

USO DE REDES NEURAIS ARTIFICIAIS PARA OBTENÇÃO DE UM SENSOR AR/COMBUSTÍVEL VIRTUAL APLICADO A UM MOTOR MONOCILÍNDRICO

Leonardo Faure Nardini Paschoa ¹; Sergio Ribeiro Augusto ²

¹ Aluno de Iniciação Científica da Escola de Engenharia Mauá (EEM-CEUN-IMT);

² Professor da Escola de Engenharia Mauá (EEM-CEUN-IMT).

Resumo. *Este trabalho visa a construção de um estimador neural (sensor virtual) utilizando uma rede do tipo PMC (perceptron multicamada) para a determinação da relação ar/gasolina (valor lambda), em uma dada faixa de regime de operação, de um motor monocilíndrico de baixa cilindrada. Através da medida de parâmetros do motor, como, por exemplo, rotação, fluxo de ar, temperatura, largura do pulso de injeção, entre outras, obtém-se um mapeamento não linear que determina o valor da relação normalizada (lambda). Com isso, pretende-se diminuir os custos de motores ao consumidor final, visto que seria realizado a troca de um sensor físico pelo virtual.*

Introdução

Os motores a combustão funcionam utilizando o princípio que havendo faísca e combustível uma explosão é gerada liberando energia. Tal energia é transformada em rotação do eixo do motor (virabrequim), permitindo que a mesma seja utilizada por exemplo para tração mecânica. O gerenciamento desses fatores, faísca e combustível, os quais garantem o funcionamento do motor, é realizado através de sistemas de injeção e ignição eletrônicas (Young, 2010).

Os sistemas de injeção e ignição eletrônicas foram desenvolvidos para se obter um maior controle sobre o funcionamento do motor, visto que diversas variáveis envolvidas no sistema são monitoradas e consideradas para cálculo, em tempo real, da quantidade de combustível e o instante de explosão da mistura, permitindo o perfeito funcionamento do motor, em qualquer situação. Consequentemente, isso permite com que tenhamos um funcionamento perto do ideal do motor: a mistura estequiométrica. Quando temos para um motor a quantidade exata da mistura Ar/Combustível, dizemos que a mistura é estequiométrica (pois temos exatas partes de combustível para comburente), ou que o valor de lambda (λ) é 1 (Amato et al., 2005).

O valor de lambda é definido pela equação:

$$\lambda = \frac{\text{ar/combustível}}{\text{ar/combustível estequiométrica}} \quad (1)$$

O valor indica, de maneira mais direta, se a mistura está rica ($\lambda < 1$, com combustível acima do ideal), ou se a mistura está pobre ($\lambda > 1$, com combustível abaixo do ideal). O controle desse parâmetro, além de garantir o perfeito funcionamento do motor, gera economia de combustível e menor quantidade de emissões de poluentes à atmosfera, visto que o combustível não é “desperdiçado”. O sistema de injeção eletrônica foi implementado em massa por volta dos anos 80 e 90 pelas montadoras ao redor do mundo (Young, 2010). Para o sistema determinar se a mistura está rica ou pobre é utilizado um sensor de oxigênio, chamado de sonda lambda, na saída de escape dos motores, o qual faz a leitura da quantidade de oxigênio presente após a queima do combustível, indicando ao sistema de injeção se todo o combustível foi queimado, não foi, ou se faltou. Este estudo se refere a emulação de um sensor λ utilizando-se redes neurais artificiais (Haykin, 1999; Turkson, 2016).

As redes neurais são uma analogia ao sistema nervoso central de um animal, pois podem aprender e observar padrões, para posteriormente os repetir e generalizar. Muitas vezes, são utilizadas para observar padrões em funções e problemas do dia a dia, para que possam ajudar a resolver algo que seria trabalhoso demais se realizado de maneira mais manual, tais como visão computacional e reconhecimento de voz (Haykin, 1999).

