



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE COMPUTAÇÃO E
AUTOMAÇÃO
CURSO DE ENGENHARIA MECATRÔNICA



Metaheurísticas para Estimação de Parâmetros na Identificação de Sistemas Não Lineares

Alcemy Gabriel Vitor Severino

Orientador: Prof. Dr. Fábio Meneghetti Ugulino de Araújo

Natal-RN
Dezembro de 2015

Metaheurísticas para Estimação de Parâmetros na Identificação de Sistemas Não Lineares

Alcemy Gabriel Vitor Severino

Trabalho de Conclusão de Curso apresentado à Banca Examinadora do curso de Engenharia Mecatrônica, em cumprimento às exigências legais como requisito parcial à obtenção do título de Engenheiro Mecatrônico.

Natal-RN
Dezembro de 2015

*Aos meus pais, Alcivan e Marineide,
pela paciência e apoio durante a
realização deste trabalho.*

Agradecimentos

Agradeço aos meus pais, Alcivan Severino e Marineide Gomes Vitor Severino, e ao meu irmão Gabriel Severino Neto, por serem uma família maravilhosa que me apoia e se importa com minha educação e futuro.

Ao meu orientador, professor Fábio Meneghetti Ugulino de Araújo, pela oportunidade de trabalharmos juntos ao longo de toda minha iniciação científica, pelo conhecimento transmitido, pela atenção e paciência.

Aos engenheiros Leandro Linhares e Ícaro Bezerra pelos conselhos, sugestões e ajuda na revisão deste trabalho.

Aos colegas de pesquisa e amigos, do Laboratório de Controle de Processos do Departamento de Engenharia de Computação e Automação/UFRN, André Henrique, Mário Sérgio, José Kleiton, Fábio Ricardo, André Luiz, Brunna Vasconcelos, Missilene Farias, Jean Mário e Álvaro Ramos pelas sugestões, paciência e momentos de descontração.

A minha querida amiga Mislainy Mayana pelo apoio.

Aos demais colegas de graduação, pelas críticas e sugestões.

Aos meus demais familiares pelo apoio e confiança.

E àqueles que não foram aqui mencionados, mas que contribuíram nesta minha jornada.

Resumo

Devido à complexidade inerente à tentativa de obtenção de modelos matemáticos satisfatórios para representação de sistemas físicos reais e a consequente necessidade de se facilitar a obtenção destes modelos, foi realizado nesse trabalho um estudo investigativo da utilização de diferentes metaheurísticas para estimação de parâmetros na identificação de sistemas não lineares. As metaheurísticas utilizadas foram o Algoritmo Genético, a Otimização por Enxame de Partículas e o Algoritmo do Morcego. Posteriormente, para validação dos resultados obtidos, os modelos estimados por meio destas metaheurísticas foram comparados entre si e com o modelo estimado fazendo uso do Método dos Mínimos Quadrados. Os resultados demonstraram a eficácia do emprego dessas metaheurísticas como técnicas de estimação de parâmetros, destacando que estas obtiveram modelos de melhor desempenho que o modelo estimado por meio do Método dos Mínimos Quadrados.

Palavras-chave: Metaheurísticas, Estimação de Parâmetros, Identificação de Sistemas Não Lineares, Método dos Mínimos Quadrados.

Abstract

Due to the complexity inherent to obtaining mathematical models that well represent real physical systems, and consequently the necessity to make easier the design of those models, in this work was realized an investigative study of using different metaheuristics to estimate the parameters at identification of nonlinear systems. The different metaheuristics analysed were: Genetic Algorithm, the Particle Swarm Optimization and Bat Algorithm. To validate the results, the estimated models obtained by these methods, were compared with each other and with another one, that used Least Mean Squares. The results demonstrated the efficacy of these metaheuristics as techniques of parameters estimation, is up to notice that they obtained a minor error compared to the model estimated by the Least Mean Squares.

Keywords: Metaheuristics, Parameter Estimation, Identification of Nonlinear Systems, Method of Least Squares.

Sumário

Sumário	i
Lista de Figuras	iii
Lista de Tabelas	iv
Lista de Abreviaturas	v
1 Introdução	1
1.1 Estrutura do documento	2
2 Fundamentação Teórica	3
2.1 Sistemas	3
2.1.1 Sistemas lineares e não lineares	3
2.2 Identificação de sistemas dinâmicos	4
2.2.1 Coleta de dados experimentais	5
2.2.2 Determinação da estrutura	6
A série de Volterra	6
Modelos de Hammerstein e de Wiener	7
Representação NARMAX	7
2.2.3 Estimação de parâmetros	8
Método dos Mínimos Quadrados	8
Metaheurísticas	10
Algoritmo Genético	11
Otimização por Enxame de Partículas	12
Algoritmo do Morcego	14
2.2.4 Validação do modelo	16
Simulação	16
3 Metodologia	17
3.1 Metodologia	17
4 Resultados	20
4.1 Modelos estimados	20
4.1.1 Modelo estimado pelo MMQ	20
4.1.2 Modelo estimado pelo GA	22
4.1.3 Modelo estimado pelo PSO	23

4.1.4	Modelo estimado pelo BA	25
4.1.5	Comparação geral	26
5	Conclusão	29
	Referências bibliográficas	30

Lista de Figuras

2.1	Procedimento para identificação de processos	4
2.2	Etapas do procedimento básico de identificação	5
2.3	Etapas básicas do GA utilizado	11
2.4	Etapas básicas do PSO utilizado	13
2.5	Etapas básicas do BA utilizado	15
3.1	Dados de entrada, ruído branco e saída do sistema	18
4.1	Saída para dados de entrada de estimação - MMQ	20
4.2	Saída para dados de entrada de validação - MMQ	21
4.3	Saída para dados de entrada de estimação - GA	22
4.4	Saída para dados de entrada de validação - GA	22
4.5	Saída para dados de entrada de estimação - PSO	23
4.6	Saída para dados de entrada de validação - PSO	24
4.7	Saída para dados de entrada de estimação - BA	25
4.8	Saída para dados de entrada de validação - BA	25
4.9	Curvas do erro entre a saída do modelo base e os modelos estimados	26
4.10	<i>Boxplot</i> dos parâmetros estimados	28

Lista de Tabelas

3.1	Valores dos parâmetros utilizados em cada metaheurística	19
4.1	Parâmetros estimados pelo MMQ	21
4.2	Parâmetros estimados pelo GA	23
4.3	Parâmetros estimados pelo PSO	24
4.4	Parâmetros estimados pelo BA	26
4.5	Média dos parâmetros estimados	27
4.6	Desvio padrão dos parâmetros estimados	27

Lista de Abreviaturas

BA:	Algoritmo do Morcego
GA:	Algoritmo Genético
MMQ:	Método dos Mínimos Quadrados
NARMAX:	<i>Non-linear AutoRegressive Moving Average with eXogenous inputs</i>
NARX:	<i>Non-linear AutoRegressive with eXogenous inputs</i>
PSO:	Otimização por Enxame de Partículas

Capítulo 1

Introdução

A representação de sistemas e fenômenos físicos sempre constituiu um desafio para a engenharia de controle. Desde a Antiguidade, o homem tem procurado maneiras de descrever sistemas matematicamente de modo a permitir maior entendimento acerca da dinâmica observada nestes processos e, desta forma, buscar métodos eficazes de solucionar diversos problemas existentes (AGUIRRE, 2004).

Neste contexto, cabe aos Engenheiros de Controle, Cientistas e Pesquisadores buscar o desenvolvimento de técnicas eficientes de modelagem de sistemas, assim proporcionando o aperfeiçoamento dos processos produtivos, melhor aproveitamento das matérias primas, obtenção de produtos de melhor qualidade, sistemas mais seguros e confiáveis, e o atendimento às necessidades da sociedade contemporânea, entre outros benefícios.

Na última década tem-se verificado uma tendência geral que tornará o uso de técnicas de identificação e análise de sistemas desejável em praticamente todas as áreas do conhecimento humano. Essa tendência é a inegável capacidade que hoje se tem de coletar dados com informação sobre a dinâmica do sistema que está sendo observado (AGUIRRE, 2004).

Araújo Júnior (2014) explica que isso se dá devido à crescente evolução e disponibilidade de computadores. Em consequência disso observamos o aumento do uso de modelos computacionais em praticamente todas as áreas da ciência, de modo que, nos dias atuais, o processo de modelagem de sistemas físicos é considerado de grande importância.

As técnicas de identificação de sistemas são bastante utilizadas para determinar modelos matemáticos a partir dos dados de entrada-saída do processo. Por meio desses modelos é possível obter uma aproximação satisfatória do comportamento dinâmico do sistema para uma determinada aplicação e uma faixa limitada de operação.

Necessariamente, não existe um modelo que reproduza com exatidão o comportamento de um sistema, de maneira que não existe apenas um modelo para determinado sistema, mas diversos modelos possíveis (DANTAS, 2013).

Na indústria, a grande parte dos sistemas utilizam modelos lineares aproximados dos processos que se desejam controlar. Segundo Santos *et al.* (2004), a utilização de técnicas de controle baseadas em modelos lineares é, em parte, devida à simplicidade dos modelos empregados para representar o comportamento do processo. No entanto, isto também constitui uma deficiência potencial, uma vez que, tais modelos lineares são, muitas vezes, inadequados quando se faz necessária uma melhor aproximação do processo.

Por outro lado, os esquemas de controle não-linear, os quais empregam modelos mais

realistas e, portanto, mais complexos, para a descrição de processos não lineares, substituam a simplicidade associada às técnicas lineares. Modelos não lineares possibilitam um “retrato” mais fiel do processo quando este se faz necessário. A complexidade ocorre devido a diversos fatores entre eles estão: a escolha da representação para sistemas não lineares, depois a necessidade de determinação da estrutura, e finalmente, a definição dos parâmetros.

Nos trabalhos de Li e Jeon (1993) e Akramizadeh *et al.* (2002) foram utilizados Algoritmos Genéticos para obtenção de modelos para sistemas não lineares. De forma semelhante, os autores Liu *et al.* (2006) e Supeni *et al.* (2009) usaram Otimização por Enxame de Partículas para a mesma finalidade.

A fim de potencializar a obtenção de modelos na identificação de sistemas não lineares, foi investigada a utilização de metaheurísticas na estimação de seus parâmetros. As metaheurísticas estudadas foram o Algoritmo Genético, a Otimização por Enxame de Partículas e o Algoritmo do Morcego. Como análise, um modelo polinomial NARMAX de um sistema não linear teve seus parâmetros estimados através das metaheurísticas. Ao final, os modelos estimados foram comparados entre si e com o modelo estimado por meio do Método dos Mínimos Quadrados.

1.1 Estrutura do documento

Este trabalho está organizado em cinco capítulos. O Capítulo 2 apresenta uma revisão sobre o procedimento básico de modelagem e identificação de sistemas dinâmicos, assim como descreve algumas representações não lineares, além de alguns métodos utilizados para estimação dos parâmetros do modelo. A metodologia adotada para a obtenção dos resultados é detalhada no Capítulo 3, ao passo que o Capítulo 4 é reservado à análise dos resultados alcançados. Finalmente, no Capítulo 5 são apresentadas as conclusões e os trabalhos futuros.

