

Metodologia de Estimação da Estrutura de um Modelo NARMAX para Módulos Termoelétricos Baseada na Implementação do Algoritmo PSO

Daniel R. Ojeda, Luiz A. L. de Almeida, Omar A. C. Vilcanqui
Pós-Graduação em Engenharia da Informação - Universidade Federal do ABC - UFABC
Santo André, São Paulo, Brasil
Email: {daniel.ojeda, luiz.almeida}@ufabc.edu.br, omarchu@gmail.com

Resumo—Um dos maiores desafios na obtenção de modelos NARMAX (*Nonlinear Auto-Regressive Moving Average model with exogenous inputs*) para sistemas dinâmicos não-lineares é a definição ou seleção da estrutura do modelo. Para este propósito, diversas metodologias têm sido propostas na literatura, mas podem se tornar entediantes e ainda resultar em desempenhos insatisfatórios. Alternativamente, o uso das meta-heurísticas tem se mostrado eficiente na resolução de problemas semelhantes. Para usar o algoritmo de otimização baseado no enxame de partículas (*PSO-Particle Swarm Optimization*) é escolhido com antecedência um número fixo de combinações de termos para o modelo NARMAX. Para cada um dos termos existe um peso e um atraso correspondente. Sabe-se que o modelo NARMAX é linear nos parâmetros de peso, que podem ser obtidos quando utilizada a técnica dos mínimos quadrados ordinários (MQO). Em cada iteração o algoritmo PSO estimará os atrasos que vão estar presentes no modelo em conjunto com os pesos obtidos por MQO. O erro para a próxima interação é obtido com este conjunto de pesos e atrasos. Um modelo não-linear de um Módulo Termoelétrico (*TEM-Thermoelectric Module*) será utilizado em um dispositivo de recuperação de energia residual de calor para a conversão em energia elétrica. Resultados de simulação serão apresentados com o intuito de mostrar a efetividade da metodologia proposta.

Palavras-chave—Identificação de sistemas não-lineares, Modelos NARMAX, Módulos termoelétricos, Algoritmo PSO, Estimação de parâmetros.

I. INTRODUÇÃO

Uma das discussões mais importantes na área de identificação de sistemas não-lineares mediante modelos NARMAX, consiste na seleção da estrutura para representar o comportamento dinâmico do sistema original [1], [2]. Embora existam várias pesquisas focadas na detecção da estrutura, esta é ainda uma questão que parece não ter uma resposta definitiva [3], [4]. As aproximações baseadas em modelos lineares seriam limitadas e representariam as dinâmicas dos sistemas em um ponto de operação. Para superar estas limitações foi utilizada uma abordagem baseada na implementação de modelos NARMAX. Tanto a estrutura quanto os parâmetros do modelo foram obtidos da observação na saída do sistema quando aplicado um sinal de excitação na entrada do mesmo [4], [5], [6], tornando-se possível reproduzir o comportamento dinâmico sem aproximações nem simplificações lineares. A informação, “a priori”, sobre as dinâmicas do sistema proposto tornar-se-á um elemento relevante na

determinação da estrutura do modelo NARMAX. Dessa forma isto resultará em modelos melhores, e principalmente, modelos fisicamente mais significativos, usualmente chamados de “Identificação Caixa-Cinza” [7]. O sinal de excitação deve ser projetado para satisfazer um conjunto de propriedades que garantirão a adequabilidade dos dados obtidos. Este deve apresentar um espectro suficientemente amplo em frequência e amplitude, de tal forma que excursione o sistema pelos regimes dinâmicos de interesse. No caso dos TEM, estes são dispositivos com características dinâmicas não-lineares. Seu uso em diversos setores da indústria está em constante ascensão devido as vantagens que oferecem em relação aos conversores de energia convencionais [8]. No entanto, muita incerteza ainda existe sobre as dinâmicas não-lineares, dado que os modelos matemáticos existentes descrevem o comportamento assumindo linearidade em uma determinada faixa de operação limitada. Nesse contexto, aplicações que requerem alta precisão, como no caso de circuitos para a conversão termoelétrica e o aproveitamento do calor do corpo [9], [10], precisam de modelos que consigam reproduzir adequadamente o comportamento dos TEM.

