

IDENTIFICAÇÃO DE UM MOTOR/GERADOR CC POR MEIO DE MODELOS POLINOMIAIS AUTORREGRESSIVOS E REDES NEURAIS ARTIFICIAIS

WILSON ROCHA LACERDA JUNIOR*, VINICIUS MARTINS ALMEIDA*, SAMIR ANGELO MILANI MARTINS*

*GCOM - Grupo de Controle e Modelagem, Departamento de Engenharia Elétrica
Universidade Federal de São João del-Rei, Praça Frei Orlando 170 - Centro, 36307-352
São João del-Rei, Minas Gerais, Brasil

Emails: wilsonrljr@outlook.com, vinalmeida@gmail.com, martins@ufsj.edu.br

Abstract— This work compares the performance of different types of mathematical representation in the identification of a DC motor as a generator. Auto-regressive models as ARX, ARMAX, NARX and NARMAX, as well as a closed-loop Multilayer *Perceptron* Neural Network were used, and the results were quantified and compared by means of Mean Square Error (MSE) and Root Mean Square Error. The results show that NARX models, as well NARMAX and neural networks model, have success in the identification of the proposed system, with a significantly better performance than ARX and ARMAX models.

Keywords— System Identification, nonlinear dynamics, NARMAX model, neural network, DC generator

Resumo— Esse trabalho compara o desempenho de diferentes representações matemáticas na identificação de um gerador CC. São utilizados os modelos autorregressivos ARX, ARMAX, NARX e NARMAX, bem como uma Rede Neural Perceptron-Multicamadas Realimentada, sendo que os resultados são quantificados e comparados por meio dos índices Erro Médio Quadrático (MSE) e Raiz do Erro Médio Quadrático (RMSE). Os resultados mostram que os modelos NARX, NARMAX e a rede neural obtém êxito na identificação do sistema proposto, com um desempenho muito superior ao dos modelos ARX e ARMAX.

Palavras-chave— Identificação de sistemas, dinâmica não linear, modelos NARMAX, redes neurais, gerador CC

1 Introdução

A Identificação de Sistemas é a área do conhecimento que estuda maneiras de modelar e analisar sistemas, na tentativa de encontrar algum padrão nas observações (Billings, 2013; Ljung, 1987). Em muitos casos é preferível usar técnicas de identificação para se obter modelos que descrevem o comportamento de um sistema (Aguirre, 2007). Nesse sentido, um modelo matemático pode ser interpretado como uma abstração de um sistema real expresso por meio de equações (Martins et al., 2013).

Devido a importância em se modelar matematicamente um sistema, diversos métodos de Identificação de Sistemas têm sido estudados e aprimorados (Martins e Aguirre, 2016; Aslam, 2016; Yan e Deller Jr, 2016). Tais métodos podem ser empregados na identificação de aquecedores elétricos (Martins et al., 2009), conversores CC-CC (Yang et al., 2009), arnotecedores magneto-reológicos (Martins e Aguirre, 2016), sistemas biomédicos (Irigoyen e Miñano, 2013), sociais (Sukhai et al., 2011), além de outras áreas, como sistemas químicos, econômicos e outros ramos da ciência.

Nesse contexto, modelos NARMAX (*Non-linear Autoregressive Moving Average model with eXogenous variables*) e redes neurais tem sido utilizados na identificação de motores CC. Yassin et al. (2011), Rahim et al. (2003) e Rahim et al. (2006) utilizaram redes neurais na identificação de motores CC, enquanto Supeni et al. (2009) obteve com razoável precisão, respectivamente, mo-

delos NARMAX e NARX (*Non-linear Autoregressive model with eXogenous variables*) na modelagem de motores CC. Apesar de comparações de desempenho entre redes neurais terem sido feitas no contexto de modelagem de motores CC (Yassin et al., 2011), a escolha de qual representação utilizar, considerando outras representações, como modelos autorregressivos polinomiais, ainda carece de estudos. Sendo assim, esse trabalho apresenta uma comparação entre os modelos ARX (*Autoregressive with eXogenous inputs*), ARMAX (*Autoregressive Moving Average with eXogenous inputs*), NARX, NARMAX e Redes Neurais na modelagem de um motor CC funcionando como gerador.