Capítulo 2

Fundamentação Teórica

Neste capítulo serão apresentados conceitos e definições importantes para compreensão do trabalho. A identificação de sistemas será abordada por meio de representações matemáticas não lineares. Também serão apresentados o regressor linear, conhecido por Método dos Mínimos Quadrados, e as metaheurísticas utilizadas neste trabalho para a estimação dos parâmetros.

2.1 Sistemas

Um sistema é constituído por componentes interconectados, os quais são caracterizados por sua relação terminal (entrada/saída) (LATHI, 2007). As características dinâmicas de um sistema podem ser representadas por um modelo matemático. De acordo com o modelo, os sistemas podem ser classificados, de forma genérica, em sistemas lineares e não lineares.

2.1.1 Sistemas lineares e não lineares

Rigorosamente falando, os sistemas lineares não existem na prática, uma vez que todos os sistemas físicos são não lineares de alguma forma (GOLNARAGHI; KUO, 2012). Um sistema é linear se o princípio da superposição for aplicável, também podemos dizer que um sistema é linear se as magnitudes dos sinais do sistema são limitadas a intervalos de valores nos quais os componentes do sistema demonstrem características lineares.

A principal motivação de utilizar sistemas lineares é simplificar a obtenção do modelo. Em algumas aplicações, aproximações lineares são suficientes. Porém, em determinados casos, modelos lineares demonstram desempenho insatisfatório, sendo as representações não lineares mais adequadas.

Optar por modelos não lineares traz como consequência um aumento na complexidade dos métodos a serem usados, entretanto, modelos não lineares produzem certos regimes dinâmicos que modelos lineares não conseguem representar (AGUIRRE, 2004).

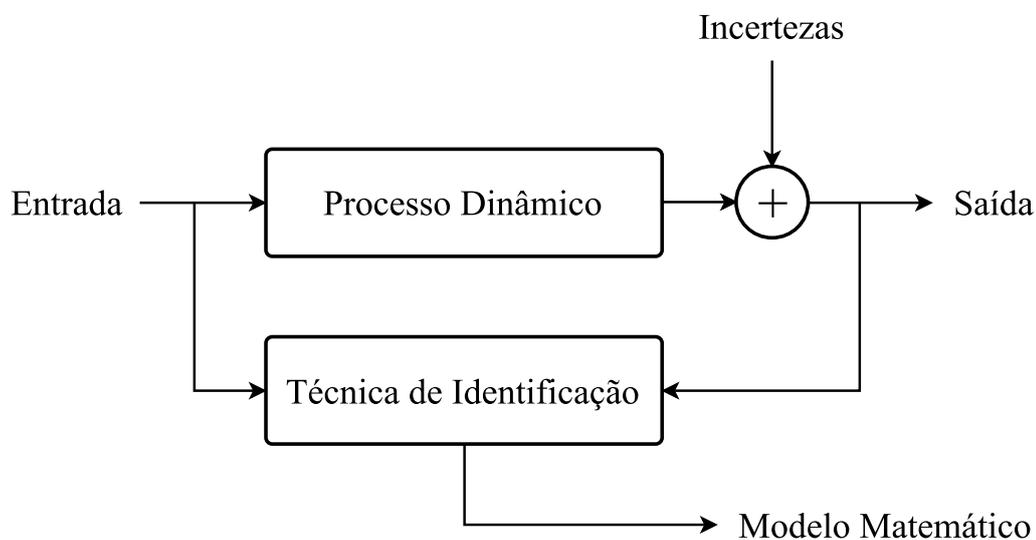
2.2 Identificação de sistemas dinâmicos

Fundamentalmente, a identificação de sistemas consiste na determinação de um modelo matemático que represente os aspectos essenciais do sistema, caracterizado pela manipulação dos sinais de entrada e saída (ISERMANN; LACHMANN, 1985; LJUNG, 1999).

De acordo com Coelho e Coelho (2004), os modelos de processos industriais, por exemplo, podem ser obtidos por meio do tratamento de medidas (procedimento estatístico, filtragem de dados) coletadas a partir de uma realização experimental para uma utilização particular, como diagnóstico, supervisão, otimização e/ou controle. Para fins de controle de processos, não se pretende encontrar um modelo matemático exato, mas um modelo adequado para uma determinada aplicação.

Estes modelos podem ser caracterizados, no processo físico, pela função de transferência, para sistemas lineares; e modelos polinomiais, por exemplo, para sistemas não lineares, com os polinômios não lineares sendo funções lineares nos parâmetros, o que permite a utilização dos algoritmos de estimação de parâmetros lineares para modelos não lineares (DANTAS, 2013). O esquema de identificação é ilustrado através de blocos pela Figura 2.1 abaixo:

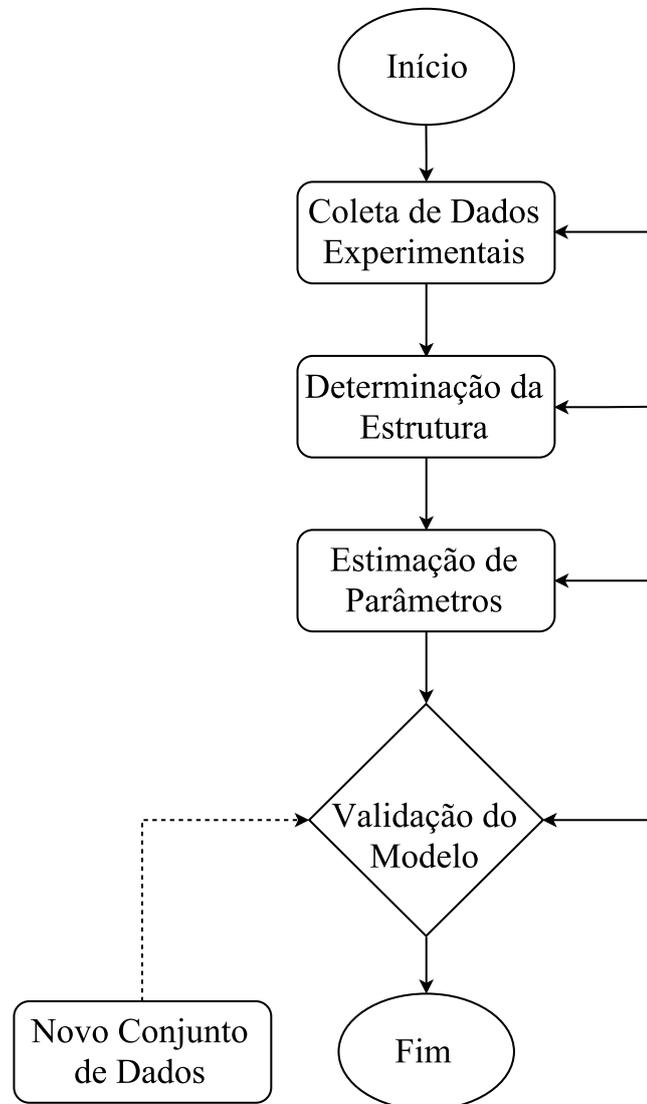
Figura 2.1: Procedimento para identificação de processos



Fonte: Modificado de Coelho e Coelho (2004).

Normalmente, a identificação é realizada em quatro passos: coleta de dados experimentais, determinação da estrutura, estimação de parâmetros e validação do modelo (Figura 2.2).

Figura 2.2: Etapas do procedimento básico de identificação



Fonte: Modificado de Dantas (2013).

2.2.1 Coleta de dados experimentais

Trata-se da coleta de um conjunto de dados que relaciona a entrada e saída do sistema, sendo os dados obtidos a partir de medições da resposta $y(k)$ do sistema quando aplicado um sinal $u(k)$ previamente determinado.

É necessário que o sinal de entrada $u(k)$ consiga excitar o sistema em todas as faixas de frequências de interesse para que seja possível a identificação, de forma a revelar as características dinâmicas e estáticas do sistema (AGUIRRE, 2004; DANTAS, 2013).

De acordo com Dantas (2013), nos métodos de identificação determinísticos e estocásticos, os sinais de excitação comumente aplicados são os degraus, senóides, sinais pseudo

aleatórios (*pseudo random signal, PRS*) e ruídos brancos ou Gaussianos (sinais aleatórios cujo espectro tem a mesma potência em todas as frequências).

Outro fator importante é a determinação do tempo de amostragem. Sua influência se estende desde a seleção da estrutura e estimação dos parâmetros, até a eficácia do modelo em representar características importantes do sistema.

Aguirre e Billings (1995) estudaram a importância da determinação correta do tempo de amostragem e perceberam que os dados precisam ser amostrados em intervalos de tempo adequados, ou seja, pequenos o suficiente, de modo que todas as frequências de interesse sejam visitadas pelo conjunto de dados, com o cuidado para que não sejam pequenos demais, prejudicando assim, o desempenho do algoritmo de estimação de parâmetros.

Além disso, algumas interações não lineares só aparecerão e serão reproduzidas se a taxa de amostragem for suficientemente alta.

2.2.2 Determinação da estrutura

Há várias formas de classificar técnicas de modelagem. Uma delas agrupa os métodos em três categorias denominadas *modelagem caixa branca*, *modelagem caixa preta* e *modelagem caixa cinza* (AGUIRRE, 2004):

- **Modelagem caixa branca** - também conhecida como *modelagem pela física do processo ou natureza do processo*, ou *modelagem conceitual*, requer um conhecimento *a priori* do sistema e igualmente das leis físicas que o caracterizam;
- **Modelagem caixa preta** - há pouco ou nenhum conhecimento *a priori* do sistema, de forma que, apenas um projeto de sinal de entrada é feito, com o objetivo de observar o comportamento da saída do sistema. Por fim, a identificação do modelo acontece pelos dados coletados da entrada e saída do processo;
- **Modelagem caixa cinza** - está localizada entre a modelagem caixa branca e modelagem caixa preta. Este tipo de modelagem utiliza informações auxiliares que os dados coletados durante a identificação não são capazes de demonstrar. A quantidade de informação auxiliar irá caracterizar a modelagem como mais "clara" ou mais "escura".

Na literatura existe uma grande diversidade de representações não lineares que, em tese, podem ser usadas na modelagem e identificação de sistemas, a exemplo o que é demonstrado por Aguirre (2004):

A série de Volterra

A saída $y(t)$ de um sistema não linear com entrada $u(t)$ pode ser representada pela chamada série de Volterra definida como:

$$y(t) = \sum_{j=1}^{\infty} \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} h_j(\tau_1, \dots, \tau_j) \prod_{i=1}^j u(t - \tau_i) d\tau_i \quad (2.1)$$

sendo que as funções h_j são os núcleos (*kernels* em inglês) e claramente são generalizações não lineares da resposta ao impulso $h_1(t)$.