Por outro lado, a obtenção de modelos não-lineares demanda mais trabalho do que para modelos lineares, implicando grande esforço computacional para serem resolvidos. Uma das alternativas baseia-se na implementação do método meta-heurístico de otimização por enxame de partículas (PSO) desenvolvido no início dos anos 90 [11]. Consiste em uma técnica de otimização estocástica robusta, não-linear, inspirada em fenômenos que acontecem na natureza. Este método não exige do usuário um conhecimento profundo do problema a ser otimizado e é possível obter excelentes soluções em intervalos de tempos curtos e consumo de recursos razoáveis.

Este trabalho visa explicar o desenvolvimento de uma metodologia baseada na implementação do algoritmo PSO e a técnica dos MQO, para a obtenção de uma estrutura NARMAX utilizada para reproduzir as dinâmicas de um sistema de aproveitamento da energia térmica mediante o uso de TEM's. O sinal de excitação aplicado no sistema consiste em um ruído branco que foi previamente filtrado, de forma a evitar os efeitos decorrentes com as dinâmicas bruscas do processo e os tempos de simulação, resultando em um sinal suficiente amplo em frequências e amplitude para estimar os

parâmetros da estrutura NARMAX estabelecida.

II. IDENTIFICAÇÃO DE SISTEMAS NÃO-LINEARES BASEADA EM MÉTODOS NARMAX

A metodologia de identificação de sistemas não-lineares mediante métodos NARMAX pode ser estruturada em cinco etapas principais [5]:

A. Aquisição de conjunto de dados

Nesta etapa do processo de identificação o sistema deve ser submetido a um sinal de excitação adequado e a observação das saídas correspondentes. A qualidade do modelo obtido estará intimamente ligada com as características do sinal de entrada que deve ser projetado de forma a explorar o sistema em toda a faixa de frequências de interesse.

B. Detecção de estrutura

Constitui a parte mais importante da metodologia NARMAX. Uma estrutura de um modelo NARMAX com período de amostragem padrão é mostrada na equação 1. Sendo $t = 1 \dots N$; F' uma função não-linear qualquer; $y(t)$, $\mu(t)$ e $e(t)$ a saída, a entrada e o ruído aditivo do sistema respectivamente, cujos atrasos máximos são representados por n_y , n_μ , n_e ; d representa o tempo morto do sistema, geralmente é atribuído um valor de $d = 1$. Este modelo é essencialmente uma expansão das entradas, as saídas e os termos de ruído atrasados no tempo.

$$y(k) = F' \left[y(k-1), y(k-2), \dots, y(k-n_y), \mu(k-d), \mu(k-d-1), \dots, \mu(k-d-n_\mu), e(k-1), e(k-2), \dots, e(k-n_e) \right] + e(k) \quad (1)$$

C. Estimação de parâmetros

Determinada a estrutura do modelo, devem-se estimar os parâmetros de forma a ajustar o comportamento dinâmico do sistema original. Várias técnicas têm sido empregadas na estimação dos parâmetros, sendo o algoritmo dos MQ o mais implementado.

D. Validação do modelo

Consiste na verificação de que o modelo se comporta de maneira suficientemente satisfatória com relação aos objetivos do estudo. O modelo então é validado e comparado com o intuito de encontrar a forma mais simples de representar as dinâmicas observadas no sistema original [5].

E. Análise

Somente quando a detecção de estrutura e de todos os procedimentos de validação forem satisfeitos, considerar-se-á o modelo como uma boa representação do sistema [5]. Os modelos obtidos são então usados para entender quais as propriedades dinâmicas do sistema e como reage quando exposto a diferentes condições de operação.

III. ALGORITMO DE OTIMIZAÇÃO BASEADA NO ENXAME DE PARTÍCULAS PSO

O método de otimização por enxame de partículas (PSO) foi originalmente desenvolvido pelo psicólogo-sociólogo James Kennedy e pelo engenheiro eletrônico Russell Eberhart, em 1995. É uma técnica meta-heurística baseada nas populações e inspirada no comportamento social do vôo das aves em procura do alimento, ou no movimento coordenado dos cardumes de peixes [11]. No método PSO cada partícula faz parte de uma possível solução representada por sua posição em um espaço de busca determinado. O processo de implementação do algoritmo pode ser visto no fluxograma da figura 1.




Figura 1. Fluxograma do algoritmo PSO

O primeiro passo é gerar as N partículas que formarão o “enxame” e suas respectivas posições. O segundo passo consiste em atribuir valores aleatórios nos vetores de posição e velocidade ou também arbitrar velocidades iniciais em cada uma das partículas, se desejado. O algoritmo manter-se-á ativo, atualizando ciclicamente os vetores de velocidade e posição até atingir a condição de convergência ou de parada (número máximo de iterações atingido ou partícula com aptidão desejada).

