uma boa representação do sistema por meio dos modelos ARX e NARX, sendo que estes possuíam valores muito próximos quando avaliado o critério de desempenho R^2 , apesar de existirem grandes diferenças nas estruturas do modelo.

No que tange a otimização de modelos pela GEP, seria possível explorar etapas futuras mecanismos de otimização multiobjetivo. Que possibilitariam ao projetista escolher modelos ótimos para diferentes graus de não-linearidade e regressões máximas, adequando assim o modelo às suas necessidades de precisão e complexidade conforme a aplicação e *Hardware* disponível.

Um controlador PI eficiente na simulação do modelo obtido foi encontrado utilizando a otimização por meio do Algoritmo Genético. Apesar da grande dispersão dos resultados quando avaliadas todas as rodadas do algoritmo, o melhor controlador encontrado possuía um critério de desempenho satisfatório. Entretanto, quando aplicado ao sistema real, para o qual fora modelado, seus resultados não foram satisfatórios.

Também se demonstrou a necessidade da aplicação da técnica adaptativa, pois o controlador PI comum não foi capaz de controlar a válvula usada, que tem sua dinâmica alterada por condições inerentes ao seu funcionamento. Esta incapacidade torna as técnicas não adaptativas não aconselháveis para a aplicação em válvulas de RGE, pois após certo desgaste decorrente do tempo de uso estas passariam a emitir um volume maior de poluentes.

Diferentemente da técnica PI, o Controlador Preditivo Generalizado obteve resultados satisfatórios na regulação da abertura da válvula. Além do que, por ser dotado de um mecanismo de adaptação, seu uso também provou-se possível na

válvula já desgastada, o que permitiria uma vida útil mais longa à esta componente de motores Diesel.

Ademais, o GPC permite ainda que, caso de desejo, sejam incluídas restrições ao sinal de controle, o que poderia melhorar o desempenho da válvula. No projeto destas restrições, além de novos parâmetros e condições iniciais para o algoritmo, pode ser explorada a utilização de uma metaheurística de otimização, a exemplo do Algoritmo Genético aqui apresentado, bem como as técnicas de Enxame de Partículas, Colônia de Formigas, Evolução Diferencial, e entre outras.

Nessa etapa futura se faria necessário o conhecimento dos efeitos da contrapressão variável do escape na válvula de RGE, para que um projeto de parâmetros mais adequado fosse realizado. Para isto, seria indispensável um modelo que exercesse esta função, ou então uma válvula conectada ao sistema completo do motor Diesel.

REFERÊNCIAS

ÅSTRÖM, K. J.; Hägglund, T. **Advanced PID Control**. 1. ed. Research Triangle Park: ISA, 2006.

ÅSTRÖM, K. J.; WITTENMARK, B. **Adaptive Control**. 2 ed. Mineola: Dover Publications, 2008.

ÅSTRÖM, K. J.; WITTENMARK, B. **Computer-Controlled Systems: Theory and Design**. 3. ed. New Jersey: Prentice Hall, 1997.

BAI, Y.; ZHU, Y.; JIANG, Y. **A New Nonlinear System Identification Method Using Gene Expression Programming**. Proceedings of the 2007 IEEE International Conference on Mechatronics and Automation, Harbin, China, p. 2951-2956, agosto 2007.

BILLINGS, S. A. **Nonlinear System Identification: NARMAX Methods in the Time, Frequency, and Spatio-Temporal Domains**. Sheffield: Wiley, 2013.

BOBÁL, V.; BÖHM, J.; FESSL, J; MACHÁČEK, J. **Digital Self-Tuning Controllers: Algorithms, Implementation and Applications**. 1^a ed., Londres: Springer-Verlag, 2005.

BUCKLAND, J. H.; COOK, J. A. **Automotive Emission Control**. Proceeding of the 2005 American Control Conference, Portland, OR, USA, v. 5, p.3290-3295, jun. 2005.

CLARKE, D. W.; GAWTHROP, B. A. **Self-Tuning Controller**. Proceedings of IEE, v. 122, n. 9, p. 929-934, 1975.

CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. **Generalized Predictive Control – Part I. The Basic Algorithm**. Automatica, v. 23, n. 2, p. 137-148, 1987a.

CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. **Generalized Predictive Control – Part II. Extensions and Interpretations**. Automatica, v. 23, n. 2, p. 149-160, 1987b.