Modelos de Hammerstein e de Wiener

Ambos os modelos são uma composição de um modelo dinâmico linear $H(s)$ em cascata com uma função estática não linear $f(\cdot)$. No caso do modelo de Hammerstein, a não linearidade estática precede o modelo dinâmico linear, ou seja:

$$U^*(s) = f(U(s)); \text{ e } Y(s) = H(s)U^*(s) \quad (2.2)$$

No caso do modelo de Wiener, o modelo dinâmico linear precede a não linearidade estática, isso é:

$$Y^*(s) = H(s)U(s); \text{ e } Y(s) = f(Y^*(s)) \quad (2.3)$$

Representação NARMAX

A representação usada neste trabalho trata-se do modelo NARMAX (*Non-linear Autoregressive Moving Average with exogenous inputs*) (CHEN; BILLINGS, 1989), com estrutura monovariável e período de amostragem normalizado, dado pela equação abaixo:

$$y(k) = F^l[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u), e(k-1), \dots, e(k-n_e)] + e(k) \quad (2.4)$$

sendo $y(k)$, $u(k)$, $e(k)$, a saída, a entrada e o ruído aditivo do sistema, respectivamente, e n_y , n_u , n_e , os respectivos atrasos máximos. Por fim, d é o tempo morto do sistema.

F^l é uma função não linear qualquer, que normalmente não tem sua forma conhecida *a priori*, de modo que, para reconstruir a dinâmica do sistema utilizam-se aproximações. Possíveis aproximações para a função F^l são os modelos polinomiais e racionais. Neste trabalho, a aproximação escolhida foi a polinomial.

A aproximação polinomial de grau l para o modelo 2.4 apresenta a seguinte estrutura (CHEN; BILLINGS, 1989 apud AGUIRRE *et al.*, 1998, p. 92):

$$\begin{aligned} y(k) = & \theta_0 + \sum_{i_1=1}^n \theta_{i_1} x_{i_1}(k) + \sum_{i_1=1}^n \sum_{i_2=i_1}^n \theta_{i_1 i_2} x_{i_1}(k) \cdot x_{i_2}(k) + \dots \\ & + \sum_{i_1=1}^n \dots \sum_{i_l=i_{l-1}}^n \theta_{i_1 \dots i_l} x_{i_1}(k) \cdot \dots \cdot x_{i_l}(k) + e(k) \end{aligned} \quad (2.5)$$

onde,

$$\begin{aligned} x_1(k) = & y(k-1), x_2(k) = y(k-2), \dots, x_{n_y+1}(k) = u(k-d), \dots, \\ x_{n_y+n_u+1}(k) = & e(k-1), \dots, x_n(k) = e(k-n_e) \\ n = & n_y + n_u + n_e \end{aligned}$$

A maior motivação para a escolha dos modelos polinomiais é o fato dos mesmos serem lineares nos parâmetros, ou seja, modelos deste tipo podem ser representados na forma $y(k) = \psi^T \theta$ e conseqüentemente permitem a utilização do Método dos Mínimos Quadrados na estimação do parâmetros.

Um subconjunto do modelo NARMAX que contém apenas a sua parte determinística é denominado modelo NARX (*Non-linear AutoRegressive with eXogenous inputs*) e é representado por (COELHO *et al.*, 2002):

$$y(k) = F^l[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u)] + e(k) \quad (2.6)$$

Este tipo de representação não linear possui como particularidade a capacidade de recuperar a característica estática de um sistema através dos dados de entrada e saída.

Há diversas representações além das previamente apresentadas, como, Redes Neurais Artificiais (MARTINS *et al.*, 2015), Neuro-Fuzzy (ARAUJO JÚNIOR, 2014; LINHARES, 2015), ANFIS Modificado (MARTINS, 2015), etc.

2.2.3 Estimação de parâmetros

Definida a estrutura do modelo, o passo seguinte será a estimação de seus parâmetros. Segundo Coelho e Coelho (2004), a estimação de parâmetros é um procedimento numérico que determina os valores dos parâmetros do modelo (desconhecidos) e pode ser formulado como um problema de otimização no qual o melhor modelo é aquele que se ajusta às medidas para um dado critério.

Como dito anteriormente, os modelos NARMAX polinomiais são lineares nos parâmetros, ou seja, o Método dos Mínimos Quadrados lineares pode ser usado na estimação. Para comparação e apresentando-se como principal objetivo deste trabalho, as metaheurísticas conhecidas como Algoritmo Genético (HOLLAND, 1975), Otimização por Enxame de Partículas (KENNEDY; EBERHART, 1995) e Algoritmo do Morcego (YANG, 2010) também foram aplicadas na estimação dos parâmetros de um modelo NARMAX polinomial.

Método dos Mínimos Quadrados

Karl Friedrich Gauss desenvolveu o Método dos Mínimos Quadrados (MMQ) em 1795, para prever a trajetória de planetas e cometas a partir de observações realizadas. De acordo com Aguirre (2004), o Método dos Mínimos Quadrados é um dos mais conhecidos e mais utilizados nas mais diversas áreas de ciência e tecnologia. Utilizando o método, é possível estimar os parâmetros que descrevem o modelo.

Definindo-se o vetor de parâmetros, $\hat{\theta}$, como:

$$\hat{\theta} = \begin{bmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \\ \vdots \\ \hat{\theta}_n \end{bmatrix} \quad (2.7)$$

A melhor previsão da saída do sistema, \hat{y} , é calculada multiplicando a matriz das

observações, ϕ , pela estimativa do vetor parâmetros, $\hat{\theta}$, dada pela Equação 2.8:

$$\hat{y} = \phi \hat{\theta} \quad (2.8)$$

Guass estabeleceu que os parâmetros estimados devem ser definidos de modo que a soma dos quadrados da diferença entre os valores observados e os calculados seja mínima. A função custo para o Método dos Mínimos Quadrados é dada por:

$$J_{MQ} = \sum_{i=1}^N \varepsilon(i)^2 \quad (2.9)$$

onde, $\varepsilon = y(i) - \hat{y}(i)$, y é o valor real da saída, \hat{y} é o valor estimado da saída, e N é o número de observações, ou seja, o tamanho do vetor dos dados de entrada.

De acordo com Aguirre *et al.* (1998), a estrutura NARMAX apresentada na Equação 2.5 pode ser representada como:

$$y(k) = \sum_{i=1}^{n_{\theta}} \varphi^T(k) \hat{\theta}_i + \varepsilon(k) \quad (2.10)$$

onde, n_{θ} é o número de termos no modelo, o símbolo “^” sobre θ indica valores estimados, $\varphi(k)$ é o vetor de regressores, $\varepsilon(k)$ representa tanto os erros de modelagem, os erros de medição, o ruído aditivo do sistema e incertezas de ordem qualquer.

A Equação 2.10 pode ser também representada a partir de sua notação matricial:

$$Y = \Psi \Theta + \Xi \quad (2.11)$$

considerando que foram realizadas N medições, e que estas sejam suficientes para estimar os parâmetros, tem-se:

$$Y = [y(1) \quad y(2) \quad \dots \quad y(N)]^T$$

$$\Xi = [\xi(1) \quad \xi(2) \quad \dots \quad \xi(N)]^T$$

$$\Psi = \begin{bmatrix} \varphi_1(1) & \varphi_2(1) & \dots & \varphi_{n_{\theta}}(1) \\ \varphi_1(2) & \varphi_2(2) & \dots & \varphi_{n_{\theta}}(2) \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_1(N) & \varphi_2(N) & \dots & \varphi_{n_{\theta}}(N) \end{bmatrix}$$

onde, Ψ é a matriz de regressores, Θ o vetor de parâmetros, e Ξ o vetor de resíduos.

O estimador dos mínimos quadrados é uma transformação linear sobre Y (função linear das medidas) e, assim, é denominado *estimador linear* que minimiza a função de custo representada na Equação 2.9 (COELHO; COELHO, 2004).

A Equação 2.12 é denominada equação normal. A sua solução, $\hat{\theta}$, existe e é única

desde que a matriz $\Psi^T\Psi$, chamada de matriz normal ou matriz de informação, seja simétrica e definida positiva. Para isto, o sistema deve estar persistentemente excitado para evitar o caso de linhas comuns na matriz Ψ (colunas linearmente dependentes) (COELHO; COELHO, 2004).

$$\hat{\theta} = [\Psi^T\Psi]^{-1}\Psi^T Y \quad (2.12)$$

Metaheurísticas

Metaheurísticas pertencem ao mundo dos métodos de otimização numérica, por isso devemos primeiro entender o que são estes métodos.

Os métodos de otimização numérica são rotinas matemáticas/computacionais que consistem na busca de uma solução ótima ou um conjunto de soluções para uma determinada função ou conjuntos de funções. Eles são separados em dois grupos:

- Determinísticos, baseados em gradientes ou derivadas, ou ainda em aproximações destas;
- Heurísticos, também conhecidos como Naturais, que são aleatórios.

A principal diferença entre estes grupos é: nos métodos determinísticos prevemos todos os seus passos conhecendo o ponto de partida, ou seja, a resposta será a mesma para o mesmo ponto inicial; nos métodos heurísticos a escolha do próximo passo é feita a partir de números aleatórios, de modo que, para um mesmo ponto inicial podemos encontrar diferentes respostas finais.

Estes grupos se dividem em subgrupos, no caso dos métodos heurísticos eles são:

- de Construção;
- de Busca de Vizinhança;
- Sistemáticas;
- Híbridas;
- Metaheurísticas.

Metaheurísticas utilizam uma combinação de escolhas aleatórias e o histórico de resultados passados encontrado pelo método para realizar buscas na vizinha dentro do espaço de pesquisa, assim evitando paradas em ótimos locais.

É importante notar que a metaheurística é o processo de orientação, ela calcula os próximos possíveis movimentos. Já a heurística é o processo de seleção, ou seja, determina quais movimentos serão executados dentre os sugeridos pelo processo de orientação.

De acordo com Osman e Laporte (1996), uma metaheurística é um processo de geração iterativo que guia uma heurística subordinada, combinando inteligentemente conceitos diferentes para explorar os espaços de pesquisa usando estratégias de aprendizagem para estruturar as informações, a fim de encontrar de forma eficiente soluções próxima do ideal.

Algoritmo Genético – Na década de 70, John Henry Holland apresentou a técnica do Algoritmo Genético (*Genetic Algorithm - GA*) (HOLLAND, 1975). Os GAs são técnicas não-determinísticas de busca, otimização e aprendizagem de máquina, que manipulam um espaço de soluções potenciais utilizando mecanismos inspirados nas teorias de seleção natural de C. Darwin e na genética de G. Mendel (COELHO; COELHO, 1999). Normalmente, os principais componentes dos GAs são a representação do problema e a função de aptidão. Os outros, dizem respeito à população, seleção, cruzamento e mutação.

Na representação, podemos usar números binários, inteiros ou reais, dependendo basicamente do problema a ser resolvido. Comumente, cada indivíduo ou cromossomo, ou seja, as possíveis soluções, possuem um tamanho constante, de modo que a representação escolhida permita que os indivíduos representem pontos no espaço de soluções potenciais do problema.

A função de aptidão, também conhecida como função objetivo (problema de maximização) ou custo (problema de minimização), é a função que será otimizada. Nela encontra-se o mecanismo de evolução responsável por avaliar cada indivíduo, atribuindo um valor de aptidão (*fitness*) de acordo com o seu próprio desempenho e dos indivíduos demais na população. Este valor representa a possibilidade do indivíduo de ser selecionado para participar do processo de reprodução das próximas gerações.

A Figura 2.3 apresenta o fluxograma do Algoritmo Genético implementado neste trabalho.