O vetor velocidade de cada partícula deve ser atualizado conforme a equação 2:

$$v_{k+1}^i = w.v_k^i + c_1.r_1(p_i^i - x_k^i) + c_2.r_2(p_k^s - x_k^i) \quad (2)$$

Onde v_k^i é a velocidade atual da partícula; p_i é a melhor posição encontrada pela partícula i ; p_k^s é a melhor posição dentre todas as partículas na iteração k e w é um parâmetro que representa a inércia da partícula e controla a sua capacidade de exploração do espaço de soluções. Um valor alto determina uma busca global enquanto um valor baixo determina uma busca local. Usualmente esses valores oscilam entre 0,4 e

1,4 [12], c_1 e c_2 são chamados parâmetros de confiança que definem o quanto uma partícula confia ou não na outra. Usualmente ambos assumem o valor igual a 2 [13]; r_1 e r_2 são números aleatórios compreendidos entre 0 e 1.

A equação 3 é utilizada para o cálculo da posição futura de cada uma das partículas:

$$x_{k+1}^i = x_k^i + v_{k+1}^i \quad (3)$$

Onde x_{k+1}^i é a posição de cada partícula i na iteração $k+1$ e v_{k+1}^i é o vetor velocidade da partícula.

IV. ESTIMAÇÃO DE PARÂMETROS MEDIANTE O MÉTODO DOS MÍNIMOS QUADRADOS (MQO)

Este método tenta minimizar a soma dos quadrados das discrepâncias (erro) entre o valor estimado (modelo) e os dados observados (processo), de forma a encontrar o melhor ajuste que consiga representar as N observações para um conjunto de dados, conforme apresentado a seguir:

$$\underbrace{e(k)}_{\text{Erro}} = \underbrace{y_P(k)}_{\text{Processo}} - \underbrace{y_M(k)}_{\text{Modelo}} \quad (4)$$

Sendo $y_P(k) = K\mu(k) + n(k)$ e $y_M(k) = K_M\mu(k)$ as observações no sistema e no modelo, quando aplicado um sinal de excitação $\mu(k)$; $n(k)$ é um sinal aleatório estacionário com $E\{n(k) = 0\}$ e K e K_M correspondem à representação matemática do processo e do modelo respectivamente, como pode ser visto na figura 2.

A equação 4 também pode ser representada na forma de matriz, conforme mostrado na equação 5.

$$y = \begin{pmatrix} Y_P(1) \\ Y_P(2) \\ \vdots \\ Y_P(N) \end{pmatrix} e = \begin{pmatrix} e(1) \\ e(2) \\ \vdots \\ e(N) \end{pmatrix} n = \begin{pmatrix} n(1) \\ n(2) \\ \vdots \\ n(N) \end{pmatrix} \theta = \begin{pmatrix} K_0 \\ K_1 \\ \vdots \\ K_q \end{pmatrix}$$

$$\psi = \begin{pmatrix} 1 & U(1) & U^2(1) & \dots & U^q(1) \\ 1 & U(2) & U^2(2) & \dots & U^q(2) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & U(N) & U^2(N) & \dots & U^q(N) \end{pmatrix} \quad (5)$$

Neste ponto a notação é alterada para uma expressão melhor conhecida de um problema de regressão, sendo ψ a matriz de dados; θ o vetor de parâmetros a serem estimados; y o vetor de saída e N o numero de observações. Assim a equação do processo é dada pela equação 6 e igualmente a equação do modelo pode ser escrita na forma da equação 7.

$$y = \psi\theta_0 + n \quad (6)$$

$$\hat{y} = \psi\theta \quad (7)$$

Onde $\hat{y}$ indica a saída do modelo. Portanto, as discrepâncias entre o processo e o modelo podem ser calculadas mediante a equação 8.

$$e = y - \psi\theta \quad (8)$$

Assim, a função objetivo é dada pela equação 9.

$$V = e^T e = (y^T - \theta^T \psi^T)(y - \psi\theta) \quad (9)$$

E o cálculo para o vetor dos parâmetros a serem estimados pode ser escrito na forma:

$$\hat{\theta} = (\psi^T \psi)^{-1} \psi^T y \quad (10)$$

Para garantir a existência de uma solução, $\psi^T \psi$ não deve ser singular. Assim, a condição para que o sistema seja o suficientemente excitado, é dado pela equação .

$$\det(\psi^T \psi) \neq 0 \quad (11)$$

Há várias razões que promovem a escolha de uma função objetivo quadrática [14] [15]. Primeiro porque é bem mais fácil de minimizar do que qualquer uma das outras funções objetivo, como por exemplo, o erro absoluto $|e(t)|$. No entanto, a principal razão é que, para um ruído normalmente distribuído, isto produz as melhores estimativas imparciais em termos da variância do erro nos parâmetros obtidos [15].