O artigo está estruturado da seguinte forma: a presente seção apresentou uma breve introdução histórica sobre o tema a ser desenvolvido. Na seção 2 são levantados os conceitos preliminares, suficientes para o entendimento do trabalho. Na seção 3 são apresentados os métodos utilizados para se chegar aos resultados discutidos na seção 4. A seção 5 trata da conclusão do trabalho e propostas de possíveis trabalhos futuros.

2 Conceitos Preliminares

2.1 Identificação de Sistemas

As principais etapas do processo de identificação de sistemas consistem em (Aguirre, 2007):

1. Testes dinâmicos e coleta de dados; dados ex-

perimentais do sistema a ser identificado são coletados, sendo imprescindível o projeto adequado do sinal de excitação a ser utilizado, bem como a frequência de amostragem dos dados coletados. Nesse trabalho foi utilizado um sinal binário pseudoaleatório como sinal de entrada.

2. Escolha da representação matemática a ser usada; cinco representações matemáticas são consideradas neste trabalho: ARX, ARMAX, NARX, NARMAX e Rede Neural *Perceptron*-Multicamadas Realimentada.
3. Determinação da estrutura do modelo; neste trabalho, a estrutura dos modelos polinomiais são determinadas usando a Taxa de Redução de Erro (ERR), do inglês *Error Reduction Ratio* e Critério de Informação de Akaike (AIC), do inglês *Akaike's information criterion* (Aguirre e Billings, 1995). Para a rede neural, foi utilizado o toolbox de redes neurais do software Matlab.
4. Estimação de parâmetros; os parâmetros estimados quantificam a contribuição de cada regressor em um dado modelo. Neste trabalho, o algoritmo utilizado é método dos mínimos quadrados e o mínimos quadrados estendidos, para os modelos polinomiais. No caso das redes neurais, precisamente da rede *perceptron* multicamadas realimentada, o algoritmo de Levenberg - Marquadt incorporado ao *back-propagation* foi utilizado.
5. Validação; essa etapa consiste em verificar se um modelo é adequado ou não para determinada aplicação. É importante destacar que um conjunto de dados diferente do utilizado para identificação deve ser usado nessa etapa. Para quantificar esta validação, índices como o Erro Quadrático Médio e a Raiz do Erro Quadrático Médio são utilizados nesse trabalho.

2.2 Erro Quadrático Médio

Definição 2.1 (*MSE - Mean Squared Error*): O *MSE* é definido por:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y - \hat{y})^2, \quad (1)$$

em que y , \hat{y} e N são os valores reais dos dados, os valores estimados e o número de amostras, respectivamente.

Com o MSE, pode-se quantificar o quão bom um modelo é em comparação a outro, sendo que quanto mais próximo de 0 for o resultado do índice, melhor é o modelo.

Definição 2.2 (Aguirre, L.A. (Aguirre, 2007), *Root Mean Square Error*) O *RMSE* pode ser definido como:

$$RMSE = \frac{\sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^N (y(k) - \bar{y}(k))^2}}, \quad (2)$$

sendo $\hat{y}(k)$ a saída do modelo e $\bar{y}(k)$ a média da saída medida, $y(k)$.

2.3 Modelos NARMAX polinomiais

Um modelo NARMAX polinomial pode ser definido por (Chen e Billings, 1989):

$$y(k) = F^\ell[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u), e(k-1), \dots, e(k-n_e)] + e(k), \quad (3)$$

em que n_y , n_u , n_e , d , $u(k)$ e $y(k)$ são os atrasos em y , em u , em e o tempo morto, o sinal de entrada e o sinal de saída no instante k , respectivamente. $e(k)$ representa ruído e possíveis incertezas que não podem ser bem representados por F^ℓ , que é uma função polinomial de $y(k)$, $u(k)$, e $e(k)$ com grau de não linearidade $\ell \in \mathbb{N}$.