Figura 2.3: Etapas básicas do GA utilizado

Inicialmente, a população é formada por um conjunto de soluções aleatórias, chamadas de indivíduos. O tamanho da população depende do problema. Quanto maior a população, maior será a chance de encontrar uma solução, entretanto, maior será o tempo e custo computacional necessário. Cabe ao projetista definir um valor adequado, pois se o tamanho é muito alto, o processo estará se aproximando de uma busca exaustiva, perdendo assim, a sua qualidade como método alternativo.

O método de seleção do GA inspira-se no processo utilizado pela natureza, em que os indivíduos mais aptos possuem maior probabilidade de sobreviver e perpetuar seu material genético. Por meio da seleção, cria-se uma população intermediária que passará pelos processos de cruzamento e mutação para formação da próxima geração. Como explicado anteriormente, a probabilidade do indivíduo ser selecionado é proporcional a sua aptidão e ao somatório das aptidões dos outros indivíduos, de modo que, maior será a chance de selecionar os indivíduos mais aptos.

Para evitar que o indivíduo mais apto seja perdido durante a seleção, utiliza-se um método conhecido como elitismo, em que o melhor indivíduo é mantido na próxima geração, perpetuando assim, o seu material genético.

Durante o cruzamento, são formados pares aleatórios de indivíduos previamente selecionados. Estes pares de indivíduos (pais) terão seus materiais genéticos manipulados para formar outros indivíduos (filhos).

A mutação tem um papel importante, uma vez que através dela os indivíduos filhos sofrem pequenas alterações, o que possibilita recolocar ou somar um material genético perdido. Em outras palavras, a mutação permite que o GA realize uma busca mais abrangente por meio do espaço de soluções. Outro benefício é o fato que depois de um certo tempo o GA tenderá a gerar indivíduos semelhantes, ocasionando que fique preso em um ponto ótimo local, de modo que a mutação pode permitir que o GA saia deste ponto e encontre o ponto ótimo global. Geralmente, utiliza-se uma taxa de mutação inspirada na natureza de 1%, que pode variar de acordo com o problema.

Otimização por Enxame de Partículas – A otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO) foi inspirada na natureza, baseando-se nas características sociais de bandos de pássaros e cardumes de peixes na busca pelo ninho ou alimento.

De acordo com Eberhart e Shi (2001), o PSO é semelhante ao GA, pois o sistema é inicializado com uma população de soluções aleatórias, aqui denominado enxame. Entretanto, esta população apresenta diferenças, pois para cada solução potencial se atribui uma velocidade- i , \mathbf{v}_i , e as potenciais soluções, chamadas de partículas, são “guiadas” através do espaço de soluções.

Cada partícula possui uma posição, \mathbf{x}_i , dentro do espaço de soluções, estando esta posição ligada com a melhor solução encontrada pela partícula- i até o momento t , \mathbf{pbest}_i . Outra solução associada a posição da partícula trata-se da melhor solução global, ou seja, a melhor solução encontrada pelo enxame- i até o momento t , \mathbf{gbest} .

O funcionamento do PSO fundamenta-se na atualização da velocidade de cada partícula por meio do \mathbf{pbest} e \mathbf{gbest} e, posteriormente, de sua posição (Equações 2.13 e 2.14).

$$\mathbf{v}_i^{t+1} = \omega \mathbf{v}_i^t + r_1 \phi_1 (\mathbf{pbest}_i^t - \mathbf{x}_i^t) + r_2 \phi_2 (\mathbf{gbest} - \mathbf{x}_i^t) \quad (2.13)$$

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + \mathbf{v}_i^{t+1} \quad (2.14)$$

onde, ω é o fator de inércia, responsável por promover um balanço entre a exploração global e local. O fator de inércia está relacionado com o “passo” do método. Caso o seu valor seja alto demais, as partículas podem passar por boas soluções sem as visitá-las; já se o seu valor for baixo demais, as partículas podem não explorar suficientemente locais que possuem boas soluções. Os termos ϕ_1 e ϕ_2 representam, respectivamente, o grau de confiança da partícula na melhor solução encontrada por ela, $pbest_i$, e na melhor solução encontrada pelo enxame, $gbest$. Se os seus valores forem muito baixos, as partículas “voarão” por rotas mais distantes em direção da região alvo, ou se os seus valores forem muito altos, as partículas realizarão movimentos abruptos em direção a região potencial. r_1 e r_2 são números aleatórios que variam entre 0 e 1.

A Figura 2.4 apresenta o fluxograma do Enxame de Partículas implementado neste trabalho.

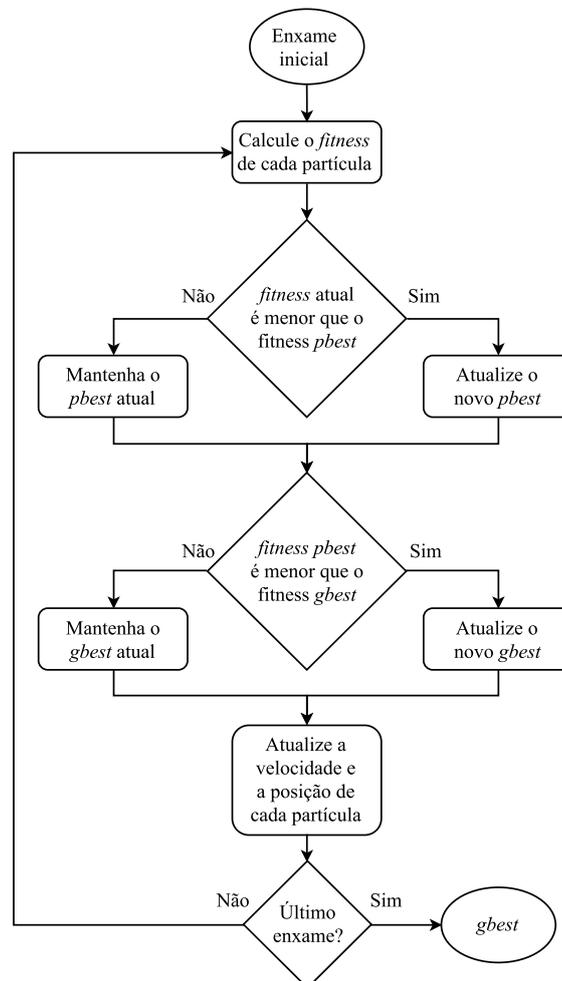


Figura 2.4: Etapas básicas do PSO utilizado

Algoritmo do Morcego – O Algoritmo do Morcego (*Bat Algorithm* - BA) é inspirado na característica de ecolocalização usada por morcegos durante seus movimentos de voo, graças a ela os morcegos possuem a capacidade de detectar presas e evitar obstáculos na total escuridão.

A ecolocalização baseia-se na emissão de ondas ultrassônicas e na correspondente medição do tempo gasto para estas ondas voltarem ao ponto de origem após serem refletidas pelo alvo ou obstáculo. A amplitude e o pulso dos sons emitidos pelos morcegos variam de acordo com a estratégia de caça. O controle da diversificação e intensificação do algoritmo é realizado com a variação entre a amplitude e a taxa de emissão de pulsos de cada morcego (ANDRÉ; PARPINELLI, 2014).

O BA é similar ao PSO, sendo inicialmente gerada uma população de soluções aleatórias, chamada de grupo. Além disto, para a caracterização de cada integrante ou morcegos- i deste grupo, se atribui uma velocidade- i , \mathbf{v}_i , e uma posição- i , \mathbf{x}_i . A principal diferença está na adição da frequência de emissão de pulso, f_i , na representação.

O funcionamento do BA baseia-se na atualização da frequência, da velocidade e posteriormente da posição de cada partícula, utilizando as Equações 2.15, 2.16 e 2.17.

$$f_i = f_{min} + (f_{max} - f_{min})\beta \quad (2.15)$$

$$\mathbf{v}_i^t = \mathbf{v}_i^{t-1} + (\mathbf{x}_i^t - \mathbf{x}_*)f_i \quad (2.16)$$

$$\mathbf{x}_i^t = \mathbf{x}_i^{t-1} + \mathbf{v}_i^t \quad (2.17)$$

onde $\beta \in [0, 1]$ é um vetor de números aleatórios com distribuição uniforme. f_{min} e f_{max} são a frequência mínima e máxima, respectivamente, que cada morcego pode assumir. Graças a Equação 2.15 a frequência terá um valor aleatório dentro do intervalo uniformemente distribuído $[f_{min}, f_{max}]$. \mathbf{x}_* , é a melhor solução encontrada atual, depois de comparar todas as soluções entre todos os morcegos.

O BA pode realizar uma busca local, para isto compara-se o valor de um número aleatório $rand \in [0, 1]$, com o valor da taxa de emissão de pulsos, r_i . Se $rand > r_i$, então realiza-se uma nova busca em torno da melhor solução atual. Essa busca é descrita pela Equação 2.18:

$$x_{new} = x_{old} + \epsilon A^t \quad (2.18)$$

onde $\epsilon \in [-1, 1]$ é um número aleatório, enquanto A^t é a média da amplitude de emissão do pulso de todos os morcegos até o momento.

A amplitude, A_i , e a taxa de emissão de pulsos, r_i , são atualizadas a cada interação utilizando as Equações 2.19 e 2.20.

$$A_i^{t+1} = \alpha A_i^t \quad (2.19)$$

$$r_i^{t+1} = r_i^0(1 - \exp^{-\gamma t}) \quad (2.20)$$

onde α e γ são constantes.

A escolha dos parâmetros, por exemplo, f_{min} e f_{max} , exige alguma experiência. Inicialmente, cada morcego pode ter diferentes valores de amplitude e taxa de emissão de pulsos, podendo isto ser conseguido por meio de inicialização aleatória (YANG, 2010).

A Figura 2.5 apresenta o fluxograma do Algoritmo do Morcego implementado neste trabalho.

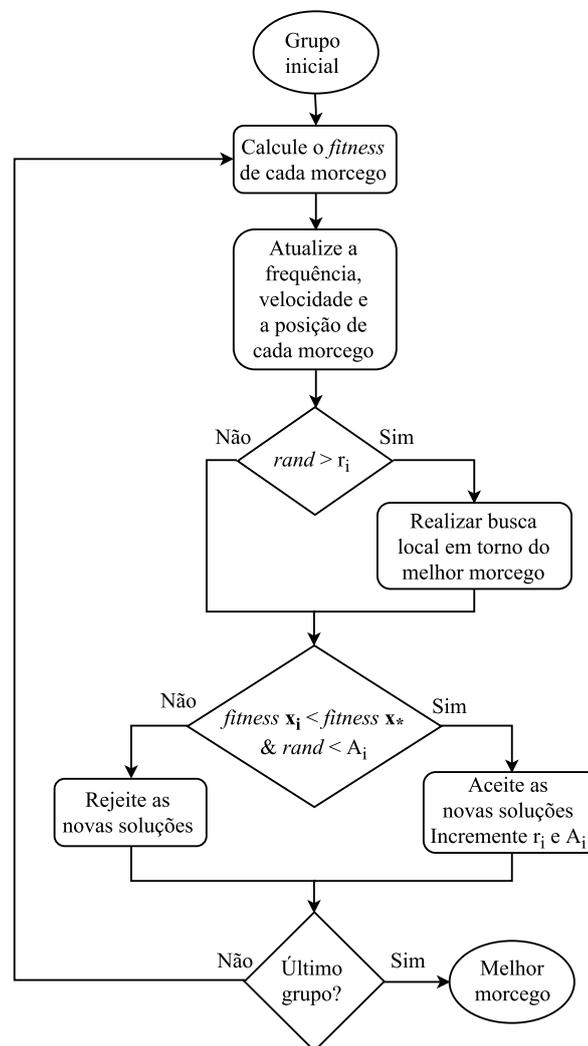


Figura 2.5: Etapas básicas do BA utilizado

2.2.4 Validação do modelo

A última etapa no processo de identificação é a validação do modelo estimado. O objetivo desta etapa é avaliar quanto o modelo é eficiente na representação da dinâmica do sistema a ser identificado.