Outros trabalhos na literatura utilizaram redes neurais para modelagem de sensores lambda, tais como Salehi (2010) e Richter (2009). Em Salehi (2010) o mesmo utilizou redes neurais para analisar o desgaste de catalisadores, utilizando uma sonda lambda antes do catalisador e prevendo o valor de lambda após o catalisador. Em Richter (2009) uma rede neural do tipo perceptron multicamadas (Haykin, 1999) foi utilizada para realizar a predição de um passo à frente do valor de lambda em função de vários parâmetros de funcionamento do motor, e utilizando um elevado conjunto de treinamento. Neste trabalho, diferentemente da literatura citada, utiliza-se um modelo não linear do tipo NARX (*non linear auto-regressive network with exogenous inputs*) (Aguirre, 2000; Narendra e Parthasarathy, 1990), ilustrado na Figura 1, cuja função não linear $f(\cdot)$ é realizada através de uma rede neural artificial do tipo perceptron multicamada, treinada utilizando o método da regularização Bayesiano (Lampinen e Vehtari, 2001).

A equação de um modelo NARX é dada pela equação (Narendra e Parthasarathy, 1990):

$$Yp(k+1) = f[Yp(k), Yp(k-1), \dots, Yp(k-n+1); u(k), u(k-1), \dots, u(k-m+1)] \quad (2)$$

A Figura 1 ilustra o modelo NARX:




Figura 1 - Diagrama do modelo NARX

A Figura 2 ilustra uma rede neural perceptron multicamadas (PMC) com uma camada escondida, consistindo de vários neurônios interconectados.




Figura 2 - Rede tipo PMC

Materiais e Métodos

Para a realização deste estudo foi utilizado um motor monocilíndrico Honda Gx35 (Honda, 2017), motor pequeno de aplicação em roçadeiras. A escolha do motor foi feita devido à facilidade de acesso e pelo mesmo ser utilizado em competições acadêmicas.

O motor utilizado vem de fábrica com sistema de carburação para alimentação do motor e para realizarmos este estudo foi necessária a instalação e configuração de um kit de injeção e ignição eletrônica. Optou-se pela aquisição de um kit fabricado pela empresa norte americana Ecotrons (Ecotrons, 2017), voltado a motores monocilíndricos. O kit é composto dos itens necessários para a conversão do sistema de alimentação do motor, incluindo bicos injetores, coletor de admissão, sensor de oxigênio, entre outros. Alguns de seus itens requerem atenção especial para a montagem, como a linha de combustível e seus periféricos, bomba e filtro. A linha de combustível necessita constante atenção, já que se houver, por exemplo, algum ar na linha, o funcionamento correto do motor é prejudicado, fazendo com que o mesmo sequer possa ser ligado.

A Figura 3 ilustra o motor utilizado e o sistema de injeção e ignição instalados.




Figura 3 - Motor com os periféricos, injeção e ignição.

O sistema de injeção inclui um software, denominado EcoCal, ilustrado na Figura 4, que permite o ajuste e calibração de diversos parâmetros do mesmo, assim como um registro de ações do sistema, e página para observação de comportamentos de variáveis. Os dados monitorados para testes foram: temperatura de admissão, temperatura do motor, rotação do motor, pressão do coletor de admissão, posição da borboleta, tempo da faísca, largura de

pulso de injeção e o valor de Lambda. O valor de λ é a saída do modelo NARX, e as demais variáveis compõem o vetor de entrada $u(k)$.



Figura 4 - Software EcoCal

O kit original da injeção eletrônica utiliza em seu sistema uma sonda lambda do tipo banda estreita (*Narrowband*) (Richter, 2009). Tais sondas possuem uma variação de tensão de saída muito abrupta em função da relação ar/combustível, fornecendo apenas se a mistura é rica ou pobre. O objetivo de nosso estudo é de estimar sensores do tipo *wideband* (Richter, 2009), mais precisos e também de custo mais elevado. Embora mais precisos, tais sensores não são normalmente utilizados em veículos devido ao seu custo.