A parte determinística da Eq. (3) pode ser expandida como o somatório de termos com graus de não linearidade na faixa $1 \leq m \leq \ell$. Dessa forma, cada termo de grau m poderá conter um fator de grau p do tipo $y(k-i)$ e um fator de grau $(m-p)$ do tipo $u(k-i)$, sendo este multiplicado por um parâmetro representado por $c_{p,m-p}(\tau_1, \dots, \tau_m)$:

$$y(k) = \sum_{m=0}^{\ell} \sum_{p=0}^m \sum_{\tau_1, \tau_m}^{n_y, n_u} c_{p,m-p}(\tau_1, \dots, \tau_p) \times \prod_{i=1}^p y(k-\tau_i) \times \prod_{i=p+1}^m u(k-\tau_i), \quad (4)$$

onde o limite superior é n_y se o somatório refere-se a fatores do tipo $y(k-\tau_i)$ ou n_u caso esse refira-se a fatores do tipo $u(k-\tau_i)$.

Na Eq. (1), se $\ell = 1$, o representação passa a ser chamada ARMAX. Caso o modelo não possua regressores da forma $u(k-i)$, tem-se os modelos AR (AutoRegressive model), no caso de $\ell = 1$, e NAR (*Nonlinear AutoRegressive model*), para $\ell > 1$. A parte média móvel (MA) do modelo é incluída caso haja ruído colorido nos dados, de forma que os resíduos apresentam alguma dinâmica que não foi explicada completamente pelo modelo. Como consequência, o método clássico dos Mínimos Quadrados se torna polarizado ou tendencioso para estimação dos parâmetros. Nesse caso, um método não polarizado deve ser utilizado, como o Mínimos Quadrados Estendidos (MQE).

2.4 Rede Perceptron-Multicamadas Realimentada

Definição 2.3 (Hecht-Nielsen, R. (Hecht-Nielsen, 1989), Rede Neural)

Uma rede neural é uma estrutura de processamento de informação distribuída, constituída por elementos de processamento interligadas em conjunto com canais de sinal unidirecionais, chamados conexões. Cada elemento de processamento tem uma única conexão de saída que se ramifica na quantidade de conexões desejadas (cada uma carregando o mesmo sinal - o sinal de saída do elemento de processamento).

A topologia empregada presente na Figura (1) foi a rede *perceptron* multicamadas realimentada. Nessa topologia, diferentemente das rede *perceptron*-multicamadas, a rede tem sua saída realimentada à entrada permitindo que o sistema obtenha as respostas passadas a partir do instante atual. O número de camadas escondidas e quantidade de neurônios são determinados pela complexidade do problema. Os sinais de saída de uma camada servem de sinal de entrada para as camadas adiante (Silva et al., 2010).

A vantagem de se ter camadas escondidas é que elas conseguem extrair um conjunto maior de informações do comportamento do processo em estudo, e as codificam por meio dos limiares e dos pesos sinápticos (Silva et al., 2010). Assim como na arquitetura de camada simples, o número de neurônios da camada de saída será a mesma quantidade dos sinais presentes nesta mesma camada (Haykin et al., 2009).

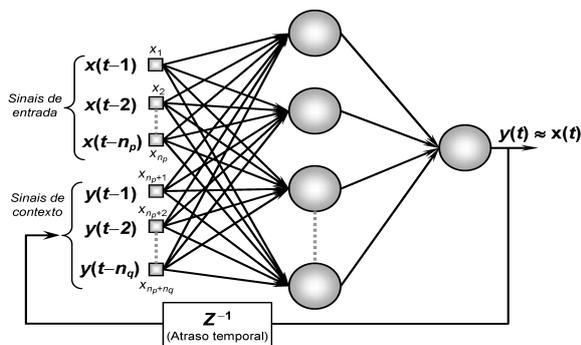


Figura 1: Topologia da RNA *perceptron* multicamadas realimentada (Silva et al., 2010).