Consequentemente, algumas perguntas serão feitas neste ponto do processo, como: o modelo é suficientemente bom? Ele pode ser utilizado? Os testes realizados são compatíveis com os dados observados? O modelo obtido é capaz de caracterizar o comportamento do sistema?

Aguirre (2004) explica que em problemas de validação, a questão chave é tentar determinar se um dado modelo é válido ou não. Em outras palavras, é necessário saber como o modelo será utilizado de forma a poder julgar se ele incorpora, ou não, as características requeridas. Essa necessidade advém do fato de que nenhum modelo, por definição, representará o sistema real em todos os aspectos. Portanto, ele apenas será considerado válido se incorporar aquelas características do sistema que são fundamentais para a aplicação em questão.

Simulação

Geralmente, a comparação da simulação do modelo obtido com os dados coletados é a forma mais usada para se validar um modelo. O objetivo é observar se o modelo reproduz ao longo do tempo os dados coletados.

Um cuidado básico é não utilizar o mesmo conjunto de dados de entradas na etapa de estimação dos parâmetros e na etapa de validação do modelo. A motivação para tal cuidado é simples, pois dado um modelo obtido a partir de um determinado conjunto de dados, deseja-se saber quão geral é o modelo.

Portanto, na prática, o ideal é efetuar dois testes independentes ao longo dos quais o sistema é observado gerando-se, assim, dois conjuntos de dados. Um deles é usado para a estimação dos parâmetros e o outro para a validação (AGUIRRE, 2004).

Capítulo 3

Metodologia

Neste capítulo será apresentada uma breve descrição do modelo de um sistema não linear. Além disto, também serão apresentados os sinais de entrada usados para estimação e validação do modelo, bem como definidos os parâmetros dos métodos utilizados na identificação do sistema.

3.1 Metodologia

Como explicado anteriormente, a maior motivação para a escolha dos modelos polinomiais é o fato dos mesmos serem lineares nos parâmetros, ou seja, modelos deste tipo podem ser representados na forma $y(k) = \psi^T \theta$ e, conseqüentemente, permitem a utilização do Método dos Mínimos Quadrados na estimação dos parâmetros.

O modelo polinomial NARMAX, previamente identificado por Cassini (1999), é dado pela Equação 3.1, com $n_y = 2$, $n_u = 2$ e $l = 2$. Por meio do modelo, deseja-se caracterizar a relação entre a tensão elétrica aplicada a um ferro de solda e a temperatura correspondente.

$$\begin{aligned} y(k) = & 1,3920y(k-1) - 0,4235y(k-2) \\ & - 0,4388u(k-2)y(k-1) + 0,3756u(k-2)y(k-2) \\ & + 0,0454u(k-1)^2 + 0,0218u(k-2)^2 \\ & + 0,0097u(k-2)u(k-1) \end{aligned} \quad (3.1)$$

Seguindo as especificações apresentadas no trabalho de Cassini (1999), dois conjuntos de sinais de entrada foram gerados. Os sinais são do tipo PRS com média igual a $0,5 pu$, sendo $1 pu$ correspondente a $136V$ na tensão de entrada e a $998,51^\circ C$ na temperatura do ferro de solda. O primeiro destes será usado para a estimação de parâmetros (Figura 3.1a) e o segundo para a validação dos modelos (Figura 3.1b).

A partir dos conjuntos de dados de entrada foram obtidas as respectivas saídas do sistema. A estas saídas foram adicionados ruídos brancos (Figuras 3.1c e 3.1d), com variação máxima de $\pm 0,0005 pu$, equivalente a uma amplitude de aproximadamente $1^\circ C$. Assim, as saídas ruidosas do sistema utilizadas na estimação de parâmetros e validação do modelo são apresentadas nas Figuras 3.1e e 3.1f.

Estas saídas foram comparadas com as saídas dos modelos obtidos por meio dos métodos de estimação estudados. A função de avaliação utilizada pelas metaheurísticas foi o somatório do erro quadrático (Equação 3.2), pois como explicado anteriormente, trata-se

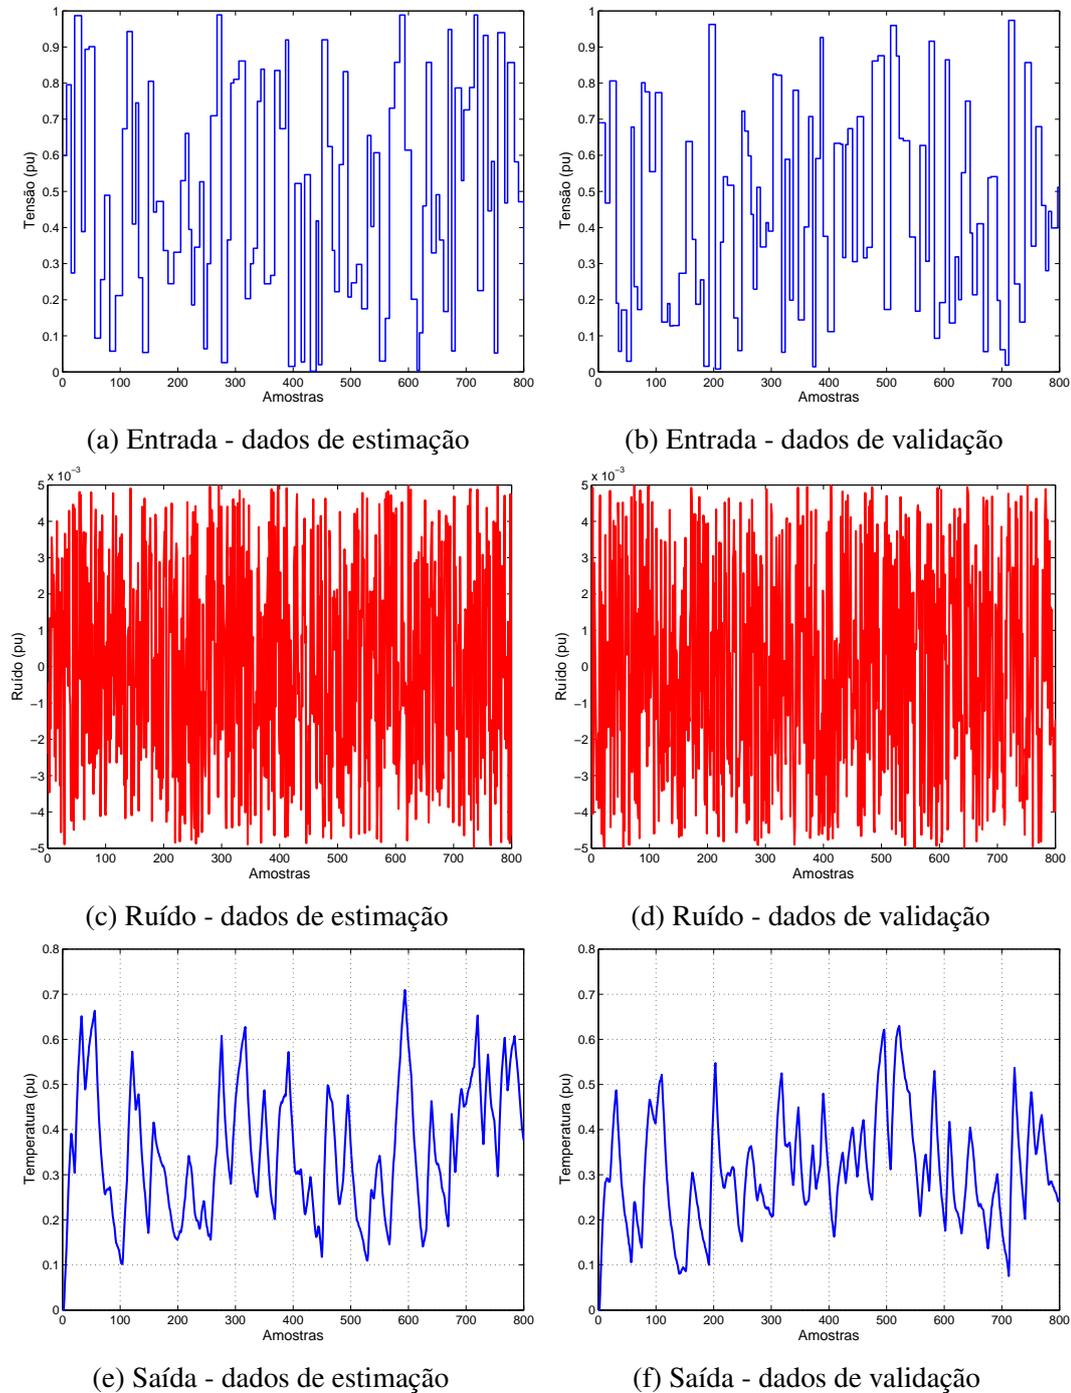


Figura 3.1: Dados de entrada, ruído branco e saída do sistema

da função objetivo do MMQ.

$$f_{AV} = \sum_{i=1}^N (y(i) - \hat{y}(i))^2 \quad (3.2)$$

As metaheurísticas foram executadas 50 vezes e cada execução continha um conjunto de 50 possíveis soluções, calculadas no decorrer de 100 iterações. Os valores de seus parâmetros foram definidos através de uma sucessão de testes e observações, até que fossem encontrados valores julgados adequados, ou seja, os parâmetros foram configurados empiricamente.

Tabela 3.1: Valores dos parâmetros utilizados em cada metaheurística

Metaheurística	Parâmetros	
GA	t_{mut}	2,5%
PSO	ω	0,001
	ϕ_1	1,3
	ϕ_2	1,3
BA	f_{min}	0,0005
	f_{max}	0,0015
	α	0,79
	γ	0,79

As velocidades iniciais do PSO e BA foram definidas com valor em 0, ou seja, as partículas e morcegos inicialmente estão parados; além disto, a amplitude inicial, A^0 , e a taxa de emissão de pulsos inicial, r^0 , do BA, tiveram seus valores estabelecidos em 1.

Capítulo 4

Resultados

Neste capítulo serão apresentados os modelos estimados pelos diferentes métodos utilizados na identificação do sistema não linear apresentado no Capítulo 3, além de uma comparação entre o modelo base e os modelos obtidos por meio do MMQ e as metaheurísticas.

4.1 Modelos estimados

O modelo base e os modelos obtidos por meio do MMQ e as metaheurísticas foram submetidos aos conjuntos de dados de entrada apresentados no Capítulo 3. Cada método teve sua curva de saída comparada com a curva de saída do modelo base. Ademais, também foi apresentado o gráfico do erro entre as curvas de saída para uma melhor análise.