A Figura 5 ilustra os dois tipos de sensores:

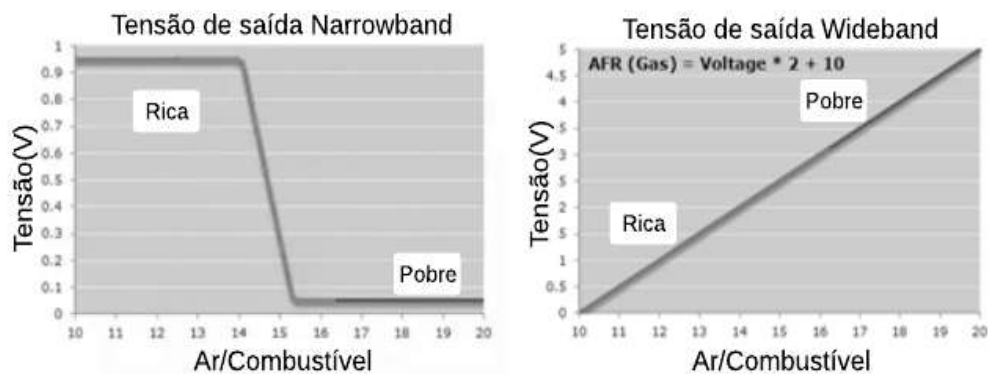


Figura 5 - Comparação Narrowband vs Wideband

Para obtenção de dados para treinamento e teste do modelo NARX, dados foram capturados para uma dada faixa de regime de operação do motor (500 rpm a 4500 rpm), com carga constante. A taxa de captura dos mesmos foi de 100ms, suficiente para as variações de interesse das variáveis envolvidas. Entre as variáveis capturadas foram selecionadas as que mais influenciaram o valor de λ durante pré-testes. Estas variáveis foram selecionadas como entradas do modelo. Como função não linear do modelo utilizou-se uma rede neural PMC

com uma camada escondida. Na camada escondida a função de ativação foi do tipo sigmoideal tangente (Haykin, 1999) e na camada de saída utilizou-se função de ativação linear.

Para facilitar o treinamento da rede neural, os dados de entrada da mesma foram normalizados entre -1 e 1. Os dados obtidos pelo *software* da injeção foram exportados para o Excel, onde foram realizadas as normalizações e outras operações de maneira a preparar os dados para uso no ambiente MATLAB.

Para treinamento da rede foi utilizado o modelo série-paralelo proposto por Narendra e Parthasarathy (1990). A vantagem de uso deste modelo é que os dados reais da variável estimada são utilizados como entrada do modelo NARX, de modo que se possibilita o treinamento da rede neural PMC utilizando-se métodos convencionais do algoritmo de retropropagação do erro aplicáveis a redes estáticas, sem realimentação (Haykin, 1999). A estimativa de um passo à frente utilizando esta filosofia é dada pela equação (3),

$$\hat{Y}_p(k+1) = f[Y_p(k), Y_p(k-1), \dots, Y_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)] \quad (3)$$

onde $\hat{Y}_p(k+1)$ é a estimativa de um passo à frente. A figura 6 ilustra a diferença entre o modelo série-paralelo e o modelo paralelo (em malha fechada). Tal filosofia é utilizada apenas para o treinamento, utilizando-se posteriormente o sistema NARX em malha fechada. Entretanto, a predição de um passo à frente pode ser interessante, quando temos disponível a variável de saída real e queremos realizar apenas uma predição da mesma.

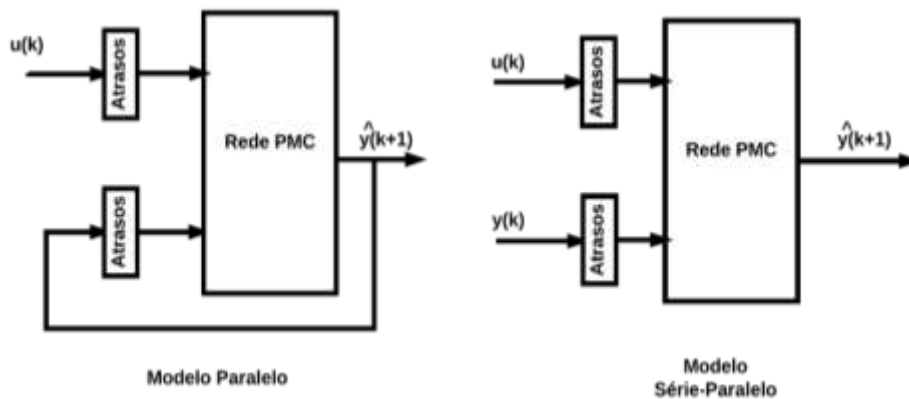


Figura 6 - Diagrama de redes paralelo e série-paralelo.