2.4.1 Algoritmo *Backpropagation*

O algoritmo *backpropagation* (retropropagação) trabalha de forma iterativa para minimizar os erros entre a saída desejada e a saída fornecida pela rede neural. O algoritmo é dividido em duas etapas ou fases: *forward* (ou em avanço) e *backward* (ou atraso). Na fase *forward*, são aplicados os sinais de entrada e estes percorrem todas as camadas até que um resultado de saída é produzido. Durante

esta primeira etapa, os pesos são mantidos inalterados (Silva et al., 2010). Na fase *backward*, o sinal de erro é retro propagado da saída para cada elemento da camada anterior. Os pesos sinápticos são ajustados de acordo com sua relevância através do sinal de erro produzido ao final da fase *forward* (Haykin et al., 2009). O cálculo do erro é realizado pelo erro quadrático médio, como exposto na seguinte equação (Silva et al., 2010).

$$E(k) = \frac{1}{2} \sum_{p=1}^2 (d_j(k) - Y_j^{(n)}(k))^2, \quad (5)$$

em que $Y_j^{(n)}$ é o valor resultante do j -ésimo neurônio de saída considerando-se a k -ésima amostra, enquanto $d_j(k)$ é o seu respectivo valor desejado. Sobre os pesos dos neurônios da camada de saída, a equação que os rege pode ser escrita como na equação:

$$W_{ij}^{(1)}(t+1) = W_{ij}^{(1)}(t) + \eta \delta_j^1 x_i. \quad (6)$$

Na Eq. (6), η é a taxa de aprendizagem, δ_j^1 , o gradiente local, $W_{ij}^{(1)}(t+1)$ é o peso futuro; $W_{ij}^{(1)}$ é o peso anterior, x_i é sinal de entrada; j representa o neurônio da camada 1 e o índice i , representa o neurônio da camada interior. Informações mais detalhadas podem ser vistas em Silva et al. (2010). Em relação à atualização dos pesos das camadas intermediárias, diferentemente da maneira como acontece com os pesos da camada de saída, não possuem valores desejados, então, são estimados a partir da ponderação dos pesos atualizados da camada de saída.

Neste trabalho, o método utilizado foi o *backpropagation* modificado, conhecido como Método de Levenberg - Marquadt. Este é um método baseado nos mínimos quadrados para modelos não-lineares que pode ser arrolado ao algoritmo para que tenha uma eficiência melhorada e com isso reduza o esforço computacional. O desenvolvimento matemático pode ser visto em Hagan e Menhaj (1994).

3 Metodologia

Para a realização do processo de identificação, é utilizado um sistema composto por 2 motores CC (6v) acoplados por um eixo, no qual um transfere energia mecânica para o outro, de modo que o segundo funcione como gerador. O esquema do circuito implementado é apresentado na Figura (2).

Inicialmente, levanta-se a curva de calibração estática do motor, de forma a relacionar a tensão de entrada com a velocidade de saída do motor. Além disso, o sinal de entrada utilizado para excitar o sistema é um sinal binário pseudoaleatório (SBPA). Os dados, super amostrados inicialmente, são decimados adequadamente, resultando

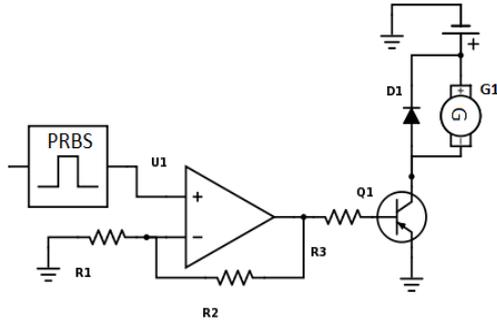


Figura 2: Esquema do sistema proposto

em 5000 amostras, sendo metade utilizados para identificação e a outra metade para validação do modelo. Para geração e coleta dos dados, utiliza-se a placa de aquisição de dados NI 6009 USB, da *National Instruments*.

Após a coleta dos dados, normalizados posteriormente, são realizados os procedimentos para identificação do sistema proposto utilizando os modelos ARX, ARMAX, NARX, NARMAX e Redes Neurais, cujos parâmetros estão definidos na Tabela (1). Inicialmente, também são considerados os modelos AR e NAR, mas, como se mostram ineficientes para a modelagem do sistema, foram desconsiderados na análise final.

Parâmetros	Especificação
Camadas escondidas	1
Neurônios na camada escondida	10
Treinamento	Levenberg-Marquardt
Máximo atraso	2

Tabela 1: Topologia da RNA.

Por fim, é realizada uma análise comparativa entre os modelos obtidos, considerando tanto o desempenho alcançado, por meio do índice MSE, quanto a complexidade estrutural de cada um dos modelos.