COELHO, L. S.; KLEIN, C. E. **Identification of a Poppet Valve Using Genetic Programming Method Based on Adaptive Probabilities with Chaotic Tuning and Orthogonal Least Squares.** Proceedings of the 20th International Congress of Mechanical Engineering (COBEM 2009), Gramado, RS, 2009.

CUTLER, C. R.; RAMAKER, B. L.; **Dynamic Matrix Control** – A Computer Control Algorithm. 86th National Meeting of the American Institute of Chemical Engineering, Houston, Texas, Abril 1979.

DEB, K. et al. **A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II.** IEEE Transactions on Evolutionary Computation, v. 6, n. 2, p. 182-197, abril 2002.

DORIGO, M.; MANIEZZO, V.; COLORNI, **A.Ant System:** Optimization by a Colony of Cooperating Agents. IEEE Transactions on Systems, Man, and Cybernetics - Part B Cybernetics, v. 26, n. 1, p. 29-41, fev 1996.

FERREIRA, C. **Gene Expression Programming:** A New Adaptive Algorithm for Solving Problems. Complex Systems, v. 13, n. 2, p. 87-129, 2001.

FERREIRA, C. **Gene Expression Programming:** Mathematical Modeling by an Artificial Intelligence. 2. ed. Bristol: Springer-Verlag, 2006.

GARCÍA-NIETO, S.; MARTÍNEZ, M.; BLASCO, X.; SANCHIS, J. **Nonlinear Predictive Control Based on Local Model Networks for Air Management in Diesel Engines.** Control Engineering Practice, v. 16, n. 12, p. 1399-1413, dez. 2008.

KENNEDY, J.; EBERHART, R. **Particle Swarm Optimization.** IEEE International Conference on Neural Networks, vol. 4, p. 1942-1948, 1995.

KOZA, J. R. **Genetic Programming:** On the Programming of Computers by Means of Natural Selection. MIT Press, Cambridge, MA, USA, 1992.

LJUNG, L. **System Identification:** Theory for the User. 2 ed. New Jersey: Prentice Hall, 1999.

LJUNG, L.; SÖDERSTRÖM, T. **Theory and Practice of Recursive Identification.** Cambridge: The MIT Press, 1986.

MAYNE, D. Q. **Model Predictive Control: Recent Developments and Future Promise.** Automatica, v.50, p. 2967-2986, 2014.

MENG, X.; SONG, B. **Fast Genetic Algorithms Used for PID Parameter Optimization.** Proceeding of the 2007 IEEE International Conference on Automation and Logistics, Jinan, China, 2144 - 2148, agosto 2007.

MICROCHIP Microchip Technology 2011, **PIC32MX3XX/4XX Family Data Sheet.** Disponível em: <<http://www.microchip.com/wwwproducts/en/PIC32MX320F128H>> Acesso em: 13/01/2016.

MUNCRIEF, R. L. et al. **Combining Biodiesel and Exhaust Gas Recirculation for Reduction in NO_x and Particulate Emissions.** Energy & Fuels, v. 22, p. 1285-1296, 2008.

OGATA, K. **Engenharia de controle moderno.** 5. ed. Rio de Janeiro: Prentice Hall, 2010.

OGUNFUNMI, T. **Adaptive Nonlinear Identification: The Volterra and Wiener Model Approaches.** Santa Clara, California: Springer, 2007.

QIN, S. J.; BADGWELL, T.A. **A Survey of Industrial Model Predictive Control Technology.** Control Engineering Practice, v. 11, p. 733-764, 2003.

RIBEIRO FILHO, J. L.; TRELEAVEN, P.C. ; ALIPPI, C. **Genetic-algorithm programming environments.** Computer, v. 27, n. 6, p. 28-43, 1994.

ST ST Microelectronics 2013, **VNH2SP30-E Datasheet.** Disponível em: <http://www.st.com/web/catalog/sense_power/FM1965/SC1039/PF145473> Acessado em: 13/01/2016.

TSOLAKIS, A.; MEGARITIS, A.; WYSZYNSKI, M. L. **Application of Exhaust Gas Fuel Reforming in Compression Ignition Engines Fueled by Diesel and Biodiesel Fuel Mixtures.** Energy & Fuels, v. 17, p. 1464-1473, 2003.

WELLSTEAD, P. E.; ZARROP, M. B. **Self-tuning systems: control and signal processing.** 1ª ed. Chichester: Wiley, 1991. 579 p.