Para treinamento e verificação da rede PMC utilizada, e do próprio modelo NARX, foi utilizado o ambiente MATLAB, realizando a importação do arquivo gerado no Excel, com as variáveis medidas. No ambiente MATLAB foram usadas principalmente as funções *nnstart* e *nntool*, de forma a reduzir o trabalho manual de programação para criação e teste das redes neurais.

Como citado anteriormente foram realizados diversos testes no motor, com regimes alternados de rotação e posição da borboleta, porém sempre mantendo a carga constante no mesmo, assim como monitorando as variáveis envolvidas. Para determinação da rede neural, e portando do modelo NARX, sempre foram realizados treinamentos com uma faixa de dados diferente da utilizada para validação e testes, de modo a verificarmos a aprendizagem e generalização da rede e do modelo.

Resultados e Discussão

Apenas de maneira ilustrativa, a Figura 7 mostra as variáveis monitoradas e os valores da sonda λ . A ideia é apenas mostrar a variabilidade no tempo das grandezas envolvidas, objetivando ressaltar a dificuldade de aprendizagem do modelo.




Figura 7 - Software EcoCal: Datalogger

Tais dados, normalizados, foram usados para determinação do modelo. O modelo, não-linear, possui vários parâmetros a escolher, como a ordem dos atrasos nas variáveis de entrada e saída e o número de neurônios da camada escondida da rede neural. Escolheu-se a função sigmoidal tangente como função não linear pela mesma fornecer bons resultados em problemas envolvendo redes neurais (Duda et al., 2012) e uma função linear na saída para ter uma melhor faixa para os valores de λ .

Para a determinação do número de atrasos e número de neurônios da camada escondida, vários treinamentos e testes foram realizados de maneira a se encontrar um resultado satisfatório. Inicialmente buscou-se uma configuração do modelo série-paralelo com uma boa predição de um passo à frente. Resultado satisfatório foi obtido com uma rede de 10 neurônios na camada escondida e com atrasos de ordem 4 nas entradas da rede ($n=m=4$ na equação 3). A Figura 8 ilustra o modelo utilizado no MATLAB usando a ferramenta *nnstart*.




Figura 8 - Diagrama da rede série-paralelo (*nnstart*).

Com tais parâmetros o modelo foi treinado usando o método Bayesiano e utilizando-se uma parte dos dados obtidos. O processo de regularização Bayesiana minimiza uma combinação dos erros quadráticos e pesos da rede de maneira a melhorar a generalização. Como método de parada para o treinamento utilizou-se o de parada antecipada (Haykin, 1999). Testando-se tal modelo em outra faixa de operação do motor obteve-se um erro médio quadrático de 0,0011 e regressão de 0,962 entre os dados reais e os obtidos pelo modelo. Tais resultados foram considerados satisfatórios para predição de um passo à frente.

A Figura 9 ilustra os dados reais e do modelo sobrepostos e a Figura 10 apresenta os mesmos dados só que com o valor simulado deslocado de 1 unidade para facilitar a visualização.




Figura 10 - Dados reais e simulados sobrepostos




Figura 9 - Dados reais e simulados deslocados

Com a rede obtida, fechou-se a malha, como na Figura 11:




Figura 11 - Diagrama da rede fechada

Escolheu-se outra faixa de dados, não utilizados no treinamento, e verificou-se o uso do modelo em malha fechada para essa nova faixa. Note-se que neste caso não se tem mais dados reais na entrada da rede, sendo o próprio dado gerado pelo modelo sendo realimentado no mesmo. Nesse caso, de maior dificuldade que o anterior, o modelo forneceu um erro médio quadrático de 0,0067 e uma regressão de 0,319.