4 Resultados

A curva de calibração estática do gerador é representada pela Figura (3). A equação da reta é dada por:

$$\omega = 1104.8 \times V - 164.2, \quad (7)$$

onde ω é a velocidade angular (rpm) e V a tensão aplicada.

Os modelos obtidos pelas representações ARX, ARMAX, NARX e NARMAX são apresentados pelas equações de (8) a (11), respectivamente. É importante ressaltar que os termos

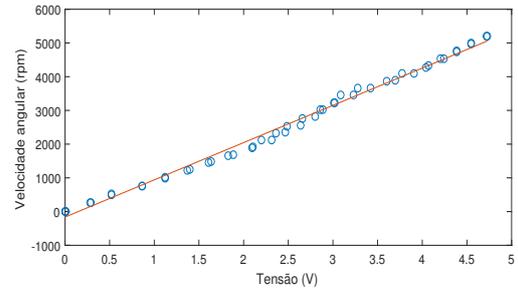


Figura 3: Curva de calibração

$e(k - n_e)$ são utilizados apenas para estimação de parâmetros, não sendo empregados durante as simulações e, por isso, não são apresentados nas equações a seguir.

$$y(k) = 1,7911y(k-1) - 0,8073y(k-2) + 0,0127u(k-1) + 0,0071. \quad (8)$$

$$y(k) = 1,7685y(k-1) - 0,7849y(k-2) + 0,0130u(k-1) + 0,0071. \quad (9)$$

$$y(k) = 1,7813y(k-1) - 0,7962y(k-2) + 0,0339u(k-1) - 0,1597u(k-1) \times y(k-1) + 0,0338u(k-2) + 0,1297u(k-1)y(k-2) - 0,1396u(k-2)y(k-1) + 0,1086u(k-2)y(k-2) + 0,0085y(k-2)^2 \quad (10)$$

$$y(k) = 1,7823y(k-1) - 0,7969y(k-2) + 0,0337u(k-1) - 0,16u(k-1) \times y(k-1) + 0,0340u(k-2) + 0,1302u(k-1)y(k-2) - 0,1389u(k-2)y(k-1) + 0,1077u(k-2)y(k-2) + 0,0082y(k-2)^2 \quad (11)$$

O desempenho do modelo ARX e ARMAX são mostrados, respectivamente, nas Figuras (4) e (5). Como pode ser visto pelas figuras e pela Tabela (2), o desempenho de ambos os modelos são muito parecidos, mostrando que a inclusão do termo $e(k)$ não resulta em ganho de qualidade do modelo.

Uma comparação análoga pode ser feita entre os resultados obtidos pelos modelos NARX e NARMAX. Os resultados apresentados pela Figura (6) e (7), bem como a Tabela (2), mostram

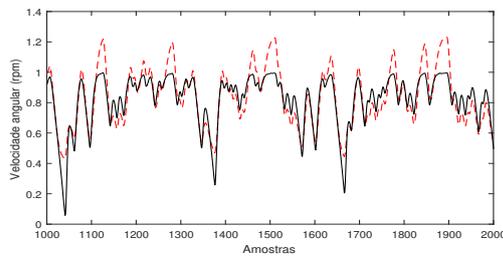


Figura 4: Validação do modelo ARX. (-) Sistema proposto, (- -) modelo identificado.

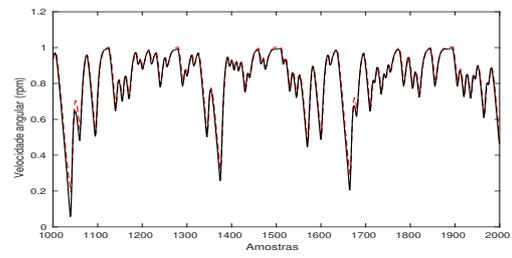


Figura 7: Validação do modelo NARMAX. (-) Sistema proposto, (- -) modelo identificado.

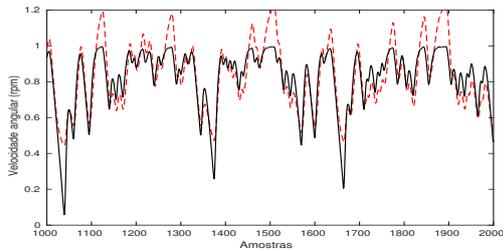


Figura 5: Validação do modelo ARMAX. (-) Sistema proposto, (- -) modelo identificado.