Figura 2. Diagrama de estimação de parâmetros mediante MQO e PSO

V. METODOLOGIA DE ESTIMAÇÃO DA ESTRUTURA NARMAX

O método implementado na estimação dos parâmetros da estrutura baseia-se no modelo Entrada-Saída, onde a relação entre um sinal de excitação e a influência gerada na resposta dinâmica em um sistema determinado é analisada. Duas técnicas de otimização foram utilizadas. A primeira utiliza o cálculo do gradiente para orientar o processo iterativo (MQO) e a segunda é fundamentada em conceitos inspirados na natureza (PSO). A escolha das duas as técnicas deve-se à capacidade de escapar de mínimos locais no caso do algoritmo PSO. Entretanto, conforme mencionado anteriormente, os modelos NARMAX são estruturas lineares nos parâmetros, justificando a estimação dos mesmos mediante MQO [16]. A implementação desta metodologia pode ser vista no fluxograma da figura 3.




Figura 3. Metodologia de estimação dos parâmetros de um modelo NARMAX

Um conjunto de equações diferenciais, que representam as características térmicas dinâmicas de um TEM [17], foram levadas em consideração, resultando na estrutura NARMAX apresentada na equação 12. Sendo T_x o perfil de temperatura a ser controlado e I representa a corrente elétrica aplicada no TEM. Os termos θ_i correspondem aos pesos a serem estimados pelo método dos MQO e os termos d_i , correspondem aos atrasos a serem estimados pelo algoritmo PSO. Desta forma, as não-linearidades do sistema original foram representadas mediante somas ponderadas das entradas e as saídas do sistema, deslocadas no tempo.

$$\begin{aligned}
 T_x[k] = & \theta_1 T[k-d_1] + \theta_2 I[k] + \theta_3 I[k-d_2] \\
 & + \theta_4 I[k-d_3] T[k-d_4] + \theta_5 I^2[k-d_5] T[k-d_6] \\
 & + \theta_6 I[k-d_7] T^2[k-d_8] + \theta_7 I^2[k-d_9] \\
 & + \theta_8 T^2[k-d_{10}]
 \end{aligned} \quad (12)$$

No entanto, o que determina o número de parâmetros necessários em um modelo linear é o tipo de regressores incluídos no modelo. Se regressores adequados forem usados, mesmo um modelo linear com poucos coeficientes, poderá reproduzir satisfatoriamente as dinâmicas não-lineares [18]. Assim, o problema de estimação dos parâmetros foi então, definido com a questão de minimização, das discrepâncias entre a resposta do modelo real e as respostas dos modelos simulados. Para quantificar tais discrepâncias é empregado o erro médio quadrático normalizado, como apresentado na equação 13:

$$J_{MQN}(\lambda) = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{\sum_{i=1}^N Y_i^2}} \quad (13)$$

Sendo que x_i representa os dados do modelo real; y_i representa os dados experimentais; N o número de pontos de dados e λ que é o vetor com os parâmetros a serem estimados. Uma

das exigências fundamentais é a implementação de um sinal dinamicamente persistente, de forma a garantir a exploração do sistema pelos regimes dinâmicos de interesse. O sinal de excitação utilizado pode ser visto na figura 4. Este consiste em um ruído branco limitado em frequência para evitar os efeitos decorrentes com as dinâmicas bruscas do processo e os correspondentes tempos de simulação.




Figura 4. Sinal de excitação implementado durante o processo de identificação do sistema

VI. TOPOLOGIA DOS AMPLIFICADORES

A topologia usada para a geração de corrente no TEM é mostrada na figura 5. Compõe-se de uma ponte H que faz a transformação de tensão contínua em tensão alternada e um filtro LC para eliminar as harmônicas produzidas na comutação das chaves da ponte H. Escolheu-se este amplificador devido a eficiência em consumo de potência, quando comparados com os amplificadores classe A e AB.