A Figura 12 ilustra os dados do modelo e do sensor real nessa nova faixa. Também, como indicado na figura, aplicou-se o modelo de um passo à frente nessa mesma faixa, para ilustração. Nota-se que mesmo em malha fechada o modelo obteve resultados satisfatórios.




Figura 12 - Dados reais e simulados deslocados, com menor faixa de amostra

A disparidade em algumas amplitudes obtidas pelos modelos acredita-se que possa ser eliminada aumentando o conjunto de treinamento, o qual não foi elevado (por volta de 2400 amostras) para a dificuldade do problema proposto. Nota-se que o modelo em malha aberta (série-paralelo) e em malha fechada forneceram resultados similares, o que mostrou ser efetivo o uso do modelo série-paralelo para treinamento, podendo-se, portanto, utilizar métodos de treinamentos de redes estáticas, muito mais simples que os para redes com realimentação. Salienta-se também que as diferenças entre o modelo obtido e o sensor real

ocorreram em regiões de grandes transitórios. Em regiões sem grandes variações abruptas (regimes de aceleração mais constantes), o modelo forneceu melhores resultados.

Conclusões e trabalhos futuros

O modelo proposto mostrou-se promissor quanto ao uso de um sensor lambda virtual, permitindo redução de custos de produção e melhoria na obtenção da relação λ , visto que na prática são utilizados sensores de banda estreita tipo *on-off* (mistura rica/pobre) menos precisos que os de banda larga.

Quanto a trabalhos futuros, pretende-se obter mais dados para treinamento, inclusive em condições de carga variável. Para tal, uma modificação no volante do motor foi projetada e está em fabricação para permitir que o mesmo possa ser conectado a um dinamômetro que controle o torque exigido do motor. Outro passo futuro é a substituição do sensor real obtido implementado em uma plataforma microprocessada, como o Arduino (Arduino, 2017), e verificar o funcionamento da injeção com o sensor virtual.

Referências Bibliográficas

- Aguirre, Luis Antonio. (2000) Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais. *Ed. UFMG*. 554 p. Belo Horizonte, MG.
- Amato, Paolo & Cesario, Nicola & di meglio, Maurizio & Pirozzi, Francesco. (2005). *Realization of a Virtual Lambda Sensor on a Fixed Precision System*. 192-197.
- ARDUINO. Disponível em: <<https://www.arduino.cc/>>. Acesso em: fevereiro de 2017.
- Duda, R.; Hart, E.; Stork, D. (2012) *Pattern Classification*. 2ª edição. John Wiley & Sons.
- ECOTRONS. Disponível em: <www.ecotrons.com>. Acesso em: fevereiro de 2017.
- HONDA ENGINES. Disponível em: <<http://engines.honda.com/models/model-detail/gx35>>. Acesso em: fevereiro de 2017.
- Haykin, Simon. (1999) *Neural networks: a comprehensive foundation*. 2ª edição. New Jersey: Prentice Hall.
- Lampinen, J. ; Vehtari, A. (2001) Bayesian Approach for Neural Networks – Review and Case Studies. *Neural Networks*, **14**, n. 3, 257-274.
- Narendra, K.S ; Parthasarathy, K. (1990) Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks*, **1**, 4-27.
- Richter, T. *Arquitetura de sistema inteligente para sensoriamento virtual de oxigênio em veículos bicomustíveis com injeção eletrônica*. 2009. Dissertação (Mestrado em Sistemas Dinâmicos) - Escola de Engenharia de São Carlos, University of São Paulo, São Carlos, 2009.
- Salehi, R; Alasti, A; Vossoughi, G; Boroushaki, M. (2010) Nonlinear Oxygen Sensor Output Voltage Estimation in a Gasoline Engine Using NARX Model. *The journal of engine research*, **22**. 13-20.

Turkson, R. (2016) Artificial neural network applications in the calibration of spark-ignition. *Engineering Science and Technology, an International Journal*, **19**, 1346-1359.

Young, R. *Utilization of a Neural Network to Improve Fuel Maps of an Air-Cooled Internal Combustion Engine*, 2010. 75p. Dissertação de mestrado - Russ College of Engineering and Technology of Ohio University, 2010.