Modelo	RMSE	MSE
ARX	0,5873	0,0077
ARMAX	0,5886	0,0078
NARX	0,0928	$1,9209 \times 10^{-4}$
NARMAX	0,1665	$6,1625 \times 10^{-4}$
Rede Neural	0,02	$1,2361 \times 10^{-5}$

Tabela 2: MSE e RMSE calculados para cada modelo analisado.

que os modelos têm desempenhos muito próximos um do outro. Contudo, nesse caso, a inclusão do termo $e(k)$ na estrutura do modelo resulta em uma piora mais significativa no resultado.

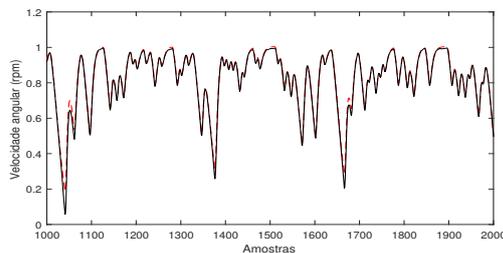


Figura 6: Validação do modelo NARX - (-) Sistema proposto, (- -) modelo identificado.

Comparando-se, no entanto, os modelos lineares com os não lineares, percebe-se claramente que os modelos não lineares se mostram bem mais eficientes ao modelar o sistema do que os modelos lineares.

Por fim, a Figura (8) apresenta os resultados utilizando a rede neural. Como pode ser visto na tabela (2), ela obtém o melhor desempenho en-

tre os modelos analisados, conseguindo representar muito bem a dinâmica do sistema. No entanto, deve-se considerar a alta complexidade estrutural da rede neural como uma desvantagem em relação aos modelos polinomiais NARX e NARMAX. A simplicidade estrutural dos modelos polinomiais é um ponto decisivo na escolha de qual modelagem utilizar, por exemplo, em um cenário de controle baseado em modelos.

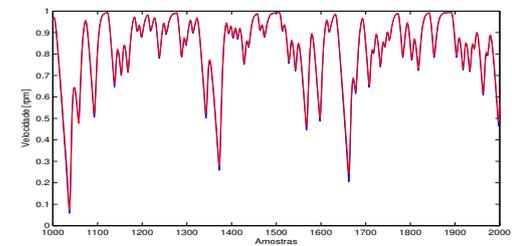


Figura 8: Validação utilizando Rede Neural Perceptron-Multicamadas Realimentada. (-) Sistema proposto, (- -) modelo identificado.

5 Conclusões

Esse trabalho comparou o desempenho de modelos ARX, ARMAX, NARX, NARMAX e rede neural *Perceptron*-Multicamadas Realimentada na identificação de um gerador CC. Para isso, o sistema foi construído utilizando dois motores de 6V e uma placa de aquisição de dados foi utilizada para gerar o sinal de entrada, bem como obter os dados de saída.

Os resultados obtidos mostram que os modelos ARX e ARMAX, mesmo apresentando índices satisfatórios para validação, não são escolhas adequadas para modelagem desse sistema. Dessa forma, as alternativas NARX, NARMAX e Rede Neural *Perceptron*-Multicamadas Realimentada, mesmo apresentando estruturas mais complexas, são escolhas pertinentes, dado que conseguem representar a dinâmica do sistema com alta precisão. Além disso, a rede neural demonstra, nesse caso, ser a melhor opção de modelagem, caso um maior grau de precisão seja requerido. Porém, se os resultados obtidos pelos modelos polinomiais se

apresentarem suficientes para determinada aplicação, seriam a escolha adequada devido à menor complexidade estrutural.

Trabalhos futuros verificarão o desempenho dos modelos utilizando outros métodos para estimação dos parâmetros, como o método dos mínimos quadrados recursivos, bem como a aplicabilidade de tais modelos em um contexto de controle do sistema proposto.

Agradecimentos

Os autores agradecem a FAPEMIG e a Universidade Federal de São João Del Rei pelo apoio.