Figura 5. Topologia do Amplificador para a injeção de corrente no TEM

A corrente no amplificador é controlada mediante Modulação por Largura de Pulsos (*Pulse-Width Modulation-PWM*). A saída é uma combinação de sinais de alta frequência e o sinal de referência. Para eliminar as frequências altas é projetado um filtro passivo na frequência de corte acima da frequência de referência. Desta forma, após o filtro LC o sinal de referência será recuperado. Para garantir que a corrente no TEM seja aquela desejada, independente das perturbações e da carga não linear do TEM, um controlador de corrente é proposto, sendo este baseado num controlador clássico PI, como mostrado na figura 6.




Figura 6. Topologia do controlador de corrente para o TEM

Para a medição da grandeza da corrente usa-se um sensor de efeito hall, por ter a propriedade de não alterar o valor da grandeza que está sendo medida, pois não é inserido um elemento ao circuito que altere a carga. Este valor de realimentação, dependendo da saída, deverá ser condicionado a valores similares ao do sinal de referência. Para embarcar o controlador PI, implementar-se-á um microcontrolador que consiga ter periféricos de saída com PWM e conversor de sinal analógico para digital (*Analog-to-Digital Converter-ADC*).

A equação que relaciona o sinal de entrada e sinal de saída do amplificador classe D em laço aberto, considerando a ponte como amplificador, é dada pela expressão:

$$G(s) = V_{DC} \frac{1/LC}{s^2 + 1/LC} \quad (14)$$

Sendo V_{DC} a tensão de alimentação da ponte e $\frac{1/LC}{s^2 + 1/LC}$ a função de transferência que descreve o filtro passa baixa.

VII. DISCUSSÃO E ANÁLISE DOS RESULTADOS

Devido ao mecanismo interno de transferência de calor do TEM o processo é altamente não-linear e dependente do ponto de operação. Estes fenômenos não-lineares não podem ser reproduzidos por modelos lineares convencionais. O modelo NARMAX utilizado para reproduzir o comportamento dinâmico do TEM é apresentado na equação 15. Aqueles termos que apresentam parâmetros com valores absolutos reduzidos em relação aos demais poderiam ser eliminados. Porém, destaca-se ainda que existe uma situação na qual um pequeno valor em algum dos coeficientes não indica que tais coeficientes sejam insignificantes. Assim, modelos completos e melhor estabelecidos têm melhores chances de reproduzir as propriedades dinâmicas do sistema original.

$$\begin{aligned} T_x[k] = & 0,6543T[k-1] - 0,235I[k] + 0,03875I[k-2] \\ & + 1,6781I[k-2]T[k-1] \\ & - 0,00021I^2[k-1]T[k-2] \\ & + 0,5155I[k-2]T^2[k-1] + 0,234I^2[k-1] \\ & - 0,6579T^2[k-1] \end{aligned} \quad (15)$$

As alterações geradas na temperatura T_x em uma das caras do TEM como resposta a um sinal de excitação I_c . A grande semelhança entre os comportamentos do modelo real e o modelo

simulado indica que a metodologia implementada forneceu resultados excepcionais de estimação, além de comprovar uma alta efetividade, mesmo quando ocasionadas mudanças agressivas no perfil de temperatura conforme apresentado na figura 8. Nesse caso, a informação prévia sobre o conhecimento do sistema original permitiu selecionar a estrutura adequada para recuperar analiticamente as características dinâmicas observadas. Essa observação reitera a importância de estabelecer uma estrutura concisa, onde os parâmetros envolvidos conservam certa relação com as grandezas físicas da planta.

Também foi implementado um sinal de onda quadrado normalizado entre -0,5 e 0,5 amp, conseguindo reproduzir as características do modelo real com boa fidelidade. Nota-se que o modelo estimado ajusta os mesmos valores para as constantes de subida e descida, como pode ser visto na figura 7.




Figura 7. Comparação da temperatura do modelo real Vs. modelo NARMAX quando utilizado um sinal de excitação quadrado

VIII. CONCLUSÃO

No presente trabalho foi apresentada a metodologia e a estimação de parâmetros para uma estrutura de modelo NARMAX, que representa o comportamento térmico dinâmico de um modulo termoeletrico. Duas técnicas de otimização foram implementadas de forma a determinar os pesos e os atrasos do modelo NARMAX, substituindo assim o seu correspondente modelo, definido mediante um conjunto de equações diferenciais, tornando-se possível a compreensão das dinâmicas do TEM em sua forma original, isto é, sem serem consideradas simplificações nem aproximações. A topologia do amplificador de corrente para a estimação de parâmetros também foi apresentada. Esta topologia é baseada numa ponte H com filtro passa-baixa, permitindo ao amplificador gerar a corrente desejada para a estimação dos parâmetros da estrutura não-linear. Os resultados obtidos poderiam ser aplicados na construção de dispositivos de recuperação de energia residual convertendo em energia elétrica. Possíveis trabalhos decorrentes poderiam se focar no uso e exploração de outros sinais de excitação ou outros tipos de arquiteturas PSO, com o intuito de, não só melhorar a efetividade desta metodologia, mas também para determinar em que medida os parâmetros estimados poderiam melhorar o desempenho dos TEM.