4.1.1 Modelo estimado pelo MMQ

As saídas do modelo estimado por meio do MMQ e do modelo base, para os dados de entrada de estimação, são apresentadas na Figura 4.1.

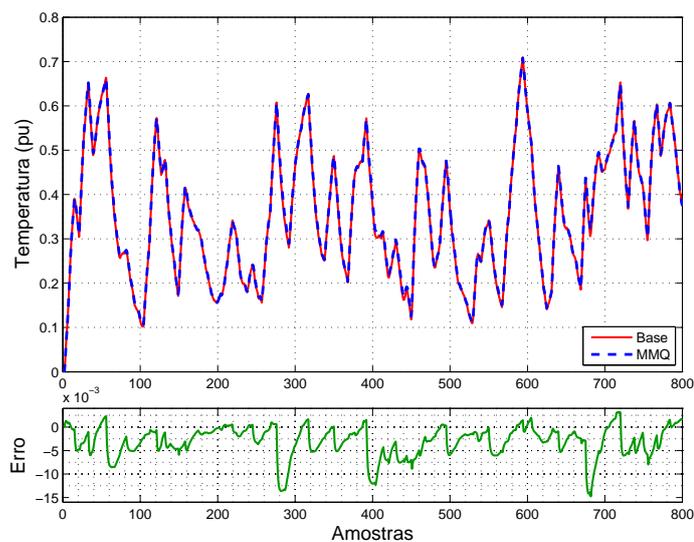


Figura 4.1: Saída para dados de entrada de estimação - MMQ

Como pode ser observado, o modelo estimado tem uma boa resposta, representando satisfatoriamente a dinâmica do sistema. Logo abaixo é apresentado o gráfico do erro entre as curvas de saída, de modo que o valor máximo do módulo do erro foi de 0,01477375. Além disso, o valor resultante da função de avaliação foi de 0,01581171.

As saídas do modelo estimado por meio do MMQ e do modelo base, para os dados de entrada da validação, são apresentadas na Figura 4.2.

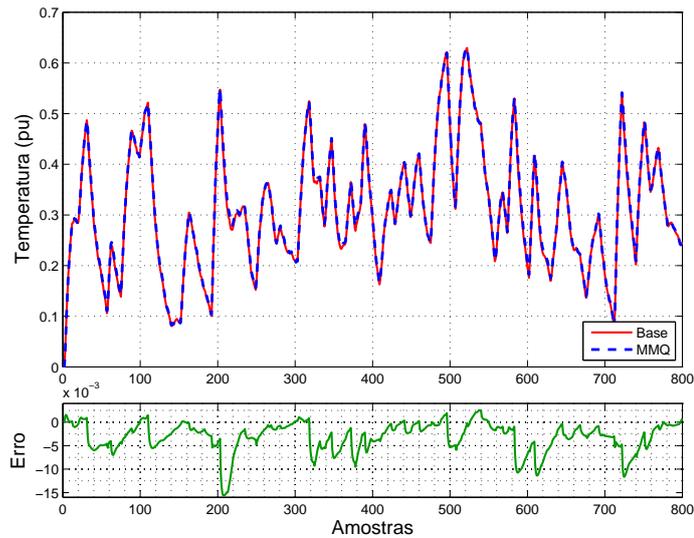


Figura 4.2: Saída para dados de entrada de validação - MMQ

A curva da saída obtida pelo modelo estimado por meio do MMQ, usando os dados de validação, confirma a capacidade de generalização do modelo, sendo o valor máximo do módulo do erro de 0,01552081.

Na Tabela 4.1 encontram-se os valores dos parâmetros obtidos pelo MMQ e para os regressores do modelo polinomial NARMAX para o sistema não linear estudado. Para comparação, a tabela também contém os valores dos parâmetros do modelo base.

Tabela 4.1: Parâmetros estimados pelo MMQ

Regressores	Parâmetros	
	MMQ	Base
$y(k-1)$	1,4034955	1,3920000
$y(k-2)$	-0,4335032	-0,4235000
$y(k-1)u(k-2)$	-0,4027270	-0,4388000
$y(k-2)u(k-2)$	0,3405760	0,3756000
$u(k-1)u(k-2)$	-0,0014812	0,0097000
$u(k-1)^2$	0,0482678	0,0454000
$u(k-2)^2$	0,0273910	0,0218000

4.1.2 Modelo estimado pelo GA

As saídas do modelo estimado por meio do GA e do modelo base, para os dados de entrada de estimação, são apresentadas na Figura 4.3.

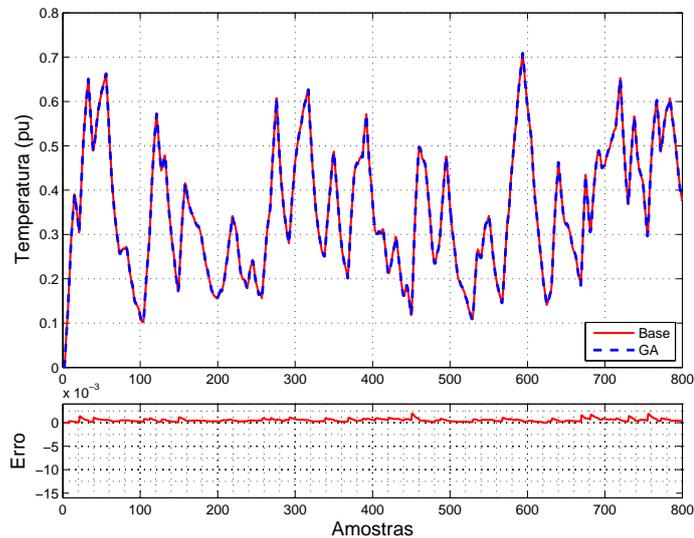


Figura 4.3: Saída para dados de entrada de estimação - GA

Como pode ser observado, o modelo estimado por meio do GA apresenta uma resposta ainda melhor do que a obtida pelo MMQ. Isso é comprovado por meio do gráfico do erro entre as curvas de saída, no qual o valor máximo do módulo do erro foi de 0,00198035, menor do que o obtido pelo MMQ. Além disso, o GA apresentou um valor da função de avaliação menor, da ordem de 0,00030943.

As saídas do modelo estimado por meio do GA e do modelo base, para os dados de entrada da validação, são apresentadas na Figura 4.4.

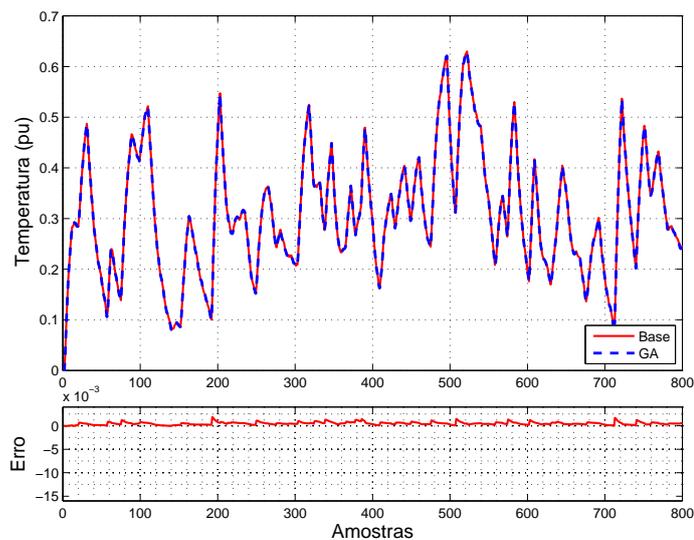


Figura 4.4: Saída para dados de entrada de validação - GA

Como era esperado, a curva da saída obtida pelo modelo estimado por meio do GA, para os dados de validação, confirma a capacidade de generalização do modelo, sendo o valor máximo do módulo do erro de 0,00184879.

Na Tabela 4.2 encontram-se os valores dos parâmetros obtidos pelo GA e os valores dos parâmetros do modelo base.

Tabela 4.2: Parâmetros estimados pelo GA

Regressores	Parâmetros	
	GA	Base
$y(k-1)$	1,38836710	1,39200000
$y(k-2)$	-0,42004033	-0,42350000
$y(k-1)u(k-2)$	-0,43513483	-0,43880000
$y(k-2)u(k-2)$	0,37192850	0,37560000
$u(k-1)u(k-2)$	0,01180341	0,00970000
$u(k-1)^2$	0,04355906	0,04540000
$u(k-2)^2$	0,02162702	0,02180000

4.1.3 Modelo estimado pelo PSO

As saídas do modelo estimado por meio do PSO e do modelo base, para os dados de entrada de estimação, são apresentadas na Figura 4.5.

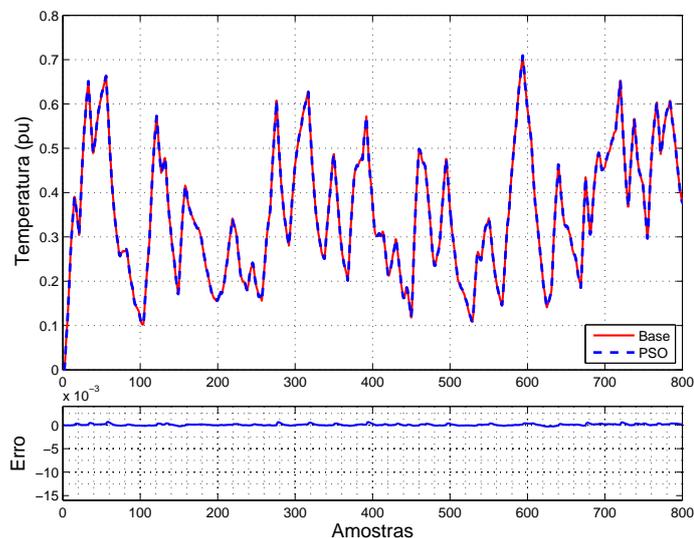


Figura 4.5: Saída para dados de entrada de estimação - PSO

Como pode ser observado, o modelo estimado por meio do PSO apresenta uma resposta melhor do que a obtida pelo GA e, conseqüentemente, melhor que o MMQ. Isto é confirmado por meio do gráfico do erro entre as curvas de saída, no qual o valor máximo

do módulo do erro foi de 0,00070284, menor do que os apresentados pelo MMQ e GA. O PSO também apresentou um valor da função de avaliação menor, de 0,00003002.

As saídas do modelo estimado por meio do PSO e do modelo base, para os dados de entrada da validação, são apresentadas na Figura 4.6.