Referências

- Aguirre, L. A. (2007). *Introdução à identificação de sistemas – Técnicas lineares e não lineares aplicadas a sistemas reais*. Editora UFMG.
- Aguirre, L. A. e Billings, S. (1995). Improved structure selection for nonlinear models based on term clustering. *International Journal of Control*, 62(3):569–587.
- Aslam, M. S. (2016). Maximum likelihood least squares identification method for active noise control systems with autoregressive moving average noise. *Automatica*, 69:1 – 11.
- Billings, S. A. (2013). *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*. Wiley.
- Chen, S. e Billings, S. (1989). Representations of non-linear systems: the NARMAX model. *International Journal of Control*, 49(3):1013–1032.
- Hagan, M. T. e Menhaj, M. B. (1994). Training feedforward networks with the marquardt algorithm. *IEEE transactions on Neural Networks*, 5(6):989–993.
- Haykin, S. S., Haykin, S. S., Haykin, S. S., e Haykin, S. S. (2009). *Neural networks and learning machines*, volume 3. Pearson Upper Saddle River, NJ, USA:.
- Hecht-Nielsen, R. (1989). Theory of the backpropagation neural network. In *Neural Networks, 1989. IJCNN., International Joint Conference on*, pages 593–605. IEEE.
- Irigoyen, E. e Miñano, G. (2013). A narx neural network model for enhancing cardiovascular rehabilitation therapies. *Neurocomputing*, 109:9–15.
- Ljung, L. (1987). *System identification: theory for the user*. Prentice-Hall information and system sciences series. Prentice-Hall.
- Martins, S. A. M. e Aguirre, L. A. (2016). Sufficient conditions for rate-independent hysteresis in autoregressive identified models. *Mechanical Systems and Signal Processing*, 75(15):607–617.
- Martins, S. A. M., Barbosa, A. M., e Nepomuceno, E. G. (2013). Determinação do número de termos de modelos polinomiais: O critério de informação de akaike multiobjetivo. In *Anais do XI Simpósio Brasileiro de Automação Inteligente*.
- Martins, S. A. M., Braga, D. C. d. S., Nepomuceno, E. G., Gomes, T. V., e Reis, M. L. F. (2009). Investigation of static curve information for multiobjective system identification. *Journal of Computational Interdisciplinary Sciences*, 1:149–157.
- Rahim, N., Taib, M., e Yusof, M. (2003). Nonlinear system identification for a dc motor using NARMAX approach. In *Sensors, 2003. Asia-Sense 2003. Asian Conference on*, pages 305–311. IEEE.
- Rahim, N. A., Taib, M., Adom, A., e Mashor, M. (2006). The NARMAX model for a dc motor using mlp neural network. In *Proceeding of the First International Conference On MAN-MACHINE SYSTEMS (ICoMMS)*, pages 61–65.
- Silva, I. d., Spatti, D. H., e Flauzino, R. A. (2010). Redes neurais artificiais para engenharia e ciências aplicadas. *São Paulo: Artliber*, pages 33–111.
- Sukhai, A., Jones, A. P., Love, B. S., e Haynes, R. (2011). Temporal variations in road traffic fatalities in south africa. *Accident Analysis & Prevention*, 43(1):421–428.
- Supeni, E., Yassin, I. M., Ahmad, A., e Rahman, F. A. (2009). NARMAX identification of dc motor model using repulsive particle swarm optimization. In *Signal Processing & Its Applications, 2009. CSPA 2009. 5th International Colloquium on*, pages 1–7. IEEE.
- Yan, J. e Deller Jr, J. (2016). NARMAX model identification using a set-theoretic evolutionary approach. *Signal Processing*, 123:30 – 41.
- Yang, X., Zhang, H., e Ma, X. (2009). Modeling and stability analysis of cascade buck converters with n power stages. *Mathematics and Computers in Simulations*, 80:533 – 546.
- Yassin, I. M., Taib, M. N., Aziz, M. Z. A., Rahim, N. A., Tahir, N. M., e Johari, A. (2011). Identification of dc motor drive system model using radial basis function (rbf) neural network. In *Industrial Electronics and Applications (ISIEA), 2011 IEEE Symposium on*, pages 13–18. IEEE.