Figura 8. Comparação da temperatura do modelo real Vs. modelo NARMAX quando utilizado um sinal de excitação aleatório

AGRADECIMENTOS

Os autores agradecem à CNPq, a CAPES, a FAPESP e a Pós-Graduação em Engenharia Elétrica da Universidade Federal do ABC por o seu apoio financeiro.

REFERÊNCIAS

- [1] Luis Antonio Aguirre and Stephen A Billings. Dynamical effects of overparametrization in nonlinear models. *Physica D: Nonlinear Phenomena*, 80(1):26–40, 1995.
- [2] Luis Antonio Aguirre and SA Billings. Retrieving dynamical invariants from chaotic data using narmax models. *International Journal of Bifurcation and Chaos*, 5(02):449–474, 1995.
- [3] SA Billings. Structure detection and model validity tests in the identification of nonlinear systems. 1982.
- [4] R Haber and Heinz Unbehauen. Structure identification of nonlinear dynamic systems a survey on input/output approaches. *Automatica*, 26(4):651–677, 1990.
- [5] SA Billings. Identification of nonlinear systems—a survey. In *IEE Proceedings D (Control Theory and Applications)*, volume 127, pages 272–285. IET, 1980.
- [6] L Bai and D Coca. Nonlinear predictive control based on narmax models. In *Optimization of Electrical and Electronic Equipment, 2008. OPTIM 2008. 11th International Conference on*, pages 3–10. IEEE, 2008.
- [7] Francesco Beneventi, Andrea Bartolini, Andrea Tilli, and Luca Benini. An effective gray-box identification procedure for multicore thermal modeling. *Computers, IEEE Transactions on*, 63(5):1097–1110, 2014.
- [8] Mihail Octavian Cernaianu and Aurel Gontean. Parasitic elements modelling in thermoelectric modules. *Circuits, Devices & Systems, IET*, 7(4):177–184, 2013.
- [9] Wensi Wang, Victor Cionca, Ningning Wang, Mike Hayes, Brendan O’Flynn, and Cian O’Mathuna. Thermoelectric energy harvesting for building energy management wireless sensor networks. *International Journal of Distributed Sensor Networks*, 2013, 2013.
- [10] Alim Dewan, Suat U. Ay, M. Nazmul Karim, and Haluk Beyenal. Alternative power sources for remote sensors: A review. *Journal of Power Sources*, 245:129–143, Jan 2014.
- [11] R. Eberhart and J. Kennedy. A new optimizer using particle swarm theory. *MHS95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 1995.
- [12] T. Therdbankerd, P. Sanposh, N. Chayopitak, and H. Fujita. Parameter identification of a linear permanent magnet motor using particle swarm optimization. In *Electrical Engineering/Electronics Computer Telecommunications and Information Technology (ECTI-CON), 2010 International Conference on*, pages 173–177, 2010.
- [13] Dian Palupi Rini, Siti Mariyam Shamsuddin, and Siti Sophiyati Yuhani. Particle swarm optimization: technique, system and challenges. *International Journal of Computer Applications*, 14(1):19–26, 2011.
- [14] SA Billings and WSF Voon. Least squares parameter estimation algorithms for non-linear systems. 1984.
- [15] Rolf Isermann and Marco Münchhof. Mathematical models of linear dynamic systems and stochastic signals. *Identification of Dynamic Systems*, pages 33–74, 2011.
- [16] Michel Verhaegen and Vincent Verdult. *Filtering and system identification: a least squares approach*. Cambridge university press, 2007.
- [17] D.R. Ojeda G, L.A.L. de Almeida, and O.A.C. Vilcanqui. Parameter identification of thermoelectric modules using particle swarm optimization. In *Instrumentation and Measurement Technology Conference (I2MTC), 2015 IEEE International*, pages 812–817, 2015.
- [18] LUIS A Aguirre, Giovanni G Rodrigues, and Cristiano RF Jácome. Identificação de sistemas não-lineares utilizando modelos narmax polinomiais—uma revisão e novos resultados. *SBA Controle e Automação*, 9(2):90–106, 1998.