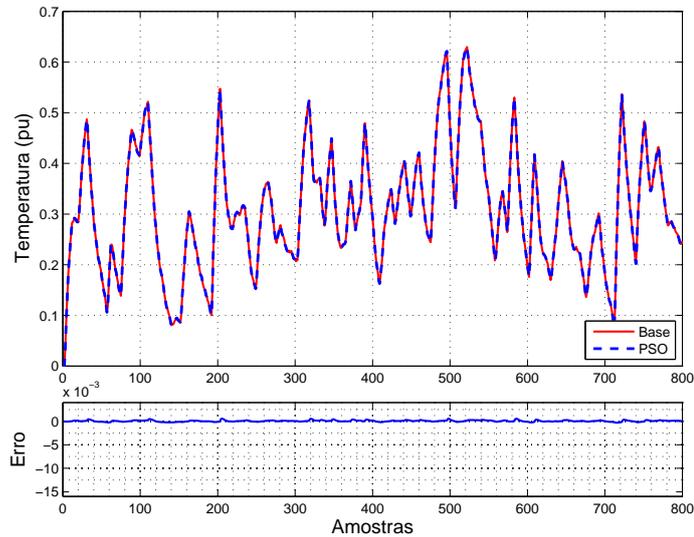


Figura 4.6: Saída para dados de entrada de validação - PSO

Assim como o MMQ e o GA, a curva da saída obtida pelo modelo estimado por meio do PSO, para os dados de validação, demonstra a capacidade de generalização do modelo e de representar a dinâmica do sistema. Sendo o valor máximo do módulo do erro de 0,00057008, também menor do que os valores apresentados pelos modelos estimados por meio do MMQ e do GA.

Na Tabela 4.3 encontram-se os valores dos parâmetros obtidos pelo PSO e os valores dos parâmetros do modelo base.

Tabela 4.3: Parâmetros estimados pelo PSO

Regressores	Parâmetros	
	PSO	Base
$y(k-1)$	1,38929230	1,39200000
$y(k-2)$	-0,42085670	-0,42350000
$y(k-1)u(k-2)$	-0,43715353	-0,43880000
$y(k-2)u(k-2)$	0,37380917	0,37560000
$u(k-1)u(k-2)$	0,01021538	0,00970000
$u(k-1)^2$	0,04540159	0,04540000
$u(k-2)^2$	0,02141478	0,02180000

4.1.4 Modelo estimado pelo BA

As saídas do modelo estimado por meio do BA e do modelo base, para os dados de entrada de estimação, são apresentadas na Figura 4.7.

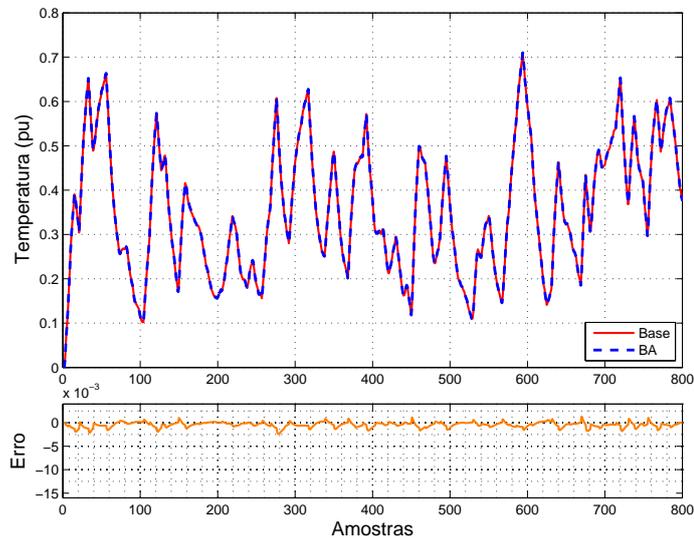


Figura 4.7: Saída para dados de entrada de estimação - BA

Como pode ser observado o modelo estimado por meio do BA também apresenta uma resposta melhor do que as obtidas pelo MMQ e GA. O que é, mais uma vez, comprovado por meio do gráfico do erro entre as curvas de saída, no qual o valor máximo do módulo do erro foi de 0,00238161, menor do que o MMQ e o GA. Além disso, o BA apresentou um valor da função de avaliação menor, de 0,00039527.

As saídas do modelo estimado por meio do BA e do modelo base, para os dados de entrada da validação, são apresentadas na Figura 4.8.

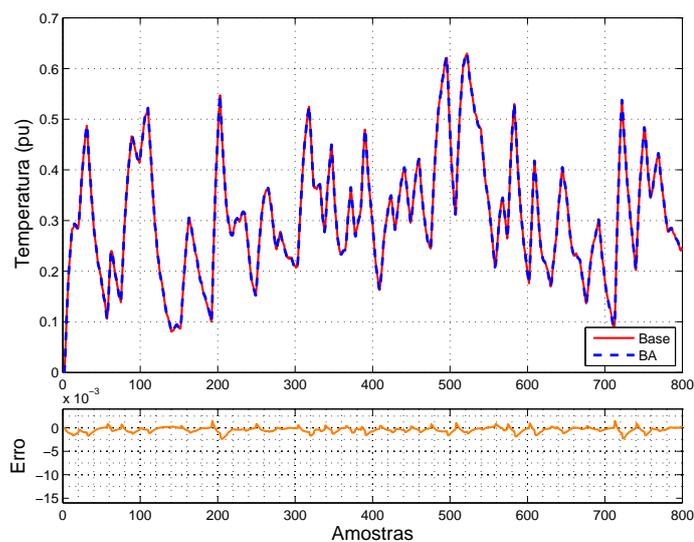


Figura 4.8: Saída para dados de entrada de validação - BA

Da mesma forma que os outros métodos, a curva da saída obtida pelo modelo estimado por meio do BA, para os dados de validação, representa bem a dinâmica do sistema, sendo o valor máximo do módulo do erro de 0,00237098, também menor do que os valores apresentados pelos modelos estimados por meio do MMQ e do GA.

Na Tabela 4.4 encontram-se os valores dos parâmetros obtidos pelo BA e os valores dos parâmetros do modelo base.

Tabela 4.4: Parâmetros estimados pelo BA

Regressores	Parâmetros	
	BA	Base
$y(k-1)$	1,39041106	1,39200000
$y(k-2)$	-0,42208219	-0,42350000
$y(k-1)u(k-2)$	-0,43880195	-0,43880000
$y(k-2)u(k-2)$	0,37506310	0,37560000
$u(k-1)u(k-2)$	0,01024293	0,00970000
$u(k-1)^2$	0,04387836	0,04540000
$u(k-2)^2$	0,02336843	0,02180000

4.1.5 Comparação geral

Nesta seção é apresentada uma comparação gráfica das curvas do erro da saída do modelo base e dos modelos estimados, além de alguns dados estatísticos a respeito das metaheurísticas utilizadas.

Abaixo (Figura 4.9), são apresentadas as curvas do erro para os diferentes métodos de estimação dos parâmetros utilizados.

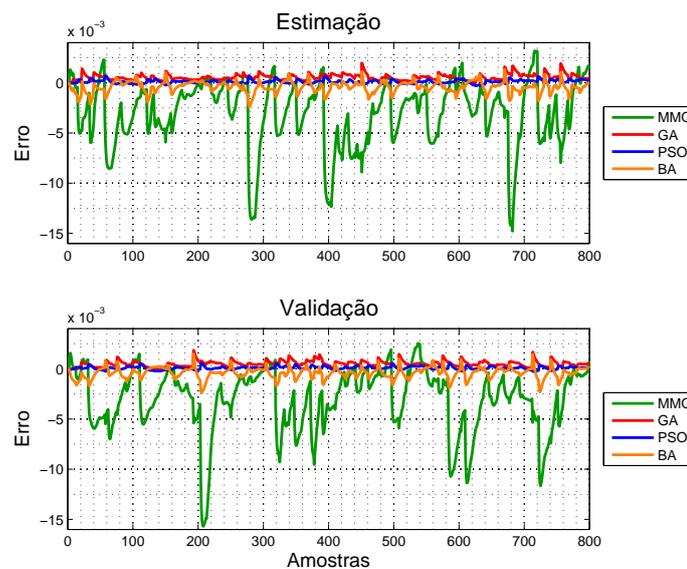


Figura 4.9: Curvas do erro entre a saída do modelo base e os modelos estimados

Na parte superior da Figura 4.9, as curvas de erro se referem à saída do modelo quando aplicados os dados de entrada para estimação. Já na parte inferior, as curvas de erro dizem respeito à saída do modelo ao aplicarmos os dados de entrada para a validação. Podemos observar que o modelo estimado por meio do PSO apresenta o menor módulo do erro, seguido pelo o GA, o BA e MMQ, respectivamente, tanto para os conjuntos de dados de entrada de estimação quanto para os de validação.

Como explicado anteriormente no Capítulo 3, as metaheurísticas foram executadas 50 vezes, cada execução continha um conjunto de 50 possíveis soluções, calculados no decorrer de 100 interações. A cada execução da metaheurística utilizada, fosse o GA, o BA ou PSO, uma nova solução é gerada, de tal forma que ao final das execuções possuímos 50 soluções de cada metaheurística para o problema estudado. A média e o desvio padrão dos parâmetros estimados nas 50 execuções são apresentados nas Tabelas 4.5 e 4.6, respectivamente.

Tabela 4.5: Média dos parâmetros estimados

Regressores	Parâmetros			
	Média			Base
	GA	PSO	BA	
$y(k-1)$	1,39159322	1,39196703	1,39441465	1,39200000
$y(k-2)$	-0,42294669	-0,42344766	-0,42595370	-0,42350000
$y(k-1)u(k-2)$	-0,43845361	-0,43862139	-0,44306482	-0,43880000
$y(k-2)u(k-2)$	0,37421644	0,37524759	0,37920552	0,37560000
$u(k-1)u(k-2)$	0,01061355	0,01000807	0,01032765	0,00970000
$u(k-1)^2$	0,04465082	0,04497633	0,04482774	0,04540000
$u(k-2)^2$	0,02219182	0,02199803	0,02227247	0,02180000

Tabela 4.6: Desvio padrão dos parâmetros estimados

Regressores	GA	PSO	BA
$y(k-1)$	0,00525480	0,00585166	0,00567832
$y(k-2)$	0,00485375	0,00554628	0,00530018
$y(k-1)u(k-2)$	0,00703910	0,00588343	0,00590444
$y(k-2)u(k-2)$	0,00871521	0,00553553	0,00590660
$u(k-1)u(k-2)$	0,00155378	0,00140963	0,00090970
$u(k-1)^2$	0,00200464	0,00181028	0,00158434
$u(k-2)^2$	0,00135271	0,00130179	0,00088325

Por meio da Tabela 4.5, podemos observar que a média dos parâmetros estimados por meio do PSO é a que mais se aproxima dos valores dos parâmetros do modelo base, seguido pelo o GA e o BA, respectivamente. No entanto, a média dos parâmetros do BA para os regressores $u(k-1)u(k-2)$ e $u(k-1)^2$ aproxima-se mais dos parâmetros do modelo base que a média dos parâmetros do GA para os mesmos regressores. Já a

Tabela 4.6, informa que o GA apresenta um menor desvio padrão para o valor dos parâmetros dos regressores $y(k-1)$ e $y(k-2)$, o PSO para $y(k-1)u(k-2)$ e $y(k-2)u(k-2)$ e, finalmente, o BA para $u(k-1)u(k-2)$, $u(k-1)^2$ e $u(k-2)^2$.

Para uma melhor visualização dos dados é apresentado o *boxplot* (Figura 4.10) de cada parâmetro estimado por meio das metaheurísticas.

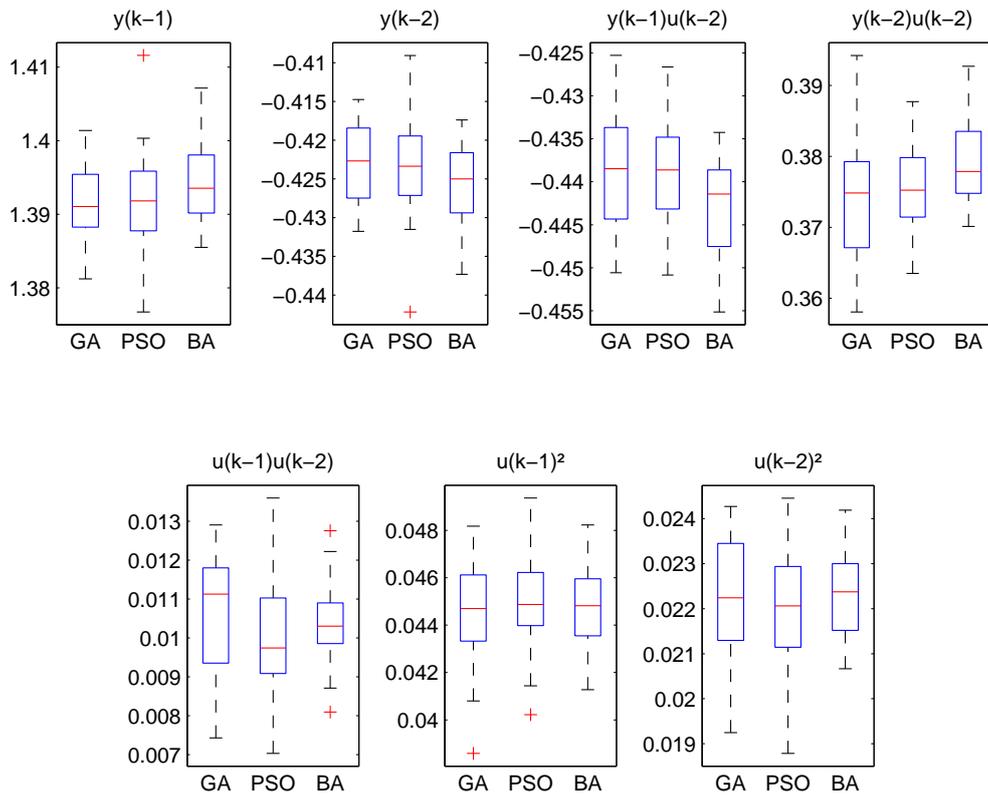


Figura 4.10: *Boxplot* dos parâmetros estimados

O *boxplot*, também conhecido como diagrama de caixa, trata-se de um gráfico que informa importantes características de um conjunto de dados por meio de cinco números, os quais são: valor mínimo, primeiro quartil, segundo quartil, terceiro quartil e valor máximo. Os pontos representados por "+" são os *outliers*.

Dependendo do parâmetro estimado, as metaheurísticas apresentam maior ou menor dispersão. Além disso, em ao menos um parâmetro estimado por meio das metaheurísticas notou-se *outliers*, o GA para $u(k-1)^2$; o PSO para $y(k-1)$, $y(k-2)$ e $u(k-1)^2$; e o BA para $u(k-1)u(k-2)$.

Capítulo 5

Conclusão

Neste trabalho foram utilizados métodos não convencionais na estimação de parâmetros de um modelo não linear, os quais são, o Algoritmo Genético, a Otimização por Enxame de Partículas e o Algoritmo do Morcego. Ao final, foi realizada uma comparação da estimação dos parâmetros do modelo entre o tradicional Método dos Mínimos Quadrados e as metaheurísticas anteriormente citadas.

Os resultados de estimação dos parâmetros do modelo mostraram-se satisfatórios, uma vez que os modelos estimados foram capazes de representar a dinâmica do sistema, tendo suas características de generalização comprovadas através do conjunto dos dados de entrada de validação.

A partir dos resultados, pôde-se notar que, para o problema estudado, o PSO foi o método que mais se aproximou do modelo previamente identificado, seja na média dos parâmetros das soluções de cada execução, seja na melhor solução dentre as melhores soluções de todas as repetições; apresentando um menor valor de erro entre a saída do modelo estimado e a saída do modelo base, tanto para o conjunto de dados de entrada usado na estimação, quanto para o conjunto de dados de entrada usado na validação.

Entretanto, é importante ressaltar que as outras metaheurísticas também apresentaram resultados semelhantes, aproximando-se do resultado encontrado pelo PSO, de tal forma, que um melhor ajuste dos parâmetros dessas metaheurísticas pode ocasionar a obtenção de melhores resultados, seja modificando o número de integrantes da população, ou o número de interações ou os parâmetros particulares de cada método, como taxa de mutação e método de seleção dos pais para o AG e f_{min} , f_{max} , amplitude e taxa de emissão de pulsos para o BA.

Por fim, os resultados demonstraram a potencial aplicação das metaheurísticas na estimação dos parâmetros de modelos não lineares. Apresentando desempenho superior a técnica normalmente utilizada, o clássico Método dos Mínimos Quadrados.

Para trabalhos futuros, as metaheurísticas estudadas podem ser usadas na otimização da estrutura de modelos e em outras representações não lineares, também podem ser usadas na estimação de parâmetros não lineares, assim como a utilização de metaheurísticas diferentes do GA, PSO e BA, e técnicas híbridas, entre outras investigações.

Referências Bibliográficas

AGUIRRE, L. A. *Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais*. 2. ed. Belo Horizonte: Editora UFMG, 2004.

AGUIRRE, L. A.; BILLINGS, S. A. Dynamical effects of overparametrization in nonlinear models. *Physica D: Nonlinear Phenomena*, Elsevier, v. 80, n. 1, p. 26–40, 1995.

AGUIRRE, L. A.; RODRIGUES, G. G.; JACOME, C. R. Identificação de sistemas não-lineares utilizando modelos NARMAX polinomiais – uma revisão e novos resultados. *SBA Controle e Automação*, v. 9, n. 2, p. 90–106, 1998.

AKRAMIZADEH, A.; FARJAMI, A.; KHALOOZADEH, H. Nonlinear hammerstein model identification using genetic algorithm. In: *Artificial Intelligence Systems, 2002. (ICAIS 2002)*. 2002 IEEE International Conference on. [S.l.: s.n.], 2002. p. 351–356.

ANDRÉ, L.; PARPINELLI, R. S. Tutorial sobre o uso de técnicas para controle de parâmetros em algoritmos de inteligência de enxame e computação evolutiva. *Revista de Informática Teórica e Aplicada*, v. 21, n. 2, p. 90–135, 2014.

ARAÚJO JÚNIOR, J. M. de. *Identificação não linear usando uma rede fuzzy wavelet neural network modificada*. Tese (Doutorado) — Universidade Federal do Rio Grande do Norte, Natal, 2014.

CASSINI, C. C. da S. *Estimação recursiva de características estáticas não lineares utilizando modelos polinomiais NARMAX*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, 1999.

CHEN, S.; BILLINGS, S. A. Representations of non-linear systems: the NARMAX model. *Int. J. Control*, v. 49, n. 3, p. 1013–1032, 1989.

COELHO, A. A. R.; COELHO, L. dos S. *Identificação de Sistemas Dinâmicos Lineares*. 1. ed. Florianópolis: Editora da UFSC, 2004.

COELHO, L. dos S.; COELHO, A. A. R. Algoritmos evolutivos em identificação e controle de processos: Uma visão integrada e perspectivas. *Controle & Automação*, (Impresso), v. 10, n. 1, p. 13–30, 1999.

COELHO, M. C. S.; AGUIRRE, L. A.; CORREA, M. V. Metodologia para representação de modelos NARX polinomiais na forma de Hammerstein e Wiener. *Tendências em Matemática Aplicada e Computacional*, v. 3, n. 1, p. 71–80, 2002.

- DANTAS, A. D. O. da S. *Identificação de modelos polinomiais NARX utilizando algoritmos combinados de detecção de estruturas e estimação de parâmetros com aplicações práticas*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, Natal, 2013.
- EBERHART, R. C.; SHI, Y. Particle swarm optimization: developments, applications and resources. In: IEEE. *Evolutionary Computation, 2001. Proceedings of the 2001 Congress on*. [S.l.], 2001. v. 1, p. 81–86.
- GOLNARAGHI, F.; KUO, B. C. *Sistemas de Controle Automático*. 9. ed. Rio de Janeiro: LTC, 2012.
- HOLLAND, J. H. *Adaptation in natural and artificial systems*. 1. ed. Cambridge, MA: MIT Press, 1975.
- ISERMANN, R.; LACHMANN, K.-H. Parameter adaptive control with configuration aids and supervision functions. *Automatica*, v. 16, p. 575–587, 1985.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. *IEEE International Conference on Neural Networks*, Piscataway, NJ, p. 1942–1948, 1995.
- LATHI, B. P. *Sinais e Sistemas Lineares*. 2. ed. Porto Alegre: Bookman, 2007.
- LI, C.; JEON, Y. Genetic algorithm in identifying non linear auto regressive with exogenous input models for non linear systems. In: *American Control Conference, 1993*. [S.l.: s.n.], 1993. p. 2305–2309.
- LINHARES, L. L. da S. *Critério de correntropia no treinamento de redes fuzzy wavelet neural networks para identificação de sistemas dinâmicos não lineares*. Tese (Doutorado) — Universidade Federal do Rio Grande do Norte, Natal, 2015.
- LIU, J.; XU, W.; SUN, J. Nonlinear system identification of hammerstien and wiener model using swarm intelligence. In: *Information Acquisition, 2006 IEEE International Conference on*. [S.l.: s.n.], 2006. p. 1219–1223.
- LJUNG, L. *System identification: theory for the user*. New Jersey: Prentice-Hall, 1999.
- MARTINS, J. K. E. da C. *Identificação de sistemas dinâmicos não lineares com aplicações na indústria do petróleo e gás*. Trabalho de Conclusão de Curso — Universidade Federal do Rio Grande do Norte, Natal, 2015.
- MARTINS, J. K. E. da C.; SOUZA, F. R. de L.; ARAUJO, F. M. U. de. Identificação de um sistema de tanques acoplados não linear com atraso utilizando RNA. *Rio Automação*, 2015.
- OSMAN, I. H.; LAPORTE, G. Metaheuristics: a bibliography. *Annals of operations research*, Springer, v. 63, n. 5, p. 511–623, 1996.

SANTOS, J. E.; SUMAR, R. R.; COELHO, A. A. Uma solução para a multiplicidade da lei de controle preditivo para o modelo de hammerstein. In: *XV Congresso Brasileiro de Automática*. [S.l.: s.n.], 2004.

SUPENI, E.; YASSIN, I.; AHMAD, A.; RAHMAN, F. Narmax identification of dc motor model using repulsive particle swarm optimization. In: *Signal Processing Its Applications, 2009. CSPA 2009. 5th International Colloquium on*. [S.l.: s.n.], 2009. p. 1–7.

YANG, X.-S. A new metaheuristic bat-inspired algorithm. In: *Nature inspired cooperative strategies for optimization (NICSO 2010)*. [S.l.]: Springer Berlin Heidelberg, 2010. p. 65–74.